

Augusto Vaccarelli Costa  
Fernando Falquetto Coelho  
Lucas Alexandre Tavares

## **Prescrição personalizada de tratamento de diálise peritoneal**

**São Paulo**

**2024**

Augusto Vaccarelli Costa  
Fernando Falquetto Coelho  
Lucas Alexandre Tavares

**Prescrição personalizada de tratamento de diálise peritoneal**

Dissertação apresentada à Escola  
Politécnica da Universidade de São  
Paulo para obtenção do título de  
Engenheiro de Computação

Orientadora:

Dr<sup>a</sup> Anarosa Alves Franco Brandão

Coorientadores:

Dr<sup>a</sup> Daniela Ponce

Dr<sup>a</sup> Maristela Carvalho da Costa

Dr Rogério da Hora Passos

**São Paulo**

**2024**

## **Resumo**

A doença renal crônica (DRC) impõe grandes desafios para a saúde pública, necessitando de terapias de substituição renal (TSR) nos estágios avançados. Entre as TSR, a Diálise Peritoneal (DP) oferece uma alternativa viável à hemodiálise, permitindo o tratamento domiciliar e preservando a estabilidade hemodinâmica do paciente. Este trabalho apresenta uma abordagem baseada em inteligência artificial (IA) para apoiar a prescrição de DP pelos médicos, indicando o regime de tratamento com base nas condições clínicas dos pacientes. O modelo proposto utiliza técnicas de aprendizado de máquina para ajustar parâmetros como volume de infusão, frequência de trocas e tipo de solução, visando maximizar a adequação do tratamento e preservar a função renal residual. A aplicação dessa tecnologia na DP tem o potencial de reduzir complicações, melhorar a qualidade de vida dos pacientes e otimizar o uso de recursos em saúde. Este trabalho está alinhado com o ODS 3 - 3.4.

## **Abstract**

Chronic kidney disease (CKD) poses major challenges for public health, requiring renal replacement therapies (RRT) in advanced stages. Among RRT options, peritoneal dialysis (PD) offers a viable alternative to hemodialysis, enabling home treatment and preserving the patient's hemodynamic stability. This work presents an artificial intelligence AI-based approach to support physicians in prescribing PD by recommending treatment regimens based on patients' clinical conditions. The proposed model employs machine learning techniques to adjust parameters such as infusion volume, exchange frequency, and solution type, aiming to maximize treatment adequacy and preserve residual kidney function. The application of this technology in PD has the potential to reduce complications, improve patients' quality of life, and optimize healthcare resource utilization. This work is aligned with SDG 3 - 3.4.

# SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>6</b>
1.1 MOTIVAÇÃO.....	6
1.2 OBJETIVO.....	7
1.3 JUSTIFICATIVA.....	7
<b>2. CONCEITOS E TECNOLOGIAS.....</b>	<b>9</b>
2.1 TERAPIA DE SUBSTITUIÇÃO RENAL.....	9
2.2 DIÁLISE PERITONEAL.....	10
2.3 MODELOS DE PRESCRIÇÃO PERSONALIZADA NA DP.....	11
2.4 INTELIGÊNCIA ARTIFICIAL E MEDICINA PERSONALIZADA.....	12
2.5 APRENDIZADO POR REFORÇO NA PRESCRIÇÃO MÉDICA.....	13
2.6 PERSPECTIVAS ECONÔMICAS DO TRATAMENTO DE DRC.....	14
2.7 APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA DP.....	14
<b>3. MATERIAIS E MÉTODOS.....</b>	<b>17</b>
3.1 DADOS.....	17
3.2 LIMPEZA DE DADOS.....	17
3.3 ARQUITETURA MULTIAGENTE.....	18
3.4 APRENDIZADO POR REFORÇO.....	19
3.4.1. SELEÇÃO DE ALGORITMO.....	19
3.5 FERRAMENTAS DE IMPLANTAÇÃO.....	20
<b>4. DESENVOLVIMENTO.....</b>	<b>21</b>
<b>4.1 ESPECIFICAÇÃO DE REQUISITOS.....</b>	<b>21</b>
4.1.1 REQUISITOS FUNCIONAIS.....	21
4.1.2 REQUISITOS NÃO FUNCIONAIS.....	22
4.2 ARQUITETURA.....	22
4.3 MODELO.....	25
4.3.1 DADOS UTILIZADOS.....	25
4.3.2 TRATAMENTO E PRÉ-PROCESSAMENTO.....	26
4.3.3 PREPARAÇÃO PARA TREINAMENTO DO MODELO.....	29
4.3.3 MODELAGEM DO AMBIENTE.....	30
4.3.4 MAPEAMENTO DE ESTADOS.....	32
4.3.5 MAPEAMENTO DE AÇÕES.....	33
4.3.6 ELABORAÇÃO DE PESOS DE ATRIBUTOS DE RECOMPENSA.....	34
4.3.7 ESTADO INICIAL DA TABELA DE Q-LEARNING.....	35
4.3.8 TREINAMENTO.....	35
<b>4.4 BACK-END.....</b>	<b>36</b>
4.4.1 AGENTE COLETOR DE DADOS.....	36
4.4.2 AGENTE RECOMENDADOR.....	37
4.4.3 AGENTE DE INTERAÇÃO.....	37
4.5 DESENVOLVIMENTO DE FRONT-END.....	37
4.5.1 INTRODUÇÃO ÀS TECNOLOGIAS.....	38

4.5.2 CARACTERÍSTICAS DO REACT.JS E NEXT.JS.....	38
4.5.3. IMPLEMENTAÇÃO E ESTRUTURA DO PROJETO.....	39
4.5.4 COMPARAÇÃO COM OUTRAS TECNOLOGIAS.....	42
4.5.5 CONSIDERAÇÕES.....	43
<b>5. RESULTADOS.....</b>	<b>45</b>
5.1 TESTES E VALIDAÇÕES.....	47
<b>6. CONCLUSÕES E TRABALHOS FUTUROS.....</b>	<b>49</b>
<b>7. REFERÊNCIAS.....</b>	<b>51</b>

# 1. INTRODUÇÃO

O presente projeto de formatura propõe uma abordagem inovadora para o processo de prescrição de diálise peritoneal (DP) por meio do desenvolvimento, validação, implementação e distribuição de um modelo de inteligência artificial (IA). O objetivo principal é disponibilizar esse modelo para médicos nefrologistas, incluindo aqueles não especialistas em DP, de forma que possam utilizá-lo como referência para prescrever tratamentos personalizados e eficazes a pacientes com doença renal crônica (DRC) avançada. O modelo visa integrar dados clínicos e demográficos para gerar recomendações adaptadas às condições únicas de cada paciente, superando limitações associadas aos métodos tradicionais de prescrição.

A aplicação de IA nesse contexto não apenas reflete uma tendência crescente de utilização de tecnologias avançadas na medicina, mas também aborda desafios centrais na personalização das terapias de substituição renal (TSR). A personalização de tratamentos é fundamental para melhorar os desfechos clínicos, reduzir complicações associadas a regimes inadequados e otimizar o uso dos recursos de saúde. Assim, este trabalho se alinha com os avanços contemporâneos da medicina de precisão e com a crescente necessidade de inovação em nefrologia, promovendo melhorias tangíveis na qualidade de vida dos pacientes.

## 1.1 MOTIVAÇÃO

A doença renal crônica (DRC) constitui uma preocupação global crescente de saúde pública, afetando cerca de 850 milhões de pessoas em todo o mundo (Nature, 2024). Nos estágios avançados da DRC, a função renal comprometida exige terapias de substituição renal para manter a homeostase do organismo, impondo uma carga significativa aos pacientes e aos sistemas de saúde (Grassmann et al., 2005). Entre as modalidades disponíveis, a diálise peritoneal (DP) destaca-se por sua flexibilidade e pelo fato de permitir que o paciente realize o tratamento em domicílio. A DP utiliza a membrana peritoneal como meio natural de filtração para remover toxinas e excesso de fluidos, oferecendo uma alternativa menos dependente de infraestrutura hospitalar quando comparada à hemodiálise.

Apesar dessas vantagens, a eficácia da DP depende diretamente da adequação do regime de tratamento às condições únicas de cada paciente, que incluem fatores

como taxa de filtração glomerular residual, características da membrana peritoneal, volume urinário e parâmetros demográficos. No entanto, a prescrição de regimes de DP é um processo desafiador, frequentemente limitado por abordagens baseadas em heurísticas e métodos padronizados que não conseguem capturar toda a complexidade das condições clínicas individuais. Como resultado, prescrições subótimas podem comprometer os resultados clínicos, contribuindo para hospitalizações frequentes, maiores taxas de morbidade e mortalidade.

A necessidade de melhorar a personalização da prescrição de DP é, portanto, evidente. A integração de tecnologias como a IA, capaz de analisar grandes volumes de dados clínicos e identificar padrões complexos, oferece uma oportunidade sem precedentes para superar as limitações dos métodos tradicionais e promover avanços significativos na prática clínica.

## **1.2 OBJETIVO**

Este projeto de formatura tem como objetivo principal inovar o processo de prescrição de DP por meio do desenvolvimento, validação e implementação de um modelo baseado em IA. Esse modelo será disponibilizado para médicos nefrologistas, com foco especial nos profissionais não especialistas em DP, para auxiliá-los na prescrição de tratamentos adaptados às necessidades específicas de cada paciente.

