

Valentin Michel Raymond Catherine

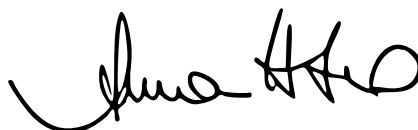
FinGAT: Redes Neurais de Grafos Para a Precificação de Ativos Financeiros

São Paulo, SP

2023

São Paulo, 12 de dezembro de 2023.

De acordo,

A handwritten signature in black ink, appearing to read 'Anna Helena Realí Costa', written in a cursive style.

Anna Helena Realí Costa

Valentin Michel Raymond Catherine

FinGAT: Redes Neurais de Grafos Para a Precificação de Ativos Financeiros

Trabalho de conclusão de curso apresentado ao Departamento de Engenharia de Computação e Sistemas Digitais da Escola Politécnica da Universidade de São Paulo para obtenção do Título de Engenheiro.

Universidade de São Paulo – USP

Escola Politécnica

Departamento de Engenharia de Computação e Sistemas Digitais (PCS)

Orientador: Prof. Anna Helena Reali Costa

Coorientador: Prof. Marcel Rodrigues de Barros

São Paulo, SP

2023

Agradecimentos

Gostaria de expressar minha mais profunda gratidão à minha família na França, que, mesmo a milhares de quilômetros de distância, nunca deixou de me apoiar através das nossas conversas e chamadas. O carinho e o incentivo de vocês foram fundamentais para a realização deste trabalho.

Um agradecimento especial à minha namorada, que tornou a minha estadia no Brasil muito mais prazerosa. A sua companhia, compreensão e amor incondicional foram um pilar de força e conforto durante esta jornada.

Não posso esquecer de agradecer a família dela, que me proporcionou um verdadeiro sentimento de lar, me acolhendo e me dando um sabor da união e carinho familiar aqui no Brasil.

Em fim, gostaria de agradecer o Pedro Forli, colega de trabalho na Oliver Wyman, que me apoiou e ensinou durante o meu estágio. Sua orientação e experiência foram de imenso valor e tiveram um impacto significativo no meu desenvolvimento profissional.

Resumo

A capacidade de prever movimentações no mercado de ações é de grande interesse para o setor financeiro. Este trabalho investiga o uso de Redes Neurais de Grafos (GNN), especificamente através do modelo FinGAT, como uma ferramenta para melhorar a precisão das previsões financeiras. Foi constatado que, no setor bancário, a abordagem utilizando a estrutura em grafo mostrou-se promissora, proporcionando previsões mais precisas para empresas que operam dentro de um mesmo setor. Por outro lado, a inclusão de variáveis fundamentais e macro-econômicas não apresentou uma melhoria consistente na acurácia das previsões, indicando a necessidade de uma seleção criteriosa dessas informações adicionais. Os resultados indicam que a modelagem baseada em grafos tem potencial para refinar as previsões no mercado de ações, especialmente quando adaptada a um grupo de ativos do mesmo setor.

Palavras-chave: Mercado de Ações, Previsão Financeira, Redes Neurais de Grafos, Análise Setorial.

Abstract

The ability to predict stock market movements is of great interest to the financial sector. This work investigates the use of Graph Neural Networks (GNN), specifically through the FinGAT model, as a tool to enhance the accuracy of financial forecasts. It was found that in the banking sector, the approach using a graph structure proved promising, providing more accurate predictions for companies operating within the same sector. However, the inclusion of fundamental and macro-economic variables did not consistently improve forecast accuracy, indicating the need for careful selection of these additional pieces of information. The results indicate that graph-based modeling has potential to refine predictions in the stock market, especially when adapted to a group of assets from the same sector.

Keywords: Stock Market, Financial Forecasting, Graph Neural Networks, Sector Analysis.

Lista de abreviaturas e siglas

SVB	Silicon Valley Bank
ML	Aprendizado de Máquina
GNN	Redes Neurais de Grafos
B3	Brasil, Bolsa, Balcão – é uma bolsa de valores brasileira sediada na cidade de São Paulo
NYSE	<i>New York Stock Exchange</i> , ou Bolsa de Valores de Nova York
SVM	<i>Support Vector Machine</i> , ou Máquinas de Vetores de Suporte
KNN	<i>K Nearest Neighbor</i> , ou K-Vizinhos mais Próximos
GAT	Rede de Atenção em Grafos
GRU	Gated Recurrent Unit
MLP	Perceptron Multicamadas
RMSE	Erro Médio Quadrático
MAPE	Erro Médio Percentual Absoluto

Sumário

1	INTRODUÇÃO	13
1.1	Motivação	13
1.2	Objetivos	14
1.3	Justificativa	14
1.4	Organização do Trabalho	15
2	ASPECTOS CONCEITUAIS	17
2.1	Os Ativos Financeiros	17
2.2	Variáveis de Interesse	17
2.2.1	Indicadores da Empresa	18
2.2.2	Indicadores Econômicos	18
2.3	Modelos de Redes Neurais	19
2.3.1	Perceptron Multicamadas	19
2.3.2	Redes Neurais Recorrentes	20
2.3.3	Redes Neurais de Grafos	21
2.3.3.1	Teoria dos grafos	21
2.3.3.2	Passagem de Mensagens em GNNs	22
2.3.3.3	GAT (Redes de Atenção em Grafos)	23
3	ESPECIFICAÇÃO DE REQUISITOS	27
3.1	Requisitos Funcionais	27
3.2	Requisitos Não Funcionais	27
4	PROPOSTA: FINGAT	29
4.1	Introdução	29
4.1.1	Variáveis de Entrada	30
4.1.2	Positional Encoding	30
4.1.3	Codificação Final da Empresa	31
4.1.4	Variáveis Econômicas	33
4.1.5	Regressão	33
5	METODOLOGIA	35
5.1	Aquisição de dados	35
5.2	Treinamento e teste do modelo	35
5.2.1	Definição dos Conjuntos de Treinamento e Teste	35
5.2.2	Mecanismo de Janela Deslizante	36

5.2.3	Métrica de Erro e Avaliação	36
5.2.4	Exemplo Prático e Ilustração	37
5.2.5	Definição dos Hiperparâmetros	37
5.2.6	Definição dos Dados	37
5.3	Experimentos	38
6	DESENVOLVIMENTO DO TRABALHO	43
6.1	Tecnologias Utilizadas	43
6.1.1	Python e Visual Studio Code (VSCode)	43
6.1.2	GitHub	43
6.1.3	Notebooks	43
6.1.4	PyTorch	44
6.1.5	Ferramenta de Linha de Comando	44
6.1.6	Streamlit	44
6.2	Projeto e Implementação	44
6.2.1	Hyperparametros	44
6.2.2	Pipeline de Automação do Processo	45
6.3	Resultados Experimentais	45
6.3.1	Experimento 1: Influência da Estrutura em Grafo na Precisão de Previsão	46
6.3.2	Experimento 2: Comparação Setorial	47
6.3.3	Experimento 3: Integração de Variáveis Fundamentais e Econômicas	47
6.4	Testes e Avaliação	48
6.4.1	Teste de Hardware	48
6.4.2	Teste de Software	49
6.4.3	Teste de Módulo	49
6.4.4	Teste de Integração	49
6.4.5	Teste de Validação	49
7	CONSIDERAÇÕES FINAIS	51
7.1	Conclusões do Projeto de Formatura	51
7.2	Contribuições	51
7.3	Perspectivas de Continuidade	52
	REFERÊNCIAS	53

1 Introdução

1.1 Motivação

A busca para prever com precisão desenvolvimentos futuros, particularmente no âmbito financeiro, tem sido um esforço constante da inteligência humana. Aspirações para prever as flutuações do mercado, como a ascensão dramática do Bitcoin ou o colapso inesperado do *Silicon Valley Bank* (SVB), sem dúvida, oferecem a possibilidade de gerar lucros. Um exemplo notável de tal estratégia bem-sucedida é o grupo de indivíduos que lucrou com a crise financeira de 2007-2008 apostando contra o mercado (LEWIS, 2010).

Na era atual de metodologias emergentes de aprendizado de máquina (ML, de *Machine Learning*) e abundância de dados, a proposta de desenvolver modelos para prever preços de ações apresenta uma oportunidade intrigante. Se esses modelos forem desenvolvidos com sucesso, eles poderiam gerar lucros significativos através de decisões financeiras adequadas. Conseqüentemente, ao longo das últimas décadas, especialistas de várias áreas, incluindo economia, engenharia financeira, estatística, pesquisa operacional e aprendizado de máquina, dedicaram-se a desvendar este problema complexo (ABARBANELL; BERNARD, 1992; BLUME; EASLEY; O'HARA, 1994; ADEBIYI; ADEWUMI; AYO, 2014; ADAM; MARCET; NICOLINI, 2016).

Grande parte da literatura existente (NAZÁRIO et al., 2017; SUGUMAR; ALWAR; JAYAKUMAR, 2014; LIN, 2018; LIN et al., 2021) por exemplos se concentrou na análise técnica, empregando indicadores baseados em preço e volume para identificar tendências nos movimentos dos preços das ações. No entanto, essa abordagem contradiz a hipótese do mercado eficiente, que postula que se o mercado for eficiente em sua forma fraca, o preço de uma ação seguirá um modelo de passeio aleatório e não pode ser previsto com precisão através da análise de preços históricos (FAMA, 1991). O cerne do desafio reside na natureza complexa dos preços, além da influência dos numerosos fatores macroeconômicos, como o desempenho da empresa e as condições econômicas gerais, observados por Ticknor (2013).

Para abordar esse desafio, um novo modelo de aprendizado de máquina conhecido como Redes Neurais em Grafos emergiu, que pode lidar habilmente com dados complexos representando-os dentro de uma estrutura de grafo (SCARSELLI et al., 2009).

1.2 Objetivos

Este projeto de formatura foca no desenvolvimento e análise de um modelo de GNN para a precificação no mercado de ativos financeiros. O objetivo central é investigar se a representação das empresas em forma de grafo oferece uma abordagem promissora para previsões financeiras. Para isso, pretendemos responder às seguintes questões específicas:

- **Influência da Estrutura em Grafo na Precisão de Previsão:** De que maneira a modelagem em forma de grafo contribui para a eficácia da previsão de preços de ativos? Existem diferenças significativas na performance do modelo quando comparado a estruturas tradicionais de dados?
- **Comparação Setorial:** A estrutura em grafo é mais vantajosa para empresas dentro do mesmo setor ou para aquelas em setores diversos? Como as interconexões setoriais influenciam a precisão do modelo?
- **Integração de Variáveis Fundamentais e Econômicas:** Como a adição de variáveis fundamentais (como lucros, dívidas, etc.) e indicadores econômicos (taxas de juros, índices de mercado, etc.) afeta a modelagem em grafo e sua capacidade de previsão? Qual o impacto desses fatores na rede e na performance do modelo?

Estas questões guiarão a pesquisa na avaliação da eficácia das Redes Neurais de Grafos na precificação de ativos financeiros, considerando tanto a estrutura interna das empresas quanto suas interações setoriais e econômicas.

