

WPGEC

Anais do VI

**Workshop de Pós-Graduação
Engenharia de Computação**

23 de novembro

São Paulo
2017

Comissão Organizadora

Presidente: Profa. Dra. Solange Nice Alves de Souza
Prof. Dr. Pedro Luiz Pizzigatti Corrêa
Prof. Dr. Jorge Rady de Almeida Júnior
Profa. Dra. Anarosa Alves Franco Brandão
Ana Maria de Castro Badiali
Lesly Alejandra González Camacho
Lucas Alves Martins
Mariza Ushijima Leone
Renata Brasil Silva
Profa. Dra. Sandra Sayuri Sato
Vinicius Mauricio de Almeida

Comitê Científico

Profa. Dra. Anarosa A. F. Brandão (EPUSP)
Profa. Dra. Anna H. Reale Costa (EPUSP)
Profa. Dra. Cintia Borges Margi (EPUSP)
Dr. Cléber G. Corrêa (EACH-USP)
Prof. Dr. David Correa Martins Jr. (UFABC)
Prof. Dr. Edison Spina (EPUSP)
Prof. Dr. Fabio G. Cozman (EPUSP)
Prof. Dr. Fábio Levi Siqueira (EPUSP)
Prof. Dr. Fabrício Rodrigues (UFMS)
Profa. Dra. Fátima L. S. Nunes (EACH-USP)
Prof. Dr. Flávio S. C. Silva (IME-USP)
Prof. Dr. Hae Y. Kim (EPUSP)
Prof. Dr. Jaime S. Sichman (EPUSP)
Prof. Dr. João B. Camargo Jr. (EPUSP)
Prof. Dr. João J. Neto (EPUSP)
Prof. Dr. Jorge Rady Almeida Jr. (EPUSP)
Prof. Dr. Jorge Kinoshita (EPUSP)
Prof. Dr. Jorge L. Risco Becerra (EPUSP)
Prof. Dr. José Sidnei C. Martini (EPUSP)
Prof. Dr. Kechi Hiramã (EPUSP)
Prof. Dr. Lisandro Z. Granville (UFRGS)
Profa. Dra. Lucia V. L. Filgueiras (EPUSP)
Profa. Dra. Maria Alice G. Varella Ferreira (EPUSP)
Prof. Dr. Marcos A. Simplício Jr. (EPUSP)
Prof. Dr. Paulo Sérgio Cugnasca (EPUSP)
Prof. Dr. Pedro L. P. Corrêa (EPUSP)
Prof. Dr. Ricardo L. A. Rocha (EPUSP)
Prof. Dr. Romero Tori (EPUSP)
Profa. Dra. Solange N. A. Souza (EPUSP)



Catálogo na Publicação

Workshop de Pós-Graduação Engenharia de Computação

Anais do VI Workshop de Pós-Graduação em Engenharia de Computação – WPGEC, São Paulo, SP, 23 de novembro de 2017 / organizado por Solange N. A. Souza et al. – São Paulo: PCS/POLI/USP, 2017.

ISBN: 978-85-86686-99-3

1. Engenharia da computação. 2. Ciência da computação. 3. Ciência da informação. I. Universidade de São Paulo. Escola Politécnica. Programa de Pós-Graduação em Engenharia de Computação. II. Alves-Souza, Solange N. III. T.

CDD 621.39

POLI USP

USP

SCOPUS

Apoio



Apresentação

Este volume consiste dos resumos expandidos e das comunicações de publicações incluídos na 6ª edição do Workshop de Pós-Graduação em Engenharia de Computação (VI WPGEC 2017), realizado na Escola Politécnica da Universidade de São Paulo (EPUSP), no Prédio da Engenharia Elétrica da EPUSP no dia 23 de novembro de 2017 (pcs.usp.br/wpgec2017).

A EPUSP oferece diversos programas de Pós-Graduação – mestrado, doutorado e doutorado direto. Dentre eles está o de Engenharia Elétrica, cuja Área de Concentração “Engenharia de Computação” é de responsabilidade dos professores do Departamento de Engenharia de Computação e Sistemas Digitais (PCS/EPUSP), sendo o curso reconhecido e avaliado regularmente pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes), fundação do Ministério da Educação (MEC), com nota “6” (entre 1 e 7). A área de concentração Engenharia de Computação do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) conta com três linhas de pesquisa relacionadas a seguir. A) Sistemas de Informação e Aplicações Computacionais, envolvendo sistemas computacionais e banco de dados com aplicações relacionadas ao agronegócio, gestão de dados científicos, qualidade de dados, ambiente, logística, governo, metro-ferroviários, aeronáuticos, confiabilidade, segurança crítica, automação, sistemas complexos e Big Data. B) Organização de Sistemas Computacionais, envolvendo redes de computadores; desempenho de sistemas Computacionais; segurança da informação e de redes; arquitetura de computadores; sistemas dedicados; arquitetura e processamento paralelos. C) Metodologias de Computação envolvendo inteligência artificial, sistemas multiagentes, visão computacional, ciência dos dados, robótica inteligente, aprendizado de máquina, técnicas adaptativas, engenharia de conhecimento, computação gráfica, realidade aumentada, interação humano-computador e computação na educação.

O WPGEC tem por objetivo difundir as pesquisas e estimular a colaboração entre os alunos, pesquisadores e professores do PPGEE/EPUSP e a comunidade em geral.

Agradecemos imensamente a todos os participantes por compartilharem discussões sobre pesquisas desenvolvidas pelos pós-graduandos do PPGEE/EPUSP, contribuindo dessa maneira com a formação dos pesquisadores na área de Engenharia de Computação do programa.

São Paulo, 23 de novembro de 2017.

Profa. Dra. Solange Nice Alves de Souza
Presidente da Comissão Organizadora do VI WPGEC 2017

Agenda do WPGEC 2017

8:00	Credenciamento	
9:00	Sessão de Abertura	
9:30	Palestra convidada “A origem da inovação: da criação à difusão” Prof.Dr.Wilson Vicente Ruggiero, EPUSP Session Chair: Prof. Dr. Pedro Luiz Pizzigatti Corrêa	
10:00	Coffee Break Exibição e Avaliação de posters Session Chair: Prof. Dr. Kechi Hirama	
11:00	Apresentações de trabalhos selecionados Apresentação oral de trabalhos Session Chair: Profa. Dra. Lília Matsumoto Sato	Trabalho 5 (10min) Trabalho 39 (10 min) Trabalho 22 (10 min) Trabalho 37 (10 min) Trabalho 38 (10 min) Trabalho 26 (10 min) Trabalho 40 (10 min)
12:10	Recesso para Almoço	
13:30	Palestra convidada “Seleção de Revistas para publicação e Identificação do Pesquisador USP” Profa. Dra. Ana Maria de Castro Badiali Session Chair: Profa. Dra. Solange N. Alves de Souza	
14:10	Apresentações de trabalhos selecionados Apresentação oral de trabalhos Session Chair: Prof. Dr. Jorge Luis Risco Becerra	Trabalho 4 (10 min) Trabalho 11 (10 min) Trabalho 12 (10 min) Trabalho 25 (10 min) Trabalho 17 (10 min)
15:00	Coffee Break Exibição e avaliação de posters Session Chair: Prof. Dr. Jorge Rady de Almeida Júnior	
16:00	Sessão de Premiação e Encerramento	

Financiadores e Apoiadores

O WPGEC 2017 foi financiado pelas seguintes instituições:

- Scopus Soluções em TI
- Programa de Pós-Graduação de Engenharia Elétrica (PPGEE)

Apoio

- Departamento de Engenharia de Computação e Sistemas Digitais
- Vika Controls - Soluções de implementação de controle de processos

Organização

- Programa de Pós-Graduação de Engenharia Elétrica da Escola Politécnica da USP (PPGEE/EPUSP) - Área de concentração: Engenharia de Computação
- Departamento de Engenharia de Computação da Escola Politécnica da USP (PCS/EPUSP).

Prêmios

Serão selecionados 12 trabalhos de qualidade destacada (5 de mestrado , 7 de doutorado), dentre dos trabalhos enviados. Parte desses trabalhos serão selecionados pelo Comitê Científico do VI WPGEC.

Os participantes indicarão para serem premiados os trabalhos apresentados na forma de posters.

Local do Evento:

O VI WPGEC será realizado no Anfiteatro Prof. Paulo Ribeiro de Arruda e na sala C1-49 do Prédio de Engenharia Elétrica, localizado no seguinte endereço: Av. Prof. Luciano Gualberto, travessa 3, n°. 158, CEP. : 05508-010 - Cidade Universitária - São Paulo - SP.

Apresentação Oral

Horario	Numero	Categoria	Autores/ Título
11h00min 11h10min	5	Doutorado	André Proto e Tereza C. M. B. Carvalho. “A study of distance metrics for energy-based anomaly detection of IoT devices”.
11h10min 11h20min	39	Doutorado	Ruben Glatt e Anna Helena Reali Costa. “Knowledge Transfer with Case-based Policy Inference”.
11h20min 11h30min	22	Doutorado	Leila Cristina C. Bergamasco e Fátima L. S. Nunes. “3D medical objects processing and retrieval using Spherical Harmonics: a case study with Congestive Heart Failure MRI exams”
11h30min 11h40min	37	Mestrado	Leandro M. Ferreira e Solange Nice Alves de Souza. “Análise de Desempenho de Banco de Dados NoSQL Orientado a Família de Colunas”
11h40min 11h50min	38	Mestrado	Gabriel de Freitas Viscondi, Solange Nice Alves de Souza e Marcelo de Paulo Corrêa. “Machine Learning for Solar Photovoltaics Electricity Generation Forecasting: the influence of data quality and number of meteorological parameters on forecast accuracy”
11h50min 12h00min	26	Mestrado	Ligia Maria Moreira Zorello e Tereza Cristina Melo de Brito Carvalho. “Comparative Analysis of Matching Algorithms for Green D2D Communication”
12h00min 12h10min	40	Doutorado	Eduardo Alves e Anna Helena Reali Costa. “Integração de dados de múltiplos sensores RGB-D para reconstrução 3D utilizando técnicas de aprendizado por reforço”
14h10min 14h20min	4	Mestrado	Everton Rodrigues Reis e Jaime Simão Sichman. “PROFITS: A MultiAgent System for Stock Portfolio Management”
14h20min 14h30min	11	Doutorado	Jhonata Emerick Ramos, Hae Yong Kim e Felipe Tancredi. “Aprendizagem de máquina no controle de qualidade de RM”
14h30min 14h40min	12	Doutorado	Felipe Leno da Silva e Anna Helena Reali Costa. “Integrating Agent Advice and Previous Task Solutions in Multiagent Reinforcement Learning”
14h40min 14h50min	25	Doutorado	Suelane Garcia Fontes, Pedro Luiz Pizzigatti Corrêa e Silvio Luiz Stanzani. “Estratégia de exploração de dados espaço-temporais para a análise de interação entre o comportamento animal e o meio ambiente utilizando mineração de dados”
14h50min 15h00min	17	Mestrado	Ricardo M. Bertani, Reinaldo A. C. Bianchi e Anna H. R. Costa. “Combinando novidade e popularidade em recomendações personalizadas através do aprendizado do perfil do usuário”

ARTIGOS - MESTRADO

Transferring Probabilistic Partial Policies in Reinforcement Learning	
BONINI, R.C.; COSTA, A.H.R.	2
Avaliação Comparativa de Algoritmos de Aprendizagem, de Máquina Aplicados a Dados Bioclimáticos	
BARBOSA, W.L.; SOUZA, S.N.A.; CORRÊA, P.L.P.	6
Utilização de Dados de Redes Sociais como Abordagem para solução de Cold-start em Sistema de Recomendação	
GONZALEZ, L.A.C.; ALVES-SOUZA, S.N.	10
Learning the Parameters of Acyclic Probabilistic Logic Programs from Data	
FARIA, F.H.P.V.; GUSMÃO, A.C.; COZMAN, F.G.; MAUÁ, D.D.	15
Impacto das práticas de Engenharia de Requisitos na degradação da arquitetura de software em projetos usando XP	
SILVA, R.B.; SIQUEIRA, F.L.	19
Análise do impacto dos atributos de projetos de software na estimativa de esforço utilizando analogia	
SILVA, C.I.L.C.; BRANDÃO, A.A.F.; SIQUEIRA, F.L.	23
Controle Veicular Autônomo: estratégia para Prevenção de Acidentes no Contexto de Veículos Autônomos	
TANCREDI MOLINA, C.B.S.; ALMEIDA JR, J.R.	26
PROFITS: a MultiAgent System for Stock Portfolio Management	
REIS, E.R.; SICHMAN, J.S.	30
Combinando novidade e popularidade em recomendações personalizadas através do aprendizado do perfil do usuário	
BERTANI, R.M.; BIANCHI, R.A.C.; COSTA, A.H.R.	34
Comparative Analysis of Matching Algorithms for Green D2D Communication	
ZORELLO, L.M.M.; CARVALHO, T.C.M.B.	38

Análise de Desempenho de Banco de Dados NoSQL Orientado a Família de Colunas

FERREIRA, L.M.; SOUZA, S.N.A.

42

Machine Learning for Solar Photovoltaics Electricity Generation Forecasting: the influence of data quality and number of meteorological parameters on forecast accuracy

VISCONDI, G.F.; SOUZA, S.N.A.; CORRÊA, M.P.

46

ARTIGOS - DOUTORADO

- Técnicas de Processamento de Linguagem Natural para Análise e Classificação de Sentimentos Utilizando Filtragem por Emoji
SILVA, A.M.; ROCHA, R.L.A.; BASTOS, R.M. **50**
- Como a Regressão Linear pode melhorar o gerenciamento em Redes de Sensores Sem Fio Definidas por Software
LUZ, T.C.; MARGI, C.B. **53**
- Visualização 3D interativa de dados médicos temporais
SILVA, L.S.; NUNES, F.L.S.; NAKAMURA, R. **57**
- Impact assessment of uas operations on airport capacity applying contingency operations
BAUM, D.M.; NETO, E.P.; ALMEIDA JR., J.R.; CAMARGO JR., J.B. **61**
- Proposta de Arquitetura de Referência de Qualidade de Dados para Ambiente Analítico em Big Data
FRANCISCO, M.M.C.; SOUZA, S.N.A. **65**
- Modelo de Referência para a Fazenda Digital: Aplicação de Tecnologia de Virtualização em Processos de Agricultura
MOSTAÇO, G.M.; CUGNASCA, C.E. **69**
- Modelo de Conservação de Alimentos Baseado em Controle Adaptativo de Sistemas
KAWANO, B.R.; CUGNASCA, C.E. **73**
- Redes bayesianas aplicadas na análise de causalidade entre gravidez na adolescência e abandono escolar
CRUZ, E.; COZMAN, F. **77**
- Na Holistic Vision on Adaptivity
CAYA, R.E.C.; NETO, J.J. **80**
- Prediction of blood glucose in type 1 diabetics using a Hybrid Model based on Agents
PEREIRA, J.P.A.; BRANDÃO, A.A.F.; BEVILACQUA, J.S. **84**
- A study of distance metrics for energy-based anomaly detection of IoT devices

PROTO, A.; CARVALHO, T.C.M.B.	88
Aprendizagem de máquina no controle de qualidade de RM	
RAMOS, J.E.; KIM, H.Y.; TANCREDI, F.	92
Integrating Agent Advice and Previous Task Solutions in Multiagent Reinforcement Learning	
SILVA, F.L.; COSTA, A.H.R.	96
3D medical objects processing and retrieval using Spherical Harmonics: a case study with Congestive Heart Failure MRI exams	
BERGAMASCO, L.C.C.; ROCHITTE, C.E.; NUNES, F.L.S.	100
Estratégia de exploração de dados espaço-temporais para a análise de interação entre o comportamento animal e o meio ambiente utilizando mineração de dados	
FONTES, S.G.; CORRÊA, P.L.P.; STANZANI, S.L.	104
Knowledge Transfer with Case-based Policy Inference	
GLATT, R.; COSTA, A.H.R.	108
Integração de dados de múltiplos sensores RGB-D para reconstrução 3D utilizando técnicas de aprendizado por reforço	
ALVES, E.; COSTA, A.H.R.	112

COMUNICAÇÕES DE PUBLICAÇÃO

Energy Map Model for Software Defined Wireless	
NUÑEZ, G.A.; MARGI, C.B.	117
Evaluating Safety and Efficiency in Aircraft Sequencing in Final Approach considering	
PINTO NETO, E.C.; BAUM, D.M.; CUGNASCA, P.S.	118
Análise de Aspectos de Segurança (Safety) para a Inserção de Vants em um Espaço Aéreo não Segregado	
ALMEIDA, V.M.; CUGNASCA, P.S.	119
Discovery protocols for SDN-based Wireless Sensor Networks with unidirectional	
ALVES, R.C.A.; MARGI, C.B.	120
Applying Copeland Voting to Design an Agent-Based Hyper-Heuristic	
CARVALHO, V.R.; SICHMAN, J.S.	121
Enabling Data Legitimacy in Data-Driven Projects	
BATISTA, A.F.M.; SILVA, D.L.; CORRÊA, P.L.P.	122
ErgoMobile: a Software to Support Usability Evaluations in Mobile Devices using Observation Techniques	
COLETI, T.A.; CORRÊA, P.L.P.; MORANDINI, M.; SOUZA, L.S.; ALLARD, S.	123
Controlling Gene Regulatory Networks with FQI-SARSA	
NISHIDA, C.E.H.; COSTA, A.H.R.; BIANCHI, R.A.C.	124
Positional Information from Gnss/Gbas and its Safety-Critical	
BARALDI SESSO, D.; CAMARGO JR., J.B.; BALVEDI, G.C.; MELLO, M.P.	125
A review on aeronautical decision-making and artificial intelligence	
MATSUMOTO, T.T.; CAMARGO JR, J.B.	126

ARTIGOS
MESTRADO

Transferring Probabilistic Partial Policies in Reinforcement Learning

BONINI, Rodrigo Cesar*; COSTA, Anna Helena Reali*

*Intelligent Techniques Laboratory (LTI) - Escola Politécnica da USP

E-mail: {rodrigo_cesarb, anna.reali}@usp.br

Abstract—Reinforcement Learning is a tool for training intelligent agents, since learning takes place automatically. This learning is accomplished through repeated interactions between agents and the environment, often by trial and error, until agents obtain enough information to act appropriately and satisfactorily to solve a given task. However, the agent can take a long time to determine which actions are best suited for each task. One way to overcome this problem is through Knowledge Transfer solutions, where the knowledge acquired by an agent after training in a task can be reused to accelerate the learning of new tasks. Partial policies, which are partial solutions to learning problems, can be used to accelerate learning and transfer learned behaviors through tasks, encapsulating partial policies into actions. However, most solutions using partial policies are specific to a single task and ignore possible alternatives to good solutions. In addition, these solutions can be able to provide bad information to the agent, making learning even slower. Previous research has investigated alternative solutions to these problems, where Knowledge Transfer has also proved beneficial for domains where partial policy solutions are used. Thus, we add the idea of generalization in these solutions, also being possible to create several levels of abstraction within a problem, then allowing generic solutions to be obtained and their reuse in order to provide a faster learning. However, there is still a need for a maturation of existing methods to enable the implementation of partial policies in more complex and diversified tasks and domains. Therefore, this research aims to propose and investigate methods that address some questions that have been answered only superficially by the state of the art, among them: (i) *How to properly abstract the partial knowledge acquired in an apprenticeship?* (ii) *How can we reuse this knowledge?* (iii) *Is the reuse of stochastic partial policies really effective in learning new tasks?*

Keywords— Reinforcement Learning; Transfer Learning, Partial Policies, Multiobjective, Markov Decision Process.

I. INTRODUCTION

Reinforcement Learning (RL) [1] is a technique that allows autonomous agents to learn with interactions in the environment. An action that affects the environment is chosen by the agent, then the agent observes how much that action helped to the task completion through a reward function. An agent can learn how to optimally solve tasks by executing this process multiple times. Although RL has been successfully applied in many problems [2], [3], [4], RL algorithms learn very slowly.

The main problem when applying RL is that the classical algorithms learn very slowly through interactions of trial and error type, taking a very long time, because RL classical approach needs many steps to explore the state-action space. The problem is further intensified when the problem must

be described by multiple reward functions. The extension of the classical RL abstraction, Multiobjective Reinforcement Learning (MORL) [5], solves tasks with multiple reward functions $\{R_1, \dots, R_i\}$ by balancing all objectives as well as possible, considering the criteria informed by humans. So, as domains become progressively complex over the years, scalability gains more importance for these methods.

Many solutions were developed to minimize these problems, like the Transfer Learning (TL) and partial policies-based ones. The Framework of partial policies proposed in [6], which we are especially interested, has proposed an approach to tackle RL scalability issues. Partial policies offer a way to propose high-level actions that encapsulate sequences of actions performed by agents, which can be easily incorporated into a variety of different RL algorithms, accelerating their learning process. A partial policy may solve a subgoal in a RL problem and may contain a subset of optimal actions for certain states where the agent is. For instance, a partial policy in a indoor navigation domain could portray some or all the actions needed to move towards a door, unlock it, and open it.

TL solutions [7], which allow to reuse knowledge acquired in previous tasks, generalizing and transferring knowledge between domains, agents and tasks, thus accelerating learning in RL domains. Along with partial policies, TL can be used to reuse knowledge from previously learned tasks, or parts of these tasks[8]. In a playing instrument learning example, an agent being instructed by a good musician about how to play some chords and notes or observing its performance playing different previous songs can accelerate learning of several new songs, because this way the agent can identify its mistakes, some similarities between the activities and, of course, it can get some explanation and feedback from the musician, i.e, "transferring knowledge" acquired.

A framework proposed in [9] explores the idea that generalization from closely related, but solved problems can produce policies that provide good decisions in many states of a new unsolved task, because it avoids the possibility of a bad performance of a known policy in a new task, indicating that abstract and non-deterministic policies can offer an effective guidance to the agents. These benefits happen on the exploration strategy, so the algorithm converges much faster than without transfer of knowledge.

Another approach was proposed in [10] to probabilistically reuse a set of past deterministic policies that solve different

tasks within the same domain. It features an autonomously growing library of policies, which stores the most different policies in order to identify core policies of a domain that give the greatest advantage when solving a new task.

However, commonly these solutions are specific for a single-task, and may ignore some good and alternative solutions when this knowledge is transferred and reused in another task. Furthermore, these solutions may provide bad knowledge (negative) to the agent, making the learning process worse than without the use of this.

Hence, here we argue that the use of partial policies is better than full policies, since they represent parts of the solution, encapsulating required behaviors to solve many related tasks. Moreover, we argue that probabilistic partial policies are important knowledge to be transferred from one task to a new task, in order to assist the agent in its learning process

We here propose a multi-task method to combine learned partial policies into a probabilistic one in order to enable better choices to the agent, so it does not get stuck in certain regions or follows bad partial solutions.

Our initial experiments show that our proposal can autonomously learn useful probabilistic partial policies that improve learning for similar tasks.

II. OBJECTIVE

This research intends to investigate and to specify a new use for the existing methods of partial policy discovery, aiming at the reuse and better combination of partial policies of previously learned tasks in RL domains, in order to accelerate the current learning process of RL and TL algorithms.

Thus, the aim of this research is to provide a technique that allows for a better combination of partial policies and to apply it and compare it with RL techniques to accelerate TL among tasks, domains and agents.

III. FOUNDATION AND RELATED WORK

Many sequential decision problems may be modeled by a Markov Decision Problem (MDP), and RL is an extensively used solution for MDPs. An MDP is described by the tuple $\langle S, A, T, R \rangle$ [11], where S is the set of environment states, A is the set of actions available to an agent, T is the transition function, and R is the reward function, which gives a feedback toward task completion.

In the RL framework [1], an agent learns by interacting with an environment over a series of discrete time steps. In each decision step t , the agent observes the current state s_t and applies an action a_t . Then, the next state is defined by a transition probability function T (unknown by the agent in learning scenarios) and the agent receives a reward r_t . The agent goal in an MDP is to learn an optimal policy π^* that maps each state to the actions that leads to the greatest expected cumulative sum of rewards.

In learning problems (where R and T are unknown) the agent can iteratively learn a Q-table, for instance with the algorithm Q-Learning [12], a function that maps every pair of state and action to an estimate of the long-term reward.

It starts from the current state-action pair, that eventually converges to the true Q function: $Q^*(s, a) = E [\sum_{i=0}^{\infty} \gamma^i r_i]$, and Q^* can be used to define an optimal policy as $\pi^*(s) = \arg \max_a Q^*(s, a)$.

However, learning Q^* may take a long time, and so TL and partial policies methods can be used to accelerate its convergence. The basic idea in most of these algorithms is to reuse previously acquired knowledge in the same task or in a new task.

Before use TL in practice, some aspects must be defined [7]: **What**, **when**, and **how** to transfer. Although many methods have been developed, there is no standard definition of how to represent knowledge and how to transfer it. Thus, the success of a TL method depends on the knowledge representation. The standard MDP formulation is not always a good representation for knowledge abstraction, which is of extreme importance when transferring knowledge between two similar tasks.

Partial policy (also known as Option) for an MDP is a conditional sequence of primitive actions defined as a three-tuple, $\{ \pi, \mathcal{I}, \beta \}$, consisting of a **policy** ($\pi : S \rightarrow A$), a set of **initiation states** ($\mathcal{I} \subseteq S$), and a **termination condition** ($\beta : S \rightarrow [0, 1]$) [6]. The initiation set \mathcal{I} is the subset of the state space in which the partial policy can begin to be executed. In other words, a partial policy is available in state s_t iff $s_t \in \mathcal{I}$. When the partial policy initiation condition is satisfied and the agent selects it, the policy is followed until a termination condition is met. The termination condition β is a probability function over states that defines the likelihood with which the agent ends the execution of a partial policy when it is in that state. It may also be a time limit, that terminates deterministically when the execution of the partial policy reaches a certain number of episodes parametrized by designer [6]. Then, when a partial policy ends, the agent has the chance to select another partial policy, and this process repeats over time, executing it many times, until a goal state is reached. Another important point is that partial policies need not be continuous actions, but may be discontinuous and contain available actions for states that have no connection with each other.




Fig. 1. Example of task in the Gridworld Domain, where the circle represents the agent and the square the goal. Adapted from [13].

Partial Policies may be applied in many real-world domains, and can perform faster than classical RL algorithms, such as we are developing in this research. The *Gridworld* Domain is one particularly relevant domain (Figure 1). The main challenge of a task in this domain is to reach the goal state with

as few steps as possible. However, commonly partial policies algorithms are specific for a single-task, and may ignore some good and alternative solutions when it comes to TL solutions. Furthermore, these solutions may provide bad partial policies to the agent, sometimes making the learning process worse than without the use of partial policies.

Thus, we here propose a multi-task method to combine learned options into a probabilistic one in order to enable better choices to the agent, so it does not get stuck in certain regions or follows bad partial solutions.

We argue that the use of partial policies is better than policies since they represent parts of the solution, encapsulating behaviors necessary to solve many related problems. Moreover, we argue that probabilistic partial policies are important knowledge to be transferred from one task to a new task, in order to assist the agent in its learning process and can perform better than standard partial policies.

IV. PROPOSAL

Most of previously proposed partial policies-based methods are focused single-objective problems [8], [14]. Notwithstanding, MORL approaches attained good results in domains that have more than one objective, pondering tasks and these objectives [15], [5].

These algorithms, in general, were purposed to work along specific kinds of problems, not being able to solve general problems with the same quality. The *PolicyBlocks Algorithm* is an interesting partial policies discovery algorithm due to its versatility and good results in very different domains [8].

Aiming at accelerate learning in MORL problems, we introduced the framework MO-Opt, an approach for partial policy-discovery[16] and for TL with fixed state variables and actions in multiobjective domains according to humans preferences [17].

The main idea of MO-Opt is to learn partial policies for each of the objectives separately and apply these partial policies in the multiobjective problem, finally transferring the obtained knowledge to a new and different domain and reusing the acquired knowledge in previous tasks. The learned partial policies are intended to optimize a single objective, but may maximize multiple objectives for some situations, or at least guide the agent towards trajectories that maximize one objective without hampering the others, according to a human setting. The RL algorithm is able to identify when each partial policy is useful, and we argue that these partial policies can accelerate the learning process, guiding the agent's exploration to learn a given task faster.

There are many TL methods that can transfer knowledge between MDPs where the type of knowledge transferred can be primarily characterized by its specificity. In this work, we assumed that the state and action spaces are fixed for the source and target tasks, but the state transition function may vary [7].

Although we got some good results, commonly the learned partial policies were specific for a single-task, and sometimes

ignored some good and alternative solutions when the knowledge were transferred and reused in another too different task. Furthermore, in this case, these solutions provided some bad partial policies to the agent, making the learning process the same or worse than without the use of partial policies.

So, we propose a multi-task method hereafter called *Probabilistic Combined Options* (PCO) to combine learned partial policies into a probabilistic one in order to enable better choices to the agent, so it does not get stuck in certain regions or follows bad partial solutions.

The learned partial policies are intended to optimize the learning process in the target task, guiding the agent towards probably good trajectories, while allowing it to explore other new states.

The idea of PCO is to learn partial policies for each source task independently (for which the *PolicyBlocks* algorithm [8], for example, can be used) combine them and apply the combined probabilistic option in the target task.

Our proposal is fully described by Algorithm 1. Firstly it initializes a set of partial policies Φ . Then, it learns a set of suboptimal policies L_ψ for each source task $\psi \in \Psi$ by using a standard RL algorithm, where Ψ is the set of source tasks. After that, it uses the standard *PolicyBlocks Algorithm* (other partial policy-discovery algorithms may be used, but were not evaluated here) to learn a set of options for each source task independently (including them in Φ).

Algorithm 1 PCO

```

1:  $\Phi \leftarrow \emptyset$ 
2: for each source task  $\psi \in \Psi$  do
3:   for H episodes do
4:     learn a set of policies  $L_\psi$  for  $\psi$ 
5:      $\Phi \leftarrow \Phi \cup \text{PolicyBlocks}(L_i)$ 
6:   end for
7: end for
8:  $\Omega \leftarrow \text{combine}(\Phi)$ 
9: run learning in target task using  $\Omega \cup A$ 

```

Finally, the partial policies are combined into a probabilistic option Ω and the learning process is then executed in the target task with the resulting option Ω as another choice in the set of actions.

The partial policies are combined in a way that Ω selects actions with a probability according to the number of times that they appear in the previous partial policies, where the more the action appears, the greater its probability. Here, Ω executes each action with a probability given according to:

$$p(a|s)_\Omega = \frac{|\Phi(a|s)| + 1}{|\Phi_s| + |A|}, \quad (1)$$

where $p(a|s)_\Omega$ is the probability of action a being chosen by Ω in state s , $|\Phi(a|s)|$ is the number of options in Φ that select a in state s , and $|\Phi_s|$ is the number of options that are defined for state s . Here, the more an action appears in a certain state inside the discovered options, the greater is its chance of being chosen by the agent.

Our experiments in the *Gridworld* Domain show that our proposal learns useful partial policies that accelerate learning while also providing alternative decisions to the agent.

V. EXPERIMENTAL EVALUATION AND DISCUSSION

To evaluate our proposal, all the experiments were performed in a 11x11 *Gridworld Domain*, in which the agent starts in a random non-terminal state and must perform 6 source tasks (one task at a time) with a different goal position to be reached in each of them.

Firstly, the agent has to learn how to achieve the goal position as fast as possible independently in the 6 source tasks and the options for each task are discovered and stored.

We performed the Q-learning algorithm for 1000 episodes, providing 5 policies to *PolicyBlocks* extracts 3 options for each task. After that, those options Ω are combined and the resulting option is evaluated in 6 target (different) tasks.

The action set available after learning the options is $A = \{\textit{north}, \textit{south}, \textit{east}, \textit{west}\} \cup \Omega$. Episodes ends when the agent achieves the goal state, resulting in a reward of +1 discounted by $\gamma = 0.9$ and otherwise, the reward is 0 for any step. We also adopted the learning rate $\alpha = 0.2$.

In order to evaluate the relative effectiveness of the probabilistic learned options, we executed 1000 learning episodes using the Vanilla Q-Learning algorithm without options and 1000 learning episodes of our approach, PCO.

Figure 2 shows the average discounted reward in 1000 repetitions of the experiment. PCO outperformed the Regular Q-Learning, learning faster at the beginning of the learning processes, achieving an average reward of 0.30 after only 10 learning episodes.

The standard Q-Learning without options was not able to achieve similar results even after 1000 learning episodes.

This difference between the average cumulative reward indicates that PCO provides a speed-up in the learning process, greatly improving the performance in the initial learning episodes, while also providing alternative decisions to the agent.




Fig. 2. The average reward for 1000 episodes during the learning process.

The main contribution of this work is that the probabilistic partial policies combined provide to the agents good alternatives based on previous knowledge.

Our experiments in the *Gridworld Domain* showed that our approach is promising both for accelerating learning and guiding the agents to good solutions in RL domains.

In the future, we intend to evaluate the options before combine them, compare probabilistic partial policies with non-deterministic policies [9], human specialists knowledge [18] and multiobjective partial policies [17]. Finally, we also intend to evaluate the approach in more complex domains.

ACKNOWLEDGMENT

We are grateful for the financial support from CEST and CNPq (grant 311608/2014-0).

REFERENCES

- [1] SUTTON, R. S.; BARTO, A. G. *Reinforcement learning: An introduction*. 1st. ed. Cambridge, MA, USA: MIT Press, 1998.
- [2] AL., A. C. et. Autonomous inverted helicopter flight via reinforcement learning. In: *Experimental Robotics IX*. [S.l.: s.n.], 2006. p. 363–372.
- [3] SINGH, S. et al. Optimizing dialogue management with reinforcement learning: Experiments with the njfun system. *Journal of Artificial Intelligence Research*, p. 105–133, 2002.
- [4] MNIH, V. et al. Human-level control through deep reinforcement learning. *Nature*, Nature Publishing Group, v. 518, n. 7540, p. 529–533, 2015.
- [5] MOFFAERT, K. V.; DRUGAN, M. M.; NOWÉ, A. Scalarized multi-objective reinforcement learning: Novel design techniques. In: *IEEE. 2013 in ADPRL*. [S.l.], 2013. p. 191–199.
- [6] SUTTON, R. S.; PRECUP, D.; SINGH, S. Between mdps and semi-mdps: A framework for temporal abstraction in reinforcement learning. *Artificial intelligence*, Elsevier, p. 181–211, 1999.
- [7] TAYLOR, M. E.; STONE, P. Transfer learning for reinforcement learning domains: A survey. *The Journal of Machine Learning Research*, JMLR.org, p. 1633–1685, 2009.
- [8] PICKETT, M.; BARTO, A. G. Policyblocks: An algorithm for creating useful macro-actions in reinforcement learning. In: *ICML*. [S.l.: s.n.], 2002. p. 506–513.
- [9] KOGA, M. L.; FREIRE, V.; COSTA, A. H. R. Stochastic abstract policies: Generalizing knowledge to improve reinforcement learning. *Cybernetics, IEEE Transactions on*, IEEE, p. 77–88, 2015.
- [10] FERNANDEZ, F.; VELOSO, M. Probabilistic policy reuse in a reinforcement learning agent. In: *Proceedings of the Fifth International Joint Conference on Autonomous Agents and Multiagent Systems*. [S.l.]: ACM, 2006. p. 720–727.
- [11] PUTERMAN, M. L. *Markov Decision Processes: Discrete Stochastic Dynamic Programming*. 1st. ed. New York, NY, USA: John Wiley & Sons, Inc., 1994. ISBN 0471619779.
- [12] WATKINS, C. J.; DAYAN, P. Q-learning. *Machine learning*, Springer Netherlands, v. 8, n. 3, p. 279–292, 1992.
- [13] BONINI, R. C. et al. Transferring probabilistic options in reinforcement learning. In: *AAMAS-2017 Workshop in Transfer in Reinforcement Learning*. [S.l.: s.n.], 2017.
- [14] BERNSTEIN, D. S. *Reusing old policies to accelerate learning on new MDPs*. [S.l.], 1999.
- [15] KHAMIS, M. A.; GOMAA, W. Adaptive multi-objective reinforcement learning with hybrid exploration for traffic signal control based on co-operative multi-agent framework. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 29, p. 134–151, 2014.
- [16] BONINI, R. C.; SILVA, F. L. da; COSTA, A. H. R. Learning options in multiobjective reinforcement learning. In: *AAAI-17 Student Paper*. [S.l.: s.n.], 2017. p. (4708–4709).
- [17] BONINI, R. C. et al. Using options to accelerate learning of new tasks according to human preferences. In: *AAAI-17 Workshop Human-Machine Collaborative Learning*. [S.l.: s.n.], 2017. p. (1–8).
- [18] PENG, B. et al. A need for speed: Adapting agent action speed to improve task learning from non-expert humans. In: *Proceedings of the 2016 International Conference on Autonomous Agents and Multiagent Systems*. [S.l.: s.n.].

Comparative Evaluation of Machine Learning Algorithms Applied to Bioclimatic Data

Avaliação Comparativa de Algoritmos de Aprendizagem de Máquina Aplicados a Dados Bioclimáticos

BARBOSA, W. L. *; SOUZA, S. N. A. *; CORRÊA, P. L. P. G. *

*PCS - Engenharia de Computação e Sistemas Digitais - Universidade de São Paulo

{wesleyloubar@usp.br, ssouza@usp.br, pedro.correa@usp.br}

Abstract— The growing volume of information being collected about different climate and biodiversity parameters on the planet is feeding huge data sets. However, the data about the measurements of these ecological and climatic processes themselves are not informative enough, it is necessary to find efficient means to extract useful information and patterns from these data. Therefore, this research proposal aims to describe a study that can culminate in the proposition of an analysis methodology that allows the implementation and evaluation of the performance of machine learning algorithms applied to the analysis of the influence of climatological factors on the biodiversity of the Amazon region, using high-performance computing technologies. To achieve this, experimental tests of machine learning algorithms will be performed on single and parallel processing nodes. These tests will seek to define appropriate techniques and ways of increasing the computing power for these data. As a result, we expect to obtain a distributed processing model applied to climate and biodiversity data analysis using appropriate machine learning techniques. This model will help to integrate the field of biodiversity with that of data analysis and facilitate studies and understanding of the phenomena of the natural world.

Keywords— Machine learning; Biodiversity; Climatic Data; High Performance Computing; Distributed Processing; GOAmazon.

Resumo— O volume crescente de informações coletadas sobre os mais diferentes parâmetros climáticos e de biodiversidade no planeta está alimentando gigantescos conjuntos de dados. Porém, somente os dados sobre as medições desses processos ecológicos e climáticos não são suficientemente informativos, é necessário encontrar meios eficientes para extrair informações e padrões úteis a partir deles. Por isso, essa proposta de pesquisa tem como objetivo descrever um estudo que possa culminar na apresentação de uma metodologia de análise que permita implementar e avaliar o desempenho dos algoritmos de aprendizagem de máquina aplicados a dados bioclimáticos, em um ambiente de processamento paralelo. Para isso, testes experimentais dos algoritmos de aprendizagem de máquina serão realizados em nós de processamento simples e paralelos. Esses testes buscarão definir técnicas apropriadas e formas de escalonar o poder de computação para esses dados. Como resultado espera-se obter um modelo de processamento

distribuído aplicado à análise de dados climáticos e de biodiversidade utilizando técnicas adequadas de aprendizado de máquina. Esse modelo ajudará a integrar o campo da biodiversidade com o da análise de dados e facilitará os estudos e a compreensão a respeito dos fenômenos do mundo natural.

Palavras-chave— Aprendizado de máquina; Biodiversidade; Dados Climáticos; Computação de Alto Desempenho; Processamento Distribuído; GOAmazon.

Classificação—Mestrado.

Categoria— Iniciante.

I. INTRODUÇÃO

A quantidade de informações coletadas por redes de observação, expedições de campo, sensores de medição e coleções biológicas, está alimentando um gigantesco conjunto de dados sobre a biodiversidade no planeta. A tendência crescente de abertura de acesso a massivos conjuntos de dados ecológicos abre novas possibilidades para que técnicas de mineração de dados e aprendizado de máquina sejam aplicadas sobre tais conjuntos para a descoberta de novos conhecimentos. No entanto, os algoritmos tradicionais e as plataformas de processamento desses algoritmos são incapazes de lidar com o tamanho e complexidade que conjuntos de dados sobre biodiversidade apresentam, constituindo, assim, um grave empecilho para a análise e síntese desses dados. Por isso, simulações de desempenho dos algoritmos e a distribuição de cargas de trabalho em estações de alto desempenho podem ser a chave para contornar esse problema, permitindo que essa análise seja realizada e novos padrões e correlações sejam obtidos a partir de volumosos conjuntos de dados. Assim, o tema escolhido para este trabalho foi a análise comparativa de algoritmos de aprendizado de máquina aplicados a dados climáticos do projeto GOAmazon e escalabilidade para arquitetura de computação de alto desempenho para processamento de dados de biodiversidade.

Com esse trabalho, tentar-se-á explicar como os algoritmos de aprendizagem de máquina podem ser aplicados na busca por correlações entre dados complexos e heterogêneos de um repositório de dados climáticos com dados de biodiversidade.

Aredita-se que algoritmos de aprendizado de máquina, como o algoritmo de aprendizado por regras de associação, podem ajudar a determinar a natureza da relação entre diversos parâmetros de um repositório de dados climático, como o GOAmazon, com dados de biodiversidade, como o ICMBio. A mensuração do desempenho das correlações descobertas pode ser realizada por Máquina de Vetor Suporte (SVM), ou, ainda, utilizando medidas de utilidade como suporte e confiança. Com diversos dados sendo coletados, como aerossóis, dados radiométricos e propriedade de nuvens e superfície, a análise de dados pode ser utilizada para compreender como esses fatores impactam a biodiversidade local.

Assim, o objetivo da proposta deste trabalho é estabelecer um modelo de análise de dados bioclimáticos que permita o estudo da influência de fatores climatológicos na biodiversidade da região Amazônica. Para isso, faz-se necessário verificar como os algoritmos de aprendizagem de máquina podem ajudar a traçar aspectos de correlação entre os dados mensurados pelo projeto GOAmazon com dados de biodiversidade, por meio de simulação num ambiente de processamento computacional escalável.

II. JUSTIFICATIVA

Os fenômenos ambientais estão entre os mais desafiadores e intrigantes problemas do mundo científico. As características intrínsecas desses fenômenos, tais como escalabilidade, heterogeneidade e multidisciplinaridade, tornam os estudos voltados para essa área bastante complexos. Na área de biodiversidade, alguns projetos já disponibilizam enormes conjuntos de dados coletados para estudos. Mas, para tirar proveito desses dados é necessário definir quais são as melhores técnicas de aprendizado de máquina para analisá-los. Algumas áreas de estudo estão mais maduras com relação aos resultados que cada um dos algoritmos disponíveis pode oferecer, como é o caso do setor financeiro, conforme mostra os trabalhos de [4] e [12]. Com dados de biodiversidade, no entanto, uma revisão aprofundada para comparação entre os algoritmos ainda é necessária. A maioria dos estudos dessa área costumam empregar poucos algoritmos, como em [6], ou as análises são realizadas para aplicações muito específicas, como os trabalhos de [1] e [13]. A ideia de uma implementação e avaliação mais aprofundada de técnicas de aprendizado de máquina em dados de biodiversidade constitui-se uma área a ser explorada por esta pesquisa.

A descoberta de modelos que expliquem a correlação entre a presença ou ausência de uma espécie numa determinada área, de acordo com um cenário climático específico, por exemplo, pode constituir uma ferramenta de grande importância para entender como fenômenos climáticos afetam a biodiversidade local. Essa pesquisa é importante porque pretende investigar o uso de diferentes técnicas de aprendizagem de máquinas para modelar a distribuição potencial de espécies de plantas e animais na região de Manaus-AM, Brasil. Entende-se que cada técnica de aprendizagem de máquina é capaz de extrair representações diferentes das relações entre as condições ambientais e o perfil de distribuição das espécies. Por isso, a avaliação consistente de alguns algoritmos pode indicar as

técnicas mais promissoras para modelar a distribuição de espécies, e sua sensibilidade aos fatores de poluição.

Considerando que esse volume de dados a ser explorado pode ultrapassar vários petabytes de dados, faz-se necessário a utilização de recursos computacionais e de armazenamento de grande porte, bem como soluções de software flexíveis. A quantidade de trabalho demandada para o processamento desses dados está aumentando significativamente como consequência do refinamento das questões que são feitas sobre esses dados. Portanto, a geração e atualização de modelos que expliquem as correlações entre os dados exigirão um processamento paralelizado e distribuídos para obter os resultados em um tempo útil. A escolha por essa abordagem de processamento em arquiteturas de alto desempenho deve-se ao fato de que, conforme apontado por [10], os algoritmos de aprendizado de máquina precisam ser altamente eficientes e paralelos, e, para tanto, demandam ecossistemas que tirem proveito dessa capacidade. É necessário considerar essa escalabilidade para grandes conjuntos de dados, dada a complexidade computacional que eles apresentam, criada pela necessidade de um número de exemplos de treinamento para os modelos, o que torna impraticável o processamento por arquiteturas locais [10]. O desafio para a pesquisa deste trabalho é apresentar uma metodologia ou estratégia eficiente que seja capaz de analisar os dados climáticos e sobre o meio ambiente, e, dinamicamente, explorar uma infraestrutura de computação de alto desempenho para lidar com as características desses dados, nomeadamente: volume, distribuição, velocidade e heterogeneidade.

Os resultados dessa pesquisa poderão melhorar a capacidade da comunidade científica de aprender e implementar os conceitos, metodologias, técnicas e ferramentas necessárias para aproveitar plenamente esta nova era do big data.

III. CIÊNCIA BASEADA EM DADOS E GOAMAZON

Cientistas passaram vários séculos criando e aperfeiçoando metodologias de estudos para compreender melhor os eventos que eles desconheciam [2]. Nos estudos ambientais não foi diferente. Muitas pesquisas em biodiversidade foram realizadas na tentativa de identificar, prever e explicar padrões na quantidade e distribuição de organismos do planeta [5]. No entanto, o modelo tradicional de pesquisa científica não permite o entendimento adequado das características dinâmicas dos ecossistemas terrestres.

Como os ecossistemas no planeta são entidades dinâmicas, cujo comportamento está sempre se adaptando, pesquisas do tipo expert-driven (orientada por especialistas) não conseguem acompanhar essas mudanças e podem ser tornar obsoletas rapidamente. Para suprir a necessidade de descoberta conhecimentos e padrões em complexos sistemas de biodiversidade, foi introduzido um novo paradigma para estudos em biodiversidade baseado em dados, conhecido como data-driven. Segundo [5], “estudos de biodiversidade orientados por dados são necessários devido à complexidade dos sistemas ecológicos, particularmente quando vistos em grandes escalas espaciais e temporais”.

A forma como a ciência ambiental vem sendo feita foi profundamente alterada nas últimas duas décadas. Essas mudanças são consequências diretas da evolução da tecnologia, a partir da qual o custo de armazenamento de informações foi drasticamente reduzido, o poder de processamento aumentou exponencialmente, a melhoria notável na qualidade dos softwares e a disseminação de acesso a internet. No campo da biodiversidade, redes de observação, expedições de campo, plataformas sensores ambientais e digitalização de pesquisas ecológicas, aumentaram significativamente a quantidade de dados disponíveis para análise. Esses dados podem fornecer informações valiosas para extrair padrões e provar hipóteses sobre os processos ecológicos observados, aprimorando de forma consistente a compreensão do mundo natural.

Algumas iniciativas surgiram para oferecer infraestrutura de armazenamento, coleta e disponibilidade de dados de biodiversidade. Por exemplo: Dynamic Ecological Information Management System - Site and dataset registry (DEIMS-SDR), Building the European Biodiversity Observation Network (EU BON), Integrated Biodiversity Assessment Tool (IBAT), Fresh Water Biodiversity Portal (FWBP), Data Observation Network for Earth (DataONE), Atmospheric Radiation Measurement (ARM), Green Ocean Amazon (GOAmazon). Muitos desses buscam agregar dados espaciais e temporais e disponibilizar acesso aberto aos dados e meta-dados em repositórios públicos, que permitem que a comunidade de cientistas utilize esses resultados para refinar a teoria com experiências adicionais, desenvolver novas teorias e realizar novas análises [9]. O Green Ocean Amazon (GOAmazon) é um experimento integrado que busca obter dados sobre sistemas terrestres-atmosfera-nuvem na Amazônia brasileira. O experimento foi projetado para permitir o estudo de como os aerossóis e os fluxos de superfície influenciam os ciclos da nuvem, bem como a forma como os ciclos de vida de aerossóis e nuvens são influenciados pela emissão de poluentes de uma grande cidade [7]. O experimento GoAmazon procura entender “como os ciclos de vida de aerossóis e nuvens são influenciados pela saída de poluentes de Manaus na floresta tropical” [8]. Para [8], essa influência é focada na “susceptibilidade das interações nuvem-aerosol-precipitação e o comportamento entre o funcionamento da biosfera, da atmosfera e das atividades humanas”.

IV. APRENDIZADO DE MÁQUINA PARA ESTUDOS DE BIODIVERSIDADE

As ciências naturais estudam interações complexas entre sistemas bióticos e abióticos para compreender e prever o resultado dessas interações [11]. Nesse contexto, a aprendizagem de máquina pode ser utilizada para encontrar padrões e ajudar a entender as correlações entre esses fatores. [14] afirma que o aprendizado apresenta uma importante vantagem sobre as técnicas estatísticas tradicionais: a capacidade de modelar dados multidimensionais e não lineares que apresentam interações complexas. Métodos tradicionais da estatística assumem uma certa linearidade dos dados tornando-se incapazes de identificar com clareza os efeitos das correlações dos dados. Essa é uma importante limitação da estatística tradicional, especialmente se aplicada à dados

ecológicos que tendem a apresentar grande complexidade nas interações entre os elementos, além de não serem lineares e possuírem grandes dimensões.

Segundo [11], “vários estudos comparativos já mostraram que as técnicas de aprendizado de máquina podem superar as abordagens estatísticas tradicionais em uma grande variedade de problemas de ciências da terra e na ecologia”. No entanto, [3] defende que a comparação de técnicas pode ser bastante complexa e requer cuidadosa consideração na parametrização dos fatores que definem a adequabilidade de uma técnica para uma determinada aplicação.

A premissa básica do aprendizado de máquina, seja o algoritmo ou modelo, é a capacidade de fazer previsões baseadas em dados. Grande parte dos algoritmos de aprendizagem de máquina funcionam de maneira iterativa. Isso quer dizer que o algoritmo vai realizar um gigantesco número de iterações para verificar todas as possíveis saídas e encontrar aquela que melhor se encaixa com algum parâmetro definido para o problema em questão. Por mais que o poder de computação tenha evoluído muito, a natureza iterativa desses algoritmos pode tornar o tempo de processamento proibitivo para determinadas aplicações. Em estudos de biodiversidade, nos quais muitas vezes a análise precisa ser feita em muitos terabytes de dados, é simplesmente inviável executar isso em computadores comuns. Para contornar essa limitação é necessário buscar formas de escalonar o poder de processamento para esses dados.

De acordo com [14], a disponibilidade da computação de alto desempenho e a maturação da internet abriram uma gama de possibilidades para processamento de grandes conjuntos de dados. Por isso, a computação de alto desempenho pode colaborar para facilitar o processamento de big data. No entanto, muitos desafios de pesquisa ainda precisam ser superados. É necessário definir estratégias para a escalabilidade do poder de processamento, de forma que este possa lidar com dados não estruturados e com as características do big data (volume, velocidade e variedade), garantindo desempenho computacional em ambientes distribuídos híbridos.

V. METODOLOGIA

Para o desenvolvimento desse trabalho serão utilizadas diferentes abordagens de pesquisa: a bibliográfica, para o estudo e compreensão teórica das técnicas de aprendizagem de máquina; e a descritiva para entender os aspectos (variáveis) envolvidos nos fenômenos. Quanto ao procedimento de coleta de dados, essa pesquisa se caracterizará como experimental, para verificar as relações de causalidades que se estabelecem entre as variáveis climáticas e de biodiversidade, e mensurar o desempenho dos algoritmos e da plataforma de processamento paralelo.

Os principais objetos de estudo deste trabalho serão os repositórios de dados do GOAmazon e do ICMBio, assim, será necessário analisar a estrutura dos dados para identificar os parâmetros para estudo. A escolha por essas bases dá-se em virtude de possuírem os dados necessários para o desenvolvimento dessa pesquisa, o GOAmazon com dados climáticos e o ICMBio com os dados de biodiversidade.

REFERÊNCIAS

Depois da análise da estrutura, será realizada a obtenção dos dados, amostragem, a partir da qual os testes serão realizados. Quanto ao procedimento de coleta de dados, essa pesquisa se caracterizará como experimental, para verificar as relações de causalidades que se estabelecem entre as variáveis climáticas e de biodiversidade, e mensurar o desempenho dos algoritmos e da plataforma de processamento paralelo. Será necessário passar por todas as etapas de análise de dados, com ênfase na etapa de avaliação da qualidade dos dados, removendo eventuais dados duplicados e inconsistentes. Com a ajuda de um especialista, hipóteses de correlações serão levantadas para serem testadas pelos algoritmos. A partir dessa etapa, a execução da análise dos dados será realizada numa plataforma escalável. A execução se dará a partir dos algoritmos já disponíveis na plataforma, utilizando um único nó para processamento. Os resultados serão, então, avaliados. A avaliação se dará por meio da análise objetiva de utilidade dos resultados. A mensuração objetiva envolve parâmetros estatísticos como suporte e confiança. Permitindo determinar os algoritmos com resultados mais consistentes.

A segunda etapa consistirá na extensão dos algoritmos para processamento paralelo. Novos testes serão efetuados para gerar resultados que podem apontar a vantagem de utilização de computação de alto desempenho para o processamento de dados de biodiversidade. Em seguida, as correlações entre dados climáticos e de biodiversidade poderão ser utilizadas para obter conclusões sobre os efeitos da poluição emitida por uma grande cidade na biota local.

Os parâmetros para mensuração dos resultados serão definidos com o auxílio de algum profissional da área de ciências biológicas. Esses parâmetros serão utilizados para comparar o desempenho dos algoritmos antes e após implementação do processamento paralelo paralela e se os modelos gerados pelos algoritmos são consistentes com o esperado. Assim, será possível mensurar o ganho de performance; e melhoria dos resultados gerados.

Por fim, buscar-se-á explicar as vantagens desse processo para processamentos de dados bioclimáticos e, principalmente, verificar a possibilidade de generalizar essa abordagem para o desenvolvimento de um modelo que possa ser aplicado a outros repositórios de dados.

VI. RESULTADOS ESPERADOS

Ao longo do desenvolvimento da pesquisa, vários algoritmos serão testados com um conjunto de dados reais de biodiversidade. Os algoritmos podem não funcionar como o esperado, sendo necessário modificá-los e adaptá-los para se adequar melhor ao teste em questão. Como corolário final, espera-se obter resultados que permitam uma comparação estatística das performances dos diferentes algoritmos aplicados nos dados. É provável que determinada abordagem proporcione uma previsibilidade significativamente maior que as demais, ou ainda, no contexto de compreensibilidade dos modelos, alguns algoritmos podem gerar resultados que, embora não sejam tão precisos, são mais úteis para a compreensão humanas dos modelos gerados.

- [1] APPELHANS, Tim et al. Evaluating machine learning approaches for the interpolation of monthly air temperature at Mt. Kilimanjaro, Tanzania. **Spatial Statistics**, [s.l.], v. 14, p.91-113, nov. 2015. Elsevier BV. Disponível em: <<http://dx.doi.org/10.1016/j.jspasta.2015.05.008>>. Acesso em: 10 nov. 2017.
- [2] CERVO, A. L.; BERVIAN, P. A. **Metodologia Científica**. 5. ed. São Paulo: Prentice Hall, 2002.
- [3] FIELDING, Alan H.. **Cluster and Classification Techniques for the Biosciences**. New York: Cambridge University Press, 2007. Disponível em: <<http://dl.acm.org/citation.cfm?id=1208655>>. Acesso em: 21 set. 2017.
- [4] GERLEIN, Eduardo A. et al. Evaluating machine learning classification for financial trading: An empirical approach. **Expert Systems with Applications**, [s.l.], v. 54, p.193-207, jul. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.eswa.2016.01.018>. Disponível em: <http://irep.ntu.ac.uk/id/eprint/28062/1/PubSub5574_McGinnity.pdf>. Acesso em: 10 nov. 2017.
- [5] KELLING, Steve et al. Data-intensive Science: A New Paradigm for Biodiversity Studies. **Bioscience**, [s.l.], v. 59, n. 7, p.613-620, jul. 2009. Oxford University Press (OUP).. Disponível em: <<http://dx.doi.org/10.1525/bio.2009.59.7.12>>. Acesso em: 10 set. 2017.
- [6] MAINA, Ciira Wa. Bioacoustic approaches to biodiversity monitoring and conservation in Kenya. **2015 Ist-africa Conference**, [s.l.], maio 2015. IEEE. <http://dx.doi.org/10.1109/istafrica.2015.7190558>. Disponível em: <<http://ieeexplore.ieee.org/document/7190558/>>. Acesso em: 10 nov. 2017.
- [7] MARTIN, S. **Observations and Modeling of the Green Ocean Amazon: Year -to -Year Differences**. Us Department Of Energy, 2013. 37 p. Disponível em: <<https://www.arm.gov/publications/programdocs/doe-sc-arm-13-009.pdf?id=28>>. Acesso em: 05 out. 2017.
- [8] NETTO, Paulo Eduardo Artaxo et al. **Interaction Between Urban and Forest Emission in Manaus, Amazonia: The Brazilian Component of GoAmazon**. São Paulo: Fapesp, 2013. 40 p. Disponível em: <http://lfa.if.usp.br/uploads/Proj/GoAmazonPaulo/GoAmazon_Paulo.pdf>. Acesso em: 05 out. 2017.
- [9] PETERS, Debra P. C. et al. Harnessing the power of big data: infusing the scientific method with machine learning to transform ecology. **Ecosphere**, [s.l.], v. 5, n. 6, jun. 2014. Wiley-Blackwell. Disponível em: <<http://dx.doi.org/10.1890/es13-00359.1>>. Acesso em: 16 set. 2017.
- [10] PINO, Robinson et al. **Machine Learning and Understanding for Intelligent Extreme Scale Scientific Computing and Discovery**. Rockville, Md: Doe Ascr, 2015. 59 p. 59 f. Disponível em: <https://www.ora.gov/machinelearning2015/Machine_Learning_DOE_Workshop_Report_6.pdf>. Acesso em: 10 nov. 2017.
- [11] PRINGLE, Elizabeth G.. Orienting the Interaction Compass: Resource Availability as a Major Driver of Context Dependence. **Plos Biology**, [s.l.], v. 14, n. 10, 12 out. 2016. Public Library of Science (PLoS).. Disponível em: <<http://dx.doi.org/10.1371/journal.pbio.2000891>>. Acesso em: 01 out. 2017.
- [12] ROBLES-GRANDA, Pablo D.; BELIK, Ivan V.. A Comparison of Machine Learning Classifiers Applied to Financial Datasets. In: WORLD CONGRESS ON ENGINEERING AND COMPUTER SCIENCE, 1., 2010, San Francisco. **Proceedings...**. San Francisco: Wcecs, 2010. Disponível em: <http://www.iaeng.org/publication/WCECS2010/WCECS2010_pp454-459.pdf>. Acesso em: 10 nov. 2017.
- [13] SHARMA, Ram C.; HARA, Keitarou; HIRAYAMA, Hidetake. A Machine Learning and Cross-Validation Approach for the Discrimination of Vegetation Physiognomic Types Using Satellite Based Multispectral and Multitemporal Data. **Scientifica**, [s.l.], v. 2017, p.1-8, 2017. Hindawi Limited. Disponível em: <<http://dx.doi.org/10.1155/2017/9806479>>. Acesso em: 10 nov. 2017.
- [14] THESSEN, Anne. Adoption of Machine Learning Techniques in Ecology and Earth Science. **One Ecosystem**, [s.l.], v. 1, p.01-31, 27 jun. 2016. Pensoft Publishers. Disponível em: <<http://dx.doi.org/10.3897/oneeco.1.e8621>>. Acesso em: 20 set. 2017.

Using Social Network Data as Approach to Cold-start Solution in Recommendation System

Utilização de Dados de Redes Sociais como Abordagem para Solução de Cold-start em Sistema de Recomendação

GONZALEZ, L. A. C.*; ALVES-SOUZA, S. N.*

*Laboratório de Tecnologias de Software – Escola Politécnica – Universidade de São Paulo
alejandrage@usp.br, ssouza@usp.br

Abstract— Recommender systems are intended to help the user to find items (products, documents, information, and services) that might interest him. As the recommendation is based on user data, in cold-start scenarios, where do not exist information about the user, the recommendation turns into a complex problem. The cold-start problem has received enough attention and several proposals have been presented in the literature, however, there is still no solution that can be applied to any domain or situation. In this scenario, data extracted from social networks is a valuable source of information that enables assertive recommendations for the user. This work presents a solution for cold-start context using only data extracted from social networks.

Keywords— *Recommender Systems; Collaborative Filtering, Social Networks; Cold-Start*

Resumo— Sistemas de recomendação tem o propósito de auxiliar o usuário a encontrar artefatos (produtos, documentos, informações e serviços) que podem interessá-lo. Como a recomendação se baseia em dados sobre o usuário, em cenários de *cold-start*, onde não existem informações disponíveis sobre mesmo, a recomendação se torna um problema de maior complexidade. O problema de cold-start tem recebido bastante atenção e várias propostas têm sido apresentadas na literatura, contudo ainda não existe uma solução que possa ser aplicada a qualquer domínio ou situação. Neste cenário, dados extraídos de redes sociais são uma fonte de informação valiosa que possibilita recomendações assertivas para o usuário. Este projeto apresenta uma solução para o contexto de cold-start utilizando somente dados extraídos de redes sociais.

Palavras-chave— *Sistemas de Recomendação; Filtragem Colaborativa; Redes Sociais; Cold-start*

Classificação— *Mestrado*
Categoria— *Iniciante*

I. INTRODUÇÃO

O crescimento excessivo e variado de informação disponível na Web, junto como a rápida evolução dos

serviços de e-commerce (e.g. Amazon, Ebay) e web sites de streaming online (e.g. Netflix, Spotify) tem aumentado o interesse e desenvolvimento de Sistemas de Recomendação (RSs, *Recommender Systems*) que visam a personalização de conteúdo de cada usuário para reduzir a sobrecarga de informação cognitiva [1]. Considerando a era atual do Big Data, com a explosão diária de dados, os RSs precisam processar essa maior quantidade de dados em tempo apropriado para recomendações efetivas ao usuário.

O objetivo principal deste trabalho é desenvolver um modelo de recomendação baseado em Filtragem Colaborativa (CF, *Collaborative Filtering*) para usuários *cold-start*, extraindo para tal informações das redes sociais do usuário e de seu grupo de amigos.

A. Sistemas de Recomendação

RSs são sistemas de processamento de informação que coletam diferentes tipos de dados (sobre itens e usuários que receberão a recomendação) para construir sua recomendação [2]. De forma geral, os RSs utilizam modelos sobre preferências do usuário e o tipo de itens como fatores representativos de características latentes usuário-item no sistema. O modelo posteriormente é treinado usando dados de classificação para prever as avaliações dos usuários sobre alguns novos itens [2].

Os RSs geralmente são classificados como: Filtragem Colaborativa (CF), Baseado em Conteúdo (CB, *Content-based Filtering*), Filtragem Demográfica (DF, *Demography Filtering*) e Filtragem Híbrida (HF, *Hybrid Filtering*)[2]. Em CF se tenta prever a avaliação de um item para um usuário específico com base nas avaliações

anteriores deste item por outros usuários similares [3]. Em CB, a avaliação de um item para o usuário é estimado com base nas avaliações de itens semelhantes já adquiridos por este usuário. DF baseia-se no princípio de que os usuários com determinados atributos comuns, como gênero, idade, nível de educação, entre outros, têm preferências comuns. HF combina duas ou mais abordagens de filtragem para o processo de recomendações [4] [5].

Abordagens por CF por incorporarem interações de outros usuários, aumentando as informações disponíveis e possibilitando maior eficiência na recomendação, têm sido mais amplamente empregadas. Este é o caso dos sistemas comerciais da Netflix e Amazon. Também identificam-se maior quantidade de pesquisas sobre CF [3], [6], [7]. Por essas razões, juntamente com os resultados obtidos em [8], CF é empregada neste trabalho.

B. Os problemas de data sparsity e cold-start

Apesar dos avanços em RSs, alguns problemas como *data sparsity* e *cold-start* ainda permanecem em aberto, por não terem uma solução que atendam as diferentes necessidades [9]–[11]. *Data sparsity* ou dispersão dos dados se caracteriza pelo baixo número de avaliações aos itens disponíveis, o que dificulta encontrar uma relação entre usuários e itens [12]. *Cold-start* é quando o RS não consegue recomendar algum item de interesse para um usuário novo, devido a falta de avaliações de itens por esse usuário. Assim, o sistema não consegue avaliar suas preferências [5], [12]. O trabalho aqui apresentado centra seus estudos no problema de *cold-start*.

Na atualidade as redes sociais (ex. *Facebook*, *Twitter*, *Instragram*) fazem parte das atividades diárias das pessoas, que as usam para se comunicar, colaborar e compartilhar informações com outras pessoas [12]. As redes sociais por serem de natureza dinâmica permitem que as informações disponíveis nessas plataformas sejam de grande valor para identificar as interações sociais, as relações de confiança entre usuários e a influência de usuários sobre outros [13].

Incorporar dados das redes sociais nos RSs, como informação complementar para suprir a escassez dos dados sobre as preferências do usuário, podem auxiliar o processo com recomendações e também a mitigar o problema de *cold-start* [14], [15], [8] culminando em maior satisfação por parte do usuário.

II. ESTADO DA ARTE

Na última década, uma linha ativa de pesquisa para resolver as dificuldades associadas aos problemas citados e que propõe uma variedade de técnicas tem se evidenciado na literatura. Tais trabalhos abordam diferentes domínios de recomendação, das mais típicas como filmes [16], [17] até recomendações de sítios de interesse [12], [18], programas de televisão [19], notícias online [20] e grupos de estudo virtual [21], entre outras.

Por exemplo, [8] implementa um RS baseado em Conteúdo (CB), usando as informações extraídas das redes sociais *Facebook* e *Twitter*. Nessa proposta os autores utilizam as postagens diretas do usuário (curtidas em conteúdo e curtidas em páginas) como única fonte de dados para usuário cold-start. Para os autores, como na proposta desta deste artigo, um cold-start, é um usuário completamente novo e para qual não se tem nenhuma informação, além das obtidas por suas redes sociais quando as utiliza para acesso ao sistema de recomendação. Seus resultados mostram que o emprego de dados das redes sociais podem ser uma boa fonte de dados para mitigar o *cold-start*.

[22] estende [8], alterando o fluxo de recomendação para avaliar o sentimento contido nas postagens do usuário. Em sua proposta, postagens que exprimem sentimento negativo são descartados, sendo utilizado, somente as postagens com valência positiva para a recomendação. Os resultados reafirmam que o emprego de dados de redes sociais como única fonte de dados para usuários cold-start realmente auxiliam na melhora de recomendações.

[12] desenvolve uma estratégia para prever sítios de interesse baseada nas preferências coletadas do usuário como check-in realizados, localização e opiniões sociais colaborativas (preferências de outros indivíduos). Novas recomendações são feitas para o usuário ou para um grupo de usuários, não somente sobre sítios que seu grupo de amigos já visitou, mas também para oferecer um conjunto de opções mais amplas que poderiam ser de seu interesse. A abordagem seguida nesta pesquisa incorpora as informações das redes sociais como suporte para determinar um perfil de usuário. No entanto, esta estratégia só é testada para mitigar a dispersão dos dados, e não mostra nenhum resultado para o problema de *cold-start*.

Algumas pesquisas como [19], [23] determinam o nível de relacionamento do usuário baseado no número de posts compartilhados na sua rede social com um

amigo em particular, ou no grupo que simplesmente compartilham o mesmo tipo de informação. Esse tipo de comportamento é assumido como laço de amizade mais forte e é de grande relevância na avaliação dos itens a recomendar para um usuário *cold-start*, para o qual não se tem nenhuma informação.

Esta pesquisa dá continuidade ao trabalho desenvolvido por [8] e [22] que obtiveram resultados positivos ao empregar dados das redes sociais do próprio usuário no RS. Diferentemente de [8] e [22], nesta pesquisa estende-se o uso das informações das redes sociais à rede de amigos, empregando-se assim abordagem por CF na recomendação. Espera-se melhorar a precisão das recomendações dos usuários *cold-start*.

III. CONTRIBUIÇÃO

Especificamente espera-se implementar um CF-RS voltado para música. A proposta, inclui o emprego de informações das redes sociais dos usuários e de sua rede de amigos, analisando cuidadosamente o tipo de relacionamento ou grau de confiança, através do comportamento de “likes” entre o usuário e seus amigos sobre música ou compartilhamento de informação (“posts”) sobre artistas e música, com o intuito de descobrir aquele conjunto de amigos que são mais influentes nas decisões e preferências do usuário. Tais informações serão utilizadas para determinar padrões de preferências de música. A escolha dos algoritmos de aprendizado de máquina (ML, *Machine Learning*) e mineração de textos (DM – *Data Mining*), definição do processo de recomendação e estratégia para recuperação dos dados sociais fazem parte da proposta.

Acredita-se que aumentar o espectro da coleta de dados das redes sociais pode melhorar significativamente os resultados, alinhado à estratégia para a identificação do grupo de amigos com maior conexão e à técnica (processo e algoritmos) empregada. Em outras palavras, espera-se melhorar a precisão das recomendações a partir da adição de dados extraídos dos relacionamentos sociais do usuário, uma vez que esta informação reflete a influência social que as conexões de amizade tem sobre as preferências do usuário e mostra que pessoas que compartilham interesses similares tendem a estar mais conectadas e interagir umas com outras [19].

A Fig 1 mostra de forma geral o esquema do modelo a ser implementado (modelo inicial). O modelo basicamente está dividido em 4 níveis os quais são explicados a seguir:

- nível 1: O sistema contém uma base de dados (BD) de música. O usuário entra no sistema através da sua conta *facebook* ou *twitter*;
- nível 2: A informação da base de produtos (BD de música) é vetorizada e treinada para separar categorizar os produtos.
- nível 3: A informação relevante das redes sociais (“likes”, “posts”) é extraída. Sua rede de amigos é identificada e dados dos amigos no *Twitter* são coletados e processados. Os dados são avaliados e tratados quanto a valência e a qualidade; Os dados das redes sociais são vetorizados para posterior comparação com a base de produtos;
- nível 4: Algoritmos de CF são aplicados para execução da recomendação.

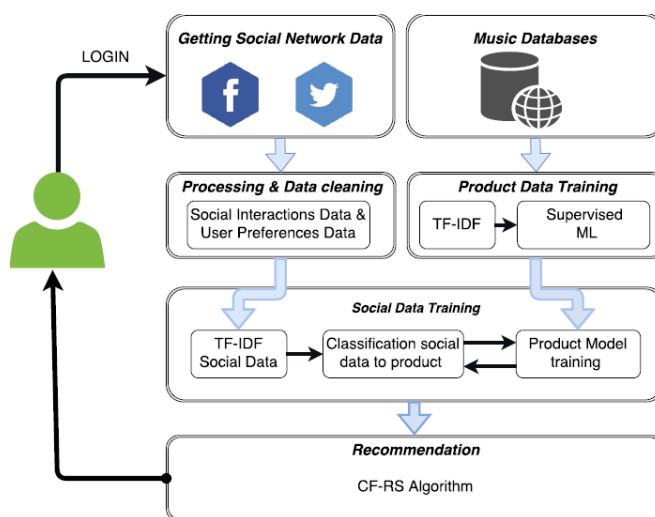


Fig. 1. Modelo do RS proposto

IV. DETALHAMENTO DA PROPOSTA

Para o cumprimento desse trabalho foram planejadas várias etapas as quais são apresentadas a seguir.

A. Levantamento e análise de referências bibliográfica

Nesta parte foi elaborada uma Revisão Sistemática da Literatura (SLR, *Systematic Literature Review*) relacionada com RS, CF e redes sociais que confirmaram o interesse no problema de escassez de dados, cold-start e emprego de dados sociais para a melhorar a recomendação. Esta revisão, foi baseada na proposta de [24] para SLR em engenharia da computação e foi feita para melhorar a qualidade da pesquisa. Nesta recopilou-

se os trabalhos mais relevantes entre o ano de 2011 e 2017, sobre as técnicas mais atuais para contornar o cenário de *cold-start*. Como resultado um artigo foi submetido para um *journal* e encontra-se em fase de avaliação.

B. Análise de uso de redes sociais em RS

Nesta etapa, deve-se analisar as principais técnicas e algoritmos usados para identificar quais se ajustam melhor ao trabalho. Como esse trabalho estende [8] e [22], serão empregadas as mesmas redes sociais daqueles trabalhos, a saber *Facebook* e *Twitter*. Para possibilitar a comparação de resultados, a proposta inclui um experimento controlado, com a criação de uma rede social com dados simulados. Os resultados obtidos serão comparados posteriormente com os dados extraídos de redes sociais reais.

C. Levantamento da base de dados a ser utilizada

Nesta parte será definida a base de dados a ser utilizada no experimento especificando o domínio de recomendação de música. Do mesmo modo, se deve fazer a extração dos dados das redes sociais que vise encontrar dados da rede de amigos mais próximos ao usuário recém cadastrado e identificar suas preferências.

D. Especificação do modelo de RS

Esta etapa está dedicada a definir que algoritmos serão usados para execução do RS. Nela serão especificadas as partes que compõe o sistema e o fluxo da informação.

E. Identificação do grupo de amigos

Estabelecimento de métricas para avaliar o grupo de amigos mais influentes sobre o usuário recém cadastrado no sistema, baseada nas propostas de [19][6].