Ao integrar as capacidades analíticas da IA com as demandas clínicas da DP, o modelo proposto busca superar as limitações das abordagens convencionais, fornecendo recomendações personalizadas baseadas em evidências extraídas de dados clínicos e demográficos. Com isso, espera-se melhorar os desfechos clínicos dos pacientes, reduzir a incidência de complicações relacionadas a tratamentos inadequados e otimizar a utilização de recursos de saúde. Este trabalho representa um avanço significativo na aplicação de IA na medicina personalizada, promovendo uma abordagem mais eficiente e acessível à nefrologia moderna.

## **1.3 JUSTIFICATIVA**

Doenças renais são a terceira causa de morte que mais cresce ao redor do mundo (NATURE, 2024). Espera-se que esse tipo de enfermidade continue afetando cada

vez mais pessoas no mundo todo no decorrer das próximas décadas. Isso se torna preocupante especialmente em países como o Brasil, que está passando pela transição demográfica já vivenciada por países desenvolvidos, na qual há um crescimento da faixa etária mais idosa da população.

Essa tendência de crescimento já afeta diretamente não só a saúde de 850 milhões de pessoas (NATURE, 2024), mas também os cofres públicos de economias globais. Países como os Estados Unidos gastam atualmente 130 bilhões de dólares no tratamento e mitigação dos danos causados por doenças renais.

Tratamentos convencionais como a hemodiálise, embora eficazes, são um dos maiores responsáveis pelos elevados custos de saúde pois exigem que o paciente se desloque ao hospital várias vezes por semana, com tratamentos contínuos que perduram até o final da vida ou até a realização de um transplante renal. Em países como a Tailândia, por exemplo, a hemodiálise representa cerca de 3% do total dos custos de saúde (NATURE, 2024). Em contrapartida, a DPI é uma modalidade de TRS mais versátil e com custos mais acessíveis, uma vez que pode ser realizada no próprio domicílio e exige menos infraestrutura hospitalar.

No entanto, a DP não é indicada para todos os casos de insuficiência renal e, quando prescrita de forma inadequada, pode contribuir para o agravamento da condição do paciente. Sendo assim, há a necessidade de assegurar um regime de DP ajustado às necessidades individuais é evidente, visando garantir estabilidade clínica e segurança ao paciente. Uma melhoria na personalização da prescrição de DP pode gerar benefícios substanciais, tanto em termos de desfechos clínicos quanto de sustentabilidade econômica, reduzindo a carga sobre os sistemas de saúde e contribuindo para a qualidade de vida dos pacientes.

## **2. CONCEITOS E TECNOLOGIAS**

A aplicação de IA na prescrição de tratamentos médicos representa uma das fronteiras mais promissoras para a medicina personalizada, com o potencial de transformar o modo como doenças crônicas são gerenciadas, especialmente em contextos como a DP. A DP, que se baseia na membrana peritoneal do paciente para realizar a filtração do sangue, oferece vantagens significativas, como a possibilidade de tratamento domiciliar e maior flexibilidade para os pacientes. No entanto, sua eficácia depende de uma prescrição rigorosamente adaptada às necessidades individuais, considerando fatores como a função renal residual, o volume urinário e as características da membrana peritoneal do paciente.

### **2.1 TERAPIA DE SUBSTITUIÇÃO RENAL**

A terapia de substituição renal (TSR) é um conjunto de tratamentos médicos projetados para replicar as funções dos rins quando estes estão incapazes de operar adequadamente devido a doença renal aguda ou crônica. Os rins desempenham uma série de funções vitais, incluindo a filtragem de resíduos metabólicos do sangue, regulação dos eletrólitos, controle do volume de fluidos e manutenção do equilíbrio ácido-base. Na ausência de uma função renal eficaz, substâncias tóxicas e líquidos podem se acumular no corpo, levando a condições potencialmente fatais que necessitam intervenção através da TSR.

Existem três principais modalidades de TSR: hemodiálise, DP e terapia de substituição renal contínua. A hemodiálise utiliza um dialisador externo que filtra o sangue fora do corpo, removendo toxinas e excesso de líquidos através de uma membrana semipermeável. O processo requer que o sangue seja circulado fora do corpo, tratado e então retornado, geralmente sendo realizado várias vezes por semana em sessões de várias horas.

A DPI, por outro lado, faz uso da membrana peritoneal do paciente como um filtro natural. Uma solução dialítica é introduzida no espaço peritoneal, e os resíduos são eliminados do sangue através da membrana peritoneal por difusão e osmose. Esta forma de diálise pode ser administrada em casa e é frequentemente preferida por oferecer maior liberdade e flexibilidade para o paciente.

A terapia de substituição renal contínua é tipicamente reservada para pacientes que estão em condições críticas, como aqueles em unidades de terapia intensiva. Esta técnica é usada principalmente em pacientes instáveis que não tolerariam as mudanças rápidas de fluido e solutos associadas com a hemodiálise convencional. É uma forma lenta e contínua de filtrar o sangue, proporcionando um controle mais refinado do balanço de fluidos e solutos.

A TSR é crucial não apenas para a remoção de substâncias nocivas e o controle do volume de fluido, mas também para facilitar o manejo metabólico e o equilíbrio eletrolítico em pacientes com falência renal. Isso ajuda a prevenir complicações sérias como hipercalemia, acidose metabólica e sobrecarga de fluidos. A escolha entre as modalidades de TSR depende de vários fatores, incluindo a condição clínica do paciente, preferências pessoais, disponibilidade local de tratamento, e outras condições médicas concomitantes.

## **2.2 DIÁLISE PERITONEAL**

A DP é uma forma de terapia de substituição renal que utiliza a membrana peritoneal do próprio paciente como um filtro natural para remover resíduos e excesso de fluidos do corpo, substituindo assim as funções normais dos rins quando estes estão comprometidos. Essa técnica é especialmente útil para pacientes com insuficiência renal crônica ou aguda que necessitam de tratamento contínuo para equilibrar os níveis de eletrólitos e remover toxinas do sangue.

Na DP, uma solução dialítica estéril é infundida na cavidade peritoneal, a cavidade abdominal que envolve os órgãos internos. A solução de diálise contém um alto teor de glicose, que serve como um agente osmótico para puxar líquidos e solutos tóxicos do sangue através da membrana peritoneal. Com o tempo, a solução dialítica absorve os resíduos e é drenada do abdômen, sendo substituída por uma nova solução para continuar o processo de limpeza. Este ciclo de infusão e drenagem é repetido várias vezes ao dia ou é realizado continuamente, dependendo do método específico de DP utilizado.

Existem dois tipos principais de DP: a diálise peritoneal ambulatorial contínua (CAPD) e a diálise peritoneal automatizada (DPA). A CAPD é realizada manualmente pelo paciente ou cuidador, com trocas de fluido ocorrendo várias

vezes ao longo do dia. Por outro lado, a DPA utiliza uma máquina chamada cicladora que automaticamente realiza as trocas de fluido durante a noite enquanto o paciente dorme, permitindo maior liberdade durante o dia.

A DP é frequentemente escolhida por oferecer maior conveniência e flexibilidade em comparação com a hemodiálise, que requer visitas frequentes a um centro de diálise. Além disso, como é geralmente administrada em casa, a DP permite que os pacientes mantenham um cronograma de trabalho ou atividades pessoais mais normal. Também é considerada mais suave em termos de equilíbrio de fluidos e estabilidade hemodinâmica, o que é particularmente vantajoso para pacientes idosos ou aqueles com condições cardíacas.

Além das vantagens, a DP exige que os pacientes mantenham uma rigorosa higiene para evitar infecções, especialmente peritonite, uma infecção potencialmente grave da cavidade abdominal. Os pacientes e cuidadores devem ser bem treinados no procedimento adequado de troca para minimizar o risco de contaminação.

### **2.3 MODELOS DE PRESCRIÇÃO PERSONALIZADA NA DP**

A prescrição personalizada em DP é essencial para atender às necessidades individuais dos pacientes, uma vez que as características fisiológicas e clínicas variam amplamente. Historicamente, as prescrições têm se baseado em princípios heurísticos e diretrizes clínicas gerais que nem sempre capturam a complexidade da condição de cada paciente. Diversos estudos buscaram desenvolver modelos que integrem mais dados do paciente para ajustar parâmetros como volume de infusão, frequência das trocas e concentração da solução.

Trabalhos como o de Galli et al. (2011) exploraram sistemas de modelagem computacional para ajustar as prescrições de DP, enquanto Zhang et al. (2005) introduziram métodos de reconhecimento de padrões fuzzy para selecionar regimes de diálise. Essas abordagens, embora promissoras, muitas vezes carecem de flexibilidade para capturar as mudanças contínuas no estado do paciente, o que destaca a necessidade de soluções mais dinâmicas e personalizadas, como a IA aplicada neste projeto.

## 2.4 INTELIGÊNCIA ARTIFICIAL E MEDICINA PERSONALIZADA

A (IA) é uma área da ciência da computação que se dedica a criar sistemas capazes de executar tarefas que normalmente requerem inteligência humana. Estas incluem processamento de linguagem natural, reconhecimento de padrões, tomada de decisões e aprendizado. O principal objetivo da IA é permitir que as máquinas aprendam a partir de experiências e ajustem suas ações a novos *inputs*, uma capacidade que é profundamente inspirada pelo raciocínio humano.