1.3 Justificativa

O presente trabalho visa avaliar a relevância das GNNs para modelar eficazmente essas conexões, representando a estrutura de grafos que incorpora as relações entre os componentes do mercado financeiro.

Historicamente, métodos estatísticos e de aprendizado de máquina (ML) convencionais, como modelos baseados em Árvores de Decisão (VU et al., 2012), Máquinas de Vetores de Suporte (SVM, de *Support Vector Machine*) (XIE et al., 2013), e o modelo de K-Vizinhos mais Próximos (KNN, de *K Nearest Neighbor*) (HELLSTRÖM; HOLMSTRÖM, 1998) têm sido amplamente aplicados no mercado financeiro. No entanto, esses métodos frequentemente encontram dificuldades ao lidar com a complexidade e a dinâmica não linear dos dados financeiros.

As Redes Neurais de Grafos (GNNs) surgem como uma alternativa promissora nesse contexto, pela sua habilidade em capturar e modelar as interações complexas entre ativos

financeiros. As GNNs oferecem vantagens significativas para a modelagem do mercado financeiro:

1. As GNNs permitem a análise de relações interativas entre ativos, considerando não apenas os atributos individuais, mas também como eles se influenciam mutuamente dentro da rede do mercado financeiro;
2. A natureza flexível das GNNs possibilita a incorporação de diversas fontes de dados, como séries temporais financeiras, dentro de uma única estrutura de grafo, facilitando uma análise mais holística;
3. Além disso, as GNNs podem ser eficazes na identificação de padrões ocultos e na previsão de tendências do mercado, superando desafios encontrados em modelos ML tradicionais.

Este trabalho foca em avaliar como as GNNs podem ser aplicadas na modelagem do mercado financeiro, explorando a capacidade dessas redes de representar de forma eficiente as complexas estruturas de interações entre os diferentes componentes desse mercado.

1.4 Organização do Trabalho

O Capítulo 2, *Aspectos Conceituais* (2), introduz os conceitos fundamentais relacionados ao modelo GNN e à sua aplicação no mercado financeiro, estabelecendo a base teórica para o trabalho.

O Capítulo 3, *Especificação de Requisitos* (3), aborda a especificação detalhada dos requisitos do projeto, englobando aspectos funcionais e não funcionais, além de definir as métricas de sucesso do modelo proposto.

No Capítulo 4, *Proposta* (4), é delineada a proposta de pesquisa, incluindo a formulação do problema, os objetivos específicos e a abordagem preliminar para o uso de GNNs no mercado financeiro.

Em seguida, o Capítulo 5, *Metodologia do Trabalho* (5), descreve a metodologia adotada para a pesquisa, incluindo a aquisição de dados, o treinamento e a validação do modelo GNN, além de detalhar as ferramentas e técnicas utilizadas.

O Capítulo 6, *Desenvolvimento* (6), discute o desenvolvimento do trabalho, com ênfase nas tecnologias empregadas, nas decisões tomadas durante a implementação, e nos procedimentos de treinamento e teste do modelo.

Por fim, o Capítulo 7, *Considerações Finais* (7), apresenta as conclusões do estudo, incluindo os resultados alcançados, a discussão desses resultados, as limitações do trabalho e as sugestões para pesquisas futuras.

2 Aspectos Conceituais

Este capítulo aborda conceitos importantes envolvidos no desenvolvimento deste projeto de formatura.

2.1 Os Ativos Financeiros

O mercado de ações é um ambiente no qual investidores negociam ações, que são pequenas frações do capital de uma empresa. Essas negociações ocorrem em bolsas de valores, como a B3 no Brasil ou a NYSE nos Estados Unidos. A negociação de ações permite que as empresas captem recursos financeiros para financiar suas atividades e projetos, enquanto os investidores podem se tornar acionistas e, assim, participar dos lucros e crescimento da empresa.

O mercado de ações é um componente fundamental do sistema financeiro e desempenha um papel importante na economia global. Ele serve como um indicador da saúde econômica de um país e fornece uma plataforma para que os investidores diversifiquem seus investimentos e gerenciem riscos. Além disso, o mercado de ações possibilita a geração de empregos, o financiamento de projetos e o desenvolvimento tecnológico (FIRTH, 1977).

A dinâmica do mercado de ações é complexa e influenciada por diversos fatores, como políticas econômicas, eventos globais, desempenho empresarial e expectativas dos investidores. A previsão das tendências e movimentos do mercado de ações é uma tarefa desafiadora, que atrai tanto investidores quanto acadêmicos interessados em desenvolver modelos e técnicas para melhorar a qualidade das previsões e, assim, otimizar as decisões de investimento.

2.2 Variáveis de Interesse

A construção de um modelo analítico envolve a identificação, extração e processamento de variáveis relevantes para a tarefa do modelo. Conforme destacado por Htun, Biehl e Petkov (2023), é comum que modelos utilizem indicadores técnicos e fundamentais das empresas. Adicionalmente, este trabalho explora os indicadores econômicos do Brasil, inspirado no estudo de Juliana Marquez Da Cruz sobre o Temporal Fusion Transformer.

Neste trabalho, o índice u representa uma empresa, onde $u \in \{1, \dots, N\}$, e N é o número total de empresas consideradas. O índice t denota um instante específico, com $t \in \{1, \dots, T\}$, sendo T o ponto final da série temporal analisada.

2.2.1 Indicadores da Empresa

As variáveis fundamentais deste estudo estão relacionadas às características específicas das empresas analisadas. Essas variáveis são divididas em duas categorias: técnicas e fundamentais.

Os indicadores técnicos são derivados dos preços históricos das ações e do volume de negociações (MURPHY, 1999). Representamos por $T_u^t \in \mathbb{R}^M$ o vetor de indicadores técnicos, onde M é o número de variáveis técnicas consideradas. Exemplos incluem preço da ação (abertura e fechamento) e volume negociado.

Para simplificar, omitiremos o instante t nas notações subsequentes. Assim, T_u^t será referenciado como T_u . Esta convenção será aplicada ao longo de todo o estudo.

Os indicadores fundamentais estão intrinsecamente ligados às operações e à saúde financeira da empresa (ABARBANELL; BUSHEE, 1997). Denotamos por $F_u \in \mathbb{R}^K$ o vetor destes indicadores, onde K representa o número de variáveis fundamentais. A Tabela 1 apresenta uma seleção de cinco indicadores fundamentais essenciais.

Tabela 1 – Cinco Indicadores Fundamentais para Análise Financeira de Empresas

Indicador	Descrição	Uso
P/L	Preço sobre Lucro	Utilizado para avaliar se o preço das ações de uma empresa está alinhado com seu lucro, indicando se está caro ou barato
PL/Ativos	Patrimônio Líquido sobre Ativos	Empregado para identificar a robustez financeira de uma empresa em termos de longo prazo
M. EBIT	Margem EBIT	Aplicado para verificar a eficiência de uma companhia na geração de caixa a partir de suas operações
ROA	Retorno sobre Ativo	Usado para analisar a eficácia da gestão financeira da empresa e sua eficiência na utilização de ativos
CAGR Lucros 5 Anos	Taxa Composta de Crescimento Anual dos Lucros em 5 Anos	Serve para compreender a rentabilidade de um investimento ao longo do tempo, observando o crescimento dos lucros

2.2.2 Indicadores Econômicos

Informações sobre o ambiente econômico atual também são relevantes para previsão do preço das ações. Estes dados, que não são específicos de uma empresa, podem influenciar significativamente o desempenho das ações no mercado.

Representamos por $O \in \mathbb{R}^J$ o vetor dos J indicadores econômicos. A tabela 2 mostra cinco indicadores econômicos do Brasil.

Tabela 2 – Principais Indicadores Econômicos e Seu Impacto na Economia Brasileira

Indicador	Descrição
Risco-Brasil	Métrica que reflete a percepção dos investidores internacionais sobre o risco econômico e político de investir no Brasil. Essencial para entender a confiança do mercado
PIB	Representa o valor total dos bens e serviços produzidos no país, sendo um indicador-chave da saúde econômica do Brasil
Dólar	Taxa de câmbio entre o real e o dólar americano, influenciando diretamente o comércio exterior e a inflação no país
Selic Over	Taxa básica de juros da economia brasileira, estabelecida pelo Banco Central. Afeta diretamente empréstimos, financiamentos e investimentos
IPCA	Principal indicador de inflação do Brasil, fundamental para avaliar as tendências de preços no país

2.3 Modelos de Redes Neurais

Várias técnicas de Machine Learning têm sido exploradas para prever comportamentos no mercado financeiro. Por exemplo, há um estudo que utiliza o Perceptron de Múltiplas Camadas (MLP) e o algoritmo CART para previsões de curto prazo em ações (HUA; ZHU; DUAN, 2022). Outra pesquisa aplica LSTM, um tipo de Rede Neural Recorrente, para antecipar tendências do mercado de ações (MOGHAR; HAMICHE, 2020). Além disso, existe um estudo sobre o uso de Temporal Fusion Transforms, desenvolvido por Juliana Marquez Da Cruz, em previsões financeiras.

2.3.1 Perceptron Multicamadas

O Perceptron de Múltiplas Camadas (MLP, do inglês *Multi-Layer Perceptron*) consiste em várias camadas de neurônios, que são elementos de processamento realizando cálculos matemáticos nas entradas (MURTAGH, 1991). Como mostrado na figura 1, um MLP típico tem uma camada de entrada, algumas camadas ocultas, e uma camada de saída.

- **Camada de Entrada:** Recebe os dados de entrada $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ e os multiplica por uma matriz de pesos $\mathbf{W}^{(1)}$, conectando à primeira camada oculta.
- **Camadas Ocultas:** Transformam os dados recebidos. A primeira camada oculta aplica a fórmula:

$$\mathbf{h}^{(1)} = f(\mathbf{W}^{(1)}\mathbf{x} + \mathbf{b}^{(1)})$$

onde $\mathbf{b}^{(1)}$ é o vetor de viés e f é a função de ativação. Cada camada subsequente segue um processo similar.

- **Camada de Saída:** Processa a saída da última camada oculta para gerar a saída final y , com a operação:

$$y = \mathbf{W}^{(saida)}\mathbf{h}^{(ultima)} + b^{(saida)}$$

onde $\mathbf{W}^{(saida)}$ e $b^{(saida)}$ são os pesos e o viés da camada de saída.

Os vetores de viés (\mathbf{b}) em cada camada são essenciais para a aprendizagem, permitindo ajustes nas funções de ativação para melhor relacionar entradas e saídas.




Figura 1 – Arquitetura de um MLP

2.3.2 Redes Neurais Recorrentes

As Redes Neurais Recorrentes (RNNs) são especializadas no processamento de seqüências de dados, como séries temporais ou linguagem natural. Em contraste com as MLPs, as RNNs contêm conexões que formam ciclos, permitindo que informações de estados prévios sejam utilizadas nos estados subsequentes. Essa característica é crucial para tarefas onde a dependência temporal é significativa.