F. Avaliação do RS

A princípio pretende-se utilizar **Root mean square error (RMSE)** e **Mean Absolute Error (MAE)** também usada nas propostas de [3],[19],[6], com o intuito de avaliar a recomendação. Outras técnicas serão analisadas.

G. Ambiente de teste

Serão convidadas um grupo de pessoas a se cadastrar no sistema mediante uma aplicação web que solicitará dados das redes sociais para o cadastro. Esse procedimento será seguido tanto para o experimento controlado quanto com os dados da rede social real. O sistema simulará o comportamento de um e-commerce real e uma vez extraídas as informações mais relevantes

das redes sociais do usuário, fará a recomendação de itens.

H. Validação dos resultados

Nesta última etapa, discute-se a precisão da recomendação apresentando os resultados obtidos aos usuários cadastrados no sistema, os quais avaliarão a recomendação feita.

V. RESULTADOS PRELIMINARES

Artigo submetido para revista indexada como resultado da SLR feita.

AGRADECIMENTOS

Os autores agradecem o apoio a Fundação de Amparo a Pesquisa de São Paulo (FAPESP). Processo #2014/04851-8, FAPESP.

REFERENCIAS

- [1] K. A. Almohsen and H. Al-Jobori, "Recommender systems in light of big data," *Int. J. Electr. Comput. Eng.*, vol. 5, no. 6, pp. 1553–1563, Dec. 2015.
- [2] F. Ricci, L. Rokach, and B. Shapira, *Recommender Systems Handbook*, vol. 44, no. 8. Boston, MA: Springer US, 2011.
- [3] X. Yang, Y. Guo, and Y. Liu, "Bayesian-inference-based recommendation in online social networks," *IEEE Trans. Parallel Distrib. Syst.*, vol. 24, no. 4, pp. 642–651, 2013.
- [4] J. Bobadilla, F. Ortega, A. Hernando, and A. Gutiérrez, "Recommender systems survey," *Knowledge-Based Syst.*, vol. 46, pp. 109–132, Jul. 2013.
- [5] J. Sun, G. Wang, X. Cheng, and Y. Fu, "Mining affective text to improve social media item recommendation," *Inf. Process. Manag.*, vol. 51, no. 4, pp. 444–457, Jul. 2015.
- [6] I. Barjasteh, R. Forsati, D. Ross, A.-H. Esfahanian, and H. Radha, "Cold-Start Recommendation with Provable Guarantees: A Decoupled Approach," *IEEE Trans. Knowl. Data Eng.*, vol. 28, no. 6, pp. 1462–1474, Jun. 2016.
- [7] Q. Liu, E. Chen, H. Xiong, C. H. Q. Ding, and J. Chen, "Enhancing collaborative filtering by user interest expansion via personalized ranking," *IEEE Trans. Syst. Man, Cybern. Part B Cybern.*, vol. 42, no. 1, pp. 218–233, Feb. 2012.
- [8] A. V Prando, F. G. Contrates, S. N. Alves-Souza, and L. S. DeSouza, "Content-Based Recommender System Using Social Networks For Cold-Start Users," in *9th International Conference on Knowledge Discovery and Information Retrieval*, 2017.
- [9] M. Al-Hassan, H. Lu, and J. Lu, "A semantic enhanced hybrid recommendation approach: A case study of e-Government tourism service recommendation system," *Decis. Support Syst.*, vol. 72, pp. 97–109, Apr. 2015.
- [10] J. Bobadilla, F. Ortega, and A. Hernando, "A collaborative filtering similarity measure based on singularities," *Inf. Process. Manag.*, vol. 48, no. 2, pp. 204–217, Mar. 2012.

- [11] T. C. K. Huang, Y. L. Chen, and M. C. Chen, "A novel recommendation model with Google similarity," *Decis. Support Syst.*, vol. 89, pp. 17–27, Sep. 2016.
- [12] O. Khalid, M. U. S. Khan, S. U. Khan, and A. Y. Zomaya, "OmniSuggest: A Ubiquitous Cloud based Context Aware Recommendation System for Mobile Social Networks," *IEEE Trans. Serv. Comput.*, vol. PP, no. 99, p. 1, Jul. 2014.
- [13] D. Schall, *Social Network-Based Recommender Systems*. Springer International Publishing Switzerland, 2015.
- [14] S. Deng, L. Huang, and G. Xu, "Social network-based service recommendation with trust enhancement," *Expert Syst. Appl.*, vol. 41, no. 18, pp. 8075–8084, Dec. 2014.
- [15] M. Jiang, P. Cui, X. Chen, F. Wang, W. Zhu, and S. Yang, "Social Recommendation with Cross-Domain Transferable Knowledge," *IEEE Trans. Knowl. Data Eng.*, vol. 27, no. 11, pp. 3084–3097, Nov. 2015.
- [16] I. T. Christou, E. Amolochitis, and Z.-H. Tan, "AMORE: design and implementation of a commercial-strength parallel hybrid movie recommendation engine," *Knowl. Inf. Syst.*, vol. 47, no. 3, pp. 671–696, Jun. 2015.
- [17] M. N. Moreno, S. Segrera, V. F. López, M. D. Muñoz, and Á. L. Sánchez, "Web mining based framework for solving usual problems in recommender systems. A case study for movies' recommendation," *Neurocomputing*, vol. 176, pp. 72–80, Feb. 2016.
- [18] H. Yin, B. Cui, Y. Sun, Z. Hu, and L. Chen, "LCARS: A Spatial Item Recommender System," *ACM Trans. Inf. Syst.*, vol. 32, no. 3, p. 11:1–11:37, 2014.
- [19] Y. Zhang, W. Chen, and Z. Yin, "Collaborative filtering with social regularization for TV program recommendation," *Knowledge-Based Syst.*, vol. 54, pp. 310–317, 2013.
- [20] C. Lin, R. Xie, X. Guan, L. Li, and T. Li, "Personalized news recommendation via implicit social experts," *Inf. Sci. (Ny)*, vol. 254, pp. 1–18, Jan. 2014.
- [21] M. Salehi, I. Nakhai Kamalabadi, and M. B. Ghaznavi Ghouschi, "An effective recommendation framework for personal learning environments using a learner preference tree and a GA," *IEEE Trans. Learn. Technol.*, vol. 6, no. 4, pp. 350–363, Oct. 2013.
- [22] F. G. Contrates, "Emprego de análise de sentimentos em um sistema de recomendação para o caso de cold-start," Universidade de São Paulo., 2017.
- [23] W. X. Zhao, S. Li, Y. He, E. Y. Chang, J. R. Wen, and X. Li, "Connecting Social Media to E-Commerce: Cold-Start Product Recommendation Using Microblogging Information," *IEEE Trans. Knowl. Data Eng.*, vol. 28, no. 5, pp. 1147–1159, May 2016.
- [24] B. Kitchenham and S. Charters, "Guidelines for performing Systematic Literature reviews in Software Engineering Version 2.3," *Engineering*, vol. 45, no. 4ve, p. 1051, 2007.
- [25] I. Barjasteh, R. Forsati, D. Ross, A. H. Esfahanian, and H. Radha, "Cold-Start Recommendation with Provable Guarantees: A Decoupled Approach," *IEEE Trans. Knowl. Data Eng.*, vol. 28, no. 6, pp. 1462–1474, Jun. 2016.

Learning the Parameters of Acyclic Probabilistic Logic Programs from Data

De Faria, F. H. O. V.*; Gusmão, A. C.*; De Bona, G.*; Mauá, D. D.†; Cozman, F. G.*

*Escola Politécnica - Universidade de São Paulo

†Instituto de Matemática e Estatística - Universidade de São Paulo

E-mail: {francisco_de_faria, arthurcguasmo, glauberbona, denis.maua, fgcozman}@usp.br

Abstract—The problem of learning a probabilistic logic program consists in finding a set of probabilistic rules that best fits some data, in order to explain how attributes relate to one another and predict the occurrence of new instantiations of these attributes. We focus on acyclic programs, because in this case the meaning of the program is quite transparent and easy to grasp. Our novel idea is that the learning process for a probabilistic acyclic logic program should be guided by a scoring function imported from the literature on Bayesian network learning. We suggest novel techniques that lead to orders of magnitude improvements in ProbLog’s parameter learning speed.

Keywords—Probabilistic Logic Programs, Machine Learning.

Classification— Master’s degree.

Category— Applies to Master degree.

I. INTRODUCTION

The meaning of acyclic probabilistic logic programs (A-PLPs) is quite transparent and easy to grasp, which is definitely not the case of most accurate Machine Learning models. The combination of logic and probabilities has been extensively studied [1], [2] and different semantics have been proposed to specify probability distributions in logic programming. Sato’s distribution semantics [3] is based on deterministic rules as, for instance

$$\text{calls}(X, Y) :- \text{alarm}(X), \text{neighbor}(X, Y). \quad (1)$$

and probabilistic facts as $0.3 :: \text{neighbor}(X, Y)$, meaning that there is a 0.3 probability that any X is a neighbor of Y . ProbLog is a state-of-art probabilistic logic programming implementation that extends Sato’s distribution semantics, allowing not only for representation of probabilistic facts, but also probabilistic rules [4].

The goal of this work is to present algorithms that learn A-PLPs both from complete and incomplete data, by adapting techniques from Bayesian network learning. More specifically, we focus on score-based learning and on exact maximum likelihood computations [5], [6].

ProbLog package includes a parameter learning algorithm that implements a variant of the Expectation Maximization (EM) algorithm that resorts to Binary Decision Diagrams (BDD’s) to speed inference whenever possible [7], [8]. However, the resulting learning algorithm is rather slow. In this work, we propose novel techniques that lead to orders of magnitude improvements in parameter learning speed, especially when data are complete [5].

II. BACKGROUND

A. Bayesian Networks

A Bayesian network consists of a directed acyclic graph that encodes dependence relations between a set of random variables \mathbf{X} . Each node of the graph corresponds to a random variable X_i associated with a joint probability distribution (usually encoded via flat tables) given its parents $\text{PA}[X_i]$. Markov independence condition states that any variable X_i in a Bayesian network is assumed independent of its nondescendants, given its parents $\text{PA}[X_i]$. We call *family* a set consisting of a variable and its parents, $\{X_i, \text{PA}[X_i]\}$.

1) *Log-Likelihood*: The Log-Likelihood (LL) is a way of scoring the performance of a Bayesian network which has the property of being *decomposable*: it can be computed locally and then summed for all subgraphs of a graphical model.

The LL of a Bayesian network B , given a dataset D , is:

$$LL(B, D) = \log[\mathbb{P}(D | B)],$$

where the probability of observing dataset D given Bayesian network B is called the likelihood of B given D . Assuming the probability distributions are encoded via flat tables, for a set of observations $d \in D$ we have:

$$LL(B, D) = \sum_{i=1}^n \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \cdot \log(\theta_{ijk})$$

where n is the number of variables represented in B , q_i is the number of states for variable X_i , r_i is the number of configurations the parents of a variable X_i can assume and N_{ijk} corresponds to the number of observations where $X_i = x_{ij}$ and $\text{PA}[X_i] = w_{ik}$ in dataset D . θ_{ijk} is a parameter encoding the probability that variable X_i assumes its j th value once its parents take their k th configuration; that is, $\theta_{ijk} = \mathbb{P}(X_i = x_{ik} | \text{PA}[X_i] = w_{ij})$.

2) *Parameter Learning*: Learning the parameters of a Bayesian network consists in, given a fixed dependency graph over variables \mathbf{X} (i.e., a fixed structure), learning the optimal parameters that describe the probability distribution of each variable X_i given its parents $\text{PA}[X_i]$.

The Maximum Likelihood Approach aims at finding the model parameters that maximize the likelihood value. When the examples are not fully observed, however, the LL value cannot be calculated directly and we have to resort to the

Expectation Maximization (EM) algorithm. It aims at maximizing the expected likelihood, meaning that we are interested in finding the set of parameters $\theta = \{\theta_1, \theta_2, \dots\}$ that gives us the *Maximum Likelihood* estimate for a given model structure.

The EM cycle has 2 steps: expectation (E-step) and maximization (M-step). The E-step consists of finding the expected LL expression we want to maximize. This implies computing the probability of observing each of the datasets one could obtain by completing the values of hidden variables. The M-step is the maximization of this expected LL with respect to the parameters. This cycle is repeated until the expected LL reaches a local maximum.

B. Logic Programs

Logic programming uses sets of facts and rules to represent knowledge and reasoning processes [9], [10]. A fact is, intuitively, a statement such as: "Bill is a man", or "Bill is Ray's father". Rules consist of sentences that impose constraints amongst predicates. We have a vocabulary of predicates and constants; in this work we do not use functions. A predicate p of arity n defines a relationship between a set of terms t_i , $i \in [1, n]$. A term can be a constant or a logical variable. A (lowercase) constant is a specific object, like bill or ray, and an (uppercase) logical variable, like A or B, represents a set of constants of the same type.

An atom consists of a predicate together with its arguments, which may be logical variables or constants. A literal is an atom, such as $\text{fatherOf}(a, b)$, called a *positive* literal, or its negation, a *negative* literal. A clause consists of a single literal (atomic clause) or a disjunction of literals. A *Horn clause* contains at most one negative literal; a *definite* clause contains exactly one negative literal [10]. A definite clause is often written as: $h \leftarrow b_1 \wedge \dots \wedge b_n$, where h denotes the clause *head* and b_i s are the literals composing the clause *body*.

A substitution $\sigma = \{X_1 \rightarrow t_1, \dots, X_m \rightarrow t_m\}$ is an injective partial function that maps a set of variables $\{X_1, \dots, X_m\}$, called the domain of σ , to a set of terms $\{t_1, \dots, t_m\}$, called the range of σ . The application of a substitution $\sigma = \{X_i \rightarrow t_i\}$ to an atom a , denoted $a\sigma$, maps all variables X_i in a , belonging to the domain of σ , to terms t_i . Other variables in a , not belonging to the domain of σ , are mapped to themselves. If no logical variable remains after the substitution, σ is called a grounding substitution of a and $a\sigma$ is a ground instance of a [10], [11].

Prolog is a computer logic programming language that is used for solving problems involving objects and relationships between them [12]. A Prolog program $T = \{c_1, \dots, c_n\}$ consists of a set of definite clauses c_i , which can be deterministic facts or rules. A Prolog query q is an atomic clause. The querying process consists in searching for true ground instances of the definite clause $q :- T$.

1) *Probabilistic Representation*: A promising strategy for developing intelligent agents is the combination of logical formulas and probabilistic assessments [13], [14]. Indeed, several proposals have tried to follow various kinds of *probabilistic logic programming* [15], [16]. A particularly successful

combination is the *distribution semantics*, originally developed by [17], [18] and by Sato [3], [19]. The main point of the distribution semantics is to allow one to specify rules such as

$$\text{fatherOf}(X, Y) :- \text{parentOf}(X, Y), \text{male}(X).$$

and additionally to specify probabilities, for example writing $\mathbb{P}(\text{male}(a)) = 0.2$ to indicate that the probability that a is a male is 0.2.

In this work we adopt the syntax of ProbLog, a probabilistic extension of Prolog [16]. A ProbLog program T consists of a set of independent probabilistic facts

$$F = \{\mathbb{P}(f_1) :: f_1, \dots, \mathbb{P}(f_n) :: f_n\}$$

and a set of probabilistic rules. A probabilistic fact $\mathbb{P}(f_i) :: f_i$ corresponds to an atomic clause f_i , which can be grounded or not, together with a probability label $\mathbb{P}(f_i)$. A probabilistic rule $\mathbb{P}(r_j) :: r_j$ is a non-grounded definite clause, with more than a single predicate, also annotated with a probability label $\mathbb{P}(r_j)$ [20].

2) *Parameter Learning*: Given a fixed structure, parameter learning consists in determining the probability parameters that best fit a dataset of grounded facts. In order to handle this task, ProbLog introduces for each probabilistic rule an auxiliary fact. In fact, according to ProbLog's semantics, a probabilistic rule $\mathbb{P}(r_j) :: h_{r_j} \leftarrow b_{r_j}$ is syntactically equivalent to:

$$\mathbb{P}(r_j) :: f$$

$$h_{r_j} \leftarrow b_{r_j} \wedge f$$

where $\mathbb{P}(r_j) :: f$ is a probabilistic fact used to encode the probability of the body of rule r_j entailing its head. As the auxiliary variables introduced by ProbLog are not observed (latent), some sort of expectation maximization is required to implement a score-based learning algorithm. Notice these latent variables correspond to root nodes and, therefore, inferences should be quite elementary.

3) *Probabilistic Rule Learning*: Probabilistic rule learning consists in building a predictive model for a target predicate t . The starting point is a background theory B , in the form of a ProbLog program, containing a set of grounded probabilistic facts. To build this predictive model, a set of true and false examples of the target predicate t is needed:

$$E = \{(x_1, p_1)_{e_1}, \dots, (x_n, p_n)_{e_n}\}$$

where each example e_i consists of a possible ground instance $x_i = t\sigma_i$ and its probability $p_i = \mathbb{P}(t\sigma_i)$ [10].

Typically, a rule learner searches for a hypothesis H , a set of probabilistic rules entailing t , capable of, together with the background knowledge B , predicting the probability $p_i = \mathbb{P}(t\sigma_i)$ that a ground instance $x_i = t\sigma_i$ is true [2], [21]. This corresponds to minimizing a loss function [20]:

$$\text{loss}(H, B, E) = \sum_{(x_i, p_i) \in E} |P_S(x_i \leftarrow B \cup H) - p_i|$$

III. NOVEL ALGORITHMS FOR PARAMETER LEARNING

Here we present an algorithm that learns the parameters of A-PLPs by adapting techniques from Bayesian network learning. We must, therefore, translate the language of A-PLPs into the language of Bayesian networks. Each predicate in our vocabulary is viewed as a binary random variable (0 is false and 1 is true), and the predicates that appear in the body of a rule are the parents of the predicate in the head of the rule.

We must now understand how the LL score can be computed for a PLP. Suppose the following propositional PLP:

$\theta_1 :: \text{burglary.}$	$\theta_4 :: \text{alarm} :- \text{fire.}$
$\theta_2 :: \text{fire.}$	$\theta_5 :: \text{johnCalls} :- \text{alarm.}$
$\theta_3 :: \text{alarm} :- \text{burglary.}$	$\theta_6 :: \text{johnCalls} :- \text{alarm.}$

From our definition, $LL(B, D) = \log[\mathbb{P}(D | B)]$, and then:

$$LL(B, T) = \log[\theta_1] + \log[1 - \theta_2] + \log[\theta_5] + \log[\theta_3 + 0 - \theta_3 \cdot 0].$$

If we had a relational model, we would need to instantiate it to all possible substitutions in order to write the LL expression. Notice that the rules defining the probability distribution over alarm are not mutually exclusive and, therefore, we cannot maximize this LL expression by simply counting on the occurrences of each family configuration in the training set.

A. Exact Solutions

Suppose, for instance, a subgraph $\text{PA}[X_0] = \{X_1, X_2\}$, where the probability distribution of X_0 is given by two rules $\theta_1 :: X_0 :- X_1, X_2$ and $\theta_2 :: X_0 :- \bar{X}_1, X_2$. The likelihood expression for this subgraph would be:

$$L(R, D) = \theta_1^{a_0} (1 - \theta_1)^{a_1} \theta_2^{b_0} (1 - \theta_2)^{b_1}$$

If there is no observation with zero likelihood, we have following exact solution of the optimization problem:

$$\theta_1 = \frac{a_0}{a_0 + a_1}, \theta_2 = \frac{b_0}{b_0 + b_1}$$

We notice other combinations of rules could lead to similar likelihood expressions. For instance, if the probability distribution of X_0 was given by other two rules $\theta_1 :: X_0 :- X_1$ and $\theta_2 :: X_0 :- X_2$ we would obtain an identical likelihood expression. In fact, there is an exact solution for several likelihood expressions obtained under following restrictions: (i) there are at most three combinations of rules entailing a same predicate, and (ii) rules have only one possible body instantiation for each head instantiation.

In our implementations we have covered all these cases. Notice that the LL does not depend on the size of the rules' bodies. This contributes to a considerable reduction on the optimization complexity, once only a few cases may require a numerical approach to be solved.

B. Complete Data

If data are complete, all variables are observed in all examples. The LL can then be easily calculated and finding the parameters to maximize it should be very simple. However, even when the data are complete, the auxiliary facts introduced

by ProbLog to handle probabilistic rules are missing. The fact that some variables are actually not observed, implies that some sort of expectation maximization is required, as mentioned in Section II-B2.

Our solution is not to insert an auxiliary (latent) atom for each probabilistic rule. Instead, we must write down the LL and maximize it directly. For many rule patterns, this maximization can be done in closed-form, as shown in Section III-A. The main insight, however, is that inference is very time-consuming and should be avoided whenever possible during learning iterations.

C. Incomplete Data

In most real world applications, the examples are not fully observed. EM has traditionally been used to deal with hidden variables. However, because the missing data points can be seen as hidden variables, a variant of EM can be derived. EM algorithm aims at maximizing the expected likelihood, i.e., finding the set of parameters $\theta = \{\theta_1, \theta_2, \dots\}$ that gives us the *Maximum Likelihood* estimate for a given set of rules $\{\theta_1 :: c_1, \theta_2 :: c_2, \dots\}$. The general form for the EM is

$$\theta^{(k+1)} = \underset{\theta}{\text{argmax}} \sum_{\mathbf{z}} \mathbb{P}(\mathbf{Z} = \mathbf{z} | \mathbf{x}, \theta^{(k)}) \cdot LL(\theta | \mathbf{x}, \mathbf{Z} = \mathbf{z}),$$

where $\theta^{(k)}$ denotes the values calculated for the model parameters in step k of the learning algorithm, \mathbf{x} denotes all the values observed for non-hidden variables and \mathbf{z} denotes all the values expected for the hidden-variables \mathbf{Z} . $LL(\theta | \mathbf{x}, \mathbf{Z} = \mathbf{z})$ is the LL of the model for an hypothetical dataset where \mathbf{x} and \mathbf{z} would be observed.

With an incomplete dataset, some examples have missing values for one or more variables. Let \mathbf{d}_i represent the observed values for an example i in dataset D , \mathbf{C}_i the variables for which values are missing in example i and \mathbf{c}_i a possible way to complete these missing values. E-step gives then the following expression for the model's expected LL:

$$ELL(\theta | D, \theta^{(k)}) = \sum_i \sum_{\mathbf{c}_i} \mathbb{P}(\mathbf{C}_i = \mathbf{c}_i | \mathbf{d}_i, \theta^{(k)}) \cdot LL(\theta | \mathbf{d}_i, \mathbf{C}_i = \mathbf{c}_i).$$

By application of Markov condition we can rewrite this expression as following:

$$ELL(\theta | D, \theta^{(k)}) = \sum_x \sum_i \sum_{\mathbf{c}_{x,i}} \mathbb{P}(\mathbf{c}_{x,i} | \mathbf{d}_i, \theta^{(k)}) \cdot \log \mathbb{P}(x_{\mathbf{c}_{x,i}} | \text{PA}[X]_{\mathbf{c}_{x,i}}, \theta),$$

where $\sum_{\mathbf{c}_{x,i}}$ iterates over all possible configurations $\{X = x_{\mathbf{c}_{x,i}}, \text{PA}[X] = \text{PA}[X]_{\mathbf{c}_{x,i}}\}$ the i th example of the dataset can assume. Note that this expression is decomposable and can be maximized on each variable X independently.

If the conditional probabilities distributions are encoded via a set of probabilistic rules, where parents configurations are not necessarily mutually exclusive, we must write down the LL expression and locally maximize it in closed-form whenever possible or numerically with a fast gradient-based routine whenever necessary.

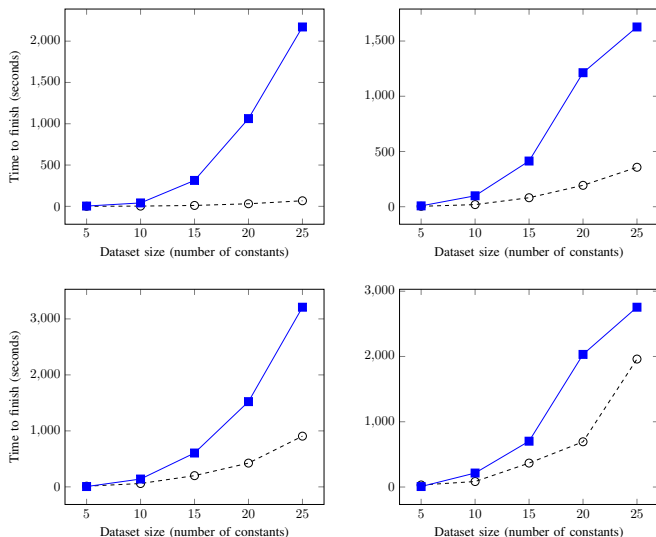


Figure 1: Learning time (solid squares for ProbLog and empty circles for our algorithm) with 0% (top left), 10% (top right), 20% (bottom left) and 30% (bottom right) of missing rate.

IV. EXPERIMENTS AND RESULTS

We compared our approach with ProbLog’s LFI (after Learning From Interpretations) using the following program:

```

0.3 :: fire(X) :- person(X).
0.4 :: burglary(X) :- person(X).
0.7 :: alarm(X) :- fire(X).
0.9 :: alarm(X) :- burglary(X).
0.8 :: cares(X, Y) :- person(X), person(Y).
0.8 :: calls(X, Y) :- cares(X, Y), alarm(Y), same(X, Y).

```

We generated datasets with varying missing data rates and dataset sizes by sampling from the model above for a given number of constants (dataset size) and discarding part of the generated observations (missing rate). For each constant c deterministic facts $\text{person}(c)$ and $\text{samePerson}(c, c)$ were added to the model. Also, we had to limit the dataset size to 25 constants because with more than that ProbLog’s algorithm approximated the likelihood values to zero and therefore returned an error when trying to calculate its log.

Each point in Figure 1 corresponds to the average computation time among four runs, each of which used a different, independently sampled dataset. In order to ensure that both algorithms reached similar LL values, we fixed ProbLog’s stopping criteria to $1e-3$ and set our algorithm to stop whenever it reaches an equal or better LL value than ProbLog did.

Our algorithm outperformed ProbLog in the vast majority of cases, losing only for datasets with 5 constants and 20% or more of missing data. From the curve, it is easy to notice that when the size of the dataset increases the ratio between ProbLog’s and our approach’s computation time tends to increase.

V. CONCLUSION

Novel techniques that lead to significant improvements in ProbLog’s parameter learning were shown. Main insights consisted of never introducing unnecessary latent atoms and maximizing LL locally in the most efficient manner [5].

ACKNOWLEDGMENT

The first author is supported by a scholarship from Toshiba Corporation. The second and third authors are supported by a scholarship from Fapesp. The fourth and fifth authors are partially supported by CNPq.

REFERENCES

- [1] GETOOR, L.; TASKAR, B. *Introduction to Statistical Relational Learning*. [S.l.]: MIT Press, 2007. ISBN 0262072882.
- [2] RAEDT, L. D. et al. *Probabilistic Inductive Logic Programming*. [S.l.]: Springer, 2010.
- [3] SATO, T.; KAMEYA, Y. Parameter learning of logic programs for symbolic-statistical modeling. *Journal of Artificial Intelligence Research*, v. 15, p. 391–454, 2001.
- [4] RAEDT, L. D.; KIMMIG, A.; TOIVONEN, H. ProbLog: A probabilistic prolog and its application in link discovery. 2007.
- [5] COZMAN, F. G. et al. Speeding-up ProbLog’s parameter learning. In: *7th International Workshop on Statistical Relational AI (StaRAI-17)*. [S.l.: s.n.], in press.
- [6] de Faria, F. H. O. V.; COZMAN, F. G.; MAUÁ, D. D. Learning probabilistic logic programs by score maximization: some tractable cases. In: *11th International Conference on Scalable Uncertainty Management (SUM-17)*. [S.l.: s.n.], in press.
- [7] GUTMANN, B.; THON, I.; RAEDT, L. D. Learning the parameters of probabilistic logic programs from interpretations. In: SPRINGER. *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. [S.l.], 2011. p. 581–596.
- [8] FIERENS, D. et al. Inference and learning in probabilistic logic programs using weighted Boolean formulas. *Theory and Practice of Logic Programming*, v. 15, n. 3, p. 358–401, 2014.
- [9] KOWALSKI, R.; SADRI, F. From logic programming towards multi-agent systems. *Annals of Mathematics and Artificial Intelligence*, Springer, v. 25, n. 3, p. 391–419, 1999.
- [10] De Raedt, L. et al. Inducing probabilistic relational rules from probabilistic examples. In: *International Joint Conference on Artificial Intelligence*. [S.l.: s.n.], 2015.
- [11] POOLE, D. Abducing through negation as failure: stable models within the independent choice logic. *Journal of Logic Programming*, v. 44, p. 5–35, 2000.
- [12] COHN, P. G. et al. Programação em lógica, Prolog e restrições: poder de expressão vs eficiência. [sn], 1991.
- [13] HALPERN, J. Y. *Reasoning about Uncertainty*. Cambridge, Massachusetts: MIT Press, 2003.
- [14] NILSSON, N. J. Probabilistic logic. *Artificial Intelligence*, v. 28, p. 71–87, 1986.
- [15] FUHR, N. Probabilistic Datalog — a logic for powerful retrieval methods. In: *Conference on Research and Development in Information Retrieval*. Seattle, Washington: [s.n.], 1995. p. 282–290.
- [16] KERSTING, K.; RAEDT, L. D. 1 Bayesian logic programming: Theory and tool. *Statistical Relational Learning*, p. 291, 2007.
- [17] POOLE, D. Probabilistic Horn abduction and Bayesian networks. *Artificial Intelligence*, v. 64, p. 81–129, 1993.
- [18] POOLE, D. The Independent Choice Logic and beyond. In: RAEDT, L. D. et al. (Ed.). *Probabilistic Inductive Logic Programming*. [S.l.]: Springer, 2008, (Lecture Notes in Computer Science, v. 4911). p. 222–243.
- [19] SATO, T. A statistical learning method for logic programs with distribution semantics. In: *Int. Conference on Logic Programming*. [S.l.: s.n.], 1995. p. 715–729.
- [20] KIMMIG, A. et al. On the implementation of the probabilistic logic programming language ProbLog. *Theory and Practice of Logic Programming*, Cambridge University Press, v. 11, n. 2-3, p. 235–262, 2011.
- [21] RAEDT, L. D. *Logical and Relational Learning*. [S.l.]: Springer, 2008.

Impact of Requirements Engineering practices on software architecture degradation in projects using XP

Impacto das práticas de Engenharia de Requisitos na degradação da arquitetura de software em projetos usando XP

SILVA, R. B.; SIQUEIRA, F. L.

*Departamento de Engenharia de Computação e Sistemas Digitais- Universidade de São Paulo
{brasil.renata, levy.siqueira}@usp.br

Abstract—One of the main characteristics of eXtreme Programming (XP) is to embrace change, especially changes in requirements. To manage volatile requirements, XP propose practices such as short feedbacks cycles, incremental design, continuous delivery of working software increments, and real customer involvement. Those practices might have influence over the process of software architecture degradation, which corresponds to one of factors that decrease quality and the lifetime of a software product. Hence, this project aims to identify requirements engineering practices of XP which could be determinants to software architecture degradation. To achieve this goal, we will evaluate the degradation through a case study. This work can motivate the proposal of new requirements engineering methods that minimize software architecture degradation in agile projects.

Keywords—software architecture; agile methods; requirements engineering; extreme programming; architecture degradation.

Resumo—Uma das principais características do eXtreme Programming (XP) é a flexibilidade na mudança de requisitos. Isso é alcançado através de práticas para gerenciar requisitos que mudam com frequência, tais como, ter ciclos de desenvolvimento curtos, design incremental, entrega contínua de incrementos funcionais e envolvimento do cliente real. Devido a isso, decisões arquiteturais podem vir a ser fonte de acúmulo de dívida técnica pela pressão para entregas rápidas e frequentes de incrementos de software contribuindo para a degradação da arquitetura de software. Sendo assim, o objetivo deste projeto de pesquisa é identificar dentre as práticas de Engenharia de Requisitos adotadas pelo XP, aquelas que podem ser determinantes para a degradação da arquitetura de software, condição que corresponde a um dos fatores que reduzem a qualidade e a vida útil de um software. Isto será alcançado através de um estudo de caso. Os resultados obtidos podem motivar a melhoria de métodos de Engenharia de Requisitos no contexto de desenvolvimento ágil.

Palavras-chave—arquitetura de software; métodos ágeis; engenharia de requisitos; extreme programming; degradação da arquitetura.

Classificação—Mestrado

Categoria—Iniciante

I. INTRODUÇÃO

O manifesto ágil (BECK et al., 2001) define valores e princípios que, em resumo, defendem maneiras mais flexíveis de desenvolver software. Entretanto, o papel da arquitetura de software não está bem definido na declaração do manifesto ágil (BASS; CLEMENTS; KAZMAN, 2012) levando à crença de que desenvolvimento ágil não combina com abordagens ou atividades arquiteturais. Contudo, não é preciso que a arquitetura seja formalmente documentada para que ela exista. Uma das motivações para torná-la explícita durante o ciclo de vida do desenvolvimento de software é que ela ajuda a compartilhar entre as partes interessadas o entendimento sobre o sistema com respeito às estruturas e às decisões de projeto (NORD; TOMAYKO; WOJCIK, 2004).

No XP e em outros métodos ágeis é fortemente desencorajado o planejamento excessivo no início do desenvolvimento, ou ainda quando o grau de conhecimento sobre os objetivos do negócio e os requisitos do produto é baixo. A Engenharia de Requisitos, nesses casos, conta com práticas que conduzem a interação frequente com o cliente e *design* incremental a partir de iterações curtas nas quais a prioridade dos requisitos é reavaliadas pelo cliente a cada início de ciclo (INAYAT et al., 2014). Porém, a execução dessas práticas no contexto da imprevisibilidade que circunda os métodos ágeis pode fazer com que algumas das decisões arquiteturais se tornem fonte de acúmulo de dívida técnica (KRUCHTEN; NORD; OZKAYA, 2012), situação que pode estar associada a degradação da arquitetura de software.

A degradação da arquitetura leva ao aumento no custo de manutenção, diminui a flexibilidade do processo de desenvolvimento e a capacidade de acomodação de novas funcionalidades (BRUNET et al., 2015). Isso compromete um dos principais benefícios do XP que é a adaptabilidade a mudanças de requisitos.

O objetivo desta pesquisa é identificar como determinadas práticas do XP relacionadas ao processo de engenharia de requisitos contribuem para a degradação da arquitetura de

software. A compreensão dessa relação pode servir de incentivo para melhorar os métodos de Engenharia de Requisitos visando minimizar o efeito da degradação da arquitetura em projetos que usam abordagens ágeis. Para entender como essas práticas afetam a arquitetura, um estudo de caso será conduzido acompanhando times usando XP. As práticas avaliadas no estudo de caso serão escolhidas após um estudo preliminar para determinar as causas da degradação da arquitetura.

Além desta introdução, esta proposta da pesquisa compreende mais três seções que estão organizadas da seguinte forma: a seção 2 apresenta a fundamentação teórica sobre o tema de pesquisa. A seção 3 corresponde ao detalhamento da proposta através da apresentação do método pelo qual se pretende chegar ao objetivo da pesquisa. A seção 4 apresenta uma revisão da literatura contendo as principais contribuições para a área que envolve degradação da arquitetura, dívida técnica, Engenharia de Requisitos, arquitetura de software e XP nos últimos anos. Por fim, a seção 5 apresenta a conclusão sobre o propósito desta pesquisa.

II. FUNDAMENTAÇÃO TEÓRICA

Esta pesquisa envolve conceitos de Engenharia de Requisitos (A), eXtreme Programming (B) e Degradação da arquitetura de software (C).

A. Engenharia de Requisitos

Os requisitos são parte fundamental do desenvolvimento de software. Requisitos mal formulados ou incompletos representam uma das maiores razões de fracasso de projetos de software (EBERLEIN; LEITE, 2002). A Engenharia de Requisitos envolve um processo sistemático para especificação e gerenciamento de requisitos através de atividades como: elicitación, documentação, validação e negociação e gerenciamento de requisitos (POHL; RUPP, 2012). Nos métodos ágeis, as atividades de Engenharia de Requisitos ocorrem de forma contínua durante os ciclos de desenvolvimento (INAYAT et al., 2014; POHL; RUPP, 2012).

B. eXtreme Programming

Os métodos de desenvolvimento ágil de software surgiram em resposta aos problemas que os métodos de desenvolvimento orientados a planos não lidavam bem (HIGHSMITH, 2002). Tais problemas estavam relacionados a mudanças no ambiente de desenvolvimento e de requisitos. Para atender a esse tipo de contexto, as abordagens de desenvolvimento ágil visam entrega rápida de software e o encorajamento dos clientes para participarem do processo contribuindo com seu conhecimento do negócio.

Um dos métodos ágeis é o eXtreme Programming (XP). Ele “é um conjunto coerente de valores, princípios e práticas para abordar problemas de desenvolvimento de software” (BECK; ANDRES, 2004, p. 203, tradução nossa). Esse método tem como base eliminar do desenvolvimento os

comportamentos que afetam negativamente a produtividade do processo e dos indivíduos envolvidos (BECK; ANDRES, 2004). O aumento da produtividade é alcançado por meio de ciclos de desenvolvimento curtos que resultam em *feedback* contínuo, flexibilidade para responder à mudanças, *design* que evolui durante o tempo de vida do software e através de boas práticas de desenvolvimento (BECK, 2000). No XP, planejamento não é uma fase, mas uma atividade e, por isso, o processo de desenvolvimento pode responder mais facilmente às necessidades de negócio, que estão em constante mudança oferecendo flexibilidade através da adaptação (BECK; ANDRES, 2004).

C. Degradação da arquitetura de software

Em 1994, Parnas introduziu o termo envelhecimento de software para descrever o fenômeno relacionado à evolução do software que leva ao aumento da complexidade de suas estruturas e à dificuldade de manutenção (PARNAS, 1994). Outra forma de falar sobre problemas que caracterizam o fenômeno de envelhecimento de software é através da metáfora da dívida técnica (SEAMAN; GUO, 2011) que utiliza a noção de débito financeiro. O termo foi introduzido na indústria de software na década de 90 por Cunningham em 1992 (RUBIN, 2012). Ela significa optar por sacrificar qualidade de código em troca de acelerar o desenvolvimento assumindo um débito que deve ser pago futuramente sob o risco do acúmulo dessa dívida comprometer a qualidade do software produzido (RUBIN, 2012). Entretanto, o sentido da metáfora vem sendo ampliado desde a sua definição e hoje corresponde não somente a atalhos em nível de implementação de código como também à violação da arquitetura e as más decisões de projetos (SEAMAN; GUO, 2011; RUBIN, 2012). As questões arquiteturais são uma das principais fontes de dívida técnica (ERNST et al., 2015) transformando o uso da metáfora em um recurso popular para tratar de tópicos relacionados a esse cenário nos métodos ágeis (BEHUTIYE et al., 2017). Em outras palavras, a degradação da arquitetura pode ser medida em termos de dívida técnica no contexto de desenvolvimento ágil. Para este trabalho, a arquitetura degrada quando a estrutura do sistema (implementação) desvia da estrutura definida no projeto (arquitetura conceitual) e isso compromete a manutenibilidade do software (HOSCHSTEIN; LINDVALL, 2005).

As causas da degradação podem ser listadas olhando por diferentes perspectivas. Dependendo da visão adotada, esses fatores podem diferir. Hochstein e Lindvall (2005) observaram que alguns trabalhos consideram uma visão dominada por problemas de projeto; outros olham por uma perspectiva mais geral, atribuindo a características relacionadas à forma como um software é desenvolvido como, por exemplo, os métodos iterativos (VAN GURP; BOSCH, 2002), fatores organizacionais ou ainda a relação com requisitos como causas; e outros colocam maior ênfase na inevitabilidade da degradação, afirmando que mesmo a melhor estratégia com o passar do tempo não conduz a um projeto ideal, em que a arquitetura real está em conformidade com a arquitetura do projeto (VAN GURP; BOSCH, 2002).

III. DETALHAMENTO DA PROPOSTA

Desejamos verificar através desta pesquisa a hipótese de que práticas do XP associadas à Engenharia de Requisitos degradam a arquitetura do software. Para este fim, é necessário estabelecer um mapeamento entre essas práticas e as causas da degradação da arquitetura e usar o resultado para o planejamento do estudo de caso a ser realizado.

A. Mapeamento entre atividades de Engenharia de Requisitos práticas do XP

Nessa atividade, serão determinadas quais práticas do XP tem relação com atividades do processo de gerenciamento de requisitos.

B. Mapeamento entre práticas de Engenharia de Requisitos no XP e causas da degradação da arquitetura

Essa atividade é responsável por estabelecer a relação entre as diversas causas da degradação da arquitetura com práticas do XP. Os métodos ágeis como XP têm, através de suas práticas, estratégias para abordar vários dos problemas identificados no processo de desenvolvimento de software ao longo do tempo, porém a dinâmica do processo ainda é responsável pelo acúmulo de dívida técnica arquitetural (KRUCHTEN; NORD; OZKAYA, 2012).

C. Planejamento do estudo de caso

A escolha do estudo de caso foi motivada pelas características da hipótese que se deseja verificar na pesquisa. Seu alto grau de abstração indica que o mais adequado é observar como ocorre a situação descrita em um contexto real e não somente verificar se ela é verdadeira ou falsa. Além disso, sem a realização das atividades anteriores, não é possível detalhar quais os critérios serão adotados para definir a degradação da arquitetura, quais as práticas envolvidas e qual o tipo de projeto será avaliado no estudo de caso a ser realizado.

IV. TRABALHOS RELACIONADOS

Weitzel et al. (2014), durante o acompanhamento de um projeto SCRUM conduzido com colaboração entre indústria e universidade, observaram que durante o desenvolvimento houve uma queda na qualidade do software e do processo de desenvolvimento em si devido a vários fatores que afetaram a agilidade do processo e a degradação da arquitetura. A pesquisa concentrou-se em analisar a influência do tamanho do ciclo de desenvolvimento do SCRUM e a degradação da arquitetura e concluiu que as limitações no planejamento das atividades nos *sprints* causa uma queda no nível de flexibilidade do projeto. Contudo, outras práticas ágeis adotadas não foram avaliadas nesse contexto, não sendo possível determinar se a limitação do tamanho do ciclo de desenvolvimento é a única característica responsável pela perda de flexibilidade do projeto. Além disso, o SCRUM é um *framework* para organizar e gerenciar trabalho (RUBIN, 2012), e em comparação com o XP, apresenta pouca ênfase em atividades técnicas de desenvolvimento de software.

Chen e Babar (2014) apresentam um estudo empírico que descobriu que para uma arquitetura satisfatória emergir ela

depende de vários fatores contextuais e identificou vinte desses fatores que foram divididos em quatro categorias: projeto, equipe, práticas e organização. Dentre esses fatores, destacamos, na categoria projeto, a taxa de mudanças de requisitos e o impacto na arquitetura devido à atividade de refatoração para acomodar as novas funcionalidades. Neste ponto, compreender como as mudanças de requisitos e outras práticas do XP afetam a evolução dessa arquitetura durante o processo de desenvolvimento de maneira a aumentar a complexidade do software através do acúmulo da dívida técnica seria uma contribuição importante.

Martini, Bosch e Chaudron (2015) determinaram quais os fatores causam o acúmulo de dívida técnica arquitetural no processo de desenvolvimento usando métodos ágeis, porém, com exceção de refatoração, não estabeleceu relacionamento direto com as práticas de desenvolvimento adotadas por esses métodos.

A contribuição deste projeto de pesquisa, por sua vez, é realizar uma análise empírica em um conjunto de práticas do XP e determinar como elas atuam no processo de degradação da arquitetura de software. O uso de XP como processo de desenvolvimento beneficia a análise pelo fato de XP ser mais centrado em desenvolvimento que outros métodos ágeis e possuir práticas que orientam o que deve ser realizado no dia-a-dia pelos desenvolvedores.

V. CONCLUSÃO

Investir em arquitetura é uma decisão que promove melhoria em manutenção, reusabilidade e aumenta a adaptabilidade do software para agregar novas funcionalidades (BRUNET et al., 2015). Embora o processo de desenvolvimento nos métodos ágeis, em particular o XP, não tenha como característica dedicar muito tempo ao planejamento inicial onde o projeto da arquitetura é definido, a preocupação com a qualidade da arquitetura faz parte do dia-a-dia e é evidente através das práticas de desenvolvimento utilizadas.

Entretanto, durante a evolução do software os desenvolvedores precisam lidar com pressão para cumprimento de *deadlines* e para acomodar mudanças. A Engenharia de Requisitos no XP gerencia os requisitos do software e ocorre de forma iterativa durante os ciclos de desenvolvimento através de práticas como jogo do planejamento e cliente no local (INAYAT et al., 2014), tais práticas tornam o processo de desenvolvimento flexível a mudanças, mas ao mesmo tempo podem contribuir para a degradação da arquitetura de software por serem possíveis fontes de acúmulo de dívida técnica arquitetural. Se a qualidade da arquitetura é comprometida, seus benefícios a longo prazo diminuem encarecendo a manutenção do software e diminuindo sua vida útil (BRUNET et al., 2015). Sendo assim, a principal contribuição desta pesquisa é compreender como práticas que gerenciam requisitos no XP se relacionam com o processo de degradação da arquitetura.

REFERÊNCIAS

- BASS, L.; CLEMENTS, P.; KAZMAN, R. *Software Architecture in Practice*. 3rd. ed. New Jersey, United States: Addison-Wesley Professional, 2012.
- BECK, K. et al. *Manifesto for agile software development*. Disponível em: <<http://agilemanifesto.org/>>. Acesso em: 29 abr. 2017.
- BECK, K. *Extreme Programming Explained: Embrace Change*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 2000.
- BECK, K.; ANDRES, C. *Extreme Programming Explained: Embrace Change (2nd Edition)*. 2. ed. Boston: Addison-Wesley Professional, 2004.
- BEHUTIYE, W. N. et al. Analyzing the concept of technical debt in the context of agile software development: A systematic literature review. *Information and Software Technology*, v. 82, p. 139–158, fev. 2017.
- BRUNET, J. et al. Five Years of Software Architecture Checking: A Case Study of Eclipse. *IEEE Software*, v. 32, n. 5, p. 30–36, set. 2015.
- CHEN, L.; BABAR, M. A. Towards an Evidence-Based Understanding of Emergence of Architecture through Continuous Refactoring in Agile Software Development. 2014 IEEE/IFIP Conference on Software Architecture. Anais...IEEE, abr. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6827119/>>.
- EBERLEIN, A.; LEITE, J. Agile Requirements Definition: A View from Requirements Engineering. *International Workshop on Time-Constrained Requirements Engineering, TCRE 2002*, p. 1–5, 2002.
- ERNST, N. A. et al. Measure it? Manage it? Ignore it? software practitioners and technical debt. *Proceedings of the 2015 10th Joint Meeting on Foundations of Software Engineering - ESEC/FSE 2015*. Anais...New York, New York, USA: ACM Press, 2015. Disponível em: <<http://dl.acm.org/citation.cfm?doid=2786805.2786848>>.
- HIGHSMITH, J. *Agile Software Development Ecosystems*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 2002.
- HOCHSTEIN, L.; LINDVALL, M. Combating architectural degeneration: a survey. *Information and Software Technology*, v. 47, n. 10, p. 643–656, jul. 2005.
- INAYAT, I. et al. A systematic literature review on agile requirements engineering practices and challenges. *Computers in Human Behavior*, v. 51, n. 0, 2014.
- KRUCHTEN, P.; NORD, R. L.; OZKAYA, I. Technical Debt: From Metaphor to Theory and Practice. *IEEE Software*, v. 29, n. 6, p. 18–21, nov. 2012.
- MARTINI, A.; BOSCH, J.; CHAUDRON, M. Investigating Architectural Technical Debt accumulation and refactoring over time: A multiple-case study. *Information and Software Technology*, v. 67, p. 237–253, nov. 2015.
- NORD, R.; TOMAYKO, J. E.; WOJCIK, R. Integrating Software-Architecture-Centric Methods into Extreme Programming (XP). Pittsburgh, PA: [s.n.]. Disponível em: <<http://www.sei.cmu.edu/pub/documents/04.reports/pdf/04tn036.pdf>>, 2004.
- PARNAS, D. L. Software aging. *Proceedings of 16th International Conference on Software Engineering*. Anais...IEEE Comput. Soc. Press, 1994. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=296790>.
- POHL, K.; RUPP, C. *Fundamentos da Engenharia de Requisitos*. Tradução de Paul Tornquist. São Paulo: T&M Testes, 2012.
- RUBIN, K. S. *Essential Scrum: A Practical Guide to the Most Popular Agile Process*. 1 edition. Addison-Wesley Professional, 2012.
- SEAMAN, C.; GUO, Y. Measuring and Monitoring Technical Debt. *Advances in Computers*, v. 82, p. 25–46, 2011.
- VAN GURP, J.; BOSCH, J. Design erosion: problems and causes. *Journal of Systems and Software*, v. 61, n. 2, p. 105–119, mar. 2002.
- WEITZEL, B.; ROST, D.; SCHEFFE, M. Sustaining Agility through Architecture: Experiences from a Joint Research and Development Laboratory. 2014 IEEE/IFIP Conference on Software Architecture. Anais...IEEE, abr. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6827100/>>.

Análise do impacto dos atributos de projetos de software na estimativa de esforço utilizando analogia

Silva, C. I. L. C. *; Brandão, A. A. F.* Siqueira, F. L.†;

*Laboratório de Técnicas Inteligentes - Escola Politécnica - USP

†Laboratório de Tecnologia de Software - Escola Politécnica - USP

E-mail: {igortkd2006, anarosabrandao, levy.siqueira}@gmail.com

Resumo— A estimativa de esforço no desenvolvimento de projetos de software é uma métrica primordial para o sucesso do projeto. Os atributos de projetos de software são as características que os diferenciam, por exemplo, a arquitetura utilizada, a metodologia, a atividade operacional do cliente, entre outros. Apesar dos esforços na busca de um método de estimativa que seja adaptável e preciso, ainda não existe uma técnica unânime na literatura. ABE é um técnica de estimativa híbrida e adaptável, que apresenta bons resultados e baixo nível de complexidade. Apesar disso existem poucos estudos sobre o ABE com foco na utilização de atributos para caracterização dos dados e o seu impacto na estimativa final. Compreender os detalhes da etapa de caracterização do ABE, é necessário para aproveitar melhor o potencial de cada atributo no modelo de estimativa por analogia. Assim a proposta desse trabalho é analisar o impacto dos principais atributos de projetos de software na métrica de estimativa de esforço por analogia.

Palavras-chave— analogy based effort; estimativa de esforço, inteligência artificial, projetos de software.

Classificação— Mestrado

Categoria— Iniciante

I. INTRODUÇÃO

Segundo Boehm, Abts e Chulani (2000) a estimativa do esforço de um projeto software é uma métrica utilizada em diversas áreas da engenharia de software, tais como, planejamento, gerenciamento, análise de risco, orçamento, entre outros. Trendowicz e Jeffery (2014) afirmam que estimativas pobres são uma das principais causas do aumento de custo da produção de um software e a segunda maior causa de desistência de projetos. Nos últimos anos a acurácia da estimativa de software têm sido um desafio devido às peculiares características desse produto como a abstração, intangibilidade [2].

Encontrar um método de estimativa eficaz, preciso e adaptável tem sido um desafio a diversos profissionais. Além das dificuldades provenientes das características do produto, no momento da estimativa, diversas características do produto e do projeto, se encontram indefinidas ou desconhecidas. É comum no momento da estimativa estaemr indefinidas a metodologia, o time e sua maturidade, a arquitetura, entre outros [3]

O dicionário Aurélio *on-line* define analogia como: "Relação de semelhança entre objetos diferentes". Segundo Keung (2009), analogia é uma técnica utilizada até hoje no cotidiano

das pessoas e pode ser definida como: "A relação entre dois problemas, medida em similaridade"[4]. É uma técnica multidisciplinar que utiliza o aprendizado de casos passados, ou análogos, para resolver um problema novo, também chamado de problema alvo [4].

A resolução de problemas por analogia é uma técnica comumente utilizada no cotidiano das pessoas, e por isso atrai maior simpatia dos profissionais da área [5]. É uma técnica de inteligência artificial, que utiliza o conhecimento adquirido previamente, para resolução de novos problemas. A utilização do conhecimento adquirido minimiza a dependência de informações do problema alvo [6].

Segundo Trendowicz e Jeffery (2014) as principais vantagens do ABE, *Analogy Based Effort*, são:

- Não necessita de um especialista em estimativas;
- Flexível;
- Documentação extensa com diversos trabalhos acadêmicos e ferramentas publicadas;
- Reutilizável;
- Validado empiricamente em estudos de contexto acadêmico e comercial;
- Possui bons resultados.

Uma das etapas do ABE é o cálculo da similaridade, que é a distância entre os atributos do projeto alvo e os atributos dos projetos análogos. Baseado nos projetos mais similares é feita a estimativa do projeto alvo [2]. Assim o cálculo da similaridade é uma etapa crucial da técnica, e parte da premissa que quanto maior a similaridade entre dois projetos, maior a similaridade entre suas estimativas.

Apesar de existirem estudos sobre os atributos e seu impacto na estimativa de esforço [3], [7], [8], [9], [10], não foram encontrados trabalhos que aplicassem esse conhecimento no cálculo de similaridade do ABE. Assim o objetivo desse trabalho é analisar a utilização dos atributos de projetos de software, no cálculo da similaridade do ABE, levando em consideração o impacto na estimativa de esforço do modelo.

II. TRABALHOS CORRELATOS

ABE utiliza as informações do projeto alvo para encontrar os projetos mais similares. A estimativa então é obtida baseada nos projetos similares, cujo esforço de produção já foi

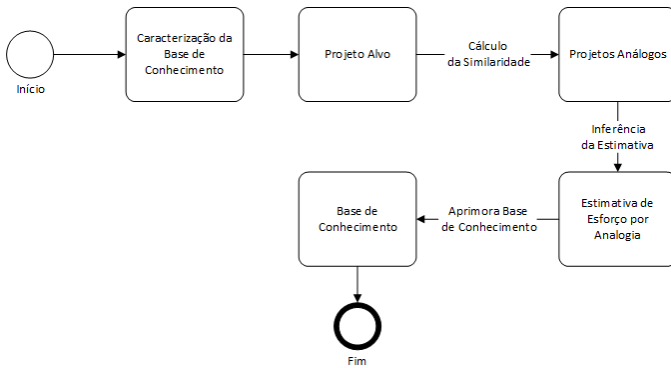


Figura 1. Etapas do ABE

computado [4]. O processo análogo parte da premissa que o cálculo da similaridade sofre menor influência da ausência de informações do que o cálculo da estimativa em si.

Segundo Shepperd e Schofield (1997) ABE é uma técnica que consiste em quatro etapas: Caracterização da base de dados para identificação dos atributos a serem utilizados; Cálculo da similaridade; Solução análoga, utiliza o conhecimento dos casos similares para prover possíveis soluções; Sugestão de uma solução ao caso alvo. Na Figura 1 é possível verificar o fluxograma básico da estimativa por analogia.

Ao utilizar ABE o primeiro passo é a caracterização da base de projetos, que consiste na escolha dos atributos que serão utilizados nas demais etapas do processo. São exemplos de atributos: tamanho do software; arquitetura utilizada; metodologia de desenvolvimento; maturidade do time; entre outros [2], [5]. Os atributos podem ser classificados como atributos de contexto ou atributos de influência.

O ambiente de um projeto de software possui diversas características que se mantêm constantes em determinados projetos. Essas características de um software são chamadas de atributos de contexto. Esses atributos geralmente são qualitativos, portanto dificilmente podem ser expressos em números. Por exemplo, domínio da aplicação, tipo de desenvolvimento, linguagem de programação, metodologia, etc. [3].

Diferentes projetos com fatores de contexto semelhantes podem apresentar métricas de estimativa de esforço bastante diferentes entre si. O desvio de esforço entre esses projetos se deve às mudanças nos demais atributos, aqueles que não são atributos de contexto, e são chamados de atributos de influência. Esses atributos são inúmeros e dificilmente um modelo será capaz de analisar todos, portanto o importante é analisar os fatores de influência mais importantes do projeto a ser estimado [3]. Os atributos de influência geralmente são expressos quantitativamente. São exemplos: métricas de tamanho de software, quantidade de programadores, tempo de execução, métricas de qualidade, análise de risco, entre outros.

Diversos estudos tem sido aplicados para encontrar uma relação entre os atributos e métricas de software como produtividade, esforço, risco, qualidade e outros, vide [3], [7], [8], [9], [10]. De fato a escolha dos atributos é relevante em modelos de estimativa, porém no momento da estimativa, pode

Atributos de Influência	Frequência
Qualificação e experiência do time	64
Experiência com a linguagem de programação	16
Experiência e familiaridade com a aplicação	16
Experiência e habilidade do gestor do projeto	15
Complexidade do software	42
Tamanho e complexidade da base de dados	9
Complexidade da arquitetura	9
Complexidade da interface com outros sistemas	8
Projeto	41
Pressão do calendário	43
Desenvolvimento descentralizado/Multisite	9
Uso de Ferramentas de qualidade/efetividade	41
Ferramentas de CASE	12
Ferramentas de teste	5
Atributos de Contexto	
Linguagem de programação	29
Domínio	14
Tipo de desenvolvimento	11

Figura 2. Fatores mais impactantes na produtividade de software fonte: Trendowicz e Münch (2009)

ser difícil mensurar certos atributos. A utilização do modelo baseado em analogia minimiza essa dificuldade pois utilizará as medidas dos casos análogos.

Segundo [11] a estimativa de esforço pode ser impactada por diversos fatores e suas interações, o autor cita como exemplo o aumento da produtividade quando há decréscimo na qualidade. Apesar da relação citada ser facilmente inferida, outras podem não ocorrer da mesma maneira. Assim utilizar um atributo a , que possua interação com um atributo b , e não utilizar o atributo b ou vice-versa pode enviesar o modelo.

Em seu trabalho Trendowicz e Münch (2009) [3] fizeram uma revisão literária dos atributos mais utilizados em trabalhos científicos e de experiências corporativas sobre estimativas de custo e esforço. Os autores consideraram que atributos relacionados à capacidade e experiência do time são os que mais influenciam medidas de produtividade, que por sua vez estão diretamente relacionadas com a medida de esforço conforme pode ser visto na figura 2 [3]. Trendowicz e Münch (2009) classificaram os atributos em sub grupos e classificaram sua relevância de acordo com sua utilização em estudos anteriores.

A escolha dos atributos, para a caracterização da base de projetos análogos, deve ser baseada nos dados disponíveis na base de conhecimento, e deve considerar a relação entre a influência dos atributos na estimativa de esforço e a dificuldade de mensuração. Deve também incluir ou excluir conjuntos de atributos que possuam interações entre si.

III. RESULTADOS ESPERADOS

É possível comparar o esforço previsto com o esforço real e obter as métricas de erro relativo. Segundo Bardsiri, Jawawi e Khatibi (2014), as métricas MRE (magnitude do erro relativo), $MMRE$ (média da magnitude do erro relativo), $MdRE$

(mediana da magnitude do erro relativo), *PRED* (percentual de previsão) e *MSE* (erro quadrado médio) têm sido utilizadas como medida de desempenho do ABE. Ainda segundo Bardsiri, Jawawi e Khatibi (2014), *MMRE* e *PRED* foram as métricas mais utilizadas pelos pesquisadores, com percentual de uso de 92% e 88% respectivamente.

Apesar disso não existe um consenso entre os pesquisadores sobre a melhor métrica de avaliação de desempenho, portanto faz se necessário utilizar métricas que evitem resultados enviesados. Bardsiri, Jawawi e Khatibi (2014) e Kocaguneli *et al* (2012) recomendam a utilização de testes estatísticos como o de *Wilcoxon* para evitar o viés nos resultados. A partir da análise do erro é possível obter eficácia da técnica de acordo com os atributos escolhidos.

Ao variar a escolha dos atributos para caracterização, será possível analisar o comportamento da eficácia da técnica. Essa análise fornecerá dados para validação dos estudos feitos por [3], [7], [8], [9], [10]. A validação ou não desses estudos trará confirmações valiosas para o entendimento das estimativas baseadas em analogia, ou abrirá campo para novas indagações, assim propiciando e fomentando um melhor entendimento do modelo.

IV. CONCLUSÃO

O propósito desse trabalho é analisar o impacto dos atributos de projetos em modelos parametrizáveis de estimativa de projetos de software baseados em analogia. Com esse resultado espera-se obter uma visão pragmática da utilização de atributos de projetos em modelos de estimativa baseados em analogia, avaliando a escolha de cada atributo de acordo com sua influência na medida de eficácia do modelo.

O resultado desse trabalho irá propiciar um melhor entendimento das nuances entre os atributos e as estimativas de projetos de software baseadas em analogia. Esse entendimento servirá para melhorar a compreensão dos modelos de estimativa baseados em analogia, principalmente no que diz respeito à escolha dos atributos do modelo.

REFERÊNCIAS

- [1] BOEHM, B.; ABTS, C.; CHULANI, S. Software development cost estimation approaches—a survey. *Annals of software engineering*, Springer, v. 10, n. 1-4, p. 177–205, 2000.
- [2] TRENDOWICZ, A.; JEFFERY, R. *Software Project Effort Estimation: Foundations and Best Practice Guidelines for Success*. [S.l.]: Springer, 2014.
- [3] TRENDOWICZ, A.; MÜNCH, J. Factors influencing software development productivity—state-of-the-art and industrial experiences. *Advances in computers*, Elsevier, v. 77, p. 185–241, 2009.
- [4] KEUNG, J. Software development cost estimation using analogy: A review. In: *2009 Australian Software Engineering Conference*. [S.l.: s.n.], 2009. p. 327–336. ISSN 1530-0803.
- [5] SHEPPERD, M.; SCHOFIELD, C. Estimating software project effort using analogies. *IEEE Transactions on software engineering*, IEEE, v. 23, n. 11, p. 736–743, 1997.
- [6] WALKERDEN, F.; JEFFERY, R. An empirical study of analogy-based software effort estimation. *Empirical software engineering*, Springer, v. 4, n. 2, p. 135–158, 1999.
- [7] KITCHENHAM, B. A.; HUGHES, R. T.; LINKMAN, S. G. Modeling software measurement data. *IEEE Transactions on Software Engineering*, IEEE, v. 27, n. 9, p. 788–804, 2001.

- [8] SAUER, C.; GEMINO, A.; REICH, B. H. The impact of size and volatility on it project performance. *Communications of the ACM*, ACM, v. 50, n. 11, p. 79–84, 2007.
- [9] SHIM, J. et al. Coproduction in successful software development projects. *Information and Software Technology*, Elsevier, v. 52, n. 10, p. 1062–1068, 2010.
- [10] TRENDOWICZ, A. et al. Integrating human judgment and data analysis to identify factors influencing software development productivity. *e-Informatica*, v. 2, n. 1, p. 47–69, 2008.
- [11] PREMRAJ, R. et al. An empirical analysis of software productivity over time. In: *IEEE. Software Metrics, 2005. 11th IEEE International Symposium*. [S.l.], 2005. p. 10–pp.
- [12] BARDSIRI, V. K.; JAWAWI, D. N. A.; KHATIBI, E. Towards improvement of analogy-based software development effort estimation: A review. *International Journal of Software Engineering and Knowledge Engineering*, World Scientific, v. 24, n. 07, p. 1065–1089, 2014.
- [13] KOCAGUNELI, E. et al. Exploiting the essential assumptions of analogy-based effort estimation. *IEEE Transactions on Software Engineering*, IEEE, v. 38, n. 2, p. 425–438, 2012.

Autonomous Vehicle Control: Strategy for Preventing Accidents in the Context of Autonomous Vehicles

Controle Veicular Autônomo: Estratégia para Prevenção de Acidentes no Contexto de Veículos Autônomos

TANCREDI MOLINA, C. B. S.; De ALMEIDA JR, J. R.
Grupo de Análise de Segurança - Universidade de São Paulo
{cbmolina, jorgerady}@usp.br

Abstract—Technological development and the massive investment in ‘intelligent’ vehicle technologies are going to turn autonomous vehicles into reality in a few years. The insertion of this intelligence at the road vehicles is expected to cause a reduction in traffic accidents due to the mitigation of human drivers errors by computerized autopilots. However, autonomous vehicles shall mitigate the existing hazards at the roadway transportation systems while not creating new hazards. Thus, It is important to study how to ensure safety in this new scenario. This paper proposes a design strategy for the architecture design level of autonomous vehicles that may facilitate the development, analysis and, safety level assuring. The main idea is to implement an independent module – the Autonomous Vehicle Control (AVC) – that is going to both interact with the vehicle's systems and create a protection layer. So, this paper presents the AVC module and how this module is going to be tested.

Keywords—Safety; Autonomous Vehicles; Autonomous Vehicle Control.

Resumo—O desenvolvimento tecnológico e o elevado investimento em tecnologias de veículos "inteligentes" vão transformar veículos autônomos em realidade em alguns anos. A inserção desta inteligência nos veículos rodoviários deverá causar uma redução nos acidentes de trânsito devido à mitigação de erros de motoristas humanos por máquinas. Contudo, os veículos autônomos devem mitigar os perigos existentes nos sistemas de transporte rodoviário, sem criar novos riscos. Assim, é importante estudar como garantir a segurança crítica (*safety*) neste novo cenário. Este artigo propõe uma estratégia de *design* para o nível de arquitetura de veículos autônomos que podem facilitar o desenvolvimento, a análise, além de assegurar o nível de segurança crítica adequado. Assim, deseja-se implementar um módulo independente - o Controle Veicular Autônomo (CVA) - que vai interagir com os sistemas do veículo e criar uma camada de proteção. Então, este artigo apresenta o módulo CVA e como este módulo será testado.

Palavras-chave—Safety; Veículos Autônomos; Controle Veicular Autônomo.

Classificação— Mestrado

Categoria— Intermediária

I. INTRODUÇÃO

Nos últimos anos, há uma maior preocupação com *safety*¹ e a confiabilidade dos sistemas de transporte [1]. Assim, estão se atentando para fazer com que as pessoas e bens cheguem aos seus destinos de forma segura.

De acordo com [2] alguns fatores afetam a *safety* veicular em situações de tráfego rodoviário, dentre os quais tem-se:

- a condição do veículo (por exemplo, condição dos pneus, desgaste dos componentes veiculares, entre outros);
- o ambiente ao redor do veículo, o qual contém características sobre o clima, a superfície da via, obstáculos e as condições de tráfego;
- e as habilidades de condução do motorista, incluindo sua condição física e mental.

Considerando esses fatores, o que mais contribui na causa de acidentes no cenário rodoviário é o relacionado à condução dos motoristas. De acordo com [3], o número de acidentes de trânsito causados por erros humanos (condução humana) corresponde a 94% dos acidentes fatais que ocorrem.

Neste contexto estão inseridos os veículos autônomos, os quais começaram a ser desenvolvidos e estudados já que poderiam melhorar o cenário atual do sistema de transporte rodoviário (STR).

Há muita especulação a respeito do impacto dos veículos autônomos no STR atual. Acredita-se que os mesmos podem estender os sistemas de mobilidade, permitindo que se viaje automaticamente entre locais de alta demanda, o que ajudaria a resolver problemas como o congestionamento, o uso adequado do espaço rodoviário, a poluição e, até mesmo, o consumo de energia [4].

Os veículos autônomos também poderiam reduzir o número de acidentes rodoviários uma vez que os comandos e as decisões de direção seriam tomadas por sistemas embarcados

¹ Neste artigo *safety* é definido como a ausência de consequências catastróficas para o usuário

nos veículos que possuem uma elevada consciência situacional para tomada de decisão devido à interação que fazem com equipamentos (sensores, LIDAR, entre outros) presentes nos mesmos. Desta forma, os sistemas que controlam um determinado veículo poderiam ter informações para tomada de decisão que muitas vezes são perdidas pelo motorista devido às distrações, podendo, assim, controlar o veículo de uma maneira mais adequada.

No cenário atual, os veículos autônomos que estão sendo desenvolvidos estão relacionados aos modelos de veículo apresentados no projeto da DARPA² (*Defense Advanced Research Projects Agency*). Assim, basicamente, são sistemas robotizados que interagem com o ambiente. Isto foi viabilizado devido ao avanço da tecnologia, especificamente nas área de robótica, de detecção (relacionada a sensores), de sistemas embarcados, de sistemas de navegação, entre outros [5], resultando no desenvolvimento de sensores de alta tecnologia, de câmeras e de radares que seriam utilizados para monitorar o veículo em questão e o ambiente ao redor do mesmo.

Safety é uma importante propriedade em qualquer sistema, particularmente em sistemas de transporte como o sistema de transporte rodoviário, no qual existe interação entre veículos, motoristas, via e ambiente (entorno como obstáculos e pedestres). Assim, ao inserir veículos autônomos nesse sistema, pelo menos o mesmo nível de *safety*, que já é atingido quando se tem pessoas controlando diretamente o veículo, deve ser garantido. Como resultado, algumas pesquisas vêm sendo desenvolvidas principalmente as relacionadas ao desenvolvimento de algoritmos de planejamento e controle que poderiam garantir *safety* [6] e as tecnologias de design (sistemas de alerta longitudinais e laterais) que podem ser úteis para evitar colisões [7]. Mesmo que a ideia proposta nessas pesquisas tenha tido a intenção de deixar o sistema de veículos autônomos mais seguros, nenhuma aborda como podem, a nível do sistema, contribuir para melhorar os níveis de segurança dos veículos autônomos. [8]

Portanto, seria importante saber como um veículo totalmente autônomo deve ser desenvolvido para que o mesmo possa atingir certos níveis de *safety*, já que não haverá um motorista que estará monitorando o veículo e o ambiente durante todo o percurso. Porém, ainda não existe um padrão para o desenvolvimento e testes de tais veículos. Atualmente, existe um padrão internacional ISO 26262 para Sistemas Automotivos Elétricos/Eletrônicos que define características funcionais de *safety* para equipamentos automotivos aplicáveis ao longo do ciclo de vida de todos os sistemas automotivos elétricos e eletrônicos de *safety* [9]. No entanto, veículos autônomos não estão em seu escopo.

Assim, este artigo apresenta a proposta de uma estratégia de design que poderá ser considerada durante a fase de projeto de um veículo autônomo, a qual tem como principal objetivo fazer com que o veículo em questão atinja os níveis de segurança adequados. O elemento principal desta estratégia é o módulo denominado Controle Veicular Autônomo (CVA), o

qual independe do desenvolvimento do veículo (parte mecânica do veículo e a carcaça do mesmo).

Desta forma, o CVA seria responsável por controlar o veículo; em outras palavras, seria um módulo que exerce as funções do motorista de uma maneira mais segura. Assim, além das funcionalidades básicas do motorista (controle e monitoramento do veículo), este módulo proporcionaria uma camada de proteção que poderia ser o submódulo responsável por assegurar *safety* para o veículo e seus ocupantes.

A abordagem presente no CVA (camada de proteção) seria interessante uma vez que para garantir que estes veículos operem de forma segura seria necessário realizar diversos testes dos sistemas do veículo autônomo em vários cenários, abordando todas as situações que o mesmo poderia encontrar no dia a dia, o que é inviável. Assim, esse módulo faz com que a camada de proteção denominada Proteção Veicular Autônoma (PVA) seja o principal modo a ser inspecionado, uma vez que será o responsável por assegurar *safety*.

Este artigo além de apresentar o CVA, também explicará como o mesmo será testado e analisado. Assim, o mesmo é estruturado em três seções. A primeira seção se refere a introdução, a qual apresenta brevemente o contexto do trabalho e a proposta do mesmo. A segunda seção apresenta uma explicação da proposta. Por fim, a última seção apresenta o ambiente de simulação no qual será testado o CVA e como os testes serão efetuados.

II. CONTROLE VEICULAR AUTÔNOMO

Um dos pontos críticos ao se falar em veículos autônomos é como os mesmos vão se comportar ao se depararem com uma situação de perigo, a qual pode ser ocasionada pelo próprio sistema uma vez que sistemas complexos (como é o caso em questão) podem apresentar um comportamento não previsível. Desta forma, os veículos autônomos devem ser capazes de identificar o estado dos elementos pertencentes às situações mais críticas para que, quando estiverem em tais situações, consigam identificá-las e contorná-las a fim de atingir um estado de falha seguro. Em outras palavras, veículos autônomos devem estar preparados para lidarem com situações anormais e inesperadas. Assim, como contornar tais situações sem deixar o sistema mais complexo ainda?

No cenário atual quando uma situação perigosa acontece, o responsável por tirar o veículo desta situação é o motorista, mesmo se o veículo tiver algum nível de automação. Assim, é o motorista quem tem a missão de controlar adequadamente o veículo, então é ele quem monitora e detecta algum problema de *safety* (ou operação anormal) tanto no sistema veicular quanto no ambiente ao redor do mesmo. Desta forma, ao se falar em veículos totalmente autônomos o motorista autônomo deve existir uma vez que a relação entre veículo, motorista e ambiente já existente no sistema de transporte rodoviário atual continuará a mesma, porém o motorista que monitorará o ambiente e o veículo autônomo, e que controlará este último vai ser representado por um sistema (máquina).

Propõe-se, então, a criação de um sistema denominado Controle Veicular Autônomo (CVA), o qual será responsável por controlar o veículo. Vale ressaltar que, de acordo com [10]

² DARPA Urban Challenge foi o primeiro projeto a propor que veículos autônomos fossem capazes de interagir com outros veículos e de tomar decisões complexas de direção com foco em *safety*.

existem 6 possíveis níveis de automação (denotados de 0 - 5), porém este trabalho considera o nível 5 de automação, no qual não há nenhuma interação humana.

A arquitetura do módulo CVA é composta por duas camadas hierárquicas (Fig. 1), na qual a camada mais baixa é responsável por proteger o veículo em movimento e controlá-lo em situações de perigo. O módulo CVA é análogo ao conceito do Controle Automático do Trem.