Um dos principais pilares da IA é o aprendizado de máquina (*Machine Learning*, ML), que fornece aos sistemas a habilidade de aprender automaticamente e melhorar com a experiência sem ser explicitamente programado. Essa aprendizagem é alcançada através de algoritmos que interpretam conjuntos de dados, aprendem com eles e fazem previsões ou tomam decisões baseadas em informações passadas. Dentre os métodos de aprendizado de máquina, o aprendizado profundo (*Deep Learning*) se destaca por utilizar redes neurais artificiais profundas que simulam o comportamento do cérebro humano, permitindo que as máquinas processem dados de maneiras complexas e com pouca intervenção humana.

As redes neurais são uma estrutura inspirada no sistema nervoso dos seres vivos, composta por camadas de nós que imitam os neurônios. Estes nós são conectados por caminhos que transmitem sinais e são ajustados durante o treinamento do modelo para melhorar a precisão das previsões ou classificações. O processo de aprendizagem em uma rede neural envolve a alimentação repetida de grandes volumes de dados, ajustando os pesos sinápticos entre os nós para minimizar a diferença entre a saída prevista e a real.

Dentro da IA, o ML é um dos pilares fundamentais, fornecendo aos sistemas a habilidade de aprender automaticamente e melhorar com a experiência sem ser explicitamente programado. Este aprendizado ocorre através de diferentes técnicas, sendo as mais comuns o aprendizado supervisionado, não supervisionado, e por reforço.

## 2.5 APRENDIZADO POR REFORÇO NA PRESCRIÇÃO MÉDICA

A técnica de IAI conhecida como aprendizado por reforço (AR) é um método que permite a um agente aprender a tomar decisões otimizadas através de tentativa e erro, interagindo com um ambiente para maximizar uma recompensa cumulativa. Este paradigma de aprendizado se diferencia das outras formas tradicionais, como o aprendizado supervisionado e não supervisionado, pelo seu foco na aprendizagem baseada em ações e suas consequências, ao invés de prever um resultado a partir de um conjunto de entradas fornecidas.

No AR, o agente toma decisões sequenciais, observando o estado do ambiente e tomando ações que resultam em transições para novos estados e a obtenção de recompensas. O objetivo principal é desenvolver uma política de ação que maximize as recompensas totais ao longo do tempo. Esta política orienta o agente sobre qual ação tomar em diferentes situações, com base no aprendizado acumulado através da experiência direta de suas interações com o ambiente.

A modelagem do ambiente no AR é frequentemente representada como um processo decisório de Markov (MDP), onde as transições entre estados são probabilísticas e dependem apenas do estado atual e da ação executada pelo agente. A função de recompensa, parte integrante de um MDP, quantifica o benefício obtido ao se tomar uma determinada ação em um estado específico.

Uma das componentes centrais do AR é a estimativa do valor de uma política de ação, geralmente através de métodos como as equações de Bellman. Essas equações ajudam a avaliar a qualidade de uma política, fornecendo um meio de atualizar as estimativas de valor com base nas recompensas recebidas e nas novas estimativas de estados subsequentes. O agente aprende a melhorar sua política gradualmente, ajustando suas escolhas de ações com base nas estimativas de valor atualizadas.

Em saúde, o AR tem se mostrado eficaz em problemas de decisão sequencial, como a prescrição de medicamentos e o ajuste de dosagens ao longo do tempo. Esse método diferencia-se por seu enfoque em ações e suas consequências a longo prazo, tornando-o particularmente adequado para regimes de tratamento que exigem adaptações contínuas.

Aplicações recentes de AR na medicina incluem o controle automatizado de dosagens de insulina para diabetes e o ajuste de ventiladores para pacientes críticos. Essas aplicações demonstram o potencial do AR para criar políticas adaptativas que respondam ao estado clínico em tempo real (Aragão Pereira et al., 2022). Em diálise DP, o uso de AR pode permitir a criação de um modelo que ajusta a prescrição de acordo com a resposta do paciente, otimizando parâmetros de tratamento de forma contínua e personalizada.

## **2.6 PERSPECTIVAS ECONÔMICAS DO TRATAMENTO DE DRC**

O impacto econômico das doenças renais é significativo e cresce à medida que a prevalência da DRC aumenta em todo o mundo. Países como os Estados Unidos gastam aproximadamente 130 bilhões de dólares anuais no tratamento e mitigação dos danos causados por essa condição (NATURE, 2024), sendo a hemodiálise uma das principais responsáveis pelos altos custos, devido à sua frequência e necessidade de infraestrutura hospitalar. Em países como a Tailândia, por exemplo, os custos com hemodiálise representam cerca de 3% do orçamento total em saúde (NATURE, 2024).

A DP, por sua vez, apresenta um custo relativamente menor e pode ser realizada em casa, reduzindo a necessidade de hospitalizações frequentes. No entanto, a falta de personalização pode levar a complicações, aumentando os custos gerais do tratamento. Estudos sugerem que a adoção de sistemas de IA para personalizar o tratamento pode diminuir essas complicações, impactando positivamente a saúde financeira dos sistemas públicos e privados de saúde (Burlacu et al., 2020). A personalização do regime de DP, portanto, não só oferece benefícios clínicos, mas também representa uma alternativa economicamente viável em longo prazo.

## **2.7 APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA DP**

Embora abordagens tradicionais tenham utilizado protocolos padronizados para a prescrição de DP, elas apresentam limitações, uma vez que não capturam a variabilidade individual dos pacientes e as mudanças em seu estado clínico ao longo do tempo. Estudos recentes têm demonstrado o valor da IA, especificamente o aprendizado de máquina, na análise de dados clínicos complexos e na adaptação de tratamentos a cada paciente. Essas técnicas permitem a análise de grandes

volumes de dados para identificar padrões sutis que podem orientar ajustes precisos nos parâmetros da diálise, como a frequência das trocas, o volume de solução infundido e a concentração dos solutos.

No contexto da DP, modelos de aprendizado supervisionado e aprendizado profundo foram inicialmente explorados para prever respostas clínicas e otimizar a prescrição com base em dados históricos de pacientes. Porém, tais métodos, por serem essencialmente estáticos, têm limitações em capturar as mudanças dinâmicas que ocorrem na condição dos pacientes. Nesse cenário, o AR emerge como uma técnica particularmente relevante, pois permite a adaptação contínua do regime de tratamento com base no feedback do estado clínico do paciente, ajustando a prescrição de acordo com o retorno do próprio ambiente do paciente (MILAN MANANI et al., 2018; BURLACU et al., 2020).

O AR é uma técnica de IA em que um agente aprende a tomar decisões ao longo do tempo para maximizar uma recompensa cumulativa, o que se alinha bem aos objetivos de uma prescrição de DP adaptativa. Em vez de fornecer uma prescrição fixa, um sistema baseado em AR pode ajustar parâmetros em tempo real, baseando-se nas respostas do paciente, como a variação nos níveis de uréia, creatinina e outros marcadores de função renal. Esse tipo de ajuste dinâmico pode não apenas otimizar a eficácia do tratamento, mas também minimizar o risco de complicações e melhorar a qualidade de vida do paciente.

Por exemplo, o modelo pode aumentar o volume de solução durante as trocas caso observe que o *clearance* de toxinas do paciente esteja abaixo dos níveis ideais, ou ajustar a concentração de solutos como potássio e cálcio com base em exames laboratoriais regulares. Ao longo do tempo, o agente de AR "aprende" as respostas mais eficazes para diferentes perfis de pacientes, adaptando-se tanto a mudanças agudas quanto a variações crônicas na condição do paciente. Esse aprendizado contínuo oferece uma vantagem significativa sobre os métodos tradicionais, pois permite que o sistema de prescrição se ajuste proativamente, antecipando possíveis complicações antes que estas afetem o paciente.

O uso de IA, e especificamente de AR, na prescrição de DP pode reduzir significativamente a carga de trabalho dos profissionais de saúde, que muitas vezes precisam revisar prescrições manualmente para cada paciente. Esse modelo de IA

serviria como um sistema de apoio à decisão, fornecendo recomendações personalizadas baseadas em uma análise extensa dos dados clínicos do paciente. Assim, os médicos poderiam focar na supervisão e validação das prescrições, enquanto o modelo ajusta automaticamente o tratamento diário, de acordo com as necessidades do paciente.

Estudos indicam que a personalização do tratamento em DP pode reduzir taxas de hospitalização, melhorar a adesão ao tratamento e diminuir o risco de complicações (JOHN; JHA, 2019). Além disso, o uso de AR para a personalização contínua da prescrição permite que o tratamento seja otimizado sem a necessidade de supervisão constante, tornando a DP uma opção mais viável e segura para pacientes que precisam ou preferem receber tratamento domiciliar.

Essa aplicação de IA, portanto, representa uma inovação significativa na nefrologia, alavancando tecnologias avançadas para fornecer um cuidado mais responsivo e eficaz. Ao utilizar dados em tempo real para ajustar a prescrição de diálise, esse modelo não só atende às exigências clínicas e econômicas atuais, mas também posiciona a DP como um tratamento mais flexível e acessível, que pode ser melhor adaptado para atender às necessidades de uma população de pacientes cada vez mais diversificada e em crescimento.

### 3. MATERIAIS E MÉTODOS

No emprego da IA à medicina, é necessário escolher as tecnologias adequadas e planejar o desenvolvimento. Este capítulo discorre sobre as tecnologias utilizadas no trabalho, linguagens de desenvolvimento de código, técnicas de ciência de dados utilizadas, entre outros recursos utilizados.

#### 3.1 DADOS

O conjunto de dados voltados para informações demográficas e nutricionais registra dados antropométricos e nutricionais, incluindo peso atual, peso seco, altura, índice de massa corporal (IMC) e consumo estimado de nutrientes, como proteínas, cálcio, fósforo e magnésio. As informações sobre a composição corporal são cruciais para o ajuste de prescrições individualizadas e para o monitoramento do estado nutricional, um fator que influencia diretamente os resultados clínicos da diálise.