Dentre as variações das RNNs, a Unidade Recorrente de Porta (GRU, do inglês *Gated Recurrent Unit*) é notável. As GRUs controlam o fluxo de informação usando mecanismos de portas, que podem ser vistas como válvulas que regulam a passagem da informação. Uma GRU tem duas portas principais: a porta de reset (reset gate) e a porta de atualização (update gate). As operações dentro de uma GRU podem ser descritas pelas seguintes equações:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (2.1)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (2.2)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t] + b) \quad (2.3)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (2.4)$$

onde x_t é a entrada no instante t , h_t é o estado oculto no instante t , r_t é a porta de reset, z_t é a porta de atualização, e W_r , W_z , W , b_r , b_z , e b são parâmetros treináveis da rede.




Figura 2 – Diagrama de uma Unidade Recorrente com Portas (GRU), demonstrando a estrutura interna e o fluxo de informações.

2.3.3 Redes Neurais de Grafos

Redes Neurais de Grafos (GNN, do inglês *Graph Neural Network*) são uma nova forma de ML projetada para dados estruturados em grafos. As GNNs aproveitam essa estrutura para identificar padrões e fazer previsões, tornando-as ideais para aplicações que exigem processamento de dados complexos interconectados.

Primeiramente, nesse contexto de GNN, é importante definir alguns conceitos básicos da teoria dos grafos, como os conceitos de nós e arestas.

2.3.3.1 Teoria dos grafos

Um grafo é uma estrutura matemática fundamental usada para representar relacionamentos entre objetos. Ele é composto por dois componentes principais: nós e arestas.

Os nós representam os objetos ou entidades no grafo, e as arestas representam as conexões ou relacionamentos entre os nós. (BIGGS; LLOYD; WILSON, 1986)

Matematicamente, um grafo pode ser definido como $G = (V, E)$, onde V é o conjunto de nós e E é o conjunto de arestas. Cada aresta e pode ser representada como um par de nós (u, v) , indicando uma conexão entre o nó u e o nó v .

Por exemplo, considere esse grafo simple 3 que representa uma rede social. Os nós poderiam representar indivíduos, e as arestas poderiam representar amizades. Podemos expressar esse grafo como $G = (V, E)$, onde $V = \{1, 2, 3, 4\}$ representa o conjunto de indivíduos e $E = \{(1, 4), (2, 3), (2, 4), (3, 4)\}$ representa as amizades entre eles.




Figura 3 – Exemplo de um grafo com 4 nós e 5 arestas.

Os grafos fornecem uma estrutura versátil para modelar diversos cenários do mundo real e têm aplicações em diversos campos, como ciência da computação, redes sociais, redes de transporte e muito mais. No nosso caso, o desafio reside em capturar de forma eficaz as relações entre empresas. À medida que as empresas operam em mercados dinâmicos e interconectados, compreender as dependências e interações entre elas é crucial para análises e previsões precisas.

2.3.3.2 Passagem de Mensagens em GNNs

Dada a estrutura completa do grafo (representação e características associadas), é importante definir qual é o modelo subjacente, ou seja, como a informação fluirá dentro do grafo para criar as representações de cada nó. Esse fluxo é chamado de passagem de mensagem.

A passagem de mensagens é um conceito fundamental em GNNs que permite a troca de informações entre os nós de um grafo. Primeiramente introduzido por Gilmer et al. (2017), ele permite que os nós agreguem e atualizem informações com base em seus relacionamentos com os vizinhos.

Na passagem de mensagens, cada nó no grafo envia uma mensagem para seus nós vizinhos, que contêm informações sobre suas próprias características. Essas mensagens são, então, agregadas nos nós receptores, geralmente usando uma soma ponderada ou uma operação de pooling.

As mensagens agregadas são combinadas com as características originais do nó para calcular uma representação atualizada para cada nó. Esse processo ocorre em etapas de passagem de mensagens, permitindo que os nós aprimorem gradualmente suas representações com base nas informações de seus vizinhos locais.

Matematicamente, o processo de passagem de mensagens pode ser representado da seguinte forma:

1. **Mensagem:** A intuição é que cada nó u criará uma mensagem \mathbf{m}_u que será enviada para outros nós posteriormente,

$$\mathbf{m}_u^{(l)} = \text{MSG}^{(l)}(\mathbf{h}_u^{(l-1)}); \quad (2.5)$$

2. **Agregação:** A intuição é que cada nó u irá agregar as mensagens dos vizinhos do nó v ,

$$\mathbf{h}_v^{(l)} = \text{AGG}^{(l)}(\{\mathbf{m}_u^{(l)}, u \in \mathcal{N}, (v)\}) \quad (2.6)$$

onde $\mathbf{h}_v^{(l)}$ representa a representação do nó v na iteração l , $\mathbf{m}_u^{(l)}$ denota a mensagem do nó u , e $\mathcal{N}(v)$ representa o conjunto de nós vizinhos do nó v .

Esse processo iterativo de passagem de mensagens permite que os nós colem e troquem informações de seu ambiente local, permitindo que as GNNs capturem relacionamentos e dependências complexas dentro de um grafo.

2.3.3.3 GAT (Redes de Atenção em Grafos)

As GATs (do inglês *Graph Attention Networks*), introduzidas por [Veličković et al. \(2018\)](#), são uma extensão das Redes Neurais de Grafos (GNNs) que incorporam mecanismos de atenção. Esses mecanismos permitem que as GATs atribuam diferentes pesos de importância aos nós vizinhos durante a agregação de informações. Isso é particularmente útil para focar em nós mais relevantes e para integrar seletivamente informações de diferentes partes do grafo.

A entrada de uma camada GAT é um conjunto de características dos nós, $\mathbf{h} = \{\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_N\}$, onde $\mathbf{h}_i \in \mathbb{R}^U$, N é o número de nós e U é o número de características em cada nó. A camada produz um novo conjunto de características dos nós, $\mathbf{h}' = \{\mathbf{h}'_1, \mathbf{h}'_2, \dots, \mathbf{h}'_N\}$, com $\mathbf{h}'_i \in \mathbb{R}^{U'}$, sendo U' a nova cardinalidade de características. Por exemplo, a figura 4 ilustra uma rede com quatro nós ($N = 4$), na qual cada nó é inicialmente representado por um vetor de três características ($U = 3$). Após a transformação pela camada de atenção do GAT, cada nó passa a ser representado por um novo vetor com cinco características ($U' = 5$).

Como passo inicial e para obter a capacidade expressiva necessária para transformar as características de entrada em características de nível superior, aplica-se uma

transformação linear aprendível, compartilhada por todos os nós e parametrizada por uma matriz de pesos $\mathbf{W} \in \mathbb{R}^{U' \times U}$.

O mecanismo de autoatenção nos nós é uma função de atenção compartilhada $a : \mathbb{R}^{U'} \times \mathbb{R}^{U'} \rightarrow \mathbb{R}$, que calcula os coeficientes de atenção:

$$e_{ij} = a(\mathbf{W}\mathbf{h}_i, \mathbf{W}\mathbf{h}_j) \quad (2.7)$$

Esses coeficientes indicam a importância das características do nó j para o nó i . Para manter a informação estrutural do grafo, a atenção é mascarada, calculando-se e_{ij} apenas para os nós j na vizinhança de i , \mathcal{N}_i , que inclui i e seus vizinhos de primeira ordem.

Os coeficientes são normalizados usando a função *softmax* para torná-los comparáveis entre diferentes nós:

$$\alpha_{ij} = \text{softmax}_j(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in \mathcal{N}_i} \exp(e_{ik})} \quad (2.8)$$

a é geralmente uma rede neural feedforward de uma camada, parametrizada por um vetor de peso $\mathbf{a} \in \mathbb{R}^{2U'}$, e aplica a não-linearidade LeakyReLU (com inclinação negativa $\alpha = 0.2$). Assim, os coeficientes de atenção podem ser expressos como:

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(\mathbf{a}^\top [\mathbf{W}\mathbf{h}_i \parallel \mathbf{W}\mathbf{h}_j]))}{\sum_{k \in \mathcal{N}_i} \exp(\text{LeakyReLU}(\mathbf{a}^\top [\mathbf{W}\mathbf{h}_i \parallel \mathbf{W}\mathbf{h}_k]))} \quad (2.9)$$

Os coeficientes de atenção normalizados são usados para calcular uma combinação linear das características que lhes correspondem, que servirá como características de saída finais para cada nó, após potencialmente aplicar uma não-linearidade σ :

$$\mathbf{h}'_i = \sigma \left(\sum_{j \in \mathcal{N}_i} \alpha_{ij} \mathbf{W}\mathbf{h}_j \right) \quad (2.10)$$

Neste contexto, o σ pode ser qualquer função de ativação não-linear adequada, como a sigmóide ou ReLU. O processo descrito é ilustrado na Figura 4, mostrando a atenção que o nó 1 presta a si mesmo e aos seus vizinhos.

Ao incorporar mecanismos de atenção, as GATs conseguem capturar de forma eficaz a importância dos diferentes nós no contexto dos vizinhos, permitindo uma agregação de informações mais refinada e adaptativa em tarefas de aprendizado em grafos.

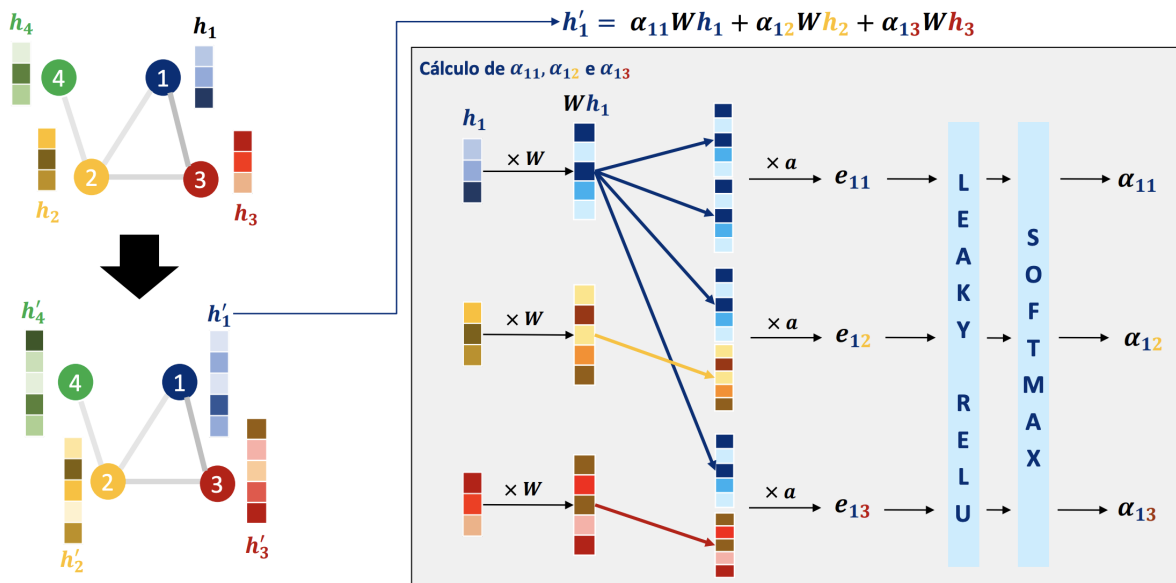


Figura 4 – Representação esquemática do mecanismo de atenção em uma Graph Attention Network (GAT). Ilustra-se o processo de atualização das características dos nós, onde cada nó inicialmente possui 3 características ($U = 3$). Por meio da transformação linear ponderada pela matriz de pesos W e do cálculo dos coeficientes de atenção α_{ij} , resultam-se novas características com uma dimensionalidade aumentada para 5 ($U' = 5$). A função softmax e a aplicação subsequente das não-linearidades LeakyReLU permitem calcular a importância relativa das características de cada nó vizinho.