Considerando a arquitetura do módulo CVA, ele contém duas camadas: uma relacionada com a parte operacional do veículo (Operação Veicular Autônoma - OVA) e a outra responsável por proteger o estado do veículo e de seus passageiros (PVA). Assim, este módulo separa a camada de proteção da de operação, facilitando o desenvolvimento de veículos autônomos uma vez que toda a inteligência não vai estar distribuída no veículo e sim organizada no CVA.

O submódulo OVA é responsável pela navegação do veículo, por controlar a direção e corrigir a velocidade. Já, o submódulo PVA monitora as variáveis do sistema (por exemplo a velocidade do veículo), e se estas excedem seus respectivos limites de segurança (no caso da velocidade, a mesma poderia exceder a velocidade máxima da via), o submódulo em questão leva o veículo a um estado seguro (por exemplo, reduzindo a sua velocidade). Além disso, o PVA monitora o sistema veicular e, caso detecte alguma situação de falha, o leva ao estado seguro. Assim, o PVA está sempre monitorando alguns elementos tanto internos quanto externos ao veículo, a fim de detectar situações (problemas e falhas) perigosas e, ao detectar tais situações, levar o veículo a um estado seguro.

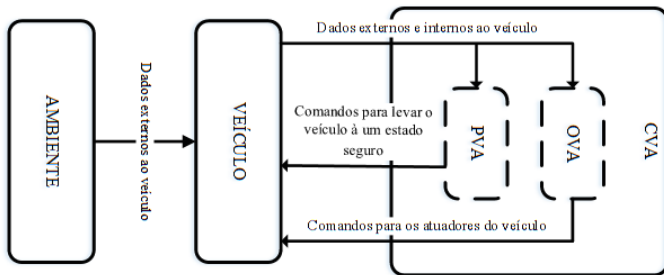


Fig. 1. Representação básica do CVA interagindo com o STR.

A Fig. 1 apresenta um esquema do sistema apresentado. Nela é possível observar que ambos os submódulos recebem dados provenientes do veículo sobre o ambiente e o seu estado e, depois de processá-los e analisá-los enviam comandos de controle ao veículo.

A. Detalhamento Dos Submódulos

Para se desenvolver os submódulos do CVA deve-se considerar as funcionalidades dos subsistemas básicos presentes em alguns veículos autônomos, os quais são: sensoriamento, percepção, planejamento e controle. Assim, considerando tais funcionalidades, os submódulos (OVA e PVA) são descritos da seguinte forma (esquema presente na Fig. 2):

- OVA é o submódulo que interpreta os dados que são provenientes do subsistema de sensoriamento que está embarcado no veículo (funcionalidade do subsistema de percepção), determina a rota do veículo e as eventuais manobras a partir da interpretação dos dados (funcionalidade do subsistema de planejamento) e manda comandos ao veículo (funcionalidade do subsistema de controle). Os comandos que são enviados ao veículo são relacionados a novos valores de aceleração, e/ou novos valores de frenagem, e/ou novos valores de coeficientes angulares (utilizados nas manobras).
- PVA é o submódulo que monitora o ambiente por meio de um subsistema de sensoriamento independente do que é utilizado no OVA. Este subsistema obtém os dados necessários que permite que o PVA observe os elementos que podem levar a uma situação insegura, como por exemplo as condições de tráfego e o clima. Assim, observando tais elementos ele consegue impor ações restritivas ao movimento do veículo sempre que um problema de segurança é detectado. Desta forma, o PVA também consegue mandar comandos ao veículo.

Pode-se observar que o OVA e o PVA são submódulos independentes a partir dos quais se obtém comandos para conduzir o veículo. No entanto, como o PVA é a camada de proteção, os comandos provenientes deste submódulo são prioritários. Além disso, é importante mencionar que o PVA não fica constantemente enviando comandos ao veículo, ele só o faz quando detecta algum problema que pode colocar em risco o veículo e seus passageiros. Acredita-se que não só o veículo e seus passageiros devem estar seguros, mas, também, o veículo não pode gerar situações que afetam negativamente o ambiente ao seu redor. Porém, ao considerar este último aspecto o comportamento do PVA fica um pouco mais complexo. Desta forma, neste trabalho de mestrado este aspecto não será considerado.

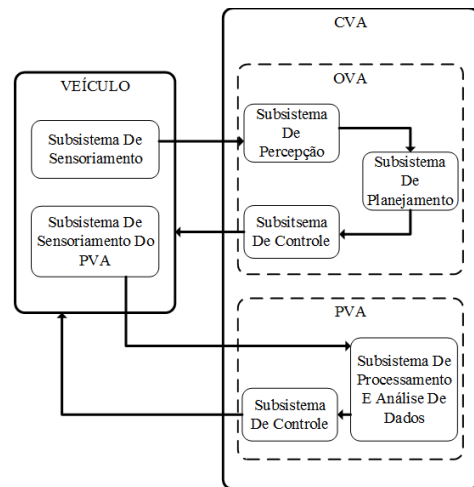


Fig. 2. Representação do CVA.

Anteriormente os submódulos foram detalhados, assim o módulo CVA já pode ser implementado a fim de ser analisado

quanto a sua capacidade de prevenir acidentes no STR. Assim, a próxima seção apresenta o ambiente de simulação e uma breve explicação dos testes que serão efetuados.

III. AMBIENTE DE SIMULAÇÃO

O ambiente de simulação foi desenvolvido após um estudo a respeito dos elementos do STR, suas especificações e interações, sobre o contexto de Sistemas de Transportes Inteligentes (STI). Assim, o ambiente foi implementado no OpenDS e no Matlab de modo a representar adequadamente o funcionamento do STR. Isto foi feito uma vez que, como o objetivo é avaliar o CVA, seria importante que o mesmo fosse inserido em um ambiente que fosse próximo ao real. Em outras palavras, um ambiente que expusesse o veículo autônomo a situações de perigo encontradas no STR atual.

O OpenDS, que é um simulador de direção *open-source*, foi escolhido uma vez que possui funcionalidades e recursos já desenvolvidos para a área automotiva e, também, por possibilitar a alteração e adaptação do código fonte e até mesmo seu reuso.

Assim, o código fonte do OpenDS foi alterado a fim de ser possível modelar adequadamente um cenário do STR que possui um determinado ambiente no qual o veículo trafega e os obstáculos que o mesmo pode encontrar em seu trajeto. Desta forma, pretende-se inserir um veículo autônomo sem a arquitetura do CVA neste ambiente considerando um cenário de teste (consiste de vias, veículos não autônomos e objetos estáticos, os quais podem surgir em tempo de simulação) específico e analisar/observar os pontos em que ocorrem situações de perigo e até mesmo colisões. Em seguida, pretende-se inserir o mesmo veículo autônomo com o CVA e analisar/observar como o mesmo se comporta nas mesmas situações de perigo e, até mesmo, se novas situações e colisões ocorrem.

Além deste, pretende-se, inicialmente, desenvolver um cenário básico no qual estará presente o veículo autônomo e um obstáculo estático distante do mesmo e, quando a simulação começar, o veículo trafega em direção ao objeto. A finalidade será analisar as curvas de frenagem do veículo autônomo quando o mesmo estiver com e sem a arquitetura do CVA.

É importante ressaltar que o veículo autônomo possui seu controle autônomo externo ao OpenDS. Assim, foi utilizado o Matlab para se implementar o motorista autônomo. Portanto, se utilizará a interface gráfica do OpenDS para representar o cenário de teste, mas o controle autônomo no qual estará instanciado o CVA será feito no Matlab.

A Fig. 3 representa o ambiente de simulação desenvolvido. Nela é possível observar que os elementos do STR estão presentes no OpenDS e que o motorista autônomo, o qual pode ou não ser representado pelo CVA, está presente no Matlab.

IV. CONSIDERAÇÕES PRELIMINARES

Foi observado até o momento que o módulo CVA consegue representar as funcionalidades necessárias para se desenvolver corretamente um veículo autônomo. Portanto, o próximo passo é realizar simulações considerando os elementos que precisam ser monitorados e as situações levantadas (maiores detalhes serão apresentados juntamente aos resultados das simulações).

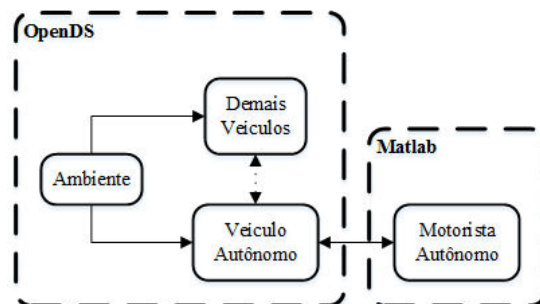


Fig. 3. Ambiente de simulação.

AGRADECIMENTOS

Agradecemos a Ericsson Telecomunicações S.A.

REFERÊNCIAS

- [1] WORK, D.; BAYEN, A. and JACOBSON, Q. Automotive Cyber Physical Systems in the Context of Human Mobility. In: National Workshop On High-Confidence Automotive Cyber-Physical Systems, Troy,USA,2008.
- [2] REIF, K. Brakes, Brake Control and Driver Assistance Systems: Function, Regulation and Components. Germany: Springer, 2014. DOI: 10.1007/978-3-658-03978-3.
- [3] POST GAZZETE. Disponível em: <http://www.post-gazette.com/opinion/OpEd/2016/09/19/Barack-Obama-Self-driving-yes-but-also-safe/stories/201609200027>. Acesso em: Junho, 2017.
- [4] CAMPBELL, M. et al. Autonomous driving in urban environments: approaches, lessons and challenges. Philosophical Transactions: Mathematical, Physical and Engineering Sciences, v. 368, n. 1928 , p. 4649-4672, Outubro 2010.
- [5] E. OHN-BAR, E. and TRIVEDI, M. M. Looking at Humans in the Age of Self-Driving and Highly Automated Vehicles. IEEE Transactions on Intelligent Vehicles, v. 1, n. 1, p. 90-104, Março 2016.
- [6] PADEN, B. et al. Survey of Motion Planning and Control Techniques for Self-Driving Urban Vehicles. IEEE Transactions on Intelligent Vehicles, v. 1, n. 1, p. 33-55, Março 2016.
- [7] BEVLY, D. et al. Lane Change and Merge Maneuvers for Connected and Automated Vehicle: A Survey. IEEE Transactions on Intelligent Vehicles, v. 1, n. 1, p. 105-120, Março 2016.
- [8] MOLINA, C. B. S. T. et al. Assuring Fully Autonomous Vehicles Safety by Design: The Autonomous Vehicle Control (AVC) Module Strategy. In: Annual Ieee/Ifip International Conference On Dependable Systems And Networks Workshops,Denver,USA,2017.
- [9] ISO. International Organization for Standardization. Disponível em: <https://www.iso.org/standard/43464.html>. Acesso em: 24 de Março de 2017.
- [10] SAE INTERNACIONAL J3016. Surface Vehicle Recommended Practice. Disponível em: J3016_201609.pdf. Acesso em: Fevereiro, 2017.

PROFTS: A MultiAgent System for Stock Portfolio Management

REIS, E. R.*; SICHMAN, J. S.*

*LTI - Intelligent Techniques Laboratory - School of Electrical and Computer Engineering

E-mail: everton.rreis@usp.br, jaime.sichman@poli.usp.br

Abstract—Portfolio management is a challenging task. When trying to do it autonomously, it becomes more complex. Most of automated trading systems (ATS) focus on maximizing return, without considering the risk, and just a few of them consider the trade-off between risk-return. MultiAgent Systems is a suitable approach to develop ATSs, given its agent's characteristics. This work proposes a Multiagent System architecture, called PROFTS, to manage an active automated stock portfolio, according to investor's risk profile, using both, fundamental and technical analysis. The system will be validated throughout simulations in the Brazilian stock market using AgEx, a financial market simulation for agents. Some prior results regarding the technical agents are promising.

Keywords— automated trading system; portfolio management; multiagent system; machine learning.

Classification— Master's degree.

Category— Beginner.

I. INTRODUCTION

Portfolio Management is a challenging task, it is necessary to decide which assets to buy, when, its price and quantity. Trying to do it autonomously, with an automated trading system (ATS), increases the problem's complexity. That is why this is a problem with unknown optimal solution.

When talking about equity portfolio management, there are basically two strategies to be adopted, the passive or active management. A passive management tries to replicates the performance of a specific benchmark, such as an index, while an active management tries to earn a return that exceeds the return of a passive benchmark portfolio, net of transaction costs and on a risk-adjusted basis. The amount of value that the active manager has added or subtracted from the portfolio is the generated *alpha* [1].

MultiAgent System (MAS) is a suitable approach to manage an active automated portfolio, because agents are *autonomous*, they operate without human interference and have control about its actions and internal state, are *social*, they can cooperate or compete to achieve a task, are *reactive*, they perceive its environment and act changing it, and are also *proactive*, acting without a response of its environment, in a goal-directed behavior [2].

The optimal portfolio, is the one that has the highest utility for a given investor. Each investor has its own utility curve, that specify the trade-off between expected return and risk [1], so, it is important to manage a portfolio based on investor's profile.

When analyzing which asset to buy, there are basically two general approaches to adopt, the top-down and the bottom-up, and both can be used with fundamental or technical analysis. In the top-down approach, economy, market and industry affects the return of an individual stock, while in the bottom-up, the manager looks for stocks that are undervalued relative to their market price, and it is expected that these will provide superior returns regardless of the economy and industry outlook [1].

Using the bottom-up approach for equity valuation with fundamental analysis, the manager can apply a valuation model based on discounted cash flow, where the value of the stock is estimated based in the present value of some measure of cash flow, or relative valuation, where the value of a stock is estimated relatively to the price of similar companies. With Technical analysis, the future price movements are forecast based on past stock price changes or other stock market data [1].

In this work, it will be described a Multiagent System to manage an active automated portfolio, considering different investor's profile and using relative valuation and technical analysis.

II. RELATED WORK

This work is based on [3]. The author developed a multiagent system that uses strategies derived from technical indicators and capable of satisfying different investor's profiles, that were: (I1) investor with maximal acceptable risk, (I2) with desired target return, (I3) with limited risk-return and (I4) with free risk and return. The results were simulated using AgEx [4], a financial market simulation tool for software agents, developed by the same author.

Another important reference is [5], where the authors developed a multiagent system that use fundamental information in its reasoning process. There was an agent called "Price Analyst" that used some models of discounted cash flow (Fundamental Analysis), and "Indexes Analysts" that used strategies based on multiples (e.g. Price/Profit).

Fundamental analysis is rarely used on automated trading systems, most of ATS are based on technical analysis. A very recent survey published by Cavalcante [6] listed 56 work categorized by its main goal, application, input variables (if it used fundamental or technical data), the machine learning techniques used and if it was a Trading System. From 56 work,

just 5 of them used Fundamental analysis and from these, just 2 were Trading System.

Another relevant article for this work was published by Junior and Galdi [7]. They compared the valuation performance of relative valuation, using cluster analysis (a combination of Ward's method with K-means) and economic sectors when identifying similar companies.

As far as we know, we are the first one to combine fundamental analysis and technical analysis to autonomously manage an active portfolio that deal with different investor's profiles.

III. PROPOSED APPROACH

A. About the Inspiring System

To understand our proposal, it is interesting to firstly introduce the one proposed by Castro [3]. He developed two societies, the first one was CTCS (Coach,Trader,Conflict Solver) and the second one was COAST (COmpetitive Agent SocieTy), and a financial market simulation tool for agents, called AgEx.

The COAST architecture, that is used as reference to this work, is presented at figure 1. In this example we have three different strategies for three different assets. The agents $\mu 1$, $\mu 2$, and $\mu 3$ are based on strategies composed by a single technical indicator, e.g. using RSI (Relative Strength Index) with period of 14 days, the agent recommend to buy if it is higher than 70% and to sell if it is equal or lower than 70%.

They are competitive agents, and they send a recommendation based on their strategy. There are also the coordinators agents, that allocate resources between the advisors and evaluate them. The advisors just communicate with their coordinator, because they are competitive and compete for resources. On the other hand, a coordinator communicate with others coordinators and they negotiate the resources that will be allocated between them.

According to the market situation (state of the environment) and the investor's profile, agents can adopt different goals, such as: (i) risk minimization, (ii) return maximization, or (iii) efficiency maximization (Sortino Ratio Maximization). It is represented at table I.

B. About our System

We adopted the same investor's profile and goals idea, but with a new architecture called PROFTS (PROfitable Fundamental and Technical System).

The architecture is presented at Figure 2. It is composed of scrapers, a fundamentalist agent, technical agents and coordinators.

The scrapers are responsible for gathering fundamental data from the internet about each stock, respecting the Robots Exclusion Protocol (/robots.txt). This protocol tells to the agent what it can access or not at a determined domain [8]. They also calculate some fundamental indicators for the regression that will be performed by the fundamentalist agent (e.g. Beta, Payout Ratio), multiples (e.g. Price to Earnings -P/E) and financial health indicators (e.g. Quick Ratio, Net




Fig. 1. COAST society to operate with three different strategies and assets. Adapted from [3].

TABLE I
POSSIBLE GOALS FOR DIFFERENT MARKET SCENARIOS AND INVESTOR'S PROFILE

		Investor Profile			
		Maximum Risk Acceptance (I1)	Minimum Return required (I2)	Limited Risk-Return (I3)	Free Risk-Return (I4)
Market Scenarios	Acceptable Risk and Return	Return Maximization	Efficiency Maximization	Efficiency Maximization	Efficiency Maximization
	High Risk, acceptable Return	Risk Minimization	Risk Min., observing min. return	Risk Minimization	Efficiency Maximization
	Acceptable Risk, Low Return	Return Max., observing max. risk	Return Maximization	Return Maximization	Efficiency Maximization
	High Risk, Low Return	Risk Minimization	Return Maximization	Efficiency Maximization	Efficiency Maximization

Profit Margin). All these data is passed to the Fundamentalist Agent.

The Fundamentalist Agent performs relative valuation. The idea is simple, if a company is similar to another, their prices should be close. To determine if it is under or over valued, it uses multiples, like the P/E, with a regression, using company's value drivers (risk, growth and potential to generate cash flow). The challenge remains in finding similar companies, as Damodaran [9] pointed out, using companies from the same sector or industry as comparable companies, may be incorrect, since they vary in size, risk profile and others characteristics. To solve this problem in a autonomous way, the fundamentalist agent cluster similar companies using X-means [10], a K-means based algorithm that automatically finds the best value for "K" through model selection, using Bayesian Information Criterion (BIC). The companies identified as undervalued, are selected to create the portfolio. The portfolio

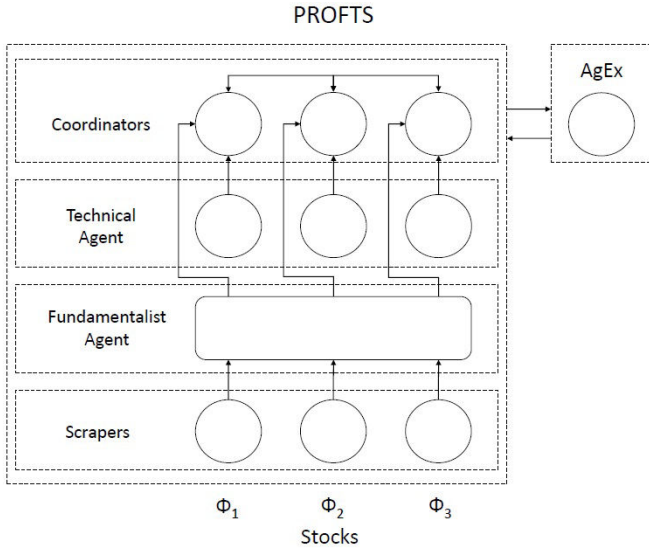


Fig. 2. PROFTS society to operate with three different assets.

is optimized based on investor's preferences. For example, if investor's profile is of type (I1), with maximal acceptable risk, the weights of each asset in the portfolio is found solving an optimization problem like the one proposed at Equation 1, where the acceptable level of risk σ_p^2 is fixed, and the expected return $E(\mathbf{r})$ is maximized.

$$\begin{aligned} & \underset{w}{\text{Minimize}} && -\mathbf{w}'E(\mathbf{r}) \\ & \text{subject to} && \sum_{i=1}^n w_i = 1 \\ & && \sigma_p^2 = \mathbf{w}'\mathbf{V}\mathbf{w} \\ & && w_i \geq 0, \forall i \end{aligned} \quad (1)$$

If investor's profile is of type (I2), with minimum return required, so the weights for the portfolio are given by Equation 2, that minimizes the risk subject to a \bar{R} level of return. The other constraints ensure that the sum of stocks weights equals 1 and are nonzero.

$$\begin{aligned} & \underset{w}{\text{Minimize}} && \mathbf{w}'\mathbf{V}\mathbf{w} \\ & \text{subject to} && \sum_{i=1}^n w_i = 1 \\ & && \mathbf{w}'E(\mathbf{r}) = \bar{R} \\ & && w_i \geq 0, \forall i \end{aligned} \quad (2)$$

After the optimal portfolio is calculated, based on investor utility, the orders are sent to coordinators, that communicate with the AgEx system. A new portfolio will be optimized after four months, when Ibovespa is also rebalanced.

The technical agents, uses a support vector machine (SVM) to predict stock price's direction. The SVM is fitted using technical indicators. As there are a lot of different technical indicators, and each one of them can be used with different

configurations, a feature selection is performed, filtering out relevant features from 62 possible combinations of technical indicators and its setups. The feature selection method chosen was the Correlation-based Feature Selection (CFS) [11], as a result of a previous study developed by Reis and Sichman [12]. If there is a high probability of price increase, a buy recommendation is sent to the coordinator, that will analyse the current society goal (see Table I), and calculate the new portfolio risk, return, or efficiency, to decide if it will buy or not the stock recommended by the technical agent. Efficiency here, is measured by the Sortino ratio (ST), given by Equation 3. It measures the portfolio's average return ($\bar{\mu}$) in excess to a minimum acceptable return threshold (\bar{R}), and consider just the downside risk (DR) instead of the total risk, to not penalize the "good" risk (the one associated with higher returns).

$$ST = \frac{\bar{\mu} - \bar{R}}{DR} \quad (3)$$

For example, if the portfolio is at an acceptable risk and return level, and investor has a maximal risk that was not reached, then the society goal is to maximize return, so, if the new portfolio, considering the stock recommended from the technical agent, has a higher expected return than the original one, then the stock is bought.

Finally, the coordinators are those that receive and send information for AgEx. They also calculate portfolio statistics, as balance, profit, risk, and other metrics. Coordinators communicate between them, deciding how to allocate resources. At each step more than one recommendation of buy can be received from technical agents, so coordinators will have to decide which, if any, attend to maximize society's utility.

IV. PARTIAL RESULTS

The partial results are for the technical agents. We implemented the framework that will be used to train each technical agent. In this article, we tested different techniques of feature selection to determine the best subset of features. The filter methods used were Information Gain, Symmetrical Uncertainty, ReliefF, CFS, and OneR; Wrappers were SFS-Sequential Forward Search and SBS-Sequential Backward Search; and a hybrid approach, combining filters and SBS.

At table II it is possible to see which technical indicators were used, and at table III it is possible to see the results obtained. The machine learning technique used was a SVM (Support Vector Machine) with a RBF kernel (Radial Bases Function). The parameters $Cost(C)$ and $gamma(\gamma)$ were obtained through a grid search procedure. The grid space of C was $\log_2 C \{-5, -3, \dots, 15\}$ and for γ was $\log_2 \gamma \{-15, -13, \dots, 3\}$. We analyzed the Ibovespa index, and now this model can be expanded to other stocks.

It is possible to see that we achieve good predictive results. More details about the methodology can be obtained at [12]. We chose CFS filter because it had a good accuracy in the test set (69,94%) and it is computationally cheap.

V. FUTURE WORK

The fundamentalist agent and scrapers are at an advanced stage of development. In the next steps we have to implement the coordinators, and make the integration between the MAS and AgEx.

When the system was completed, we will perform a portfolio backtesting to validate our system, and compare its results with those obtained by the Buy and Hold Strategy and the Ibovespa index, that will be used as benchmark.

TABLE II
TECHNICAL INDICATORS AND PARAMETERS FROM TTR PACKAGE
(DOCUMENTATION AVAILABLE AT [13]).

Feature	Description	Technical Trading Rules
MACD9	Moving average Convergence/Divergence	MACD (maType = 'EMA')
BOLL20	Bollinger Bands	BBands (n = 20)
K9	Stochastic	stock (default)
WR10	William's Over- bought/Oversold Index	WPR (n = 10)
RSI6	Relative Strength Index	RSI (n = 6)
RSI14	Relative Strength Index	RSI (default)
TRIX9	Triple Smoothed Exponential Oscillator	TRIX (n = 9)
TRIX20	Triple Smoothed Exponential Oscillator	TRIX (default)
CCI14	Commodity Channel Index	CCI (n = 14)
CCI20	Commodity Channel Index	CCI (default)
SMA5	Simple Moving Average	SMA (n = 5)
SMA30	Simple Moving Average	SMA (n = 30)
SMA200	Simple Moving Average	SMA (n = 200)
EMA5	Exponential Moving Average	EMA (n = 5)
EMA30	Exponential Moving Average	EMA (n = 30)
EMA200	Exponential Moving Average	EMA (n = 200)
ADX14	Welles Wilder's Directional Movement Index	ADX (maType = 'EMA')
AROON20	Aroon	aroon (default)
ATR14	Average True Range	ATR (default)
chaikinvolatility10	Chaikin Volatility	chaikinVolatility(default)
CMO14	Chande Momentum Oscillator	CMO (default)
DPO10	De-Trended Price Oscillator	DPO (default)
ROC	Rate of Change/Momentum	ROC (default)
SAR	Parabolic Stop-and-Reverse	SAR (default)
ultimateOscillator	The Ultimate Oscillator	ultimateOscillator (default)
VHF28	Vertical Horizontal Filter	VHD (default)
Volatility10	Volatility	volatility (default)
WilliamsAD	Williams Accumula- tion/Distribution	williamsAD (default)
WPR14	William's %R	WPR (default)

REFERENCES

- [1] REILLY, F. *Investment analysis & portfolio management*. Mason, OH: South-Western Cengage Learning, 2012. ISBN 978-0-538-48238-7.
 [2] BELLIFEMINE, F. L.; CAIRE, G.; GREENWOOD, D. *Developing multi-agent systems with JADE*. [S.l.]: John Wiley & Sons, 2007. v. 7.

TABLE III
CLASSIFICATION ACCURACIES FOR EACH MODEL AND DIFFERENT TEST
SUBSETS FOR THE IBOVESPA DATASET.

Method	N ^o Fea- tures	Training/Validation (Accuracy)	Test set (Ac- curacy)	Cost (C)	gamma (γ)
SVM	33	70,16 ± 9,04%	69,57%	2 ⁷	2 ⁻¹⁵
SVM + wrap- per_SFS	7	75,82 ± 5,57%	66,82%	2 ¹⁵	2 ⁻⁹
SVM + wrap- per_SBS	24	72,34 ± 7,82%	69,19%	2 ⁷	2 ⁻¹⁵
SVM + Informa- tion Gain (t = 0.05)	13	72,87 ± 6,57%	68,62%	2 ⁻¹	2 ⁻⁷
SVM + Symmet- rical uncertainty (t = 0.05)	15	72,17 ± 7,51%	69,57%	2 ⁵	2 ⁻¹¹
SVM + ReliefF (t = 0.01)	22	66,11 ± 13,17%	66,92%	2 ⁷	2 ⁻¹³
SVM + Cfs	9	72,50 ± 7,50%	69,94%	2 ³	2 ⁻¹¹
SVM + OneR (t = 3.5)	12	65,04 ± 10,86%	59,26%	2 ⁻¹	2 ⁻¹
SVM + IG_SBS	10	75,57 ± 5,94%	67,77%	2 ⁵	2 ⁻⁷
SVM + SU_SBS	11	74,88 ± 6,87%	69,09%	2 ¹³	2 ⁻¹⁵
SVM + ReliefF_SBS	7	72,01 ± 7,91%	69,75%	2 ¹⁵	2 ⁻¹⁵
SVM + Cfs_SBS	5	75,29 ± 6,07%	68,72%	2 ⁹	2 ⁻⁷
SVM + OneR_SBS	5	69,39 ± 8,71%	70,04%	2 ¹⁵	2 ⁻¹⁵

- [3] CASTRO, P. A. L. d. *Uma arquitetura para administração automatizada de ativos baseada em agentes competitivos*. Tese (Doutorado) — Universidade de São Paulo, 2009.
 [4] CASTRO, P. A. L. D.; SICHMAN, J. S. Agex: A financial market simulation tool for software agents. In: SPRINGER. *International Conference on Enterprise Information Systems*. [S.l.], 2009. p. 704–715.
 [5] ARAÚJO, C. H. D.; CASTRO, P. A. L. D. Towards automated trading based on fundamentalist and technical data. In: SPRINGER. *SBIA*. [S.l.], 2010. p. 112–121.
 [6] CAVALCANTE, R. C. et al. Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, Elsevier, v. 55, p. 194–211, 2016.
 [7] JUNIOR, C. G. C.; GALDI, F. C. Avaliação de empresas por múltiplos aplicado em empresas agrupadas com análise de cluster. *Revista de Administração Mackenzie (Mackenzie Management Review)*, v. 13, n. 5, 2012.
 [8] EICHMANN, D. Ethical web agents. *Computer Networks and ISDN Systems*, Elsevier, v. 28, n. 1-2, p. 127–136, 1995.
 [9] DAMODARAN, A. *Avaliação de investimentos: ferramentas e técnicas para a determinação do valor de qualquer ativo*. [S.l.]: Qualitymark, 2010.
 [10] PELLEGG, D.; MOORE, A. W. et al. X-means: Extending k-means with efficient estimation of the number of clusters. In: *ICML*. [S.l.: s.n.], 2000. v. 1, p. 727–734.
 [11] HALL, M. A. *Correlation-based feature selection for machine learning*. Tese (Doutorado) — The University of Waikato, 1999.
 [12] REIS, E. R.; CASTRO, P. A. de; SICHMAN, J. S. Enhancing classification accuracy through feature selection methods. In: *XIII Encontro Nacional de Inteligência Artificial e Computacional*. Recife, PE: [s.n.], 2016. p. 1–12.
 [13] ULRICH, J. R package ttr. *Version 0.23-1*, 2016.

Combinando novidade e popularidade em recomendações personalizadas através do aprendizado do perfil do usuário

BERTANI, R. M.*; BIANCHI, R. A. C.† COSTA, A. H. R.*;

*Laboratório de Técnicas Inteligentes - EP/USP

†Departamento de Engenharia Elétrica - FEI

E-mail: ricardo.bertani@usp.br; rbianchi@fei.edu.br;anna.reali@usp.br

Abstract— Recommender Systems have been an interesting tool to help users to find relevant content, once the amounts of on-line information vastly increase. A wide variety of algorithms have been proposed for this purpose, in particular those based on collaborative filtering, which often fail in sparse data, affecting the quality of recommendations. A hybrid algorithm based on diffusion has been proposed in the literature in order to mitigate this gap, however, it does not differentiate users according to their profiles. In this paper, a new diffusion-based algorithm is presented for learning user profiles and combining novel and popular items to make personalized recommendations. The experiments were performed in a high sparse dataset and show that the results outperforms those obtained by the original diffusion-based algorithm, in the same settings.

Keywords— machine learning, recommender systems, sparsity data, diffusion-based algorithms.

Resumo— Sistemas de recomendação têm sido uma interessante ferramenta no auxílio a usuários pela busca de conteúdo relevante, uma vez que a quantia de informações online aumenta consideravelmente. Uma ampla variedade de algoritmos foi proposta para esta finalidade; em particular aqueles baseados em filtragem colaborativa, que frequentemente falham em dados esparsos, afetando a qualidade das recomendações. Um algoritmo híbrido baseado em difusão foi proposto na literatura para mitigar essa lacuna, no entanto, este algoritmo não diferencia os usuários de acordo com seus perfis. Neste artigo, um novo algoritmo baseado em difusão é apresentado para aprender o perfil particular dos usuários e combinar itens populares e de novidade para a geração de recomendações personalizadas. Os experimentos foram conduzidos em um conjunto de dados altamente esparsos e mostram que os resultados superam aqueles obtidos pelo algoritmo original baseado em difusão, sob as mesmas configurações.

Palavras-chave— aprendizado de máquina, sistemas de recomendação, dados esparsos, algoritmos baseados em difusão

Classificação— Mestrado

Categoria— Iniciante

I. INTRODUÇÃO

Sistemas de Recomendação (SR) são programas de computador capazes de realizar sugestões de conteúdo a usuários de acordo com a predição de suas preferências. Segundo [1], os conteúdos recomendados ao usuário, tais como músicas, livros, notícias, e até amigos em redes sociais podem ser representados pelo termo "item". De acordo com [2], para que seja possível a realização de uma recomendação é necessário levar em consideração alguns conceitos fundamentais, tais

como: algoritmos de filtragem, tipo de dados disponível e a medida de qualidade das recomendações. Na visão de [3], os algoritmos de filtragem podem ser classificados de acordo com seu tipo (baseado em conteúdo, colaborativos, baseado em conhecimento e híbridos) e de acordo com a abordagem adotada (baseado em memória ou baseado em modelo). Com relação ao tipo de dados disponível geralmente são explorados os atributos de usuários e itens, além das avaliações que os usuários atribuem a itens em um SR, as quais podem ser explícitas ou implícitas, sendo a primeira expressa através de um "rating" de um usuário para um item [4], e a segunda quando é necessário acessar dados de navegação do usuário (cliques em links, movimentos do mouse, download de conteúdo) para inferir suas preferências [5]. O principal tipo de algoritmo de filtragem, de acordo com a literatura, é o colaborativo, o qual sofre com dois problemas conhecidos: partida a frio (*cold-start*) e o problema dos dados esparsos (*sparsity data*) [6],[4].

O primeiro consiste na falta inicial de avaliações devido tanto a novos itens quanto a novos usuários; já o último ocorre devido ao alto número de itens e usuários no sistema acompanhados de uma quantia muito baixa de interações entre ambos, o que prejudica a identificação de uma vizinhança de usuários similares e afeta diretamente a qualidade das recomendações. Neste artigo é apresentado um novo algoritmo baseado em difusão, o qual é capaz de combinar itens populares e pouco conhecidos (novidade) nas recomendações de acordo com o perfil dos usuários, o que permite a geração de recomendações personalizadas. Resultados experimentais mostram que a nova abordagem supera o algoritmo baseado em difusão original e uma implementação básica do algoritmo colaborativo.

O artigo está organizado da seguinte forma. A seção II apresenta alguns trabalhos relevantes presentes na literatura dos SR. A seção III procura detalhar os algoritmos baseados em difusão, os quais suportam esta pesquisa. Na seção IV é apresentada a proposta desta pesquisa. Na sequência, na seção V são descritos os experimentos e é realizada uma discussão dos resultados. Por fim na seção VI, são apresentadas as conclusões e os trabalhos futuros.

II. TRABALHOS RELACIONADOS

Diversas abordagens tem sido consideradas na literatura dos SR [7], [3], [6], entretanto o algoritmo de filtragem colabo-

rativa (FC) mostra-se como o mais popular. Este algoritmo explora informações prévias de um grupo de usuários similares para fazer a predição do nível de interesse de um usuário por um item [8], e pode ser classificado como baseado em memória ou baseado em modelo, sendo que na primeira abordagem todas as informações de usuários e itens devem estar disponíveis a todo momento, enquanto que na segunda gera-se um modelo probabilístico a partir dos dados, o qual é utilizado para prever o nível de interesse do usuário [1].

Os algoritmos FC baseados em memória também são conhecidos na literatura como algoritmos "baseados em vizinhança" (*neighborhood-based*) [8], isto porque nesta abordagem busca-se encontrar uma vizinhança de usuários similares ao usuário alvo da recomendação para inferir suas preferências. Neste contexto, para a determinação da vizinhança de usuários são utilizadas algumas medidas de similaridade que consideram os *ratings* atribuídos aos itens, sendo a mais comum o coeficiente de correlação de Pearson [9], que mede o grau de correlação entre dois usuários, baseado na avaliação de ambos sob o mesmo conjunto de itens.

Como tais medidas exploram os *ratings* presentes nos datasets, e estes são frequentemente bastante esparsos, tem-se que as vizinhanças necessárias para o cálculo são insuficientes afetando as recomendações, o que é conhecido como "problema dos dados esparsos" [10]. Algumas soluções conhecidas exploram alternativas como *tagging social* [11], fatorização de matrizes [12] e também os algoritmos baseados em grafos (especialmente os baseados em processos de difusão) [13], [14]. A seção seguinte apresenta em mais detalhes a essência dos algoritmos baseados em difusão, utilizados de base para a proposta desta pesquisa.

III. ALGORITMOS BASEADOS EM DIFUSÃO

Tais algoritmos utilizam alguns processos físicos para explorar os relacionamentos indiretos entre usuários e itens dentro do SR. Em particular, um algoritmo híbrido baseado em difusão foi apresentado em [13] — a partir deste ponto será referenciado como *Hybrid* — o qual combinou os algoritmos *Mass Diffusion (MD)* [15] e *Heat-Spreading (HS)* [16] para a geração de recomendações.

Nesta abordagem, um SR é representado como um grafo bipartido, definido formalmente como $G = \{U, I, E\}$, onde $U = \{u_1, u_2, \dots, u_N\}$, $I = \{i_1, i_2, \dots, i_M\}$ e $E = \{e_1, e_2, \dots, e_K\}$ são o conjunto de usuários, o conjunto de itens e o conjunto de arestas do grafo, respectivamente. Dado um conjunto de dados previamente conhecido, o grafo G é construído, atribuindo cada usuário a um vértice $u_i \in U$, cada item distinto a um vértice $i_j \in I$ e, caso o usuário u_i tenha tido qualquer interação com o item i_j , uma aresta $e_s \in E$ é inserida em G , o que torna u_i adjacente a i_j . Logo, para cada usuário alvo da recomendação (u) presente na base de dados, são executadas as três etapas a seguir:

Passo 1 Inicialmente, um valor de recurso $r(u, i)$ é atribuído a cada item i no grafo, da seguinte forma: se existe uma aresta entre i e u então $r(u, i) = 1$,

caso contrário, $r(u, i) = 0$.

Passo 2 Na segunda etapa, ocorre um processo de propagação dos valores de recurso do lado item para o lado usuário no grafo; cada item i com $r(u, i) > 0$ propaga um novo valor de recurso recalculado $r'_{HB}(u, i)$ para cada usuário u com o qual é adjacente no grafo G .

Passo 3 Na última etapa do processo, ocorre uma nova propagação dos recursos do lado usuário para o lado item no grafo, onde cada item i recebe um valor de recurso recalculado $r''_{HB}(u, i)$ a partir dos valores de recurso do lado usuário, $r'_{HB}(u, i)$.

O cálculo dos novos valores de recurso nos Passos 2 e 3 descritos anteriormente, dependem do algoritmo considerado, MD, HS ou *Hybrid*, além da quantia de interações que os usuários e itens tiveram na base de dados do SR, o que é representado pelo grau dos vértices no grafo, dado por $w(u)$ e $w(i)$, sendo respectivamente o grau do usuário u e do item i . Neste artigo, o cálculo destes valores de recurso é apresentado de forma resumida através das equações 1 e 2.

$$r'_{HB}(u, i) = \left(\sum_{i \in I} \frac{r(u, i)}{w(i)^\lambda} \right) / w(i)^{(1-\lambda)}; \quad e \quad (1)$$

$$r''_{HB}(u, i) = \left(\sum_{u \in U} \frac{r'_{HB}(u, i)}{w(u)^\lambda} \right) / w(u)^{(1-\lambda)}. \quad (2)$$

Nota-se que quando $\lambda = 0$ tem-se puramente a aplicação original do algoritmo HS e, quando $\lambda = 1$, tem-se a aplicação original do algoritmo MD. Qualquer valor entre 0 e 1 permite a combinação de ambos em *Hybrid*. Após a execução dos três passos descritos anteriormente, referentes ao usuário alvo u , todos os itens com um valor final de recurso positivo, $r''(u, i) > 0$, são então ordenados de forma crescente, resultando na chamada lista de predição; sendo os itens com os maiores valores de recurso os que compõem a lista de recomendação.

Observe que o algoritmo MD tende a gerar recomendações compostas de itens mais populares (vértices do grafo com maiores graus), enquanto que HS tende a recomendar itens menos conhecidos (vértices de menores graus no grafo). Neste caso, o mesmo grau de mistura (λ) é utilizado para todo e qualquer usuário, independentemente de seu perfil.

IV. DIFUSÃO ORIENTADA AO PERFIL DO USUÁRIO

A proposta do presente artigo consiste em um algoritmo capaz de combinar o *Hybrid* com o aprendizado supervisionado do grau de mistura (λ) em função do perfil individual de cada usuário, para permitir a geração de recomendações personalizadas através de difusão. O método foi nomeado como "Difusão orientada ao Perfil do Usuário"; ou *User Profile Oriented Diffusion (UPOD)*, em inglês. A ideia consiste em agrupar usuários que compartilhem perfis similares e definir, para cada tipo de perfil, o valor de λ mais apropriado para MD e HS no algoritmo *Hybrid*. Todo o processo é dividido

nas fases de treinamento e recomendação, apresentadas nas subseções a seguir.

A. Fase de Treinamento

A fase de treinamento tem por objetivo a geração de um classificador treinado, capaz de prever o grau de mistura mais adequado para determinado usuário tomando de base seus atributos, disponíveis em alguma base de dados (ex. gênero, idade e localização).

Todo o fluxo é exemplificado através dos passos descritos no algoritmo 1; onde inicialmente é criado um conjunto de treinamento vazio (passo 1); Na sequência, no passo 2, a partir do grafo G que representa as interações de usuários e itens de uma base de dados previamente conhecida, um conjunto de usuários de treinamento U_{train} é criado, contendo os valores dos atributos $Feat$ para cada usuário de G . No passo 3, os usuários presentes em U_{train} são agrupado em k grupos menores através do algoritmo k -Modes, o qual consiste de uma extensão do algoritmo k -Means para dados categóricos [17].

Na sequência, no laço for do passo 4 ao 10 o algoritmo *Hybrid* é aplicado repetidamente para cada um dos valores de λ presentes no conjunto Λ , e estima-se o melhor valor λ_{best} com base na métrica selecionada M no passo 5. Para cada usuário de cada um dos k grupos são obtidos os valores de seus atributos individuais (passo 7) e é gerado o par $\langle ValorAtributos, \lambda_{best} \rangle$, que é concatenado ao conjunto de treinamento no passo 8. Posteriormente este conjunto é utilizado para o treinamento do classificador no passo 11. Por fim, tem-se o classificador treinado a partir de todos os pares presentes no conjunto de treinamento; o classificador utilizado foi o SVM [18]

Algorithm 1 Fase de Treinamento do UPOD

Require: grafo bipartido usuário-item G , conjunto de atributos de usuários $Feat$, número de grupos k , valores considerados como parâmetro para a difusão Λ , métrica M de avaliação do melhor $\lambda \in \Lambda$ para a difusão híbrida.

- 1: $CjTreinamento \leftarrow \{\}$
- 2: $U_{train} \leftarrow usuarios(G, Feat)$
- 3: $grupos[1..k] \leftarrow kModes(U_{train}, k)$
- 4: **for** $i = 1$ to $i = k$ **do**
- 5: $\lambda_{best}[i] \leftarrow RepeatHybrid(G, grupos[i], \Lambda, M)$
- 6: **for each** usuário de grupos $[i]$ **do**
- 7: $ValorAtributos \leftarrow ExtraiValor(grupos[i].user, Feat)$
- 8: $CjTreinamento \leftarrow CjTreinamento \cup \{ \langle ValorAtributos, \lambda_{best}[i] \rangle \}$
- 9: **end for**
- 10: **end for**
- 11: $classificador \leftarrow TreinaClassificador(CjTreinamento)$
- 12: **return** $classificador$

B. Fase de Recomendação

Esta fase é exemplificada através do algoritmo 2, onde para cada usuário alvo u_a , são lidos seus atributos (passo 1), os quais são fornecidos como entrada para o classificador treinado durante a fase de treinamento, o qual fornece como saída a predição do valor de λ_{u_a} mais adequado para o respectivo usuário u_a durante o passo 2. No passo 3, tendo como entradas

o grafo bipartido de usuários-itens G , o usuário alvo u_a , o valor predito λ_{u_a} e o tamanho da lista de recomendações L , UPOD aplica o algoritmo *Hybrid* (eq. 1 e 2) e fornece uma lista de itens recomendados para u_a , ordenada de forma decrescente pelo valor do recurso r'' .

Finalmente, UPOD gera a lista de recomendação personalizada através de difusão utilizando o valor λ_{u_a} predito para u_a , a qual combina novidade e popularidade dos itens presentes na base de dados.

Algorithm 2 Fase de Recomendação do UPOD

Require: conjunto de atributos de usuários $Feat$, usuário alvo u_a , $classificador$, grafo bipartido usuário-item G , número de itens na lista de recomendação L .

- 1: $ValorAtributos \leftarrow ExtraiAtributos(u_a, Feat)$
- 2: $\lambda_{u_a} \leftarrow classificador(ValorAtributos)$
- 3: $listaRecomendacao \leftarrow Hybrid(G, u_a, \lambda_{u_a}, L)$
- 4: **return** $listaRecomendacao$

UPOD foi testado e avaliado de acordo com algumas métricas descritas na próxima seção.

V. RESULTADOS EXPERIMENTAIS

Após a geração das listas de recomendação para um determinado usuário, se faz necessário medir o quanto estes itens correspondem ao que o usuário, de fato, gostaria de receber. Para esta finalidade algumas métricas de avaliação conhecidas na literatura foram utilizadas:

- *Recall e Precision*: medem, respectivamente, a proporção de itens do conjunto de validação que correspondem a itens na lista de recomendação e a proporção de itens na lista de recomendação que correspondem a itens no conjunto de validação; sendo todos os itens relacionados ao usuário alvo.
- *RankScore*: calcula um valor de *rank* para cada item presente na lista de predição gerada para o usuário alvo, o qual considera a posição dos mesmos na lista de forma que quanto mais próximo das primeiras posições, menor o valor da métrica.
- *Novelty*: mede a capacidade do SR em gerar resultados inesperados, isto é, mede a imprevisibilidade de um item relativa à sua popularidade global.

Para os experimentos, foi considerado um conjunto aleatório da base de dados Bookcross com 3.434 usuários, 27.138 itens e 36.191 interações entre ambos, tal base de dados é considerada muito esparsa na literatura dos SR. Foram consideradas 10 execuções em conjuntos aleatórios de treinamento e validação (80% para treinamento e 20% para validação). Para o agrupamento dos usuários através do algoritmo k -Modes, considerou-se o seguinte espaço de atributos: idade (foi considerado o intervalo de idade de 5 em 5 anos - "5_10", "10_15", "15_20", etc) e localização (nome do país); foi adotado o classificador SVM para a fase de treinamento [18], a quantia de grupos (k) utilizada foi 5 (valor obtido experimentalmente), e o tamanho adotado para as listas de recomendação foi $|L| = 30$.

As tabelas a seguir exibem os resultados comparativos entre os algoritmos FC, *Hybrid* e UPOD sob o dataset Bookcross.

Tabela I

RESULTADOS OBTIDOS COM A BASE DE DADOS BOOKCROSS PARA AS MÉTRICAS RANKSCORE E RECALL.

Algoritmo	RankScore		Recall	
	média	σ	média	σ
FC	0.371	0.004	3.6×10^{-4}	1.32
Hybrid	0.361	0.099	0.001	0.099
UPOD	0.360	0.010	0.002	2.4×10^{-4}

Tabela II

RESULTADOS OBTIDOS COM A BASE DE DADOS BOOKCROSS PARA AS MÉTRICAS PRECISION E NOVELTY.

Algoritmo	Precision		Novelty	
	média	σ	média	σ
FC	4.2×10^{-5}	1.09	0.04	0.01
Hybrid	2.3×10^{-4}	0.09	0.26	0.11
UPOD	4.3×10^{-4}	3.3×10^{-5}	0.52	0.06

Através dos resultados, observa-se que o algoritmo UPOD obteve resultados melhores que FC e Hybrid, em média, para todas as métricas consideradas. Com o intuito de avaliar a relevância estatística de cada resultado de UPOD comparado aos demais, foi aplicado o Teste t considerando grau de confiança igual a 95% ($\alpha = 0.05$) e $N = 10$, onde houve superioridade estatística do UPOD em relação ao algoritmo de FC nas métricas RankScore e Novelty e superioridade estatística do UPOD em relação ao Hybrid na métrica Novelty.

Dada a análise dos resultados obtidos e a respectiva relevância estatística é possível concluir que o algoritmo UPOD apresentou resultados significativos, especialmente quando avaliado pelo nível de novidade das recomendações, o que evidencia que o aprendizado supervisionado do grau de mistura para grupos de usuários com perfis similares, de fato, é capaz de aprimorar a qualidade das recomendações.

VI. CONCLUSÃO E TRABALHOS FUTUROS

Este artigo apresentou o algoritmo UPOD, o qual permite a determinação automática do grau de mistura no processo de difusão para a geração de recomendações personalizadas combinando itens populares ou novidades em função do perfil de um usuário. Foi demonstrado através de alguns experimentos considerando quatro métricas em uma base de dados altamente esparsa que o algoritmo UPOD pode melhorar a qualidade das recomendações quando comparado ao algoritmo FC e o Hybrid; e os resultados obtidos até então mostram-se bastante motivadores.

Possíveis extensões do método proposto para trabalhos futuros seriam: ponderar as difusões no grafo através dos valores de ratings, assim como também permitir um maior número de propagações no grafo. Outra melhoria interessante seria definir de forma automática o número ideal de grupos de usuários similares.

AGRADECIMENTOS

Gostaríamos de agradecer ao CNPq

REFERÊNCIAS

- [1] KOTKOV, D.; WANG, S.; VEIJALAINEN, J. A survey of serendipity in recommender systems. *Knowledge-Based Systems*, Elsevier B.V., v. 111, p. 180–192, 2016. ISSN 09507051. Disponível em: <<http://dx.doi.org/10.1016/j.knsys.2016.08.014>>.
- [2] BOBADILLA, J. et al. Recommender systems survey. *Knowledge-Based Systems*, Elsevier B.V., v. 46, p. 109–132, 2013. ISSN 09507051. Disponível em: <<http://dx.doi.org/10.1016/j.knsys.2013.03.012>>.
- [3] SANCHEZ-MORENO, D. et al. A collaborative filtering method for music recommendation using playing coefficients for artists and users. *Expert Systems with Applications*, v. 66, p. 1339–1351, 2016. ISSN 09574174.
- [4] YANG, Z. et al. A Survey of Collaborative Filtering-Based Recommender Systems for Mobile Internet Applications. *IEEE Access*, v. 4, p. 3273–3287, 2016. ISSN 2169-3536.
- [5] LACERDA, A. Multi-Objective Ranked Bandits for Recommender Systems. *Neurocomputing*, Elsevier B.V., v. 0, p. 1–13, 2017. ISSN 09252312. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S092523121730228X>>.
- [6] LU, J. et al. Recommender system application developments: A survey. *Decision Support Systems*, Elsevier B.V., v. 74, p. 12–32, 2015. ISSN 01679236. Disponível em: <<http://dx.doi.org/10.1016/j.dss.2015.03.008>>.
- [7] LU, Z. et al. Content-based collaborative filtering for news topic recommendation. *AAAI 2015: Proceedings of the Twenty-ninth AAAI Conference on Artificial Intelligence*, p. 217–223, 2015.
- [8] CHRISTAKOPOULOU, E.; KARYPIS, G. Local Item-Item Models For Top-N Recommendation. *Proceedings of the 10th ACM Conference on Recommender Systems - RecSys '16*, p. 67–74, 2016. Disponível em: <<http://dl.acm.org/citation.cfm?doid=2959100.2959185>>.
- [9] RICCI, F. et al. *Recommender Systems Handbook*. 1st. ed. New York, NY, USA: Springer-Verlag New York, Inc., 2010. ISBN 0387858199, 9780387858197.
- [10] SHAMBOUR, Q.; LU, J. An effective recommender system by unifying user and item trust information for B2B applications. *Journal of Computer and System Sciences*, Elsevier Inc., v. 81, n. 7, p. 1110–1126, 2015. ISSN 00220000. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0022000014001998>>.
- [11] BELLOGGI, A.; CANTADOR, I.; CASTELLS, P. A comparative study of heterogeneous item recommendations in social systems. *Information Sciences*, v. 221, p. 142–169, 2013. ISSN 00200255.
- [12] NIKOLAKOPOULOS, A. N.; KOUNELI, M. a.; GAROFALAKIS, J. D. Hierarchical Itemspace Rank: Exploiting hierarchy to alleviate sparsity in ranking-based recommendation. *Neurocomputing*, Elsevier, v. 163, p. 126–136, 2015. ISSN 09252312. Disponível em: <<http://www.scopus.com/inward/record.url?eid=s-2.0-84924196269&partnerID=tZOtx3y1>>.
- [13] ZHOU, T. et al. Solving the apparent diversity-accuracy dilemma of recommender systems. *Proceedings of the National Academy of Sciences of the United States of America*, v. 107, n. 10, p. 4511–4515, 2010. ISSN 0027-8424.
- [14] MA, W. et al. Personalized recommendation via unbalance full-connectivity inference. *Physica A: Statistical Mechanics and its Applications*, Elsevier B.V., v. 483, p. 273–279, 2017. ISSN 03784371. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378437117303588>>.
- [15] ZHOU, T. et al. Bipartite network projection and personal recommendation. *Physical Review E - Statistical, Nonlinear, and Soft Matter Physics*, v. 76, n. 4, p. 1–7, 2007. ISSN 15393755.
- [16] ZHANG, Y.-C.; BLATTNER, M.; YU, Y.-K. Publisher's Note: Heat Conduction Process on Community Networks as a Recommendation Model [Phys. Rev. Lett. 99, 154301 (2007)]. *Physical Review Letters*, v. 99, n. 16, p. 169902, 2007. ISSN 0031-9007. Disponível em: <<http://link.aps.org/doi/10.1103/PhysRevLett.99.169902>>.
- [17] HUANG, Z. Extensions to the k -Means Algorithm for Clustering Large Data Sets with Categorical Values. v. 2, n. 3, p. 283–304, 1998.
- [18] WITTEN, I. H. et al. Weka: Practical machine learning tools and techniques with Java implementations. In: KASABOV, N.; KO, K. (Ed.). *Proceedings of the ICONIP/ANZIIS/ANNES'99 Workshop on Emerging Knowledge Engineering and Connectionist-Based Information Systems*. [S.l.: s.n.], 1999. p. 192–196. Dunedin, New Zealand.

Comparative Analysis of Matching Algorithms for Green D2D Communication

Ligia M.M. Zorello*, and Tereza C.M.B. Carvalho*

*Escola Politécnica of University of Sao Paulo, Sao Paulo, Brazil. email: {ligia.zorello,terezacarvalho}@usp.br

Abstract—In this paper, we consider a Device-to-Device (D2D) communication in cellular networks. Idle users, called UER (User Equipment Relay), work as relays between active users and the base station to improve their data rate and the energy efficiency of the network. The relaying induces a cost for UER, e.g., in terms of energy, that can be compensated by a payment from the mobile operator. The problem hence arises for the operator to select the best matching between active users and relays at a reasonable cost, optimizing the perceived network quality and the energy efficiency. We formulate this problem as a budget feasible matching problem. In this context, we compare four different matching algorithms. Hungarian, Threshold, Online Weighted Knapsack and ON algorithms will be analyzed, simulated and compared in the context of D2D communications under the constraints of budget feasibility, acceptance of online settings and energy efficiency.

Keywords— D2D; energy efficiency; algorithms analysis

Classification— Master’s degree.

Category— Beginner.

I. INTRODUCTION

The great increase in the number of mobile devices, such as smartphones and tablets, and services leads to an exponential growth of mobile data traffic. Indeed, it is expected that by 2022 there will be more than 9 billion mobile devices and that the global mobile traffic will reach 69.2 ExaBytes per month [1]. Several authors mention that the power consumption of Information and Communication Technology (ICT) is becoming an important part of the world total power consumption, and the mobile communication participation is increasing significantly [2,3]. As a consequence, mobile operators face a growing necessity of enhancing link quality, guaranteeing good Quality of Service (QoS), and improving the energy efficiency of their systems [4].

The Fifth Generation Mobile Communication System (5G) is being developed to meet these requirements [5]. An important 5G feature is the usage of Heterogeneous Cellular Networks (HetNet), which consists of an integration of different communication technologies, such as macrocells and low-power nodes, and which aims to provide larger coverage and higher user throughput [4,6]. The use of cooperative relays to retransmit traffic of active cell users (UE - User Equipment) in the cell is one of the possible types of communication performed on HetNets. Two different approaches have been studied to provide this type of communication, using fixed relays or idle users as relays. Hasan *et al.* explain in [3] that using fixed relays is a good option for green communication, because it is more energy efficient, albeit the second option

is more robust. Moreover, the use of idle users as relays can be easily deployed, not requiring extra operator’s investments, and they can provide the reuse and diversity gains [7]. In the work, we will analyze the usage of matching algorithms to create green communications with good performance using the second scenario.

Device-to-Device (D2D) communication is defined as the direct communication between two devices in a cell, without the Base Station (BS) intermediation. Its use enables the development of cooperative relay communication using idle users as relays. Thus, it can use a User Equipment Relay (UER) to retransmit the data of other UEs in the cell. With D2D communication as an underlay tier, we can improve the UE data rate and also the cellular coverage [8].

We consider UERs retransmitting the information that UEs send in the uplink to the BS. This relaying considers the network utility and energy efficiency, and the UERs cost. Utility represents the data rate improvement when considering the relay mode in respect to the direct mode. Energy efficiency corresponds to the amount of energy needed to transmit the data in either modes. Cost indicates the energy consumed to retransmit other active users traffic. Because of UERs cost, we consider that the operator gives them incentives to act as a relay, such as advantages in their mobile bundle. The problem arises for the operator to match UERs and UEs so that the network global utility and energy efficiency increase with a reasonable cost. Moreover, we need to consider requirements such as truthfulness (UERs reporting their true cost), budget feasibility (payment to all UERs must be under a certain budget), and the potential of matching UERs to UEs as they arrive in the cell, which is called an online scenario.

Several matching algorithms have been proposed in the literature, such as Hungarian [9], Threshold [10], Online Weighted Knapsack (OWK) [11], ON [12]. The Hungarian algorithm finds the maximum weighted matching considering only the utility in an offline scenario, but it is not truthful nor budget feasible, as it was not built to consider UERs cost and to provide a payment to UERs. The Threshold algorithm selects the optimal assignment taking into account both utility and cost in an offline scenario, and it is capable to detect whether UERs misreport their cost, being truthful and also budget feasible. The Online Weighted Knapsack algorithm is online, it was built to calculate the optimal matching considering edges utility and UERs cost, and it is only budget feasible, but not truthful, because, as Hungarian algorithm, it was not built to provide payments. Lastly, the ON algorithm is online and

finds the matching considering truthfulness, budget feasibility and online requirements. None of these algorithms, however, considers the energy efficiency when calculating the matching, which is the focus of our work.

This paper formulates the D2D communication with UERs as a matching problem and presents comparative analyses based on simulations of the Hungarian, Threshold, OWK and ON algorithms. These evaluations aim to verify the report between the total energy efficiency and the total utility of calculated matching for each algorithm, analyzing whether they can be energy efficient even though not considering this requirement when calculating the matching. We also verify the influence of the requirements of truthfulness, budget feasibility and online in the final matching. The structure of the paper is as follows: Section II presents the related work, Section III introduces the different algorithms, Section IV shows the system models, Section V presents the simulation results, and Section VI concludes the paper.

II. RELATED WORK

D2D communication has been extensively studied to find solutions for quality, data rate and energy efficiency problems. Different algorithms were proposed to validate this type of communication considering different requirements. Several authors studied and simulated these algorithms, either to understand their performance or to compare with others. Hungarian and Greedy are well-known algorithms for finding optimal or good matching; therefore, there are many studies on their performance. T. Kim and M. Dong compare in [13] Greedy, an improved Greedy and a modified Hungarian method. In addition, D. Niyato and E. Hossain analyses and compares in [14] Hungarian algorithm on the context of subcarrier and rate allocation in multirate OFDMA, verifying the performance in different scenarios, such as average total transmission rate, throughput and average delay.

In a crowdsourcing context, G. Goel, A. Nikzad and A. Singla presented UniformMechanism in [10], which was used as basis for Threshold [12]. The authors ran simulations to evaluate the algorithms performance both with simulated data and with realistic values resulting from a case usage, verifying the reported costs and the total utility of the matching.

M. Babaioff, N. Immorlica, D. Kempe, and R. Kleinberg presented in [11] another matching algorithm, Online Weighted Knapsack algorithm, with focus on the secretary problem. They analyzed it mathematically; however, the authors did not analyze its complexity. In addition, they did not run simulations to test whether it works in realistic applications or not, and they did not verify its scalability considering its functionalities and execution time.

In [12] and [15], the authors apply the algorithms proposed by them to calculate the matching in the context of D2D communication when UER can be used to relay traffic of active users. R. Vaze and M. Coupechoux in [12] only present mathematical studies to prove the algorithms performance, without further simulations to test the algorithm. Furthermore, R. Vaze in [15] simulates a new version of ON algorithm,

which is called ON-TRUTH with improved competitive ratio, and he does not compare its results to ON.

Furthermore, none of the authors compares all the algorithms analyzed in this paper, nor do they consider their characteristics and scalability by simulations in a D2D context. Moreover, the majority of the research does not take into consideration the energy efficiency when building the algorithm. Indeed, none of these algorithms was built to cope with the energy efficiency problem. Xiao et al. present in [8] one of the first attempts to propose a matching algorithm with focus on energy efficiency for D2D communications. It provides simulations of this algorithm to a Brute-Force-Based Mobile Association (BMA), which calculates the matching by brute-force. The simulations show that the proposed algorithm is better than the brute-force one; however, they do not compare it to other existing algorithms that are potentially useful.

III. ALGORITHMS

The algorithms studied in this paper have been selected to evaluate the influence of the requirements:

- Truthfulness [12]: UER do not misreport their cost;
- Budget feasibility [12]: the total payment is at most the budget specified by the operators;
- Online [12]: the system does not have any information about UER before their arrival in the cell;
- Energy efficiency: energy needed to send some data.

A. Hungarian Algorithm

The Hungarian algorithm [9] finds the matching that maximizes the total weight of a bipartite graph. D2D communication can use this algorithm to select the maximum matching considering utility as the graph weight. Also, we assume that the payment offered by the system is set as the UERs cost, but it is not considered when calculating the final matching. It is an offline algorithm, i.e. we consider that it has all the information about the UERs at any time. In addition, it is not budget feasible, because it pays the UERs the same amount that it reported as its cost. Consequently, it is not possible to control whether UERs report their true cost or not.

B. Threshold Algorithm

Threshold algorithm [12] is based on UniformMechanism [10], and was built to calculate the matching of a complete bipartite graph with the highest utility, considering the budget constraint in an offline scenario. In addition, UERs cost is taken into account to calculate the optimal matching. It is truthful and budget feasible, but it is offline [12].

C. Online Weighted Knapsack Algorithm

The Online Weighted Knapsack (OWK) algorithm [11] is based on the knapsack secretary problem to find the optimal matching of a complete bipartite graph considering the edges and nodes weight, i.e. the utility and the cost. A constant fraction of the UERs is used to tune a selection criterion, which is then applied to the subsequent elements observed by the algorithm. OWK takes into account the online scenario,

and it was also constructed to respect the budget constraint by selecting UERs that report cost under a virtual budget, as showed in [11]. As there is no payment in OWK, we allocate the reported cost. OWK is thus not truthful.

D. ON Algorithm

ON algorithm was developed by R. Vaze *et al.* in [12] to be an algorithm that finds the matching of a complete bipartite graph and respects the requirements of truthfulness, budget feasibility and acceptance of online scenarios. As an online algorithm, it also uses the paradigm of sampling a fraction of the UERs to define a selection criterion that define which of the subsequent UERs that arrive in the cell will be selected. Therefore, it is composed of an offline (or learning) phase and an online phase. During its learning stage, it uses Threshold algorithm to calculate the selection criterion. R. Vaze and M. Coupechoux prove mathematically in [12] that ON is both truthful and budget feasible.

IV. SYSTEM DESCRIPTION

A. D2D Description

We consider one cell served by a single base station (BS). Let U be the set of users in the cell that want to transmit some data to the BS, which are called UE (User Equipment). Let R be the set of users that are registered to the operator for the relaying service. The relay users are called UER. We assume that no two UERs can be connected to the same UE, and each UER can retransmit the traffic of a single UE.

When the system selects a UER to relay a UE traffic, it uses its own resources for the task; therefore, it has an induced cost c_r associated to relaying. This cost is dependent exclusively on the amount of power the UER is willing to provide for the retransmission and it is independent of the UE to which it is connected; hence, we define the cost of a UER r as

$$c_r = P_r, \quad (1)$$

where P_r is in dBm. The operator should offer incentives so that the UER accepts the service, such as monetary or commercial benefits. Thus, we assume that it offers a payment p_r greater or equal to the UER reported cost. Moreover, the sum of the payment offered to all UERs should be inferior or equal to the operator maximum budget B , *i.e.* $\sum p_r \leq B$.

The D2D communication is modeled as a weighted bipartite graph $G(U \cup R, E)$, where E is the set of edges that represent all possible communication between UEs and UERs, with $e = \{(u, r), u \in U, r \in R\}$. The weight of each graph is called utility w_e and represents the advantage of using the D2D communication in respect to the direct one. Several approaches can be used to define this characteristic. In this paper, we consider it as the difference between the bit transmission time of the direct and relay mode; therefore, it is worth considering the D2D relay when its bit transmission time is lower than the direct communication. It is calculated as

$$w_{ur} = \max\{0, T_{ub} - T_{ur}\} \quad (2)$$

where $T = 1/R$ and R is the data rate.

B. Relaying Model

A cooperative communication can be performed in various forms [2], and two of them are represented in Figure 1.




Fig. 1. Relaying models

In the first model (Figure 1-a), the UE sends packets both to the UER and to the BS, and the UER retransmit the received packets to the BS. In the second model (Figure 1-b), whenever the system decides that the relay option will be used, the UE sends packets only to the UER that will then retransmit the traffic to the BS.

In this paper, we consider the second model, in which the UE sends its traffic exclusively to the UER if the system chooses the cooperative communication (called relay mode), or the direct communication to the BS otherwise (called direct mode). To these means, we consider a single relay channel, where a UE u is the source, a UER r relays the traffic and the BS b is the destination. The data rate of the direct mode R_{ub} and of the relay mode R_{ur} are calculates as follows [16]:

$$R_{ub} = \frac{1}{2} \log_2 \left(1 + \frac{g_{ub} P_u}{\sigma^2} \right), \quad (3)$$

$$R_{ur} = \frac{1}{2} \log_2 \left[1 + \min \left(\frac{g_{ur} P_u}{\sigma^2}, \frac{g_{ub} P_u + g_{rb} P_r}{\sigma^2} \right) \right] \quad (4)$$

where $g = \frac{1}{pl}$ is the channel gain, pl is the path loss, σ^2 is the noise power, P_u and P_r are, respectively, the transmission power of the UE and UER. We consider that it is worth choosing the relay mode instead of direct mode if and only if $R_{ub} \leq R_{ur}$.

C. Energy Efficiency Model

The energy efficiency (EE) represents the amount of energy needed to transmit some data [2]. In D2D communications, it is used to verify the efficiency in which the power consumed by the relaying device uses in order to perform the retransmission of the UE traffic. Equation 5 and Equation 6 express the energy efficiency on direct and relay mode, respectively [2,7,17].

$$EE_{ub} = \frac{R_{ub}}{P_u + P_c} \quad (5)$$

$$EE_{ur} = \frac{R_{ur}}{\frac{(P_u + P_r)}{2} + P_c} \quad (6)$$

V. SIMULATIONS

A. Simulation Parameters

We consider the uplink of a small cell covering a disk of radius $R_C = 200\text{m}$. The system bandwidth is $W = 10\text{ MHz}$ [18] and its noise power is calculated by $\sigma^2 = N_0W$, where N_0 is the power spectral density, set as -174 dBm/Hz [19] in simulations. UE and UER are uniformly distributed in the cell. UE transmit at maximum power $P_u = P_{\max} = 23\text{ dBm}$. UER may choose not to use their maximum power to relay the traffic of UE. Hence UER transmit power is randomly and uniformly selected in the range $[0, P_{\max}]$. We set the maximum budget to $B = 10.5N_h$, where $N_h = |H|$ is the number of UER (the budget scales with the number of UER).

1) *Propagation Model*: There are two types of communication used in the system: user-to-BS and user-to-user. The first one comprises the communication between UE or UER and the BS, and we can assume that the propagation model for this communication is similar to Long Term Evolution (LTE) model. From [18,20], we have that the path loss (PL) in dB for the user-to-BS communication on a Urban Micro (UMi) NLOS hexagonal cell layout is given by Equation 7.

$$PL = 36.7\log_{10}(d) + 22.7 + 26\log_{10}(f_c) \quad (7)$$

where d is the distance between user and BS ($10\text{ m} < d < 2000\text{ m}$), and $f_c = 2.6\text{ GHz}$ is the carrier frequency [20]. The user-to-user communication, on the other hand, comprises the one between UE and UER. Its propagation model is taken from [21] and the PL in dB can be calculated by Equation 8.

$$PL_{uh} = \max\{PL_1(d), PL_2(d)\} \quad (8)$$

where $PL_1 = (44.9 - 6.55\log_{10}(h_{BS}))\log_{10}(d) + 5.83\log_{10}(h_{BS}) + 18.38 + 23\log_{10}(f_c)$, $h_{BS} = 1.5\text{m}$ [22], and $PL_2 = 20\log_{10}(d) + 46.4 + 20\log_{10}(f_c/5)$ [23].

VI. FINAL CONSIDERATIONS AND FUTURE WORK

This paper presents the algorithms and the parameters that will be used for simulating and analyzing the algorithms. In this article, we consider a scenario with a D2D network, in which UER serve as relays for cellular users to improve their uplink data rate and the energy efficiency of the network. We formulate the problem as budget feasible matching problem to compare four algorithms Hungarian, Threshold, Online Weighted Knapsack (OWK) and ON in this context. We intend to verify the influence of three requirements (truthfulness, budget feasibility, and acceptance of online scenario) in the final result, as well as understand how energy efficient these algorithms can be. As future works, it is necessary to simulate these algorithms in terms of the requirements and of the parameters presented. Considering the results and the analyses, an interesting topic of research could be to evaluate which is the best algorithm to be applied in a larger system.

ACKNOWLEDGMENT

This work was partially supported by CNPq and CAPES (Brazil) (process 132234/2017-3 and 88888.076739/2013-00)

REFERENCES

- [1] N. Heuvelodp, "Ericsson mobility report," Ericsson, Tech. Rep. EAB-17:005964 Uen Rev B, June 2017.
- [2] A. Ricieri Castri e Souza, J. R. Almeida Amazonas, and T. Abrao, "Energy-efficiency maximisation for cooperative and non-cooperative ofdma cellular networks survey," *Transactions on Emerging Telecommunications Technologies*, 2014.
- [3] Z. Hasan, H. Boostanimehr, and V. K. Bhargava, "Green cellular networks: A survey, some research issues and challenges," *IEEE Communications Surveys Tutorials*, vol. 13, no. 4, pp. 524–540, 2011.
- [4] H. H. Yang, J. Lee, and T. Q. S. Quek, "Heterogeneous cellular network with energy harvesting-based d2d communication," *IEEE Transactions on Wireless Communications*, vol. 15, no. 2, pp. 1406–1419, Feb 2016.
- [5] Ericsson, "5g systems - enabling industry and society transformation," Ericsson, Tech. Rep. 284 23-3251 Uen, January 2015.
- [6] A. Damnjanovic, J. Montojo, Y. Wei, T. Ji, T. Luo, M. Vajapeyam, T. Yoo, O. Song, and D. Malladi, "A survey on 3gpp heterogeneous networks," *IEEE Wireless Communications*, vol. 18, no. 3, pp. 10–21, June 2011.
- [7] S. Xiao, X. Zhou, D. Feng, Y. Yuan-Wu, G. Y. Li, and W. Guo, "Energy-efficient mobile association in heterogeneous networks with device-to-device communications," *IEEE Transactions on Wireless Communications*, vol. 15, no. 8, pp. 5260–5271, Aug 2016.
- [8] A. Asadi, Q. Wang, and V. Mancuso, "A survey on device-to-device communication in cellular networks," *IEEE Communications Surveys Tutorials*, vol. 16, no. 4, pp. 1801–1819, Fourthquarter 2014.
- [9] S. Suri, "Bipartite matching & the hungarian method," August 2016.
- [10] G. Goel, A. Nikzad, and A. Singla, "Matching workers expertise with tasks: Incentives in heterogeneous crowdsourcing markets," in *NIPS Workshop on Crowdsourcing*, 2013.
- [11] M. Babaioff, N. Immorlica, D. Kempe, and R. Kleinberg, *A Knapsack Secretary Problem with Applications*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, pp. 16–28.
- [12] R. Vaze and M. Coupechoux, "Online budgeted truthful matching," *NetEcon*, June 2016.
- [13] T. Kim and M. Dong, "An iterative hungarian method to joint relay selection and resource allocation for d2d communications," *IEEE Wireless Communications Letters*, vol. 3, no. 6, pp. 625–628, December 2014.
- [14] D. Niyato and E. Hossain, "Adaptive fair subcarrier/rate allocation in multirate ofdma networks: Radio link level queuing performance analysis," *IEEE Transactions on Vehicular Technology*, vol. 55, no. 6, pp. 1897–1907, November 2006.
- [15] R. Vaze, "Online knapsack problem and budgeted truthful bipartite matching," *IEEE InfoCom*, May 2017.
- [16] L.-L. Xie and P. R. Kumar, "A network information theory for wireless communication: scaling laws and optimal operation," *IEEE Transactions on Information Theory*, vol. 50, no. 5, pp. 748–767, March 2004.
- [17] W. Dang, M. Tao, H. Mu, and J. Huang, "Subcarrier-pair based resource allocation for cooperative multi-relay ofdm systems," *IEEE Transactions on Wireless Communications*, vol. 9, no. 5, pp. 1640–1649, May 2010.
- [18] 3GPP, "3rd generation partnership project; technical specification group radio access network; further advancements for e-ultra; lte-advanced feasibility study in ran wg4 (release 9)," 3GPP, Tech. Rep. TR 36.815 V9.0.0, March 2010.
- [19] S. Mathur, R. Tandra, S. Shellhammer, and M. Ghosh, "Initial signal processing of captured dtv signals for evaluation of detection algorithms," *IEEE 802.22-06/0158r4*, September 2006.
- [20] 3GPP, "3rd generation partnership project; technical specification group radio access network; evolved universal terrestrial radio access (e-ultra); further advancements for e-ultra (release 9)," 3GPP, Tech. Rep. TR 36.814 V9.0.0, March 2010.
- [21] —, "Technical specification group radio access network; study on lte device to device proximity services; radio aspects (release 12)," 3GPP, Tech. Rep. TR 36.843v12.0.1, March 2014.
- [22] J. Meinila, P. Kyosti, L. Hentila, T. Jamsa, E. Suikkanen, E. Kunnari, and M. Narandzic, "Winner+ final channel models," WINNER+, Tech. Rep. D5.3, June 2010.
- [23] P. Kyosti, J. Meinila, L. Hentila, X. Zhao, T. Jamsa, C. Schneider, ..., and T. Rautiainen, "Winner ii channel models," WINNER+, Tech. Rep. D1.1.2 V1.2, September 2007.