#### 3.2 LIMPEZA DE DADOS

Para treinar um modelo de IA para modelar um fenômeno baseado em dados clínicos, que são majoritariamente numéricos, é necessário completude desses dados. Sendo assim, algumas técnicas de tratamento de dados empregadas devem ser citadas. Há uma ampla variedade de dados a serem considerados, que são distribuídos em diversas tabelas, como de exame nutricional, prescrições e dados demográficos. Para converter cada entrada de dados num caso de teste que pode ser usado para treinamento, há a necessidade de unir os dados numa única tabela, num processo chamado *outer join*.

O *outer join* gera uma alta quantidade de registros, somando as quantidades de registros das tabelas que o compõem. No entanto, a sua completude costuma ser extremamente baixa. Assim é razoável assumir que muitos dados do paciente não estarão presentes em todas as tabelas. Entretanto, é seguro assumir que todo registro estará atrelado a um paciente e a uma data. Tendo em vista a natureza dos tratamentos médicos, exames e prescrições

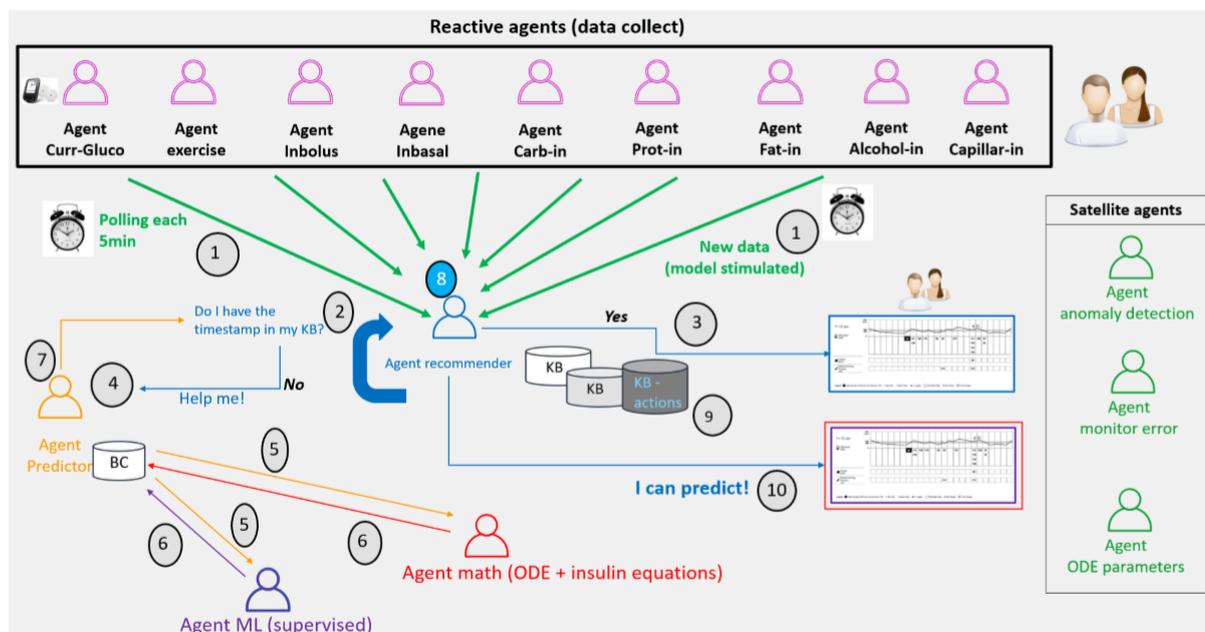
Esses dados podem ser organizados por paciente e depois cronologicamente, a fim de criar uma "linha do tempo" para cada paciente, para aumentar a sua completude, pode ser feito um *forward fill*. Este método, realizado dentro da série temporal de

exames e prescrições de cada paciente, consiste em preencher os valores ausentes com o último valor registrado para cada variável, preservando assim a continuidade das informações. Aplicando essas técnicas, esperamos uma completude de dados satisfatória para realizar o treinamento do modelo.

### 3.3 ARQUITETURA MULTIAGENTE

Como inspiração para o modelo de arquitetura foi escolhida a de Aragão Pereira et al. (2022), pois a intenção do modelo Tesseractus, elaborado por ele, é similar à intenção deste trabalho. Este trabalho tem o intuito de ser um modelo que possa ser distribuído a um público, no nosso caso de médicos não especialistas em DP, para que possam se inspirar nas sugestões de prescrição fornecidas com base em dados clínicos de seus pacientes para lhes prescrever um tratamento personalizado.

Figura 1: Arquitetura do Tesseractus



Fonte: ARAGÃO PEREIRA et al., (2022)

Tendo em mente a modularidade, baixo acoplamento entre componentes e a inspiração de arquitetura, foi decidido que o trabalho seria implementado com programação orientada a agentes, tal qual no trabalho de Aragão Pereira et al (2022).

### 3.4 APRENDIZADO POR REFORÇO

O AR difere tanto do aprendizado supervisionado quanto do não supervisionado por não precisar da apresentação de exemplos corretos de comportamento, como pares de entrada-saída rotulados. Em vez disso, o foco está em encontrar um equilíbrio entre exploração de território desconhecido e exploração do conhecimento atual do agente, com o objetivo de maximizar a recompensa cumulativa ao invés de encontrar uma estrutura oculta no fenômeno estudado (SUTTON; BARTO, 2018).

O ambiente é normalmente declarado na forma de um Processo de Decisão de Markov (PDM), já que muitos algoritmos de AR usam técnicas de programação dinâmica. A principal diferença entre os métodos clássicos de programação dinâmica e os algoritmos de AR é que estes últimos não assumem o conhecimento de um modelo matemático exato do processo de decisão de Markov e têm como alvo grandes PDM onde métodos exatos se tornam inviáveis (SUTTON; BARTO, 2018). Dada a ausência de modelos matemáticos para basear o aprendizado do agente, essa família de algoritmos foi escolhida para o agente aprendiz para prescrição de DP.

#### 3.4.1. SELEÇÃO DE ALGORITMO

Dada a natureza do fenômeno estudado, sabendo que não há modelo matemático formal para a prescrição de tratamento de DP, portanto foi escolhido o *q-learning*, um algoritmo de AR que opera sem modelo. Esse algoritmo ensina um agente a atribuir valores a cada ação que ele pode tomar, condicionado ao agente estar em um estado particular. Ele não requer um modelo do ambiente, e pode lidar com problemas com transições estocásticas e recompensas sem exigir adaptações.

Para qualquer processo de decisão de Markov finito, o Q-learning encontra uma política ótima no sentido de maximizar o valor esperado da recompensa total em todas e quaisquer etapas sucessivas, começando pelo estado atual. O AR envolve um agente, um conjunto de estados  $S$  e um conjunto de ações  $A$  por estado. Ao executar uma ação  $a$  o agente transita entre estados. Executar uma ação em um estado específico fornece ao agente uma recompensa na forma de uma pontuação numérica.

O objetivo do agente é maximizar sua recompensa total. Ele faz isso adicionando a recompensa  $R_{t+1}$  máxima possível de estados futuros à recompensa por atingir seu estado atual, influenciando efetivamente a ação atual pela recompensa futura potencial. Essa recompensa potencial é uma soma ponderada dos valores esperados das recompensas de todas as etapas futuras a partir do estado atual. Um passo do aprendizado  $Q$  pode ser descrito pela seguinte fórmula (SUTTON; BARTO, 2018):

$$Q^{new}(S_t, A_t) \leftarrow (1 - \alpha) \cdot Q(S_t, A_t) + \alpha \cdot [R_{t+1} + \gamma \cdot \max_a Q(S_{t+1}, a) - Q(S_t, A_t)]$$

A taxa de aprendizagem  $\alpha$  ou tamanho do passo determina até que ponto as informações recém-adquiridas substituem as informações antigas. Um fator de 0 faz com que o agente explore exclusivamente o conhecimento prévio, enquanto um fator de 1 faz com que o agente considere apenas as informações mais recentes.

O fator de desconto determina a importância das recompensas futuras. Um fator de 0 tornaria o agente míope ao considerar apenas as recompensas atuais, ou seja, enquanto um fator se aproximando de 1 faria com que ele se esforçasse por uma alta recompensa de longo prazo. Se o fator de desconto atingir ou exceder 1, os valores de ação podem divergir.

### **3.5 FERRAMENTAS DE IMPLANTAÇÃO**

Entre as ferramentas de implantação utilizadas temos o git para controle de versão e Vercel como serviço de hospedagem eletrônica, fornecendo endereço eletrônico para nosso site. Vercel foi escolhido pela capacidade de hospedagem gratuita, integração com *Next.js* e familiaridade dos membros do grupo.

## **4. DESENVOLVIMENTO**

O desenvolvimento do presente trabalho incluiu o estudo de técnicas de Aprendizado de Máquina, coleta de dados, implementação dos agentes, treinamento e validação do modelo. A pesquisa teórica se focou na busca de modelos matemáticos para tratar o problema na literatura médica, no qual pudéssemos basear a modelagem. No entanto, não foi encontrado nenhum modelo matemático para calcular parâmetros da prescrição de DP na literatura clássica.