3 Especificação de Requisitos

3.1 Requisitos Funcionais

Os requisitos funcionais estabelecem as funcionalidades essenciais que o sistema deve desempenhar. São eles: previsão de preços de ações, cálculo do erro entre os preços previstos e observados, e registro dos resultados alcançados.

- **Previsão de preços de ações:** Por meio de técnicas avançadas de análise de dados e modelos preditivos, o sistema busca estimar os valores futuros dos preços das ações, fornecendo *insights* valiosos para investidores e tomadores de decisão no mercado financeiro.
- **Cálculo do erro entre previsto e observado:** O sistema deve ser capaz de comparar as previsões realizadas com os preços observados em cada instante de tempo. Essa comparação é fundamental para avaliar a qualidade das previsões geradas e identificar possíveis desvios ou discrepâncias entre os valores previstos e os valores reais. Métricas de erro, como o RMSE ou o MAPE, são utilizadas para quantificar a diferença entre as previsões e as observações.
- **Registro dos resultados:** É importante que o sistema seja capaz de registrar de forma precisa e organizada os resultados obtidos durante o processo de previsão de preços. Isso inclui o armazenamento dos hiperparâmetros dos modelos utilizados, as especificações dos dados utilizados no treinamento e teste, bem como as estatísticas de erro geradas. Esse registro dos resultados permite uma análise posterior mais detalhada, facilitando a comparação entre diferentes abordagens e a identificação de melhores práticas.

Esses requisitos funcionais são fundamentais para garantir a eficiência e confiabilidade do sistema de previsão de preços de ações, fornecendo informações valiosas para auxiliar nas tomadas de decisão no mercado financeiro.

3.2 Requisitos Não Funcionais

Os requisitos não funcionais estabelecem como o trabalho irá cumprir os requisitos funcionais. Eles englobam a manutenção de métricas de erro reduzidas e uma boa documentação/reprodutibilidade:

- **Manutenção de métricas de erro reduzidas:** É crucial que as métricas de erro de treinamento e teste sejam mantidas em níveis baixos, assegurando que as previsões dos ativos sejam altamente precisas e confiáveis. Isso requer a implementação de técnicas avançadas de modelagem e análise de dados, além de uma constante avaliação e ajuste do desempenho do sistema de previsão.
- **Boa documentação e reprodutibilidade:** É essencial que o trabalho possa ser reproduzido por qualquer pessoa interessada em fazê-lo. Para isso, é necessário que os códigos-fonte de treinamento do modelo sejam disponibilizados publicamente, juntamente com uma documentação clara e abrangente. Essa documentação deve fornecer informações detalhadas sobre os procedimentos adotados, os métodos utilizados e os dados empregados, possibilitando a replicação dos experimentos e facilitando a utilização do trabalho como referência para pesquisas futuras.
- **Usabilidade com Interface Simplificada:** A interface do sistema deve ser simplificada, permitindo ao usuário executar as seguintes tarefas sem dificuldades:
 1. Selecionar de forma prática quais dados deseja extrair para análise.
 2. Configurar e executar o modelo com hiperparâmetros customizados pelo usuário, ajustando as variáveis de acordo com as necessidades da predição.
 3. Escolher o modelo final para realizar a predição dos valores dos ativos com flexibilidade e autonomia.

A interface deve ser projetada para que o usuário tenha uma curva de aprendizado rápida e possa operar o sistema de forma eficiente, mesmo sem conhecimento prévio em modelos de machine learning.

Os requisitos não funcionais são fundamentais para garantir a eficácia, confiabilidade e reprodutibilidade do sistema de previsão de preços de ações. Ao atender a esses requisitos, o trabalho estará apto a fornecer resultados consistentes e valiosos, contribuindo para a tomada de decisões informadas no mercado financeiro.

4 Proposta: FinGAT

4.1 Introdução

Este trabalho propõe o modelo FinGAT (do inglês *Financial Graph Attention Network*), uma abordagem inovadora para a predição de preços de ativos financeiros utilizando Redes de Atenção em Grafos.

O modelo **FinGAT** é inspirado e estruturado com base nos trabalhos de [Kim et al. \(2019\)](#) e [Huang et al. \(2022\)](#), integrando conceitos avançados de aprendizado de máquina e análise de redes complexas. A arquitetura clássica de modelos para predição no mercado de ações geralmente inclui uma fase de codificação dos dados de entrada, utilizando técnicas como RNN, CNN ou Transformers, seguida por uma transformação linear para a obtenção da saída. O diferencial do FinGAT reside na inclusão de um bloco GAT entre essas duas fases. Essa adição permite não apenas a codificação das características das empresas, mas também a modelagem das relações entre elas. Assim, o modelo visa capturar a dinâmica intercorporativa, proporcionando uma análise mais aprofundada e potencialmente levando a previsões mais precisas. A Figura 5 ilustra a visão geral do modelo desenvolvido, destacando cada um desses módulos.

O primeiro módulo foca na codificação das variáveis: as variáveis de entrada, incluindo preços históricos e indicadores fundamentais das empresas, são codificadas. Além disso, é aplicada uma codificação posicional para lidar com séries temporais que podem possuir dados ausentes.

No segundo módulo de modelagem das relações, a arquitetura GAT é empregada para aprender os pesos e interações entre as empresas.

Por fim, no último módulo de predição, as representações latentes de cada empresa são transformadas na saída desejada.

Módulo 1: Codificação da empresa

Neste projeto, utilizamos preços históricos e métricas fundamentais como indicadores das mudanças nos preços das ações. Um componente adicional, o *Positional Embedding*, foi incorporado para integrar o componente temporal aos dados. A codificação final da empresa está obtida com o *GRU*.

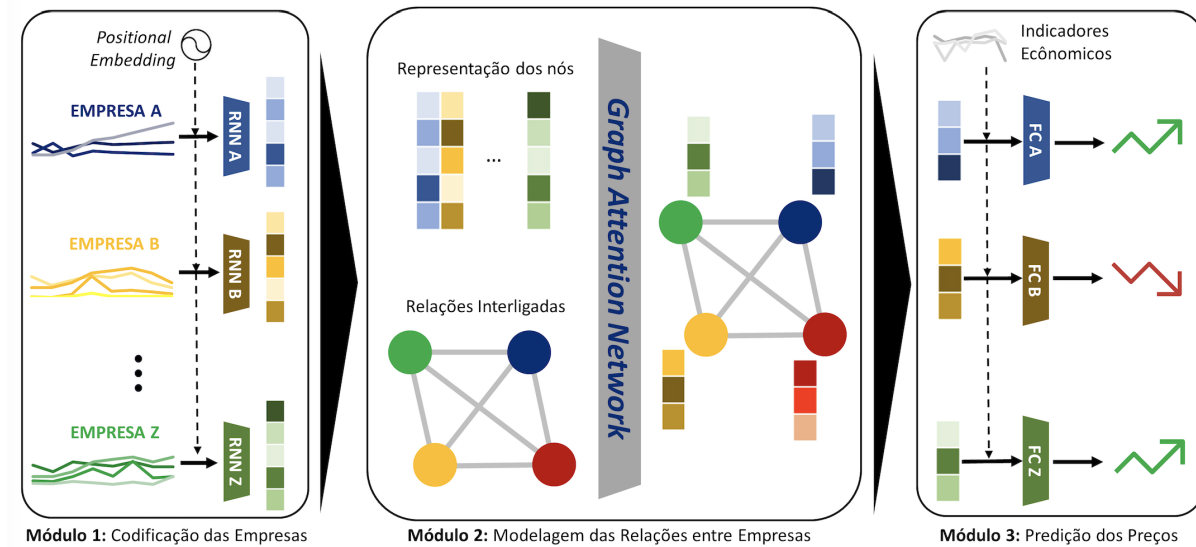


Figura 5 – Visão geral do modelo proposto

4.1.1 Variáveis de Entrada

A previsão dos preços dos ativos financeiros leva em consideração um conjunto de variáveis de entrada.

Inicialmente, o primeiro grupo de variáveis é constituído pelos próprios preços dos ativos. Conforme discutido por Fama (1991), a hipótese do mercado eficiente sugere que os preços das ações refletem todas as informações disponíveis. Assim, para cada empresa, a primeira variável considerada é naturalmente o preço de fechamento diário dos ativos financeiros.

Representamos o preço de fechamento da empresa u por $p_u \in \mathbb{R}^H$ onde H é a janela histórica de H dias.

Além dos preços, incluímos também indicadores fundamentais de cada empresa. Estes indicadores visam refletir a saúde da empresa, considerando aspectos como endividamento e eficiência. Algumas variáveis fundamentais já foram apresentadas anteriormente na tabela 1.

Denotamos $\mathbf{F}_{u,H} \in \mathbb{R}^{H \times M}$, a matriz dos indicadores fundamentais da empresa u .

4.1.2 Positional Encoding

Antes de codificar essas variáveis brutas, uma codificação posicional está adicionada. A razão principal é que cada série temporal tem dados ausente por causa de fim de semana, férias, o ativo em sim ou a API. Então incluir esse codificação posicional permite o modelo entender essas ausências (SHAW; USZKOREIT; VASWANI, 2018)

Introduzido em modelos de Processamento de Linguagem Natural para adicionar

informação posicional aos mecanismos de atenção totalmente conectados nos *Transformers*, esse mecanismo ajusta o modelo para janelas de dados ausentes. Primeiramente, cada marcação de tempo l é internamente representada em relação a t e, em seguida, a codificação posicional é aplicada para criar uma representação vetorial onde P é um hiperparametro.

$$t' = l - t, \quad (4.1)$$

$$\tau_{2k}^t = \sin\left(\frac{t'}{1000 \times 2k/P}\right) \in \mathbb{R}^{1 \times P} \quad (4.2)$$

$$\tau_{2k+1}^t = \cos\left(\frac{t'}{1000 \times 2k/P}\right) \in \mathbb{R}^{1 \times P} \quad (4.3)$$

Esta abordagem é conveniente, pois representa os eventos passados em relação a t . Denotamos t' a marcação de tempo relativa da medida t de uma série temporal.