Benchmark of NoSQL Data Base Oriented to Column Family

Análise de Desempenho de Banco de Dados NoSQL Orientado a Família de Colunas

FERREIRA, L. M.; SOUZA, S. N. A.

Departamento de Engenharia de Computação e Sistemas Digitais - Universidade de São Paulo
{leandro.mferreira, ssouza}@usp.br

Abstract— Several organizations have been adopting NoSQL database as an important part of their computational architecture. Among these NoSQLs Oriented to Columns Family is one of the types preferred mainly due to its high performance. However, aiding to selection which technology to adopt, the benchmarking strategy is considered as one of the main to assist in this decision-making. Thus, present work performs the performance analysis of NoSQL HBase, which is one of the exponents among the NoSQL Oriented Column Family. For this, it is used the framework for benchmark in Big Data and NoSQL known as YCSB. This benchmark analysis was realized in a clustered environment with high-capacity hardware. In this way we can see the high performance of HBase in features like throughput and latency.

Keywords— *NoSQL; HBase; Benchmarking.*

Resumo— Diversas organizações vêm adotando bancos de dados NoSQL como parte importante de sua arquitetura computacional. Entre esses NoSQLs os Orientados a Família de Colunas são um dos tipos preferidos, principalmente devido ao seu alto desempenho. Entretanto para ajudar na escolha de qual tecnologia adotar, os *benchmarking* são tidos como uma das principais estratégias para auxílio nesta tomada decisão. Assim, o presente trabalho realiza a análise de desempenho do NoSQL HBase, que é um dos expoente entre os NoSQL Orientados a Família de Coluna. Para isso é utilizado o “*framework*” para *benchmark* em Big Data e NoSQL conhecido como YCSB. Esta análise de desempenho foi realizada em um ambiente clusterizado com hardwares de alta capacidade. Desta forma, podemos ver o alto desempenho do HBase em quesitos como “*throughput*” e latência de operações.

Palavras-chave— *NoSQL; HBase; Benchmarking.*

Classificação— *Mestrado*

Categoria— *Iniciante*

I. INTRODUÇÃO

NoSQLs Orientados a Colunas possuem diversas características como: alto desempenho, alta disponibilidade, processamento distribuído e alto poder de compactação de dados [1]. Entretanto, o alto desempenho sem dúvida é a característica que mais tem atraído diversas organizações a

adotar o NoSQL como principal Sistema Gerenciador de Banco Dados (SGBD) para seus sistemas computacionais transacionais, bem como em sistemas de tomada de decisão e analíticos [2].

Pensando principalmente nessa característica de desempenho, testes de performance, conhecidos como “*benchmark*” são um dos principais subsídios para que organizações e seus arquitetos e pesquisadores possam escolher qual o sistema certo e as compensações correspondentes para sua aplicação, projeto ou pesquisa [3].

Em [4] vemos que em computação, um “*benchmark*” é o resultado da execução de um conjunto de programas de computador a fim de avaliar o desempenho relativo de sistemas, executando uma série de testes padrões. Ao fazer isso, os pesquisadores destacam as características de certos sistemas que são capazes de classificar o desempenho operacional. Desta forma, os *benchmarks* são artefatos de pesquisas importantes para apoio de tomada de decisão e fundamento a inovação e crescimento tecnológico.

O presente trabalho se propõe a realizar um “*benchmark*” de um SGBD NoSQL Orientado a Colunas, em um cluster computacional de alto desempenho a fim de gerar parâmetros que resultem em subsídios para adoção da tecnologia analisada. Para este trabalho foi selecionado o NoSQL HBase para realização dos testes propostos. Como ferramenta e “*framework*” de “*benchmark*” foi utilizado o Yahoo! Cloud System Benchmark (YCSB).

Assim, na sessão II vê-se a descrição sobre o NoSQL HBase, sua arquitetura, modelagem e seu funcionamento. Na sessão III descreve-se o “*framework*” YCSB. Na sessão IV é explanado o plano de trabalho desenvolvido para esta pesquisa, na sessão V são descritos os resultados e realizada a análise destes, por fim na sessão VI é apresentada a conclusão.

II. O HBASE

O HBase é um NoSQL Orientado a Família de Colunas que foi criado tendo como base a arquitetura do NoSQL, desenvolvido pelo Google chamado BigTable. O HBase é distribuído, tolerante a falhas, altamente escalável, construído

sobre o sistema de arquivos distribuídos Hadoop (HDFS) com a intenção de ser uma plataforma amplamente escalável de alta performance, pronto para lidar com dados heterogêneos [5]. Vale ressaltar ainda que o HBase ao lado do Cassandra e do Hypertable são os principais NoSQL Orientados a Família de Colunas utilizados atualmente [6].

Vemos ainda em [5] que em sua arquitetura o HBase adotou estratégia de “*master-slave*”. O Mestre (HMaster) é responsável pelo sistema de distribuição denominado “regiões”. Já os escravos (HRegionServers) são responsáveis por gerenciar pedidos de clientes para leitura e escrita e pela recuperação de falhas. O HBase ainda utiliza o Zookeeper outro subprojeto Hadoop, para gerenciamento do seu cluster.

Outra característica que herda dos seus projetos inspiradores é a capacidade do HBase ser executado em clusters feitos de *hardwares* comuns. Como todo NoSQL orientado a colunas o HBase suporta a escrita e leitura de tabelas muito grandes. As tabelas do HBase possuem ainda a característica de ser distribuída de forma horizontal através das “regiões” gerenciadas pelos HRegionServers [7].

A modelagem de dados dentro do HBase é realizada através do seu esquema de Tabelas, Família de Colunas, Colunas, Chaves de Linhas e Linhas. Em [6] vemos a explicação de cada um desses pontos, sendo eles:

- Tabelas: Forma como o HBase organiza as informações.
- Família de colunas: É a estrutura lógica dentro das tabelas que armazena as colunas. Uma tabela pode conter diversas famílias de colunas.
- Colunas: É a estrutura onde cada dado é persistido. Uma família de colunas pode armazenar diversas colunas. As colunas não precisam ser definidas em tempo de criação das tabelas, e sim, elas são criadas no momento da inserção dos dados.
- Linha: Agrupamento lógico de dados orientado e identificado univocamente pela sua chave. Assim, para cada chave de linha temos diversas colunas das diversas Famílias de Colunas relacionadas. A inserção e leitura dos dados no HBase é orientada a linhas e suas chaves.

Devido a sua arquitetura e modelagem de dados, no HBase a única estrutura indexada é sua chave, e é a partir dela que as consultas, inserções e atualizações devem ser realizadas. Ademais por ser um NoSQL o HBase não possui uma linguagem SQL nativa, entretanto estrutura e “*frameworks*” adicionais como Hive, Impala, Drill e Phoenix podem suprir essa carência, desta forma possibilita realizar consultas com a linguagem SQL [1][2],

III. O YCSB

Com o enorme número de NoSQL disponíveis no mercado, existia uma grande dificuldade de realizar uma comparação de forma uniforme entre eles. Assim o YCSB veio para suprir esse problema, já que os testes e métricas do YCSB são

independentes do banco de dados. Cada conjunto de testes executados pelo YCSB é baseado em diversos parâmetros, tais como: endereços IP, número de registros a serem persistidos, tamanho dos registros persistidos, número de leituras e escritas por segundo, entre outras métricas [3].

O YCSB foi desenvolvido no Yahoo para teste de performance em banco de dados, principalmente SGBDs NoSQL. Ele é distribuído de forma “*open source*” com licença Apache 2.0. Esta ferramenta tem a característica de se conectar em mais de duas dezenas de NoSQL, e é capaz de gerar extensas cargas de trabalhos sobre estes[8]. É importante destacar que hoje o YCSB é um dos sistemas mais populares para “*benchmark*” para Big Data e NoSQL[4][7]. Temos na bibliografia científica diversos trabalhos que utilizam o YCSB como base para realização de experimentos e análises sobre SGBDs NoSQL. Em [9], por exemplo, vemos um trabalho que faz a comparação de 5 (cinco) NoSQL diferentes, entre eles, o HBase onde é analisado a partir do YCSB o desempenho de cada uma das tecnologias através de métricas como latência e “*throughput*” sobre operações de carga de dados, leitura e escrita.

Por meio do YCSB é possível executar teste de carga iniciais (“*load*”) de dados, bem como cargas de trabalho de operações de “*insert*”, “*update*”, “*read*”, “*delete*” e “*scan*”. Possui também, a capacidade de parametrização do percentual de cada tipo de operação em uma carga de trabalho, desta forma pode-se definir cada estratégia de carga que se queira mensurar[10].

IV. PLANO DE TRABALHO

Para o presente trabalho almejou-se realizar a análise de desempenho do HBase como SGBD NoSQL Orientado a Família de Colunas. O *benchmark* foi realizado em um cluster de alto desempenho que possui as seguintes características:

- 8 Nós como Region Servers
- 1 Nó como Master Server
- 1 Nó como Data Node para HDFS
- 3 nós como Zookeeper Server
- 1 Nó Worker de Carga de Trabalho (Executou a ferramenta YSCB)

Todos os nós do cluster tinham as seguintes configurações:

- 8 vCores de 2,3 GHz cada
- 16GB de Memória RAM
- HD High Performance 15000 rpm
- Placa de Rede Gb de transmissão
- Sistema Operacional Red Hat 7.12

As seguintes cargas de trabalho foram definidas para execução do YCSB:

Tabela I. CARGAS DE TRABALHOS

Workload Name	Read	Insert	Update	Scan
Load		0%	100%	0%
Read_Unit	95%	5%	0%	0%
Read	95%	5%	0%	0%
Insert	10%	80%	10%	0%
ReadUpdate	50%	25%	25%	0%
Scan	45%	10%	0%	45%
ScanReadInsert	35%	35%	15%	15%

Cada carga de trabalho realizou 10.000.000 (Dez milhões) de operações, distribuídas de acordo com a percentagem demonstrada na Tabela 1. A carga de trabalho “Load” teve por objetivo a inserção massiva de dados de forma inicial. Cada operação de “insert” e de “update” persiste um registro de 1kb de dados, em uma família de colunas composta por 10 colunas. Desta forma, a primeira carga de trabalho denominada “Load” gerou uma carga de dados de 10GB. A carga de trabalho “Read_Unit” faz a leitura de uma única coluna da família de coluna. Todas as outras operações de leitura realizada nas demais cargas de trabalho faz a leitura de todas as colunas da família de colunas.

A distribuição de HBase, Zookeeper e Hadoop (HDFS) utilizadas foram a da Cloudera 5.10. Não foi realizada nenhuma configuração especial de “tuning” sendo todas as peças utilizadas conforme distribuição padrão da Cloudera. Foi criado no HBase um *namespace* especial para o teste, chamado “ycsb”. A instrução desenvolvida para criação da tabela destinada ao “benchmark” foi: `create 'ycsb:usertable', 'family'`. Nenhuma configuração especial de “split” das tabelas e famílias de colunas foi realizada.

V. RESULTADOS

As cargas de trabalho foram executadas em uma única máquina contra o cluster de HBase. O YCSB de forma automática instanciava o maior número de *threads* possível, tendo o limite de 32. Entretanto, nos testes realizados eram instanciadas em média de 12 a 14 *threads* para cada carga de trabalho. Todas as cargas de trabalho realizaram 10.000.000 (Dez milhões) de operações. O resumo dos resultados obtidos é demonstrado na tabela abaixo:

Tabela II. RESUMO DE RESULTADOS

Workload	Tempo Total (min)	Throughput Médio (ops/sec)	Latência Média Insert (ms)	Latência Média Read (ms)	Latência Média Update (ms)	Latência Média Scan (ms)
Load	36	4552	7,014	-	-	-
Insert	36	4618	5,977	14,189	5,71	-
Read	38	4321	6,45	11,276	-	-
Read_Unit	34	4823	6,396	7,104	-	-
Read_Update	53	3113	6,218	14,03	6,029	-
Scan	676	246	12,497	22,408	-	261,282
Scan_Read_Insert	255	653	10,29	21,825	9,91	238,216

Podemos observar nos resultados que existe uma similaridade na taxa de “*throughput*” médio entre as cargas de “Insert”, “Load”, “Read”, tendo um pequeno acréscimo na carga “Read_Unit”, o que pode ser explicado pela diminuição

de tráfego que a carga “Read_Unit” tem em relação as outras cargas, já que esta carga realiza 95% de operações de leitura de uma única coluna, não operando sobre a família de coluna inteira como nas outras cargas. Houve também uma baixa das operações na carga de “Read_Update”, podendo-se explicar pela complexidade maior de operações de atualização de registros.

Podemos observar nos resultados que existem uma diferença significativa entre os tempos de execução de todas as cargas em relação as cargas que continham operações de “scan”, essas diferenças podem ser melhores observadas nos gráficos apresentado a seguir:

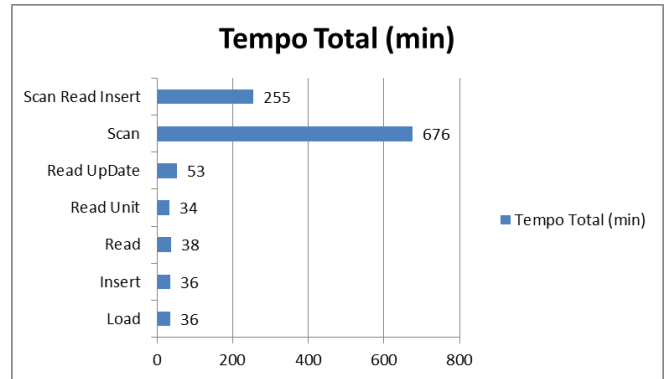


Fig. 1. Gráfico de Tempo Total de Execução de Cargas de Trabalho.

Vemos na Fig. 1. a carga de trabalho “Scan”, mesmo contendo apenas 45% de operações de buscas sequenciais sobre o HBase (scan), acarretou um acréscimo de mais de 17(dezessete) vezes em relação a carga de trabalho “Read”. Podemos observar, também, isso ocorrendo nas operações por segundo, conforme gráfico abaixo (Fig. 2).

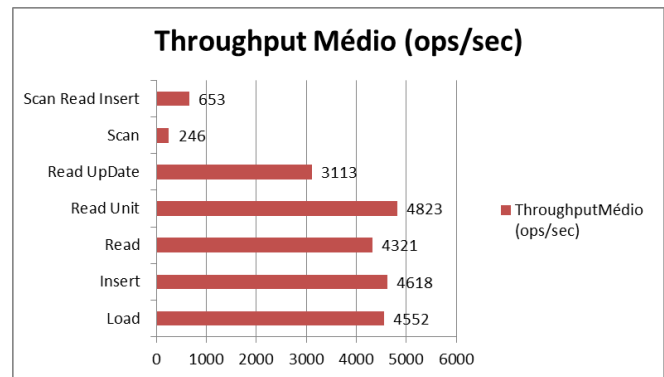


Fig. 2. Gráfico de Taxa de Operações por segundo na Execução de Cargas de Trabalho.

Vemos na Fig. 2., uma diminuição significativa das operações por segundo (“*throughput*”) nas cargas que contém operações de buscas sequenciais. Isso é explicado ao fazermos uma comparação entre a latência média das operações de leitura carga “Read” com uma taxa de 11,276 (ms) contra a latência média de operações de scan na carga “Scan”, que possui uma latência média de 261,282, sendo uma taxa

23(vinte e três) vezes maior. Desta forma, podemos concluir que a arquitetura do HBase favorece operações de leituras baseadas na chave de linha conforme explicado na sessão II, e que as operações de scan, que não utilizam chave de linha são altamente custosas a este NoSQL.

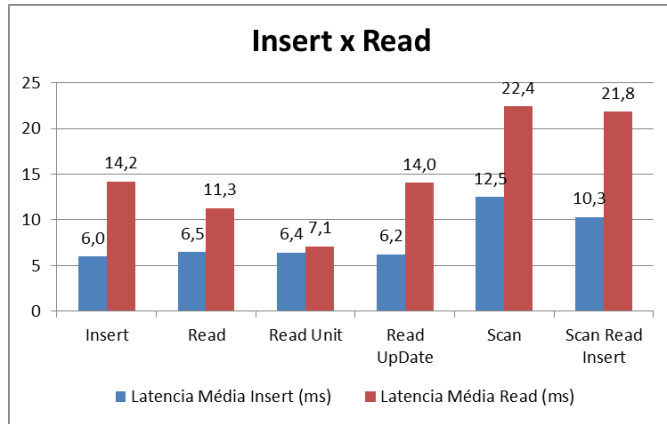


Fig. 3. Gráfico de Comparação de Latência entre Operações de *Insert* e *Read*.

Outro fato que podemos observar nos dados, destacado na Fig. 3., é a superioridade em tempo de operações de inserção de dados em comparação as operações de leitura. Em todas as cargas de trabalho, até mesmo na carga de trabalho “Read_Unit”, onde é realizada a leitura de apenas uma coluna da Família de Colunas, as operações de inserção tem latência média inferior as operações de leitura.

Em termos gerais, o HBase alcançou excelentes taxas de desempenhos. Mesmo sendo requisitado por cargas massivas de trabalho alcançou taxas médias de latência e “*throughput*” de extremo desempenho ainda mais em comparação a outros “*benchmark*” realizados sobre tecnologias de banco de dados diferentes [8]. Ao se analisar o uso dos recursos do cluster, durante a execução de todas as cargas de trabalho, foram utilizados, no pior caso, entre todos os nós HRegionServer 27% de capacidade de CPU e 22% do total de memória física disponível. Desta forma, as cargas de trabalhos utilizadas durante o “*benchmark*” consumiram em média menos de um quarto dos recursos disponíveis pelo cluster, demonstrando de forma clara o alto desempenho do Hbase.

VI. CONCLUSÃO

Vimos neste trabalho as principais características do NoSQL Orientado a Família de Colunas – Hbase, um SGBD de alto desempenho, com características de processamento distribuído de cluster. Além disso, foi percorrido de forma ampla sobre a importância dos *benchmarks* para tomada de decisão e escolhas de tecnologias nas organizações. Foi demonstrado também o YCSB, “*framework*” para execução de “*benchmark*” amplamente utilizado para análise de desempenho em ambiente de Big Data e NoSQL. Nas análises dos resultados percebemos o grande poder de processamento do HBase quando em um cluster compostos de *hardwares* de configuração de alto desempenho. Observou-se que o HBase tem taxas elevadas de “*throughput*” e baixa latência para

operações de inserção e leitura de dados, mas que existe uma perda considerável de desempenho para as operações de leitura sequencial de dados (“*scan*”).

A. Trabalhos Futuros

Como trabalhos futuros recomenda-se repetir o teste com mais nós trabalhando como “*workers*” de carga de trabalho, para que seja possível saturar a capacidade do cluster de HBase. Outra proposta é realizar o “*benchmark*” em relação a outros NoSQL Orientado a Família de Colunas, como o Cassandra, para realizar uma comparação de desempenho em NoSQL que possuem arquiteturas semelhantes. Sugere-se também que sejam analisados além das métricas de “*throughput*” e latências, que sejam acompanhadas métricas internas do NoSQL, como taxa de compactação, espaço em disco utilizado, uso de memória e CPU de todos os nós envolvidos, bem como “*flush*” e a taxa de distribuição dos dados entre todos os nós. Por fim, recomenda-se para trabalhos futuros que sejam testados os clusters de NoSQL sobre condições de desastres, como retirada e a inserção de nós no cluster em tempo de teste, bem como a capacidade de distribuição de dados em diferentes “*data centers*”

REFERÊNCIAS

- [1] SOARES, B. E. and BOSCARIOLI, C. Modelo de Banco de Dados Colunar: Características, Aplicações e Exemplos de Sistemas. In: Escola Regional de Banco de Dados – Sociedade Brasileira de Computação (IX ERBD – SBC), Camobiu, 2013.
- [2] DEHDOUH, K. et al. Columnar NoSQL Star Schema Benchmark. In: 4th International Conference on Model Engineering and Data Engineering (MEDIE), Larnaca, CYPRUS, 2014.
- [3] KUMAR, S. P. Evaluating consistency on the fly using YCSB. In: International Workshop on Computational Intelligence for Multimedia Understanding (IWCIM). Paris, 2014.
- [4] BARATA, M. YCSB and TPC-H: Big Data and Decision Support Benchmarks. In: IEEE International Congress on Big Data, Anchorage (ICBD), AK, 2014.
- [5] VORA, M. N. Hadoop-HBase for large-scale data. In: International Conference on Computer Science and Network Technology (ICCSNT), Harbin, 2011.
- [6] ALEXANDRE, J. and CAVIQUE, L. NoSQL no Suporte à Análise de Grande Volume de Dados. Revista de Ciências da Computação. v. 8, n. 8. Lisboa, 2013.
- [7] BAKSHI, K. Considerations for big data: Architecture and approach. IEEE Aerospace Conference (AERO), Big Sky, MT, 2012.
- [8] COOPER, B. F. et al. Benchmarking cloud serving systems with YCSB. In: Proceedings of the 1st ACM Symposium on Cloud Computing (SoCC), USA, Indianapolis, 2010.
- [9] TANG, E. and FAN, Y. Performance Comparison between Five NoSQL Databases. In: International Conference on Cloud Computing and Big Data (CCBD), Macau, 2016.
- [10] COOPER, B. F. e et al. Yahoo! Cloud System Benchmark (YCSB). In: <https://github.com/brianfrankcooper/YCSB>, 2017.

Machine Learning for Solar Photovoltaics Electricity Generation Forecasting: the influence of data quality and number of meteorological parameters on forecast accuracy

VISCONDI, G. F.*; SOUZA, S. N. A.*; CORRÊA, M. P.†

* Polytechnic School of the University of São Paulo (POLI-USP) – Computer and Digital Systems Department

† Natural Resources Institute – Federal University of Itajubá (UNIFEI)
gabrielviscondi@usp.br, ssouza@usp.br, mpcorrea@unifei.edu.br

Abstract - As a result of environmental pressure and market pull technology driven innovations, new electricity generating sources such as solar photovoltaics are expected to play a significant role on the world's electricity mix during the upcoming years. Even though it is a constantly evolving technology, solar radiation natural variability is a challenge to overcome to supply constant, reliable and low-priced electricity to households, markets and industry. Improving solar radiation forecast is one alternative to aid the complementation of solar power plants with more stable generating sources and the main objective of this paper. Machine learning algorithms such as artificial neural networks, support vector machines and extreme learning machines have been showing remarkable results, increasing the short and long-term accuracy of radiation forecast. By analyzing these three machine learning methodologies, this paper aims to present a methodology to evaluate the impacts of data quality and the number of meteorological parameters used to train the artificial intelligence algorithms. A dataset from the meteorological station of the University of São Paulo will be utilized and statistical parameters such as mean bias error, mean absolute error and root mean square error will compare the results for each evaluation. Finally, the researchers expect to verify the impacts of the on the performance of the three proposed machine learning techniques and compare the forecasting performance of each algorithm separately.

Keywords - solar electricity forecasting, data quality, machine learning, data mining, extreme learning machine

Classification - master's degree

Category - Beginner

I. INTRODUCTION

The world electricity mix is suffering a complete new revolution during the past few years. Mainly due to environmental awareness and market pressure for a transition of fossil fuel usage, new electricity generating sources such as solar and wind start to figure as imminent protagonists of the future of electricity generating capacity. As stated by the International Renewable Energy Agency, solar installed capacity went from 8,7 GW in 2007 to 291 GW in the end of 2016. Furthermore, only in 2016, 70 GW of solar panels were installed globally led, mainly, by the continuous growth

in energy demand of countries like China, United States and Japan [1].

These energy sources bring new technological, marketing, environmental and research perspectives to every electricity stakeholder of the market. On the other hand, they evidence the need for a new power sector model, which tends to be based on a considerable participation of variable and non-dispatchable power plants. This unpredictability of natural resources such as solar radiation and wind flow, start to point out new challenges and uncertainties to the operation of electrical systems and, consequently, to the security of electricity supply and price formation [2].

Intending to make feasible and comprehensible this still confusing market paradigm, innovating technologies such as smart grids, smart meters, sensors and natural resources forecasting models start to assume great importance for an efficient integration of variable solar installed capacity into the electricity grid [3]. These technologies have an important role on teaching the power sector the challenges and opportunities in the next few years and, as in any other sector, the increasing number of sensors, meters and smart objects (internet of the things), is certainly leading to a data oriented decision-making scenario.

Therefore, big data technology, through artificial intelligence algorithms, database organization, data quality assurance procedures and faster data processing is expected to play a significant role on the development of new variable and renewable electricity sources.

Forecasting solar electricity generation is a way of reducing inherent source variability problems. Big data, mainly through machine learning and data mining techniques is helping the development of constantly more accurate and with a bigger time span resolution solar radiation forecasts [4, 5, 6, 7, 8]. In general, these machine learning models, perform solar energy forecasting by means of historical irradiation data and weather information as inputs, through multiple algorithms such as artificial neural networks, support vector machine, multilayer perceptron, regression forest and gradient boosting [9, 10, 11, 12, 13].

The core objective of this paper is to present a proposal to evaluate the influence of data quality and number of meteorological parameters on the forecast accuracy of solar photovoltaics electricity generation.

Succeeding the introduction presented above, the paper is structured as follows: section 2 describes briefly previous works related to the work proposal; section 3 presents the project proposal and, finally, section 4 brings the conclusion.

II. RELATED WORK

During the past five years, an increasing number of researchers and projects are addressing the challenge of the variability of solar electricity generation and possible solutions using machine learning algorithms.

In 2015 Haupt, S. E. et al. investigated the use of machine learning algorithms for applied weather forecasts, focusing on utility operation. The researchers considered that accurate prediction of meteorological variables is a big data problem that requires a multitude of disparate data, multiple models that are each applicable to a specific time frame, and application of computational intelligence techniques to deliver real-time information to decision makers. The paper approaches the main available models to forecast solar electricity generation before presenting the SunCast model as an alternative of predicting electricity generation. This model focuses on short and long-term predictions, through regression trees (RT) algorithms based on historically acquired electricity generation and radiation data

Li, L. et al. published in 2016 an article concentrating on the analysis of multiple machine learning algorithms to forecast solar irradiance of photovoltaic systems. The study aimed answering which algorithm provides the best solar radiation prediction considering a short-term prediction basis. The authors analyzed support vector machine (SVM) and Hidden Markov Model machine learning methodologies, which both presented precise forecast irradiation values when applied to a dataset generated by the Australian Bureau of Meteorology.

A hierarchical approach was proposed by Li, Z. et al. using machine learning methods to forecast solar photovoltaic electricity production. In this research project, the authors evaluated the best algorithm to predict electricity production from solar photovoltaic generating facilities 15 minutes, 1 hour and 24 hours ahead of time. Support vector regression (SVR) and artificial neural networks (ANN) were the selected methodologies, applied to an historical electricity generation database. The accuracy of the algorithms/models were evaluated through statistics, by using error methodologies such as mean bias error (MBE), mean absolute error (MAE), root mean square error (RMSE), relative MBE (rMBE), mean percentage error (MPE) and relative RMSE (rRMSE). Both algorithms showed low errors and great performance to forecast short-term generation.

Shamshirband, S. et al. Presented in 2015 a comparative evaluation for identifying the suitability of a specific neural network approach called extreme learning machine (ELM) to

predict global solar radiation. By using this specific machine learning technology, the authors investigated the impact of using different meteorological parameters to train the algorithm and estimate horizontal radiation, evaluating at the end the most influential constraints. The authors also compared the performance of ELM to SVM, genetic programming (GP) and ANN to verify the precision of ELM. The results showed that using multiple parameters the estimation of horizontal radiation is higher through every machine learning technology and ELM is the most accurate and reliable technology to estimate solar radiation.

Finally, ELM ability to forecast solar electricity generation based on past generation data and meteorological parameters was assessed by La Cadre, et al. in 2015. Both electricity generation and meteorological data from 13 stations were trained together into the algorithms to estimate the future production of a solar power plant. From all the evaluated parameters, past generation was the most important and decisive to the forecast followed by precipitation.

III. WORK PROPOSAL

Based on the literature review and the core related works presented by the previous section, this paper presents a work proposal based on the following main findings:

- ANN are the most accurate algorithms to predict solar irradiation and, consequently, the most proposed by the literature;
- ELM has been reducing the learning time and raising the precision of radiation forecast as a neural network methodology;
- Few papers use electricity generation data itself. Most of the research focuses on the natural resource – irradiation and other meteorological parameters;
- Few papers cite dynamics and procedures to assess data quality and how it impacts radiation forecast;
- In general, as the number of meteorological parameters used to train the model grows, the accuracy of the forecasting result also increases;
- MAE and RMSE are the most used statistical parameters to evaluate the precision of machine learning algorithms regarding irradiation forecast.

Founded on the conclusions presented above, the present project proposes the evaluation of the most cited machine learning forecasting algorithms – SVM, ANN and ELM – assessing the influence of data quality and number of meteorological parameters on forecast accuracy.

The analysis will be divided into two main strategies, oriented by different guiding questions (Figure 1):

- 1) *How the number of meteorological parameters affects the accuracy of the models on radiation forecast?*
- 2) *How data quality affects the accuracy of the models on radiation forecast?*

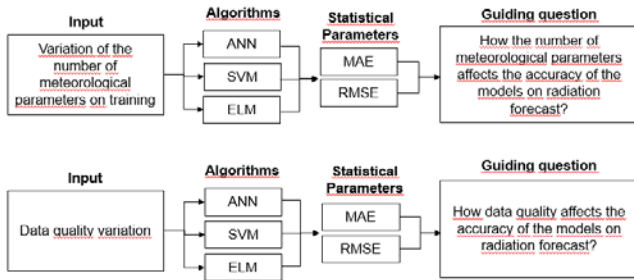


Figure 1 - Description of the proposed methodology

REFERENCES

For the first analysis, data will be acquired at the meteorological station located inside the University of São Paulo campus. This station will supply the following meteorological parameters data to the study: wind speed, wind direction, global horizontal irradiation, direct irradiation, pluviosity, cloud index, atmospheric pressure, relative humidity and temperature.

For the second analysis, a methodology to evaluate different categories of data cleanliness will be developed and applied to the database of the first analysis.

In the end, the researchers expect to see through statistical validation, the impacts of the number of meteorological parameters and data quality on the performance of the three proposed machine learning techniques. In addition to the two research questions presented above, it is also expected to compare the performance difference on each of the algorithms (SVM, ANN and ELM), separately.

CONCLUSION

Machine learning algorithms are aiding the penetration of solar power plants through improvements on solar radiation forecasts and, consequently, helping the power sector on enhancing its planning procedures to match electricity production and demand. Avoiding over-generation of electricity, the systems reduces the cost of electricity for its users by using its capacity efficiently.

During the processes of literature review and research proposal, many insights were found to help understand the state-of-art of machine learning radiation prediction models. The most important verifications include: ELM, ANN and SVM as the main big data methodologies, low quality assurance, focus on natural resource (radiation) and MAE e RMSE as the main statistical criteria to evaluate algorithm performance in this field of study.

Therefore, this paper presented a methodology to evaluate, using for the first time Brazil's meteorological and local collected data, the main machine learning technologies to forecast solar electricity generation. As an incipient electricity source in the country, it is expected that this methodology can assist the development of this resource in the country by dealing with local specificities of the weather and power mix.

- [1] IRENA (2017), Renewable capacity statistics 2017, International Renewable Energy Agency (IRENA), Abu Dhab (Agora,2015).
- [2] Agora Energiewende (2015): The Integration Cost of Wind and Solar Power. An Overview of the Debate on the Effects of Adding Wind and Solar Photovoltaic into Power Systems.
- [3] IEA. Next Generation Wind and Solar Power: From Cost to Value. Paris: International Energy Agency, 2016.
- [4] Aybar-Ruiz, A., et al. "A Novel Grouping Genetic Algorithm - Extreme Learning Machine Approach for Global Solar Radiation Prediction from Numerical Weather Models Inputs." *Solar Energy*, vol. 132, 2016, pp. 129–142., doi:10.1016/j.solener.2016.03.015.
- [5] Shao, Xiaoyan, et al. "Solar Radiation Forecast with Machine Learning." 2016 23rd International Workshop on Active-Matrix Flatpanel Displays and Devices (AM-FPD), 2016, doi:10.1109/amfpd.2016.7543604.
- [6] Li, Z., Rahman, S., Vega, R. and Dong, B. A Hierarchical Approach Using Machine Learning Methods in Solar Photovoltaic Energy Production Forecasting. *Energies*, 2016, 9(1), p.55.
- [7] Aler, Ricardo, et al. "A Study of Machine Learning Techniques for Daily Solar Energy Forecasting Using Numerical Weather Models." SpringerLink, Springer, Cham, 1 Jan. 2015.
- [8] Senekane, M. and Taele, B. Prediction of Solar Irradiation Using Quantum Support Vector Machine Learning Algorithm. *Smart Grid and Renewable Energy*, 2016, 07(12), pp.293-301.
- [9] Yuregir, O. and Sagiroglu, C. Solar Energy Validation for Strategic Investment Planning via Comparative Data Mining Methods: An Expanded Example within the Cities of Turkey. *International Journal of Photoenergy*, 2016, pp.1-16.
- [10] Assouline, D., Mohajeri, N. and Scartezzini, J. Quantifying rooftop photovoltaic solar energy potential: A machine learning approach. *Solar Energy*, 2017, 141, pp.278-296.
- [11] Burianek, Tomas, and Stanislav Misak. "Solar Irradiance Forecasting Model Based on Extreme Learning Machine." 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 2016, doi:10.1109/eeeic.2016.7555445.
- [12] Martin, R., et al. "Machine Learning Techniques for Daily Solar Energy Prediction and Interpolation Using Numerical Weather Models." *Concurrency and Computation: Practice and Experience*, vol. 28, no. 4, 2015, pp. 1261–1274., doi:10.1002/cpe.3631.
- [13] Shamshirband, Shahabodinn, et al. "A Comparative Evaluation for Identifying the Suitability of Extreme Learning Machine to Predict Horizontal Global Solar Radiation." *Renewable and Sustainable Energy Reviews*, vol. 52, 2015, pp. 1031–1042., doi:10.1016/j.rser.2015.07.173.
- [14] HAUPT, S. E.; KOSOVIĆ, B. Big data and machine learning for applied weather forecasts: Forecasting solar power for utility operations. *Proceedings - 2015 IEEE Symposium Series on Computational Intelligence, SSCI 2015*. 2016.
- [15] LI, J. et al. Machine learning for solar irradiance forecasting of photovoltaic system. *Renewable Energy*, v. 90, p. 542–553, 2016.
- [16] H'el'ene Le Cadre, Ignacio Aravena, Anthony Papavasiliou. *Solar PV Power Forecasting Using Extreme Learning Machine and Information Fusion*. European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, Apr 2015, Bruges, Belgium. 2015.

ARTIGOS
DOUTORADO

Natural Language Processing Techniques for Analysis and Classification of Sentiment Using *Emoji* Filtering

Técnicas de Processamento de Linguagem Natural para Análise e Classificação de Sentimentos Utilizando Filtragem por *Emoji*

SILVA, A. M.*; BASTOS, R. M.*; ROCHA, R. L. A.*†

*LTA - Laboratório de Linguagens e Técnicas Adaptativas

Departamento Engenharia da Computação

Escola Politécnica da Universidade de São Paulo - São Paulo - Brasil

†E-mail: {ariana.moura,rodrigo.matta.bastos,rlarocha}@usp.br

Abstract—A method of filtering that could be used in natural language processing is the use of messages composed with *Emoji* to analyze and classify feelings that the individuals express about a subject. This paper exemplifies a way to extract and to automate tweets containing *Emoji* for later inference of the relationship between the *Emoji* and the true sentiment expressed in that mention.

Keywords— Natural Language Processing - NLP; Sentiment Analysis; *Emoji*; Social Networks; Corpus.

Resumo— Uma maneira de filtragem que pode ser utilizada em processamento de linguagem natural é a utilização de mensagens com *Emoji* para análise e classificação de sentimentos que os indivíduos exprimem sobre determinado assunto. Este trabalho exemplifica uma maneira de extração e automatização de tweets que contenham *Emoji* para posterior inferência da relação entre o *Emoji* e o verdadeiro sentimento expresso naquela menção.

Palavras-chave— Processamento de Linguagem Natural; Análise de Sentimentos; *Emoji*; Redes Sociais; Corpus.

Classificação— Doutorado.

Categoria— Intermediária.

I. INTRODUÇÃO

A ocorrência de acontecimentos oriundos de desastres naturais, ou até mesmo do lançamento de uma nova marca e/ou produto, mudanças de leis em nosso código penal, mudanças comportamentais de indivíduos, formalização de uma ideia ou opinião de um determinado assunto, transformam-se em notícias, comentários ou relatos que invadem nossos meios de comunicação [1]. Esses acontecimentos são documentados de forma textual utilizando *blogs*, redes sociais, *websites* entre outros, desta forma é possível ter acesso ao texto e recuperar essas informações.

Constatou-se que o indivíduo produz uma massa de dados muito grande, o que já chamamos da “Era Big Data” [2]. Devido a isso surgem então as novas áreas de pesquisa voltadas

para análise dessas informações documentadas, para posterior geração de conhecimento. Indo mais além surge a necessidade de conhecer o sentimento envolvido/expresso pelo indivíduo ao documentar certo texto/menção. Afinal o ser humano é um indivíduo emocional, que exprime emoções inclusive na sua maneira de escrever.

O grande desafio encontra-se no propósito de como quantificar, metrificar, criar indicadores ou padrões de classificação desses sentimentos entendendo a complexidade da língua e a forma de expressões do indivíduo, e ensinar isso para a máquina utilizando modelos computacionais [3]. Frente a este problema, o presente trabalho tem o objetivo de apresentar, através de informações realistas divulgadas no Twitter, como a relação que o *Emoji* inserido no texto pode ajudar nas técnicas de Processamento de Linguagem Natural auxiliando no processo de filtragem para a classificação de sentimentos e avaliação da reação que a população exprime sobre o assunto analisado.

O objetivo principal deste trabalho é realizar a coleta de um grande volume de dados, especificamente mensagens em língua portuguesa extraídas do micro blog Twitter. Projetar o armazenamento de tais mensagens de forma sistemática, que permita a recuperação deles através de filtragem utilizando os *Emojis*.

Nas Seção II serão abordados os aspectos conceituais com os grandes temas: PLN, Análise de Sentimento e *Emoji*; a Seção III define a metodologia utilizada; e a Seção IV os resultados e a a Seção V apresenta algumas conclusões obtidas a partir de análises feitas sobre exemplos apresentados e possíveis trabalhos futuros.

II. ASPECTOS CONCEITUAIS

A linguagem humana não é simplesmente a manifestação de uma ação física qualquer do ser humano. As palavras são como símbolos, em que seus significados semânticos representam uma ideia. Os símbolos da linguagem podem ser codificados em voz, gesto, escrita e outros. Processamento de Linguagem Natural (PLN) tem diferentes níveis desde o processamento da fala até a interpretação semântica e processamento de discurso. PLN tem por objetivo projetar, construir algoritmos capazes de ajudar a máquina na compreensão na linguagem natural humana [4].

Tarefas como verificação ortográfica, pesquisa por palavra-chave, encontro de sinônimos, são tarefas consideradas fáceis. Já a análise de conteúdo/informações em sites ou documentos são consideradas nível médio. As tarefas de nível difícil são: tradução automática, análise semântica, co-referência ou encontrar respostas subliminares em perguntas destacadas em determinado documento [4].

Uma emoção não é simplesmente um estado de sentimento. Emoção é uma cadeia de eventos frouxamente ligados que começam com um estímulo e incluem sentimentos, alterações psicológicas, impulso para a ação e comportamento específico, dirigido por objetivos [5].

A análise do sentimento é uma técnica usada para extrair e encontrar automaticamente o sentimento expresso em linguagem natural. O termo 'sentimento' refere-se a emoções ou sentidos como: audição, visão, toque, olfato e paladar. O que queremos extrair das mensagens compartilhadas nas redes sociais é o sentimento expresso de forma positiva, negativa ou neutra.

A análise de sentimento no nível da palavra verifica a polaridade desta palavra especificamente. No nível da sentença, será levado em conta não apenas o polaridade das palavras que a contém, mas também as relações entre essas palavras e seu uso gramatical. No nível do documento, leva em consideração o contexto completo do documento, levando a uma análise mais complexa sobre como as frases interagem umas com as outras [6].

Atualmente os *Emojis* são muitos populares na escrita em redes sociais, principalmente como o Facebook e também em aplicativos de troca de mensagens instantâneas, como o WhatsApp. é uma expressão de origem japonesa composta pela junção dos elementos *e* (imagem) e *moji* (letra), e é considerado um pictograma ou ideograma, ou seja, uma imagem que transmite a ideia de uma palavra ou frase completa.

A figura 1 mostra um exemplo de *Emoji* chorando de rir, apesar da palavra “chorando” possuir uma polaridade negativa quando observada individualmente, no sentido da palavra. Quando composta pela palavra “rir”, a palavra “chorando” passa a ter um valor de exagero e juntas formam uma polaridade positiva. Levando em consideração que “Chorando de Rir” foi a etiqueta dada para o símbolo de *Emoji* demonstrado na figura.

“Nós usamos entonação de voz ou linguagem corporal para contextualizar o que estamos dizendo. Os *Emojis* são a forma

que usamos para fazer isso online”, afirmou Iyad Rahwan, professor associado do MIT [7].



Emoji Chorando de rir: é utilizado para representar uma felicidade ou gargalhada extrema, quando determinada coisa é muito engraçada.

Figura 1. Exemplo de *Emoji* Chorando de Rir.

III. METODOLOGIA

Foram desenvolvidos programas na linguagem Java para a extração e armazenamento das mensagens em língua portuguesa extraídas do Twitter, que possuem a função de coletar mensagens sobre os *top-trends* (tópicos mais populares do blog) e coletar mensagens relacionadas a um parâmetro de busca específico, informado pelo usuário, que pode ser por data, uso de palavra-chave, ou popularidade da mensagem na rede. As mensagens extraídas são arquivadas em um banco de dados estruturado no programa *MySQL*, em conjunto com informações que permitam a sua filtragem posterior. Além das tarefas propostas, foi utilizado um método de Análise de Sentimento baseado na análise de *Emojis* para ser aplicado nas mensagens extraídas pelos programas. A base de *Emojis* utilizada para análise foi a do *Unicode* disponível na url: <http://www.unicode.org/emoji/charts/full-emoji-list.html>.

IV. RESULTADOS

Através da tabela Unicode foi possível criar uma chave entre os códigos que simbolizam os *Emojis* do Twitter e a tabela de significado por polaridade. Com essa primeira filtragem foi possível quantificar as mensagens por *TopTrends*, para auxiliar como parâmetros de entrada dos programas desenvolvidos em java que darão início a fase de pré-processamento linguístico para a futura construção do *corpus* de sentimentos anotado.

A figura 2 exemplifica as polaridades obtidas de menções extraídas do Twitter no dia 06 de agosto de 2017 através da *hashtag* GrandPrix, que indica o evento Grand Prix de Volêi 2017 (<http://grandprix.cbv.com.br/>).




Figura 2. Análise de Sentimentos do Tópico GrandPrix dia 06/08/2017

A figura 3 exemplifica as polaridades obtidas de menções extraídas do Twitter no dia 06 de agosto de 2017 através da *hashtag* DomingoDeTremuraSDV, que faz menção a uma expressão usual no Twitter, para entender é preciso desmembrar essa *hashtag*, onde “SDV” significa “segue de volta”; “De-Tremura” faz menção ao usuário @DeTremura que pertence a

peessoa Denise Tremura; e “Domingo” com a indicativa de dia da semana (<https://www.manualdousuario.net/sdv-detremura-twitter/>).




Figura 3. Análise de Sentimentos do Tópico DomingoDetremuraSDV dia 06/08/2017

A figura 4 exemplifica as polaridades obtidas de menções extraídas do Twitter no dia 06 de agosto de 2017 através da hashtag IveteAVontade, que faz menção a música chamada “A vontade” da cantora Ivete Sangalo.

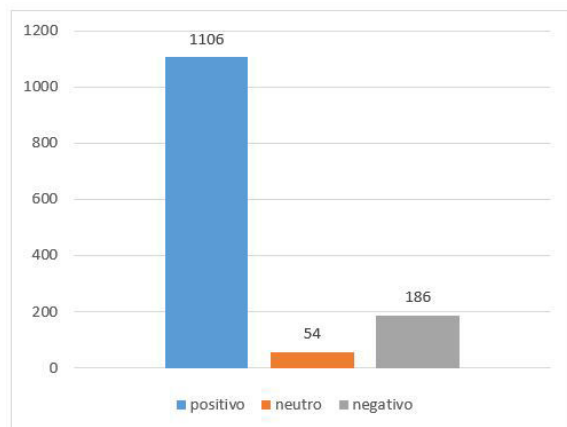


Figura 4. Análise de Sentimentos do Tópico IveteAvontade dia 06/08/2017

V. CONCLUSÃO

Os programas conseguem realizar de forma automatizada etapas importantes para a Análise de Sentimentos em redes sociais. O experimento utilizando o método de análise por meio de emojis proporcionou vislumbrar um caminho para outros métodos. Em projetos futuros pretende-se desenvolver métodos de Análise de Sentimentos mais elaborados.

AGRADECIMENTOS

Os autores agradecem ao CNPQ processo no 141077/2015-8 pelo apoio recebido, na forma de concessão de bolsa de doutorado, para o desenvolvimento deste trabalho, à comissão

organizadora deste Workshop, à coordenação do curso de pós-graduação em Engenharia da Computação e a Escola Politécnica da Universidade de São Paulo.

REFERÊNCIAS

- [1] SILVA, A. M. d. *REDES DE COMUNICAÇÃO DE DESASTRES NATURAIS: Indicadores Léxico-semânticos de Relevância Social em um Corpus Jornalístico*. Dissertação (Mestrado) — Universidade Federal do ABC, 2013.
- [2] NAIK, K.; JOSHI, A. Role of big data in various sectors. In: *2017 International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*. [S.l.: s.n.], 2017.
- [3] SILVA, A. M. d.; ROCHA, R. L. d. A. d. Análise de sentimentos de mensagens de redes sociais: Mineração de dados do twitter. In: *Anais do IV Workshop de Pós-Graduação da Área de Concentração Engenharia de Computação do Programa de Pós-Graduação em Engenharia Elétrica da EPUSP WPG-EC 2015*. [S.l.]: Departamento de Engenharia de Computação e Sistemas Digitais, 2015.
- [4] CHAUBARD MICHAEL FANG, G. G. R. M. R. S. F. Natural language processing with deep learning. In: . [s.n.], 2017. Disponível em: <https://web.stanford.edu/class/cs224n/lecture_notes/cs224n-2017-notes1.pdf>.
- [5] PLUTCHIK, R. The nature of emotions. v. 89, n. 4, p. 344–350, 2001.
- [6] LIU, B. *Sentiment Analysis and Opinion Mining*. [S.l.]: Morgan & Claypool Publishers, 2012. ISBN 1608458849, 9781608458844.
- [7] BRASIL, B. Emojis ajudam computador a identificar mensagens sarcásticas. In: . [s.n.], 2017. Disponível em: <<http://f5.folha.uol.com.br/voceviu/2017/08/emojis-ajudam-computador-a-identificar-mensagens-sarcasticas.shtml>>.

How Linear Regression can improve the management in Software Defined Wireless Sensor Networks

Como a Regressão Linear pode melhorar o gerenciamento em Redes de Sensores Sem Fio Definidas por Software

LUZ, T. C. e MARGI, C. B.

Escola Politécnica da Universidade de São Paulo

Departamento de Engenharia de Computação e Sistemas Digitais

E-mail: {thamires.luz, cintia}@usp.br

Abstract—Wireless Sensor Networks (WSN) provide the infrastructure to enable the dissemination of Internet of Things (IoT). Some IoT challenges are related to control and management of millions of sensor nodes. An automatized management is vital for continuous improvement of WSN. Software Defined Networking (SDN) paradigm enables improved management in WSN. SDN can provide the management of technologies and infrastructure of the network by allowing the global view of the network topology. Many specific solutions for management are found in the literature, but none of them present a good proactive monitoring to management of the network. Thus, in this paper we present how Linear Regression (LR), a Machine Learning method, can enable an efficient proactive monitoring for a management in Software Defined Wireless Sensor Networks (SDWSN) paradigm.

Keywords— software defined wireless sensor networks; prediction; management; linear regression.

Resumo— As Redes de Sensores Sem Fio (WSN) fornecem a infraestrutura para a disseminação da Internet das coisas (IoT). Alguns desafios da IoT estão relacionados ao controle e gerenciamento de milhões de nós sensores. Um gerenciamento automatizado é vital para a melhoria contínua da WSN. Uma possível solução que permite o gerenciamento na WSN é o paradigma de Redes Definidas por Software (SDN). A SDN pode fornecer o gerenciamento de tecnologias e infraestrutura da rede, permitindo a visão global da topologia da rede. Muitas soluções específicas para gerenciamento são encontradas na literatura, mas nenhuma delas apresenta um bom monitoramento proativo para o gerenciamento da rede. Assim, neste artigo, é apresentado como a Regressão Linear (RL), um método de Aprendizado de Máquina, pode permitir um monitoramento proativo eficiente para um gerenciador no paradigma de Redes de Sensores Sem Fio Definidas de Software (SDWSN).

Palavras-chave— redes de sensores definidas por software; previsão; gerenciamento; regressão linear.

Classificação— Doutorado

Categoria— Iniciante

I. INTRODUÇÃO

As Redes Definidas por Software (SDN - *Software Defined Networking*) inovaram o conceito tradicional estabelecido pelas redes de computadores ao separar o plano de dados e o plano de controle que antes eram integrados [1]. Dessa forma, o plano de controle passa a ser centralizado em uma entidade lógica externa chamada controlador SDN, e os *switches* mantém o plano de dados localmente. Com a separação dos planos de dados e controle, a SDN permite que as configurações e parametrizações de rede sejam realizadas por software, e não mais fiquem apenas restritas às regras implementadas nos dispositivos de rede. Dessa forma, a SDN simplifica a configuração e inovação por parte do administrador de rede através de sua programação [1]. Devido ao dinamismo oferecido pela SDN, pesquisas para integrar a SDN a Rede de Sensores Sem Fio (WSN - *Wireless Sensor Networks*) estão em foco [2], gerando o paradigma de Redes de Sensores sem Fio Definidas por Software (SDWSN - *Software Defined Wireless Sensor Networks*).

A WSN é uma rede com diversos nós sensores interligados capazes de monitorar fatores físicos e ambientais (como por exemplo a temperatura e umidade do solo) em diversas áreas. Um nó sensor típico apresenta processador, rádio, fonte de energia e um ou mais sensores. Tais nós sensores são implantados de forma estruturada ou não na área de monitoramento de interesse e se comunicam passando sua informação para os vizinhos próximos até chegar no nó sorvedouro (*sink*), que apresenta a conexão com a rede externa. Por conta disso, a WSN é considerada um tipo especial de rede *ad hoc multihop* devido à sua estrutura onde os próprios nós atuam como encaminhadores de mensagens e usuários finais. Um dos principais desafios existentes na WSN é a limitação de recursos computacionais e de energia. Além disso, a WSN apresenta diversas tecnologias e protocolos de comunicação,

o que dificulta na padronização de trocas de mensagens e configuração da rede.

Com o desenvolvimento da WSN, a Internet das Coisas (IoT – *Internet of Things*) pode evoluir e se desenvolver. A IoT apresenta uma grande variedade de dispositivos inteligentes sem fio conectados entre si para monitoramento de diversas áreas como por exemplo na saúde e sociais [3]. Dessa forma, os sistemas de IoT têm que lidar com milhares de dispositivos conectados entre si, o que dificulta a configuração e o gerenciamento manual pelo administrador [4].

O futuro da IoT depende da escalabilidade dos sensores sem fio e da capacidade de gerenciamento autônomo para acessar a rede [5]. Isso demonstra que a automatização e gerenciamento da rede e de seus recursos é de suma importância atualmente, sendo necessário a implementação de um gerenciador autônomo que atue em conjunto com o controlador SDN [4]. Ainda que sejam encontrados alguns desafios e dificuldades na WSN, o gerenciador deve buscar atuar nessas situações para melhorar o desempenho da rede.

É importante considerar que para que a infraestrutura WSN possa ser compartilhada entre diversas aplicações, como no modelo de *Sensing as a Service*, é necessário propor uma solução que considere os diversos aspectos de forma integrada, já que as propostas na literatura tratam de aspectos únicos [6].

Para tomar as decisões de forma integrada e proativamente o gerenciador deve ter as informações de recursos existentes de cada nó e da rede para prever os possíveis comportamentos que podem acontecer. Os ciclos de trabalhos dos nós sensores devem ser reprogramados automaticamente antes que os nós apresentem falhas ou tenham sua capacidade computacional e de energia esgotados. Para realizar isso, com a SDN permitindo a programação de novas políticas de roteamento, flexibilidade e maior controle de fluxos pelo administrador da rede, o gerenciamento de recursos e aplicações da rede pode considerar métodos de Aprendizado de Máquina (ML) para realizar essas previsões e realizar as ações necessárias.

Sendo assim, neste trabalho é apresentada uma arquitetura para gerenciamento em SDWSN, e como a Regressão Linear (RL), um método de ML, pode auxiliar no gerenciamento proativo da rede.

O restante do artigo é organizado como segue. Trabalhos relacionados são discutidos na Seção II. A Seção III apresenta a arquitetura proposta. A Seção IV apresenta a metodologia utilizada. Os resultados e conclusões são apresentados nas Seções V e VI, respectivamente.

II. TRABALHOS RELACIONADOS

Alguns trabalhos possibilitaram o uso de SDN em WSN. O Flow-Sensor [7] propõe a utilização das principais características do OpenFlow [8] permitindo que os nós sejam reconfigurados e monitorados mais facilmente. Há também o Sensor OpenFlow [9] e SDWN [10], que aplicam o paradigma da SDN a WSN ao fazerem a separação do plano de dados e de controle, permitindo a realocação de tarefas e o compartilhamento de funções implementadas.

O TinySDN [11] é uma abordagem que possibilita o controle distribuído. Baseado no TinySDN, o IT-SDN [12] é apresentado como sendo um arcabouço com melhorias em arquitetura, protocolos e implementação.

Com a utilização do SDN em WSN, alguns trabalhos que visam realizar o gerenciamento da rede e dos nós sensores puderam apresentar resultados. Para gerenciamento da rede, Gante et al.[13] propõem um *framework* para que a SDN gerencie a WSN de forma que o controlador seja implementado na estação base. E Dias et al. [5] apresenta a aplicação de métodos de previsão para a rede. Os autores citam como métodos baseados em regressão, séries temporais e redes neurais podem ser aplicados na previsão de dados coletados e detecção de eventos.

Embora tais trabalhos apresentem aspectos de gerenciamento da rede e de seus recursos, nenhum deles apresenta um monitoramento proativo com predição de valores para gerenciar tais aspectos. Os trabalhos atuais apresentam apenas soluções específicas, não sendo encontrada solução que gerencie vários aspectos da rede baseados em previsão.

III. ARQUITETURA

Para promover o gerenciamento proativo na SDWN foi definido inicialmente uma arquitetura baseada na conexão entre os nós sensores e o controlador SDN, e o gerenciador conectado ao controlador para realizar as atividades necessárias.

O gerenciador utilizará o IT-SDN [12] para controlar a rede e obter informações atuais da rede. Através dos métodos de ML que determinarão como será a utilização de recursos e infraestrutura da rede, o gerenciador utilizará alguns *frameworks* disponíveis atualmente para realizar as atividades específicas da rede como realocação de tarefas [14], melhoria de roteamento, e economia de energia. A Figura 1 mostra como deve ser a arquitetura proposta.




Figura 1. Arquitetura proposta da implementação com o servidor de gerenciamento ligado ao controlador SDN.

Resumidamente, as funções do controlador SDN e do gerenciador são:

- controlador SDN: coletar informações de topologia da rede e configurar os fluxos de dados e controle.
- gerenciador de aplicações: interagir com o controlador SDN e com as aplicações para obter informações de topologia da rede e capacidade dos nós (recursos físicos e aplicações suportadas), para decidir a alocação de tarefas e fluxos conforme os critérios estabelecidos, podendo

dinamicamente realocar tarefas e fluxos para manter o melhor funcionamento da WSN.

Com a arquitetura definida, a realização de testes preliminares foram realizados e a metodologia utilizada é definida na seção seguinte.

IV. METODOLOGIA

Como parte inicial da utilização de métodos para predição de métricas necessárias para realizar o gerenciamento da rede, neste trabalho foram realizados experimentos para estimar a energia remanescente em cada nó levando-se em conta os eventos da rede.

Esses experimentos foram feitos com o simulador Cooja [15], específico para redes de sensores sem fio, e considerados cenários com topologias em grade de 16, 25, 36, 49 e 64 nós, sendo o nó 1 sempre o controlador e o nó 2 sempre a estação base. Todas as simulações rodaram por uma hora. Foi utilizado o IT-SDN para dar suporte a SDN, e o sistema operacional Contiki.

O sistema operacional Contiki permite a configuração da camada RDC, que é responsável pelo controle quando um nó pode dormir/acordar, neste trabalho foi utilizado o valor padrão: ContikiMAC. Além disso, foi utilizado o protocolo CSMA na camada MAC, que é responsável pela detecção de colisões e retransmissão de pacotes, caso necessário.

Os nós foram separados em dois conjuntos de tarefas que são executados a cada 30 segundos: (a) detecção de temperatura: uma tarefa normal que não exige muito processamento e (b) criptografia de um texto: uma tarefa que exige mais processamento. Essas tarefas foram escolhidas para emular as principais atividades realizadas nos nós sensores de uma rede. Ou seja, coletar dados dos ambientes através do sensoriamento e processar algumas funções como agregação de dados, agrupamento e outras funcionalidades que exigem mais processamento. A Figura 2 mostra um exemplo da topologia.




Figura 2. Exemplo da topologia em grade com 16 nós. O nó 1 é o controlador. O nó 2 a estação base. Os nós de 3 a 9 capturam a temperatura, e os nós de 10 a 16 processam a criptografia de texto.

V. RESULTADOS PRELIMINARES

Nesta seção são apresentados os resultados obtidos nos testes preliminares. Nestes primeiros experimentos, o objetivo

foi prever a energia remanescente dos nós a cada minuto considerando os eventos da rede, além disso, determinar quais eventos mais influenciam nessa predição.

Após rodar as simulações no cooja com os cenários mencionados anteriormente, foi aplicado o método Regressão Linear para prever a energia remanescente dos nós considerando os eventos da rede: (a) pacotes de controle que saíram do nó (CS); (b) pacotes de controle que chegaram ao próximo salto (CT); (c) pacotes que foram encaminhados pelo nó (FP); (d) pacotes que foram encaminhados pelo nó e chegaram ao próximo salto (FD); (e) pacotes de dados que saíram do nó (DS); (f) pacotes de dados que chegaram ao próximo salto (DT); (g) pacotes recebidos (RV); e (h) processamentos que aconteceram no nó (PS).

A Regressão Linear (RL) é um método que além de conseguir prever um determinado valor (rótulo) baseado nos atributos apresentados, também apresenta a relação entre eles e o rótulo. Ou seja, através dos coeficientes extraídos, a RL indica quais atributos mais influenciam para a predição [16]. Nos experimentos realizados, os atributos utilizados foram os eventos descritos anteriormente, e o como rótulo a energia a cada um minuto. A Figura 3 apresenta uma parte da predição realizada para o cenário com topologia de 16 nós. A variância média dos experimentos ficou próximo de 0,86 e os coeficientes extraídos são apresentados na Tabela 4.

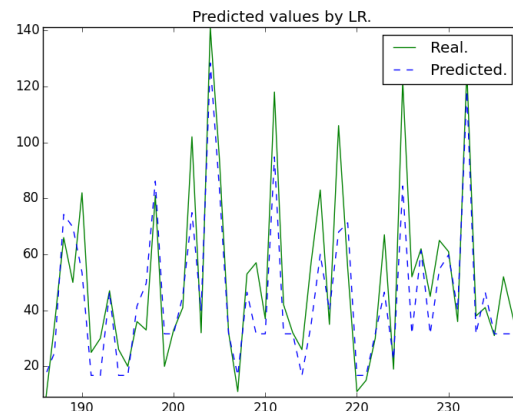


Figura 3. Parte da predição de energia (em joules) realizada com a topologia de 16 nós. Note que os valores previstos não são iguais aos reais, mas os erros são aceitáveis já que a variância ficou entre 0,86.

	CS	CT	FP	FD	DS	DT	RV	PS
16	10,23	1,39	10,14	-2,93	14,87	-12,28	-3,32	1,61
25	9,23	-1,21	3,38	6,79	4,00	21,67	6,39	-10,12
36	10,98	-4,66	3,80	9,30	7,53	27,71	-0,77	-2,71
49	11,43	-2,75	1,63	11,05	7,05	19,57	2,15	-4,63
64	11,61	0,89	5,34	7,90	4,75	23,42	-1,32	-1,35

Tabela 1

COEFICIENTES EXTRAÍDOS PELA RL PARA CADA CATEGORIA E SIMULAÇÃO REALIZADA.

Na simulação com 16 nós, os eventos mais relevantes foram o envio de pacotes de dados (DS) com 14,87 e o envio de

pacote de controle (CS) com 10,23, indicando que quanto mais o nó envia pacotes de dados e pacotes de controle, mais energia é consumida. É um resultado muito intuitivo, uma vez que a transmissão de rádio é a tarefa mais custosa em termos de energia para um nó. Apesar disso, um contraste é encontrado para as outras simulações.

Nas simulações com 25, 36, 49 e 64 nós, os eventos mais relevantes foram os pacotes de dados que efetivamente chegaram no vizinho (DT) e também o envio de pacotes de controle (CS). Isso significa que a RL está considerando o fato de um nó receber a confirmação do pacote de entrega mais relevante que apenas o ato de enviar o pacote. Essa diferença ocorreu devido à complexidade da rede. Nesses cenários com mais nós, o ato de confirmar que um pacote de dados foi enviado corretamente é mais caro devido ao fato do nó manter o rádio ligado para receber a confirmação. Além disso, com mais nós, o número de colisões aumentam e, portanto, o nó precisa retransmitir os pacotes, o que afeta a energia consumida.

Analisando os coeficientes extraídos para as outras atividades do nó, é possível notar que o ato de confirmar se um pacote foi encaminhado corretamente (FD) também impacta na energia consumida quando comparado aos outros coeficientes. A confirmação de que uma mensagem de controle foi recebida (CT) não ocorre, portanto, não influencia diretamente na energia consumida.

Os eventos de receber pacotes (RV) e processamento (PS) não afetam diretamente a energia consumida se comparados com os coeficientes de pacotes trocados. Quanto maior o valor do coeficiente mais relevante para a predição, e os valores negativos indicam que não afetam a predição.

O uso desses coeficientes pode permitir a predição de estados da rede com base nas ações que os nós podem executar, e assim, agir para gerenciar a rede, aplicativos e recursos.

VI. CONCLUSÃO E TRABALHOS FUTUROS

O gerenciamento para Redes de Sensores Sem Fio Definidas por Software (SDWN) pode funcionar com um monitoramento proativo, o que significa que o gerenciador pode atuar com base na previsão de eventos futuros. Assim, neste artigo, é apresentada uma arquitetura para realizar o gerenciamento da rede e como os métodos de ML podem auxiliar nesta tarefa. Como resultados preliminares, é apresentado a Regressão Linear (RL) para realizar a previsão da energia gasta e também indicar qual atividade realizada pelos nós mais influenciam nela.

Foram analisados os eventos de enviar pacotes de controle (CS) e pacotes de dados (DS), pacotes de controle (CT) e dados (DT) que foram efetivamente enviados, pacotes para encaminhamento (FP), pacotes que foram encaminhados efetivamente (FD), recebimento de pacote (RV) e processamento (PS).

Os coeficientes extraídos com a RL mostraram que para uma topologia pequena (16 nós), os eventos de DS e CS são os que mais impactam na energia consumida. Para topologias com

mais nós, o evento de DT afeta mais a energia consumida. Isso ocorre porque com uma topologia maior, mais colisões estão presentes e, portanto, a quantidade de pacotes que precisam ser retransmitidos aumenta.

Como trabalho futuro é necessário implementar o gerenciador conforme a arquitetura proposta. E atualmente, novas métricas como atraso na rede e taxa de entrega estão sendo avaliadas para a predição. Está planejado a aplicação de RL na arquitetura de gerenciamento para atuar de forma proativa com o gerenciamento automatizado.

AGRADECIMENTOS

T. C. Luz possui bolsa de estudos Capes processo número PROEX0212083.

REFERÊNCIAS

- [1] QILIN, M.; WEIKANG, S. A load balancing method based on sdn. In: *2015 Seventh International Conference on Measuring Technology and Mechatronics Automation*. [S.l.: s.n.], 2015. p. 18–21. ISSN 2157-1473.
- [2] KOBO, H. I.; ABU-MAHFOUZ, A. M.; HANCKE, G. P. A survey on software-defined wireless sensor networks: Challenges and design requirements. *IEEE Access*, v. 5, p. 1872–1899, 2017. ISSN 2169-3536.
- [3] HAKIRI, A. et al. Publish/subscribe-enabled software defined networking for efficient and scalable iot communications. *IEEE Communications Magazine*, v. 53, n. 9, p. 48–54, September 2015. ISSN 0163-6804.
- [4] SEMASINGHE, P.; MAGHSUDI, S.; HOSSAIN, E. Game theoretic mechanisms for resource management in massive wireless iot systems. *IEEE Communications Magazine*, v. 55, n. 2, p. 121–127, February 2017. ISSN 0163-6804.
- [5] DIAS, G. M.; BELLALTA, B.; OECHSNER, S. A survey about prediction-based data reduction in wireless sensor networks. *CoRR*, abs/1607.03443, 2016. Disponível em: <<http://arxiv.org/abs/1607.03443>>.
- [6] MARGI, C. B.; ALVES, R. C. A.; SEPULVEDA, J. Sensing as a service: Secure wireless sensor network infrastructure sharing for the internet of things. *Open Journal of Internet of Things (OJIOT)*, v. 3, n. 1, p. 91–102, 2017. ISSN 2364-7108.
- [7] MAHMUD, A.; RAHMANI, R. Exploitation of openflow in wireless sensor networks. In: *Proceedings of 2011 International Conference on Computer Science and Network Technology*. [S.l.: s.n.], 2011. v. 1, p. 594–600.
- [8] MCKEOWN, N. et al. Openflow: Enabling innovation in campus networks. *SIGCOMM Comput. Commun. Rev.*, ACM, New York, NY, USA, v. 38, n. 2, p. 69–74, mar. 2008. ISSN 0146-4833. Disponível em: <<http://doi.acm.org/10.1145/1355734.1355746>>.
- [9] LUO, T.; TAN, H. P.; QUEK, T. Q. S. Sensor openflow: Enabling software-defined wireless sensor networks. *IEEE Communications Letters*, v. 16, n. 11, p. 1896–1899, November 2012. ISSN 1089-7798.
- [10] COSTANZO, S. et al. Software defined wireless networks: Unbridling sdns. In: *2012 European Workshop on Software Defined Networking*. [S.l.: s.n.], 2012. p. 1–6. ISSN 2379-0350.
- [11] OLIVEIRA, B. T. de; GABRIEL, L. B.; MARGI, C. B. Tinsdn: Enabling multiple controllers for software-defined wireless sensor networks. *IEEE Latin America Transactions*, v. 13, n. 11, p. 3690–3696, Nov 2015. ISSN 1548-0992.
- [12] ALVES, R. C. A. et al. It-sdn: Improved architecture for sdn. In: *XXXV Simpósio Brasileiro de Redes de Computadores - SBRC 2017*. [S.l.: s.n.], 2017.
- [13] GANTE, A. D.; ASLAN, M.; MATRAWY, A. Smart wireless sensor network management based on software-defined networking. In: *2014 27th Biennial Symposium on Communications (QBSC)*. [S.l.: s.n.], 2014. p. 71–75.
- [14] SILVA, H. et al. Warm: Wsn application development and resource management. In: *XXXIV SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÃO - SBrT 2016*. [S.l.: s.n.], 2016.
- [15] OSTERLIND, F. et al. Cross-level sensor network simulation with cooja. In: *Proceedings. 2006 31st IEEE Conference on Local Computer Networks*. [S.l.: s.n.], 2006. p. 641–648. ISSN 0742-1303.
- [16] COHEN, J. et al. *Applied multiple regression/correlation analysis for the behavioral sciences*. [S.l.]: Lawrence Erlbaum Associates, 2003.

Interactive 3D visualization for medical temporal data

Visualização 3D interativa de dados médicos temporais

SILVA, L. S.*†; NUNES, F. L. S.*†; NAKAMURA, R.*

*Interactive Technology Laboratory (Interlab) - Departamento de Engenharia de Computação e Sistemas Digitais
Escola Politécnica da Universidade de São Paulo

†Laboratório de Aplicações de Informática em Saúde (LApIS)
Escola de Artes, Ciências e Humanidades (EACH) - Universidade de São Paulo (USP)
E-mail: {leonardosilva, fatima.nunes, ricardonakamura}@usp.br

Abstract—Temporal data visualization is an important research area that helps understanding patterns and relations among data, whose organization presents time-based aspects, supporting planning, and decision-making processes. In the Healthcare area, the Anamnesis procedure offers to the physician a large volume of valuable information, which usually is analyzed considering temporal aspects. Despite their importance and richness, the lack of adequate tools to explore these data can limit their use. Approaches based on Virtual Reality (VR) techniques are still little explored to visualize temporal data, although they can provide more natural interaction in real time. Considering the limited use of three-dimensional (3D) space in temporal data visualization, we propose a controlled experiment to evaluate the user experience of a VR-prototype to allow visualization and exploration of medical data with temporal aspects. The findings pointed out the background information influence in the user experience issues, such as users' interaction and the learning processes involved. Our results also indicate that the 3D space use can open opportunities in temporal data visualization bringing benefit in the data exploration.

Keywords— Information Visualization; Temporal Data; Medical Data; Virtual Reality.

Resumo— A visualização de dados temporais é uma importante área de pesquisa que auxilia no entendimento de padrões e relações existentes entre os dados, apoiando processos de planejamento e tomada de decisões. Na área da Saúde, o procedimento de Anamnese é fonte de um grande volume de importantes informações, normalmente analisadas sob a perspectiva temporal. Apesar de sua importância e riqueza, o chamado uso secundário dessas informações tem sido pouco explorado em função da ausência de ferramentas adequadas. Abordagens baseadas no uso de técnicas de Realidade Virtual (RV) são pouco exploradas na visualização de dados temporais, assim, considerando o uso limitado do espaço tridimensional (3D) na visualização de dados temporais, um experimento controlado foi proposto para avaliar a experiência dos usuários na utilização de um protótipo, baseado em técnicas de RV, para visualização e exploração de dados médicos com aspectos temporais. Além da influência do conhecimento prévio nas questões relacionadas à experiência do usuário, nos processos de aprendizagem e interação, os resultados indicaram que o uso do espaço 3D pode vir a beneficiar a exploração de dados temporais.

Palavras-chave— Visualização de Informações; Dados Temporais; Dados Médicos; Realidade Virtual.

Classificação— Doutorado.

Categoria— Iniciante.

I. INTRODUÇÃO

A área de Saúde produz um grande volume de dados com características temporais, manipulados em sua maioria por ferramentas bidimensionais (2D), que contribuem para a compreensão dos registros médicos de acordo com a chamada abordagem baseada em evidências. Inicialmente, os registros médicos eram organizados em uma linha do tempo [1][2], posteriormente, com a adoção do Prontuário Eletrônico, do inglês *Electronic Health Record* (EHR), novas ferramentas para Visualização de Informação (VI) foram desenvolvidas, visando o uso secundário da informação [3] e a exploração desse novo tipo de dado, responsável por descrever a trajetória clínica de um paciente [4].

Diferentes áreas de conhecimento têm sido influenciadas por importantes contribuições vindas da Realidade Virtual (RV), mas o uso do espaço tridimensional (3D) na visualização de dados temporais ainda pode ser considerado limitado [5]. Por acreditar que técnicas 3D/RV podem agregar relevantes benefícios na visualização e exploração de dados temporais, um protótipo com uma representação visual 3D foi desenvolvido, permitindo operações como: navegação, seleção e manipulação [6][7]. O ineditismo deste projeto de pesquisa, está no emprego de Modelos de Atenção Visual com intuito de otimizar a percepção visual das informações apresentadas.

Este trabalho apresenta o protótipo desenvolvido com base em técnicas de RV e avalia a experiência dos usuários na interação com dados temporais oriundos de procedimentos de Anamnese realizados pelo Departamento de Homeopatia de um hospital público da cidade de São Paulo.