Foi realizada a coleta de dados contendo informações demográficas e clínicas de pacientes com DRC submetidos a TSRs. Os dados foram coletados do Hospital das Clínicas da Faculdade de Medicina de Botucatu e foram preparados para a concepção de um treinamento. Na implementação, de acordo com proposta de arquitetura na seção 3.3, o único agente não reativo é o agente aprendiz, assim a elaboração sobre o desenvolvimento dos agentes reativos será tratada de maneira mais superficial.

As prescrições geradas pelo modelo serão comparadas às recomendações de especialistas (Dr Rogério da Hora Passos, Dr<sup>a</sup> Daniela Ponce). Esta comparação não só servirá para ajustar e auxiliar no treinamento do modelo, mas também para demonstrar sua viabilidade e eficácia em ambientes clínicos reais. Ao final da validação, e após verificação de acurácia, o modelo será disponibilizado para uso hospitalar através de uma aplicação web, a fim de difundir e aumentar a qualidade dos tratamentos de DP em geral.

### **4.1 ESPECIFICAÇÃO DE REQUISITOS**

Como parte desta dissertação, inclui-se o desenvolvimento do ambiente onde o sistema será distribuído, havendo a necessidade de especificar requisitos e de se entregar o ambiente já integrado ao modelo.

#### **4.1.1 REQUISITOS FUNCIONAIS**

O sistema deve ser capaz de integrar e processar uma ampla gama de dados clínicos dos pacientes, incluindo informações demográficas, condições médicas preexistentes, e resultados de exames. Ele deverá analisar esses dados para identificar padrões que informem a prescrição de parâmetros específicos do

tratamento de diálise, como o volume de infusão, número de trocas diárias, tipo de solução de diálise e a duração das sessões.

É vital que o modelo ajuste as prescrições com base em *feedback* contínuo sobre a eficácia do tratamento e eventuais efeitos adversos, assegurando uma resposta adaptativa às necessidades do paciente. O sistema também precisa fornecer uma interface de usuário intuitiva que permita aos profissionais de saúde inserir facilmente dados e acessar prescrições e históricos de tratamento.

Ademais, o sistema deve ser capaz de gerar relatórios para monitoramento e revisão médica e se integrar de forma fluida aos sistemas hospitalares existentes, facilitando uma operação coesa dentro do ambiente médico.

#### **4.1.2 REQUISITOS NÃO FUNCIONAIS**

A confiabilidade é crucial, com o modelo precisando oferecer prescrições precisas para minimizar riscos de complicações. Dados absurdos, desconexos da realidade não devem ser gerados. O desempenho também é chave, com a necessidade de fornecer respostas em tempo real ou quase real para facilitar a tomada de decisão rápida sem interrupções no tratamento.

A segurança dos dados do paciente deve ser rigorosamente protegida em conformidade com leis e regulamentos como a LGPD. O sistema também deve ser escalável, capaz de atender a um número crescente de pacientes e adaptável a diferentes locais e situações.

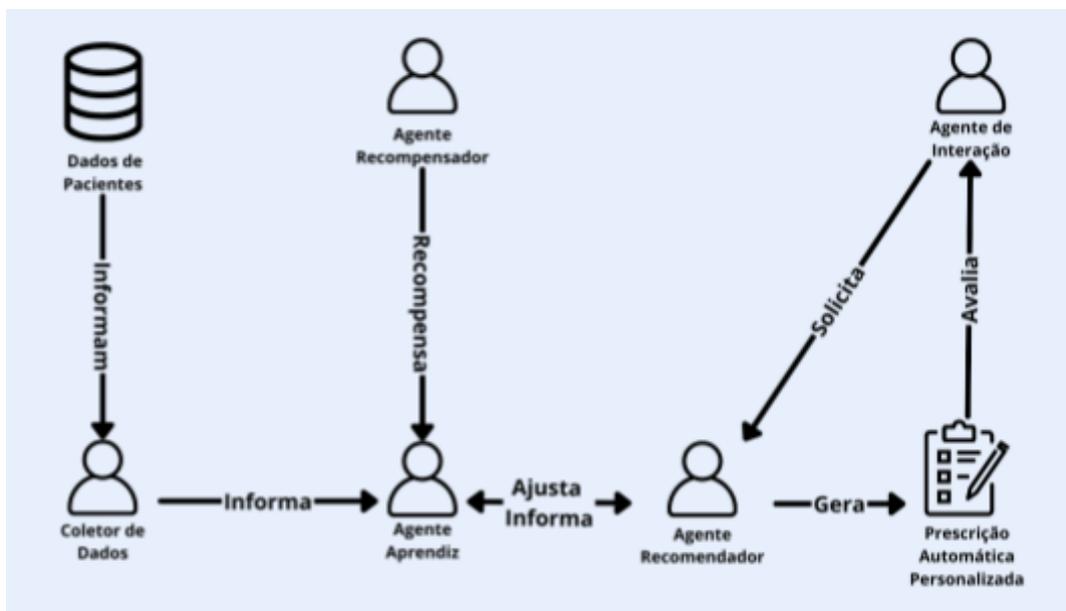
Outros aspectos importantes incluem a manutibilidade, para permitir atualizações e ajustes fáceis ao modelo; a interoperabilidade, para funcionar em conjunto com outros sistemas de tecnologia em saúde; e a usabilidade, garantindo que o sistema seja acessível mesmo para usuários menos familiarizados com tecnologias avançadas.

#### **4.2 ARQUITETURA**

O desenvolvimento do sistema passa por três etapas diferentes no quesito de arquitetura: palpite inicial, treinamento com testes sintéticos e treinamento contínuo após disponibilização. Todas elas possuem dois elementos em comum que



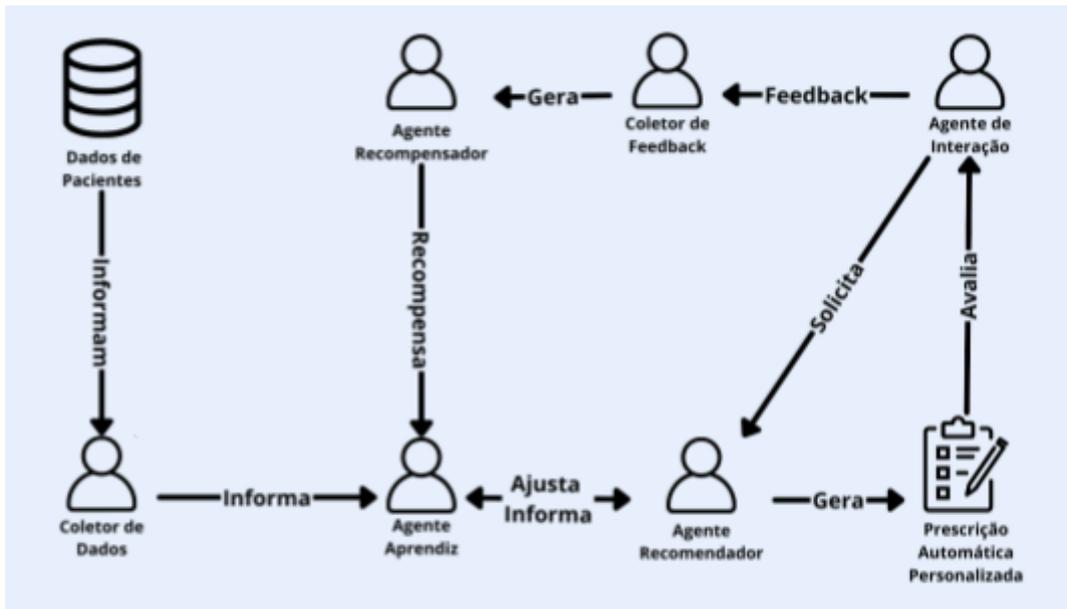
Figura 3 - Arquitetura do treinamento com testes sintéticos



Fonte: elaborado pelos autores (2024)

Durante o treinamento, as prescrições geradas pelo sistema serão continuamente validadas pelos Dr Rogério da Hora Passos e Dr<sup>a</sup> Maristela Carvalho da Costa, a fim de refinar as recompensas do agente aprendiz. Quando o modelo for capaz de gerar prescrições com acurácia e precisão adequadas, ele poderá ser disponibilizado para uso e o testador sintético será substituído pelos médicos usuários do sistema, os quais serão responsáveis por solicitar os parâmetros do tratamento e fornecer *feedbacks* quanto às prescrições para que o aprendizado continue.

Figura 4 - Arquitetura do treinamento contínuo



Fonte: elaborado pelos autores (2024)

### 4.3 MODELO

Para a codificação do modelo foi empregado um *notebook jupyter*, que é um ambiente de desenvolvimento que possibilita codificação cooperativa online. O modelo foi codificado em Python sem *frameworks* externos. Foram usadas as bibliotecas *scikit-learn* para fazer o *split* 80/20, *pandas* e *numpy* para análise e tratamento dos dados obtidos e *seaborn* para a geração do mapa de calor.

#### 4.3.1 DADOS UTILIZADOS

Para a realização do presente trabalho, foram utilizados dados retrospectivos de pacientes em tratamento de DP, fornecidos pelo Hospital das Clínicas da Faculdade de Medicina de Botucatu. Os dados foram recebidos com informações anonimizadas, contendo exames laboratoriais, informações demográficas, clínicas e nutricionais, além de prescrições fornecidas aos pacientes.