No final, o vetor da codificação posicional está representada da forma seguinte:

$$\tau_{H,P} \in \mathbb{R}^{H \times P} \quad (4.4)$$

4.1.3 Codificação Final da Empresa

Para cada empresa, a cada tempo, temos o seguinte vector :

$$\mathbf{e}_u = [\mathbf{p}_u || \mathbf{F}_u || \tau] \in \mathbb{R}^{H \times (1+M+P)} \quad (4.5)$$

onde $[\cdot || \cdot]$ representa a operação de concatenação.

Posteriormente, esse vetor entra num GRU distinto para cada empresa (CHO et al., 2014). O objetivo é utilizar o GRU para processar sequencialmente as informações contidas nesse vetor, capturando as dependências temporais e criando uma representação contextualizada para a previsão do mercado de ações:

$$\mathbf{e}'_u = \text{GRU}_u(\mathbf{e}_u) \in \mathbb{R}^U \quad (4.6)$$

onde U representa o tamanho do embedding (número de unidades no GRU)

Esse vector \mathbf{e}'_u representa simplesmente uma visão compacta das variáveis da empresa u .

Cada empresa tem um GRU com parametros distintos. A saída desse módulo consiste um vetor de tamanho U para cada empresa, ou seja, uma matriz de tamanho $N \times U$.

Módulo 2: Modelagem das Relações entre Empresas

Este módulo tem como entrada as codificações individuais de cada empresa, tratando-as de forma distinta e não compartilhada inicialmente. O objetivo é promover a troca de informações entre os *embeddings* de cada empresa, de modo que cada uma tenha uma representação que seja tanto própria quanto compartilhada.

A estrutura em forma de grafo facilita a propagação dessas informações. O primeiro passo é definir a estrutura do grafo, ou seja, determinar como os nós e as relações serão estabelecidos.

Conforme a literatura sobre o uso de grafos no mercado financeiro, há um consenso quanto à definição dos nós: cada nó representa uma empresa (HUANG et al., 2022; KIM et al., 2019). Entretanto, as variações nas arquiteturas de grafos na literatura advêm principalmente da definição das conexões.

Abordagens como o uso de matrizes de correlação ou grafos baseados em relações corporativas são interessantes para modelar as relações entre empresas. A matriz de correlação reflete as dinâmicas compartilhadas entre as empresas com base na evolução histórica de seus preços, enquanto um grafo baseado em relações corporativas pode indicar conexões mais profundas, como pertencer ao mesmo setor ou ter acordos comerciais conjuntos.

No entanto, optamos por não seguir essas abordagens devido a algumas limitações. A primeira é a complexidade na construção e manutenção desses grafos, especialmente em um mercado de ações sempre em mudança. Além disso, ao empregar uma arquitetura de GAT, a rede aprende autonomamente os pesos e as interações entre as empresas.

Assim, a GAT é configurada para interconectar todas as empresas e determinar, de forma independente, os pesos dessas conexões com base nos dados de treinamento. Essa metodologia, embora menos intuitiva, tem o potencial de identificar dinâmicas e relações latentes que podem não ser óbvias nas abordagens tradicionais e é menos suscetível a erros ou omissões em dados externos.

A formulação matemática do módulo de GAT pode ser expressa como:

$$\{\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_N\} = \text{GAT}(\{\mathbf{e}'_1, \mathbf{e}'_2, \dots, \mathbf{e}'_N\}) \quad (4.7)$$

onde $\mathbf{e}'_i \in \mathbb{R}^U$ representa o embedding da empresa i e $\mathbf{h}_i \in \mathbb{R}^{U'}$ é a sua representação no grafo após a aplicação do GAT.

Módulo 3: Predição

O módulo final do nosso modelo tem o propósito de realizar efetivamente a previsão dos preços futuros dos ativos financeiros. Este módulo processa as saídas do módulo

anterior, que são as representações latentes das empresas - denotadas pelo conjunto $\{\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_N\}$, e também incorpora variáveis econômicas relevantes para o contexto brasileiro.

4.1.4 Variáveis Econômicas

Para enriquecer a análise, além dos preços e dos indicadores fundamentais das empresas, incluímos indicadores socioeconômicos do Brasil como variáveis de entrada. Esta abordagem é inovadora no uso de GAT no contexto do mercado financeiro, permitindo avaliar a relevância dessas variáveis no modelo proposto.

Alguns indicadores econômicos já foram apresentados na tabela 2. A escolha destes indicadores baseou-se na disponibilidade dos dados e na diversidade das informações que eles proporcionam.

4.1.5 Regressão

O objetivo é combinar essas representações latentes com os indicadores econômicos e transformá-las na saída desejada, um processo realizado através de um MLP. Esse modelo recebe como entrada a concatenação dos indicadores econômicos $O \in \mathbb{R}^J$ e a representação latente da empresa \mathbf{h}_u , gerando a previsão de preço $\hat{\mathbf{p}}_u$.

A definição do MLP é a seguinte:

$$\hat{\mathbf{p}}_u = \text{MLP}([O || \mathbf{h}_u]) \quad (4.8)$$

O MLP executa uma série de transformações não lineares na entrada concatenada, facilitando a identificação de padrões e relações complexas essenciais para a previsão da variável alvo.

5 Metodologia

Com o objetivo de avaliar a relevância do uso desse tipo de modelo, é necessário adquirir os dados para o treinamento e a validação.

5.1 Aquisição de dados

A coleta de dados envolve a obtenção de indicadores técnicos, fundamentais e econômicos, que são essenciais para a construção do modelo.

- Os **indicadores técnicos** são adquiridos utilizando o pacote `yfinance` do Python, que acessa a API do Yahoo Finance. Esse pacote permite especificar o símbolo do ativo desejado e extrair informações pertinentes para análise temporal. Para este projeto, focamos na extração do preço de fechamento diário do ativo. Maiores detalhes podem ser encontrados no link do projeto: [Yahoo! Finance's API](#).
- Inicialmente, buscou-se extrair **indicadores fundamentais** das empresas através de uma API gratuita, mas rapidamente constatou-se que tal recurso não estava disponível. Diante dessa limitação, optou-se por inserir manualmente os dados num Excel para somente um conjunto de empresas (o setor bancário). Obtivemos os dados a partir do portal [Status Invest](#)
- A plataforma IPEA Data é reconhecida como uma fonte confiável de **indicadores econômicos** do Brasil. Para otimizar e automatizar o processo de extração desses dados, utilizou-se o pacote `DadosAbertosBrasil`, uma API que facilita o acesso a tais informações.

5.2 Treinamento e teste do modelo

Para a divisão do conjunto de dados em treinamento e teste, adotamos uma metodologia específica, visando maximizar a eficácia e a realidade das previsões do nosso modelo.

5.2.1 Definição dos Conjuntos de Treinamento e Teste

Inicialmente, definimos o conjunto de teste como sendo os últimos `test_days` dias do grupo das séries temporais dos ativos. Esta seleção estratégica garante que o modelo seja avaliado em um cenário realista, onde o desafio é prever valores futuros que não foram

expostos durante a fase de treinamento. O restante dos dados, anterior a este período, constitui o conjunto de treinamento.

5.2.2 Mecanismo de Janela Deslizante

Durante as fases de treinamento e teste, implementamos um mecanismo de janela deslizante que percorre as séries temporais. Esta janela, em cada iteração, captura os últimos `history` dias de dados para servir como entrada do modelo. Com base nessa entrada, o objetivo é prever os preços para os próximos `horizon_forecast` dias. Essencialmente, a janela é movida progressivamente ao longo da série, tanto no treinamento quanto no teste, assegurando que cada previsão seja baseada nas informações mais atualizadas e evitando qualquer sobreposição entre os conjuntos de treinamento e teste.

5.2.3 Métrica de Erro e Avaliação

Na avaliação do desempenho do nosso modelo preditivo, optamos por utilizar o Índice de Concordância (IoA, do inglês *Index of Agreement*) como nossa função de perda, e o MAPE (*Mean Absolute Percentage Error*) como métrica de desempenho. A escolha do IoA como função de perda é motivada pela sua capacidade de capturar a concordância entre os valores observados e os previstos, considerando tanto a magnitude dos erros quanto a direção (sobrestimação ou subestimação) (WILLMOTT, 1981)

O IoA é formulado como:

$$\text{IoA} = 1 - \frac{\sum_{t=1}^n (p_t - \hat{p}_t)^2}{\sum_{t=1}^n ((|p_t - \bar{p}|) + (|\hat{p}_t - \bar{p}|))^2}, \quad (5.1)$$

onde p_t são os preços reais dos ativos, \hat{p}_t são os preços previstos pelo modelo e \bar{p} é a média dos preços observados. O IoA varia de 0 a 1, onde 1 indica concordância perfeita e 0 indica discordância total.

Por outro lado, o MAPE é empregado como métrica devido à sua interpretação intuitiva e facilidade de comunicação dos resultados. É definido como:

$$\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{p_t - \hat{p}_t}{p_t} \right|, \quad (5.2)$$

com p_t e \hat{p}_t mantendo os mesmos significados anteriores. O MAPE é uma média dos erros percentuais, proporcionando uma medida relativa da precisão das previsões.

A combinação do IoA como função de perda e do MAPE como métrica permite uma avaliação robusta do modelo: enquanto o IoA penaliza desvios tanto em magnitude quanto em direção, fornecendo uma otimização mais abrangente durante o treinamento, o MAPE oferece uma perspectiva percentual que é facilmente compreendida e comparada,

independentemente da escala dos preços dos ativos. Assim, essa abordagem dual garante que o modelo seja otimizado para alcançar concordância nos padrões de preços, ao mesmo tempo em que permite uma avaliação acessível do seu desempenho geral.

5.2.4 Exemplo Prático e Ilustração

Por exemplo, conforme ilustrado na figura 6 com cinco ativos financeiros, o período de treinamento (verde) abrange de Jan-2021 a Dez-2020, e o período de teste (laranja) vai de Jan-2020 a Nov-2023. Em cada instante t , o modelo utiliza os dados históricos (representado em cinza) dentro da janela para realizar previsões para o período futuro (indicado em azul escuro). Nesse exemplo específico, `history = 4` anos, `horizon_forecast = 1` ano e `test_days = 4` anos (1460 dias). Importante destacar que, para instantes dentro no período de treinamento, como por exemplo t_1 , os parâmetros do modelo estão continuamente sendo atualizados, enquanto para instantes dentro do período de teste como t_2 o modelo opera sem atualizações de parâmetros.