II. TRABALHOS CORRELATOS

Presentes em diversas áreas de conhecimento, o entendimento dos dados temporais é considerado um elemento chave na construção de um uso significativo dos dados, por essa

razão, diversas técnicas de visualização de dados temporais tem sido propostas, grande parte delas orientadas a um contexto ou propósito específico [8][9].

Combinar o sistema visual humano com o poder e recursos computacionais dos avanços tecnológicos é uma das grandes contribuições da VI na exploração, entendimento e análise de dados abstratos [10][11]. Por sua vez, além de permitir a criação de metáforas mais próximas do mundo real por meio de técnicas de RV, a utilização do espaço 3D oferece uma nova dimensão na representação do tempo, o que pode vir a ser muito útil no trabalho com dados temporais[12].

Como abordagem a visualização de Histórias Pessoais, uma arquitetura e um modelo de dados voltados ao trabalho com linhas do tempo foram propostos, permitindo estruturar e visualizar dados médicos e contribuir com uma abordagem baseada em evidências [1][2]. A adoção do Prontuário Eletrônico impõe um novo tipo de dados, o dado longitudinal e o desafio de promover o uso secundário de dados médicos, impulsionando a criação de novas ferramentas de VI [3][4][13][14][15].

A metáfora em formato de Cubo é considerada uma representação conceitual muito interessante em visualizações 3D em virtude das possibilidades de utilização oferecidas, quando a visualização de dados temporais é considerada e mesmo em situações onde não há necessidade da representação espacial. Um *Space-Time Cube* já foi utilizado para uma revisão de técnicas de visualização temporais, por meio da realização de uma série de operações paramétricas [16].

A discussão acerca dos efetivos benefícios advindos do uso do espaço 3D não é nova, mas continua aberta. Dessa forma, considerando os avanços na área de RV, torna-se possível vislumbrar oportunidades no nível de interação oferecidas por ferramentas de VI na visualização de dados temporais.

III. PROTÓTIPO - 3D Block

Inicialmente com foco em dados médicos, oriundos do procedimento de Anamnese, foi proposto o protótipo de uma ferramenta interativa 3D para visualização de dados temporais, o *3D Block*. A ferramenta usa um conjunto de dados disponibilizado por um hospital parceiro na pesquisa, coletado durante o atendimento ambulatorial oferecido a população, sendo possível agrupar os dados em quatro categorias: (a) dados pessoais, (b) sintomas, (c) hipótese diagnóstica, e (d) conduta adotada.

Uma vez considerado os dados coletados durante todas as consultas de um paciente, essa informação torna-se de grande valia ao permitir estabelecer uma linha do tempo e oferecer *insights* sobre a condição médica de um paciente ou apoiar a definição de um protocolo de tratamento. Assim, a representação visual escolhida para o protótipo foi a de um bloco 3D, inicialmente configurado conforme a Figura 1.

Assim, se cada consulta for representada visualmente por um bloco 3D, o eixo Z pode ser usado para oferecer uma perspectiva histórica. Da ponto de vista de projeto, além da facilidade de interação a representação visual escolhida viabiliza futuras extensões e a integração com dispositivos de RV. As operações de navegação, seleção e manipulação




Figura 1. Representação visual escolhida para visualização de dados médicos.

implementadas no protótipo permitem aos usuários acessar as informações e interagir com o protótipo em diferentes perspectivas, em algumas situações acessando até três grupos de informações diferentes sobre o paciente, Figura 2. O protótipo foi implementado usando o motor de jogos *Unity3D*, sendo que os dados dos pacientes estão armazenados em um banco de dados *MySQL*, acessado por meio de *scripts PHP*.

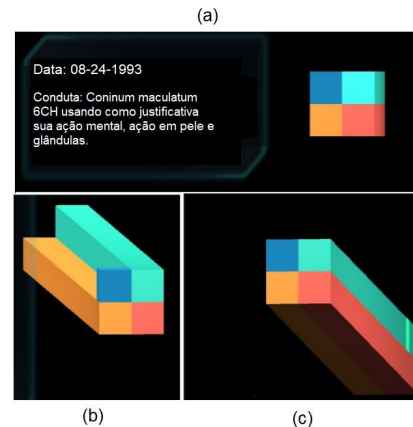


Figura 2. Visões da interface do protótipo *3D Block*.

IV. EXPERIMENTO

Um experimento controlado foi realizado com o objetivo de avaliar a experiência do usuário junto a uma interface interativa 3D para visualizar dados médicos temporais, oriundos do procedimento de Anamnese, representados por meio de blocos 3D.

No protótipo, o registro médico é inicialmente representado conforme a Figura 2a; Um bloco 3D é mostrado sendo que cada cor representa um grupo de informação (seção III), ainda que a princípio o usuário tenha a impressão de que é um único bloco 3D, todos os registros médicos recuperados para um determinado paciente já estão carregados na visualização. Assim que iniciada a interação dos usuários com o bloco 3D, eles poderão visualizar o bloco 3D em sua totalidade e acessar os dados médicos do paciente, como mostra as Figuras 2b e 2c. Vale mencionar que o tamanho final do bloco 3D dependerá do número de registros médicos armazenados no banco de dados.

A. Objetivo e Hipóteses

O principal objetivo era avaliar a experiência do usuário na utilização do protótipo para visualização de dados médicos

temporais. O protótipo em avaliação posteriormente será usado em novos experimentos visando discutir possibilidades e contribuições do espaço 3D e técnicas de RV na visualização de dados temporais.

Guiaram a realização do experimento as seguintes questões de pesquisa:

- 1) *Quais são os efeitos do uso do espaço 3D na exploração de dados médicos temporais?*[1][4][15]
- 2) *Quais são os efeitos do uso do espaço 3D no esforço cognitivo para visualizar dados médicos temporais?*[7]

Apoiando cada uma das questões de pesquisa propostas há as seguintes hipóteses:

- 1) *O uso do espaço 3D contribuirá para melhorar a exploração de dados médicos temporais, oferecendo interfaces mais intuitivas e interativas.*
- 2) *Usando a representação visual de bloco 3D melhora a percepção dos usuários sobre a visualização de dados temporais.*

B. Participantes

Participaram do experimento 14 voluntários, ainda que não fosse pré-requisito cinco voluntários declararam familiaridade com conceitos de 3D/RV, todos declararam familiaridade com uso de computador e sistemas computacionais, não sendo exigido nenhum conhecimento prévio na área de saúde, uma vez que o foco era a avaliação da experiência do usuário na utilização do protótipo. A idade média dos voluntários foi de 38 anos, sendo o grupo composto por estudantes de graduação, pós-graduação e outros profissionais.

C. Avaliação do Protótipo

A Figura 3 representa o método adotado na condução do experimento. Todos os voluntários tiveram um tempo livre para interagir com o protótipo e, por opção, não foi disponibilizada uma seção de treinamento. Além de observar a reação dos voluntários no primeiro contato com o protótipo, buscava-se avaliar se os mesmos seriam capazes de baseados no conhecimento adquirido durante o tempo livre, executar uma tarefa simples que exigia alguma interação com os dados do paciente.

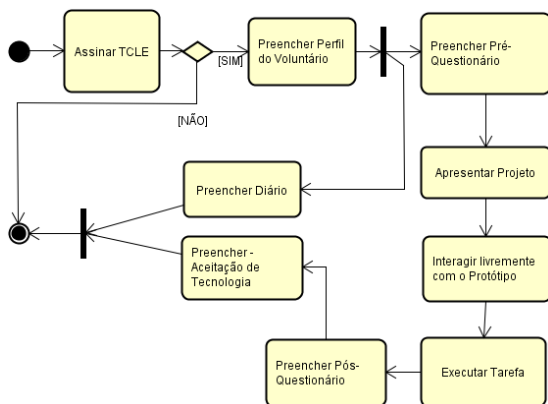


Figura 3. Método adotado - Condução do Experimento.

Ao final do experimento, todos os voluntários preencheram um conjunto de formulários que foi analisado de maneira qualitativa, o áudio das seções foram gravados para que junto dos registros feitos acerca das reações dos usuários pudessem ser usado na análise dos resultados. O experimento está registrado junto ao Comitê de Ética em Pesquisa (CEP) da Escola de Artes, Ciências e Humanidades da Universidade de São Paulo (EAHC/USP) sob o CAAE: 70626117.6.0000.5390 - Parecer Consubstanciado número 2.223.465.

V. RESULTADOS E DISCUSSÕES PRELIMINARES

O protótipo foi avaliado em um experimento controlado em que usuários experientes e não experientes no uso de tecnologias 3D/RV puderam expressar suas opiniões sob duas perspectivas: experiência do usuário e aceitação de tecnologia.

A. Perspectiva de Experiência do Usuário

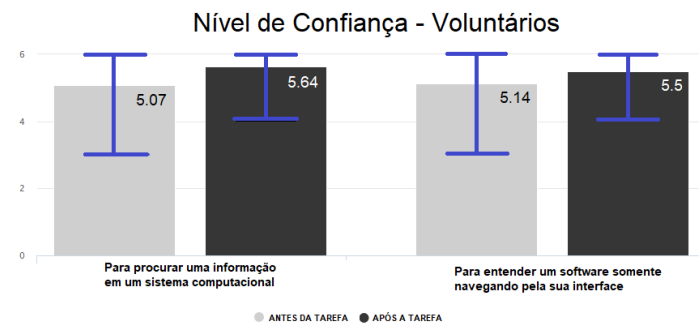


Figura 4. Resultado Geral - Nível de Confiança.

A Figura 4 apresenta a média e a variância para o nível de confiança dos voluntários, antes e após o experimento com o protótipo. Enquanto o primeiro aspecto avaliado considerava a habilidade de buscar uma informação em um sistema, o segundo aspecto estava relacionado a habilidade de entender um software somente navegando por sua interface.

Ambos os aspectos avaliados mostraram aumento no nível de confiança após a realização do experimento. No primeiro aspecto, os voluntários inicialmente apresentaram um nível de confiança médio de 5,07, aumentando após o experimento para 5,64 e com a variância indo de 3 até 6. Já no segundo aspecto, inicialmente era observado uma média de 5,14 e após o experimento de 5,5, com variância também variando entre 4 e 6.

Vale destacar que há forte influência do conhecimento prévio do voluntário, em tecnologias 3D/RV, nessa avaliação. Quando analisados sob essa perspectiva, ainda que todos os voluntários manifestem reconhecer os benefícios advindos, os usuários considerados experientes indicam claramente pontos de melhoria e são mais críticos, em especial, na avaliação do segundo aspecto. Usuários considerados não experientes, sinalizam as mesmas questões levantadas pelos experientes, contudo, isso não causa impacto em suas avaliações.

O conhecimento prévio também foi determinante nos primeiros momentos de contato do usuário com o protótipo,

enquanto os mais experientes já buscavam formas de interação com o bloco 3D, aqueles considerados não experientes, precisavam de mais tempo para compreender como manipular a representação visual. Todos os voluntários foram capazes de completar a tarefa proposta e reconhecer o uso do eixo *Z* como representação do tempo.

B. Perspectiva de Aceitação de Tecnologia




Figura 5. Resultado Geral - Aceitação de Tecnologia.

A Figura 5 resume os resultados gerais para os voluntários a partir da perspectiva de aceitação de tecnologia, independentemente do conhecimento prévio todas as respostas se concentraram nos níveis superiores da escala adotada.

As respostas indicam que os voluntários creem que o uso do espaço 3D pode melhorar a forma como os usuários interagem com os dados temporais, configurando em um recurso relevante. Também sinalizaram o protótipo como sendo fácil de usar, oferecendo uma forma interativa e intuitiva para interação com o conjunto de dados. Da mesma forma, todos concordaram que um menor esforço cognitivo é necessário para lidar com os dados, mesmo para os usuários que não possuíam conhecimento prévio.

Ainda que comentários promissores e contribuições efetivas tenham sido registrados, uma pequena parte dos voluntários manifestou desconforto com situações relacionadas ao mau funcionamento da tecnologia em suas rotinas diárias, ocasionando, por exemplo, paradas no trabalho. Ainda que tais respostas não tenham relação direta com o protótipo, elas foram registradas como questões relevantes a serem consideradas em trabalhos futuros.

VI. CONCLUSÕES

Com base nos resultados desse trabalho, e considerando nosso objetivo e hipóteses, é possível chegar as seguintes implicações após a avaliação da experiência de usuário com o protótipo:

- 1) Mesmo sem a seção de treinamento os voluntários relataram uma experiência positiva com o uso do protótipo, reportando sua interface como intuitiva e interativa. Voluntários pertencentes à área médica foram capazes

de citar situações onde poderiam usar o protótipo, independentemente de possuírem conhecimento prévio ou não em tecnologias 3D/RV.

- 2) Todos os voluntários reconheceram que o bloco 3D representava um registro médico e que o alinhamento de todos os blocos 3D no eixo *Z* formava uma linha do tempo, relatando maior facilidade para navegar nas informações ou mesmo entender como um paciente evoluiu ao longo do tempo.

Os encaminhamentos vão no sentido de refinar o protótipo de acordo com os pontos de melhorias apontados e a inclusão de novas funcionalidades e a realização de novos experimentos para validação do protótipo com profissionais da área da Saúde e seu impacto e influência na rotina dos profissionais.

REFERÊNCIAS

- [1] PLAISANT, C. et al. Lifelines: Using visualization to enhance navigation and analysis of patient records. In: *Proceedings of the 1998 American Medical Informatic Association Annual Fall Symposium*. [S.l.: s.n.], 1998. p. 76–80.
- [2] HSU, W.; ARNOLD, C. W.; TAIRA, R. K. A neuro-oncology workstation for structuring, modeling, and visualizing patient records. In: *ACM. Proceedings of the 1st ACM International Health Informatics Symposium*. [S.l.], 2010. p. 837–840.
- [3] ROQUE, F. S.; SLAUGHTER, L.; TKATŠENKO, A. A comparison of several key information visualization systems for secondary use of electronic health record content. In: *ASSOCIATION FOR COMPUTATIONAL LINGUISTICS. Proceedings of the NAACL HLT 2010 Second Louhi Workshop on Text and Data Mining of Health Documents*. [S.l.], 2010. p. 76–83.
- [4] WANG, T. D. et al. Visual information seeking in multiple electronic health records: design recommendations and a process model. In: *ACM. Proceedings of the 1st ACM International Health Informatics Symposium*. [S.l.], 2010. p. 46–55.
- [5] RIVA, G. Applications of virtual environments in medicine. *Methods of information in medicine*, Schattauer GmbH, v. 42, n. 5, p. 524–534, 2003.
- [6] BOWMAN, D. et al. *3D User Interfaces: Theory and Practice*, CourseSmart eTextbook. [S.l.]: Addison-Wesley, 2004.
- [7] TEYSEYRE, A. R.; CAMPO, M. R. An overview of 3d software visualization. *IEEE transactions on visualization and computer graphics*, IEEE, v. 15, n. 1, p. 87–105, 2009.
- [8] AIGNER, W. et al. Visualizing time-oriented data—a systematic view. *Computers & Graphics*, v. 31, n. 3, p. 401 – 409, 2007. ISSN 0097-8493. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0097849307000611>>.
- [9] DAASSI, C.; NIGAY, L.; FAUVET, M.-C. A taxonomy of temporal data visualization techniques. *Information-Interaction-Intelligence*, Cite-seer, v. 5, n. 2, p. 41–63, 2005.
- [10] GERSHON, N.; EICK, S. G.; CARD, S. Information visualization. *Interactions*, ACM, v. 5, n. 2, March/April 1998.
- [11] LIU, S. et al. A survey on information visualization: Recent advances and challenges. *The Visual Computer*, Springer Berlin Heidelberg, 1994.
- [12] SILVA, S. F.; CATARCI, T. Visualization of linear time-oriented data: a survey. In: *Proceedings of the First International Conference on Web Information Systems Engineering*. [S.l.: s.n.], 2000. v. 1, p. 310–319 vol.1.
- [13] DABEK, F. et al. Visualization of longitudinal clinical trajectories using a graph-based approach. In: *ACM. Proceedings of the 2015 Workshop on Visual Analytics in Healthcare*. [S.l.], 2015. p. 5.
- [14] FAIOLA, A.; SRINIVAS, P.; HILLIER, S. Improving patient safety integrating data visualization and communication into icu workflow to reduce cognitive load. In: *SAGE PUBLICATIONS. Proceedings of the International Symposium on Human Factors and Ergonomics in Health Care*. [S.l.], 2015. v. 4, n. 1, p. 55–61.
- [15] CHITTARO, L. Information visualization and its application to medicine. *Artificial Intelligence in Medicine*, Udine, v. 22, n. 2, 2001.
- [16] BACH, B. et al. A review of temporal data visualizations based on space-time cube operations. In: *Eurographics conference on visualization*. [S.l.: s.n.], 2014.

Impact Assessment Of UAS Operations on Airport Capacity Applying Contingency Operations

BAUM, D.M*, NETO, E.P.*, ALMEIDA, J.R.*, CUGNASCA, P.S.*, CAMARGO Jr., J.B.*

School of Engineering - University of São Paulo (Poli - USP)

São Paulo, Brazil

derick.baum@usp.br, euclidescpn@usp.br,

jorgerady@usp.br, cugnasca@usp.br, joaocamargo@usp.br

OLIVEIRA, I.R.*, MELLO, M.P. *, FREGNANI, J.A.T.G*

Boeing Research & Technology-Brazil - The Boeing Company

Estrada Dr Altino Bondesan 500 – São José dos Campos-SP, Brazil 12247-016, italo.romanideoliveira@boeing.com,

marcio.p.mello@boeing.com, jose.a.fregnani@boeing.com

Abstract—Integrating Unmanned Aircraft Systems (UAS) into non-segregated airspace is a challenge nowadays. According to the International Civil Aviation Organization (ICAO), it depends on technological advances and development of associated procedures. ICAO has created rules based on UAS to segregated airspace, including contingency operations related to failures in Command and Control (C2) link. Considering the airport capacity analytical model proposed by Department of Airspace Control (DECEA), this research aims at assessing the impact of UAS operations on airport capacity by applying contingency operations in case of C2 link failures in non-segregated airspace.

Keywords— UAS, Airport Capacity, Non-Segregated Airspace, C2 link failures, Remotely Piloted Aircraft System (RPAS).

Classification— Doctor's degree.

REFERENCE

- [1] BAUM, D.M, et. al. "Impact Assessment of UAS Operations on Airport Capacity Applying Contingency Operations". Presented in XVI SITRAER (Simpósio de Transporte Aéreo), RJ, 2017.

1. INTRODUCTION

UAS is an aircraft and its associated elements which are operated with no pilot on board and RPAS is defined as a set of configurable elements consisting of a remotely-piloted aircraft, its associated remote pilot station(s), the required command and control links and any other system elements as may be required, at any point during flight operation [1]. This document describes how to operate the RPAS, communication, rules of air traffic and use of airports. An essential factor to be considered, which directly affects the safety, is the

loss of C2 link. This work aims at addressing airport capacity assessment by considering the loss of link C2 in non-segregated operation. We considered the runway capacity evaluation, not taking into account passenger terminal and apron. Although several models of airport capacity calculation are presented, we emphasized our considerations for the analytical model used by the Brazilian Department of Airspace Control (DECEA).

2. UAS OPERATION AND CONTINGENCY PROCEDURES

Considering operation of UAS in an airport, based on [1], aerodrome integration issues must be considered, such as:

- the UAV's ability to follow ATC instructions in the air or on the maneuvering area;
- applicability of instrument approach minima to UAV operations;
- infrastructure, such as approach aids, ground handling vehicles, landing aids, launch/recovery aids;
- integration of UAV with manned aircraft in the vicinity of, and on the movement area of, an airport and others.

Considering a controlled airport, that is, provided with TWR, the UAV should be able to

perform the maneuvers defined by ATCo, as well as manned aircraft, without reduction of safety levels.

Considering that the UAV will be remotely piloted, an important aspect is the C2 link, which connects the RPS and the UAV for controlling the flight [1]. There are two different forms to link between UAV and remote pilot: RLOS, as presented on figure 1, and BRLOS as presented on figure 2:

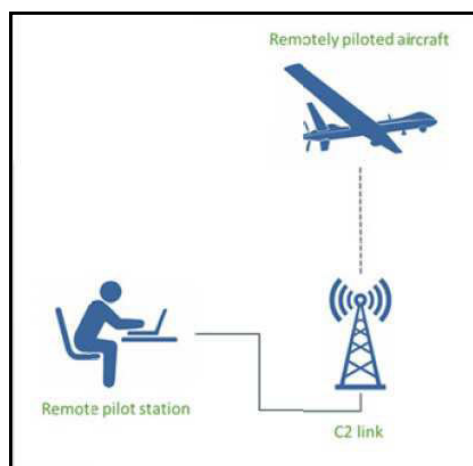


Figure 1: UAV and remote pilot – direct access [1]

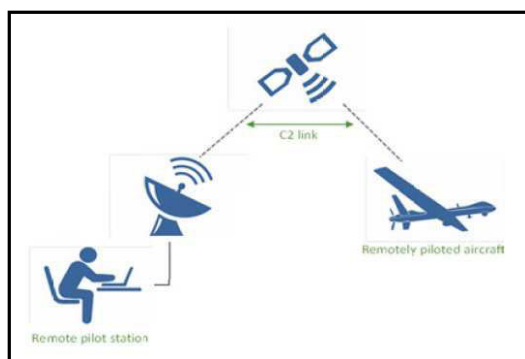


Figure2: UAV and remote pilot–via satellite access [1]

However, this link may fail and, thus, the aircraft must become a fully autonomous system. However, it is necessary to know the differentiation between loss of C2 link and failure of ATC voice communications, because different procedures may be required for C2 link loss and ATC voice communications failure events. It will be necessary for ATC to be able to distinguish between these situations. In airspace where SSR (transponder)

carriage is required, this can best be achieved by use of a dedicated SSR code.

In case of ATC voice communication failure, the UAV will likely still be under the remote pilot's command, and must execute specific procedures, defined in [5]. These procedures are the same both for unmanned and manned aircraft.

In case of C2 link loss, it must be considered that the UAV will apply contingency operations, described in [1]:

- a) continue original flight plan;
- b) land at nearest appropriate designated landing site;
- c) direct return to departure aerodrome or departure site;
- d) flight termination: should be avoided as it presents a risk to people and property on the ground; and
- e) climb to altitude to attempt to regain the C2 link.

The aim is evaluating the impact of C2 link loss on capacity, then we disregarded flight termination and climb to altitude. We must be aware that, as described above, immediate flight termination is not recommended because of drastic reduction of safety level.

3. THE BRAZILIAN MODEL FOR RUNWAY SYSTEM CAPACITY

The Brazilian Model for runway capacity is called of Runway System Capacity and presented in [9]. This model uses the definition of Theoretical Runway Capacity as a runway capacity system of an airport, calculated for an interval of sixty minutes, as a function of runway occupation average time, added of Regulatory separation between aircraft, provided for in legislation, as well as the specific rules and procedures applicable to the air operations of the locality concerned.

Considering the purpose of this work, the main factors to be taken into account are Runway Occupation Average Time e Aircraft MIX. O Runway Occupation Average Time (MATOP), defined as arithmetic mean, by aircraft category, between the Runway Occupation Time during the Departure (TOPD) and the Runway Occupation

Time during the Landing (TOPP). The MATOP is presented in (3):

$$MATOP = \frac{TOPD + TOPP}{2} \quad (3)$$

MIX of aircraft is the fleet percentage distribution operating on studying airport. According to ICAO, specified on DOC 8168 (PANS OPS-Aircraft Operation), the aircraft are subdivided into five categories, considering the threshold crossing speed. Consequently, aircraft are classified in the following categories:

- a) CAT “A” Speed less than 90 KT;
- b) CAT “B” Speed between 91/120KT;
- c) CAT “C” Speed between 121/140KT;
- d) CAT “D” Speed between 141/165KT; and
- e) CAT “E” Speed between 166/210K.

Thus, the concept of Weighted Mean Time of Runway Occupation arises (TMOP), which is defined as the weighted average between MATOP, using the aircraft MIX as a weighting factor. The average time should be calculated for each existing threshold at the aerodrome, depending on the different taxiway configurations for each runway in use (4):

$$TMOP = \frac{MIXa * TOPa + MIXb * TOPb + MIXc * TOPc + MIXd * TOPd + MIXe * TOPe}{\Sigma MIX} \quad (4)$$

4. NON-SEGREGATED AIRPORT AND UAS C2 LINK FAILURE

Considering UAS operation in non-segregated airspace, a model describing additional ATCo activities was presented in [4] for different situations, highlighting C2 Link failure and the contingency operation “Continue Original Flight Plan”, presented in figure 3. One of the proposed activities was the interruption of airport operations.

5. IMPACT OF UAS C2 LINK FAILURE ON AIRPORT CAPACITY

The impact on airport capacity of the UAS C2 link failures will depend, directly:

- of the number of runway in that airport; and
- the moment it will be determined that the airport will be impracticable.

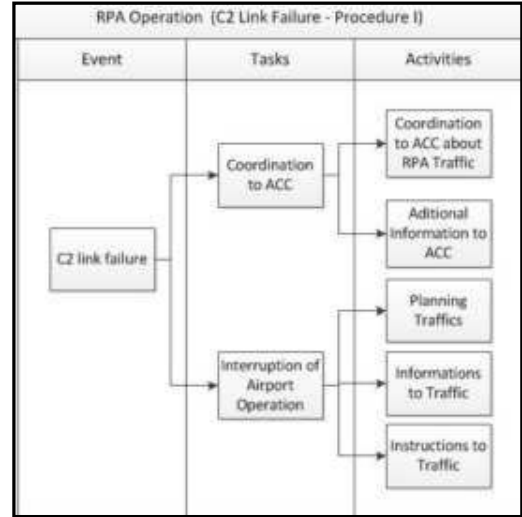


Figure 3: C2 link failure Procedure I [4]

The runway capacity presented by DECEA, is a departure point for the definition of a criterion for the approval of new flights to those airports. Thus, with the presence of the UAS operation in an airport, all the characteristics of the operation of this aircraft should be known (occupation runway time, time to comply with ATCo instructions, taxiing, etc.) including the probability of C2 link failure and all procedures to be performed in this case. It is reasonable to propose the inclusion of the UAV variable in equation 4, making it (8):

$$TMOP = MIXa * TOPa + MIXb * TOPb + MIXc * TOPc + MIXd * TOPd + MIXe * TOPe + MIXu * TOPu \quad (8)$$

6. FINAL CONSIDERATIONS

This paper presents the possible impacts of the UAS operation on the non-segregated airspace and airport capacities. It should be noted that the impacts generated in both the airspace capacity and the non-segregated airport are based on modeling, considering that the simple presence of the UAV increases the workload of the ATCo, consequently

reduces the airspace capacity. The aim of this work was to show that the C2 link failure, according to the modeling, will impact the capacity of the destination airport. However, analyzing the operation of the UAV as a whole, from runway occupation time to taxiing time, is fundamental to analyze the impacts, if any, of operating the UAV on the airport capacity, even without any loss of link. This analysis will entail the inclusion of another category of aircraft in the equation that defines the runway occupation time, foreseen in the DECEA model.

ACKNOWLEDGMENT

The authors would like to thank Boeing Research & Technology-Brazil (BR&T-Brazil) for the support for this research and for its institutional support to the Safety Analysis Group (GAS) of the School of Engineering of the University of São Paulo (Poli-USP).

7. REFERENCES

- DOLPH, C.; LOGAN, M. J.; GLAAB, L. J.; VRANAS, T. L.; MCSWAIN, R. G.; JOHNS, Z. Sense and Avoid for Small Unmanned Aircraft Systems. **AIAA Information Systems-AIAA Infotech @ Aerospace**, n. 10, 2017. Disponível em: <<http://arc.aiaa.org/doi/10.2514/6.2017-1151>>.
- FAA. Airport Capacity and Delay - AC: 150/5060-5. n. 10, p. 1–31, 1994.
- FAA. Concept of Operations for the Next Generation Air Transportation System. 2011. n. October, 2011.
- HORONJEFF, R.; MCKELVEY, F.; SPROULE, W.; YOUNG, S. **Planning and design of airports. 2010**. [s.l: s.n.]
- ICAO. **Manual on remotely piloted aircraft systems (rpas)**. [s.l: s.n.]
- NETO, E. P.; BAUM, D. M.; HERNANDEZ-SIM, C. E.; JR, J. R. A.; JR, B. C.; CUGNASCA, P. S. An Airspace Capacity-Based Safety Assessment Model Considering UAS Integration . 2017.
- NEUBAUER, K.; FLEET, D.; GROSOLI, F.; VERSTYNEN, H. **Unmanned aircraft systems (uas) at airports: a primer**. [s.l: s.n.].
- OGAN, R. T.; MEMBER, I. S. Integration of Manned and Unmanned Aircraft Systems into U . S . Airspace. **IEEE, Piscataway, NJ I5MAR2014**, p. 4–7, 2014.
- R. AUSTIN. **Unmanned aircraft systems. 2011**. [s.l: s.n.]

Proposal of Data Quality Reference Architecture for Analytical Environment in Big Data

Proposta de Arquitetura de Referência de Qualidade de Dados para Ambiente Analítico em Big Data

FRANCISCO, MARITZA M. CARVALHO; SOUZA, PROFA. DRA. SOLANGE N. ALVES

PCS – Engenharia de Computação e Sistemas Digitais – Escola Politécnica da Universidade de São Paulo

maritza@vantageinfotech.com.br, ssouza@usp.br

Abstract- Data quality (DQ) is a relevant subject for modern organizations, especially those that are implementing big data solutions. Key features of big data bring new data quality challenges that must be addressed by DQ management practices. It is observed that it is not possible to evolve in data quality surveys in big data without considering in an integrated way the concepts of data characteristics and the environment. This research aims to define the essential dimensions for the analytical environment based on the common problems of this environment, notably in big data, and proposes a reference architecture for data quality in this technological context. This architecture will consider the combinations of problems, existing architectures, applications used, usage context.

Keywords-Data quality, data quality architecture, big data, data quality dimensions, analytics, models of data quality.

Resumo— Qualidade de dados (QD) é um assunto relevante para as organizações modernas, especialmente aquelas que estão implementando soluções de *big data*. As características essenciais do *big data* trazem novos desafios de qualidade de dados que devem ser endereçados pelas tratativas de gerenciamento de QD. Observa-se que não se consegue evoluir nas pesquisas de qualidade de dados em *big data* sem considerar, de forma integrada, os conceitos de características dos dados e do ambiente. Esta pesquisa objetiva definir as dimensões essenciais para o ambiente analítico baseando-se nos problemas comuns deste ambiente, notadamente em *big data*, e propõe uma arquitetura de referência para a qualidade de dados neste contexto tecnológico. Esta arquitetura considerará as combinações de problemas de QD, arquiteturas existentes, aplicações utilizadas e contexto de uso.

Palavras-chave— Qualidade de dados, arquitetura de qualidade de dados, *big data*, dimensões da qualidade de dados, *analytics*, modelos de qualidade de dados.

Classificação—Doutorado

Categoria—Iniciante

I. INTRODUÇÃO

A tecnologia da informação vem evoluindo de modo a oferecer recursos tecnológicos e computacionais capazes de processar, de forma rápida e confiável, um grande e diverso

volume de informações, gerando oportunidades para os gestores melhorarem a visão de futuro das organizações, promovendo a inovação, a melhoria de serviços, a previsibilidade do comportamento de mercado, a prevenção de riscos, o aumento da efetividade dos negócios. Por isso, uma das questões de extrema relevância na atualidade diz respeito à utilização dos dados gerados pelo uso intenso da tecnologia da informação, notadamente internet e redes sociais, [1]. Um exemplo de solução que trata a informação como fator de competitividade é o *big data*, capaz de coletar dados de várias fontes, em formatos distintos, e construir análises de dados em uma escala sem precedentes, [1][2]. Assim, a importância de projetos de qualidade de dados (QD) tem crescido substancialmente nos últimos anos, pois dados de alta qualidade é a condição mandatória para a análise e a utilização do *big data*, garantindo, assim, o valor dos dados e sua efetiva contribuição para o negócio.

A base para se estabelecer um programa contínuo de qualidade de dados é identificar os níveis de qualidade presentes nos dados. Este processo de avaliação é realizado considerando as características de qualidade que os dados devem ter, representadas por meio de dimensões de QD. A literatura disponibiliza várias propostas para a definição das dimensões de QD, [3],[4],[5],[7],[8],[9],[10],[11],[12],[13],[14], [14], no entanto, não há consenso na definição da maior parte delas devido à natureza contextual da qualidade. Isto quer dizer que, dependendo do contexto de uso, os conceitos e a relevância das dimensões podem sofrer variações.

Em termos de arquitetura, há propostas de referência, como em [15] e a de grandes fornecedores, como IBM, Microsoft, Oracle e EMC/PIVOTAL,[16]. Para esta pesquisa, é necessário analisar como os componentes dessas referências suportam os processos de QD que tratam os desafios mencionados, para identificar as possíveis lacunas existentes, e, desta forma, propor uma arquitetura completa.

O objetivo principal desta pesquisa é propor e validar uma arquitetura de referência específica para qualidade de dados em ambiente analítico baseado em *big data*.

Como objetivos específicos deste trabalho podem ser citados:

- Identificação e análise dos problemas e desafios de qualidade de dados no ambiente de *big data* nos segmentos de saúde, varejo, financeiro, educacional, governamental, agronegócio e ambiental;
- A definição das dimensões de qualidade de dados relevantes para o ambiente analítico em *big data*. Por dimensão relevante entende-se comum aos ambientes pesquisados;
- Um framework para a seleção e definição das dimensões de qualidade de dados, adaptável a qualquer contexto de uso.

II. REVISÃO DA LITERATURA

O termo *big data* foi inicialmente definido segundo o conceito dos 3Vs (volume, velocidade, variedade), ou seja, um ambiente com grande volume de dados, com processamento muito rápido e que compreende uma variedade de diferentes tipos de dados e de ferramentas para processar, analisar e apresentar esses dados [1],[2],[17],[19],[20],[19].

- **Volume:** Diariamente, observa-se um volume cada vez maior de troca de e-mails, transações bancárias, interações em redes sociais, registro de chamadas e tráfego de dados em linhas telefônicas. Todos esses exemplos evidenciam a volumetria de dados presentes no mundo atualmente;
- **Velocidade:** a rapidez com a qual a informação é obtida, tratada e utilizada é uma vantagem competitiva das empresas. Para a tratativa de determinados problemas, a velocidade para a manipulação dos dados deve ser feita em tempo hábil, adequado à necessidade de uso;
- **Variedade:** inclui dados variados, estruturados, semiestruturados e não estruturados, de origens diversas.

Os 3Vs apresentados acima (volume, velocidade e variedade) representam as características técnicas do *big data*, evidenciando a magnitude e abrangência deste ambiente. Os demais Vs que estão sendo mencionados neste contexto relacionam-se aos dados em si, tais como a veracidade: refere-se à confiabilidade dos dados, e o valor: ter acesso a uma solução de *big data* traz bons resultados somente quando transforma seu uso em valor.

Percebe-se, então, que todas essas características podem representar um aumento da complexidade dos desafios de qualidade de dados, tais como, [2],[3],[4],[6],[8],[8],[13],[13],[20],[21],[21]:

- A diversidade de fontes de dados propicia a coleta de diferentes tipos de dados e estruturas de dados complexas, o que aumenta a dificuldade de integração de dados e a aplicação de regras de qualidade de dados, por exemplo.
- Aproximadamente 80% dos dados disponíveis em ambiente de *big data* são de natureza não estruturada. A maioria das abordagens atuais de tratamento da qualidade de dados não atua em dados desta natureza;
- Percebe-se uma dificuldade na tarefa de se determinar e conceituar quais dimensões da qualidade de dados são relevantes para este universo;

- Avaliar a qualidade dos dados de um grande volume de dados em um prazo razoável, adequado à necessidade de uso é um grande desafio;
- Os dados mudam muito rapidamente, e para que esta mudança seja devidamente processada, permitindo que o dado seja utilizado dentro de sua janela de oportunidade, aumenta-se significativamente as exigências em relação às tecnologias de processamento;
- Não há padrões unificados e aprovados de qualidade de dados.

Em relação às dimensões de qualidade de dados, há diversas propostas[3],[4],[5],[20],[7],[8]. [3] propõe um modelo para a avaliação da qualidade de dados em *big data*, porém esta proposta baseia-se nas dimensões aplicáveis à maioria dos ambientes de informação. [5]apresenta um estudo sobre as dimensões em *big data* e alguns autores apresentam as dimensões de QD incluindo conceitos novos em virtude da era dos dados, tais como, viralidade, mas sem um consenso da comunidade científica.

As arquiteturas relacionadas à *big data* propostas em [15]e[22] apresentam camadas e componentes específicos para QD. A arquitetura de referência do NIST, [15], distribui a qualidade de dados nos três componentes da arquitetura:

- Gerenciamento e armazenamento: *Cleaning* e transformação;
- *Big Data Analytics* e Interfaces de Aplicação: Governança, constituída pelas atividades de data profiling, qualidade de dados e a governança propriamente dita;
- *Big Data Infrastructure*: atividades de integração de dados.

A arquitetura de referência proposta pela IBM,[22], também inseri a qualidade de dados como um componente da camada vertical de Qualidade de Serviço. Mas ao contrário da proposta da arquitetura NIST, que distribui as atividades de qualidade de dados em todos os seus componentes, ela centraliza a QD em um único componente.

É necessário verificar se e como os desafios de QD já identificados e os que serão mapeados por meio da pesquisa de campo, são suportados por estas arquiteturas.

III. METODOLOGIA DE PESQUISA

A proposta deste estudo envolve, dentre outras atividades, uma pesquisa de campo para a identificação dos desafios reais de *big data*, a análise dos resultados obtidos nesta pesquisa com as propostas de dimensões existentes, a avaliação das arquiteturas atuais frente aos desafios identificados, a proposição de uma arquitetura de referência que tratará os gaps identificados nas análises e a aplicação prática desta proposta para a validação de sua eficácia A Figura 1 apresenta o método de pesquisa estruturado em quatro fases:

- Desafios de QD na era dos dados;
- Dimensões da qualidade de dados em *big data*;
- Avaliação das arquiteturas existentes;
- Proposta e aplicação da arquitetura proposta.

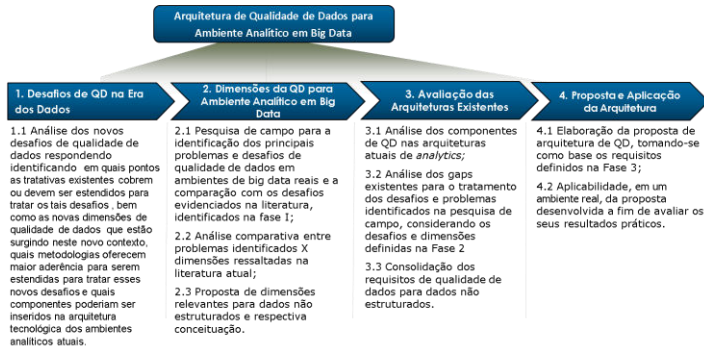


Fig. 1. Metodologia de Pesquisa Utilizada

IV. CRONOGRAMA DE PUBLICAÇÕES

As produções científicas desta pesquisa estão representadas na Figura 2. Consistem em 7 artigos científicos, além do texto completo da tese. Os artigos 1 e 2 já estão em fase de produção.

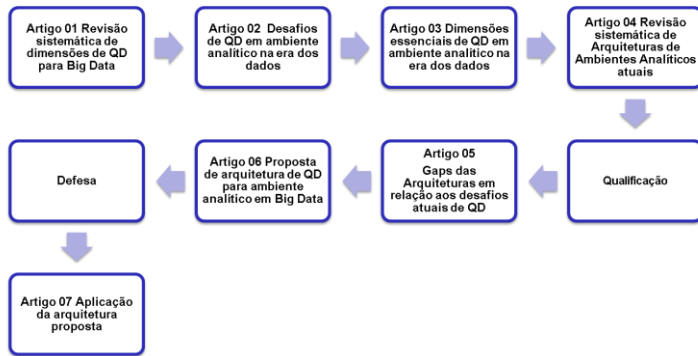


Fig. 2. Publicações Científicas da Pesquisa

V. RESULTADOS ESPERADOS

- Criação de uma arquitetura de referência para a qualidade de dados em ambiente de *big data*;
- Identificação das dimensões de qualidade de dados mais relevantes para o contexto de *big data* nos segmentos de saúde, varejo, financeiro, educacional, governamental, agronegócio e ambiental;
- Um framework para a seleção e definição das dimensões de qualidade de dados, adaptável a qualquer contexto de uso.

Todos os conceitos desenvolvidos nesta pesquisa serão validados por meio da aplicação prática em um ambiente real. Os critérios de avaliação desta aplicabilidade serão definidos posteriormente.

VI. RESULTADOS PARCIAIS

Foi realizado o mapeamento bibliográfico para a identificação dos desafios atuais de qualidade de dados em ambiente analítico na era dos dados. A revisão sistemática sobre as dimensões de qualidade de dados inerentes ao contexto de *big data* foi iniciada. Até o momento, os principais pontos identificados estão resumidos nos itens abaixo.

Em termos de caracterização do ambiente de *big data*, [1],[2],[17],[19],[20],[19],[21]: os estudos atuais estão

relacionando mais 5 Vs Visão (propósito), Visualização (apresentação adequada e efetiva), Variabilidade (dados cujo significado está em constante mudança), Validade (valores de dados estão dentro de intervalos aceitáveis para o uso), Volatilidade (tempo de retenção do dado no qual seu uso ainda é válido).

Em relação às dimensões, além daquelas já definidas e utilizadas em qualquer contexto, tais como acurácia, completude, acessibilidade, credibilidade dentre outras, estão surgindo novos conceitos devido à natureza dos dados e fontes diversas do cenário existente na era dos dados. Até o momento foram identificadas as seguintes novas dimensões, [5],[7],[11],[13],[14]: Viscosidade (resistência ao fluxo de dados devido à reputação da fonte de informação), Viralidade Textual (É a facilidade de leitura, de compreensão devido ao estilo de escrita), Consistência Textual (coesão e coerência. A coesão é a utilização de certos dispositivos linguísticos para unir o texto, já a coerência entre as ideias expostas), Acessibilidade Textual (a acessibilidade diz respeito ao nível de dificuldade das palavras utilizadas, palavras difíceis, específicas de um domínio, por exemplo), fidelidade (grau de correspondência aparente da imagem com o original), utilidade (grau de correspondência aparente da imagem com a referência interna do observador).

REFERENCES

- [1] ZUPPO, DANIELA; COSTA, LUCIANA SODRÉ; FERNANDES, SORAYA. **Big Data: Estudo do Ambiente, Desafios e Análise Estratégica para o Brasil**. TCC (Pós Graduação) - Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2013.
- [2] SASHA, BARNA; SRIVASTAVA, DIVESH. **Data Quality: The other Face of Big Data**. Publicado em Data Engineering (ICDE), 2014 IEEE 30th International Conference. Marco 2014.
- [3] CAI, LI; YANGYONG, ZHU. **The Challenges of Data Quality and Data Assessment in the Big Data Era**. Data Science Journal, 14: 2, pp. 1-10. 2015. Disponível em: <http://dx.doi.org/10.5334/dsj-2015-002>.
- [4] ABDULLAH, NORAINI; ISMAIL, SAIFUL ADLI; SOPHIAYATI, SITI; SA, SURIANI MOHD. **Data Quality in Big Data: A Review**. Int. J. Advance Soft Compu. Appl, Vol. 7, No. 3, November 2015. ISSN 2074-8523
- [5] TALEB I.; H. KASSABI, T. E. M.; SERHANI, A.; DSSOULI, R.; BOUHADDIOUI, C. **Big Data Quality: A Quality Dimensions Evaluation**. 2016 Intl IEEE Conferences on Ubiquitous Intelligence & Computing, Advanced and Trusted Computing, Scalable Computing and Communications, Cloud and Big Data Computing, Internet of People, and Smart World Congress. 2016. DOI 10.1109/UIC-ATC-ScalCom-CBDCom-IoP-SmartWorld.2016.145.
- [6] CABALLERO, ISMAEL; SERRANO MANUEL; BIBIANO, RIVAS; PIATTINI, MARIO. **A Data Quality in Use model for Big Data**. Future Generation Computer Systems. Contents lists available at ScienceDirect. Springer. 2015. <http://dx.doi.org/10.1016/j.future.2015.11.024>
- [7] IMMONEN, ANNE; PÄÄKKÖNEN PEKKA; OVASKA, EILA. **Evaluating the Quality of Social Media Data in Big Data Architecture**. IEEE Access. 2015.
- [8] TOIVONEN, MIRVA. **Big Data Quality Challenges in the Context of Business Analytics**. Dissertação de Mestrado. Universidade de Helsinkin. Departamento de Ciência da Computação. 2015.
- [9] ISO/IEC 25012:2008 2015. Software Engineering - Software Product Quality Requirements and Evaluation (SQuaRE) - **Data Quality Model**. ISO/IEC.

- [10] BATINI, CARLO; RULA, ANISA; SCANNAPIECO, MONICA; VISCUSI, GIANLUIGI. **From Data Quality to Big Data Quality**. JOURNAL OF DATABASE MANAGEMENT. JANUARY 2015. DOI: 10.4018/JDM.2015010103
- [11] BATINI, C.; SCANNAPIECO, M.. **Data and information quality. Dimensions, principles and techniques**. Springer, New York. 2016
- [12] GE, M; HELFERT, M. **A Review of Information Quality** - research-develop a reseach agenda. in: Proceeding of 12th International Conference on Information Quality. 2017.
- [13] JUDDOO, SURAJ. **Overview of data quality challenges in the context of Big Data**. IEEE. 2015.
- [14] SCHAAL, MARKUS; MUELLER, ROLAND M.; MACLEAN, RUTGER. **Information Quality Dimensions for the Social Web**. ACM. *MEDES'12* October 28-31, 2012.
- [15] **NIST Big Data Interoperability Framework: Volume 6, Security and Privacy**. NIST Big Data Public Working Group (NBD-PWG) Reference Architecture Subgroup *Information Technology Laboratory*. 2015. Publicação disponível em: <http://dx.doi.org/10.6028/NIST.SP.1500-5>
- [16] **NIST Big Data Interoperability Framework: Volume 5, Architectures White Paper Survey** NIST Big Data Public Working Group (NBD-PWG) Reference Architecture Subgroup. 2015. Publicação disponível em: <http://dx.doi.org/10.6028/NIST.SP.1500-5>
- [17] **NIST Big Data Interoperability Framework: Volume 1, Definitions**. NIST Big Data Public Working Group Definitions and Taxonomies Subgroup. 2015. Publicação disponível em: <http://dx.doi.org/10.6028/NIST.SP.1500-1>.
- [18] MADDEN, SAM. **From Data Bases to Big Data**. Publicado em IEEE Internet Computing (Volume: 16, Issue: 3, May-June 2012).
- [19] EMMANUEL, ISITOR; STANIER, DR CLARE. **Defining Big Data**. BDAW'16, ACM. 2016.
- [20] LUKOIANOVA, T.; RUBIN, V. **Veracity Roadmap: Is Big Data Objective, Truthful and Credible?**. Advances In Classification Research Online, 24(1). doi:10.7152/acro.v24i1.14671. 2014.
- [21] ZHANG, DU. **Inconsistencies in Big Data**. Proc. 12th IEEE Int. Conf. on Cognitive Informatics & Cognitive Computing (ICCI*CC'13).D.F. Hsu, Y. Wang, A.R. Rao, D. Zhang, W. Kinsner, W. Pedrycz, R.C. Berwick & L.A. Zadeh (Eds.), IEEE. 2013. 978-1-4799-0783-0/13/\$31.00.
- [22] MYSORE, DIVAKAR; KHUPAT, SHRIKANT; JAIN, SHWETA. **Entendendo as camadas de arquitetura de uma solução de big data. Série Arquitetura e Padrões de Big Data, Parte 3**. IBM DeveloperWorks. Publicado em 28/02/2014. Disponível em <https://www.ibm.com/developerworks/br/library/bd-archpatterns3/index.html>. Acesso em 23/10/2017.

Modelo de Referência para a Fazenda Digital: Aplicação de Tecnologia de Virtualização em Processos de Agricultura

MOSTAÇO, G. M.*; CUGNASCA, C. E.*

*Laboratório de Automação Agrícola [LAA] – Escola Politécnica da Universidade de São Paulo
{gmostaco, carlos.cugnasca}@usp.br

Resumo — Muitas tecnologias e sistemas foram desenvolvidos de forma isolada em prol da Agricultura de Precisão nos últimos anos, porém ainda existe grande dificuldade na sua integração no agronegócio. O desenvolvimento cada vez mais acelerado de dispositivos e sistemas para Internet das Coisas possibilita a proposição de ferramentas avançadas de gestão e automação no campo. Caminha-se, portanto, no sentido da Agricultura Inteligente, que inclui monitoramento, planejamento e controle inteligentes de processos agrícolas. A virtualização de objetos possibilita a atuação remota, além de capacidades avançadas para sistemas de controle integrados. Como mecanismo para a virtualização dos módulos de atividades da futura fazenda digital surge a ideia de *Digital Twin* (Gêmeo Digital), na qual um sistema físico é modelado em linguagem computacional, criando-se uma réplica digital desse sistema, que será objeto de constantes análises e simulações para geração de conhecimento e tomada de decisões. Partindo-se de estruturas instaladas em campo, como redes de sensores sem fio, aplicação de identificação por radiofrequência para identificação de equipamentos e etapas dos processos, utilização de tecnologias como *Global Positioning System* e Sistema de Informação Geográfica, e empregando mecanismos avançados de análise de dados (ou *analytics*) em uma estrutura de objetos e sistemas virtualizados, pretende-se caminhar no sentido da obtenção de tecnologia relevante em prol da agricultura inteligente.

Palavras-chave — Agricultura de Precisão; Gerenciamento Agrícola Assistido; Internet das Coisas; Virtualização; Gêmeo Digital.

Classificação — Doutorado.

Categoria — Iniciante.

I. INTRODUÇÃO

A Agricultura Inteligente é um estilo de gestão que inclui monitoramento, planejamento e controle inteligentes de processos agrícolas. Não obstante à modernização dos processos industriais, decorrentes do desenvolvimento de tecnologias que possibilitaram a sua gestão informatizada e inteligente, a agricultura deve seguir em uma mesma direção, porém, com a criação de ferramentas próprias e adaptadas à realidade do campo, das cadeias de suprimentos e distribuição estando, assim, aptas para o agronegócio como um todo [1].

Dentre vários desafios vividos pela Agricultura de Precisão (AP) há a dificuldade na integração entre as tecnologias propostas para solução de problemas isolados do agronegócio. Neste sentido, deve-se promover a integração do gerenciamento

da fazenda com as máquinas e ativos, tendo-os como elementos atuadores e de insumo, respectivamente, trabalhando o panorama geral como se faz no meio industrial, no sentido do controle e da automação de processos.

Assim sendo, a Internet das Coisas (do inglês, *Internet of Things* - IoT) tem papel fundamental por atuar como agente habilitador das comunicações, análises e respostas em tempo real [2]. Ela se utiliza de elementos como redes de sensores sem fio (RSSF), tecnologia de identificação por radiofrequência (*Radio-Frequency IDentification* - RFID), computação e armazenamento de dados em nuvem, além de elementos de Inteligência Artificial (IA), tais como *softwares Analytics* e ferramentas como *Data Mining* e *Machine Learning*. Logo, as possibilidades de aplicação para soluções de problemas e otimização de processos na agricultura são inúmeras, tanto em áreas isoladas, quanto na integração de muitas delas [3][4].

Conjuntamente à emergência da IoT, o controle de sistemas e processos pode se basear em objetos virtuais como alternativa à observação direta de objetos físicos, possibilitando o controle e coordenação remotos, e realizados por diferentes participantes. Ademais, objetos virtuais podem ser enriquecidos com informações que vão além da observação humana, dando-lhes capacidades avançadas para sistemas de controle, i.e., rastreabilidade, monitoramento de qualidade e planejamento contínuo das atividades. Como mecanismo para a virtualização dos módulos de atividades da fazenda digital pode-se utilizar a ideia de *Digital Twin* (Gêmeo Digital), a qual consiste na modelagem do sistema físico em linguagem computacional, criando uma réplica digital do objeto ou sistema, em conjunto com a coleta constante de dados de sensores e a aplicação de técnicas avançadas de *analytics* e IA com autoaprendizado, de forma a obter respostas únicas em relação a eficiência e ganhos operacionais.

Finalmente, deve-se trabalhar no sentido de oferecer tecnologias atuais e conhecimentos especializados, auxiliando o agricultor a se conectar a toda a cadeia de suprimentos da agricultura. Possibilitar ainda, pela geração e organização de dados sistemática, a adoção de sistemas de *Enterprise Resource Planning* (ERP) e *Business Intelligence* (BI), ganhando percepções importantes sobre estoque, produção e distribuição de seus recursos, gerando com isso ganhos em planejamento de produção, produtividade, quantidade de produção, redução de perdas, conservação de água e por fim, um aumento do lucro para o agricultor [1]. É possível ainda o emprego de dados

gerados pelo poder público para o desenvolvimento de políticas agrícolas.

Pretende-se com a presente pesquisa, possibilitar a interação entre as diferentes atividades realizadas em um ambiente de produção agrícola, por meio da utilização de ferramentas computacionais. Partindo-se de estruturas instaladas em campo como RSSF, aplicação de RFID para identificação de equipamentos e etapas dos processos, utilização de tecnologias *Global Positioning System* (GPS) e Sistema de Informação Geográfica (SIG), e empregando mecanismos avançados de análise de dados (ou *analytics*) em uma estrutura de objetos e sistemas virtualizados (*Digital Twins*), pretende-se obter tecnologia relevante e inovadora para a Agricultura Inteligente.

II. OBJETIVOS ESPECÍFICOS

Os objetivos específicos da presente pesquisa são:

- Proposição de modelo de referência para implementação da fazenda digital com base em IoT;
- Criação de metodologia para virtualização dos módulos de atividade da fazenda em *Digital Twin* (apenas um módulo será determinado para estudo);
- Comparação econômica entre máquinas menores e de grande escala.

III. TECNOLOGIAS DE AGRICULTURA DE PRECISÃO DESENVOLVIDAS PARA DIFERENTES SETORES DA FAZENDA

A evolução das técnicas de AP passou por um ponto-chave, que foi a finalidade de se mapear e manejar a variabilidade de atributos de fertilidade do solo, na qual ao invés de se considerar determinadas áreas agrícolas uniformes, passa-se a dividi-las em pequenos talhões ou zonas de manejo, com características próprias e determinantes, as quais passam a serem analisadas individualmente quanto ao tipo e qualidade de nutriente a receber. Em um segundo momento, com o desenvolvimento de diversas tecnologias para suprir diferentes necessidades computacionais aplicadas à agricultura, que em sua maioria eram instaladas em máquinas e implementos agrícolas, surge a necessidade de padronização para comunicação entre e através estes dispositivos [5][6].

Em seguida, pode-se ressaltar a criação de tecnologias de aplicação ligadas tanto a pontos específicos das atividades agrícolas quanto as que se aplicam em diferentes cenários do agronegócio, dentre elas podem-se citar algumas como: a robótica, RSSF, utilização de GPS e GIS na criação de mapas e piloto automático, sistemas de controle e otimização de ambientes para animais e estufas [7][8], irrigação [9], pulverização, entre outros.

Por fim, podem-se citar alguns trabalhos que empregaram visão de futuro e técnicas computacionais complexas para solução de problemas atuais, como o uso de análise de imagens [10], envolvendo *Big Data*, *Machine Learning* e *Analytics* [11][12] e a comunicação por meios óticos sem fio VLC [13].

IV. UM ESFORÇO NO SENTIDO DA INTEGRAÇÃO: DIGITAL FARMING

Diante dos esforços e avanços obtidos nas mais variadas frentes de pesquisa no meio agrícola, percebe-se uma lacuna no sentido da integração das diferentes atividades comumente realizadas em um ambiente de produção agrícola. Faz-se necessária a utilização de ferramentas computacionais para o desenvolvimento de soluções, nas quais seja possível ter como entradas o conhecimento gerado pela sociedade científica e as situações reais de campo – traduzidas na forma de sinais por sensores – passando por mecanismos avançados de análise de dados (ou *analytics*), com o intuito de gerar resultados, decisões ou ações de relevância para as atividades agrícolas [14][15].

A ideia de inúmeros nós sensores formando uma rede, um dos preceitos da *Smart Dust*, vem ganhando solidez à medida que se popularizam os dispositivos inteligentes [16], demandando estruturas para agregar diferentes fontes de dados, além de técnicas para extração de informação relevante e inteligível desta massa de dados. Esta tendência deve ser seguida e aplicada em diversas áreas da agricultura, de forma a tornar os sistemas cada vez mais auto ajustáveis e inteligentes na coleta e análise de dados do campo.

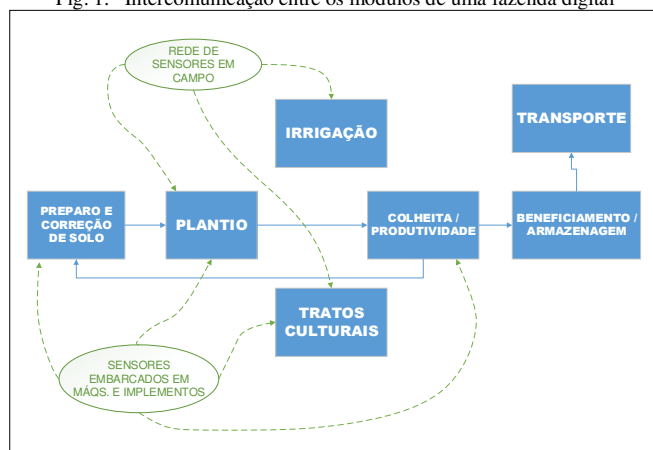
Porém, não se deve esquecer das dificuldades impostas tanto pelo ambiente, quanto pela falta de extensão científica e de infraestrutura no campo, as quais podem gerar diversas dificuldades para a implementação de tecnologias relacionadas ao paradigma da IoT, como: intempéries às quais os equipamentos ficam sujeitos, escassez de energia, dificuldade de comunicação, falta de incentivos e altos custos associados aos equipamentos de tecnologia, que por sua vez, trazem como necessidade para seu funcionamento a implementação de infraestrutura de dados e energética.

Neste sentido, o panorama geral, no qual a fazenda inteira estaria sendo monitorada, simulada e cuidada por sistemas computacionais, está longe de ser obtido, pelo menos de forma ampla e completa, não deixando, porém, de ser necessária sua discussão e a proposição de modelos de referência para sua implementação, o que se aponta como um dos objetivos buscados com este trabalho.

Como base para a discussão na presente pesquisa, propõe-se o aprofundamento nos estudos relacionados com modelos de intercomunicação e fluxo de informação entre os blocos de atividades presentes dentro da porteira de uma fazenda (Fig. 1). Para tal, apresentou-se um modelo mais generalista, que poderia ser utilizado, por exemplo, para representação de uma unidade produtora de grãos. Porém deve-se chamar a atenção para o fato de que as propriedades e as culturas possuem detalhes exclusivos, e que para a implementação devem ser tratados levando em conta suas especificidades.

Como exemplo de uma possível atuação deste modelo, têm-se a utilização de mecanismos de análise de dados e tomada de decisão integrados com veículos autônomos para a detecção de necessidades operacionais e realização automática de operações em campo.

Fig. 1. Intercomunicação entre os módulos de uma fazenda digital



Fonte: autor

Outro exemplo de aplicação reside nas granjas para criação intensiva de animais, nas quais o desenvolvimento de tipologia específica de módulos se faz necessária, porém, de forma geral, alguns dos principais problemas encontram-se no controle térmico, demais condições ambientais e na individualização de animais para acompanhamento de sua alimentação e desenvolvimento, sempre respeitando e aplicando conhecimentos de boas práticas de bem-estar animal.

As possibilidades com a integração das tecnologias geradas pelas diferentes áreas de conhecimento da agricultura são inúmeras, cabendo aos pesquisadores trabalharem tanto no sentido do desenvolvimento e aprimoramento de técnicas em suas áreas isoladas, quanto na integração entre elas.

V. DIGITAL TWIN COMO TECNOLOGIA HABILITADORA

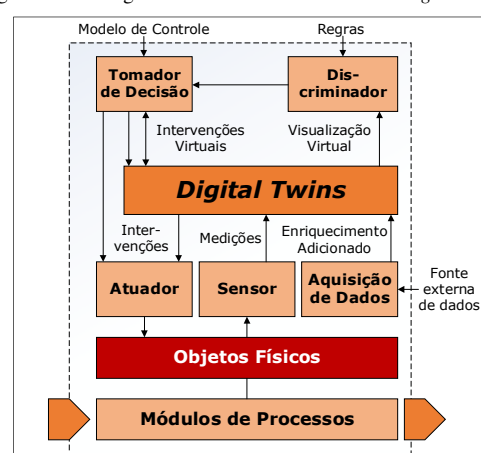
Até mesmo trabalhos que visam a implementação de redes de automação residencial e o desenvolvimento de tecnologias para casas e cidades inteligentes apontam a necessidade de uma inteligência artificial no centro do comando de forma a extrair os mais altos níveis de eficiência e sustentabilidade dos sistemas [17][18].

Neste sentido, e conjuntamente à emergência da IoT, o controle de sistemas e processos pode, cada vez mais, basear-se em objetos virtuais como alternativa à observação direta de objetos físicos. O gerenciamento virtual não mais requer proximidade física, possibilitando assim, que o controle e coordenação sejam realizados remotamente e por diferentes participantes. A virtualização de objetos permite a dissociação de atividades de controle da necessidade de manipulação e observação de produtos e recursos físicos. Ademais, objetos virtuais podem ser enriquecidos com informações que vão além da observação humana. Isto possibilitará capacidades avançadas para sistemas de controle, i.e., relacionadas à rastreabilidade, monitoramento de qualidade e planejamento contínuo das atividades [19].

Assim sendo, os sistemas de informação devem sustentar análise e comunicação inteligentes dos dados trocados. Tais funcionalidades permitem alertar em tempo hábil interrupções ou desvios inesperados em variáveis como temperatura,

umidade, tensão de bateria, etc., além de previsão avançada de consequências dada uma determinada situação. Suas tecnologias habilitadoras incluem *Business Intelligence*, *Business Process Management*, Ferramentas de Suporte à Decisão, Configuradores, *Event Management Systems*, *Lógica Fuzzy* e *Data Mining* [20].

Como mecanismo para a virtualização dos módulos de atividades da fazenda digital, pode-se utilizar a ideia de *Digital Twin*, o que consiste em um primeiro passo na modelagem do sistema físico em linguagem computacional, criando uma réplica digital do objeto ou sistema em estudo, em conjunto com uma coleta constante de dados de sensores e a aplicação de técnicas avançadas de *analytics* e IA com auto aprendizado, de forma a obter respostas únicas em relação a eficiência e operação em determinado módulo (Fig. 2).

Fig. 2. Modelo genérico de controle baseado em *Digital Twins*

Fonte: adaptado de [19]

VI. METODOLOGIA PROPOSTA

A metodologia proposta considera as seguintes etapas:

- A. *Proposição de modelo de referência para implementação da fazenda digital com base em Internet das Coisas*
 - Levantamento das necessidades de uma fazenda inerentes à cultura que se irá trabalhar, ou um conjunto delas (a definir);
 - Definição dos módulos (ou blocos de atividades) de forma a otimizar o fluxo de informações, possibilitando o monitoramento contínuo e que apresentem boa representação da situação real;
 - Levantamento das atividades envolvidas em cada módulo; Pesquisa acerca de métodos de virtualização (*Digital Twin*).
- B. *Criação de metodologia para virtualização dos módulos de atividade da fazenda em Digital Twins*
 - Levantamento das necessidades agrônômicas da cultura (a definir);
 - Criação do modelo para a virtualização do módulo plantio, envolvendo as variáveis necessárias;

- Aplicação do modelo em situação prática de campo, utilizando as tecnologias de RFID, RSSF e GPS, sob a ótica da IoT;
- Análise crítica das dificuldades e dos êxitos obtidos na criação e aplicação da metodologia, bem como das sugestões para continuidade do trabalho de forma a adaptar a metodologia para aplicação nas diferentes frentes da fazenda;
- Provimento das bases para a adaptação da metodologia para aplicação nas diferentes frentes da fazenda.

C. Comparação econômica entre máquinas menores e de grande escala

- Levantamento de custos de aquisição, operação, manutenção e depreciação de tratores, implementos e equipamentos computacionais envolvidos nos dois cenários propostos (maior e menor escala);
- Análise comparativa dos resultados obtidos.

VII. RESULTADOS ESPERADOS

Os principais resultados esperados são:

- Obter um modelo de referência para integração das diferentes atividades presentes em um ambiente de produção agrícola, pela intercomunicação e fluxo de informação entre as mesmas, utilizando-se de sensores, atuadores, ferramentas computacionais e mecanismos avançados de análise de dados de forma a gerar resultados, decisões ou ações de relevância para as atividades agrícolas.
- Desenvolver metodologia viável para virtualização de módulos de atividades da fazenda em *Digital Twins*, criando uma réplica digital do sistema estudado em conjunto à coleta constante de dados de sensores e aplicação de técnicas avançadas de *analytics* e IA.
- Comparar as questões envolvidas no uso de máquinas menores frente às de grande escala em termos de potência demandada, compactação do solo, eficiência durante operações, custos de aquisição e manutenção, e facilidade e versatilidade quanto ao planejamento operacional.

VIII. RECURSOS A SEREM UTILIZADOS

Os recursos a serem utilizados envolvem *softwares* relacionados ao processo de virtualização (a serem definidos durante esta etapa da pesquisa), *softwares* de simulação do modelo proposto como SIMUL8, Rifi, LINGO, Arena e MatLab, além do uso do MS Excel® para análise dos resultados obtidos. Serão utilizados ainda equipamentos necessários para o controle e monitoramento de um conjunto trator-implemento em campo de forma a aplicar e validar o modelo de virtualização proposto.

AGRADECIMENTOS

Ao CNPq pela concessão de bolsa de Doutorado ao autor principal.

REFERÊNCIAS

- [1] VERDOUW, C.N.; ROBBEMOND, R.M.; WOLFERT, J. ERP in agriculture: Lessons learned from the Dutch horticulture. *Computers and Electronics in Agriculture*, v. 114, p. 125-133, 2015a.
- [2] ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: A survey. *Computer networks*, v. 54, n. 15, p. 2787-2805, 2010.
- [3] ABBASI, A.Z.; ISLAM, N.; SHAIKH, Z.A. A review of wireless sensors and networks' applications in agriculture. *Computer Standards & Interfaces*, v. 36, n. 2, p. 263-270, 2014.
- [4] GUBBI, J. *et al.* Internet of Things (IoT): A vision, architectural elements, and future directions. *Future generation computer systems*, v. 29, n. 7, p. 1645-1660, 2013.
- [5] SARAIVA, A.M.; CUGNASCA, C.E. Redes de comunicação serial em máquinas agrícolas: uma revisão. *Revista Brasileira de Agroinformática*, v. 8, n. 1, p. 17-35, 2006.
- [6] SUPREM, A.; MAHALIK, N.; KIM, K. A review on application of technology systems, standards and interfaces for agriculture and food sector. *Computer Standards & Interfaces*, v. 35, n. 4, p. 355-364, 2013.
- [7] MOSTAÇO, G.M. *et al.* Determination of piglets' rectal temperature and respiratory rate through skin surface temperature under climatic chamber conditions. *Engenharia Agrícola*, v. 35, n. 6, p. 979-989, 2015.
- [8] CONDOTTA, I.C.F.S.; MIRANDA, K.O.S.; MOSTAÇO, G.M. Aplicação da lógica fuzzy na correlação entre temperatura superficial de suínos em fase de creche e conforto térmico para região de Piracicaba. *Boletim de Indústria Animal*, v. 71, p. 1-1, 2015.
- [9] COATES, R. W.; DELWICHE, M.J. Wireless mesh network for irrigation control and sensing. *Transactions of the ASABE*, v. 52, n. 3, p. 971-981, 2009.
- [10] SILVA, L.O.L.A.; KOGA, M.L.; CUGNASCA, C.E.; COSTA, A.H.R. Comparative assessment of feature selection and classification techniques for visual inspection of pot plant seedlings. *Computers and electronics in agriculture*, v. 97, p. 47-55, 2013.
- [11] WOLFERT, S.; GE, L.; VERDOUW, C.; BOGAARDT, M.J. Big Data in Smart Farming—A review. *Agricultural Systems*, v. 153, p. 69-80, 2017.
- [12] VERDOUW, C.N. *et al.* Virtualization of food supply chains with the internet of things. *Journal of Food Engineering*, v. 176, p. 128-136, 2016.
- [13] MARE, R.M.; MARTE, C.L.; CUGNASCA, C.E. Visible Light Communication Applied to Intelligent Transport Systems: an Overview. *IEEE Latin America Transactions*, v. 14, n. 7, p. 3199-3207, 2016.
- [14] MURAKAMI, E. *et al.* An infrastructure for the development of distributed service-oriented information systems for precision agriculture. *Computers and Electronics in agriculture*, v. 58, n. 1, p. 37-48, 2007.
- [15] CAMILLI, A. *et al.* From wireless sensors to field mapping: Anatomy of an application for precision agriculture. *Computers and Electronics in Agriculture*, v. 58, n. 1, p. 25-36, 2007.
- [16] FARIA, M.L.L.; SILVA, R.F.; CUGNASCA, C.E. A Framework for Implementing the Concept of Citizen as a Sensor. In: *Mobile Ad Hoc and Sensor Systems (MASS), 2016 IEEE 13th International Conference on*. IEEE, 2016. p. 370-372.
- [17] CAMPOS, L.B. *et al.* Towards an IoT-based system for Smart City. In: *Consumer Electronics (ISCE), 2016 IEEE International Symposium on*. IEEE, 2016. p. 129-130.
- [18] TOSCHI, G.M.; CAMPOS, L.B.; CUGNASCA, C.E. Home automation networks: A survey. *Computer Standards & Interfaces*, v. 50, p. 42-54, 2017.
- [19] VERDOUW, C.N. *et al.* A control model for object virtualization in supply chain management. *Computers in Industry*, v. 68, p. 116-131, 2015b.
- [20] VERDOUW, C.N.; BEULENS, A.J.M.; VAN DER VORST, J.G.A.J. Virtualisation of floricultural supply chains: A review from an Internet of Things perspective. *Computers and Electronics in Agriculture*, v. 99, p. 160-175, 2013.

Model of Food Conservation Based on Adaptive Control Systems

Modelo de Conservação de Alimentos Baseado em Controle Adaptativo de Sistemas

KAWANO, B. R. *; CUGNASCA, C. E. *

*Laboratório de Automação Agrícola (LAA) – Departamento de Engenharia de Computação e Sistemas Digitais – Escola Politécnica da Universidade de São Paulo

bruno.kawano@usp.br; carlos.cugnasca@poli.usp.br

Abstract—Supply chains for agricultural products are essential for the development of the Brazilian economy. Among the main products exported by Brazil are perishable agricultural products, mainly fruits. The traceability of agricultural products is a requirement of consumers in developed countries and in relation to the collection, storage, transport and supply of information related to products and processes to which they have been subjected. In current fruit storage systems there are many food losses due to faulty systems controlling the conditions as well as the large amount of disturbances to the system. In this way, it was intended, through this article, to model an Adaptive Control system using the Multiple Inputs, Multiple Output (MIMO) technique to promote a control of the variables studied (temperature, humidity and concentration of oxygen, carbon dioxide and ethylene) in a storage chamber. The preliminary results allow us to conclude that the adaptive systems control applied to fruit conservation is effective and there is the potential to reduce energy consumption by the system, as well as the maintenance of fruit quality.

Keywords— Adaptive Control; food preservation; optimal control; food transport.

Category—Doctorate degree

Classification: In conclusion.

*Resumo—Cadeias de suprimentos de produtos agrícolas são essenciais para o desenvolvimento da economia brasileira. Entre os principais produtos exportados pelo Brasil são produtos agrícolas perecíveis, principalmente as frutas. A rastreabilidade dos produtos agrícolas é uma exigência dos consumidores nos países desenvolvidos e em relação à colheita, armazenamento, transporte e fornecimento de informações relacionadas a produtos e processos a que foram submetidos. Nos sistemas atuais de armazenamento de frutas há muitas perdas de alimentos por sistemas falhos de controle as condições bem como a grande quantidade de perturbações ao sistema. Dessa forma, pretendeu-se, por meio deste artigo, modelar um sistema de Controle Adaptativo utilizando a técnica de *Multiple Inputs, Multiple Outputs* (MIMO) para promover um controle das variáveis estudadas (temperatura, umidade e concentração de gases oxigênio, gás carbônico e etileno) em uma câmara de armazenamento. Os resultados preliminares, permitem concluir que o controle adaptativo de sistemas aplicado à conservação de frutas, é efetivo e há o potencial de redução do consumo de energia pelo sistema, bem como a manutenção da qualidade da fruta.*

Palavras-chave— Controle Adaptativo; conservação de alimentos; controle ótimo; transporte de alimentos.

Classificação—Doutorado

Categoria—Em conclusão

I. INTRODUÇÃO

Um terço dos alimentos produzidos no mundo é perdido nas diversas etapas das cadeias de suprimentos. Assim, o desenvolvimento e a aplicação de tecnologias na etapa de pós-colheita são fundamentais para que este cenário seja mitigado [1]. Por exemplo, fatores que influenciam fortemente nestas perdas são a carência de investimentos em infraestrutura e o uso de tecnologias e processos de pós-colheita inadequados. A modificação da atmosfera do ambiente onde o alimento se encontra pode ser feita por atmosfera controlada. Este método consiste no controle dos gases onde o fruto está, como por exemplo: níveis de gás carbônico (CO₂) e de oxigênio (O₂), a fim de se reduzir o metabolismo dos microrganismos. Este método é utilizado no caso da maçã [2].