O conjunto de dados laboratoriais contém informações sobre parâmetros bioquímicos essenciais ao monitoramento dos pacientes, incluindo medições periódicas de creatinina, ureia (pré e pós-diálise), potássio, cálcio e fósforo, entre outros marcadores de função renal e equilíbrio eletrolítico. Esses exames fornecem dados fundamentais para avaliar a resposta dos pacientes ao tratamento e

identificar possíveis ajustes terapêuticos, assegurando o controle dos níveis metabólicos críticos.

Por fim, os dados sobre a prescrição de diálise inclui detalhes individuais do tratamento de cada paciente, como a frequência das sessões, volume e composição das soluções utilizadas e parâmetros como as concentrações de sódio, potássio e cálcio nas soluções de diálise. Estes dados são essenciais para o desenvolvimento de modelos de prescrição otimizada, pois refletem as variáveis controláveis do tratamento e serão tanto a saída quanto a medida de sucesso do agente aprendiz.

Ao total, trabalhamos com 3825 entradas de dados divididas entre prescrições, exames laboratoriais e nutricionais de 183 pacientes distintos, e todo paciente possui cadastro com dados demográficos.

#### **4.3.2 TRATAMENTO E PRÉ-PROCESSAMENTO**

Durante o processo de preparação dos dados, foram aplicadas diversas etapas com o objetivo de integrar e padronizar as informações, garantindo uma boa qualidade desses dados para análises e treinamento subsequentes. Cada tabela foi carregada no ambiente de análise e todas as colunas com dados temporais foram convertidas para o formato *datetime*.

Dado o interesse exclusivo em pacientes que realizavam DP, o segundo passo foi a filtragem do conjunto demográfico e clínico para selecionar apenas os pacientes neste tipo específico de programa. Para isso, a coluna “programa” foi utilizada como critério de seleção, e os registros de pacientes com outras modalidades de tratamento foram removidos. Como foram recebidos dados provenientes de todos os pacientes de diálise (e não somente DP), essa etapa é fundamental para garantir a presença exclusiva de informações do grupo de interesse da pesquisa.

Na etapa de fusão, os conjuntos de dados de exames, nutricional, prescrição e demográfico foram integrados em um único arquivo mestre com base nas colunas “*codigopaciente*” (identificador do paciente) e “*data*”. A fusão dos dados foi realizada em etapas, começando pela junção dos conjuntos de exames e nutricional, seguida da integração do conjunto de prescrição e, por fim, dos dados demográficos filtrados. Esse processo seguiu uma abordagem de fusão externa (*outer join*) para

preservar todas as entradas de cada conjunto, assegurando a inclusão de registros íntegros, mesmo em casos onde eles não estivessem completos. Após a fusão, colunas duplicadas foram identificadas e removidas para manter a integridade das informações e evitar redundâncias, a tabela 1 possui as informações referentes a cada coluna da tabela final gerada após essas fusões.

Tabela 1 - Colunas da tabela com dados de pacientes em DP

Nome da Coluna	Descrição	Tipo de Dado	Exemplo
PatientCode	Identificador único de cada paciente.	Numérico	46
date	Data do exame ou do registro, utilizada para ordenar os eventos cronologicamente.	Data	2008-03-11
Gender	Gênero do paciente.	Categórico	m
Weight	Peso do paciente no momento do registro, em quilogramas.	Numérico	70.5
Height	Altura do paciente, em centímetros.	Numérico	175
BMI	Índice de Massa Corporal (IMC), calculado com base no peso e altura.	Numérico	23.0
Creatinine	Nível de creatinina sérica, marcador de função renal, medido em mg/dL.	Numérico	10.6
Urea	Nível de ureia no sangue, importante para avaliação da função renal.	Numérico	116.0
Potassium	Nível de potássio no sangue, medido em mEq/L.	Numérico	5.6
Sodium	Nível de sódio no sangue, em mEq/L.	Numérico	138
Hemoglobin	Concentração de hemoglobina no sangue, usada para avaliar anemia, em g/dL.	Numérico	13.5
CRP	Proteína C-reativa, marcador de inflamação no sangue, medido em mg/L.	Numérico	3.0
Phosphorus	Nível de fósforo no sangue, importante para o equilíbrio mineral, medido em mg/dL.	Numérico	4.5
Calcium	Nível de cálcio no sangue, essencial para o equilíbrio mineral, medido em mg/dL.	Numérico	9.2
PTH	Paratormônio, um hormônio que regula o cálcio e fósforo, medido em pg/mL.	Numérico	55.0
ECW	Extra Celular Water, ou Líquido ExtraCelular (LEC), medida em razão com a água corporal total	Numérico	0.45
UreaClearance	Volume de Ureia eliminado pelos rins por minuto, medido em ml/min	Numérico	17.6

UrineOutput	Volume de urina diário, em mililitros (mL).	Numérico	1200
TotalVolume	Volume total administrado por ciclo de diálise, em mililitros (mL).	Numérico	2000
TreatmentFrequency	Frequência do tratamento de diálise (em dias por semana).	Numérico	3
CycleCount	Número de ciclos de troca de solução em uma sessão de diálise peritoneal.	Numérico	4
TherapyDuration	Duração da sessão de diálise, em horas.	Numérico	8
Bicarbonate	Nível de bicarbonato no sangue, relevante para equilíbrio ácido-base, medido em mmol/L.	Numérico	24.0
SolutionCalcium	Concentração de cálcio na solução dialítica.	Numérico	1.5
SolutionPotassium	Concentração de potássio na solução dialítica.	Numérico	0.1
SolutionGlucose	Concentração de glicose na solução dialítica, usada para controle osmótico.	Numérico	1.5
SolutionInsulin	Quantidade de insulina adicionada à solução dialítica, em unidades internacionais (UI).	Numérico	10

Fonte: elaborado pelos autores (2024)

Para lidar com valores ausentes, que eram recorrentes devido à natureza clínica dos dados, foi aplicado o método de preenchimento progressivo (*forward fill*). A tabela 2 mostra a diferença no número de dados ausentes antes e depois da aplicação do *forward fill*.

Tabela 2 - Comparação entre dados ausentes antes e após o *forward fill*

Nome da Coluna	Dados Ausentes Antes do Forward Fill	Dados Ausentes Após o Forward Fill
PatientCode	0	0
date	7	7
Gender	0	0
Weight	10426	1291
Height	10414	1292
BMI	10449	1294
Creatinine	6004	794

Urea	6067	826
Potassium	6087	849
Sodium	13627	13253
Hemoglobin	6162	922
CRP	10299	3790
Phosphorus	6557	936
Calcium	6240	863
PTH	8657	1353
ECW	6161	1616
UreaClearance	10532	915
SolutionInsulin	13284	10752
UrineOutput	9315	2586
TotalVolume	12298	7040
TreatmentFrequency	10115	1286
CycleCount	10147	1372
TherapyDuration	10161	1381
Bicarbonate	8170	2079
SolutionCalcium	11506	3083

Fonte: elaborado pelos autores (2024)

#### 4.3.3 PREPARAÇÃO PARA TREINAMENTO DO MODELO

Para preparar os números na base de dados para emprego no treinamento, é necessário discretizar os valores apresentados na base dados em função de valores considerados normais, para que o modelo trabalhe com números inteiros, a fim de que não tenha opções demais na tomada de decisão. Assim, com base em American Journal of Kidney Diseases (2006) e Auguste e Bargman (2023), buscamos valores considerados normais para substâncias relacionadas a DP, dentre os disponíveis na nossa base de dados. Essas substâncias podem influenciar todos os parâmetros da prescrição, e para compor essa discretização, é necessário observar quais valores de quais atributos são desejáveis ou considerados ruins para a saúde do paciente. Assim, construiu-se a Tabela 3 abaixo, que foi validada por especialistas.

Tabela 3: Dados clínicos e seus valores típicos

Indicador Clínico	Valor Alto	Valor Médio	Valor Baixo	Valor Ideal
BIC (mEq/L)	acima de 25	de 16 a 22	abaixo de 22	Médio
Cálcio (mg/dL)	acima de 10,5	de 8,2 a 10,5	abaixo de 8,2	Baixo
Creatinina (mg/dL)	acima de 3,5	de 1,3 a 3,5	abaixo de 1,2	Baixo
CRP (g/dL)	acima de 1		abaixo de 0,5	Baixo
Fósforo (mg/dL)	acima de 5,5	de 3,5 a 5,5	abaixo de 3,5	Baixo
Hemoglobina (g/dL)	acima de 15	de 10 a 12	abaixo de 10	Médio
Potássio (mEq/L)	acima de 5,5	de 3,5 a 5,5	abaixo de 3,5	Médio
PTH (pg/dL)	acima de 800	de 350 a 800	abaixo de 150	de 150 a 350
Sódio (mEq/L)	acima de 145	de 135 a 145	abaixo de 135	Baixo
Ureia (mg/dL)	acima de 120	de 80 a 120	abaixo de 80	Baixo

Fonte: elaborado pelos Autores (2024)

Para os índices de *ECW* e *UreaClearance* foi usada uma técnica diferente de classificação. Como todos os pacientes submetidos ao tratamento de DP possuem comprometimento nesses dois indicadores, foram usados recortes percentuais uniformes de um valor de referência, no caso, o maior disponível na base de dados.

Como a implementação do modelo calcula o próprio progresso por uma regra de “maior é melhor”, se faz necessário rotular os intervalos da tabela 3 em valores discretos e simples, para que a lógica possa ser assimilada. Com base na tabela 3, estabelecemos respectivamente para valores considerados ruins, medianos e bons os valores 0, 1 e 2 para o treinamento. Com base nessa escolha, foi elaborada uma tabela 4, que elenca rótulos maiores para intervalos mais desejáveis para cada indicador clínico disponível.