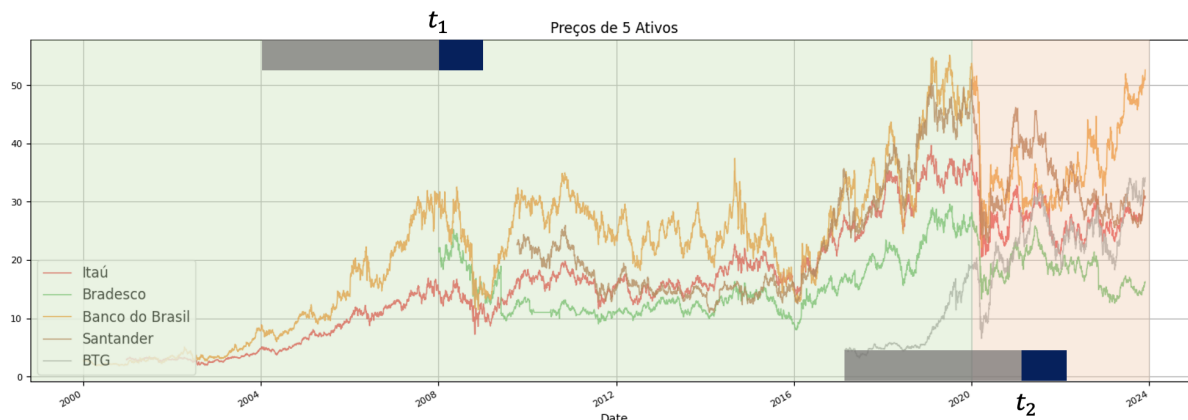


Figura 6 – Ilustração do método de janelas deslizantes aplicado ao modelo.

5.2.5 Definição dos Hiperparâmetros

Diferentes modelos com distintas arquiteturas serão avaliados ao longo deste trabalho. Idealmente, cada modelo exigiria uma configuração única de hiperparâmetros para otimizar seu desempenho. No entanto, a fim de simplificar a explicação e a gestão da complexidade envolvida, optou-se por utilizar um conjunto comum de hiperparâmetros para todos os modelos. As figuras 3 e 4 resumem, respectivamente, os hiperparâmetros relacionados aos dados e aos modelos.

5.2.6 Definição dos Dados

Na prática, os períodos de treinamento e teste dependem da data de início do ativo mais antigo no grupo.

Tabela 3 – Hiperparâmetros dos Dados

Hiperparâmetro	Descrição	Valor
history	Quantidade de pontos anteriores considerados para a entrada no modelo.	90
horizon_forecast	Quantidade de pontos futuros que o modelo deve prever.	14
test_days	Tamanho do período destinado aos testes do modelo.	360
P	Dimensão da codificação posicional utilizada.	30

Tabela 4 – Hiperparâmetros dos Modelos

Hiperparâmetro	Descrição	Valor
U	Dimensão do <i>embedding</i> utilizado na GRU.	50
U'	Dimensão da saída do modelo GAT.	50
lr	Taxa de aprendizado inicial dos modelos.	5e-2
scheduler	Estratégia de ajuste da taxa de aprendizado.	OnPlateau
patience_lr	Número de épocas sem melhora no desempenho antes de ajustar a taxa de aprendizado.	10
factor	Fator de redução da taxa de aprendizado.	0.9
epochs	Número total de épocas de treinamento.	1000
heads	Número de heads do GAT	4
Optimizer	Estratégia de atualizações dos parametros.	Adam

À partir dessas datas e dos hiperparâmetros dos dados, os períodos podem ser definidos. Principalmente 2 conjuntos de foi extraídos: o grupo **bancario** que tem o 5 ativos mais poderosos do mesmo setor: o setor bancario. O segundo grupo é o grupo **diverso** que tem o 5 ativos mais importante da B3 de setores diferentes. Detalhes podem ser obtidas na tabela 5 onde está detalhado os ativos de cada grupo, além da data de inicio.

Dando essas datas de inicio e dos hiperparâmetros dos dados da tabela 3, podemos definir os períodos conforme na tabela 6

5.3 Experimentos

Para explorar o uso do GAT (Graph Attention Networks) na previsão do mercado de ações, iremos variar e combinar diferentes blocos no nosso modelo:

- **Arquitetura:** GRU ou FinGAT.

Tabela 5 – Visão Geral das Empresas Seleccionadas de Diferentes Setores com Seus Respective Tickers e Datas de Início no [Yahoo Finance API](#)

Grupo	Ticker	Empresa	Data Início
Bancos	BBAS3.SA	Banco do Brasil	3/Jan/2000
	BPAC11.SA	Banco BTG	24/Fev/2017
	ITUB4.SA	Itaú	21/Dez/2000
	BBDC4.SA	Bradesco	2/Jan/2008
	SANB11.SA	Santander	7/Out/2009
Diverso	PETR4.SA	Petrobras	3/Jan/2000
	ABEV4.SA	Ambev	5/Jan/2000
	VALE3.SA	Vale	3/Jan/2000
	B3SA3.SA	B3	26/Out/2007
	JBSS3.SA	JBS	29/Mar/2007

Grupo	Períodos Treinamento	Período Teste
Bancos	3/Dez/2002 até 30/Nov/2022	1/Dez/2022 até 30/Aug/2023
Diverso	- 4837 dias	- 360 dias

Tabela 6 – Essa tabela está feito com um snapshot do 30/Nov/2023. A data do início do período de treinamento corresponde a data mais antiga de cada grupo mais o `history`. A data do fim corresponde à última data disponível (supposamos 30/Nov/2023) menos o `test_days` (1 ano). O período de teste é simplesmente o resto até o 30/Nov/2023.

- **Ativos:** Grupo Bancário ou Diverso.
- **Variáveis:** Usar apenas preços, adicionar indicadores fundamentais de cada empresa e, posteriormente, características macroeconômicas.

A tabela 7 ilustra os 7 modelos desenvolvidos.

Experimento 1: Influência da Estrutura em Grafo na Precisão de Previsão

O foco inicial deste estudo é avaliar como a estruturação dos dados em forma de grafo impacta a precisão das previsões, comparando-a com um modelo *baseline*.

		Modelo	M1	M2	M3	M4	M5	M6	M7
Arquitetura	GRU		x		x				
	FinGAT			x		x	x	x	x
Variáveis Adicionais	Fundamentais						x		
	Econômicos							x	
	Ambos								x
Sector	Igual				x	x	x	x	x
	Diverso		x	x					

Figura 7 – Os 7 modelos para conduzir os 3 experimentos. Ao comparar M1 com M2 e M3 com M4, tanto o experimento 1 quanto o 2 estão sendo investigados. Os modelos de M4 até M7 permitem focar no experimento 3.

A análise se concentrará no grupo de ativos classificados como 'diverso' (conforme detalhado na tabela 5), utilizando exclusivamente os preços desses ativos como variáveis de interesse.

O modelo *baseline* será o FinGAT, excluindo-se o módulo 2, isto é, o GAT. Assim, o *baseline* consiste em uma rede GRU distinta para cada ativo financeiro, sem compartilhamento de informações entre eles.

Para a investigação proposta, serão desenvolvidos dois modelos: um incluindo a estrutura GAT entre os módulos 1 e 3, e outro sem esta estrutura. A ideia é isolar o efeito da infraestrutura GAT na capacidade de previsão. A comparação entre os modelos será realizada através do MAPE.

Pretende-se identificar se o compartilhamento de informações via GAT contribui para uma melhoria significativa nas previsões, comparativamente ao modelo *baseline* com GRU. Esta análise será crucial para entender a relevância da estrutura em grafo no contexto da precificação de ativos financeiros.

Experimento 2: Avaliação da Influência Setorial Utilizando Grafos de Atenção

O objetivo deste experimento é determinar se a aplicação do GAT na análise de ações é mais efetiva quando os ativos pertencem ao mesmo setor ou quando são de setores diferentes. Busca-se compreender se as informações de preços de ações de um mesmo setor contribuem mais significativamente para a acurácia das previsões do que informações de setores diferentes. Para tal investigação, serão conduzidos testes com quatro configurações de modelos:

1. Modelo sem GAT para ações de um único setor.
2. Modelo com GAT para ações de um único setor.

3. Modelo sem GAT para ações de setores diversos.
4. Modelo com GAT para ações de setores diversos.

Para a realização do experimento, foram constituídos dois conjuntos de ativos:

- **Conjunto Bancário:** Contendo 5 ativos do setor financeiro.
- **Conjunto Diverso:** Composto por 5 ativos de setores variados.

A análise comparativa entre os modelos visa elucidar a seguinte questão: No uso do GAT, são os preços de ações do mesmo setor mais indicativos para a previsão de um ativo do que os preços de ações de setores diferentes? Espera-se que os resultados revelem a importância das conexões setoriais e ofereçam direcionamento sobre como a similaridade setorial pode ser utilizada para aprimorar a precisão das previsões de preços de ações.

Experimento 3: Incremento de variáveis de entrada no modelo

Neste experimento, o foco é analisar como a adição incremental de variáveis de entrada pode influenciar o desempenho do modelo. Para isso, utilizamos um modelo baseado em grafo focado no setor bancário e adicionamos as variáveis de forma incremental.

O objetivo é observar como a introdução de indicadores fundamentais e, subsequentemente, características macroeconômicas, podem afetar a precisão das previsões.

6 Desenvolvimento do Trabalho

6.1 Tecnologias Utilizadas

No desenvolvimento deste trabalho, diversas tecnologias e ferramentas foram empregadas para garantir precisão, eficiência e replicabilidade. A seguir, apresentamos as tecnologias e ferramentas mais relevantes utilizadas ao longo da pesquisa.

6.1.1 Python e Visual Studio Code (VSCode)

O Python, uma linguagem de programação de alto nível conhecida por sua versatilidade e comunidade ativa, foi a escolha primordial para a codificação e modelagem deste projeto. A decisão de utilizar o Python se deu principalmente devido à vasta biblioteca de pacotes disponíveis para análise de dados e machine learning, bem como sua integração amigável com outras ferramentas e plataformas.

O ambiente de desenvolvimento selecionado foi o Visual Studio Code (VSCode), um editor de código-fonte leve, porém poderoso, que oferece suporte nativo para Python e uma variedade de extensões úteis que facilitam o desenvolvimento. O VSCode oferece funcionalidades como realce de sintaxe, depuração e integração direta com sistemas de controle de versão, como o Git.

6.1.2 GitHub

Para o controle de versão e colaboração, foi utilizado o GitHub, uma plataforma de hospedagem de código-fonte com controle de versão usando o Git. O GitHub não apenas facilitou o rastreamento das mudanças no código ao longo do tempo, mas também permitiu uma colaboração eficiente entre os membros da equipe e ofereceu uma maneira de compartilhar o progresso do projeto com a comunidade.

6.1.3 Notebooks

No estágio inicial da pesquisa, notebooks foram essenciais para a exploração interativa dos dados e testes iniciais com modelos de redes neurais de grafos. Eles proporcionaram um ambiente dinâmico onde o código, visualizações e anotações poderiam coexistir, facilitando a compreensão e a iteração rápida durante as fases experimentais.

6.1.4 PyTorch

O PyTorch foi a biblioteca escolhida para a construção e treinamento das redes neurais de grafos. Ele é uma biblioteca de aprendizado de máquina de código aberto para a linguagem de programação Python, favorecida por sua flexibilidade e eficiência. Com um foco especial em aplicações de aprendizado profundo, o PyTorch oferece um conjunto robusto de ferramentas e funcionalidades que tornaram possível implementar, treinar e avaliar os modelos propostos neste trabalho.