As tecnologias atuais existentes para conservação em frutas, objeto desta pesquisa, são sistemas de câmaras frias que não possuem, em sua maioria, a capacidade de controle dinâmico otimizado levando em consideração a interação entre as variáveis como Temperatura, Umidade, concentração de gases O₂, CO₂ e etileno [2]. Os atuais sistemas levam em consideração somente as variáveis individualizadas e seus efeitos nos atributos de qualidade como, por exemplo, perda de massa de frutas durante o armazenamento refrigerado [3]. Dessa forma, além de comprometer a qualidade das frutas, há um gasto energético com a refrigeração dessas câmaras acima do ideal.

Isso ocorre, devido ao fato de não haver um controle otimizado e dinâmico, ou seja, que leve em consideração que a composição ótima da atmosfera de gases para armazenamento é variável com o passar do tempo, pois as frutas continuam a emitir gases e perder água neste processo [4]. Neste contexto, buscou-se inserir neste trabalho, elementos de Controle Adaptativo de Sistemas [5]. Há diversos tipos de controladores,

como o controlador proporcional tipo P, controladores proporcionais integrais PI, controladores que trabalham em regimes transitório e permanente PID, controladores que utilizam a teoria de *Fuzzy*, além de outros controladores mais limitados como o do tipo liga e desliga.

Por meio do Controle Adaptativo, o sistema tem a capacidade de reagir a mudanças necessárias para o seu devido funcionamento, segundo variáveis de interesse. Neste trabalho as condições ambientais (variáveis) de uma câmara fria destinada à conservação de alimentos que foram consideradas são: temperatura do ar; umidade relativa; teor de gás carbônico; teor de gás oxigênio; teor de gás etileno (gás indicativo da maturação) e carga térmica inicial dos alimentos.

Indo ao encontro da interação dessas variáveis, apresenta-se aqui a proposta de um modelo de um sistema de conservação de alimentos, possuindo como Controle de Sistemas de Múltiplas Entradas e Múltiplas Saídas (MIMO). Dessa forma, é possível obter a rastreabilidade desse processo, permitindo definir estratégias de operação dos sistemas de refrigeração adaptáveis ao contexto, isto é, a cada tipo de produto e condições ambientais (internas e externas) [6].

II. RASTREABILIDADE E SEGURANÇA ALIMENTAR DOS ALIMENTOS

O tema deste trabalho está envolvido no contexto da rastreabilidade e segurança alimentos dos alimentos. A rastreabilidade pode ser definida como o acompanhamento e monitoramento do produto ao longo de todos os elos da cadeia, permitindo a identificação de pontos críticos de controle de qualidade. A definição de rastreabilidade [7] é a habilidade de rastrear o histórico, o processamento e os locais por onde um produto passou por meio de identificações gravadas em um sistema.

A aplicação do conceito de rastreabilidade possibilita um controle de todas as etapas de uma cadeia de suprimentos, fornecendo insumos para uma melhor análise e gestão de riscos da cadeia como um todo. A tecnologia de informação é essencial para que os objetivos da rastreabilidade sejam devidamente cumpridos, permitindo uma simplificação na operacionalização das etapas de coleta, transmissão, armazenamento e acesso às informações relacionadas aos produtos e processos.

III. SISTEMAS DE CONTROLE APLICADO À CONSERVAÇÃO DE ALIMENTOS

Nas últimas décadas, muitas pesquisas científicas denominadas de *plantwide control* tem buscado padronizar o desenvolvimento de sistemas de controle, em que segundo [6] há 5 principais estratégias de um projeto de controle:

a) Caracterização do Problema de controle; b) A modelagem matemática do processo; c) A análise das respostas

dinâmicas do sistema através do modelo matemático; d) Projeto da estrutura de controle; e) Sintonia do controlador.

Sistemas de controle automáticos têm potencial de serem aplicados à conservação de alimentos em câmaras frias [8], a fim de solucionar problemas complexos que dizem respeito à interação entre as variáveis de controle da atmosfera controlada e seus efeitos fisiológicos nos frutos armazenados [9].

Na Figura 1, há um esquema genérico de um sistema de controle automático industrial e seus componentes.




Figura 1: Diagrama de blocos de um sistema de controle automático industrial. Fonte: Adaptado de [5].

IV. MATERIAIS E MÉTODOS

Este trabalho encontra-se em fase de simulação do modelo de controle adaptativo. A simulação do sistema de controle foi realizada no *software* MATLAB[®] onde foram inseridas as regras das funções de transferência, tais como as que definem limites superiores e inferiores para as variáveis para o produto maçã. Ao final do projeto de doutorado, serão compilados os resultados das simulações de controle de todas as variáveis (neste trabalho obteve-se somente os resultados da simulação para a temperatura) e verificação do potencial de economia de energia por meio deste modelo, no contexto da eficiência energética.

Os dados escolhidos para a simulação foram obtidos da, devido a uma maior disponibilidade de dados de armazenamento para este produto no Brasil. Os dados de entrada do sistema de controle simulado neste trabalho foram dados reais de medição de temperatura em uma câmara fria de armazenamento de maçãs, de uma empresa no município de Vacaria-RS. Os dados obtidos e utilizados neste trabalho possuem o perfil de tempo de armazenamento de 30 dias e com perturbações, ou seja, sujeito a 3 aberturas e fechamento da câmara para a introdução e retirada de frutas.

Estas perturbações ao modelo de controle, são relevantes pois são um caminho para se otimizar o controle da atmosfera de gases e de temperatura e umidade de acordo com a previsão de perturbações. Um outro exemplo de perturbação ao sistema é a adição de paletes de maçãs com carga térmica superior à temperatura ideal do sistema, ocasionando então, uma nova característica térmica no sistema por um tempo até que ele volte a se estabilizar novamente conforme se verifica no

trabalho [10]. A Figura 2 a seguir mostra o diagrama da metodologia adotada.

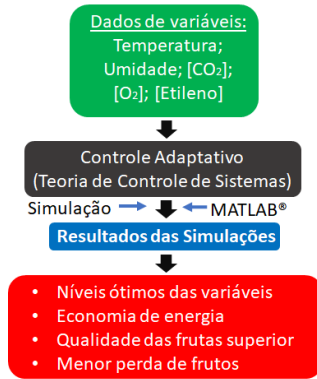


Figura 2: Diagrama da metodologia

V. RESULTADOS PRÉVIOS E ETAPAS FUTURAS

No caso teste trabalho, há múltiplas entradas no sistema como os fluxos de gases e a regulagem da temperatura e umidade e múltiplas saídas, que são os valores das concentrações de gases na câmara e os valores de temperatura e umidade. Assim, as técnicas adotadas serão as chamadas MIMO (*Multiple Input, Multiple Output*) conforme verificou-se também no trabalho [11]. Trata-se de uma metodologia adaptada, do SISO (*Single Input, Single Output*) para controladores que utilizam os princípios de controle adaptativo de sistemas PID (Controle Proporcional Integral Derivativo) [12]. Dessa forma, neste trabalho foi utilizado o sistema de controle do tipo MIMO aliado a aspectos teóricos do controlador PID, cujo algoritmo que representa a função é:

$$u(t) = K_p e(t) + K_i \int_0^t e(\tau) d(\tau) + K_d \frac{de(t)}{dt} \quad (1)$$

Onde:

K_p = Ganho proporcional

K_i = Ganho integral

K_d = Ganho derivativo

e = erro

t = tempo

τ = Tempo de integração

Aplicando a transformada de Laplace:

$$L(s) = K_p + \frac{K_i}{s} + K_d s \quad (2)$$

Onde:

s = Frequência complexa

De forma geral, a aplicação das técnicas de controle sobre um processo, visa à normalização de uma variável ou conjunto de variáveis em menor tempo, ou com menor custo. Para isso, podem ser configurados os valores de K_p , K_i e K_d a fim de se criar cenários com as saídas desejadas. Neste trabalho, são apresentados somente os resultados do controle da variável (T) temperatura, os das outras variáveis estão sendo compilados

e ajustados para se obter a estimativa da redução da energia utilizada. Os dados de entrada foram dados reais de medição de temperatura em uma câmara fria de armazenamento de maçãs, cuja temperatura ideal de armazenamento é de 1,0°C.

Na Figura 3, tem-se o incremento do valor de K_p , no sentido de iniciar a melhoria da resposta de controle da temperatura. Conforme o processo de controle vai se efetivando, o controle da temperatura vai se aproximando do valor ótimo referenciado e normalizado, neste caso do modelo é o valor = 1,00. O valor real de ideal de armazenamento de maçãs, é de 5 graus Celsius.




Figura 3: Incremento do K_p

Em seguida, sobre o mesmo resultado ótimo obtido na simulação anterior, obtém-se, por meio do incremento do K_d , que tende a se estabilizar, a Figura 4 abaixo.




Figura 4: Incremento do K_d

Após o incremento do K_d , realizou-se o incremento do valor K_i , que na simulação anterior obteve *score* de 0,96, na última simulação para os valores de K_i , obteve-se o *score* de $K_i = 0,97$. Em relação ao *score* de 0,5 da *Base line*, atingiu-se então o valor otimizado para o controle da temperatura, obtendo-se a saída da Figura 5.




Figura 5: Incremento do K_i (valor máximo de desempenho na simulação)

Os ganhos são em relação a uma menor variação das saídas dos sistemas (T, UR%, [CO₂], [O₂] e [Etileno]). Dessa forma, as frutas apresentarão um melhor desempenho em termos dos valores de atributos de qualidade conforme verificam [10]. Neste trabalho, não foi realizada a análise de qualidade das frutas, sendo o escopo deste artigo a simulação do sistema de controle e obtenção das saídas otimizadas.

A Figura 6, a seguir, mostra um exemplo de controle da temperatura, pelo modelo adotado, em que pode-se verificar a curva da dados reais (cor vermelha), já normalizada para o valor máximo de 1,00 e a curva de controle (cor azul). A curva de controle demonstra que o modelo concebido possui potencial para redução das variações de temperatura quando a câmara de armazenamento está sujeita a perturbações em sua atmosfera.




Figura 6: Implementação do modelo de controle de temperatura. Dados reais versus curva de controle.

No caso deste trabalho, deseja-se que o estado a ser mantido seja o das condições das variáveis de controle do ambiente de conservação, a fim de se evitar o mínimo de perdas relacionadas às questões que envolvem qualidade, que consequentemente envolvem perdas econômicas.

Os resultados parciais baseiam-se na obtenção do levantamento dos dados da revisão bibliográfica, bem como das informações relativas às faixas ideais de conservação da manga e outros frutos, bem como a modelagem dos requisitos. Ressalta-se que esse modelo, embora tenha sido simulado com os dados da maçã, pode ser extrapolado para outros produtos agrícolas perecíveis, tanto frutas, como hortaliças, até mesmo carnes e flores, cujos transportes também são realizados pela cadeia do frio. Esta extrapolação do modelo viria da configuração do modelo de acordo com os valores ótimos de conservação de cada produto, que precisaria ser levantado.

De acordo com a bibliografia levantada, observou-se que há potencial de aplicação do controle de sistemas adaptativo no modelo concebido. Entretanto, notou-se que poucos trabalhos na literatura abordam a aplicação desta técnica na área agrícola e de conservação de alimentos, demonstrando que há um potencial de desenvolvimento de estudos nessa linha de pesquisa. Além disso, o sistema poderia ser configurado para controlar os limites mínimos de temperatura dos intervalos

apresentados a partir dos quais um alerta poderia ser acionado permitindo ao sistema reconhecer automaticamente a necessidade de manutenção da temperatura dentro dos níveis ideais.

VI. CONCLUSÕES

Considerando o modelo proposto, visualiza-se um potencial da utilização de controle de sistemas na conservação de frutas armazenadas. O diferencial desse modelo de controle é o fato de incluir variáveis de controle como O₂, CO₂, etileno e não somente a temperatura e umidade como é feita em sistemas de refrigeração. Há também a possibilidade de se configurar este modelo para o transporte de frutas em caminhões refrigerados, em que as perturbações ao sistema são maiores. Por meio do controle dinâmico e otimizado, que varia com o passar do tempo durante a armazenagem das frutas, é possível configurar o sistema de forma a obter um menor consumo de energia. Dessa forma, outro benefício deste modelo é a eficiência energética.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), auxílio nº 161109/2013 e 485847/2013-2.

REFERÊNCIAS

- [1] SILVERIO, G. A.; Ultramari, K. Food waste in Brazilian Units Food and Nutrition. **Ambiência Guarapuava (PR)**, v.10, n.1, p. 125 - 133, 2014.
- [2] PUTNIK, P.; KOVACEVIC, D.B.; HERCEG, K.; ROOHINEJAD, S. GREINER, R. BEKHIT, A.E.A.; LEVAJ, B. Modelling the shelf-life of minimally-processed fresh-cut apples packaged in a modified atmosphere using food quality parameters. **Food Control**, v.80, p. 55-64, 2017.
- [3] SAQUET, A.; STREIF, J.; ALMEIDA, D.P.F. Responses of 'Rocha' pear to delayed controlled atmosphere storage depend on oxygen partial pressure. **Scientia Horticulturae**, v.222, p. 17-21, 2017.
- [4] CORTELLINO, G.; PIAZZA, L.; SPINELLI, L.; TORICELLI, A.; RIZZOLO, A. Influence of maturity degree, modified atmosphere and anti-browning dipping on texture changes kinetics of fresh-cut apples. **Postharvest Biology and Technology**, v.124, p. 137-146, 2017.
- [5] OGATA, K. **Engenharia de Controle Moderno**. 5 ed. São Paulo. PearsonPrentice Hall, 2010. 809p.
- [6] LUYBEN, M.L.; TYRÉUS, B.D.; LUYBEN, W. L. **Plantwide Process Control**. New York. McGraw-Hill, 1998. 395p.
- [7] JURAN, J.; GODFREY, A. B. **Quality Handbook**. Republished McGraw-Hill, 1999.
- [8] MAYNE, D. Robust and stochastic model predictive control: Are we going in the right direction?. **Annual Reviews in Control**, v.41, p. 184-192, 2016.
- [9] ERDOGDU, F.; ALTIIN, O.; MARRA, F. BEDANE, T. F. A computational study to design process conditions in industrial radio-frequency tempering/thawing process. **Journal of Food Engineering**, v.213, p. 99-112, 2017.
- [10] WEBER, A.; BRACKMANN, A.; ANESE, R.O.; BOTH, V.; PIVOTTO, E. Controlled atmosphere to the storage of 'Maxi Gala' apples. **Revista Ciência Agronômica**, v.44, n.2, p. 294-301, 2013.
- [11] FORBES, M.; PATWARDHAN, R.S.; HAMADAH, H.; GOPALUNI, R. B. Model Predictive Control in Industry: Challenges and Opportunities. **IFAC-PapersOnLine**, v.48, n.8, p. 531-538, 2015.
- [12] ASTRÖM, K.J.; HAGGLUND, T. The future of PID control. **Control Engineering Practice**, v.9, p. 1163-1175, 2001.

Bayesian networks applied in the analysis of causality between pregnancy in adolescence and school dropout

Redes bayesianas aplicadas na análise de causalidade entre gravidez na adolescência e abandono escolar

CRUZ, E.*; COZMAN, F.*

*Departamento de Engenharia Elétrica - Universidade de São Paulo

efcruz@usp.br, fgcozman}@usp.br

Abstract — This article studies the relationship between teenage pregnancy and the impact on the adolescent's school situation. Two Bayesian networks were constructed and compared in terms of efficiency in the prediction of school dropout based on data collected from a group of adolescents participating in the Casa do Adolescente project (which compose the Adolescent Health Program of the State Department of Health of São Paulo). The collected data were used for statistical learning using cross-validation "k-fold" method which produced parameters for the comparison of the two Bayesian networks under investigation in this work.

Keywords— School Dropout, Statistical Learning, Bayesian Networks, Adolescent Health

Classification—Doctorate degree

Category—Beginner

Resumo — Este artigo estuda a relação entre a gravidez na adolescência e o impacto na situação escolar do adolescente. Duas redes bayesianas foram construídas e comparadas quanto à eficiência na predição do abandono escolar a partir de dados coletados de um grupo de adolescentes participantes do projeto Casa do Adolescente (que compõe o programa Saúde do Adolescente da Secretaria de Estado da Saúde de São Paulo). Os dados coletados foram utilizados para o aprendizado estatístico recorrendo-se ao método "cross validation k-fold" que, por sua vez, deu origem a parâmetros utilizados na comparação das redes bayesianas sob investigação nesse trabalho.

Palavras-chave— Evasão escolar, Aprendizado Estatístico, Redes Bayesianas, Saúde do Adolescente

Classificação—Doutorado

Categoria—Iniciante

I. INTRODUÇÃO

A adolescência é o período de vida dos seres humanos entre 10 e 19 anos [1] marcado por intensas e bruscas mudanças tanto físicas como comportamentais [2]. Em particular, temas relacionados à sexualidade emergem com intensidade, além disso, problemas como doenças e impactos sociais diante de uma gravidez precoce não respeitam idade nem localização geográfica afetando áreas em desenvolvimento em escala global [3],[4].

No Brasil o IBGE - Instituto Brasileiro de Geografia e Estatística estima em 17,1 milhões o número de adolescentes para 2020 [5], assim diante da magnitude dos números e da

importância e vulnerabilidade dessa etapa de vida, tornam-se fundamentais os serviços de atenção e cuidados voltados aos adolescentes.

A Casa do Adolescente, projeto do Programa Saúde do Adolescente da Secretaria do Estado da Saúde – SP, oferece espaços de acolhimento dedicados à saúde integral do adolescente onde equipes multifuncionais de profissionais da saúde atuam de forma integrada [6]. Atualmente já são mais de 30 espaços como esses espalhados pelo estado de São Paulo, sendo as Casas de Pinheiros e Heliópolis as com maior número de acolhimentos.

Além de todo apoio nas mais diversas dimensões da saúde do adolescente oferecido nas Casas do Adolescente, elas também constituem um verdadeiro núcleo de aquisição de dados (médicos, sócio-econômicos, comportamentais, etc.). Dados esses coletados desde o primeiro momento do acolhimento, constituindo assim um valioso banco de dados que, por sua vez, convida à investigação na busca por informações latentes visíveis, talvez, somente sob a luz da exploração estatística.

Assim, o objetivo desse trabalho é dar os primeiros passos na construção de um modelo estatístico que permita estudar a causalidade entre dois itens observáveis e de grande importância social: a gravidez na adolescência e o impacto na situação escolar do adolescente [7].

Compara-se aqui o desempenho de duas redes bayesianas aprendidas a partir de dados e com diferentes suposições de independência. A expectativa é que simulações de cenários probabilísticos levem ao entendimento das relações causais entre esses dois ingredientes e dêem suporte ao planejamento de ações para melhorar a saúde do adolescente.

A Seção II apresenta uma breve revisão sobre redes Bayesianas, já a seção III apresenta a metodologia de coleta de dados e aprendizado estatístico, seguida pela seção IV que reúne as análises dos resultados obtidos e, por fim, a seção V encerra as conclusões desse trabalho.

II. REDES BAYESIANAS E MODELOS DE CAUSALIDADE

Modelos Bayesianos são tópicos de interesse cada vez mais frequente nos mais diversos campos do conhecimento [8],[9],

parte desse sucesso pode ser atribuída à facilidade em modelar relações de causalidade [10].

De modo sucinto, uma rede bayesiana é um grafo orientado acíclico onde cada nó representa uma variável aleatória, associado a uma distribuição conjunta de probabilidades fatorizada em acordo com a hipótese de Markov [11]. Dessa forma, uma Rede Bayesiana (RB) guarda em sua topologia informações sobre as relações de causalidade entre as variáveis que a compõe [12], [13].

Em termos de Aprendizado Estatístico é possível aprender tanto a estrutura quanto os parâmetros de uma RB a partir de um conjunto de dados. Além disso, também é possível combinar opiniões de especialistas com informações obtidas dos dados [14], [15].

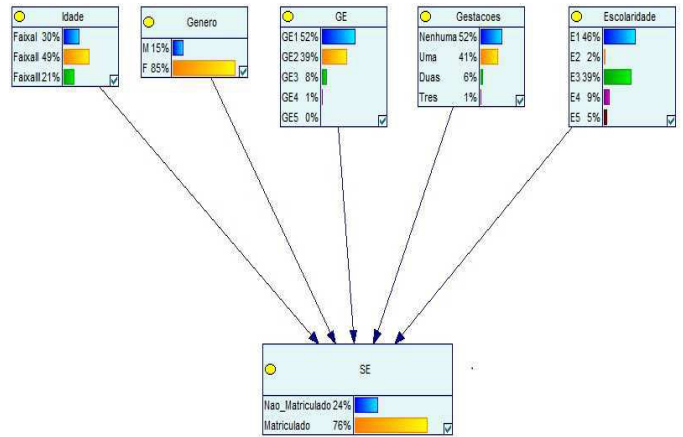
III. METODOLOGIA

Foram coletados dados referentes a 105 adolescentes acolhidos nas Casas do Adolescente de Pinheiros e de Heliópolis (São Paulo-SP), no momento as instalações de maior representatividade em procura de todas as demais Casas dos Adolescentes. A coleta foi realizada pelas Assistentes Sociais responsáveis pela coordenação geral após treinamento direcionado a todo o processo de coleta. Os direitos de uso dos dados, assim como a responsabilidade pelo armazenamento e políticas de compartilhamento são da Secretaria de Estado da Saúde - SP que, por sua vez, permitiu a utilização dos mesmos para o propósito desse trabalho. Os dados coletados referem-se aos seguintes atributos: Idade (Faixas Etárias: I1=(10-14), I2=(15-17), I3=(18-21)), Gênero (Masculino/Feminino), Grupo Étnico (GE1=Branco, GE2=Pardo, GE3=Negro, GE4=Amarelo, GE5=Indígena), Escolaridade (E1=Ensino Fundamental Incompleto, E2=Ensino Fundamental Completo, E3=Ensino Médio Incompleto, E4=Ensino Médio Completo, E5=Ensino Superior), Quantidade de Gestações (0,1,2) e Situação Escolar (Matriculado e Não Matriculado em instituições de ensino). Posteriormente, os dados foram organizados para uso no software *Genie Solutions* (<https://www.geniesolutions.com.au>). Então, foram geradas duas redes bayesianas distintas (RB1 e RB2), com diferentes suposições de causalidade. Enquanto a RB1 assume forte independência entre os atributos, a RB2 teve a estrutura definida com a colaboração de profissionais das Casas de Pinheiros e Heliópolis considerados como especialistas no assunto.

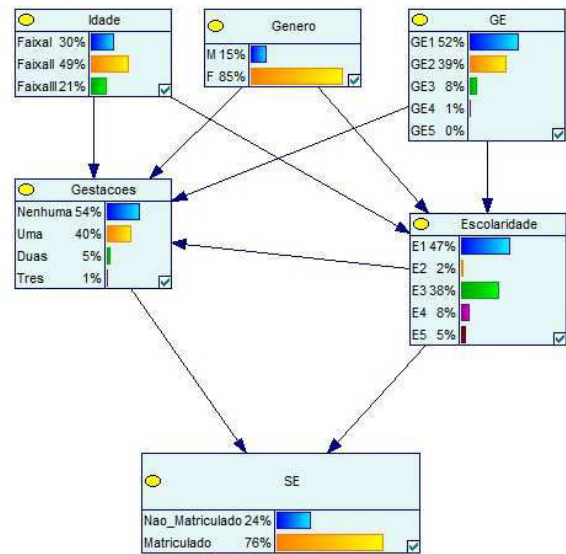
Finalmente, os dados coletados e devidamente tratados compuseram a base do processo de aprendizagem estatística realizado com o suporte do software *Genie* recorrendo-se à técnica *k-fold cross-validation* onde foi adotado $k=4$ objetivando um processo de aprendizado menos sensível a tendências locais.

IV. RESULTADOS E ANÁLISES

As figuras 1 e 2 mostra as redes RB1 e RB2 utilizadas nesse trabalho.



RB1
Fig.1. RB1



RB2
Fig.2. RB2

Uma vez construídas as redes é possível compor cenários probabilísticos onde evidências (100% de probabilidade de ocorrência) são impostas. O primeiro experimento considerou como evidências os seguintes itens: Idade (Faixa etária 10-14 anos), Gênero (Feminino), Grupo Étnico (Branco), Escolaridade (Ensino Fundamental Incompleto) e para esse mesmo cenário variou-se o número de gestações (0 e 1). Em um segundo experimento, foram adotadas como evidências: Idade (Faixa etária 15-17 anos), Gênero (Feminino), Grupo Étnico (Branco), Escolaridade (Ensino Médio Incompleto) e para esse mesmo cenário variou-se o número de gestações (0, 1 e 2). As figura 1 e 2 apresentam as probabilidades obtidas.



Fig.2. Resultados Obtidos (10-14 anos)




Fig.3. Resultados Obtidos (15-17 anos)

Da análise de ambos os experimentos verifica-se que as duas RB dão conta de expressar um fenômeno observado na prática: o impacto negativo da gravidez precoce na vida escolar da adolescente.

Por exemplo, o modelo associado a RB1 aponta um salto de 13% para 60% na probabilidade de evasão escolar (no cenário de meninas brancas na faixa etária 10-14 anos e com ensino fundamental incompleto) em comparação a situação onde não há ocorrência de gravidez precoce.

Fenômeno, também, apontado de forma qualitativa pela RB2. Já no cenário composto por meninas brancas na faixa etária 15-17 anos e ensino médio incompleto observa-se o mesmo comportamento com relação ao número de gestações. Enquanto a RB1 indica escalada 2% - 13% - 25%, a RB2 aponta o ritmo 6% - 24%.

Com relação a acurácia e sensibilidade, obteve-se para a RB1 a medida de 83% de sucesso na predição da situação escolar, já a sensibilidade correspondente a previsão dos estados “matriculado” e “não matriculado” foram de 91% e 59%

respectivamente. Para RB2 os resultados calculados foram de 81% (85 acertos de 105) para a acurácia global e 88% e 59% de sensibilidade na predição dos estados “matriculado” e “não matriculado” respectivamente.

V. CONCLUSÃO

Os experimentos não apontaram significativa diferença entre os modelos considerados, ficando o primeiro, RB1, globalmente mais preciso se equiparando à RB2 na sensibilidade em prever o abandono escolar. No entanto, ambos foram efetivos no estabelecimento de possível relação de causalidade entre a gravidez na adolescência e evasão escolar, fato que estimula a exploração científica no campo da modelagem bayesiana.

Assim, o presente trabalho aponta para a análise dos dados via abordagem bayesiana como uma interessante aliada no incremento da efetividade das ações e no esclarecimento de relações de causalidade já conhecidas e outras que possam estar ocultas no emaranhado de dados.

A consistência desse primeiro trabalho passa pela necessidade da investigação envolvendo um número maior de dados, tarefa que exige um árduo trabalho de coleta e organização de dados, trabalho esse já em progresso.

REFERENCES

- [1] WHO. Hrp annual report 2016. <http://www.who.int>, 2017.
- [2] Takiuti, A. Utopia ? Editora Artes e Contos, 2001.
- [3] Grant and Hallman. Pregnancy-related school dropout and prior school performance in kwazulu-natal, south africa. *Studies in Family Planning* vol. 39(4), pp. 369_382, 2008.
- [4] UN. World Population Monitoring. United Nations, 2012.
- [5] IBGE. Crianças e adolescentes indicadores sociais. <http://biblioteca.ibge.gov.br>, 1997.
- [6] SSSP. Adolescência e Saúde III. Imprensa Oficial São Paulo, 2008.
- [7] Kasen, S., Cohen, P., and Brook, J. Adolescent school experiences and dropout, adolescent pregnancy, and young adult deviant behavior. *Journal of Adolescent Research* vol. 13, pp. 49_72, 1998.
- [8] Charniak, E. Bayesian networks without tears. *AI Magazine* 12 (4): 50-63, 1991.
- [9] Goldenberg, A., Zheng, A., Fienberg, S., and Airoidi, E. Survey of statistical network models. *Foundations and Trends in Machine Learning* vol. 2, pp. 129_233, 2010.
- [10] Hand, D. and Yu, K. Idiot's bayes _ not so stupid after all? *International Statistical Review* vol. 69, pp. 385_399, 2001.
- [11] Ghahramani, Z. An introduction to hidden markov models and bayesian networks. *IJ PRA* , vol. 15, pp. 9_42, 2001.
- [12] Pearl, J. *Causality: Models, Reasoning and Inference*. Cambridge, 2000.
- [13] Spirtes, P., Glymour, C., and Scheines, R. *Causation, Prediction and Search*. MIT Press, 2000.
- [14] Darwiche, A. *Modeling and Reasoning with Bayesian Networks*. Cambridge, 2009.
- [15] Koller, D. and Friedman, N. *Probabilistic Graphical Models: Principles and Techniques* (Adaptive Computation and Machine Learning series). MIT Press, 2009. Pearl, J. *Causality: Models, Reasoning and Inference*. Cambridge, 2000.

An holistic vision on Adaptivity

CAYA, R.*; NETO, J. J.*

*Adaptive Technology Laboratory - Department of Computer Engineering and Digital Systems
Polytechnic School of University of São Paulo
E-mail: rosalia.caya@usp.br, joao.jose@poli.usp.br

Abstract—This article studies adaptivity as a general phenomenon, a subject of matter, permeable to different perspective within technological research areas. From a simple and general definition grounded in Biology and Psychology to sophisticated and particular definitions within Computer technology areas, such as Computer Science, Information Technology, and Software Engineering, this work focus in retrieving the core features that characterize adaptivity, its needs and properties. We present a proposal for the holistic characterization of adaptive behavior that contributes in the establishment of a framework to share scientific knowledge in the technological arena.

Keywords— adaptivity; autonomic computing; complex systems; cybernetics; holistic vision.

Classification— Doctorate Degree

Category— Intermediate

I. INTRODUCTION

The idea of an entity capable of modifying its own behavior according to characteristics of its environment and its own particular goals it's not a novelty, in fact it has been around from ancient times: from Daedalus, credited with making the first “living statues” to Hephaestus, the Greek god of invention and technology creator of Talos, the gigantic animated bronze warrior programmed to guard the island of Crete. Greek Mythology has record the interest of humankind in autonomous entities that given a specific task are aware of the circumstances in its surroundings to be able to fulfill its goal, through the acquisition of hidden knowledge or underlying truth [1]. The same interest is shown in works of Leonardo Da Vinci, with his mechanical knight, Descartes describing animal bodies as complex systems and several inventors during the Golden Age of Automata in the 19th century.

Most real-world problems deal with complexity, uncertainty and optimization of some type where information must be exploited as acquired so that performance maintains or improves apace. This characteristics compound the basic definition for adaptive behavior we will present in the next section, and permeates problems in several areas of knowledge as diverse as ecology, psychology, economy, artificial intelligence, computational mathematics, sociology, and others. This way, over the years, some fields within the technological arena have dedicated special efforts to study adaptive behavior and developed approaches to deal with it in its particular domain.

In the last decades the study of adaptivity is gaining attention as a multi-disciplinary concern due to the rising demand for intelligent and more realistic applications. Applications mimicking human behavior, considering continually changing conditions, critical systems or high-definition simulation of

real life situations have introduced back into technology the complexity cut off by the reductionist approach at the beginning of computer's era. As consequence a variety of spaces to develop research related to adaptivity have been created. However, despite the growth and advances shown by research this scenario and promising tendency reveal one weakness: the leak of a unified approach for adaptivity. The approaches taken by specific fields present ad-hoc solutions to deal with adaptivity within their domains. This situation creates domain specific terminology, methods, models and resources, that sometimes remain invisible or even conflict between each other. To address this challenge, in this article we propose an study on literature about the characterization of adaptivity in three different fields to create an holistic framework matching theoretical and practical approaches to define, model and create technology considering adaptive behavior. This study is a foundational part of bigger research project that aims to develop an adaptive software factory to level up a variety of adaptable devices by wrapping them with additional layers created automatically. In that line, this study establishes the core elements to work with while developing such software factory.

Paper Organization The rest of the paper is organized as follows: first we give an intuitive and basic definition of adaptive behavior to describe the phenomenon under analysis. Then we look at the approaches this phenomenon has taken within different technological areas aiming to solve problems related to their particular subject matter. We took three main fields that have developed solid approaches for dealing with adaptive behavior: cybernetics, complex systems, and autonomic computing. Next, we propose an holistic vision of adaptivity, the factors that allow such approach, the common ground between the theory in the analyzed fields, and the contribution and advantages it will bring. Finally, we elaborate the conclusions about this work and present the future directions to develop an holistic vision of adaptivity.

II. ADAPTIVITY

In the most basic approach, we define adaptivity in the following intuitive terms: adaptivity is the ability of an *entity*, at any moment, to *decide* the modification, by *executing* a set of proper actions, of its own features, structure and/or behavior, or even its environment, when facing new coming events *perceived* in its surroundings while pursuing a particular *goal to suit more efficiently* the new *context* of its functioning.

The term *entity* can take a wide range of meanings for example: individual, system, structure, agent, being, and so on, the concrete meaning is largely determined by the field of study. The *decision* to effectively change any of its components comes uniquely from its own analysis about the benefits gained in doing so revealing its autonomous nature. The direct *execution* of the proper set of actions matching the situation means the entity in fact has the media to enact different behavior. The analysis mechanism is performed due to stimulus *perceived*, or sensed, in the current situation. The high-level *goal* the entity aims generally is set by an external high-level authority: a leader, a manager, a need or even evolution. The motivation in performing adaptations is a better suiting of the entity and its goal into the new situation, this has a variety of consequences, such as: incorporation/drop of new features to take advantage of opportunities, avoidance of threats, or preparation for facing danger. By being adaptive the entity tries to respond to changes in the *context* in which it performs at the moment. The context is defined by its internal features (behavior and structure) the characteristics of the external environment (resources, events, objects within) and the channels of interaction between them.

III. DIFFERENT APPROACHES

The three approaches presented here were selected based on an exploratory review made on Web of Science aimed to discover the major areas within computational arena that research in subjects related to adaptivity. The exploratory review revealed that Computational Cybernetics, Complex Adaptive Systems and Autonomic Computing are the areas of knowledge that most directly referred to adaptivity.

A. Cybernetics

Cybernetics is, in general terms, defined as the area of knowledge that studies the abstract principles of organization in complex systems, focusing on how systems use information, models, and control actions to steer towards and maintain their goals, while overcoming difficulties [2]. By being inherently interdisciplinary, cybernetic reasoning can be applied to understand systems of any kind and it has influenced many fields including computer science, robotics, management, sociology, political science, economics, psychology and philosophy. According to Beer in [3]: "cybernetics studies the flow of information around a system, and the way in which this information is used by the system as a means of controlling itself: it does this for animate and inanimate systems indifferently". Later, organization theorists regard Cybernetics as a science of information processing, decision-making, learning, adaptation, and organization, whether this occurs in individuals, groups, organizations, nations, or machines [4].

In [5] the author points out that the operation of cybernetic systems can be characterized by a cycle with five stages:

- 1) goal activation: discovering goals, intentions and expectations that can be achieved, in the current state of the system;
- 2) action selection: this stage enacts the decision making mechanism of the system;
- 3) action: execution of the strategy, the implementation of the necessary context and the detailed directions for the actual behavior of the system in the environment;
- 4) outcome interpretation: at this stage the system retrieves the data and facts from the environment to interpret the consequences of the behavior performed before. This information is passed to the system as feedback using memory updating and storing;
- 5) goal comparison: this stage is about examination, deliberation and revision of the information from the feedback to reveal the achieving of the selected goal. If the goal has not been achieved yet, then some actions may be done to approach its completion. This can be summed up as analyzing the mutual influence between the system and the environment in which it performs.

These elements can be divided into two basic categories: mechanisms and stored data. The first category is a collection of mechanisms that evolved to carry out the different processes associated with each stage of the cycle. The mechanisms are called into play by encounter with uncertainty. These mechanisms reflect the two different natures involved in the system: Stability (to maintain the stability of ongoing goal-directed functioning) and plasticity (tendency toward exploration, the creation of new goals, interpretations, and strategies [5]). Plasticity reflects the degree to which the cybernetic system is prone to generating new goals, interpretations, and strategies, not only when required by events that have caused instability and disintegration, but also voluntarily, in response to the incentive reward value of the unknown. The second category refers to elements stored in memory: a collection of goals, actions, and knowledge about the world (strategies, standards, behavioral repertoire, and patterns that exist in the world). Most of these are learned through experience rather than innately preprogrammed. These learned, updateable memory contents of the cybernetic system are deployed by the mechanisms described in the first category.

B. Complex Systems

In both Engineering and Science the term *complexity*, does not have a sharp definition and the demarcation with the notion of complicated systems is a challenge [6], [7]. However, this does not forestall a rigorous scientific approach to the subject matter. A system is considered complex if it has many components that collaborate to create a functioning whole. The function of such system is governed by the dynamical interactions of the components (within the system and with the environment) and cannot be fully understood by the description and analysis of its parts in an individual manner, as with the reductionist approach [8]. Complex systems are characterized, and distinguished from *complicated* systems, by two factors: (i) it exhibits unexpected behavior, often referred to as emergence of properties, as a consequence of non-linear interactions between its parts, framed by the hierarchical structure that build up the system, and (ii) the uncertainty in predicting

the behavior of the system, named unpredictability, due to continuous change in function and structure [6], [8]. Complexity has become a highly interdisciplinary topic today, building bridges between several fields. Most areas of knowledge have turned to complexity as a way to get answers to questions that would otherwise remain inaccessible and to offer a key to new kinds of understanding [6]. This reflects the fact that most real-world systems are complex, as pointed out in [9] complexity is considered an inherent feature of the matter, being nature its ultimate source [10], and so is technology. According to [6] the field of complexity studies has split into two subfields: the study of *Complex Physical Systems* (CPS) and the study of *Complex Adaptive Systems* (CAS). In this work we focus on the latter. In [11] Holland proposes a general way of characterizing Complex Adaptive Systems by seven basics: four properties (p): aggregation, nonlinearity, flows and diversity, and three mechanisms (m): tagging mechanism, internal models and high-level reorganization patterns. These seven principals intend to be a framework to organize the different features present in complex adaptive systems. They are not the only basic features that could be selected from all the complex systems, although, most of the other can be derived from appropriate combinations of them. Some of the aforementioned characteristics even when not mentioning adaptivity directly depend upon this faculty to develop a technique for processing continuous change. Feedback, learning, self-organization, aggregation and balancing the dichotomy of forces are some of the characteristics at systems' level that laid upon adaptivity to achieve its major goals.

The direct mention of adaptivity is particularly granted to elements of the system, the agents. In [11], Holland states that adaptation is the *sine qua non* of CAS. He defines CAS as systems composed by interacting agents described in terms of rules. These agents adapt by changing their rules as experience accumulates. Moreover, in [12] the authors state that lifelong research work developed by Holland, recognized that adaptation is central to fields that concern populations of agents that must continually obtain information from uncertain, changing environments and be able to use it to improve its performance and chance of survival, this extends the impact of studying adaptive behavior beyond CAS.

C. Autonomic Computing

Autonomic Computing is a term coined by IBM's vice-president, Paul Horn at 2001 [13]. It describes systems that can manage themselves, self-managing systems, given high-level goals from human administrators [14], [15], [16]. The term resembles the ability observed in the *Autonomic Nervous System* to govern and regulate a whole set of body functions without the need for conscious human involvement [14], [13], [17]. To cope with the challenge of managing and use technologies with complex infrastructures, autonomic computing systems need to be capable of running themselves, adjusting to varying circumstances and preparing their resources to handle the workloads that system administrators put upon them [14], [15].

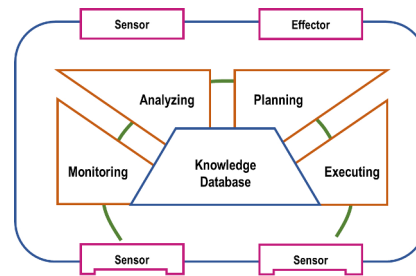


Figura 1. Internal architecture for autonomic managers. Extracted from [16].

To build such high-level systems, IBM describes a proposal for the necessary architectural building blocks, organization and behavior to build self-managing autonomic capability [14], [16], [15]. The proposed architecture presents a hierarchical organization with autonomic managers at its core. An autonomic manager must implement the architecture known as MAPE-K (Monitoring-Analyzing-Planning-Executing-Knowledge) architecture. Figure 1 shows the MAPE-K architecture and its general elements. These mechanisms communicate and collaborate with one another and exchange appropriate knowledge and data. The information within the knowledge database consists of particular types of data (policies, symptoms, metrics, and logs) that can be accessed and/or modified by the mechanisms in the autonomic manager.

IV. PROPOSED HOLISTIC FRAMEWORK

After revising the approaches presented in the previous section we were able to identify the necessary conditions for the existence of adaptive behavior, and the main properties observed in adaptive systems.

A. Necessary Conditions

We identify the elements that are the *sine qua non* of adaptive behavior in a multidisciplinary scope. The following conditions need to be present, perhaps under different terminology, when modeling adaptivity to offer a complete framework to understand the phenomenon:

- Awareness [18], [8], [19]: both self-awareness and context awareness;
- Models [20]: system (internal) and environmental model. They can be either implicit and learned over evolutionary time, i.e. evolutionary computing, or explicit and learned (or given) over a single lifespan;
- Hierarchical structure [12]: allows the application and managing of behavioral rules according to the level of abstraction of the entities and their capabilities;
- Characteristic response [12]: The normal or standard behavior over which the modifications, the adaptations, will be developed;
- Monitoring and selection Mechanism [19];
- Autonomy [18], [8];
- Learning Method [8], [19]: also called Learning Cycle. This is the part where the adaptivity per se is performed;
- Memory [12], [20]: stored knowledge;

Particularly, the learning method need to implement some basic elements to support its goal :

- Feedback loop [19], [11];
- Structural modifiers or operators [12], [20]: elements responsible for implementing direct modifications and its propagation;
- Mechanism for comparison and assessment [19], [12], [20] : are the mechanism that allows the program to evaluate how convenient are different alternatives to modify its behavior;

B. Properties observed in Adaptive Systems

The following properties have been identified in systems that perform adaptive behavior:

- Open endedness [8], [12];
- Continuity, as explained in [8], [11], [20], [12], [19];
- Traceability [6], [20]
- Self-* properties;
- Emergence and Propagation of features[19], [12];
- Exhibition of high-order patterns[12];
- Operation at multiple spacial and temporal scales.

V. FINAL REMARKS

By the end of this work we have come to the following findings:

- Understanding the participants involved in adaptive behavior allows to identify core components, even when named under different terminologies, that perform the same task. By doing so it is possible to establish parallels between theories and techniques, as the one presented in Fig. 2 resulting in opportunities to share knowledge [10].

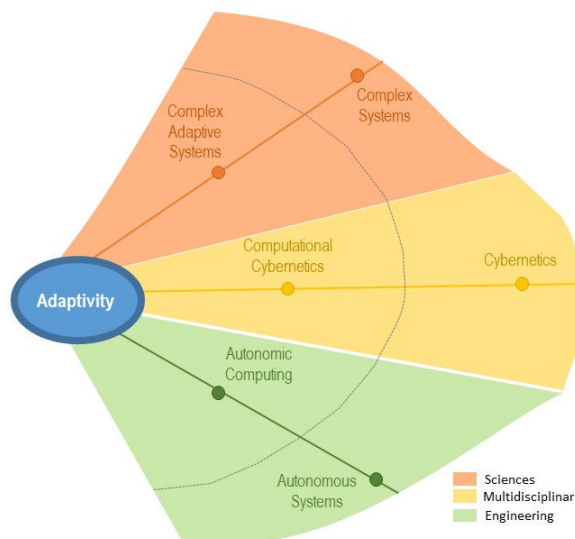


Figura 2. Partial holistic framework of adaptive behavior considering Complex Adaptive Systems, Autonomic computing and Cybernetics.

- The fulfillment of the necessary conditions for adaptivity leads to the identification of research problems that can be solve with adaptivity.

- Some future work to be perform is to integrate the findings of this study with some other areas of knowledge within the computational arena to complete an holistic theory of adaptivity for a richer understanding of: [i]the phenomenon (features, properties, mechanism, elements, interactions); [ii] the benefits, consequences, requirements and focus of the scientific tools available to work with; and [iii] the remaining challenges related to adaptivity. This is possible because the information within different approaches synergy through the core components.

REFERÊNCIAS

- [1] HYMAN, W. *The Automaton in English Renaissance Literature*. [S.l.]: Ashgate, 2011. (Literary and scientific cultures of early modernity). ISBN 9780754695196.
- [2] HEYLIGHEN, F.; JOSLYN, C. Cybernetics and second order cybernetics. *Encyclopedia of physical science & technology*, v. 4, p. 155–170, 2001.
- [3] BEER, S. *Decision and Control: The Meaning of Operational Research and Management Cybernetics*. [S.l.]: John Wiley, 1966.
- [4] UMPLEBY, S. A. Cybernetics. In: *International Encyclopedia of Organization Studies. Volume 1*. [S.l.]: Sage, 2007. p. 350–353.
- [5] DEYOUNG, C. G. Cybernetic big five theory. *Journal of Research in Personality*, v. 56, p. 33 – 58, 2015. ISSN 0092-6566. Integrative Theories of Personality.
- [6] HOLLAND, J. *Complexity: A Very Short Introduction*. [S.l.]: Oxford University Press, 2014. (Complexity: A Very Short Introduction). ISBN 9780199662548.
- [7] CHEN, C.-C.; CRILLY, N. *From Modularity to Emergence: A Primer in the design and science of Complex Systems*. [S.l.], 2016.
- [8] CILLIERS, P. *Complexity and Postmodernism: Understanding Complex Systems*. [S.l.]: Taylor & Francis, 2002. ISBN 9781134743292.
- [9] GRABOWSKI, F.; STRZALKA, D. Simple, complicated and complex systems: the brief introduction. In: *2008 Conference on Human System Interactions*. [S.l.: s.n.], 2008. p. 570–573. ISSN 2158-2246.
- [10] UNIVERSITY OF CAMBRIDGE. *How can we share solutions to complex systems problems across domains and application areas?* 2017. Disponível em: <<https://phys.org/news/2017-03-solutions-complex-problems-domains-application.html>>.
- [11] HOLLAND, J. H. *Hidden Order: How Adaptation Builds Complexity*. Redwood City, CA, USA: Addison Wesley Longman Publishing Co., Inc., 1995. ISBN 0-201-40793-0.
- [12] FORREST, S.; MITCHELL, M. Adaptive computation: The multidisciplinary legacy of john h. holland. *Commun. ACM*, New York, NY, USA, v. 59, n. 8, p. 58–63, jul. 2016. ISSN 0001-0782.
- [13] NAMI, M. R. et al. A survey of autonomic computing systems. In: *Intelligent Information Processing III: IFIP TC12 International Conference on Intelligent Information Processing (IIP 2006), September 20–23, Adelaide, Australia*. Boston, MA: Springer US, 2007. p. 101–110. ISBN 978-0-387-44641-7.
- [14] HORN, P. *Autonomic computing: IBM's Perspective on the State of Information Technology*. [S.l.]: IBM, 2001.
- [15] KEPHART, J. O.; CHESS, D. M. The vision of autonomic computing. *Computer*, IEEE Computer Society Press, Los Alamitos, CA, USA, v. 36, n. 1, p. 41–50, jan. 2003. ISSN 0018-9162.
- [16] IBM (Ed.). *An Architectural Blueprint for Autonomic Computing*. [S.l.], 2005.
- [17] SINGH, P. K. et al. Autonomic computing: A revolutionary paradigm for implementing self-managing systems. In: *2011 International Conference on Recent Trends in Information Systems*. [S.l.: s.n.], 2011. p. 7–12.
- [18] KHAKPOUR, N. et al. Formal modeling of evolving self-adaptive systems. *Science of Computer Programming*, v. 78, n. 1, p. 3 – 26, 2012. ISSN 0167-6423.
- [19] PRINCIPE, J. C.; EULIANO, N. R.; LEFEBVRE, W. C. *Neural and Adaptive Systems: Fundamentals Through Simulations with CD-ROM*. 1st. ed. Berlin, Germany: John Wiley & Sons, Inc., 1999. ISBN 0471351679.
- [20] HOLLAND, J. H. *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control and Artificial Intelligence*. Cambridge, MA, USA: MIT Press, 1992. ISBN 0262082136.

Prediction of blood glucose in type 1 diabetics using a Hybrid Model based on Agents

PEREIRA, J. P.A.*; BRANDÃO, A. A. F.*; BEVILACQUA, J. S.

* Departamento de Computação e Sistemas Digitais - Escola de Engenharia de Computação
Departamento de Matemática Aplicada - Instituto de Matemática e Estatística
{rajoma, anarosa.brandao}@usp.br, joyce@ime.usp.br

Abstract — The number of Diabetes Mellitus cases has constantly grown in recent decades around the world. Thus, numerous mathematical and agent-based models have been proposed to shape the human glucose-insulin regulatory system and its ultradian oscillations. However, the most current models do not have the ability to learn constantly in order to increase the prediction of human blood glucose from 30 minutes to approximately 8 hours. In order to contribute to the improvement of these mechanisms, this research project presents an autonomous reactive model to inputs such as physical activity, quantity and type of insulin, as well as food intake, in order to predict the oscillation of glucose concentration in the human bloodstream for approximately 8 hours in type 1 diabetic patients. The main property of the proposed model is to combine a discrete modeling approach, agent-based model, with continuous model to form a hybrid model. This model is based on the schematic diagram of the human glucose-insulin regulatory system, and each agent within the physiological process will follow a mathematical model to characterize its functions and interactions. The use of agents representing, for example, the pancreas and its alpha and beta cells, tends to facilitate the process of learning from the variable's values related to each patient, and deliberation of which of them should be re-fed into the mathematical model (differential equations). The end result tends to identify the behavior of each type 1 diabetic with their respective glucose variation for 8 hours and create recurrent and subjective recommendations.

Keywords – Diabetes Mellitus; mathematical model; agent-based model; predict; glucose concentration.

Classification: doctorate degree.
Category: Beginner.

I. INTRODUCTION

Current society has changed their lifestyle with the increase of sedentarism associated with the consumption of industrialized foods with high energy density. The number of the diabetes cases has tripled in the USA since 1990 [3] and reach more than 16 million in Brazil [11]. Public policies aimed at adults, children and adolescents, associated with a model that can facilitate the circadian routine of a diabetic are necessary and emerging to reduce the advance of this chronic disease [6]. The ease of access to software in devices with low computational capacity may facilitate the integration of diabetic patients with a model capable of predicting the oscillation of glucose in the bloodstream [9]. In fact,

users/patients from different places with specific diseases are encouraged to perform most of their checks through a software or device [5].

The nature of the human organism necessitates a model that mimic this dynamic exchange of information across its components. In our research project, we typically link descriptions of human glucose-insulin regulatory system (HGIRS) described in Fig. 1. In Fig. 1, the solid lines denote production/consumption of a substrate (glucose or insulin), dotted lines denote inhibition by a substrate, and dashed lines denote encouragement by a substrate. Ingested food, for example carbohydrates or fat, is converted to glucose, which the human body uses to supply their processes. Glucose also stimulates pancreatic β -cells to produce insulin [9]. However, note here that there isn't connection between pancreatic β -cells and insulin in this diagram because is a HGIRS from type 1 diabetic (T1D). In the case of T1D, the pancreas is incapable of producing insulin, and so healthy glucose levels can only be maintained through the injection of external insulin. It is not possible to induce stable glucose oscillations under these conditions, but we can determine how much insulin is required to keep glucose within range of 80-120 mg/dl of the blood in the human bloodstream [9]. In our research project, we involved a dichotomy about insulin concentration in bloodstream: identify which type (basal or fast-acting) and quantify what insulin is needed to maintain glucose levels in the appropriate range in bloodstream (80-120 mg/dl), during all day long.

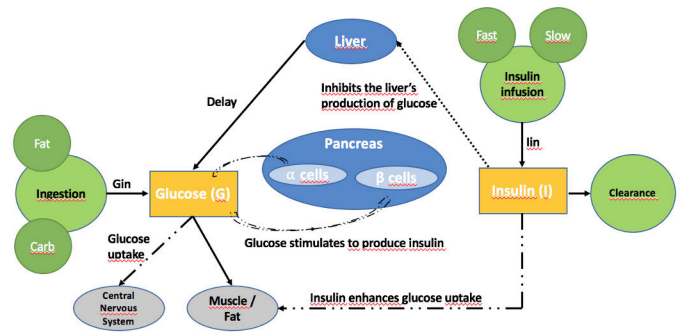


Fig. 1. Human glucose-insulin regulatory system (HGIRS): T1D

The central nervous system (CNS) processes glucose without insulin, whereas insulin enhances glucose uptake by muscle and fat cells. Thus, when blood glucose (BG) levels are

high or before daily meals, insulin infusion by injection is necessary to stimulate glucose uptake and to slow the production of further glucose from the liver [9]. When BG levels are low, the most part of the time is necessary to ingest food and the liver's production of glucose speeds up. This feedback loop helps to keep a person's BG levels in a state of oscillatory homeostasis [9].

ABMs are discrete models that utilize individual entities known as agents, here representing individual organs and hormones represented in Fig. 1. Each agent is autonomous and behaves based on decisions from the set of rules, interactions, and states given to it, leading the heterogeneity among agents. Agents can receive inputs from environment, influencing their decision making, and can also have the ability to alter their environment. The models that combine aspects of both continuous and discrete model are commonly referred to as hybrid models [4]. Hybrid ABSs arise when continuous models are used to describe part of overall model, such as the environment and parts of decision-making processes.

Computational models are used in living organisms in order to understand, translate and predict their behavior. When building our hybrid model represented in Fig. 2, four different areas could be considered: (1) how to *construct a model* – create a mathematical formulation that is able to recapitulate the dynamics of a human glucose-insulin regulatory system (systemic part of a living organism), (2) how to *solve a model* – determining the most efficient way to solve the underlying mathematics [4], (3) how to *analyze models* - calibrate and validate the model and then make and understand model predictions [4], and (4) *agent-based model (ABM)* – responsible to learn and store the individual parameters from each patient, to characterize the behavior from them and re-fed into mathematical model.

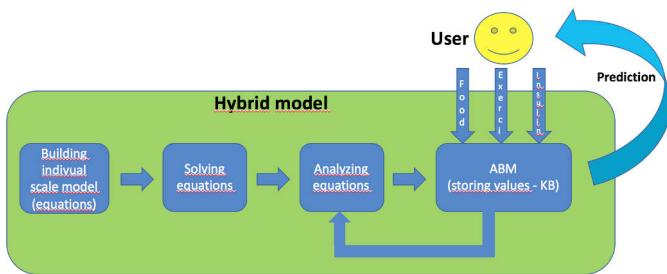


Fig. 2. Considerations for building our hybrid model

We focus this research to build a Hybrid Agent-based Model where an ABS (discrete) is informed by differential equation models (continuous), operating at same environment (organism): HGIRS. The use of continuous models is to describe the dynamics of the HGIRS and agent-associated reactions that occur at the same space and scale, and influence agent decision-making processes.

A. Current research

With no known cure for diabetes, lifelong treatment is generally the only option. T1D patients must monitor their BG levels throughout the day and take corrective action whenever they are hyper or hypoglycemic [14]. There has been a recent

of interest in human BG prediction due to its role in closed loop control for the artificial pancreas [5]. This research upon a foundation of previous models of the human glucose and insulin system, based only on differential equations but not with the focus of prediction, but on immediate recommendations [9][10]. However, the Artificial Intelligence, but exactly the Machine Learning has helped improve the prediction of glucose in human blood. In [14], the focus of the research was on the prediction of 30 minutes and also hypoglycemia only, using physiological and regression models.

Compared with the models already created, the our model aims to predict the glucose level in T1D patients for 8 hours simply because of the average sleep time of a patient in order to avoid nocturnal hypoglycemia. The joint use of the mathematical model to simulate the SRGI and the constant calibration of the values of the parameters through the agents, as the insulin sensitivity, tends to facilitate the prediction.

II. METHODOLOGY

The method adopted in the development of the present work is the Applied Research based on the hypothetical-deductive approach, using references available in the specialized literature for the definition of the problem, specification of hypotheses and analysis of such hypotheses [13]. The proposed model is specified by means of a prototype, based on agents and differential equations, that allows the validation of the hypotheses that serve as basis for the design of the model.

The first phase of this work consists of a seven-step study. The first is the study of articles referring to endocrinological medicine [10][16]. The second focuses on the construction of mathematical models, but specifically differential equations, in order to replicate the behavior of HGIRS. In this step the Matlab software is used, so with your fsolve feature. The third step is based on the analysis of the various functionalities of ABSs in order to understand the possible advantages of its use in a HGIRS [17]. The fourth step focuses on the study of how an ABS can be applied to simulate a HGIRS, as well as in combination with the continuous part (differential equations). The fifth step is based on the verification and study of the programming language named Jason. Jason is to develop the ABS which allows its implementation, and evaluation in a simulation environment with support for communication between agents. The sixth stage focuses on the construction of the final model, with the objective of predicting the oscillation of glucose in the blood of a T1D patient, using our hybrid model. Finally, the seventh step consists in calibrating the model with some T1D patients, in order to measure to the accuracy in the reached values. Initially, the calibration will be with only one T1D patient. In the last step, the T1D patient can use modern devices for continuous monitoring of blood glucose level.

III. HYBRID MODEL

A. Mathematical model

The glucose concentration (G) can increase via two pathways: ingestion and endogenous production [9]. Initially, we only model glucose release from ingestion, which we represent by the glucose intake rate Gin . We make this term periodic (in the case of multiple daily meals) (1) with ultradian glucose oscillations. In this way, we can consider carbohydrates and fat when are consumed, each one with different metabolism to generate glucose into HGIRS. Primarily, we model glucose from the liver, commonly called hepatic production (HGP), and we make this term constant (1).

The glucose concentration (G) can decrease via two pathways, namely: utilization by the Central Nervous System (CNS) and utilization by muscle and fat cells [9]. Glucose utilization by the CNS does not depend on insulin concentration; these cells will use all of the glucose available to them up to a threshold [9]. Equation (1) primarily uses this term constant ($CNSGU$). On the other hand, muscle and fat cells, do rely on the presence of insulin to take up glucose; thus, we represent their consumption with the product $f1(G(t)) * f2(I(t))$. Here we arrive at the first complication that diabetic illness introduces; the muscle and fat cells from people with T1DM depends on external insulin to take up glucose from the bloodstream as easily as the corresponding cells of a person without diabetes [9]. The scaling factor μ accounts for this; μ can take values from 0 to 1, with corresponding to no ability for muscle and fat cells to take up glucose (T1D), and 1 corresponding to the glucose uptake ability of a person without diabetes. The additional factor, $[1+(E-Em)]$ (1), accounts for the positive effect of exercise on insulin sensitivity [7]. Here, E corresponds to minutes of physical activity (MPA) per day, as defined by [12]. 60 minutes per day of MPA ($Em = 60$) is considered average; any less than this decreases glucose tolerance and any more increases glucose tolerance.

There is only one pathway by which the insulin concentration can increase in T1D: insulin infusion Iin (external) (2) because T1D does not have insulin production from pancreatic β -cells. We make this term periodic (in the case of multiple insulin infusion before daily meals) (2) with ultradian glucose oscillations. We let the insulin infusion rate Iin be a periodic term since only make sense if glucose intake is also periodic. Finally, there is one significant way for insulin concentration to decrease, which is through metabolism by human insulin-degrading enzyme (IDE) [1]. As an enzymatic reaction, we quantify insulin degradation with Michaelis-Menten kinetics using the term $VmaxI(t) / (Km+I(t))$ (2). Here, $Vmax$ is the maximum insulin clearance rate and Km is the enzyme's half-saturation value [18].

We can represent these processes mathematically by:

$$G' = Gin + HGP - CNSGU - \mu [1 + (E - Em)] * f1(G(t)) * f2(I(t)) \quad (1)$$

$$I' = Iin - (VmaxI(t) / Km + I(t)) \quad (2)$$

This mathematical model provide the framework upon which we base our analysis of human glucose and insulin dynamics [9]. We are in the development phase of the functions $f1$ and $f2$, to represent the consumption of glucose in relation to the application of insulin.

B. Agent-Based Model (ABM)

The agent-based model within our hybrid model works cooperatively using the BDI model (Belief, Desire and Intention) [19]. The proposed model has as important characteristic: the ability of communication between all the agents that compose it. The cooperation between agents is an important feature used in a way that is implicit in the model plans. The proposed model is not purely reactive because agents, in addition to continuously responding to environmental changes (HGIRS), try to systematically achieve their goals calling their functions. A knowledge base (KB) is used by each agent in order to store information needed to achieve individual goals and model goals [19].

The diagram described in Fig. 3 represents the agents that make up the HGIRS, and their possible state and actions. In addition, there are resources that can be inserted or released by the agents, such as glucose and insulin. For the model to be effective, it must assure some essential accuracy characteristics for data obtained based on information entered by the user/patient, such as BG value (mg/dl), amount of carbohydrate and fat ingested, type and time of physical exercise, besides the types and quantity of each insulin (basal and fast effect).

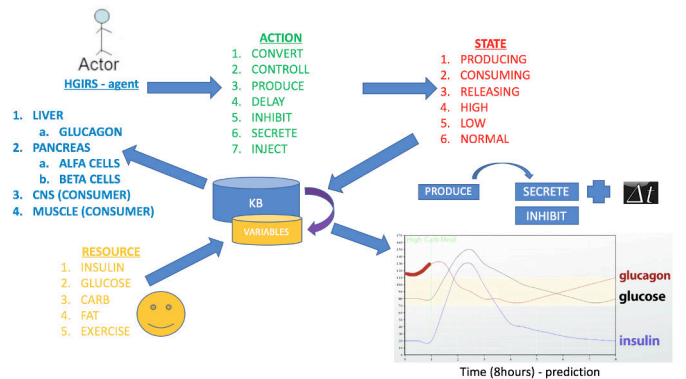


Fig. 3. Agent-based model diagram

In a predictive way, the proposed model aims to guarantee these characteristics by means of the agents (organs and hormones), representing the HGIRS. The model can store the inserted values from user and to maintain the accuracy of the glucose oscillation curve in the blood, for at least 8 hours. An agent can accumulate knowledge based on previous experiences and, consequently, perform a task more efficiently than in previous executions [8]. The behavior of the agents, their actions, their relationship between them and their respective function calls are based on differential equations. From the learning curve of each patient, the predictive values reached in the BG oscillation curve tend to be more precise, so that the agents feed the model, and consequently to the variables of the differential equations.

We are in the development phase of the ABS to represent the HGIRS based in differential equations and to predict the behavior of concentration of glucose in human blood. There are many well-known agent languages that combine declarative and imperative features (hybrid approach). Primarily, we define to use Jason [2], that is an interpreter, for an extended version of AgentSpeak(L) [15]. Jason was chosen due to be fully customisable in Java and to have a clear notion of the agent-based environment, in our case the HGIRS.

IV. CONCLUSIONS

With this research project, we have proposed a hybrid model (discrete and continuous) to predict the oscillation of glucose in the bloodstream of T1D. This model aims to replicate fundamental behaviors of the HGIRS, in order to better understand and predict the model behavior as a whole. The main idea is that, through the minimum of possible information provided by the user/patient, as well as type and quantity of food, insulin and exercise, to know with accuracy the oscillation of glucose levels in T1D for at least 8 hours. The use of an ABS, being that each component of HGIRS is an agent, tends to facilitate the process of storing the values in an individualized way and reusing them. Through the model, a personalized treatment can be suggested for each user/patient, so that the glucose levels remain between 80-120 mg/dl of blood, cooperating with the current medical recommendations.

In this way, T1D patients with the possession of this model can have the freedom to live with more tranquility, especially in moments of sleep, avoiding hyperglycemia and hypoglycemia.

REFERENCES

- [1] AUTHIER, F.; POSNER, B.; BERGERON, J. Insulin-degrading enzyme. *Clin. Investig Med.* 19 (3), 149-160. 1996
- [2] BORDINI, R.; HÜBNER, J.; WOOLDRIDGE, M. *Programming Multi-Agent Systems in AgentSpeak using Jason*. Wiley. 2007.
- [3] CENTERS FOR DISEASE CONTROL AND PREVENTION. *Diabetes Data and Trends*. Technical Report, US Department of Health and Human Services, CDC, National Diabetes Surveillance System, Atlanta, GA. URL: (www.cdc.gov/diabetes/statistics) 2012.
- [4] CILFONE, N. A.; KIRSCHNER, D. E.; LINDERMAN, J. J. Strategies for Efficient Numerical Implementation of Hybrid Multi-Scale Agent-Based Models to Describe Biological Systems. *Cellular and Molecular Bioengineering*, Vol. 8, pp. 119-136. 2015.
- [5] COBELLI, C.; RENARD, E.; KOVATCHEV, B., Artificial pancreas: past, present, future. *Diabetes* 60 (November (11)), 2672-2682. 2011.
- [6] DANEMAN, D. Type 1 diabetes. *Lancet* 367 (March (9513)), 847-858, URL: (<http://www.ncbi.nlm.nih.gov/pubmed/16530579>) . 2006.
- [7] DEVLIN, J. T. Effects of exercise on insulin sensitivity in humans. *Diabetes Care* 15 (November (11)), 1690-1693, URL <<http://www.ncbi.nlm.nih.gov/pubmed/1468302>>.
- [8] HAMMOUD, D.; MAAMRI, R.; SAHNOUN, Z. Machine Learning in an Agent: A Generic Model and an Intelligent Agent Based on Inductive Decision Learning. *Journal of Artificial Intelligence*, 4. pp. 29-44. 2011.
- [9] KISSLER, S.; CICHOWITZ, C.; SANKARANARAYANAN, S.; BORTZ, D. Determination of personalized diabetes treatment plans using a two-delay model. *Journal of Theoretical Biology* 359, pp. 101-111. 2014.
- [10] LI, J.; KUANG, Y.; CLINTON, C. Modeling the glucose-insulin regulatory system and ultradian insulin secretory oscillations with two explicit time delays. *Mason Department of Mathematics and Statistics, Arizona State University, Tempe, AZ 85287-1804, USA* Received 4 January 2006; received in revised form 9 March 2006; accepted 3 April 2006 Available online 18 May 2006.
- [11] MINISTÉRIO DA SAÚDE. Available in: <<https://www.endocrino.org.br/numeros-do-diabetes-no-brasil>>. Access in: Oct. 10 2017.
- [12] NELSON, R.K., HOROWITZ, J.F., HOLLEMAN, R.G., SWARTZ, A.M., STRATH, S.J., KRISKA, A.M., RICHARDSON, C.R. Daily physical activity predicts degree of insulin resistance: a cross-sectional observational study using the 2003-2004 National Health and Nutrition Examination Survey. *Int. J. Behav. Nutr. Phys. Act.* 10 (January (1)). 2013.
- [13] PEREIRA, J. P. A. Método de mitigação contra ataques de negação de serviço distribuídos utilizando sistemas multiagentes. Access in: <<http://www.teses.usp.br/teses/disponiveis/3/3141/tde-18032015-155642/pt-br.php>>. 2014.
- [14] PLIS, K., BUNESCU, R., MARLING, C., SHUBROOK, J., SCHWARTZ, F. A Machine Learning Approach to Predicting Blood Glucose Levels for Diabetes Management. *Modern Artificial Intelligence for Health Analytics: Papers from the AAAI-14*. 2014.
- [15] RAO, A. S. AgentSpeak(L): BDI agents speak out in a logical computable language. In *Proceedings of Modelling Autonomous Agents in a Multi-Agent World*, number 1038 in LNAI, pages 42-55. Springer Verlag, 1996.
- [16] SIMON, C., WEIBEL, L., BRANDENBERGER, G. Twenty-four-hour rhythms of plasma glucose and insulin secretion rate in regular night workers. *Am. J. Physiol. Endocrinol. Metab.* 278 (March (3)), E413-E420, URL: <http://ajpendo.physiology.org/content/278/3/E413>. 2000.
- [17] WEERDT, M.; MORS, A.; WITTEVEEN, C. Multi-agent Planning An Introduction to planning and coordination. 2005. Available in: <<http://www.st.ewi.tudelft.nl/~mathijs/publications/easss05.pdf>>. Access: Sept. 28 2011.
- [18] WANG, H., LI, J., KUANG, Y. Enhanced modelling of the glucose-insulin system and its applications in insulin therapies. *J. Biol. Dyn.* 3 (January (1)), pp. 22-38. 2009.
- [19] WOOLDRIDGE, M. *An Introduction Multi Agent Systems*. Wiley, 2^o ed. 2009.

A study of distance metrics for energy-based anomaly detection of IoT devices

PROTO, A.*; CARVALHO, T. C. M. B. *

*Sciences Laboratory - School of Electrical and Computer Engineering

E-mail: andre.proto@gmail.com, carvalho@usp.br

Abstract—Internet of Things (IoT) are usually tiny devices with low processing, memory and energy available. As an emerging technology, many open challenges about security of these devices are related on literature. In particular, some types of attacks waste energy battery of sensors directly or indirectly. Detecting those attacks with minimal device resources has been a challenge. Several Intrusion Detection Systems (IDS) exchange information between devices, demanding data transmission and increasing energy consumption. Aware of this problem, we propose an anomaly detection model that uses energy consumption analysis for intrusion detection task without demanding traffic exchange resources. Our proposal applies three distance metrics to discriminate normal and anomaly energy consumption: *Jeffrey*, *Sibson* and *Hellinger* distances. Moreover, a detection algorithm is proposed and simulated on Cooja simulator. The simulation results show a promising lightweight approach for intrusion detection in the context of IoT.

Keywords— Internet of Things; anomaly detection; energy-based; energy consumption; distance metrics.

Classification— Doctorate degree

Category— Beginner

I. INTRODUCTION

Internet of Things (IoT) has been changing our way to see the technology. Composed by heterogeneous objects able to connect to the Internet, the IoT can be applied on many home and industry applications. Essentially, an IoT system is composed by several devices/sensors with low hardware configuration. They are designed to have low memory, processor and battery, and consequently, to spend low energy. Many works have proposed models and algorithms to reach energy efficiency [1], [2] in IoT, but energy efficiency still continues to be a challenge. Security is another challenge for IoT systems. IoT has several security open challenges related to privacy, authenticity, and in particular, availability [3], [4]. For example, Denial of Service (DoS) attacks try to reach unavailability of systems [5]. A subclass of DoS attacks tries to drain battery of sensors, increasing its energy consumption. Although Intrusion Detection Systems (IDS) are consolidated for intrusion detection in traditional infrastructures, they do not work well for IoT infrastructures, because of the low power processing and energy consumption of devices [6].

Thus, our paper proposes an anomaly detection model based on energy consumption analysis of IoT devices. The goal is to apply distance metrics to discriminate normal and anomalous energy consumption. This approach is relevant because it minimizes the communication between IDS and sensor devices. We analyze three distance metrics widely used to discriminate DoS

and Flash Crowd events on network infrastructures: *Jeffrey*, *Sibson* and *Hellinger* distances. Although our simulation was applied on an IoT network with RIME stack protocol [7], the methodology can be applied for any other protocols, because it does not depend on the type of lower protocol used. The results show a promising approach to identify anomalies in sensors behavior without traffic exchange among them.

II. BACKGROUND

In the context of IoT attacks, many types of attacks are related to IoT devices and networks. Patil *et al.* in [5] described several Denial of Service attacks for wireless sensors. A set of those attacks are related to waste energy of sensors. They are called Denial of Sleep attack and Vampire attack. Another set of attacks are related to DoS but can waste energy indirectly. They are Path Based DoS attack, Carousel attack and Stretch attack. Despite the authors had proposed suggestions to detect the described attacks, they did not present simulation and results. While Grover *et al.* in [4] presented three categories of attacks for a Wireless Sensors Network (WSN): based on Routing; based on Capacity and; based on Protocol Layer. Although those classes and their attacks are not the scope of our paper, some of them may be detected by our proposed method such as HELLO attack, when an attacker broadcast a HELLO message with high transmission power, wasting energy. Lastly, Chen *et al.* in [8] implemented several proof-of-concept attacks that could drain battery on Android Systems. Although the work was focused on a mobile system, this paper described a good example of how to waste energy of devices without network traffic exchange.

In the context of IDS for IoT, Zarpelão *et al.* in [6] provided a survey of IDS for IoT architectures. Firstly, they described some of IDS placement strategies. The strategies were defined as: Distributed IDS placement, when the IDSs are deployed in each node of IoT network; Centralized IDS placement, when the IDS task is centralized on a specific node; and Hybrid IDS placement, when both previous strategies are deployed. After that, they categorized the types of intrusion detection. The categories were defined as: Anomaly-based, Signature-based, Specification-based and Hybrid. Although there were many proposed IDS for IoT, the authors discussed several difficulties to deploy intrusion detection tasks without compromising energy efficiency. While Pongle *et al.* in [9] proposed a Hybrid IDS to detect specially wormhole attack and the node attacker. They analyzed the location information of neighbors

to identify malicious nodes. Although their work had focus on 6LowPAN [10] and network information analysis, their approach was concerned about energy efficiency. The work was limited to few attacks, but some techniques can be improved or used in other works. Lastly, Lee *et al.* in [11] described a lightweight intrusion detection schema based on Energy Consumption Analysis. Such work proposed a energy consumption model and analyzed the energy consumption behavior of a single node. Thus, it tried to minimize the computational resources needed for intrusion detection. Although such work is the closest propose of our methodology, the authors did not evaluate the false positives. Moreover, the proposed schema was developed specifically for 6LowPAN.

III. ENERGY-BASED ANOMALY DETECTION MODEL

In this section we discuss our methodology for anomaly detection based on energy consumption of a sensor. It is divided in two subsections: III-A and III-B.

A. Metrics for Distance Measures

We chose three distance metrics to be applied on energy consumption data. These metrics provided good results in other works for discriminating flash crowd events and DDoS attacks based on traffic flow analysis [12], [13]. Our work applies a modified algorithm based on [12], which uses such metrics to detect anomaly behavior in energy consumption of a sensor. We chose this technique because the energy consumption behavior of a sensor might be compared as flash crowd or DDoS events of network traffic analysis scenarios. Flash crowd represents a high rate legal requests for sensing tasks, while DDoS represents illegal requests or exploration techniques with malicious objective, in particular to waste energy. The goal of distance metrics is to discriminate these behaviors.