#### 4.3.3 MODELAGEM DO AMBIENTE

Tendo em vista a utilização do algoritmo Q-learning, o modelo desenvolvido interage diretamente com o ambiente simulado, que é constituído por estados e ações. O ambiente foi projetado de forma a balancear a complexidade computacional do algoritmo com a necessidade de uma representação precisa do sistema clínico. O custo computacional do Q-learning aumenta significativamente com o número de

estados e ações disponíveis (SUTTON; BARTO, 2018). Por isso, foi adotada uma abordagem de discretização dos dados (data binning), reduzindo as opções do modelo a intervalos pré-definidos, que são ajustados especificamente para cada variável relevante.

Os estados do modelo representam as condições clínicas dos pacientes, com variáveis como Índice de Massa Corporal (IMC), níveis séricos de creatinina, ureia, *clearance* de uréia, potássio, sódio, bicarbonato, hemoglobina, cálcio, fósforo, PTH, e CRP. Essas variáveis foram discretizadas em intervalos definidos como bons, aceitáveis ou ruins, refletindo faixas de valores considerados clinicamente significativos. Essa discretização reduz o espaço de estados para um tamanho computacionalmente gerenciável, sem perder a capacidade de capturar variações clínicas importantes.

As ações disponíveis ao modelo correspondem a ajustes nos parâmetros da prescrição de DP, incluindo volume total da solução, frequência dos ciclos, duração da terapia e concentrações de cálcio, potássio, glicose e insulina. Cada ação é uma combinação específica desses parâmetros, representada como uma tupla de índices dos intervalos discretizados. Essas combinações abrangem milhares de possibilidades, permitindo uma gama diversificada de intervenções terapêuticas.

Durante a simulação do ambiente, o modelo observa todas as combinações possíveis de estados clínicos e ações prescritas. As transições entre estados são calculadas com base em mudanças médias observadas em pacientes reais para cada ação executada, com uma componente adicional de ruído para simular a variabilidade clínica. O modelo aprende a associar ações a estados com base em um sistema de recompensas: ações que aproximam os indicadores clínicos de valores desejáveis recebem recompensas positivas, enquanto aquelas que pioram as condições dos pacientes são penalizadas.

Essa abordagem permite ao modelo gerar prescrições otimizadas, movendo os pacientes de estados clínicos menos favoráveis para estados mais desejáveis. O ambiente simulado, portanto, desempenha um papel crucial no treinamento do agente, garantindo que ele aprenda a prescrever tratamentos eficazes e personalizados.

#### 4.3.4 MAPEAMENTO DE ESTADOS

Os estados do modelo foram definidos com base nos valores clínicos dos pacientes disponíveis no conjunto de dados. Cada estado representa uma combinação única de variáveis discretizadas, as quais incluem indicadores como Índice de Massa Corporal (IMC), creatinina, ureia, clearance de uréia, potássio, sódio, bicarbonato, hemoglobina, cálcio, fósforo, PTH e CRP. Esses indicadores clínicos foram normalizados e discretizados em faixas (bins) com base em valores considerados normais, médios ou críticos para a saúde do paciente. Isso reduz a dimensionalidade do espaço de estados e permite que o modelo manipule esses valores de forma computacionalmente eficiente.

Após o agrupamento de dados em bins, cada estado foi representado como um vetor de valores numéricos que corresponde a essas variáveis discretizadas. Além disso, foi realizada uma validação cruzada para garantir que todos os estados criados refletissem adequadamente as condições clínicas dos pacientes no conjunto de treinamento.

Tabela 04: Escolhas de valor *binning* nos dados de entrada

Indicador Clínico	Intervalo Bom (valor 2)	Intervalo Médio (valor 1)	Intervalo Ruim (valor 0)
Bicarbonato (mEq/L)	de 16 a 22	de 22 a 25	de 0 a 16 e de 25 a $+\infty$
Cálcio (mg/dL)	de 0 a 8,2	de 8,2 a 10,5	de 10,5 a $+\infty$
Creatinina (mg/dL)	de 0 a 1,2	de 1,2 a 3,5	de 3,5 a $+\infty$
CRP (g/dL)	de 0 a 0,5	de 0,5 a 1	de 1 a $+\infty$
Fósforo (mg/dL)	de 0 a 3,5	de 3,5 a 5,5	de 5,5 a $+\infty$
Hemoglobina (g/dL)	de 0 a 10	de 10 a 12	de 12 a $+\infty$
Potássio (mEq/L)	de 0 a 3,5	de 3,5 a 5,5	de 5,5 a $+\infty$
PTH (pg/dL)	de 150 a 350	de 350 a 800	de 0 a 150 e de 800 a $+\infty$
Ureia (mg/dL)	de 0 a 80	de 80 a 120	de 120 a $+\infty$
Clarence de Ureia	de 100% a 66%	de 66% a 33%	de 33% a 0%
Líquido Extracelular	de 100% a 66%	de 66% a 33%	de 33% a 0%

IMC		de 18,5 a 25	de 25 a +∞
-----	--	--------------	------------

Fonte: elaborado pelos autores (2024)

O espaço de estados foi então gerado combinando as diferentes possibilidades para cada indicador clínico, resultando em um conjunto finito, mas suficientemente grande, para representar o ambiente de forma satisfatória.

#### 4.3.5 MAPEAMENTO DE AÇÕES

As ações disponíveis para o modelo foram mapeadas como combinações de parâmetros ajustáveis relacionados à prescrição de DP. Esses parâmetros incluem o volume total da solução, a frequência dos ciclos, a duração da terapia, e as concentrações de cálcio, potássio, glicose e insulina na solução dialisante. Assim como nos estados, os valores possíveis para cada parâmetro foram discretizados em intervalos predefinidos (bins) baseados em valores clínicos típicos.

Cada ação é representada como uma tupla contendo os índices dos bins correspondentes para cada parâmetro. Por exemplo, uma ação pode ser representada como “(3, 2, 4, 0, 1, 3, 2)”, onde cada número corresponde a um bin específico para um parâmetro clínico.

Todas as combinações possíveis de bins entre os parâmetros foram geradas, resultando em um espaço de ações que inclui milhares de possibilidades. Esse espaço de ações permite ao modelo explorar e selecionar intervenções que otimizem os resultados clínicos, movendo o paciente de um estado clínico menos desejável para um mais desejável. Essas possibilidades foram geradas usando os intervalos de *binning* disponíveis na tabela 5.

Tabela 5: Intervalos de binning escolhidos para dados de saída

Parâmetro de Prescrição	valor 0	valor 1	valor 2	valor 3	valor 4	valor 5
Volume por ciclo (mL)	de 400 a 800	de 801 a 1000	de 1001 a 1400	de 1401 a 1800	de 1801 a 2000	de 2001 a 2500
Cálcio	de 0 a 1,5	de 1,5 a 3,5				
Contagem de	de 0,5 a	de 3,5 a	de 4,5 a	de 5,5 a	de 6,5 a	de 7,5 a

ciclos	3,5	4,5	5,5	6,5	7,5	10,5
Potássio	de 0 a 20	de 20 a 45				
Duração (horas)	de 2,5 a 7,5	de 7,5 a 8,5	de 8,5 a 9,5	de 9,5 a 10,5	de 10,5 a 11,5	de 11,5 a 24
Glicose (%)	de 1 a 1,5	de 1,5 a 2,5	de 2,5 a 3,5	de 3,5 a 4,25		
Insulina	de 0 a 20	de 20 a 40				

Fonte: elaborado pelos autores (2024)

Durante o treinamento, o modelo aprende a associar as melhores ações para cada estado, ajustando os parâmetros de prescrição com base nas recompensas recebidas. Recompensas mais altas são atribuídas às ações que aproximam os indicadores clínicos dos pacientes de valores ideais, enquanto penalidades são aplicadas para ações que pioram os estados clínicos.

#### 4.3.6 ELABORAÇÃO DE PESOS DE ATRIBUTOS DE RECOMPENSA

Também dos guias de práticas clínicas em American Journal of Kidney Diseases (2006) e Auguste e Bargman (2023) buscamos estabelecer prioridades para quais características devem possuir maior recompensa no treinamento. Sendo assim, estabelecemos pesos de recompensa maiores para características consideradas mais vitais para uma boa prescrição de DP, de acordo com a tabela 6 abaixo, que foi verificada por especialistas.

Tabela 6: Pesos de Recompensa dos indicadores clínicos

Indicador Clínico	Peso de Recompensa
ECW	0.5
Urea	0.5
UreaClearance	0.5
Creatinine	0.3
Potassium	0.3
Bicarbonate	0.1
BMI	0.1
Calcium	0.1
CRP	0.1

Hemoglobin	0.1
Phosphorus	0.1
PTH	0.1

Fonte: elaborado pelos autores (2024)

#### **4.3.7 ESTADO INICIAL DA TABELA DE Q-LEARNING**

Os primeiros episódios do treinamento podem custar muitas iterações até se obter uma convergência razoável a partir de uma matriz de aprendizado vazia. Conforme discutido na arquitetura, optamos por preencher a matriz de aprendizado com um palpite inicial da literatura clássica. Os valores são baseados nas discretizações adotadas nos parâmetros de entrada e em direcionamentos de guias clínicos de prescrição como os encontrados em American Journal of Kidney Diseases (2006) e Auguste e Bargman (2023).