6.1.5 Ferramenta de Linha de Comando

Após a exploração inicial e refinamento dos modelos usando notebooks, uma ferramenta de linha de comando foi desenvolvida. Esta ferramenta permite a execução dos modelos de maneira mais automatizada, sem a necessidade da interface visual dos notebooks, facilitando assim a integração com outros sistemas e a produção de resultados em escala.

6.1.6 Streamlit

Neste projeto, Streamlit, uma ferramenta open-source para aplicações web em ciência de dados, teve um papel crucial. Além de facilitar a ingestão e manipulação de dados, Streamlit permitiu a construção interativa e o ajuste de modelos de machine learning, bem como o registro e teste desses modelos. Sua interface intuitiva possibilitou a visualização eficiente de resultados, incluindo métricas de desempenho e gráficos comparativos, essenciais para a análise dos dados. Adicionalmente, Streamlit serviu como uma alternativa leve ao MLflow, gerenciando de forma eficaz o armazenamento e organização dos resultados dos modelos, o que foi fundamental para acompanhar a evolução do projeto.

6.2 Projeto e Implementação

6.2.1 Hyperparâmetros

Os seguintes resultados foram obtidos utilizando os hiperparâmetros mencionados anteriormente na tabela 4. Devido ao extenso tempo de execução e à instabilidade observada ao sintonizar os hiperparâmetros para cada modelo individualmente, optei por ajustar os hiperparâmetros em apenas um modelo. Após encontrar a combinação ideal, apliquei os mesmos hiperparâmetros a todos os outros modelos para garantir consistência e eficiência.

6.2.2 Pipeline de Automação do Processo

O projeto de formatura contempla uma automatização robusta do processo de extração, preparação e treinamento dos modelos acima dos dados financeiros e econômicos. A figura abaixo ilustra o fluxo estabelecido:

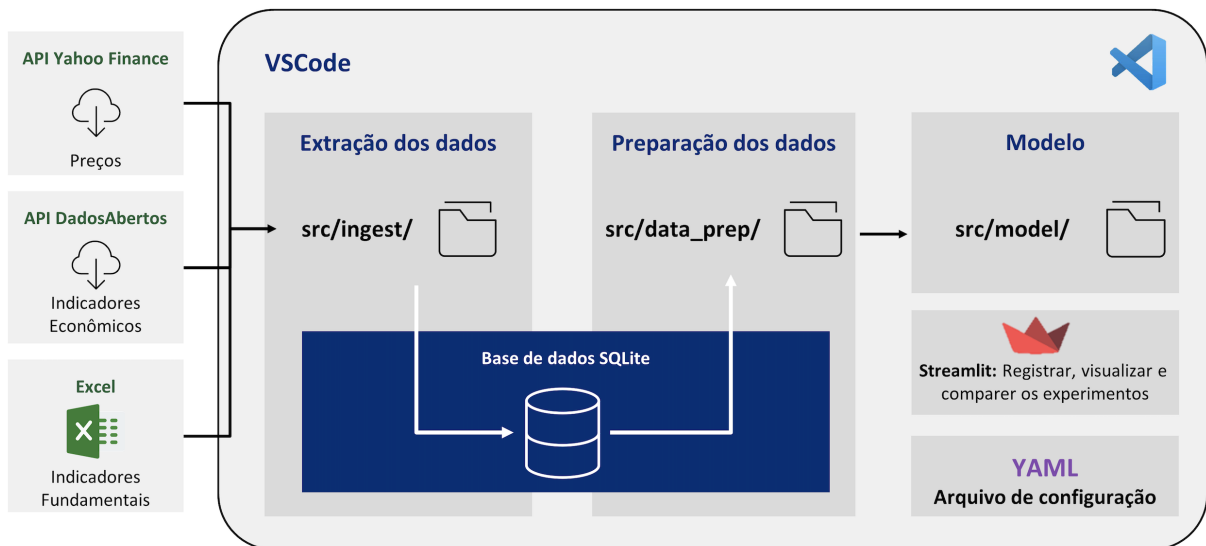


Figura 8 – Pipeline de Automação do Processo.

O pipeline segue uma estrutura lógica e linear:

1. **Extração dos Dados:** Os dados são extraídos das fontes mencionadas anteriormente e armazenados na pasta `src/ingest/`.
2. **Preparação dos Dados:** Uma vez coletados, os dados passam por um processo de limpeza e transformação, sendo então preparados na pasta `src/data_prep/`.
3. **Modelagem:** Com os dados preparados, são então alimentados para os modelos de análise ou previsão em `src/model/`.

A base de dados SQLite serve como repositório central para armazenar e recuperar os dados processados. Adicionalmente, a ferramenta `streamlit` é utilizada para registrar e comparar diferentes experimentos realizados, enquanto o arquivo de configuração em YAML garante uma gestão eficiente e parametrizável do projeto.

6.3 Resultados Experimentais

A seguir são apresentados os resultados dos três experimentos descritos na Seção 5.3.

6.3.1 Experimento 1: Influência da Estrutura em Grafo na Precisão de Previsão

Nesta seção, apresentamos os resultados obtidos com a aplicação do modelo FinGAT em comparação ao GRU, com o objetivo de verificar a influência da estrutura em grafo na precisão da previsão de preços de ativos financeiros. Conforme ilustrado na Figura 9, as análises focaram na precisão das previsões, medida pelo MAPE, para um conjunto selecionado de empresas.

Os resultados indicam que a representação em grafo provou ser uma abordagem valiosa. O modelo FinGAT alcançou, em geral, um MAPE inferior ao GRU, o que sugere uma maior acurácia nas previsões. Especificamente, no setor "Igual", o modelo FinGAT obteve um MAPE de 4,16%, enquanto o GRU apresentou um MAPE ligeiramente mais baixo de 4,11%. Esta diferença, apesar de pequena, é indicativa da eficiência do modelo FinGAT em capturar as dinâmicas complexas do mercado que podem ser negligenciadas por modelos que não consideram a estrutura em grafo.

Para algumas empresas analisadas como Vale ou Santander, a superioridade do modelo FinGAT foi mais acentuada, o que reforça a relevância de uma estrutura em grafo para a precificação de ativos. O modelo de atenção baseado em grafos demonstrou uma habilidade particular em discernir informações relevantes dentro da topologia complexa dos dados, resultando em previsões de preço mais precisas.




Figura 9 – Comparação do MAPE para os modelos GRU e FinGAT em diversas empresas.

6.3.2 Experimento 2: Comparação Setorial

Os resultados da figura 10 são os mesmos do experimento 1, no entanto, focamos em comparar o tipo do grupo de setor nesse case. Esses resultados mostraram que para o setor "Igual", onde os ativos pertencem ao mesmo setor, o modelo FinGAT apresentou um MAPE de 4,11%, ligeiramente melhor do que o modelo GRU com 4,16%. Esta melhoria, embora modesta, sugere que a modelagem em grafo pode ter um desempenho ligeiramente superior na detecção de padrões e interconexões dentro de setores homogêneos, potencialmente devido à capacidade de capturar as relações intrassetoriais de forma mais efetiva.

Por outro lado, no setor "Diverso", que considera ativos de diferentes setores, o modelo FinGAT obteve um MAPE de 4,52%, que não superou o modelo GRU, que teve um MAPE de 4,48%. Este resultado indica que a estrutura em grafo não necessariamente proporcionou uma vantagem significativa neste contexto.




Figura 10 – Comparação do MAPE entre os modelos GRU e FinGAT para ativos de setores diferentes e iguais.

6.3.3 Experimento 3: Integração de Variáveis Fundamentais e Econômicas

A Figura 11 exibe o MAPE para o modelo FinGAT com a inclusão isolada de variáveis macroeconômicas (FinGAT + Macro), apenas variáveis fundamentais (FinGAT + Fundamental) e uma combinação de ambas (FinGAT + Macro + Fundamental), em comparação com o modelo FinGAT padrão e o modelo GRU.

Os resultados indicam que a adição de variáveis macroeconômicas e fundamentais não resultou em uma melhoria consistente da precisão das previsões. Observamos que em alguns casos houve uma ligeira redução no MAPE, como no caso do "Santander", onde o modelo com ambas as variáveis atingiu um MAPE de 3,40%, em comparação com 3,60% do modelo FinGAT padrão. No entanto, para outros casos como "Itaú" e "BTG", o modelo FinGAT padrão teve um desempenho melhor do que as variantes com variáveis adicionais.

Estes resultados sugerem que a simples adição de mais variáveis ao modelo nem sempre se traduz em uma maior precisão de previsão. Pode ser que a complexidade adicional introduzida por essas variáveis não esteja sendo adequadamente capturada pela estrutura atual do modelo, ou que seja necessário um refinamento adicional nas técnicas de processamento e na seleção de características relevantes.

Conclui-se que é fundamental uma análise mais criteriosa das variáveis escolhidas e da forma como elas são integradas ao modelo de GNN. Futuras investigações deverão se concentrar na otimização da seleção de características e no *feature engineering* para melhor explorar o potencial das variáveis fundamentais e econômicas na modelagem em grafo.




Figura 11 – Comparação do MAPE do modelo FinGAT com a inclusão de variáveis macroeconômicas e fundamentais, em relação ao nosso modelo proposto e ao GRU.

6.4 Testes e Avaliação

A avaliação do sistema proposto foi conduzida por meio de uma série de testes estruturados para garantir a funcionalidade, performance e confiabilidade. Estes testes foram categorizados da seguinte forma:

6.4.1 Teste de Hardware

Os testes de hardware foram realizados para assegurar que a infraestrutura de servidores do PCS suportasse adequadamente o processamento das Redes de Atenção em Grafos (GAT). Foram avaliados a estabilidade, desempenho e a compatibilidade do hardware com as necessidades de computação do CUDA.

6.4.2 Teste de Software

Para o software, os testes focaram na correta execução do código fonte, principalmente na integração do PyTorch e nas bibliotecas de CUDA. A verificação de bugs, a consistência dos outputs e a adequação dos algoritmos de GNN foram elementos chave nessa fase.

6.4.3 Teste de Módulo

Individualmente, cada módulo do sistema foi testado para validar suas funcionalidades específicas. Isso incluiu o módulo de extração de dados, o módulo de treinamento e o módulo de predição, assegurando que operassem conforme especificado.

6.4.4 Teste de Integração

Após os testes individuais, os módulos foram integrados e testados em conjunto para identificar e resolver quaisquer incompatibilidades e garantir a fluidez no processamento dos dados e na execução das predições.

6.4.5 Teste de Validação

Finalmente, foram realizados testes de validação, onde o modelo completo foi avaliado para determinar sua acurácia, utilizando o MAPE como métrica principal. A validação foi feita com base em dados históricos do mercado de ações e os resultados foram comparados com modelos de previsão existentes para confirmar a superioridade do sistema proposto.