There are two categories in distance measures: a) measure based on information theory, and b) measure of affinity. For category a), we can find *Sibson distance* and *Jeffrey distance*. The *Sibson distance* is defined in Equation (1), while *Jeffrey distance* is defined in Equation (2). Lastly, the category b) originally came from *Bhattacharyya's measure of affinity* [12] and the major metric use for this category is *Hellinger distance*, which is defined in Equation (3).

$$D_s(p, q) = \frac{1}{2}D[p, \frac{1}{2}(p+q)] + D[q, \frac{1}{2}(p+q)] \quad (1)$$

$$D_j(p, q) = \sum_{x=1}^{\eta} (\sqrt{p(x)} - \sqrt{q(x)})^2 \quad (2)$$

$$D_h(p, q) = \frac{1}{\sqrt{2}} \left[\sum_{x=1}^{\eta} (\sqrt{p(x)} - \sqrt{q(x)})^2 \right]^{\frac{1}{2}} \quad (3)$$

B. Anomaly detection algorithm

Our proposed algorithm for anomaly detection is based on *Discriminating Algorithm* described by [12]. Basically our propose is to deploy it on a sensor node. We use the Poisson distribution for our proposal because of two reasons: a) This

distribution is quite used for network data representation; and b) We believe that Poisson distribution has a good representation of expected behavior of energy consumption in a sensor. Because of factorial in Poisson equation, the energy consumption samples are converted to natural numbers k . The conversion implies on clustering of samples in portions of 0.5mW and their conversion for natural numbers by Equation $k = 2x + 1, k \in \mathbb{N}$. The proposed algorithm is described in **Algorithm 1**.

Algorithm 1: Energy-based anomaly detection algorithm.

- 1) Identify an energy consumption sample $f_i > \rho$ in a sensor i , initialize two sample slots A and B , sample size N , and a discrimination threshold δ .
 - 2) Get samples of energy consumption of f_i and save on A until the sample size = N . Represent the sample as $x_1^i, x_2^i \dots x_N^i$.
 - 3) Then, get samples of energy consumption f_i with the same size of previous sample and save them on B . Represent the sample as $y_1^i, y_2^i \dots y_n^i$.
 - 4) Calculate the probability distribution (Poisson) of the first sample as $p(x^i)$ and write it down as $p(A)$.
 - 5) Calculate the probability distribution (Poisson) of the second sample as $p(y^i)$ and write it down as $p(B)$.
 - 6) Calculate the distance between $p(A)$ and $p(B)$ using the proposed metrics *Jeffrey*, *Sibson* and *Hellinger* and write them down as D_j, D_s and D_h respectively.
 - 7) If $D_j \leq \delta$ or $D_s \leq \delta$ or $D_h \leq \delta$, so send an anomaly detection alert.
 - 8) If an anomaly detection alert was sent, then go to step 2; else go to step 1.
-

IV. SIMULATION, RESULTS AND DISCUSSION

In this section we describe the simulation parameters and results. After that, we analyze and discuss the results in the last subsection.

A. Simulation parameters

Our proposed methodology was tested in Cooja Simulator [14]. In our simulation, we used a network topology with thirteen sensor nodes and one sink node (gateway). The energy consumption model and parameters were based on Cooja [9], [15]. In simulation, we considered the total energy consumption of a node, that includes CPU, transmission, listen and idle energy consumption.

Three scenarios were simulated: (a) A standard legal traffic behavior, representing the expected tasks of a network sensors; (b) A flash crowd traffic behavior, when lots of legal requests came from sink node; and (c) A vampire attack behavior, when lots of illegal requests were sent to sensors by a malicious node. For scenario (a), the sink node requests sensing data via broadcast messages in a random time between 2-30 seconds. For scenario b), the sink node requests sensing data via broadcast messages in a short random time, between 1-5 seconds. Lastly, for scenario c) a malicious node is deployed

in topology and executes a vampire attack in some nodes by requesting sensing data repeatedly.

The proposed algorithm was implemented in all sensing nodes, excluding sink node. The samples of energy consumption were collected in a interval of 2 seconds. This interval was defined because of low precision of integers of CPU nodes (16-bits integers). Moreover, two variables were defined: ρ and δ . The ρ variable was defined as 2 mW. This value was defined based on average energy consumption of nodes when they were executing a task. The δ value was defined as 0.01 and 0.001 to validate the detection and false positives for both values. The size samples A and B was defined as $N = 5$. Lastly, λ was defined as 4 for Poisson probability distribution, that means the expected energy consumption for nodes was between 1.5 mW and 2.0 mW.

B. Results

This subsection shows the results reached with simulation. We executed the simulation for 10 minutes in each scenario. Moreover, we only show data information about node 9 to avoid excessive information on following graphics. The Figure 1 shows the energy consumption of the three scenarios. The differences of energy consumption for each scenario can be observed.




Fig. 1. Energy consumption samples of node 9 for the three scenarios.

In proposed scenarios we observed two parameters: the sensitivity of metrics (how much the metrics varied over time); and the number of false positives. Figure 2 shows the distance metrics obtained in scenario (a), when the node ran the detection algorithm 18 times. While Figure 4 shows the distance metrics obtained in scenario (b), when the node ran the detection algorithm 25 times. Lastly, Figure 4 shows the distance metrics obtained for scenario (c), when the node ran the detection algorithm 26 times. In last scenario, we analyzed the number of detections and false negatives.

C. Discussion

In this subsection we discuss the results of simulation tests in the proposed scenarios. First of all, we presented the energy consumption of node 9 on Figure 1. The energy consumption for scenario (a) was lower than others as expected. In this situation, the detection algorithm was not performed all the

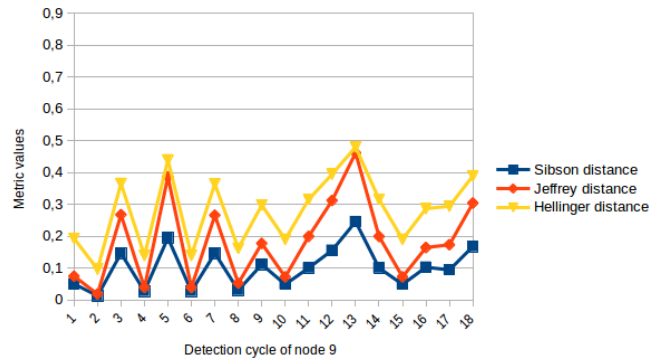


Fig. 2. Distance metrics for scenario (a).




Fig. 3. Distance metrics for scenario (b).

time due to step 1 of **Algorithm 1**, avoiding unnecessary processing of nodes. This can be observed by the number of times that the algorithm was executed: 18 against 25 and 26 times of scenarios (b) and (c). For scenario (b), we observed a high amplitude of energy consumption, with many high and low values, as expected. Although the scenario (c) also presented a high amplitude, the energy consumption had less lower values than scenario (b), keeping its most values between 10 and 20 mW. This is an important characteristic to determine the difference between a legal or illegal behavior.

Secondly, the simulation of scenario (a) showed that the three metrics had no false positives. In this scenario, the least sensitive metric was *Sibson distance*. We considered sensitive as how much the metric values fluctuated. Thirdly, the simulation of scenario (b) presented one false positive of *Sibson distance* and *Jeffrey distance* each, for $\delta = 0.01$ in 25 detection cycles, that means, 4% of total. While for $\delta = 0.001$ the number of false positives of *Jeffrey distance* was the same, but *Sibson distance* was two false positives, that means, 8%. Moreover, *Hellinger distance* had the best performance with no false positives for proposed δ values. Despite considering a satisfactory result, we could decrease the number of false positives by adjusting the δ parameter or increasing the sample size N . We can also increase the λ parameter, to adjust the Poisson probability distribution values. Fourthly, in simulation of scenario (c) the *Sibson distance*

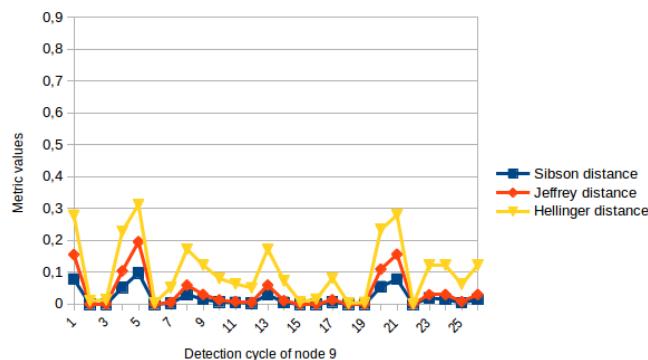


Fig. 4. Distance metrics for scenario (c).

presented the best performance, with 15 and 8 anomaly detections for $\delta = 0.01$ and $\delta = 0.001$, respectively, in 26 cycles of algorithm execution. In the same cycles, *Jeffrey distance* presented 12 and 8 anomaly detections and *Hellinger distance* presented 6 and 1 anomaly detections, for $\delta = 0.01$ and $\delta = 0.001$, respectively. Thus, *Hellinger distance* presented the worst performance, explained by the high metric values presented in results. The best accuracy of anomaly detection was 46% (by *Sibson distance*). Despite this, in simulated scenario the cycles of detection had the duration of 20 seconds. Moreover, the detection algorithm can be executed in several nodes. Thereby, the attack can be detected in few seconds, because of fast cycles and collaboration among nodes.

Lastly, we analyzed the complexity of our proposed algorithms. In general, the complexity of detection algorithm is $\theta(n)$ and the complexity of Poisson distribution equation is $\theta(n^2)$. Such complexity can be explained by the necessity to calculate a factorial for each energy consumption. Despite this, the factorial in simulated scenarios was not bigger than λ value, i.e., the number 4 in our simulation. Moreover, the complexity of detection algorithm is related to sample size N , i.e., the number 5 in our simulation. So we can conclude that the algorithm has a low number of mathematical operations. Anyway, an alternative to decrease the algorithm complexity is to change the probability distribution.

V. CONCLUSIONS AND FUTURE WORKS

In this paper we analyzed the metric distances applied to energy consumption data of IoT sensors to detect anomaly behaviors. The objective was to evaluate the accuracy of these metrics to differ legal requests from malicious attacks, whose objectives were waste energy of sensors. This approach was chosen because avoid excessive traffic exchange among nodes. That approach has been considered promising and innovative.

Thus, we analyzed the *Jeffrey*, *Sibson* and *Hellinger* distance metrics to detect anomalies and discriminate illegal from legal behaviors. The results showed that *Sibson distance* is the best metric to detect anomalies in energy consumption data analysis, although it presented some false positives in scenarios with high rate sensing requests. Despite this, some parameters can be adjusted in simulations to improve the

detection algorithm and decrease the false positives rate. Moreover, by using another distribution probability such as Normal distribution (also commonly used for anomaly detection), we can improve the algorithm complexity. Thus, in future works, we will simulate other probability distributions and implement an algorithm to set parameters like λ , δ , ρ and N automatically, based on energy consumption behavior through the time.

ACKNOWLEDGMENT

The authors would like to thank Ligia M. M. Zorello and Professor José Roberto Amazonas of São Paulo University, for helping with discussions and proofreading.

REFERENCES

- [1] KRISHNAKUMAR, A.; ANURATHA, V. Survey on Energy Efficient Load-Balanced Clustering Algorithm based on Variable Convergence Time for Wireless Sensor Networks. 2016.
- [2] POUR, N. K. Energy Efficiency in Wireless Sensor Networks. 2016. Disponível em: <<https://arxiv.org/abs/1605.02393>>.
- [3] LIN, J. et al. A Survey on Internet of Things: Architecture, Enabling Technologies, Security and Privacy, and Applications. *IEEE Internet of Things Journal*, p. 1–1, 2017. ISSN 2327-4662. Disponível em: <<http://ieeexplore.ieee.org/document/7879243/>>.
- [4] GROVER, J.; SHARMA, S. Security issues in Wireless Sensor Network - A review. In: *2016 5th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*. IEEE, 2016. p. 397–404. ISBN 978-1-5090-1489-7. Disponível em: <<http://ieeexplore.ieee.org/document/7784988/>>.
- [5] PATIL, J. R.; SHARMA, M. Survey of Prevention Techniques for Denial Service Attacks (DoS) in Wireless Sensor Network. *International Journal of Science and Research (IJSR) ISSN (Online Index Copernicus Value Impact Factor*, v. 14611, n. 3, p. 2319–7064, 2013. Disponível em: <www.ijsr.net>.
- [6] ZARPELÃO, B. B. et al. A survey of intrusion detection in Internet of Things. *Journal of Network and Computer Applications*, v. 84, p. 25–37, 2017. ISSN 10848045. Disponível em: <<http://www.sciencedirect.com.ez67.periodicos.capes.gov.br/science/article/pii/S1084804517300802>>.
- [7] DUNKELS, A.; OSTERLIND, F. An Adaptive Communication Architecture for Wireless Sensor Networks. Disponível em: <<http://dunkels.com/adam/dunkels07adaptive.pdf>>.
- [8] CHEN, T. et al. Silent Battery Draining Attack against Android Systems by Subverting Doze Mode. In: *2016 IEEE Global Communications Conference (GLOBECOM)*. IEEE, 2016. p. 1–6. ISBN 978-1-5090-1328-9. Disponível em: <<http://ieeexplore.ieee.org/document/7842268/>>.
- [9] PONGLE, P.; CHAVAN, G. Real Time Intrusion and Wormhole Attack Detection in Internet of Things. *International Journal of Computer Applications*, v. 121, n. 9, p. 975–8887, 2015. Disponível em: <<http://research.ijcaonline.org/volume121/number9/pxc3904589.pdf>>.
- [10] KUSHALNAGAR, N. et al. Transmission of IPv6 Packets over IEEE 802.15.4 Networks. Disponível em: <<https://tools.ietf.org/html/rfc4944>>.
- [11] LEE, T.-H. et al. A Lightweight Intrusion Detection Scheme Based on Energy Consumption Analysis in 6LowPAN. In: . Springer, Dordrecht, 2014. p. 1205–1213. Disponível em: <http://link.springer.com/10.1007/978-94-007-7262-5_137>.
- [12] YU, S. et al. Discriminating DDoS Flows from Flash Crowds Using Information Distance. *IEEE*, p. 351–356, 2009.
- [13] TAO, Y.; YU, S. DDoS Attack Detection at Local Area Networks Using Information Theoretical Metrics. In: *2013 12th IEEE International Conference on Trust, Security and Privacy in Computing and Communications*. IEEE, 2013. p. 233–240. ISBN 978-0-7695-5022-0. Disponível em: <<http://ieeexplore.ieee.org/document/6680846/>>.
- [14] CONTIKI. *Contiki: The Open Source Operating System for the Internet of Things*. 2017. Disponível em: <<http://www.contiki-os.org/>>.
- [15] CONTIKI. *SensorData.java - Contiki Source Code*. 2008. Disponível em: <<https://github.com/contiki-os/contiki/blob/master/tools/collect-view/src/org/contikios/contiki/collect/SensorData.java>>.

Machine learning for MRI quality assurance

Aprendizagem de máquina no controle de qualidade de RM

RAMOS, JHONATA E.*; TANCREDI, F. B.†; KIM, Hae Yong*

*Escola Politécnica - USP

†Centro de Pesquisa em Imagem - Hospital Israelita Albert Einstein
jhonata.emerick@usp.br, felipe.tancredi@einstein.br, hae@lps.usp.br

Abstract—Magnetic Resonance Imaging (MRI) is a powerful, versatile and all-important medical imaging method. The image quality of a MRI scanner is assessed from measurements in phantom images (phantom is a test object of known geometry and composition). The American College of Radiology (ACR) accreditation program recommends 7 periodic measures in its multi-purpose phantom. The image acquisition and manual analysis take approximately 30min. Such tests are essential for quality assurance; but also costly. Several automated methods have been proposed, but reports on the low-contrast resolution test are nebulous and results unconvincing. This test is entirely dependent on (the visual perception of) the operator. We propose the use of Machine Learning (ML) to emulate the operator’s ability resolving the the 120 low-contrast structures of the ACR phantom, and here report results of a short proof-of-concept study on the new method. We have used 38 sets of images acquired in a 1.5T scanner, which totaled 4,560 structures to be classified between ‘detectable’ or ‘undetectable.’ As predictors of detectability, we have utilized 22 image features – extracted from the structure itself, its surroundings and other areas –, such as mean, min and max signals, noise, size and position of the structure, shading, sharpness and ringing levels. An operator labeled each structure as ‘detectable’ and ‘undetectable.’ Among the various machine supervised learning methods that we have tested, the xgboost was the one that resulted in the best accuracy: Area Under the Curve of 97.3%. These are preliminary but extremely encouraging results. We believe that after small adjustments in our feature extraction algorithms and training of our classifier with a larger data set we will be able to demonstrate that ACR MRI tests can be fully automated with the aid of ML.

Keywords—MRI; Quality Assurance; Machine Learning.

Classification—*doctorate degree*.

Category—(*Doctorate degree*): *Beginner*

Resumo—A ressonância magnética (RM) constitui poderoso, versátil e talvez o mais importante método de imagem médica. Assim como a qualidade de geração de imagens de um scanner de RM pode ser avaliada a partir de medidas extraídas de imagens de *phantom* (um objeto teste com geometria e composição conhecidas). O programa de acreditação do Colégio Americano de Radiologia (ACR) recomenda 7 medidas periódicas em seu *phantom* multi-propósito. A aquisição e análise manual das imagens leva aproximadamente 30 minutos. Tais testes são essenciais para o controle de qualidade, porém onerosos. São várias as propostas de automação desse processo. Contudo até hoje nenhum estudo apontou uma solução satisfatória para a medida de resolução em baixo contraste – uma medida que depende exclusivamente (da percepção visual) do operador.

Nossa proposta consiste em utilizar aprendizagem de máquina para emular a capacidade do operador de resolver as 120 estruturas de baixo contraste do *phantom* ACR. Para a prova de conceito do novo método utilizamos 38 séries de imagens adquiridas em um equipamento de 1.5T, que nos forneceram um total de 4.560 estruturas a serem classificadas como ‘visíveis’ ou ‘não-visíveis’. Como preditores, utilizamos 22 features de imagem – que extraímos das estruturas, seus entornos e alhures –, tais como sinais mínimo, médio e máximo, ruído, posição e tamanho da estrutura, sombreamento, definição de bordas e nível de *ringing*. Cada estrutura foi classificada por um operador como ‘visível’ ou ‘não-visível’. Entre os diversos métodos de treinamento supervisionado que testamos, o método xgboost ofereceu o melhor resultado: 97.3% de AUC (*Area Under Curve*). São resultados preliminares, mas muito encorajadores. Acreditamos que após alguns ajustes no processo de extração de *features* e treinamento do algoritmo classificador com uma base de dados maior seremos capazes de demonstrar a tese de que o controle de qualidade RM do ACR pode ser totalmente automatizado com auxílio de ML.

Palavras-chave— Ressonância Magnética, Controle de Qualidade, Aprendizagem de Máquina.

Classificação—*Doutorado*.

Categoria—(*Doutorado*): *Iniciante*

I. INTRODUÇÃO

A Ressonância Magnética (RM) é modalidade de imagem médica que oferece a maior gama de contrastes de imagem [1]. Produz imagens onde se podem resolver estruturas ósseas como Raio-X, mas também outras onde se podem resolver estruturas com tênues diferenças de composição (ie. contraste inerentemente baixo), como um pequeno infarto no miocárdio.

Assim como qualquer instrumento de medida, um scanner de RM deve passar por testes de controle de qualidade. E como todo instrumento de imagem médica esse teste consiste em avaliar imagens de um objeto de composição e geometria conhecidas, apelidado de *phantom*. Um scanner com bom desempenho produz imagens fidedignas do *phantom* e – por extrapolação – também do corpo humano.

O programa de controle de qualidade mais conhecido e difundido é aquele preconizado pelo Colégio Americano de Radiologia (ACR) [2]. Aqui no Brasil apenas algumas instituições de ponta como o Hospital Albert Einstein aderem

ao programa; nos EUA, a acreditação pelo ACR é compulsória para quem atende o sistema público de saúde.

O programa de controle de qualidade de RM do ACR prevê 7 testes em seu *phantom* multi-propósito. A aquisição e análise manual das imagens para extração das de qualidade levam aproximadamente 30 minutos. São 25 horas de tempo de máquina e mão de obra dedicada ao programa ACR por ano, por scanner. Um custo que justifica a procura por ferramentas tecnológicas para automação o processo.

Existem algumas propostas de automação do programa de controle de qualidade em RM do ACR [3,4]. Entretanto, a automação de um dos testes permanece um problema em aberto. Encontramos um único estudo na literatura que trata do assunto [5] e os resultados apresentados não são convincentes. Tratamos aqui do teste de resolução de estruturas em baixo contraste, um teste que depende exclusivamente da percepção visual do operador. Nossa proposta consiste da utilização de *Machine Learning* (ML) para emular a tarefa humana de resolver as estruturas de baixo contraste do *phantom* ACR.

II. RESOLUÇÃO EM BAIXO CONTRASTE

O teste de resolução em baixo contraste tem como objetivo averiguar a capacidade do scanner de oferecer imagens com qualidade suficiente para permitir diferenciar estruturas com pouco contraste com relação ao fundo. São adquiridos quatro cortes axiais no *phantom* ACR, na região onde se encontram finas películas de acrílico perfurada, cada uma com 30 furos de diâmetros variados e organizados em 10 *triplets* radiais (Fig.1).




Fig 1 – Phantom do ACR para RM – imagem típica do corte axial 10

Os furos de um mesmo raio têm o mesmo diâmetro, que diminui gradativamente, no sentido horário, indo de 7mm até 1.5mm. As películas de cada tomo possuem diferentes espessuras, que é o que determina o contraste entre o fundo e os furos. Os furos possuem sinal da solução de NaCl/NiCl que preenche o *phantom*, enquanto que o sinal proveniente da região da película (fundo) é uma composição entre o sinal da solução e o sinal da estrutura de acrílico; que varia dependendo da espessura da película. A diferença entre eles – ie. o contraste – diminui progressivamente do corte 11 até o corte 8. A posição dos *triplets* também muda ligeiramente.

O teste de resolução consiste essencialmente em contar quantos dos 10 *triplets* de furos podem ser resolvidos em cada um dos tomos 11 a 8. Inicia-se a contagem a partir da fatia 11, onde o contraste é maior; e dos raios com furos de maior diâmetro para os de menor diâmetro. O *triplet* é considerado visível quando todos os 3 furos que o compõem podem ser claramente visíveis. Quanto melhor a qualidade de imagem, maior o número de raios visíveis.

III. VARIÁVEIS E MODELAGEM

O resultado do teste de baixo contraste do ACR é expresso em termos da contagem de *triplets* de furos. No entanto, o operador avalia a visibilidade de cada furo individualmente. Logo, a modelagem da leitura do operador também é realizada furo a furo. Foram testados alguns classificadores, todos baseados em treinamento supervisionado; e uma base de dados com 4.560 furos. Em todos os testes utilizamos 70% do conjunto de dados para o treinamento e 30% para teste. Imagens de *phantom* foram obtidas em equipamento de 1.5T ao longo de 40 semanas.

A seguir tratamos da definição de variáveis preditivas e da modelagem da variável resposta, ie. leituras do operador. As leituras de visibilidade foram obtidas com aplicativo desenvolvido em Matlab que permite ajustes de imagem semelhantes aos disponíveis na *workstation* do scanner (tais como *zoom*, *pan* e *janelamento*) e responde a cliques de mouse nas regiões dos furos para coleccionar as leituras: o primeiro clique assinalando variável de resposta 1-‘visível’ e subsequentes alternando valor, por ex. para 0 – ‘não-visível’.

A. Preditores

Uma estrutura é percebida numa imagem (ie. detectada, visualizada) quando estamos seguros de que algo (ie. a estrutura) se destaca do fundo. A percepção visual de estruturas depende tanto do tamanho e sinal da estrutura tanto quanto da relação desses com seus entornos. Isso sem contar os diversos problemas de qualidade de imagem, como sombreamento, distorções, efeitos de borda e de amostragem. Para modelagem da visibilidade dos furos do *phantom* ACR foram extraídos 22 *features* da imagem, localmente, na região do furo, e alhures (Tabela I). A extração de *features* locais foi baseada em mascaramento da imagem original com 3 tipos de máscaras: um consistindo da região do furo propriamente dita; um

segundo representando a região periférica ao furo; e um terceiro representando as demais adjacências. Esses ROIs foram criados através do corregistro de um template dos 30 furos com a fatia 11, onde todos os furos são sempre visíveis. O posicionamento dos ROIs nas demais fatias foi realizada por extrapolação.

Diversas *features* foram extraídas das imagens com a intenção de aumentar o poder preditivo dos modelos de ML, porém nem todas as variáveis são utilizadas no modelo final.

Tabela I. RESUMO DAS VARIÁVEIS PREDITIVAS

Feature	Descrição
SLICE	Fatia onde se encontra a estrutura (8-11)
RADIUS	Raio onde se encontra a estrutura (1-10)
POSITION	Posição da estrutura no raio (1-3)
GHOST	Nível de Ghosting da imagem
RING	Nível de artefato de borda relativo ao raio
EDGE	Definição de bordas da estrutura
S_*	Sinal na região de interesse
N_*	Desvio padrão do Sinal na região de interesse

* As features S_ e N_ são calculadas em diversas regiões de interesse da imagem. S_ ainda recebe índices de mean, min e max.

B. Métricas de Desempenho

Para a validação da capacidade preditiva dos modelos de ML foram usados o teste de Kolmogorov-Smirnov (KS), curva ROC (*Receiver Operating Characteristic*) e o coeficiente de Gini [6]. A estatística de **Kolmogorov-Smirnov (KS)** é uma estatística não paramétrica para testar se as funções de distribuição de probabilidades de dois grupos são iguais. O valor do KS do modelo é a maior diferença entre as distribuições acumuladas das probabilidades dos grupos de furos “visíveis” e “não-visíveis”. O valor da estatística pode variar entre 0 e 1, sendo que quanto mais próximo de 1, maior o poder discriminatório do modelo.

A **Curva ROC** é uma métrica para avaliação de modelos, que permite estudar a variação para as medidas de sensibilidade e especificidade, para diferentes pontos de corte.

A área sob a curva ROC (**AUC**) é um método bastante utilizado porque é uma medida global de desempenho independente de limites de corte, geralmente empregados na construção da matriz de confusão. Quanto mais próximo de 1 for a área, melhor o desempenho.

O **coeficiente de Gini** é determinado a partir da construção da curva ROC, definido como quociente entre áreas. Quanto maior o coeficiente maior será a separação entre “visíveis” e “não-visíveis”.

C. Modelos e Resultados

A variável resposta é do tipo binária (‘visível’ / ‘não-visível’), assim a técnica de classificação que surge como candidata natural é a regressão logística. Para efeito de comparação, outras duas técnicas de classificação bem populares foram avaliadas: *Support vector machine* (SVM) e XGBOOST. Todos os dados foram analisados no software R e foram utilizadas 4.560 *entries* entre treinamento e teste dos classificadores. Um resumo dos resultados pode ser encontrado na Tabela II.

a) *Regressão logística*: Candidato natural a um problema de classificação. O modelo de regressão logística binomial está incluso na família de modelo lineares generalizados (i.e., *generalized linear model*). Para a implementação utilizou-se a função `glm` do R. A regressão logística apresentou um desempenho levemente inferior ao XGBOOST quando se olha o AUC (0.972 vs. 0.971) e o GINI (0.944 vs. 0.943) em ambas as bases de treino e teste, porém o KS da regressão logística ficou consideravelmente abaixo quando comparado ao do XGBOOST (0.840 vs. 0.853).

b) *XGBOOST*: A implementação desta técnica foi realizada fazendo uso do pacote `xgboost` do R. O modelo *gradiente boost* (GB) é de regressão aditiva, na qual os termos são árvores decisórias obtidas após simples partição recursiva. O XGBOOST do R se trata de uma implementação mais eficiente e escalável do GB, além de ser uma técnica muito eficaz, que na prática gera ótimos resultados de classificação e tem sido escolhida para solução de para vários problemas de *Machine Learning*. No presente estudo a técnica apresentou desempenho superior em relação às outras duas testadas, se mesmo que a diferença seja modesta quando comparada à de regressão logística: AUC de 0.973 vs. 0.971. A Figura 2 mostra a curva ROC (na realidade as duas obtidas das amostras de treino e teste). O fato das curvas estarem próximas do canto superior esquerdo do diagrama, o que confere maior área sob a curva, demonstra seu grande poder discriminante.

c) *Support Vector Machine (SVM)*: O processo decisório em problemas de reconhecimento de padrões pode ser realizado através de funções que dividem o espaço de características (*features*) em regiões. A forma mais simples de fazer isso é através de hiperplanos. SVM baseia-se nessa estratégia ao construir um tipo especial de hiperplano, o Hiperplano de Margem Máxima. Aqui a implementação foi feita utilizando o pacote `e1071` do R. Dentre todas as técnicas testadas foi a que apresentou o pior desempenho de acordo com todas as métricas. Este modelo precisa ser revisto em relação ao *overfitting*.

Tabela II. DESEMPENHO DOS MODELOS DE CLASSIFICACAO

Base/Métrica	KS	GINI	AUC
Regressão Logística			
Treino	0.840	0.944	0.972
Teste	0.853	0.943	0.971
SVM			
Treino	0.978	0.975	0.987
Teste	0.696	0.651	0.825
XGBOOST			
Treino	0.960	0.991	0.995
Teste	0.907	0.946	0.973

IV. CONCLUSÃO

Este trabalho analisou o desempenho de 3 métodos de *Machine Learning*, com o objetivo de modelar a capacidade de percepção humana em uma tarefa específica: resolver estruturas de baixo contraste em imagens de *phantom* de RM, isto é de classificar estruturas como visíveis ou não-visíveis em condições de baixo contraste. Entre os 3 modelos testados, a estratégia XGBOOST apresentou resultados superiores. Vários atributos do modelo podem ainda ser alterados na tentativa de melhorar seu desempenho, como por exemplo, taxa de aprendizado, profundidade da árvore decisória.




Fig 2 - Curva ROC DO MODELO XGBOOST

Como futuro desenvolvimento pretendemos realizar ajustes no processo de extração de *features*, e usar uma base de dados 100 vezes maior, que leve em conta mais imagens e leitores. Com esses ajustes esperamos que o método se torne pelo menos 200 vezes mais confiável (ie. não cometa mais do que 1 erro de leitura a cada 10 anos de teste) para com isso demonstrar que com ajuda de técnicas de aprendizagem de máquina os testes de controle de qualidade de RM do ACR podem ser completamente automatizados.

AGRADECIMENTOS

Agradecemos ao Hospital Israelita Albert Einstein, pela permissão de análise das imagens de *phantom*, e à Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, pelo apoio financeiro ao projeto (processo nº 2015/27022-0, auxílio recebido por FBT).

REFERÊNCIAS

- [1] BROWN, Robert W. et al. Magnetic resonance imaging: physical principles and sequence design. John Wiley & Sons, 2014.
- [2] Site do ACR: <http://www.acraccreditation.org>
- [3] M-n L. P. Panych, J.-Y. G. Chiou, L. Qin, V. L. Kimbrell, L. Bussolari, and R. V. Mulkern, "On replacing the manual measurement of ACR phantom images performed by MRI technologists with an automated measurement approach," J Magn Reson Imaging, pp. n/a–n/a, Sep. 2015.
- [4] M. Davids, F. G. Zöllner, M. Ruttorf, F. Nees, H. Flor, G. Schumann, L. R. Schad, and T. I. Consortium, "Fully-automated quality assurance in multi-center studies using MRI phantom measurements," Magn Reson Imag, vol. 32, no. 6, pp. 771–780, Jul. 2014.
- [5] J. Sun, M. Barnes, J. Dowling, F. Menk, P. Stanwell, and P. B. Greer, "An open source automatic quality assurance (OSAQA) tool for the ACR MRI phantom," Australasian Physical & Engineering Sciences in Medicine, vol. 38, no. 1, pp. 39–46, Oct. 2015.
- [6] ZHANG, Lingling et al. The Measurement of Distinguishing Ability of Classification in Data Mining Model and Its Statistical Significance. In: International Conference on Computational Science. Springer, Berlin, Heidelberg, 2009. p. 578-587.

Integrating Agent Advice and Previous Task Solutions in Multiagent Reinforcement Learning

SILVA, F. L.*; COSTA, A. H. R.*;

*Intelligent Techniques Laboratory (LTI)

Escola Politécnica of the University of São Paulo.

E-mail: {f.leno,anna.reali}@usp.br

Abstract—Reinforcement learning methods have successfully been applied to build autonomous agents that solve challenging sequential decision-making problems. However, agents need a long time to learn a task, especially when multiple autonomous agents are in the environment. This research aims to propose a Transfer Learning framework to accelerate learning by exploiting two knowledge sources: (i) previously learned tasks; and (ii) advice from a more experienced agent. The definition of such framework requires answering several challenging research questions, including: *How to abstract and represent knowledge, in order to allow generalization and posterior reuse?*, *How and when to transfer and receive knowledge in an efficient manner?*, and *How to consistently combine knowledge from several sources?*

Keywords— Artificial Intelligence; Machine Learning; Reinforcement Learning; Multiagent Systems

Classification— Doctorate.

Category— Intermediate.

I. CONTEXT AND MOTIVATION

Reinforcement Learning (RL) [1] is an extensively used technique for autonomous agents with the ability to learn through experimentation. First an action that affects the environment is chosen, then the agent observes how much that action collaborated to the task completion through a reward function.

An agent can learn how to optimally solve tasks by executing this procedure multiple times. The main limitation of RL is that agents take a long time to learn how to solve tasks. However, like in human learning, previous knowledge can greatly accelerate the learning of a new task. For example, it is easier to learn Spanish beforehand knowing Portuguese (or a similar language).

Many RL domains can be treated as *Multiagent Systems* (MAS) [2], in which multiple agents are acting in a shared environment. We are especially interested in Cooperative Multiagent RL (MARL) [3], in which all agents work cooperatively to solve the same task. In such domains, other type of knowledge reuse is applicable. Agents can communicate to transfer learned behaviors.

In the language learning example, being taught by a fluent speaker of the desired language can accelerate learning, because the teacher can identify learner's mistakes and provide customized explanations and examples. However, learning how to actuate in a MAS may be a difficult task, since the environment becomes non-stationary due to the parallel actuation of multiple agents [4].

Transfer Learning (TL) [5] allows to reuse knowledge acquired in previous tasks, and has been used to accelerate learning in RL domains and alleviate scalability issues. In MARL, TL can either reuse knowledge from previously learned tasks or from agent communication, in which one agent can transfer learned behaviors to another agent.

Even though TL has been used in many ways in MARL [6], [7], there is no consensual answer to many aspects that must be defined in order to specify a TL algorithm. This research aims to specify a TL framework to allow knowledge reuse in multiagent domains from both previously learned tasks (when available) and agent tutoring, two scenarios that are common in human learning.

II. RESEARCH GOALS AND EXPECTED CONTRIBUTIONS

This research aims to **propose a Transfer Learning framework** to allow knowledge reuse in **Multiagent Reinforcement Learning**, both from previous tasks and between agents [8], [9]. In order to specify a method to fulfill the expected contributions, we would need to define:

- 1) A model which allows knowledge generalization;
- 2) What information is transferred through tasks or agents;
- 3) How to define when the knowledge of a given agent must be transferred to another.

Figure 1 depicts the proposed framework. The agent extracts knowledge from advice given by other agents and combines it with previously solved tasks to accelerate the learning of a new task. The solution of this new task can then be abstracted and added to the knowledge base. In the long-term, the agent is expected to learn tasks much faster due to the task solutions stored in his knowledge base and the received advice, which is specific for the current task.




Fig. 1. The proposed Transfer Learning framework.

Even though we here focus on Multiagent RL Systems, the main ideas of our proposal are applicable in the Multiagent Systems, Reinforcement Learning, and Machine Learning areas in general.

III. BACKGROUND AND RELATED WORK

Single-agent sequential decision problems are often modeled as a *Markov Decision Process* (MDP), which can be solved by RL. An MDP is described by the tuple $\langle S, A, T, R \rangle$ [10], where S is the set of environment states, A is the set of actions available to an agent, T is the transition function, and R is the reward function, which gives a feedback toward task completion.

At each decision step, an agent observes the state s and chooses an action a (among the applicable ones in s). Then the next state is defined by T . The agent must learn a policy π that maps the best action for each possible state. The solution of an MDP is an optimal policy π^* , a function that chooses an action maximizing future rewards at every state.

In learning problems (where R and T are unknown) the agent can iteratively learn a Q-table, i.e. a function that maps every combination of state and action to an estimate of the long-term reward starting from the current state-action pair, which eventually converges to the true Q function [11]: $Q^*(s, a) = E [\sum_{i=0}^{\infty} \gamma^i r_i]$, where γ is a discount rate and r_i is the reward received after i steps from using action a on state s . Q^* can be used to define an optimal policy as: $\pi^*(s) = \arg \max_a Q^*(s, a)$.

However, learning Q^* may take a long time, and TL methods can be used to accelerate convergence. The basic idea in any TL algorithm is to reuse previously acquired knowledge in a new task. In order to use TL in practice, three aspects must be defined [12]: *What*, *when*, and *how* to transfer. Even though many methods have been developed, there is no consensual definition of how to represent knowledge and how to transfer it. Therefore, the success of a TL method depends on the knowledge representation. The standard MDP formulation is not a good representation for knowledge abstraction, which is of utmost importance when transferring knowledge between two similar tasks.

Relational representations achieved great success in knowledge abstraction and TL [13]. *Object-Oriented MDP* (OO-MDP) [14] is a relational representation that allows generalization opportunities by modeling similar entities of a domain as *objects* that follow the description of a *class*.

An OO-MDP requires the definition of a set of *classes* C , where each class C_i is composed of a set of *attributes*, and each attribute has a *domain*, which specifies the set of values this attribute can assume. The state is defined by the set of objects that exist in the environment. As the objects of the same class follow the same description, the learner can abstract experiences by assuming that objects of the same class are affected in the same way by actions. For example, a robot learning how to navigate in an environment can learn that moving towards a specific wall results in a disadvantageous collision. Then, the robot can assume that moving towards any

wall would be harmful, thus avoiding all wall collisions even though the agent has never collided with many of the walls in the environment.

Although OO-MDP seems promising to TL, so far no OO-MDP extensions to MAS are available in the literature. Thus, the specification of an OO-MDP extension to MAS is a good first step toward a knowledge representation that could lead to successful TL.

It is also important to model how multiple agents can interact and share knowledge among themselves. In the *teacher-student* framework [15], a more experienced agent (teacher) suggests actions to a learning agent (student). This paradigm is very flexible because the student and teacher roles may be played by both humans and autonomous agents, regardless of the internal representation or learning algorithm of the agents [15]. However, works following the *teacher-student* paradigm assume that teachers follow a fixed (and good) policy. This means that, in order to apply this idea in a Multiagent RL domain, teacher-student relations could only be established after teachers have trained enough to achieve a fixed policy, but we are concerned about systems composed of simultaneously learning agents, where this assumption does not hold. For the reuse of knowledge from previous tasks, varied types of information have been successfully transferred, such as samples of low-level interactions with the environment, policies, value functions, abstract or partial policies [13], and heuristics or biases for a more effective exploration [16], each of them presenting benefits over learning from scratch [5]. As no work combined advice-based procedures with those methods, we are not sure yet on which information would be optimal for transfer in our setting.

IV. PARTIAL RESULTS AND FUTURE WORK

In order to define a representation which allows knowledge generalization, we proposed an OO-MDP extension to MAS, called *Multiagent Object-Oriented MDP* (MOO-MDP). This extension is introduced in our BRACIS paper [17] and fully described in a paper submitted to a journal [18], in which an algorithm to solve deterministic cooperative MOO-MDPs is also presented.

MOO-MDP is inspired by the insight that each agent in a MAS can be seen as an object, hence the environment is described by a set of agents and environment objects, in which the former can perform autonomous actions and the latter are unreasoning entities. While MOO-MDP enables state space abstraction by generalizing experiences for all objects of the same class, coordinated behaviors can still be learned since agents can identify other reasoning entities and act according to previous experiences with that same class of agents.

Our proposal allows a state abstraction as illustrated in Figure 2. This kind of state abstraction accelerate learning and provides generalization, which is also useful for Transfer Learning [13]. Under certain conditions, our algorithm *Distributed Object-Oriented Q-Learning* (DOO-Q) was proved to learn the optimal policy while providing generalization. The proof of the following proposition is available in [17].

Proposition 1: Each agent in a MAS composed of DOO-Q learners, at convergence time, learns a policy that results in an optimal joint policy under certain conditions.

In addition to be proven to learn an optimal policy, in practice our proposal also achieves better results than other state of the art methods.

Figure 3 shows the Cumulative Reward achieved by each of the learning algorithms when solving the *Goldmine* task, an extensively studied benchmark in the Multiagent community. The algorithms were executed with a timeout, and the *MAQL* was not able to complete the training process. DOO-Q allowed to achieve good rewards much faster, due to the aforementioned generalization.




Fig. 2. Graphical representation of the state space abstraction. The left side represents two concrete states (ids on top of gold pieces) that are described by a single abstract state in the right side.




Fig. 3. Observed discounted cumulative reward in the *Goldmine* learning problem. The DOO-Q curve refers to our proposal, while the other curves refer to related state of the art methods. The shaded area correspond to the 95% confidence interval.

Furthermore, as an additional step towards the framework described in Section II, we developed an advising framework based on *teacher-student*, called *Ad Hoc Advising*, specialized to tasks in which multiple agents are learning together. This work was published in the AAMAS conference [19].

The agent relations in our proposal are termed advisor-advisee relations, where the advisor not necessarily has to perform optimally. Instead of having a fixed teacher, the advisee evaluates its confidence in the current state, and broadcasts an advice request for all the reachable agents in

case its confidence is low. Each prospective advisor then evaluates its own confidence in the advisee's state. In case the advisor's confidence is high, an ad hoc advisor-advisee relation is initiated and the advisor suggests an action. Advice works as a heuristic for the exploration strategy, thus it does not affect the convergence of most base learning algorithms (after the maximum number of advice is spent the agents return to their standard exploration strategy). Our proposal seems to be a promising way to provide the advising ability of Figure 1. So far, we have explored the benefits of the ad hoc advising in robot soccer simulations and our proposal presented a speed-up when compared to state-of-the-art advising techniques. Figure 4 is an example of achieved improvement in performance at the end of training.




Fig. 4. The average percentage of goals scored by each algorithm at the end of the training process. AdHocTD and AdHocVisit are two parametrizations of our proposal.

The next long term step for our proposal is to define how to build and reuse the Abstract Knowledge Base. The agents must be able to compute task similarities to select the most similar task(s) from the knowledge base and reuse its solution. Also, task solutions need to be abstracted before stored in the knowledge base, since overfitted solutions are not likely to be useful in new tasks. While a common procedure in the literature is to provide hand-coded task mappings, autonomously computing task similarities is hard. Our first work in this direction estimates Probabilistic Inter-TASK Mappings (PITAM) [20] through the before-mentioned object-oriented task description. The main idea is to receive a relational description of each task and a class mapping to relate entities in the two tasks. Based on that, the algorithm estimates a probabilistic mapping from one task to another, which can be used to transfer knowledge. However, the optimal procedure to transfer knowledge using PITAM, how to properly select source tasks to transfer from, and how to combine this procedure with *ad hoc advising* are still open problems.

We are now exploring techniques based on *Curriculum Learning* [21], in which the main purpose is to decompose a complex task into several easier ones. The easiest tasks are trained first, and then we can reuse the knowledge from them to learn the complex task faster (e.g., using PITAM).

ACKNOWLEDGEMENT

We acknowledge financial support from CNPq (grant 311608/2014-0) and São Paulo Research Foundation (FAPESP), grants 2015/16310-4 and 2016/21047-3.

REFERENCES

- [1] SUTTON, R. S.; BARTO, A. G. *Reinforcement Learning: An Introduction*. 1st. ed. Cambridge, MA, USA: MIT Press, 1998. ISBN 0262193981.
- [2] WOOLDRIDGE, M. J. *An Introduction to MultiAgent Systems (2. ed.)*. [S.l.]: Wiley, 2009. ISBN 978-0-470-51946-2.
- [3] BAZZAN, A. L. C. Beyond Reinforcement Learning and Local View in Multiagent Systems. *Künstliche Intelligenz*, v. 28, n. 3, p. 179–189, 2014.
- [4] BUSONI, L.; BABUSKA, R.; SCHUTTER, B. D. A Comprehensive Survey of Multiagent Reinforcement Learning. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, v. 38, n. 2, p. 156–172, 2008. ISSN 1094-6977.
- [5] TAYLOR, M. E.; STONE, P. Transfer Learning for Reinforcement Learning Domains: A Survey. *Journal of Machine Learning Research*, v. 10, p. 1633–1685, 2009.
- [6] HU, Y.; GAO, Y.; AN, B. Learning in multi-agent systems with sparse interactions by knowledge transfer and game abstraction. In: *Proceedings of the 14th International Conference on Autonomous Agents and MultiAgent Systems (AAMAS)*. [S.l.: s.n.], 2015. p. 753–761.
- [7] TAYLOR, A. et al. Transfer Learning in Multi-Agent Systems Through Parallel Transfer. In: *Proceedings of the Workshop on Theoretically Grounded Transfer Learning*. [S.l.: s.n.], 2013.
- [8] SILVA, F. L.; COSTA, A. H. R. Transfer Learning for Multiagent Reinforcement Learning Systems. In: *Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence (IJCAI)*. [S.l.: s.n.], 2016. p. 3982–3983.
- [9] SILVA, F. L.; COSTA, A. H. R. Accelerating Multiagent Reinforcement Learning through Transfer Learning. In: *Proceedings of the 31st AAAI Conference on Artificial Intelligence*. [S.l.: s.n.], 2017. p. 5034–5035.
- [10] PUTERMAN, M. L. *Markov Decision Processes : Discrete Stochastic Dynamic Programming*. Hoboken (N. J.): J. Wiley & Sons, 2005. ISBN 0-471-72782-2.
- [11] WATKINS, C. J.; DAYAN, P. Q-learning. *Machine learning*, Springer Netherlands, v. 8, n. 3, p. 279–292, 1992.
- [12] PAN, S. J.; YANG, Q. A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, v. 22, n. 10, p. 1345–1359, 2010.
- [13] KOGA, M. L.; SILVA, V. F.; COSTA, A. H. R. Stochastic Abstract Policies: Generalizing Knowledge to Improve Reinforcement Learning. *IEEE Transactions on Cybernetics*, v. 45, n. 1, p. 77–88, 2015.
- [14] DIUK, C.; COHEN, A.; LITTMAN, M. L. An Object-oriented Representation for Efficient Reinforcement Learning. In: *Proceedings of the 26th International Conference on Machine Learning (ICML)*. [S.l.: s.n.], 2008. p. 240–247. ISBN 978-1-60558-205-4.
- [15] TAYLOR, M. E. et al. Reinforcement Learning Agents Providing Advice in Complex Video Games. *Connection Science*, v. 26, n. 1, p. 45–63, 2014.
- [16] BOUTSIUKIS, G.; PARTALAS, I.; VLAHAVAS, I. Transfer Learning in Multi-agent Reinforcement Learning Domains. In: *Proceedings of the 9th European Workshop on Reinforcement Learning*. [S.l.: s.n.], 2011.
- [17] SILVA, F. L.; GLATT, R.; COSTA, A. H. R. Object-Oriented Reinforcement Learning in Cooperative Multiagent Domains. In: *5th Brazilian Conference on Intelligent Systems (BRACIS)*. [S.l.: s.n.], 2016. p. 19–24.
- [18] SILVA, F. L.; GLATT, R.; COSTA, A. H. R. MOO-MDP: An Object-Oriented Representation for Cooperative Multiagent Reinforcement Learning. *IEEE Transactions on Cybernetics*, (Submitted), 2017.
- [19] SILVA, F. L.; GLATT, R.; COSTA, A. H. R. Simultaneously Learning and Advising in Multiagent Reinforcement Learning. In: *International Conference on Autonomous Agents and Multi-agent Systems (AAMAS)*. [S.l.: s.n.], 2017. p. 1100–1108.
- [20] SILVA, F. L.; COSTA, A. H. R. Towards Zero-Shot Autonomous Inter-Task Mapping through Object-Oriented Task Description. In: *Workshop on Transfer in Reinforcement Learning (TiRL) at AAMAS*. [S.l.: s.n.], 2017.
- [21] SILVA, F. L.; COSTA, A. H. R. Automatic Object-Oriented Curriculum Generation for Reinforcement Learning. In: *Proceedings of the 1st Workshop on Scaling-Up Reinforcement Learning (SURL)*. [S.l.: s.n.], 2017.

3D medical objects processing and retrieval using Spherical Harmonics: a case study with Congestive Heart Failure MRI exams

BERGAMASCO, L. C. C.*; ROCHITTE, C. E. †; NUNES, F. L. S.*‡

*Interactive Technologies Laboratory (INTERLAB) - Graduate Program in Electrical Engineering
Polytechnic School - University of Sao Paulo (PPgEE/POLI/USP)

†Cardiology and Pulmonary Division - Heart Institute, InCor - University of Sao Paulo Medical School

‡ Laboratory of Computer Applications for Healthcare (LApIS) - Graduate Program in Information System
School of Arts, Science and Humanities - University of Sao Paulo (PPgSI/EACH/USP)

E-mail: {leila.cristina, fatima.nunes}@usp.br, rochitte@incor.usp.br

Abstract—Spherical Harmonics (SPHARMs) have been widely used in the three-dimensional (3D) object processing domain. The set of harmonics coefficients generated by this mathematical theory are considered a robust source of information about analyzed 3D objects. Some works already use SPHARMs to compare 3D objects, but their application in the medical object retrieval domain is innovative. This work presents the use of SPHARMs to aid the diagnosis of Congestive Heart Failure (CHF) disease, by retrieving similar cases given a 3D objects of the heart as a query argument. We validated our approach by executing retrievals from cases with and without CHF. The results indicated an average precision of 85%. Robustness of SPHARMs in a specific application domain is corroborated, showing that they can be a promising descriptor for 3D medical objects.

Keywords— Spherical Harmonics; 3D object retrieval; Congestive Heart Failure; left ventricle; 3D signal-based analysis

Classification— Doctorate degree

Category— Intermediate

I. INTRODUCTION

Congestive Heart Failure (CHF) is a common chronic cardiac disease and it affects about 22 million people in the world. The main characteristic of CHF is the inability of the heart pump the necessary blood to different organs, causing an extra effort on the heart. In a long term, this overload can deform the ventricles structures [1]. These ventricle deformations are small and their identification requires the analysis of many two-dimensional (2D) images (slices). This is a difficult task, especially when the physician do not have much expertise. Thus, it is necessary to improve methods to process, store and retrieve this high volume of information in an efficient way.

The Content-Based Image Retrieval (CBIR) uses the images content to find similar images in a database. This technique has been widely used in different domains, including healthcare area, since it can improve the search precision and performance. CBIR was first used for 2D images, but in the last two decades some researches focused on CBIR for three-dimensional (3D) objects, also known as 3D CBIR [2].

Within this context, Spherical Harmonics (SPHARMs) have been used as a signal-based descriptor for 3D objects [3].

SPHARMs are a solution to Laplace's equation in spherical coordinates. As a spherical function can be expressed by a linear combination of their harmonics coefficients, these coefficients can be used for different purposes in Computer Graphics domain such as 3D modeling, 3D lightning diffusion, and 3D object representation [4]. Thus, for this last option, it is feasible to use harmonics coefficients as a features vector, which represents the 3D object shape.

Several works already highlighted the SPHARMs potential for this purpose [5]–[7], aiming at favoring shape analysis of medical images, considering the SPHARMs strength to differentiate different shapes. However, their use in the 3D CBIR for medical applications is innovative.

Considering the scenario above mentioned, this paper aims to present the implementation, as well as an analysis of the SPHARMs performance in a specific medical problem, the CHF disease. SPHARMs were applied into two groups of 3D objects reconstructed from heart Magnetic Resonance Imaging (MRI) images: a group with CHF disease and another control group without the disease.

This article is organized as follow: Sections II and III introduce two important concepts used in this paper: CBIR and SPHARMs, respectively; Section IV details the methodology used; Section V presents and discusses the results found, and Section VI presents the final considerations and conclusion of this work.

II. 3D CONTENT-BASED IMAGE RETRIEVAL

CBIR retrieves from a database images that are more similar to an image provided as a query. The same concept is applied in the 3D domain, i.e., 3D CBIR retrieves from a database, 3D objects similar to a 3D object given as a query. CBIR systems can be divided into some steps: preprocessing, features extraction, and similarity comparison, which uses methods that are capable of measuring similarity among different objects.

In the preprocessing stage, algorithms are applied to enhance regions of interest or decrease noise. In 3D domain. In the features extraction step, quantitative information is

extracted from different aspects of the 3D object such as shape, topological information, color, texture, statistics, among others. Finally, to compute the similarity among features vectors we can use distance functions, such as Euclidean or Manhattan distance, or other computational method such as matching, k-means, and machine learning [3], [8].

Regarding CBIR in 3D domain, there is a predominance of global descriptors, which considers the whole 3D object information. However, many times healthcare area has problems where the differences among 3D objects are subtle and present changes only in specific locals. Thus, it is important to investigate how global descriptors can be adapted or how we can create new descriptors with local perspective.

III. SPHERICAL HARMONICS

SPHARMs are spherical functions that satisfy the Laplace's equation. These functions can be expressed as a linear combination of their harmonic coefficients (Equation 1). In Equation 1, the term a_{lm} is the complex harmonic coefficient matrix and $Y_l^m(\theta, \phi)$ are SPHARMs of degree l and order m for the spherical coordinates (θ, ϕ) . Usually the m value respects the interval $[-l, l]$ and $l \in \mathbb{N} [0, \infty]$.

$$f(\theta, \phi) = \sum_l \sum_{m=-l}^l a_{lm} Y_l^m(\theta, \phi) \quad (1)$$

SPHARMs computation is not trivial and briefly, we can define each part as follows [4]:

- 1) Harmonics computation: the term $Y_l^m(\theta, \phi)$ in Equation 1 is the harmonic for a specific degree l , order m and spherical coordinates (θ, ϕ) . The spherical coordinate θ represents the polar angle, and ϕ represents the azimuth. Computation of this term is presented in Equation 2, where N_l^m is the normalization factor, $P_l^m(\cos\phi)$ is the Associate Legendre Polynomial and $e^{im\phi}$ is the complex exponential. These terms are defined in the next equations:

$$Y_l^m(\theta, \phi) = N_l^m P_l^m(\cos\phi) e^{im\phi} \quad (2)$$

- a) Normalization factor is a binomial using the l and m values as input (Equation 3).

$$N_l^m = \sqrt{\frac{2l+1}{4\pi} \frac{(l-m)!}{(l+m)!}} \quad (3)$$

- b) Associated Legendre Polynomials: are solutions for the general Legendre equation [9]. These polynomials can be expressed using an explicit sum, as shown in Equation 4, where l and m are the same values as used previously on Equation 2, and k is a variable with initial value equal zero, which depends on l and m values to determine its maximum value.

$$P_l^m(x) = (1-x^2)^{\frac{m}{2}} \sum_{k=0}^{\frac{l-m}{2}} \frac{(2l-2k)!}{2^l (l-k)! k! (l-2k-m)!} x^{l-k-m} \quad (4)$$

$$\omega = (-1)^k x^{(l-2k-m)} \quad (5)$$

- c) Complex exponential: according to Equation 6, this term is computed using Euler's identity, where i means the imaginary part of the complex number, ϕ is the azimuth angle and m is the SPHARM order.

$$e^{im\phi} = \cos(m\phi) + i\sin(m\phi) \quad (6)$$

- 2) Coefficients a_{lm} : are projections of $f(\theta, \phi)$ on each basis function $Y_l^m(\theta, \phi)$ over the sphere, as showed in Equation 7.

$$a_{lm} = \int_{\theta=0}^{\pi} \int_{\phi=0}^{2\pi} f(\theta, \phi) Y_l^m(\theta, \phi) \sin(\theta) d\phi d\theta \quad (7)$$

After the computation of all those steps, we have as output a feature vector of size $1 \times N$, where N is the number of vertices of the mesh that represents the 3D object and this feature vector has dimension equal to one since as it is possible verify on Equation 1 we computed the sum according to the l value defined.

Most of the researches that used the SPHARMs in 3D medical objects retrieval aimed to analyze shapes or quantify some 3D object characteristics such as 3D volume and surface area. However, none of them used the concept of CBIR, i.e., the authors did not use the quantitative information extracted as a feature vector and compared these vectors through similarity functions [5]–[7], [10]–[13]. A common characteristic among all the selected papers was the utilization of SPHARM coefficients (a_{lm}) as the main data considered for comparison/reconstruction.

IV. METHODOLOGY

The methodology used in this present research was formulated aiming to evaluate quantitatively the SPHARMs performance to retrieve 3D medical objects. The test dataset was composed by 30 set of slices from MRI exams, which were segmented, reconstructed and submitted to a retrieval system based in SPHARMs.

As mentioned, to validate our approach, we used 30 cases, i.e., 30 3D objects of left ventricle reconstructed from MRI images. From these cases, 47% are related to subjects without the CHF disease and 53% are subjects that have the disease. Each 3D object was reconstructed from a set of cardiac MRI slices from short axis in a diastolic phase (when the left ventricle gets its maximum aperture).

We manually segmented the 2D MRI images by using open source software [14]. After segmentation, the contours of the ventricles segmented in all the slices of each set were joined to form a 3D object (a surface), also using open source software [15]. Each mesh reconstructed has about 11000 vertices.

The implementation tests and validation of the SPHARMs were done in a computer with processor Intel i5, with 8GB of RAM and using Windows 7 OS - 64bits. The algorithm was developed using Java JDK 1.8 in the Eclipse Helius IDE [16].

As mentioned, for segmentation we use the software Seg3D [14] and for reconstruction the software ImageVis 3D [15]. For validation we used the *R* library [17] to process the results.

A. Evaluation

To evaluate the SPHARMs' performance to retrieve similar 3D objects we use the method proposed by Kazhdan *et al.* [18] to compute the similarity for each l value between two SPHARMs set $f(\theta, \phi)$. This method is an adaptation of the Euclidean Distance for SPHARMs, shown in Equation 8, where $f(\theta, \phi)$ and $f'(\theta, \phi)$ are two distinct spherical functions and the comparison is made considering the each l value.

$$Distance = \sum_{l=0}^{\infty} (f(\theta, \phi) - f'(\theta, \phi))^2 \quad (8)$$

In order to propitiate a more complete evaluation, we used different metrics to validate our approach: dendograms with hierarchical clustering to visualize how the groups' hierarchy was built, silhouette to validate the cluster separation, and Precision *vs.* Recall curve to compare the retrieval precision for each subset of cases (CHF and non-CHF subjects).

Silhouette coefficient is a well known metric to analyze the cluster division. This coefficient is defined in the interval $[0, 1]$, and higher values indicate strong division in the cluster, with well-divided groups; otherwise, lower values indicate the opposite [19]. In our experiment it was created two clusters: one for CHF group and other for non-CHF group.

Precision *vs.* Recall curve is a common measurement used for information retrieval problems [20]. The precision metric indicates the percentage of relevant objects retrieved in relation to the total of objects retrieved. The recall indicates the percentage of objects retrieved that are relevant in relation to the of total relevant objects present in the database. The larger the area between the curve generated and the x axis, the greater is the system accuracy, the values in both axis are in the normalized range $[0,1]$ or can be expressed in percentage $[0,100]$.

V. RESULTS AND DISCUSSION

As mentioned in Section IV, we use 30 subjects to validate our approach. We performed several tests to find a better l value and identified values less than 10 have a lower precision, and values greater than 10 cause processing time increase without increase accuracy. Thus, $l = 10$ has a good balance between precision *vs.* processing time.

Figure 1 presents the Dendrogram built after the SPHARMs extraction and comparison, which provides a high level view about the similarities between each case. The green box in the left part contains most of the cases related to CHF disease, while the blue box contains most of the non-CHF cases. In addition, the circles show some outliers identified, as the cases 19 and 26, which are non-CHF cases but during the comparison they appear within the CHF cluster. An explanation for this behavior can be the similarity function used (Euclidean Distance), which is a global metric and very sensitive; any discrepancy in the SPHARMs coefficients could impact the




Fig. 1: Results of the control group using a Dendrogram: the green box is related to CHF cases and blue box are subjects without the disease

final result. We intend to execute more experiments with different distance functions in order to verify the influence of the comparison similarity method in our approach.

Still related to the SPHARMs shape discrimination ability, we found a silhouette coefficient of 0.68. Although it can seem that this result is not so favorable, it is another form of interpreting the results, considering the individual dissimilarity among the objects. This coefficient measures the difference between members of all the classes in a problem. Thus, in this case, the value obtained confirms that objects have similarity, even if they belong to different classes. Therefore, this value confirms that SPHARMs propitiate good discrimination for the problem, i.e., although objects have only subtle differences, SPHARMs can separate the two classes with efficiency, even if there are some outliers.

Related to the 3D CBIR task, we obtained the Precision *vs.* Recall curve presented in Figure 2. This graphic shows that we had about an average precision of 85.8% for CHF cases and 79.8% for non-CHF cases. It is a better result found than another previous works, which uses SPHARMs in household 3D objects [18], which presented precision about 60-70%. Related to the CHF problem, our results outstanding previous descriptors [21], [22] which obtained a precision average of 80%.

Additionally, to calculate this curve we considered the 16 first 3D objects retrieved (for CHF subjects) and the 14 first 3D objects for non-CHF subjects. When we consider only the first five objects retrieved, we improve this value: 89% for CHF and 84% for non-CHF cases. This behavior is related to the silhouette value found. As the shape deformations are subtle it is expected that the retrieval becomes more difficult as the remaining 3D objects in the database have shape alterations decrease.

VI. CONCLUSION

In this paper we presented a novel approach using SPHARMs in a 3D CBIR system, considering 3D medical objects from left ventricle. The problem presented is related to the CHF disease, which has as the main symptom the shape alterations on left ventricle. These deformations are subtle and




Fig. 2: Precision vs. recall curve for CHF and non-CHF cases.

it is difficult to identify using common shape descriptors. Thus, SPHARMs presented a promising descriptor in this case.

To validate our approach, we built a case study with 30 subjects and we got very interesting results, as an average precision of more than 80%. Silhouette coefficient confirm the SPHARMs ability to differentiate the left ventricle shapes. It is important to highlight the problem nature, which presents very small shape deformations on left ventricles as indicative of the CHF disease. This particularity always will give similar values for dissimilarity metrics, which adds a degree of complexity on system accuracy.

Although these challenges, SPHARMs outperformed others approaches, and in future work we will test them with different comparison similarity methods as bipartite graphs [21] with the aim of improving the retrieval performance.

VII. ACKNOWLEDGMENTS

This work is supported by Brazilian National Council of Scientific and Technological Development, and the National Institute of Science and Technology Medicine Assisted by Scientific Computing.

REFERENCES

- [1] ASSOCIATION, A. H. *Heart Failure*. Disponível em: <<http://www.heart.org/HEARTORG/Conditions/HeartFailure>>.
- [2] VRANIC, D. V.; SAUPE, D. *3D model retrieval*. 226 p. Tese (Doutorado) — University of Leipzig, 2004.
- [3] YU, F. et al. *Three-dimensional model analysis and processing*. [S.l.]: Springer Science & Business Media, 2011. 500 p. ISBN 9783642126512.
- [4] ARFKEN, G. B.; WEBER, H. J. *Mathematical methods for physicists*. 7. ed. [S.l.]: Elsevier, 1992. 732 p.
- [5] CHEN, X. et al. Shape manifold regression with spherical harmonics for hippocampus shape analysis. In: *SPIE Medical Imaging*. [S.l.: s.n.], 2013. v. 8669, p. 866940–866949.
- [6] STYNER, M. et al. Statistical shape analysis of neuroanatomical structures based on medial models. *Medical Image Analysis*, v. 7, n. 3, p. 207–220, 2003. ISSN 1361-8415.
- [7] STYNER, M. et al. Boundary and medial shape analysis of the hippocampus in schizophrenia. *Medical Image Analysis*, v. 8, n. 3, p. 197–203, 2004. ISSN 1361-8415.
- [8] SMEULDERS, A. W. M. et al. Content-based image retrieval at the end of the early years. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 22, n. 12, p. 1349–1380, 2000. ISSN 0162-8828.
- [9] GROEMER, H. *Geometric applications of Fourier series and spherical harmonics*. [S.l.]: Cambridge University Press, 1996. v. 61. ISBN 9780511530005.
- [10] CAO, N. et al. Approximating high angular resolution apparent diffusion coefficient profiles using spherical harmonics under BiGaussian assumption. In: *SPIE Medical Imaging*. [S.l.: s.n.], 2009. v. 7262, p. 726204–726208.
- [11] COPPINI, G. et al. 3-D heart motion from X-ray angiography. In: *Computers in Cardiology 1995*. [S.l.: s.n.], 1995. p. 71–74.
- [12] ECK, S. et al. 3D shape analysis of heterochromatin foci based on a 3D spherical harmonics intensity model. In: *SPIE Medical Imaging*. [S.l.: s.n.], 2014. v. 9034, p. 90340X–90340X–6.
- [13] EDVARDSON, H.; SMEDBY, O. Compact and efficient 3D shape description through radial function approximation. *Comput Methods Programs Biomed*, v. 72, n. 2, p. 89–97, 2003.
- [14] CBIC. Seg3D: Volumetric Image Segmentation and Visualization. Scientific Computing and Imaging Institute (SCI). www.sci.utah.edu/cbic-software/seg3d.html, 2012.
- [15] CBIC. ImageVis3d: A Real-time Volume Rendering Tool for Large Data. Scientific Computing and Imaging Institute (SCI). www.sci.utah.edu/software/imagevis3d.html, 2012.
- [16] Eclipse. *Eclipse IDE*. 2017. Disponível em: <www.eclipse.org>.
- [17] PROGRAMMING, R. *R Programming*. 2017. Disponível em: <<https://www.r-project.org>>.
- [18] KAZHDAN, M.; FUNKHOUSER, T.; RUSINKIEWICZ, S. Rotation invariant spherical harmonic representation of 3D shape descriptors. In: *Proceedings of the 11th Eurographics/ACM SIGGRAPH symposium on Geometry processing*. Aachen, Germany: Eurographics Association, 2003. p. 156–164.
- [19] ROUSSEEUW, P. J. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, Elsevier, v. 20, p. 53–65, 11 1987. ISSN 03770427. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/0377042787901257>>.
- [20] MÜLLER, H. et al. A review of content-based image retrieval systems in medical applications—clinical benefits and future directions. *International Journal of Medical Informatics*, v. 73, n. 1, p. 1–23, 2004. ISSN 1386-5056. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1386505603002119>>.
- [21] BERGAMASCO, L. C. C. et al. Using Bipartite Graphs for 3D Cardiac Model Retrieval. In: *2015 IEEE 28th International Symposium on Computer-Based Medical Systems*. [S.l.: s.n.], 2015. p. 232–237. ISSN 1063-7125.
- [22] BERGAMASCO, L. C. C.; NUNES, F. L. S. Three-dimensional Content-Based Cardiac Image Retrieval using global and local descriptors. In: *AMIA. AMIA Annual Symposium Proceedings*. Washington, USA, 2015. p. 1811–1820.

Estratégias de spatiotemporal data exploration for the analysis of the interaction between animal behavior and the environment using data mining

Estratégia de exploração de dados espaço-temporais para a análise de interação entre o comportamento animal e o meio ambiente utilizando mineração de dados

Suelane Garcia Fontes¹, Pedro Luiz Pizzigatti Corrêa¹, Silvio Luiz Stanzani²

¹Escola Politécnica da Universidade de São Paulo – USP - São Paulo – SP – Brasil

² Centro de Computação Científica – UNESP - São Paulo – SP – Brasil

{suelane, pedro.correa@usp.br, silvio@ncc.unesp.br}

Resumo— *O mundo tem vivenciado grandes mudanças na natureza como a ocorrência de grandes desastres naturais e o risco de extinção de diversas espécies devido às ações humanas indevidas. Com os avanços tecnológicos recursos, como sensores e GPS, estão sendo utilizados no monitoramento da fauna para a obtenção de informações que orientem ações e políticas de preservação e conservação. Uma forma de obter informações sobre as mudanças do meio ambiente é analisar a evolução do comportamento animal. Desta forma, neste trabalho é apresentada uma proposta de estratégia de exploração da correlação entre dados espaço-temporais relativos ao comportamento animal e aos fatores ambientais, utilizando técnicas de mineração de dados.*

Palavras-chave — *data science, data mining, trajetórias, dados espaço-temporais, comportamento animal.*

Classificação— *Doutorado*

Categoria— *Intermediária*

I. INTRODUÇÃO

A sociedade tem observado a ocorrência de grandes transformações na natureza causadas pela ação humana devastadora que causa a diminuição dos recursos naturais e dos ecossistemas [1]. Alguns animais estão ameaçados de extinção devido à caça predatória, ao comércio ilegal e à destruição ou fragmentação de seu habitat, para o desenvolvimento de agricultura, criação de gado, exploração mineral ou assentamentos humanos [2]. Diante disso, há projetos que buscam investigar as mudanças nos padrões de movimentação dos animais em função dos fatores ambientais com o objetivo de fornecer informações que possam ser utilizadas para subsidiar estratégias de manejo, como conservação de áreas adequadas e corredores para predadores topo de cadeia, tais como, onças e tigres [3].

Uma forma de analisar as transformações que ocorrem na natureza é acompanhar a evolução dos animais, considerando que o comportamento do animal pode sofrer alterações de acordo com as mudanças ocorridas no ambiente. Com os avanços tecnológicos os dados espaço-temporais passaram a ser amplamente coletados por dispositivos, tais como, sensores e sistemas de rastreamento GPS [4]. Estes avanços aumentaram a capacidade de acompanhar, estudar e gerenciar os movimentos dos animais

que representam a evolução espaço-temporal de um objeto em movimento, a Trajetória.

A análise de trajetórias [4] pode fornecer informações sobre o porquê, como, quando e onde os animais se movimentam e como este processo está relacionado ao meio ambiente [5]. De acordo com as informações sobre o movimento do animal, como a variação da velocidade e a distância percorrida ou a frequência em que são encontrados os animais num mesmo tempo e espaço, pode-se identificar padrões de comportamento dos animais.

Para realizar a análise da interação entre o comportamento animal e o meio ambiente, considera-se que os animais se movem ao longo de um determinado espaço e tempo, descrevendo suas trajetórias, estando sujeitos às influências do meio ambiente e podendo apresentar variações de comportamento. Esta interação é analisada para identificar a correlação entre a variação dos fatores ambientais e o comportamento do animal.

Para a descoberta de padrões de movimento há técnicas baseadas em estatística e matemática, como a Mineração de Dados [6][7], que fornecem um conjunto de estratégias e ferramentas para exploração dos dados e a obtenção de conhecimento, sendo uma das etapas da Ciência dos Dados [8][9]. A Ciência dos Dados envolve a captura, curadoria e análise de grandes quantidades de dados de diferentes origens, incluindo o sensoriamento remoto, por satélite e aéreo, instrumentos e a observação humana [10].

O desafio em analisar a interação entre os dados espaço-temporais, relativos ao comportamento animal e aos fatores ambientais, é a diversidade de técnicas existentes para a identificação de comportamento animal e para a análise de trajetórias e a heterogeneidade dos dados relativos aos fatores ambientais.

Este trabalho tem como objetivo propor uma estratégia que combine técnicas que permitam analisar a correlação entre dados espaço-temporais relativos ao comportamento animal e aos dados ambientais, utilizando mineração de dados.

II. FUNDAMENTAÇÃO

Esta seção apresenta os conceitos que norteiam a exploração e a análise de dados de movimentação animal.

Conceitos

A mineração de dados compreende o conjunto de estratégias, ferramentas e algoritmos que permitem a exploração e a extração de padrões dos dados [11]. Estes algoritmos compõem as técnicas de mineração de dados que podem ser classificadas como: supervisionadas e não supervisionadas. As técnicas supervisionadas, como a classificação, exigem a escolha de uma classe como parâmetro de entrada para servir como referência para mineração. As técnicas não supervisionadas, como a clusterização, não requerem a entrada de parâmetros para serem utilizadas como referência [12]. A classificação identifica grupos de itens e indivíduos baseados em uma classe pré-definida; a clusterização, identifica grupos de itens baseados em uma classe não definida previamente e as regras de associação permitem extrair correlações, padrões frequentes ou associações [13]. O algoritmo Apriori [14] executa a tarefa de mineração das regras de associação. Como resultado do algoritmo Apriori são obtidas as regras de associação, as medidas básicas (suporte, confiança) e as medidas de interesse que podem ser: convicção, lift, coeficiente de correlação (ϕ) e hyperlift. A medida de suporte representa a porcentagem de transações da base de dados que contém um conjunto de itens, indicando a relevância da mesma. Já a medida de confiança representa a probabilidade da regra estar correta.

A análise de padrão de comportamento dos animais em movimento tem como objetivo identificar como os animais se comportam ao longo das trajetórias, obtendo indícios sobre fatores ambientais que influenciaram este comportamento. A identificação de diferentes tipos de comportamento pode ajudar a entender, o porquê da ocorrência de algo ou a causa de determinadas ações [15]. Os padrões de comportamento são identificados com base na exploração dos dados espaço-temporais relativos ao movimento animal que são compostos por: pontos, que determinam a posição (longitude e latitude) e o tempo (data e hora do movimento). Estes dados podem ser relativos a grupos de animais da mesma espécie, a grupos de espécies diferentes ou a um único animal.

O comportamento animal pode ser dividido em estados e eventos. Os estados correspondem ao comportamento que ocorre por uma duração estendida, tais como: descansando, caminhando e forrageando. Os eventos correspondem aos comportamentos que são curtos em duração e contados durante o tempo, tais como: lutando, perseguindo e desviando.

Como fatores ambientais temos os dados relativos às ocorrências que podem influenciar no comportamento animal como: variação de temperatura, ocorrência de queimadas, precipitação, população humana ou a presença de outros animais.

A análise de padrão de comportamento dos animais permite identificar a interação entre os animais e o meio ambiente. Por interação entende-se a relação entre os

padrões de comportamento gerados pelo movimento dos animais e os fatores ambientais, que compreendem as características relacionadas ao ambiente onde ocorre o movimento.

A correlação é a associação entre duas variáveis que inclui a correlação estatística entre duas variáveis numéricas e todos os casos de co-ocorrência de características ou comportamento. A correlação pode medir a interação entre pares de trajetórias. No entanto, a causalidade não pode ser conhecida por meio das medidas de correlação que indicam apenas a força e a direção do relacionamento linear entre dois atributos [17].

III. ESTRATÉGIA PROPOSTA

Com base nas referências bibliográficas estudadas e no objetivo do trabalho de analisar a interação entre o comportamento do animal e o meio ambiente foi definida a proposta, dividida em quatro etapas, mostrada na fig. 1:

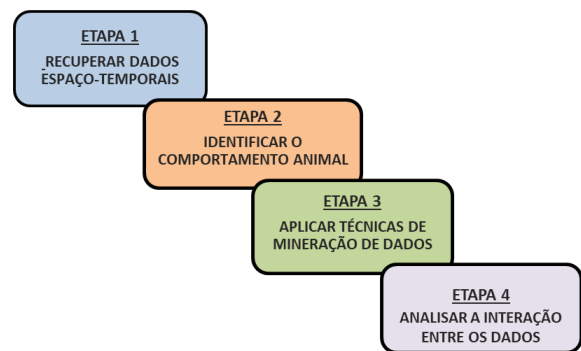


Fig. 1 – Estrutura da Estratégia Proposta

Etapa 1: Recuperar dados espaço-temporais

Nesta etapa devem ser definidos os conjuntos de dados a serem analisados contendo o registro da movimentação animal (latitude, longitude e data/hora), a identificação dos animais e os parâmetros necessários para a realização das análises, como: distância mínima entre os animais, suporte mínimo (frequência de ocorrência dos itens) e a confiança mínima.

Nos casos onde a análise requer mais de um conjunto de dados, por exemplo, na análise de interação entre a movimentação dos animais e os fatores externos como temperatura, vegetação, entre outros, é necessário fornecer estes dados contendo os registros de ocorrência (latitude, longitude e data/hora).

Etapa 2: Identificar o comportamento animal

Nesta etapa os dados devem ser preparados para serem analisados com base na hipótese de análise definida. Esta etapa está subdividida em quatro subEtapas, fig. 2, que são a identificação: da distância entre os animais, dos encontros entre os animais, do período de ocorrência do movimento animal e dos estados do comportamento animal.

Etapa 2.1: Identificar distância entre animais

Esta etapa somente será aplicada nos casos onde o conjunto de dados contém movimentação de dois ou mais animais. Um procedimento criado na linguagem SQL é utilizado para realizar o cruzamento dos dados de forma a obter a distância

entre os animais. Este procedimento denominado `calculaDistancia()` utiliza a fórmula Vincenty [18] para calcular a distância em metros entre dois pontos tendo como base um círculo. Após o cálculo da distância os dados são armazenados em uma tabela do banco de dados, contendo os dados relativos aos indivíduos (animais) 1 e 2, a data de movimentação (do indivíduo 1 e do indivíduo 2) e a distância calculada entre os dois indivíduos numa determinada data, hora e minuto.

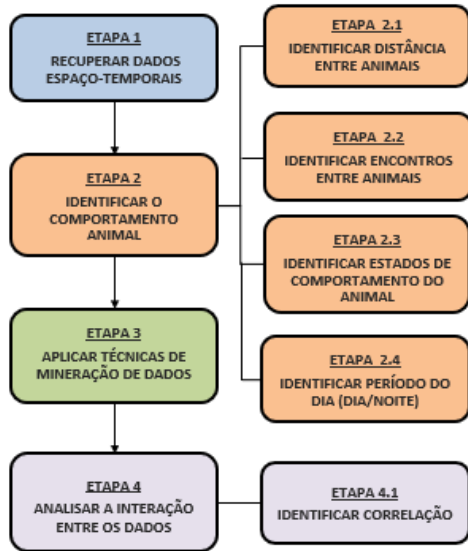


Fig. 2 – Detalhamento da Estratégia Proposta

Etapa 2.2: Identificar encontros entre animais

Quando o conjunto de dados é composto por dois ou mais animais pode-se identificar a ocorrência de encontros entre os animais. Para identificar os encontros é utilizado um procedimento na linguagem SQL que verifica quais animais estavam no mesmo local na mesma data e hora e posição (latitude e longitude) numa determinada distância limite definida como parâmetro de entrada da estratégia proposta. Por exemplo, considera-se que houve encontro entre os animais que tiveram o registro de movimentação na mesma posição (longitude/latitude), na mesma data e hora mantendo um distância de no máximo 400 metros.

Etapa 2.3 - identificar estados de comportamento animal

Nesta etapa são identificados os estados de comportamento animal, considerando três estados: descansando, em trânsito e forrageando. Para identificar o comportamento animal é utilizado o método de Residência no Espaço e Tempo [19].

O método de Residência no Espaço e Tempo (RST), utiliza a função `ResidenceTimeCalc` que identifica o comportamento animal baseado na distância e tempo de residência, considerando um raio especificado pelo usuário ou calculado dinamicamente.

Método: Distância total percorrida e a quantidade de tempo gasto na área de escala constante (1x1km)

- Identifica o Tempo de residência (RT) e Distância de Residência (RD) para cada ponto;
- Normaliza as variáveis RT e RD;
- Subtrai $RT - RD$, gerando o resultado do Resíduo (entre -1 e 1)

Resultado:

- Resíduo $> 0 \rightarrow$ ARS (*area restricted search*), forrageamento, tempo e distância elevados cobertos dentro da área;
- Resíduo $< 0 \rightarrow$ descanso, tempo elevado na área e pequenas distâncias;
- Resíduo $= 0 \rightarrow$ trânsito, tempo baixo e baixa distância.

Desta forma, com base nos dados de movimentação animal é executado o algoritmo do método de RST sendo identificado para cada ponto de movimentação qual o estado de comportamento do animal de acordo com o valor do resíduo obtido. Como resultado são identificados a latitude e longitude, a data/hora do movimento, o identificador do animal e o estado de comportamento para cada ponto de movimentação do animal. Estes dados são armazenados em uma base de dados.

Etapa 2.4 - identificar período do dia (dia/noite) do comportamento animal

Nesta etapa é adicionado um atributo, relativo ao período de ocorrência do movimento (dia/noite), na tabela de estados de comportamento animal. Uma rotina em SQL foi utilizada para realizar esta análise, considerando o período entre '00:00:01' e '17:59:59', como dia (D) e o período entre '18:00:00' e '23:59:59', como noite (N).

Etapa 3: Aplicar técnicas de mineração de dados

Para identificar a interação entre os dados é utilizada a regra de associação que busca encontrar elementos que implicam na presença de outros elementos em uma mesma transação, que significa encontrar relacionamentos ou padrões frequentes entre conjuntos de dados ou dados correlacionados. Para aplicar a técnica de regras de associação [7] é utilizado o pacote Arules [16], algoritmo Apriori, e como resultado são obtidas as regras de associação e as medidas de interesse.

Para a geração das regras de associação é necessário, primeiramente, ter bem definida a hipótese que será considerada na análise, porque os dados que serão utilizados podem variar de acordo com o que se deseja observar. O algoritmo Apriori utilizado para a geração das regras de associação supõe-se que sejam passadas as duas variáveis a serem analisadas e os parâmetros mínimos de suporte e confiança.

Um exemplo de hipótese a ser considerada é a ocorrência de atração entre os animais. Para esta análise é realizado o cruzamento entre os animais contidos no conjunto de dados para identificar os animais com proximidade e são utilizadas como variáveis as ocorrências do indivíduo 1 e do indivíduo 2, num determinado raio de distância em metros e um valor mínimo de suporte e confiança. Um outro exemplo seria considerar a hipótese de que o período do dia (dia/noite) influencia no comportamento do animal. Nesta análise utiliza-se as variáveis de estado do comportamento do animal e o período do dia.

Desta forma, observa-se que dependendo da hipótese de análise, as variáveis utilizadas no algoritmo de geração das regras de associação serão diferentes.

Etapa 4: Analisar a interação entre os dados

Nesta etapa as regras de associação são analisadas de acordo com as medidas básicas e de interesse geradas no processo de mineração. São identificados os itens que possuem maior probabilidade de correlação, bem como é avaliado o nível de significância destas regras analisando as medidas [20], como: suporte, para verificar a frequência de ocorrência dos pares de itens identificados em cada regra, a confiança, lift, convicção e hyperlift. O suporte (S) corresponde ao percentual de vezes que o conjunto A e B aparece no conjunto de transações. A confiança corresponde ao percentual de vezes com que B aparece nas transações que contém A. O lift permite a análise da dependência entre os atributos, considerando os resultados: lift = 1, A e B são independentes, B não tem efeito sobre A; lift < 1, aparecem com menor frequência juntos, a ocorrência de A tem efeito negativo sobre B; lift > 1, A e B aparecem frequentemente juntos, A tem efeito sobre B. A convicção é uma medida de implicação e tem valor 1 se os itens não são relacionados. O phi corresponde ao coeficiente de correlação considerando a classificação:

- -1.0 a -0.7 = forte associação negativa (FOAN);
- -0.7 a -0.3 = fraca associação negativa (FAAN);
- -0.3 a 0.3 = pouca ou nenhuma associação (PONE);
- 0.3 a 0.7 = fraca associação positiva (FAPO)
- 0.7 a 1.0 = forte associação positiva (FOPO)

IV. CONCLUSÃO

Neste artigo foi apresentada a proposta da tese que aborda, dentro do contexto da biodiversidade, como explorar a mineração de dados para a análise de movimento dos animais visando a descoberta de conhecimento sobre o comportamento animal e sua interação com o meio-ambiente.

AGRADECIMENTOS

Agradecemos a Escola Politécnica da Universidade de São Paulo (EPUSP) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

REFERÊNCIAS

[1] KELLING, S. et al. Data-intensive Science: A New Paradigm for Biodiversity Studies. *BioScience*, 7 jan. 2009. v. 59, n. 7, p. 613–620.
 [2] MORATO, R. G.; GENARO, G. Padrão de atividade de onças pintadas (*Panthera onca* Linnaeus, 1758) mantidas em cativeiro: manejo e comportamento. *Revista de Etologia*, dez. 2005. v. 7, n. 2, p. 75–77.
 [3] MORATO, R. G. et al. Space Use and Movement of a Neotropical Top Predator: The Endangered Jaguar. *PLOS ONE*, 28 dez. 2016. v. 11, n. 12, p. e0168176.
 [4] DEMŠAR, U. et al. Analysis and visualisation of movement: an interdisciplinary review. PMID: 25874114 PMCID: PMC4395897: *Movement Ecology*, 2015. v. 3, n. 1, p. 5.

[5] NHAT HAI, P. **Mining Object Movement Patterns from Trajectory Data**. França: Académie de Montpellier, Université Montpellier, 2014. Doutorado.
 [6] ZHENG, Y. Trajectory Data Mining: An Overview. *ACM Trans. Intell. Syst. Technol.*, maio. 2015. v. 6, n. 3, p. 29:1–29:41.
 [7] BLEISCH, S. et al. Mining candidate causal relationships in movement patterns. *International Journal of Geographical Information Science*, v. 28, n. 2, p. 363–382, fev. 2014.
 [8] FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From Data Mining to Knowledge Discovery in Databases. *AI Magazine*, 15 mar. 1996a. v. 17, n. 3, p. 37.
 [9] HEY, T. The Fourth Paradigm – Data-Intensive Scientific Discovery. (S. Kurbanoğlu et al., Org.). In: *International Symposium on Information Management in Changing World, Communications in Computer and Information Science*, 2012, [S.l.] . **Anais eletrônicos...** [S.l.]: Springer Berlin Heidelberg, 2012. p. 1–1. Disponível em: <http://link.springer.com/chapter/10.1007/978-3-642-33299-9_1>. Acesso em: 26 fev. 2017.
 [10] AYANKOYA, K.; CALITZ, A.; GREYLING, J. Intrinsic Relations between Data Science, Big Data, Business Analytics and Datafication. [S.l.]: ACM Press, 2014. p. 192–198. Disponível em: <<http://dl.acm.org/citation.cfm?doi=2664591.2664619>>. Acesso em: 2 maio. 2016.
 [11] FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMYTH, P. Advances in Knowledge Discovery and Data Mining. In: FAYYAD, U. M. et al. (Org.). Menlo Park, CA, USA: American Association for Artificial Intelligence, 1996b, p. 1–34
 [12] WITTEN, I. H.; FRANK, E. *Data Mining: Practical Machine Learning Tools and Techniques, Second Edition* (Morgan Kaufmann Series in Data Management Systems). San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2005.
 [13] JAISWAL, V.; AGARWAL, J. The Evolution of the Association Rules. *International Journal of Modeling and Optimization*, 2012. p. 726–729.
 [14] AGRAWAL, R.; SRIKANT, R. *Fast Algorithms for Mining Association Rules in Large Databases*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1994. p. 487–499. Disponível em: <<http://dl.acm.org/citation.cfm?id=645920.672836>>. Acesso em: 21 set. 2016.
 [15] LUCCA SIQUEIRA, F. DE; BOGORNY, V. Discovering Chasing Behavior in Moving Object Trajectories. *Transactions in GIS*, 1 out. 2011. v. 15, n. 5, p. 667–688.
 [16] HAHSLER, M.; GRUEN, B.; HORNIK, K. arules – A Computational Environment for Mining Association Rules and Frequent Item Sets. *Journal of Statistical Software*, out. 2005. v. 14, n. 15, p. 1–25.
 [17] MAZLACK, L. J. Considering Causality in Data Mining. In: *INTERNATIONAL CONFERENCE ON SOFTWARE ENGINEERING–2008, 2008*, [S.l.] . Anais... [S.l.]: Citeseer, 2008.
 [18] VICENTY (April 1975a). "Direct and Inverse Solutions of Geodesics on the Ellipsoid with application of nested equations" (PDF). *Survey Review*. XXIII (176): 88–93. doi:10.1179/sre.1975.23.176.88. Retrieved 2009-07-11. In selecting a formula for the solution of geodesics it is of primary importance to consider the length of the program, that is the amount of core which it will occupy in the computer along with trigonometric and other required functions.
 [19] TORRES, L. G. et al. Classification of Animal Movement Behavior through Residence in Space and Time. *PLOS ONE*, 3 jan. 2017. v. 12, n. 1, p. e0168513.
 [20] MANIMARAN, J.; VELMURUGAN, T. Analysing the Quality of Association Rules by Computing an Interestingness Measures. *Indian Journal of Science and Technology*, 15 jul. 2015. v. 8, n. 15. Disponível em: <<http://www.indjst.org/index.php/indjst/article/view/76693>>. Acesso em: 8 out. 2017.

Knowledge Transfer with Case-based Policy Inference

GLATT, R.; COSTA, A. H. R..

Laboratório de Técnicas Inteligentes - Escola Politécnica

Universidade de São Paulo

E-mail: {ruben.glatt, anna.reali}@usp.br

Abstract—Our work is concerned with the transfer of knowledge for Deep Reinforcement Learning agents. Over the last year, we introduced a formulation for applying the *Case-Based Reasoning* methodology to these kind of problems. Based on this framework, we proposed the *Case-based Policy Inference (CBPI)* algorithm to accelerate learning by selecting similar cases from a library of previously learned tasks with their respective solutions to solve a new target task in a simple domain. *CBPI* guides the training by dynamically selecting and blending policies according to their usefulness for the current target task, progressively switching the control to a new policy as it converges to the optimal behavior. The framework was well received in workshops and shows great potential for applying it to more complex problems.

Keywords— Deep Learning; Reinforcement Learning; Transfer Learning; Case Based Reasoning.

Classification— Doctorate degree.

Category— Intermediate.

I. INTRODUCTION

A great part of *Artificial Intelligence (AI)* research is concerned with learning how to solve a given task in a most efficient way. One way, such tasks can be modeled is as a *Markov Decision Process (MDP)* [1], which is a discrete time stochastic control process, where at each time step, the *MDP* is in a state and an agent can perform actions that lead to an observable update of the state combined with a reward signal.

Many very powerful methods for solving this kind of decision-making processes are specified in the field of *Reinforcement Learning (RL)* [2]. In *RL*, an agent explores the space of possible strategies to solve a task in a given environment, receives a feedback (reward or punishment) on the outcome of the actions it takes and deduces a behavior policy from its observations over time. The goal of the agent is to determine a policy π that maps each state s to an action a , which maximizes the accumulated reward R over a given horizon.

Although *RL* has been successfully used to autonomously learn how to solve complex tasks like for example robot soccer [3], learning to solve a new task with good results still takes a relative long time. This is due to the fact that agents applying *RL* techniques require a large number of samples of interactions with the environment to infer an effective solution policy even for simple tasks.

With the raise of *Deep Learning (DL)* [4], it became possible to use *RL* successfully on more complex problems like autonomous helicopter flight [5] or Atari computer games

[6]. Here, *DL* is characterized by architectures of multiple layers of artificial neural network structures that allow to learn abstract representations of high dimensional data and the behaviour policy at the same time. The emerging field is called *Deep Reinforcement Learning (DRL)*.

In the past, most research efforts have been focused on learning individual tasks from scratch but it is now shifting to more advanced agents that can learn to solve not only one, but multiple tasks with the help of using a priori gathered knowledge in order to progressively reduce the sample complexity. The field of *Transfer Learning (TL)* emerged from the need to solve these kind of problems and in recent years many efforts have been directed on expanding *Machine Learning (ML)* algorithms with the ability to transfer knowledge, experience or skills to allow learning of multiple tasks more efficiently [7]. The idea of using accumulated knowledge in this way is inspired by the human transfer learning abilities which work quite similar. The goal is to create intelligent agents that can learn to master varied tasks in a single or various domains by engaging in continuous or even lifelong learning [8].

A. Preliminary results

During the course of the program we have produced and published various relevant articles in workshops and international conferences.

One of the articles [9] was an early work on transfer in *DRL* and discussed the usefulness of weight transfer for the initialization of a Deep Neural Network architecture from previously learned games in the Atari domain. Another paper [10] was awarded *best conference paper* at the *5th Brazilian Conference on Intelligent System (BRACIS 2016)*. It was concerned with *Object-Oriented RL* in cooperative multiagent domains to combine the exploitation of regularities in a domain with the division of workload among multiple agents. A short paper [11] sketched out an advising framework for multiagent *RL* agents and was awarded *Honorable mentions as Best Student Poster* of the *AAAI Conference on Artificial Intelligence (AAAI-17)*. Another short paper [12] proposed to adapt an effective solution for knowledge transfer, *Probabilistic Policy Reuse*, from classic *RL* to *DRL*.

Of the most recent papers, one describes a simple algorithm to transfer probabilistic options in *RL* [13] and another one provides an extensive evaluation for simultaneously learning and advising in multiagent *RL* [14].

We will take a closer look at the most recent paper, which sketches out a framework to combine *Case-based Reasoning (CBR)* and *RL* [15], in the following sections.

Apart from the publications, our work was accepted to be presented at the *Doctoral Consortium (DC)* at the (AAAI-17) conference in San Francisco. The whole proposal also received several honours like winning the Google Research Award in 2015 and 2016, as well as a *Distinguished Work Award* at the *5th Postgraduate Workshop in Computer Engineering (WPGEC)* 2016. We also received a GPU grant from NVIDIA and Ruben was selected as one of few outstanding Young Researchers to participate in the *5th Heidelberg Laureate Forum*¹ in 2017.

II. RECENT WORK

A. Related research

An overview of approaches that reuse knowledge from previously learned tasks utilizing *RL* approaches is given by [16], but the interest is still growing and new interesting concepts are emerging frequently, as for example transferring knowledge in the form of options [17], by transferring artificial neural network weights [9] or through advice from other agents [14].

In this respect we find two approaches especially interesting. The first one is called *Probabilistic Policy Reuse* [18], where the authors propose a framework to autonomously build a library of core policies for a given domain. During training, the approach follows a policy for a certain amount of time that has been selected according to an importance measure W that indicates the usefulness of the policy for the current task which accelerates learning. The other approach is called *Option-Critic architecture* [19], where a framework allows an agent to discover options autonomously as it acts in the environment. *Options* are partial policies that solve only subtasks and are defined by a starting condition to detect when they should be activated, a policy that is followed when activated, and a termination function that exits the option execution. In this framework, the options are learned autonomously during training and at the same time a policy over these options is learned to guide the option selection.

Another important concept to benefit from previously acquired knowledge is described in the *CBR* approach [20], which describes a methodology to build computational models to reuse existing knowledge in a general manner [21]. The guiding assumption for *CBR* is that similar problems have similar solutions. *CBR* has been shown to be very successful and has been widely applied in a number of fields [22]. A high-level description of the *CBR* cycle describes four stages during the learning of a new task with previously acquired knowledge [20], [23]. First, the agent has to *RETRIEVE* the most similar cases from its knowledge base and then *REUSE* the contained information to propose a solution to the new task. After that, the proposed solution is *REVISED* to find a final solution to the target task. In the end, the agent can decide

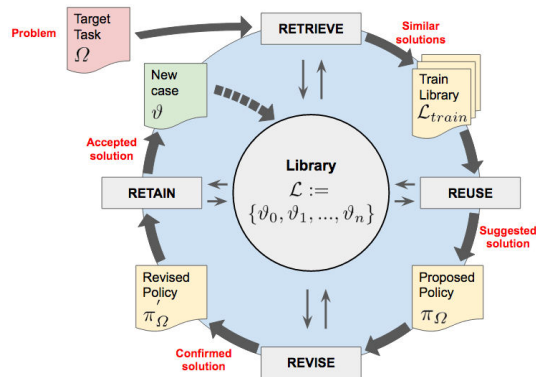


Fig. 1. A view on the *CBR* cycle adapted to *RL* terminology.

if it should *RETAIN* the gathered solution in the knowledge base.

B. Case-Based Reasoning in Reinforcement Learning terminology

As is common for sub-fields of a research area, *CBR* has evolved its own terminology and perspectives, making it less tangible for other communities. Therefore, we attempt to provide a formulation that defines the *CBR* framework using *RL* terminology with the goal of making it more accessible for the *RL* community and making *RL* more attractive to the *CBR* community.

In *CBR* terminology, a case describes a problem and its solution. A case base is comprised of a number of retained cases, which have been learned in the past and whose solutions can be reused to solve future problems. In *RL*, a *case* contains the task (problem), defined by an *MDP*, and a policy associated with that task (solution).

A *case base* is then equivalent to a *library* in *RL* and the cases are ideally distinct from each other to avoid duplicate information.

The cyclic process in *CBR* integrates solving a new task and learning from experience while building a case base over time. A visualization of this process using *RL* terminology is sketched out in Figure 1.

In our publication, we are leaving the definitions intentionally wide so that adaptations to other variants are possible, as for example by Aha [24], who introduces an additional *REVIEW* step between *REVISE* and *RETAIN*, or by Hüllermeier [25] who also describes a framework but focuses on the *RETAIN* stage and proposes to build a *credible* set that contains some (possibly all) solutions for a given problem.

C. Case-based Policy Inference

We propose an implementation of the framework described in the previous section and coin it *Case-based Policy Inference (CBPI)*. It is based on the idea of creating a generalization of past policies during training and focuses on the *REUSE* and *REVISE* stages of the *CBR* cycle. For details we refer the interested reader to our workshop paper published at *ECML* just recently.

¹<http://www.heidelberg-laureate-forum.org/>




Fig. 2. The used grid world domain for a simple robot navigation scenario in the experiment. The graphs show all goal positions that were considered as individual tasks (green: previously solved tasks, red: task to learn).

We evaluated the algorithm in a domain which has been adapted from the original *Probabilistic Policy Reuse* publication [18], where an agent has to find its way to a goal position in an *office domain* consisting of rooms and connecting corridors represented in a grid world. Although simple, this domain has been used in many publications (e.g. [26], [27], [28]) to offer a clear way to compare different *RL* algorithms without the need of much expert knowledge. The domain and the goal positions for the experiments is shown in Figure 2.

We performed two experiments. The first one shows the suitability of our approach for learning a new task with an existing library, and the second one shows that it can also be used for building a library with core policies for a domain from scratch.

In the first experiment we evaluate our *CBPI* algorithm against *Policy Library Policy Reuse (PLPR)* [18] and vanilla *Q-Learning*.

For this purpose, we let an agent train on five source tasks $\Omega_{1,\dots,5}$ using *Q-Learning* until an optimal policy is learned, and save the learned policies $\pi_{\Omega_1,\dots,\Omega_5}$ for each case in the library \mathcal{L} . The agent then has to learn to perform well on a new target task Ω and learn a policy π_{Ω} for that task.

We evaluate two scenarios with the same training settings. In the first scenario, we are using all available policies for the policy library, $\mathcal{L}_{1,2,3,4,5} = \{\pi_{\Omega_1}, \pi_{\Omega_2}, \pi_{\Omega_3}, \pi_{\Omega_4}, \pi_{\Omega_5}\}$. In the second scenario, we deliberately chose to only use policies from tasks that seem very unrelated to our target task, so the policy library becomes $\mathcal{L}_{2,3,4} = \{\pi_2, \pi_3, \pi_4\}$.

The first part of this experiment uses a library \mathcal{L} that contains 5 cases corresponding to tasks $\Omega_{1,\dots,5}$ including two, $\Omega_{1,5}$, that are very similar to the target task Ω . In Figure 3 we can see the achieved rewards per episode and both *PLPR* and *CBPI* outperform the standard *Q-Learning* approach by far. It is also notable, that our algorithm performs better at the beginning of the training, due to the fact that it evaluates the available policies before it starts training, while *PLPR* starts randomly and learns the weights W for each policy on the fly.

The second scenario uses a library \mathcal{L} that contains 3 cases corresponding to tasks $\Omega_{2,3,4}$ without the policies that are very similar to the target task Ω . Again, the *PLPR* approach uses




Fig. 3. Resulting rewards when using a policy library that also contains policies from very similar tasks (Ω_1 and Ω_5).




Fig. 4. Resulting rewards when using a library only containing policies from very unrelated tasks (Ω_2, Ω_3 , and Ω_4).

all available tasks for its training library \mathcal{L}_{train} , while the similarity metric in *CBPI* detects that there are no similar tasks in the library and builds the training library ignoring the available cases. In Figure 4 we can see the achieved rewards per episode. Here, it is interesting to see that *CBPI* and *Q-Learning* perform exactly the same, meaning that the unhelpful policies were successfully detected, while *PLPR* takes much longer to converge suffering from *negative transfer*.

The results shown above show that our approach performs slightly better than *PLPR* when the available knowledge contains similar tasks, and is clearly better if the available knowledge only contains unrelated tasks. *CBPI* has shown that it benefits from existing favorable knowledge while in the worst case performs as if no *a priori* knowledge was available. This behaviour shows that it can better deal with the problem of *negative transfer* during training, as long as a well-defined similarity metric is given.

In the second experiment, we let the algorithm learn a large number of tasks and build a reasonable knowledge base in the progress. When compared to *PLPR*, it is clearly visible that both algorithms have similar behaviour and select a good set of policies. It is however notable, that *CBPI* provides a set of solutions that contains a policy for every room apart from the connecting rooms, which makes sense since those can already be reached by the policy for the next room, a circumstance that is not recognized by *PLPR*. We therefore conclude that our selection approach in the *RETAIN* stage is sensitive enough for selecting core policies in this domain and provides acceptable results compared to *PLPR*.

III. CONCLUSION

The results reported here indicate that applying the *CBR* methodology on *RL* is a promising approach. A part of our

future efforts will therefore be directed towards implementing the framework with more sophisticated *RL* algorithms and evaluate it in more complex domains. We are especially interested in combining our earlier research on *DRL* with the *CBR* framework and publish the results in a major conference.

ACKNOWLEDGMENT

We are grateful for the support from CAPES, CNPq (grant 311608/2014-0), and FAPESP (grants 2015/16310-4, 2016/21047-3). We also thank Google (Research Award) and the Nvidia corporation (GPU donation).

REFERENCES

- [1] PUTERMAN, M. L. *Markov Decision Processes: Discrete Stochastic Dynamic Programming*. Hoboken, NJ, USA: John Wiley & Sons, 2014. ISBN 1118625870.
- [2] SUTTON, R. S.; BARTO, A. G. *Introduction to Reinforcement Learning*. Cambridge, MA, USA: MIT Press, 1998.
- [3] STONE, P.; SUTTON, R. S. Scaling Reinforcement Learning toward RoboCup soccer. In: *Proc. 18th Int. Conf. on Machine Learning (ICML)*. [S.l.: s.n.], 2001. v. 1.
- [4] LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- [5] NG, A. Y. et al. Autonomous inverted helicopter flight via Reinforcement Learning. In: *Experimental Robotics IX*. [S.l.]: Springer, 2006. p. 363–372.
- [6] MNIH, V. et al. Human-level control through Deep Reinforcement Learning. *Nature*, Nature Publishing Group, v. 518, n. 7540, p. 529–533, 2015.
- [7] PAN, S. J.; YANG, Q. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering (TKDE)*, IEEE, v. 22, n. 10, p. 1345–1359, 2010.
- [8] THRUN, S.; MITCHELL, T. M. *Lifelong robot learning*. [S.l.]: Springer, 1995.
- [9] GLATT, R.; SILVA, F. L. da; COSTA, A. H. R. Towards knowledge transfer in deep reinforcement learning. In: *IEEE, Proceedings of the 5th Brazilian Conference on Intelligent Systems (BRACIS)*. [S.l.], 2016. p. 91–96.
- [10] SILVER, D. et al. Mastering the game of Go with Deep Neural Networks and Tree Search. *Nature*, Nature Publishing Group, v. 529, n. 7587, p. 484–489, 2016.
- [11] SILVA, F. L. d.; GLATT, R.; COSTA, A. H. R. An advising framework for multiagent reinforcement learning systems. In: *AAAI PUBLICATIONS. Proceedings of the Thirty-First AAAI AAAI Conference on Artificial Intelligence (AAAI-17)*. [S.l.], 2017. p. 4913–4914.
- [12] GLATT, R.; COSTA, A. H. R. Policy reuse in deep reinforcement learning (student abstract). In: *AAAI PUBLICATIONS. Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17)*. [S.l.], 2017. p. 4929–4930.
- [13] BONINI, R. C. et al. Transferring probabilistic options in reinforcement learning (short paper). In: [ACCEPTED]. *Workshop on Transfer in Reinforcement Learning at the 16th International Conference on Autonomous Agents and Multiagent Systems (AAMAS)*. [S.l.], 2017.
- [14] SILVA, F. L. d.; GLATT, R.; COSTA, A. H. R. Simultaneously learning and advising in multiagent reinforcement learning. In: [ACCEPTED]. *Proceedings of the 16th International Conference on Autonomous Agents and Multiagent Systems (AAMAS)*. [S.l.], 2017.
- [15] GLATT, R.; SILVA, F. L. da; COSTA, A. H. R. Case-based policy inference for transfer in reinforcement learning. In: *Workshop on Scaling-Up Reinforcement Learning at the 28th European Conference on Machine Learning (ECML)*. [S.l.: s.n.], 2017. p. 1–8.
- [16] TAYLOR, M. E.; STONE, P. Transfer Learning for Reinforcement Learning domains: A survey. *Journal of Machine Learning Research (JMLR)*, JMLR.org, v. 10, 2009.
- [17] KONIDARIS, G.; SCHEIDWASSER, I.; BARTO, A. G. Transfer in reinforcement learning via shared features. *Journal of Machine Learning Research (JMLR)*, v. 13, n. 1, p. 1333–1371, 2012.
- [18] FERNÁNDEZ, F.; VELOSO, M. Probabilistic Policy Reuse in a Reinforcement Learning agent. In: *ACM. Proc. 5th International Joint Conference on Autonomous Agents and Multiagent Systems (AAMAS-06)*. [S.l.], 2006. p. 720–727.
- [19] BACON, P.-L.; HARB, J.; PRECUP, D. The option-critic architecture. *arXiv preprint arXiv:1609.05140*, 2016.
- [20] AAMODT, A.; PLAZA, E. Case-based reasoning: Foundational issues, methodological variations, and system approaches. *AI communications*, IOS press, v. 7, n. 1, 1994.
- [21] WATSON, I. Case-based reasoning is a methodology not a technology. *Knowledge-based systems*, Elsevier, v. 12, n. 5, p. 303–308, 1999.
- [22] CHEETHAM, W.; WATSON, I. Fielded applications of case-based reasoning. *The Knowledge Engineering Review*, Cambridge Univ Press, v. 20, n. 03, p. 321–323, 2005.
- [23] KOLODNER, J. *Case-based reasoning*. [S.l.]: Morgan Kaufmann, 2014.
- [24] AHA, D. W. The omnipresence of case-based reasoning in science and application. *Knowledge-based systems*, Elsevier, v. 11, n. 5, p. 261–273, 1998.
- [25] HULLERMEIER, E. Credible case-based inference using similarity profiles. *IEEE Transactions on Knowledge and Data Engineering*, IEEE, v. 19, n. 6, p. 847–858, 2007.
- [26] KOGA, M. L.; FREIRE, V.; COSTA, A. H. R. Stochastic abstract policies: Generalizing knowledge to improve Reinforcement Learning. *IEEE Transactions on Cybernetics*, IEEE, v. 45, n. 1, p. 77–88, 2015.
- [27] SHERSTOV, A. A.; STONE, P. Function approximation via tile coding: Automating parameter choice. In: *Abstraction, Reformulation and Approximation*. [S.l.]: Springer, 2005. p. 194–205.
- [28] THRUN, S.; SCHWARTZ, A. Finding structure in reinforcement learning. *Proceedings of the 7th International Conference on Neural Information Processing Systems (NIPS-94)*, Morgan Kaufmann Publishers, p. 385–392, 1995.

Map Merging of Multiple RGB-D sensors using Reinforcement Learning

Integração de dados de múltiplos sensores RGB-D para reconstrução 3D utilizando técnicas de aprendizado por reforço

Eduardo Alves*; Anna Helena Reali Costa*

*Laboratório de Técnicas Inteligentes - Departamento de Engenharia de Computação e Sistemas Digitais

E-mail: {esalves,anna.reali}@usp.br

Abstract—The 3D reconstruction of an unknown physical environment from sensory measurements is a field of research explored in many areas, from autonomous robot navigation to augmented reality applications. This proposal suggests a technique for deciding the best time to merge several local maps constructed from RGB-D sensor data. Using a reinforcement learning algorithm and some map quality heuristics, a model can be established and trained to determine the best strategy for integrating local maps. It is expected that the technique developed will result in a better quality global map when compared to other strategies in the literature.

Keywords— SLAM; map merging; Reinforcement Learning.

Resumo— A reconstrução 3D de um ambiente físico desconhecido a partir de medições sensoriais é um campo de pesquisa bastante explorado em diversas áreas, desde navegação autônoma de robôs até sistemas de realidade aumentada. Esta proposta sugere uma técnica para decidir qual o melhor momento de efetuar a fusão de vários mapas locais construídos a partir de dados de sensores RGB-D. Utilizando um algoritmo de aprendizado por reforço e algumas heurísticas sobre a qualidade dos mapas, um modelo pode ser estabelecido e treinado para determinar a melhor estratégia de integração dos mapas locais. Espera-se que a técnica desenvolvida resulte em um mapa global de melhor qualidade quando comparado com outras estratégias da literatura.

Palavras-chave— SLAM; Aprendizado por Reforço; Fusão de Mapas.

Classificação— Doutorado

Categoria— Iniciante

I. INTRODUÇÃO

A habilidade de construir um modelo espacial de um ambiente físico inicialmente desconhecido a partir de medições sensoriais é um campo de pesquisa bastante explorado pela comunidade científica em diversas áreas. Por exemplo, no contexto de navegação autônoma de robôs existe um problema comumente referido por Mapeamento e Localização Simultâneos (da sigla em inglês, SLAM) [1] em que um robô tem que resolver duas tarefas fortemente dependentes uma da outra: construir uma representação do ambiente (mapa) e, simultaneamente, obter uma estimativa da sua localização com

relação a este mapa. Outro grande potencial de aplicação é em reconstrução de cena e integração de dados em sistemas de Realidade Aumentada (RA).

Uma tendência atual é utilizar uma abordagem colaborativa para reconstrução de ambientes em que os dados de múltiplos sensores são integrados a fim de gerar uma representação global do ambiente. A Figura 1 ilustra um exemplo de integração de vários mapas parciais. Em robótica, esta abordagem é referida como Sistemas Multi-Robôs (também conhecida pela sigla em inglês, MRS). Em um cenário de SLAM, a abordagem MRS é motivada pelo fato de que tarefas de exploração e mapeamento podem ser feitas mais rapidamente, com maior flexibilidade e tolerância a falhas do que em sistemas de um único robô. Algumas operações que exigem colaboração incluem: controle de incêndio em florestas e ambientes urbanos, resgate de pessoas em desastres naturais, segurança, vigilância etc. O trabalho apresentado em [2] levanta as principais características deste tipo de abordagem em SLAM. Aplicações na área de realidade aumentada também podem beneficiar-se deste tipo de abordagem combinando dados de múltiplos sensores em um ambiente colaborativo [3].

Contudo, essas vantagens cobram o seu preço. Sistemas colaborativos de percepção e mapeamento de ambientes são mais complexos e trazem algumas dificuldades adicionais tais como definir um algoritmo eficiente para integração dos dados de vários sensores ou ainda restrições de comunicação (atrasos, perda de pacotes, alcance) no compartilhamento de informações entre os agentes. Várias técnicas foram propostas nos últimos anos no sentido de superar estas dificuldades. No âmbito de navegação autônoma de robôs móveis, os autores em [2] apresentam um trabalho de revisão bastante extenso sobre as principais soluções neste campo.

Progressivamente, sensores do tipo RGB-D têm sido usados como uma alternativa confiável e de baixo custo com relação a sensores mais tradicionais tais como radares de feixes laser e câmeras de vídeo em aplicações de navegação e mapeamento de ambientes, vigilância e robótica móvel autônoma. Existe




Figura 1. Um exemplo de integração de vários mapas parciais. Três mapas são combinados para formar uma representação global do ambiente. As elipses identificam estruturas semelhantes entre os mapas parciais (Adaptado de [4]).

uma grande expectativa que este tipo de dispositivo promoverá uma grande impulso em técnicas de reconstrução 3D de ambientes não apenas no campo da robótica [5], mas também em outras áreas como aplicações de realidade aumentada [6]. Atualmente muitos destes dispositivos são largamente comercializados por grandes empresas de tecnologia do mercado¹.

Em particular, a abordagem proposta neste trabalho enfatiza o problema de como processar e integrar os dados de múltiplos sensores de forma colaborativa para reconstruir um modelo 3D do ambiente. O foco desta proposta é desenvolver uma nova técnica de fusão de dados, especificando um algoritmo de decisão capaz de escolher a melhor forma de integrar as medições de vários sensores RGB-D. Usando técnicas de aprendizado por reforço em um cenário onde os dados são adquiridos em instantes de tempo diferentes e a localização relativa entre os dispositivos é inicialmente desconhecida pode-se determinar qual o melhor momento de realizar esta integração e como os mapas individuais devem ser fusionados.

II. CONCEITOS BÁSICOS EM FUSÃO DE MAPAS

Fusão de mapas é o termo utilizado na literatura para definir o problema de construir um mapa global de um ambiente a partir de um conjunto de mapas parciais possivelmente ruidosos [7]. Esta abordagem pode contribuir de diversas maneiras para melhorar o processo de mapeamento em diferentes situações. Por exemplo, pode-se reutilizar mapas incompletos já disponíveis ao invés de instanciar um novo processo de mapeamento ou até mesmo permitir a combinação de mapas locais construídos em instantes de tempo diferentes.

¹Visite o site <https://blog.robotiq.com/bid/40428/Using-The-Kinect-For-Robotic-Manipulation> para maiores informações.

Primariamente, as técnicas de fusão de mapas adotam uma estratégia off-line, isto é, o foco principal é encontrar uma forma eficiente para combinar mapas parciais previamente construídos gerando assim uma representação global, detalhada e consistente do ambiente. Esta estratégia contrasta com as soluções de SLAM com múltiplos robôs que é notadamente uma abordagem on-line visto que a operação de fusão acontece simultaneamente ao processo de construção dos mapas locais. A diferença mais marcante entre estas duas estratégias é a necessidade de comunicação entre os agentes (robôs/sensores). Na abordagem on-line, pressupõe-se que haja troca de informações durante o processo de mapeamento de tal forma que cada robô constrói um mapa local, mas utiliza observações coletadas por outros robôs para expandir e atualizar seu próprio mapa. Por outro lado, nas estratégias off-line a fusão acontece posteriormente ao processo de construção dos mapas parciais.

A abordagem de SLAM com múltiplos robôs (on-line) tem um forte caráter colaborativo e além de considerar o problema de fusão de mapas, têm que lidar com restrições de comunicação entre os agentes, processamento e armazenamento de dados à medida em que o número de robôs aumenta.

Em geral, os mapas locais estão referenciados a sistemas de coordenadas diferentes e o processo de fusão depende essencialmente do estabelecimento de um sistema de referência comum entre os robôs [8]. Portanto, uma etapa fundamental no processo de fusão é encontrar uma transformação entre os mapas parciais que resulte no alinhamento de suas estruturas sob um sistema de referência comum. Esta transformação pode ser obtida quando há sobreposição (regiões similares) entre os mapas locais. Contudo, a maior dificuldade reside em encontrar de forma robusta e precisa as regiões coincidentes em cada mapa [9].

III. TRABALHOS RELACIONADOS

Uma grande variedade de soluções foram produzidas ao longo dos últimos anos considerando diferentes representações de mapa, dispositivos de sensoriamento e métodos de obter uma transformação que promovesse um melhor alinhamento entre os mapas parciais. Uma breve porém elucidativa revisão foi apresentada em [10].

Uma tendência mais recente é o esforço por alcançar soluções eficientes para o problema de fusão de mapas em um espaço 6D, ou seja, assume-se que tanto o mapa quanto a localização dos sensores são representados em um ambiente tridimensional. Para o caso 6D, os autores em [11] defendem que os métodos de localização e mapeamento baseados em otimização de grafo de poses são as técnicas mais promissoras para se construir uma solução eficaz para o problema de fusão de mapas locais. Além disso, os mapas representados por grafos de poses são modelos mais flexíveis visto que sua topologia pode ser facilmente modificada e múltiplos mapas podem ser combinados criando uma nova estrutura composta por todos os nós e arestas dos grafos individuais. Nos últimos anos, várias abordagens em mapeamento colaborativo utilizaram técnicas

de SLAM formuladas com grafos de poses [12], [13], [14], [15], [16], [17], [18], [19].

Em [17] e [12] foram apresentadas soluções descentralizadas para o problema de mapeamento colaborativo em que os dados dos mapas locais são regularmente transmitidos entre todos os robôs. Os primeiros, propuseram um esquema robusto baseado em um algoritmo EM (*Expectation-Maximization*) para estabelecer um sistema de referência comum entre os robôs mesmo na presença de observações espúrias. Por outro lado, Lazaro et. al. em [12] desenvolveram uma maneira de condensar as informações do grafo de poses com o objetivo de reduzir os custos de transmissão dos mapas locais.

A proposta feita em [11] também baseia-se em uma arquitetura descentralizada e os autores apresentam um método para diminuir o esforço de otimização do grafo de poses empregando uma topologia que incorpora os resultados de um conjunto de filtros locais de acordo com a precisão de suas estimativas.

Outras soluções baseiam-se em uma estrutura centralizada em que as observações dos sensores ou os mapas locais são transferidos para uma estação central responsável por processar e integrar todos os dados.

Loianno et. al. em [15] apresentam um sistema de mapeamento cooperativo centralizado utilizando sensores RGB-D. Neste sistema, constrói-se os mapas locais a partir de um algoritmo de SLAM visual utilizando-se apenas as imagens RGB dos sensores. Todos os dados são enviados a um servidor central e as associações entre os mapas locais são feitas com base na informação de profundidade (D).

Em [13], cada robô constrói, de forma independente, um mapa local 3D representado por um grafo de poses. O processo de associação de dados entre os mapas locais é feito através da detecção mútua entre os robôs, ou seja, detectar se um robô é observado no campo de visão do outro e calcular uma transformação de coordenadas que relacione suas poses. Por fim, todos os dados são transferidos para um servidor central que executa o processo de fusão dos mapas locais.

Em [19], um servidor central agrega as experiências de cada agente, procura laços fechados nas trajetórias dos sensores e promove a fusão dos mapas locais, se necessário. O servidor pode retransmitir o mapa global atualizado de tal forma que um agente possa se beneficiar com as informações de outros agentes.

Para combater o problema de fusão em mapas distorcidos e afetados por incertezas nas observações dos sensores, Dinnissen et. al. [20] propuseram um método que combina algumas heurísticas sobre a qualidade das estimativas dos mapas locais e uma técnica de aprendizado por reforço para aprender quando executar o processo de fusão. Os autores empregam uma representação 2D e um filtro de partículas (RBPF-SLAM) durante o processo de construção dos mapas locais. Os próprios autores atestam que os resultados foram apresentados apenas em um cenário de simulação desenvolvido sob várias hipóteses simplificadoras, principalmente com relação ao treinamento do modelo de aprendizado por reforço.

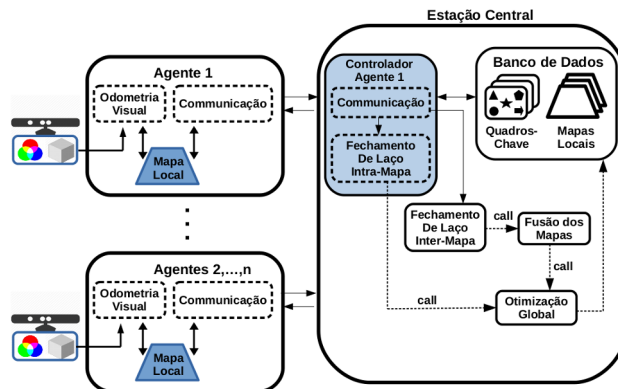


Figura 2. Arquitetura geral do sistema proposto.

O trabalho em [21] propõe uma abordagem de mapeamento que lida com a fusão de mapas locais ruidosos representados por grafo de poses. A solução apresentada pelos autores corrige as possíveis distorções em cada mapa aplicando um modelo de deformação local durante o processo de fusão. Contudo, as distorções em cada mapa são verificadas a posteriori e em nenhum momento os agentes têm acesso ao mapa global atualizado.

Esta proposta de pesquisa aproveita algumas características dos diversos trabalhos apresentados nesta seção. Os mapas locais são representados por uma estrutura em grafo de poses associadas a um conjunto de pontos 3D (nuvem de pontos) extraídos com base em um algoritmo de SLAM visual com sensores RGB-D. Utiliza-se uma arquitetura centralizada em um esquema parecido com o trabalho em [19]. Contudo, inspirando-se na técnica apresentada em [20], o servidor é capaz de decidir o melhor momento de realizar a fusão entre os mapas locais. Esta característica é especialmente importante uma vez que apenas a identificação de um laço fechado entre as trajetórias locais dos sensores não é suficiente para garantir a eficiência do processo de fusão. Apoiando-se em um modelo de aprendizado por reforço o servidor é capaz de aprender quando executar o processo de fusão baseado em uma medida de consistência dos mapas locais.

IV. METODOLOGIA

O sistema proposto compreende múltiplos agentes equipados com sensores RGB-D que são capazes de se comunicar com um servidor por meio de um canal de transmissão sem fio. Esta abordagem não assume nenhuma informação inicial sobre a posição dos agentes e cada um deles executa suas tarefas com relação a um sistema de coordenadas local. O servidor central acumula a experiência de cada agente (mapas locais) para geração de um mapa 3D global do ambiente. A Figura 2 mostra a arquitetura geral deste sistema.

A. Mapas Locais

Os mapas locais são construídos com um algoritmo conhecido na literatura como RGBD-SLAM [22]. Segundo esta técnica, o mapa é representado por uma estrutura em grafo, cujos nós são as posições do sensor ao longo da trajetória no

ambiente e as arestas ligam nós que apresentam observações em comum. Dependendo da abordagem utilizada, juntamente com cada nó deste grafo pode ser armazenado os seguintes dados: imagem RGB da cena, marcações visuais extraídas da imagem RGB e/ou uma nuvem de pontos 3D.

Os quadros adquiridos pelo sensor RGB-D são enviados a um sistema de odometria visual. O objetivo deste sistema é calcular, para cada quadro, o deslocamento do sensor através do rastreamento de um conjunto de pontos de interesse (*landmarks*) extraídos entre cenas sucessivas. Posteriormente, estes *landmarks* formarão os mapas locais construídos pelos agentes (nuvem de pontos 3D).

B. Fusão de Mapas Locais

Cada agente transmite para o servidor o grafo de posições no ambiente juntamente com as informações do mapa associadas a cada nó. O servidor é responsável por identificar similaridades entre os dados provenientes de cada agente e realizar o processo de fusão dos grafos recebidos. Uma vez identificada a existência de regiões similares calcula-se uma transformação de coordenadas entre os sistemas de referência local de cada agente. Desta forma, os dados locais (grafo de posições e pontos 3D associados a cada nó do grafo) de dois agentes diferentes podem ser representados com relação ao mesmo sistema de referência.

C. Aprendizado por Reforço

Em geral, sempre que um laço fechado entre dois mapas locais é identificado, procede-se o algoritmo de fusão. Independentemente do algoritmo de mapeamento utilizado, os mapas locais são sempre afetados por erros e imprecisões devido às incertezas das medidas dos sensores que não podem ser completamente removidas. Sob severas distorções, uma transformação adequada entre os mapas parciais não pode ser encontrada, mesmo que existam grandes regiões similares entre eles. Portanto, a eficiência do processo de fusão depende da consistência dos mapas locais.

A ideia principal desta proposta é especificar uma abordagem automática baseada em técnicas de aprendizado por reforço para aprender o melhor momento de integrar os mapas locais e minimizar a propagação das imprecisões para o mapa global. Os estados do modelo de aprendizado por reforço são construídos com base em uma heurística de consistência dos mapas locais. Utiliza-se a definição de consistência dada em [23]. Neste trabalho, os autores definem uma medida estatística de consistência do mapa e apresentam uma função de pontuação que quantifica a falta de correspondência nos dados dos sensores após a otimização do grafo de poses.

V. CONSIDERAÇÕES FINAIS

Para finalizar a proposta, atualmente estamos trabalhando na modelagem da técnica de aprendizado por reforço. Neste caso, considera-se duas classes de métodos: aprendizado por reforço *online* ou aprendizado por reforço em lotes. Seria necessário um estudo mais aprofundado para definir qual tipo de algoritmo usar e quais seriam as implicações práticas para o sistema proposto neste artigo.

REFERÊNCIAS

- [1] KHAIRUDDIN, A. R.; TALIB, M. S.; HARON, H. Review on simultaneous localization and mapping (slam). In: *2015 IEEE International Conference on Control System, Computing and Engineering (ICCSCE)*. [S.l.: s.n.], 2015. p. 85–90.
- [2] SAEEDI, S. et al. Multiple-robot simultaneous localization and mapping: A review. *Journal of Field Robotics*, v. 33, n. 1, p. 3–46, 2016. ISSN 1556-4967. Disponível em: <<http://dx.doi.org/10.1002/rob.21620>>.
- [3] GRANDI, J. G. et al. Collaborative manipulation of 3d virtual objects in augmented reality scenarios using mobile devices. In: *2017 IEEE Symposium on 3D User Interfaces (3DUI)*. [S.l.: s.n.], 2017. p. 264–265.
- [4] SAEEDI, S. et al. Map merging for multiple robots using hough peak matching. *Robotics and Autonomous Systems*, v. 62, n. 10, p. 1408 – 1424, 2014. ISSN 0921-8890. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0921889014001134>>.
- [5] ENDRES, F. et al. 3-d mapping with an rgb-d camera. *IEEE Transactions on Robotics*, v. 30, n. 1, p. 177–187, Feb 2014. ISSN 1552-3098.
- [6] NEWCOMBE, R. A. et al. Kinectfusion: Real-time dense surface mapping and tracking. In: *2011 10th IEEE International Symposium on Mixed and Augmented Reality*. [S.l.: s.n.], 2011. p. 127–136.
- [7] CARPIN, S.; BIRK, A.; JUCIKAS, V. On map merging. *Robotics and Autonomous Systems*, v. 53, n. 1, p. 1 – 14, 2005.
- [8] ROMERO, V. A.; COSTA, O. L. V. Map merging strategies for multi-robot fastslam: A comparative survey. In: *2010 Latin American Robotics Symposium and Intelligent Robotics Meeting*. [S.l.: s.n.], 2010. p. 61–66.
- [9] RONE, W.; BEN-TZVI, P. Mapping, localization and motion planning in mobile multi-robotic systems. *Robotica*, Cambridge University Press, v. 31, n. 1, p. 1–23, 2013.
- [10] LEE, H. C. et al. A survey of map merging techniques for cooperative-slam. In: *2012 9th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*. [S.l.: s.n.], 2012. p. 285–287.
- [11] SCHUSTER, M. J. et al. Multi-robot 6d graph slam connecting decoupled local reference filters. In: *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. [S.l.: s.n.], 2015. p. 5093–5100.
- [12] LÁZARO, M. T. et al. Multi-robot slam using condensed measurements. In: *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*. [S.l.: s.n.], 2013. p. 1069–1076.
- [13] CHEN, H. et al. Pose-graph based 3d map fusion with distributed robot system. In: *2014 IEEE International Conference on Robotics and Biomimetics (ROBIO 2014)*. [S.l.: s.n.], 2014. p. 1608–1613.
- [14] RIAZUELO, L.; CIVERA, J.; MONTIEL, J. C2tam: A cloud framework for cooperative tracking and mapping. *Robotics and Autonomous Systems*, v. 62, n. 4, p. 401 – 413, 2014.
- [15] LOIANNO, G.; THOMAS, J.; KUMAR, V. Cooperative localization and mapping of mavs using rgb-d sensors. In: *2015 IEEE International Conference on Robotics and Automation (ICRA)*. [S.l.: s.n.], 2015. p. 4021–4028.
- [16] MOHANARAJAH, G. et al. Cloud-based collaborative 3d mapping in real-time with low-cost robots. *IEEE Transactions on Automation Science and Engineering*, v. 12, n. 2, p. 423–431, April 2015.
- [17] INDELMAN, V. et al. Incremental distributed inference from arbitrary poses and unknown data association: Using collaborating robots to establish a common reference. *IEEE Control Systems*, v. 36, n. 2, p. 41–74, April 2016. ISSN 1066-033X.
- [18] DEUTSCH, I.; LIU, M.; SIEGWART, R. A framework for multi-robot pose graph slam. In: *2016 IEEE International Conference on Real-time Computing and Robotics (RCAR)*. [S.l.: s.n.], 2016. p. 567–572.
- [19] SCHMUCK, P.; CHLI, M. Multi-uav collaborative monocular slam. In: *2017 IEEE International Conference on Robotics and Automation (ICRA)*. [S.l.: s.n.], 2017. p. 3863–3870.
- [20] DINNISSSEN, P.; GIVIGI, S. N.; SCHWARTZ, H. M. Map merging of multi-robot slam using reinforcement learning. In: *2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. [S.l.: s.n.], 2012. p. 53–60. ISSN 1062-922X.
- [21] BONANNI, T. M.; CORTE, B. D.; GRISSETTI, G. 3-d map merging on pose graphs. *IEEE Robotics and Automation Letters*, v. 2, n. 2, p. 1031–1038, April 2017.
- [22] ENDRES, F. et al. 3-d mapping with an rgb-d camera. *IEEE Transactions on Robotics*, v. 30, n. 1, p. 177–187, Feb 2014. ISSN 1552-3098.
- [23] MAZURAN, M. et al. A statistical measure for map consistency in slam. In: *2014 IEEE International Conference on Robotics and Automation (ICRA)*. [S.l.: s.n.], 2014. p. 3650–3655. ISSN 1050-4729.

**COMUNICAÇÕES
DE
PUBLICAÇÕES**

Energy Map Model for Software-Defined Wireless Sensor Networks

Gustavo A. Núñez; Cintia B. Margi

Department of Computer Engineering and Digital Systems - University of São Paulo

E-mail: gnunez@larc.usp.br, cintia@usp.br

Abstract—Wireless sensor networks (WSN) is a technology commonly used for remote monitoring, tracking and detection applications. Since energy efficiency is a major concern in WSN, to know the remaining energy on each node could optimize the energy consumption. We propose a novel method to create an energy map for a Software-Defined Wireless Sensor Network (SDWSN). We implement an energy consumption prediction model into the controller, which obtains information of each node and estimates its energy consumption rate. This approach reduces the node processing overhead and memory usage when compared to other approach available.

Keywords— Wireless Sensor Networks, Software-Defined Networking, energy map.

Classification— Article publishing communication

REFERENCE

- [1] Núñez, G; Margi, C. Energy Map Model for Software-Defined Wireless Sensor Networks. *XXXV Brazilian Communications and Signal Processing Symposium (SBrT 2017)*. September, 2017. http://www.sbrt.org.br/sbrt2017/anais/anais_sbrt_2017.pdf

Evaluating Safety and Efficiency in Aircraft Sequencing in Final Approach considering the UAS Presence

Euclides Pinto Neto, Derick M. Baum,
Jorge R. Almeida Jr., João B. Camargo Jr., Paulo S. Cugnasca
School of Engineering - University of São Paulo (Poli - USP)
São Paulo, Brazil
{euclidescpn, derick.baum, jorgerady, joaocamargo, cugnasca}@usp.br

Abstract—Nowadays, considering the increasingly adoption of new technologies into the shared airspace, there are many challenges to be accomplished. Among these technologies, Unmanned Aircraft Systems (UAS), which has military and civilian applications, play an important role. There is an understanding that Air Traffic Controllers (ATCos) may be careful when dealing with this technology due to the lack of familiarity with it, which leads to a higher workload. However, in a futuristic scenario, UAS may operate along with traditional aircraft. In this paper, we present a simulation tool, called Final Sector Simulation Tool (FSST), which aims evaluate safety (from workload perspective) and efficiency in aircraft sequencing in final sector considering the UAS presence. Also, bad weather conditions and the Technology Maturity Level (TML), which models the level of familiarity of ATCo with these aircraft, are considered. The experiments, which achieved realistic results in terms of sequencing duration, showed that UAS has a considerable impact on ATCo workload.

Keywords— UAS; Levels of Safety; Airspace Management.

Classification— Master's degree (beginner)

REFERENCE

- [1] Neto, Euclides Pinto, et al. "Evaluating Safety and Efficiency in Aircraft Sequencing in Final Approach Considering the UAS Presence" XXXI Congresso de Pesquisa e Ensino em Transportes, 2017.

ANALISE DE ASPECTOS DE SEGURANÇA (SAFETY) PARA A INSERÇÃO DE VANTS EM UM ESPAÇO AEREO NÃO SEGREGADO

Almeida, V. M. de; Cugnasca, P. S.

Grupo de Análise de Segurança- Universidade de São Paulo
viniciusmda@usp.br, cugnasca@eec.br

Abstract— UAVs insertion in airspace may cause probability increase of aircrafts collision. For this insertion it is required that UAV safety levels are greater or similar to those of manned aircrafts. Detection research using sensing fusion techniques has been created and allows UAVs to detect and avoid other aircrafts. This work analyzes failure probability of a detection system through the use of Bayesian networks, calculating its reliability using decision trees and Markov model. Finally, the safety analysis of UAVs insertion in non-segregated airspace is presented.

Keywords— UAV; sense and avoid; safety.

Resumo— A inserção de Veículos Aéreos Não Tripulados – VANTS em um espaço aéreo pode aumentar a possibilidade de colisão entre aeronaves. Para esta inserção, a ICAO requer que os níveis de segurança relacionados aos VANTS sejam maiores ou similares aos de aeronaves tripuladas. Pesquisas vêm criando mecanismos para permitir aos VANTS detectar e desviar de outras aeronaves, utilizando-se de técnicas de detecção por fusão de sensores. Este trabalho apresenta uma análise de segurança (safety) de um sistema de detecção, calculando sua confiabilidade através de árvores de falha e de modelo de diagrama de bloco, bem como a probabilidade de falha utilizando redes bayesianas..

Palavras-chave— VANTS; Detecção; Safety.

Classificação— Comunicação de Submissão no Sitraer

REFERENCE

- [1] Almeida, V. M. de; Cugnasca, P. S (Submetido). ANALISE DE ASPECTOS DE SEGURANÇA (SAFETY) PARA A INSERÇÃO DE VANTS EM UM ESPAÇO AEREO NÃO SEGREGADO. XVI *Sitraer*. October, 2017.

Discovery protocols for SDN-based Wireless Sensor Networks with unidirectional links

Alves, R. C. A.*; Margi, C. B.*;

*Computing and Digital Systems Department – University of Sao Paulo

E-mail: {renanalves, cintia}@usp.br

Abstract—Ad hoc and wireless sensor networks routing protocols are usually oblivious to the existence of unidirectional links. We propose to use Software Defined Network to take advantage of these links, instead of using the flooding-based or specific-purpose protocols found in the literature. To achieve this goal, it is necessary to devise Controller Discovery and Neighbor Discovery protocols tailored for unidirectional networks. We designed and implemented such algorithms and compared to the traditional Collect-based approach. The results show that SDN is a promising alternative to routing in unidirectional networks.

Keywords— Wireless sensor networks; Software defined networks; Unidirectional networks; Neighbor Discovery.

Classification— Article publishing communication

REFERENCE

- [1] ALVES, R. C. A.; MARGI, C. B. Discovery protocols for SDN-based Wireless Sensor Networks with unidirectional links. In: *XXXV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*. Rio de Janeiro - RJ: SBrT, 2017.

Applying Copeland Voting to Design an Agent-Based Hyper-Heuristic

Vinicius Renan de Carvalho; Jaime Simão Sichman

*Intelligent Techniques Laboratory (LTI)

Computer Engineering Department (PCS)

University of So Paulo (USP)

E-mail: {vrcarvalho,jaime.sichman}@usp.br

Abstract—Meta-heuristics are algorithms which are applied to solve problems when conventional algorithms can not find good solutions in reasonable time; evolutionary algorithms are perhaps the most well-known examples of meta-heuristics. As there are many possible meta-heuristics, finding the most suitable meta-heuristic for a given problem is not a trivial task. In order to make this choice, one can design hyper-heuristics. In the literature, one can find some agent-based research whose focus is to propose a framework where meta-heuristics are considered as agents, that solve a given problem in a collaborative or competitive way. Most of these works focus on mono-objective meta-heuristics. Other works focus on how to select multi-objective meta-heuristics, but not using an agent-based approach. We present in this work an agent-based hyper-heuristic for choosing the most suitable evolutionary meta-heuristic for a given problem. Our approach performs a cooperative Copeland voting procedure, considering five different metrics, to define which one of three competitive evolutionary meta-heuristics should execute during a certain processing time. We use the Walking Fish Problem (WFG) suite with two and three objectives to analyse the proposed approach performance. The obtained results showed that in all cases our strategy found the most indicated evolutionary algorithm and gets competitive results against the state of art.

Keywords— Meta-heuristics, Hyper-heuristics, Evolutionary algorithms, Self-organization, Complex systems, Analysis of agent-based simulations, Agent cooperation.

Classification— Paper published on Proceedings of the 16th Conference on Autonomous Agents and MultiAgent Systems (AAMAS'2017) [1].

REFERENCE

- [1] CARVALHO, V. R. de; SICHMAN, J. S. Applying Copeland Voting to Design an Agent-Based. In: *Proceedings of the 16th Conference on Autonomous Agents and MultiAgent Systems*. [S.l.: s.n.], 2017. p. 972–980.

Enabling Data Legitimacy in Data-Driven Projects

ANDRÉ F. M. BATISTA*, DANIEL L. da SILVA*, PEDRO L. P. CORREA*

* Escola Politécnica da Universidade de São Paulo (POLI-USP) - São Paulo - Brazil
{andrefmb, daniellins, pedro.correa}@usp.br

Abstract—In the last decade, Science has been faced with an enormous amount of data from a wide range of sources, such as the Internet, social media, IoT devices, and so on. Increasingly it is essential to develop methods and tools that enable the most varied forms of understanding of the data and transformation processes involved in an experiment. The veracity dimension plays an essential role in meeting these needs, and it must be incorporated into a data management process. This paper presents a proposal of an architecture model for a Data Portal that provides users the ability of assessment of the legitimacy of datasets. Legitimacy consists of the communication of decisions in the construction of computational models and the provenance of the data. We present the proposed architecture and how it can be embedded in scientific data portals.

Keywords— Data Science, Data Veracity, Data Legitimacy, Data Understandability, IoT.

Classification— Article publishing communication

REFERENCES

- [1] BATISTA, A. F. M.; SILVA, D. L.; CORREA, P. L. P. Enabling Data Legitimacy in Data-Driven Projects. *Proceedings of the IEEE International Conference on Current Trends in Computer, Electrical, Electronics and Communication (ICCTCEEC 2017)*, Mysuru, Karnataka, India. Sep, 2017.

ErgoMobile: A Software to Support Usability Evaluations in Mobile Devices Using Observation Techniques

COLETI, T. A.*; SOUZA, L. S.†; MORANDINI, M.‡; ALLARD, S.§; CORREA, P. L. P.*

*School of Engineering, University of Sao Paulo, Sao Paulo, Brazil

† Center of Technological Sciences, Northern State University of Parana, Bandeirantes, Parana Brazil

‡ School of Arts, Sciences and Humanities of University of Sao Paulo, Sao Paulo, Brazil

§ University of Tennessee, Knoxville, USA

E-mail: {thiagocoleti,m.morandini, pedro.correa}@usp.br, leticiasap@gmail.com, sallard@utk.edu

Abstract—The characteristics of mobile devices and their applications have led to changes in the way these systems are developed and tested. Usability tests are stages of development that are under constant modifications, since it is being taken into account that traditional techniques may not be sufficient to accomplish the testing activity for mobile devices. For example, the User Observation and Filming/Verbalization techniques involve the use of secondary devices to record the data. This may be a problem as the testing activity can become more complex and less comfortable for the users/evaluators. Aiming to present a strategy to minimize this issue, we are presenting the ErgoMobile environment that was developed with the main objective of avoiding the use of secondary devices since it can be installed directly in the mobile device and can collect images from the camera, sounds from the microphone and store interface snapshots. Initial tests presented that this tool behaves well when working in conjunction with other mobile applications, collecting good amounts of data and working in the background and practically had not created any disturbances to the participant or to the evaluator.

Keywords— Usability Test, Mobile Device, Mobile Application, Observation

Classification— Article publishing communication

REFERENCE

- [1] COLETI, T.A.; SOUZA, L. S.; MORANDINI, M.; ALLARD, S.; CORREA, P. L. P., ErgoMobile: A Software to Support Usability Evaluations in Mobile Devices Using Observation Techniques. *Proceedings of Human Computer Interaction International Conference - DUXU 2017, Part I, LNCS 10288* (HCII). v. 18, n. 1, p. 363-378, July, 2017, DOI: 10.1007/978-3-319-58634-2_27.

Controlling Gene Regulatory Networks with FQI-SARSA

NISHIDA, C. E. H.*; COSTA, A. H. R.*; BIANCHI, R. A. C.†

*Escola Politécnica - Universidade de São Paulo

†Departamento de Engenharia Elétrica – Centro Universitário FEI
{cyntiaeico, anna.reali}@usp.br, rbianchi@fei.edu.br

Abstract—External control of a gene regulatory network model can help accelerate the design of treatments to make it avoid diseased states. However, inferring this model and then controlling it has an exponential complexity of time and space, making large networks infeasible for model dependent approaches. This is visible in the literature as only models with at most dozens of genes could be used in control problems. We propose to apply a batch reinforcement learning method Fitted Q Iteration Sarsa for controlling partially observable gene regulatory networks directly from data, with a new reward function and a way to create experience tuples from gene expression samples. Our framework produces approximate stochastic policies without restricting it to time series samples, allowing it to freely manage the experience tuples. Results demonstrate that our method is more effective than previous studies, with a higher shifting between undesirable to desirable states and higher expected reward.

Keywords— Reinforcement Learning; Gene Network control;
Classification— Article publishing communication.

REFERENCE

- [1] NISHIDA, C. E. H.; COSTA, A. H. R. ; BIANCHI, R. A. C. . Controlling Gene Regulatory Networks with FQI-SARSA. In: Brazilian Conference on Intelligent Systems, 2017, Uberlândia. 6th Brazilian Conference on Intelligent Systems (BRACIS), 2017. v. 1. p. 216-221.

Positional Information from GNSS/GBAS and its Safety-Critical Applications from a UAS Perspective

BARALDI SESSO, D.*; BALVEDI, G. C.†; MELLO, M. P.†; CAMARGO JUNIOR, J. B.*

* Grupo de Análise de Segurança (GAS) – Escola Politécnica da Universidade de São Paulo

† Boeing Research & Technology (BR&T) – São José dos Campos / SP, Brasil

* {daniel.baraldi, joaocamargo}@usp.br, † {glauca.c.balvedi, marcio.p.mello}@boeing.com

Abstract — The demand for increasing air traffic volume has been pressing aviation authorities for more efficient operations in Air Traffic Management (ATM) systems. Nevertheless, new technologies, such as Global Navigation Satellite System (GNSS) and its augmentation systems (SBAS and GBAS, Satellite- and Ground-Based Augmentation System, respectively) should be assessed. Correctness of positional information is essential to avoid exposure to hazards, especially during approach and landing phases. This paper presents a literature review of related works that use GNSS and its augmentation systems for safety-critical flight operations and discusses its usage in applications for Unmanned Aerial System (UAS) case.

Keywords — Satellite-Based Augmentation System, Ground-Based Augmentation System, Global Navigation Satellite System, Landing procedures, Flight operations.

Classification — Article publishing communication

REFERENCE

- [1] BARALDI SESSO, D.; BALVEDI, G. C.; MELLO, M. P.; CAMARGO JUNIOR, J. B. Positional Information from GNSS/GBAS and its Safety-Critical Applications from a UAS Perspective. *In: XVI Air Transportation Symposium (SITRAER)*, Rio de Janeiro, RJ, Brasil. *Proceedings...* Rio de Janeiro, RJ, Brasil: SBTA – Sociedade Brasileira de Transporte Aéreo, 2017.

A review on aeronautical decision-making and artificial intelligence for unmanned aircraft

MATSUMOTO, T. T.; CAMARGO JUNIOR, J. B.

Escola Politécnica da Universidade de São Paulo – EPUSP
{tmatsumoto, joacamargo}@usp.br

Abstract— We present a review of decision-making concepts with focus on Aeronautical Decision-Making (ADM), traditionally performed by humans, and possible decision-making methods presented in Artificial Intelligence (AI) literature, with focus on collision avoidance. Additionally, from the human decision-making model used in ADM, we perform a comparison with AI methods with the objective of identifying advantages and disadvantages of replacing a human by an AI-based system within an aircraft. The identification of the state of the art on those subjects will be used as basis to future researches on unmanned aircraft autonomous operation.

Keywords— *Aeronautical decision-making; artificial intelligence; UAS.*

Classification— **Article publishing communication**

REFERENCE

- [1] MATSUMOTO, T. T.; CAMARGO JUNIOR, J. B. A review on aeronautical decision-making and artificial intelligence for unmanned aircraft. *XVI SITRAER – Simpósio de Transporte Aéreo*, 2017, pp. 1-10, submitted for publication.

ÍNDICE DE AUTORES

ALLARD, S.	123
ALMEIDA JR, J.R.	26, 61
ALMEIDA, V.M.	119
ALVES, E.	112
ALVES, R.C.A.	120
ALVES-SOUZA, S.N.	10
BALVEDI, G.C.	125
BARALDI SESSO, D.	125
BARBOSA, W.L.	6
BASTOS, R.M.	50
BATISTA, A.F.M.	122
BAUM, D.M.	61, 118
BERGAMASCO, L.C.C.	100
BERTANI, R.M.	34
BEVILACQUA, J.S.	84
BIANCHI, R.A.C.	34, 124
BONINI, R.C.	2
BRANDÃO, A.A.F.	23, 84
CAMARGO JR, J.B.	61, 125, 126
CARVALHO, T.C.M.B.	38, 88
CARVALHO, V.R.	121
CAYA, R.E.C.	80
COLETI, T.A.	123
CORRÊA, M.P.	46
CORRÊA, P.L.P.	6, 104, 122, 123
COSTA, A.H.R.	2, 34, 96, 108, 112, 124
COZMAN, F.G.	15, 77
CRUZ, E.	77
CUGNASCA, C.E.	69, 73
CUGNASCA, P.S.	61, 118, 119
FARIA, F.H.P.V.	15
FERREIRA, L.M.	42
FONTES, S.G.	104
FRANCISCO, M.M.C.	65
GLATT, R.	108
GONZALEZ, L.A.C.	10
GUSMÃO, A.C.	15
KAWANO, B.R.	73
KIM, H.Y.	92
LUZ, T.C.	53

MARGI, C.B.	53, 117, 120
MATSUMOTO, T.T.	126
MAUÁ, D.D.	15
MELLO, M.P.	125
MORANDINI, M.	123
MOSTAÇO, G.M.	69
NAKAMURA, R.	57
NETO, E.P.	61
NETO, J.J.	80
NISHIDA, C.E.H.	124
NUNES, F.L.S.	57, 100
NUÑEZ, G.A.	117
PEREIRA, J.P.A.	84
PINTO NETO, E.C.	118
PROTO, A.	88
RAMOS, J.E.	92
REIS, E.R.	30
ROCHA, R.L.A.	50
ROCHITTE, C.E.	100
SESSO, D.B.	
SICHMAN, J.S.	30, 121
SILVA, A.M.	50
SILVA, C.I.L.C.	23
SILVA, D.L.	122
SILVA, F.L.	96
SILVA, L.S.	57
SILVA, R.B.	19
SIQUEIRA, F.L.	19, 23
SOUZA, L.S.	123
SOUZA, S.N.A.	6, 42, 46, 65
STANZANI, S.L.	104
TANCREDI, F.B.	92
TANCREDI MOLINA, C.B.S.	26
VISCONDI, G.F.	46
ZORELLO, L.M.M.	38