Cada etapa de teste foi documentada meticulosamente, e os resultados foram revisados com o apoio do orientador para garantir a conformidade com os objetivos de pesquisa estabelecidos.

7 Considerações Finais

7.1 Conclusões do Projeto de Formatura

Este trabalho explorou o potencial da representação em grafo aplicada ao modelo FinGAT para a tarefa de precificação no mercado de ativos financeiros. Os objetivos delineados foram cuidadosamente investigados, com foco na comparação entre a modelagem em grafo e estruturas de dados tradicionais, na análise setorial e na integração de variáveis fundamentais e econômicas.

Os experimentos realizados evidenciaram que a estrutura em grafo, implementada por meio do modelo FinGAT, ofereceu melhorias nas previsões financeiras para o setor bancário, superando o modelo GRU. Observou-se uma vantagem particular da abordagem em grafo para empresas do mesmo setor, o que indica que a modelagem em grafo pode captar com mais eficiência ativos do mesmo setor.

Contrariamente, a inclusão de indicadores fundamentais e macroeconômicos não produziu uma melhoria consistente na precisão das previsões. Essa constatação levanta questões pertinentes sobre a seleção, relevância e integração dessas variáveis no contexto das Redes Neurais de Grafos.

Conclui-se que, embora a representação em grafo possa ser promissora, a sua aplicação na precificação de ativos financeiros requer uma abordagem meticulosa. Os resultados sugerem que uma estrutura em grafo pode ser mais vantajosa quando adaptada especificamente para ativos do mesmo setor, e que a inclusão de indicadores adicionais deve ser cuidadosamente avaliada porque não se mostrou promissora.

7.2 Contribuições

O desenvolvimento do código foi um esforço individual significativo, refletindo um profundo entendimento dos mecanismos subjacentes ao GAT e sua aplicação prática. As contribuições do coorientador foram cruciais, fornecendo *insights* valiosos sobre a implementação da codificação temporal, a seleção de um modelo específico e o aprofundamento conceitual necessário para a robustez do projeto. A integração dessas perspectivas contribuiu para a evolução do trabalho, tornando-o mais alinhado com as práticas atuais de análise de dados.

7.3 Perspectivas de Continuidade

Ao longo deste estudo, identificamos várias áreas que poderiam beneficiar-se de investigações adicionais e melhorias metodológicas. Aqui estão algumas considerações para trabalhos futuros:

- A granularidade dos dados é um fator crucial na modelagem preditiva. Atualmente, a extração de dados é realizada em uma base diária. A inclusão de dados com granularidade mais fina, como horária ou por minuto, poderia potencialmente capturar melhor a volatilidade do mercado e as dinâmicas intradiárias, possibilitando uma análise mais detalhada e previsões mais precisas.
- A emergência de Modelos de Linguagem de Grande Escala (LLMs) com capacidade de pesquisa online abre novas fronteiras para a análise de sentimentos e a geração de insights. A integração da saída desses modelos, como indicadores de sentimento ou tendências derivadas de redes sociais e notícias, poderia enriquecer o modelo FinGAT com uma camada de análise qualitativa que reflete o clima e as expectativas do mercado.
- A automatização na aquisição de dados fundamentais por meio de APIs dedicadas representa uma oportunidade significativa de melhorar tanto a eficiência quanto a abrangência do conjunto de dados. Dados mais abrangentes e atualizados automaticamente poderiam fornecer uma base mais sólida para o modelo, permitindo que variáveis econômicas e fundamentais sejam integradas de forma mais dinâmica e em tempo real na modelagem.

Essas direções apontam para a possibilidade de um modelo mais robusto e adaptativo, capaz de responder não apenas às mudanças quantitativas dos mercados, mas também às qualitativas, refletindo uma compreensão mais profunda dos ativos financeiros e do ambiente econômico em que se inserem.

Referências

ABARBANELL, J. S.; BERNARD, V. L. Tests of analysts' overreaction/underreaction to earnings information as an explanation for anomalous stock price behavior. *The journal of finance*, Wiley Online Library, v. 47, n. 3, p. 1181–1207, 1992. Citado na página 13.

ABARBANELL, J. S.; BUSHEE, B. J. Fundamental analysis, future earnings, and stock prices. *Journal of Accounting Research*, [Accounting Research Center, Booth School of Business, University of Chicago, Wiley], v. 35, n. 1, p. 1–24, 1997. ISSN 00218456, 1475679X. Disponível em: <<http://www.jstor.org/stable/2491464>>. Citado na página 18.

ADAM, K.; MARCET, A.; NICOLINI, J. P. Stock market volatility and learning. *The Journal of finance*, Wiley Online Library, v. 71, n. 1, p. 33–82, 2016. Citado na página 13.

ADEBIYI, A. A.; ADEWUMI, A. O.; AYO, C. K. Comparison of arima and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*, Hindawi, v. 2014, 2014. Citado na página 13.

BIGGS, N.; LLOYD, E.; WILSON, R. *Graph Theory, 1736-1936*. Clarendon Press, 1986. ISBN 9780198539162. Disponível em: <<https://books.google.com.br/books?id=XqYTk0sXmpoC>>. Citado na página 22.

BLUME, L.; EASLEY, D.; O'HARA, M. Market statistics and technical analysis: The role of volume. *The journal of finance*, Wiley Online Library, v. 49, n. 1, p. 153–181, 1994. Citado na página 13.

CHO, K. et al. Learning phrase representations using RNN encoder–decoder for statistical machine translation. In: MOSCHITTI, A.; PANG, B.; DAELEMANS, W. (Ed.). *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha, Qatar: Association for Computational Linguistics, 2014. p. 1724–1734. Disponível em: <<https://aclanthology.org/D14-1179>>. Citado na página 31.

FAMA, E. F. Efficient capital markets: Ii. *The Journal of Finance*, [American Finance Association, Wiley], v. 46, n. 5, p. 1575–1617, 1991. ISSN 00221082, 15406261. Disponível em: <<http://www.jstor.org/stable/2328565>>. Citado 2 vezes nas páginas 13 e 30.

FIRTH, M. The role of the stock market. In: _____. *The Valuation of Shares and the Efficient-Markets Theory*. London: Macmillan Education UK, 1977. p. 1–13. ISBN 978-1-349-15819-5. Disponível em: <https://doi.org/10.1007/978-1-349-15819-5_1>. Citado na página 17.

GILMER, J. et al. *Neural Message Passing for Quantum Chemistry*. 2017. Citado na página 22.

HELLSTRÖM, T.; HOLMSTRÖM, K. *Predicting the stock market*. [S.l.]: Mälardalens högskola, 1998. Citado na página 14.

HTUN, H. H.; BIEHL, M.; PETKOV, N. *Survey of feature selection and extraction techniques for stock market prediction*. U.S. National Library of Medicine, 2023. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9834034/>>. Citado na página 17.

- HUA, Y.; ZHU, R.; DUAN, Y. Construction of short-term stock price prediction algorithm based on mlp and cart bagging ensemble learning. In: *2022 IEEE Conference on Telecommunications, Optics and Computer Science (TOCS)*. [S.l.: s.n.], 2022. p. 371–376. Citado na página 19.
- HUANG, K. et al. Ml-gat:a multilevel graph attention model for stock prediction. *IEEE Access*, v. 10, p. 86408–86422, 2022. Citado 2 vezes nas páginas 29 e 32.
- KIM, R. et al. *HATS: A Hierarchical Graph Attention Network for Stock Movement Prediction*. 2019. Citado 2 vezes nas páginas 29 e 32.
- LEWIS, J. K. M. *Betting on the blind side*. 2010. Disponível em: <<https://www.vanityfair.com/news/2010/04/wall-street-excerpt-201004>>. Citado na página 13.
- LIN, Q. Technical analysis and stock return predictability: An aligned approach. *Journal of Financial Markets*, v. 38, n. C, p. 103–123, 2018. Disponível em: <<https://EconPapers.repec.org/RePEc:eee:finmar:v:38:y:2018:i:c:p:103-123>>. Citado na página 13.
- LIN, Y. et al. Stock trend prediction using candlestick charting and ensemble machine learning techniques with a novelty feature engineering scheme. *IEEE Access*, v. 9, p. 101433–101446, 2021. Citado na página 13.
- MOGHAR, A.; HAMICHE, M. Stock market prediction using lstm recurrent neural network. *Procedia Computer Science*, v. 170, p. 1168–1173, 2020. ISSN 1877-0509. The 11th International Conference on Ambient Systems, Networks and Technologies (ANT) / The 3rd International Conference on Emerging Data and Industry 4.0 (EDI40) / Affiliated Workshops. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050920304865>>. Citado na página 19.
- MURPHY, J. *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. Penguin Publishing Group, 1999. ISBN 9781101659199. Disponível em: <<https://books.google.com.br/books?id=teitAAAQBAJ>>. Citado na página 18.
- MURTAGH, F. Multilayer perceptrons for classification and regression. *Neurocomputing*, v. 2, n. 5, p. 183–197, 1991. ISSN 0925-2312. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0925231291900235>>. Citado na página 19.
- NAZÁRIO, R. T. F. et al. A literature review of technical analysis on stock markets. *The Quarterly Review of Economics and Finance*, v. 66, p. 115–126, 2017. ISSN 1062-9769. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1062976917300443>>. Citado na página 13.
- SCARSELLI, F. et al. The graph neural network model. *IEEE Transactions on Neural Networks*, v. 20, n. 1, p. 61–80, 2009. Citado na página 13.
- SHAW, P.; USZKOREIT, J.; VASWANI, A. *Self-Attention with Relative Position Representations*. 2018. Citado na página 30.
- SUGUMAR, D.; ALWAR, R.; JAYAKUMAR, C. A technique to stock market prediction using fuzzy clustering and artificial neural networks. *Computing and Informatics*, v. 33, p. 992–1024, 01 2014. Citado na página 13.

TICKNOR, J. L. A bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications*, Elsevier, v. 40, n. 14, p. 5501–5506, 2013. Citado na página 13.

VELIČKOVIĆ, P. et al. *Graph Attention Networks*. 2018. Citado na página 23.

VU, T. T. et al. An experiment in integrating sentiment features for tech stock prediction in Twitter. In: *Proceedings of the Workshop on Information Extraction and Entity Analytics on Social Media Data*. Mumbai, India: The COLING 2012 Organizing Committee, 2012. p. 23–38. Disponível em: <<https://aclanthology.org/W12-5503>>. Citado na página 14.

WILLMOTT, C. J. On the validation of models. *Physical Geography*, Taylor & Francis, v. 2, n. 2, p. 184–194, 1981. Disponível em: <<https://doi.org/10.1080/02723646.1981.10642213>>. Citado na página 36.

XIE, B. et al. Semantic frames to predict stock price movement. In: *Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*. Sofia, Bulgaria: Association for Computational Linguistics, 2013. p. 873–883. Disponível em: <<https://aclanthology.org/P13-1086>>. Citado na página 14.