#### **4.3.8 TREINAMENTO**

O treinamento do modelo de Q-learning foi implementado utilizando um loop iterativo, no qual o agente interage diretamente com o ambiente simulado. Esse loop foi organizado em episódios, cada um representando uma sessão de aprendizado do agente para um paciente selecionado aleatoriamente no conjunto de dados. Dentro de cada episódio, o agente executa múltiplos passos, ajustando gradualmente sua política de ações com base nas recompensas obtidas pelas transições entre estados.

No início de cada passo, o agente escolhe uma ação com base na política  $\epsilon$ -greedy, que equilibra a exploração de novas ações com a exploração de ações previamente identificadas como promissoras. Durante os primeiros episódios, o agente prioriza a exploração, com uma alta probabilidade de selecionar ações aleatórias. Conforme o treinamento avança, o valor de  $\epsilon$  diminui exponencialmente, incentivando o agente a se concentrar em ações que historicamente produziram melhores resultados.

Após selecionar uma ação, o agente a aplica ao estado atual no ambiente simulado. Essa aplicação gera uma transição para um próximo estado, calculada com base em mudanças médias observadas nos dados clínicos reais, complementadas por

uma componente de ruído aleatório que simula a variabilidade inerente ao ambiente clínico. Em seguida, uma recompensa é atribuída ao agente, com base na melhoria ou deterioração dos indicadores clínicos do paciente. Recompensas maiores são dadas para transições que aproximam os indicadores dos valores ideais, enquanto penalidades são aplicadas para ações que resultam em estados clínicos piores.

A tabela Q, que armazena os valores de recompensa esperados para cada par estado-ação, é atualizada após cada transição utilizando a equação de Bellman. Essa atualização considera a recompensa recebida, o valor do estado resultante e os parâmetros de aprendizado ( $\alpha$ ) e desconto ( $\gamma$ ). O parâmetro  $\alpha$  controla a taxa de aprendizado, enquanto  $\gamma$  pondera o impacto das recompensas futuras no cálculo do valor atual.

Ao longo do treinamento, o agente repete esse ciclo de escolha de ação, transição de estado, atribuição de recompensa e atualização da tabela Q para cada passo em cada episódio. Esse processo permite que o modelo aprenda uma política de ações que maximize a recompensa acumulada, ajustando os parâmetros da prescrição para mover os pacientes de estados clínicos menos desejáveis para estados mais favoráveis.

O loop de treinamento foi projetado para explorar todo o espaço de estados e ações, garantindo que o agente adquirisse experiência suficiente para lidar com uma ampla gama de situações clínicas. Esse processo iterativo permite ao modelo refinar continuamente sua política, tornando-o capaz de personalizar prescrições de DP de forma eficiente e adaptativa.

#### **4.4 BACK-END**

O desenvolvimento do back-end da arquitetura envolve os agentes reativos em torno do modelo, como especificado nas figuras 2, 3 e 4. Esses agentes interagem entre si e com o modelo elaborado.

##### **4.4.1 AGENTE COLETOR DE DADOS**

O Agente Coletor de Dados é um agente reativo que se conecta com o banco de dados usado para treinamento do modelo. Ele coleta os dados da tabela geral e os adequa para serem usados pelo Agente Aprendiz.

#### 4.4.2 AGENTE RECOMENDADOR

Este agente reativo se comunica com o Agente Aprendiz e com o Agente de Interação, pedindo prescrições e enviando os dados do paciente e recebendo essas prescrições, encaminhando-as ao Agente de Interação. No entanto, essa tarefa não é um somente repasse de dados.

Como explicado na seção 4.3, os intervalos de aprendizado do modelo foram discretizados numa lista de opções de valores para cada campo, a fim de acelerar o aprendizado. Sendo assim, é necessário um agente que encaminhe os dados para o *front-end* e os converta à grandeza física correta. O Agente Recomendador é um dos agentes que conhece a discretização de dados empregada no modelo.

#### 4.4.3 AGENTE DE INTERAÇÃO

O Agente de interação é uma interface com o front-end. Ele é chamado pelos scripts do site e encaminha os pedidos de prescrição (e os dados de paciente que os acompanham) para o Agente Recomendador, que interage diretamente com o Agente Aprendiz. Nosso agente de interação encapsula o *back-end* do projeto e pode ser chamado como uma API por serviços externos. Essa decisão de projeto torna o modelo mais flexível e a implantação mais modular.

#### 4.5 DESENVOLVIMENTO DE *FRONT-END*

Dado que o objetivo deste projeto é melhorar o cenário de prescrição de DP no Brasil, se faz necessário distribuir o modelo de IA através de algum meio acessível. Tendo isso em mente, a opção favorita foi a de criar uma interface web, disponibilizada através de um endereço eletrônico, um *site*, para que o trabalho possa ser usado como um serviço, de maneira assíncrona e amplamente disponível.

O *framework* escolhido para tal tarefa foi o Next.js, além da familiaridade do grupo com a tecnologia, Next.js faz com que a criação de interfaces interativas seja uma tarefa fácil. É possível criar *views* simples para cada estado na aplicação, e o Next.js atualiza e renderiza de forma eficiente apenas os componentes necessários na medida em que os dados mudam. O Next.js também pode ser renderizado no servidor, usando *Node*, e ser usado para criar aplicações mobile, tornando o trabalho ainda mais acessível.

#### **4.5.1 INTRODUÇÃO ÀS TECNOLOGIAS**

React.js e Next.js estão entre as tecnologias mais utilizadas para o desenvolvimento de aplicações web modernas. Essas ferramentas, comumente associadas a projetos de alta escalabilidade e desempenho, foram escolhidas para o sistema de prescrição de DP devido à sua capacidade de atender a requisitos complexos, como renderização eficiente, flexibilidade de design e segurança de dados sensíveis.

O React.js é uma biblioteca JavaScript centrada na criação de interfaces de usuário. Ele permite o desenvolvimento modular, baseado em componentes reutilizáveis, o que reduz significativamente o tempo de manutenção e evolução do sistema. Por outro lado, o Next.js é um framework completo que amplia as capacidades do React.js ao incluir funcionalidades como renderização no servidor, roteamento automático e integração de APIs.

Essas tecnologias possibilitaram a criação de uma aplicação responsiva e funcional, com foco em fornecer uma experiência de usuário fluida e em otimizar o desempenho para médicos e profissionais de saúde. Além disso, o suporte a SEO do Next.js garantiu que o sistema fosse acessível e facilmente navegável.

#### **4.5.2 CARACTERÍSTICAS DO REACT.JS E NEXT.JS**

React.js é uma biblioteca JavaScript de código aberto, criada pelo Facebook, que permite o desenvolvimento de interfaces de usuário baseadas em componentes. Sua abordagem declarativa facilita a criação de uma interface de usuário que se atualiza de forma eficiente em resposta às mudanças de dados.

React.js foi criado para simplificar o desenvolvimento de interfaces de usuário por meio de componentes independentes que se integram para formar aplicações complexas. Uma das características mais importantes do React.js é o Virtual DOM, que melhora o desempenho ao renderizar apenas as partes da interface que sofreram alterações, em vez de atualizar toda a página.

Outra funcionalidade essencial é o fluxo unidirecional de dados, conhecido como "*One-Way Data Flow*". Isso garante que as mudanças no estado da aplicação sejam previsíveis, facilitando a depuração e o rastreamento de bugs.

No sistema de prescrição, o React.js foi responsável por gerenciar toda a camada de apresentação, garantindo que os dados clínicos fossem exibidos de maneira clara, organizada, escalável e intuitiva através de componentes reutilizáveis. Esses componentes reutilizáveis foram amplamente empregados para criar tabelas, formulários e gráficos de forma modular, o que acelerou o desenvolvimento e simplificou ajustes futuros.

Já o Next.js é um framework que estende as capacidades do React.js, fornecendo ferramentas como roteamento automático, suporte a CSS modular e renderização híbrida. Ele é amplamente utilizado para criar aplicações que demandam SEO otimizado e carregamento rápido.

Além disso, a geração estática de páginas (SSG) melhora o desempenho ao criar versões pré-renderizadas de páginas que não mudam com frequência. Por exemplo, a página "Sobre o Projeto" do sistema foi implementada com SSG, garantindo carregamento quase instantâneo para todos os usuários.

O suporte a roteamento automático do Next.js também simplificou a navegação no sistema. Não foi necessário configurar manualmente rotas para cada página, pois a estrutura de pastas do projeto gerou automaticamente as URLs correspondentes. Isso facilitou a criação de telas como a de "Resultados" e "Dados Clínicos".

#### **4.5.3. IMPLEMENTAÇÃO E ESTRUTURA DO PROJETO**

O projeto foi estruturado com uma divisão clara entre componentes, páginas e APIs. Esta abordagem facilita a manutenção e escalabilidade do sistema. A arquitetura do sistema foi organizada com base nas melhores práticas do Next.js, o que garantiu uma separação clara entre diferentes responsabilidades da aplicação. O diretório *pages/* armazenou as principais telas do sistema, enquanto *components/* centralizou os elementos reutilizáveis, como gráficos e formulários.

Esse design modular não apenas acelerou o desenvolvimento, mas também tornou o código mais legível e fácil de manter. Por exemplo, qualquer mudança em um botão ou tabela pôde ser realizada diretamente no componente correspondente, afetando todas as partes do sistema que utilizavam esses elementos.

Para gerenciar a lógica do sistema, foram criadas APIs no diretório *api/*. Essas rotas serviram como intermediárias entre o front-end e o banco de dados, manipulando operações CRUD relacionadas a dados clínicos e históricos de pacientes.

Os diretórios principais incluem:

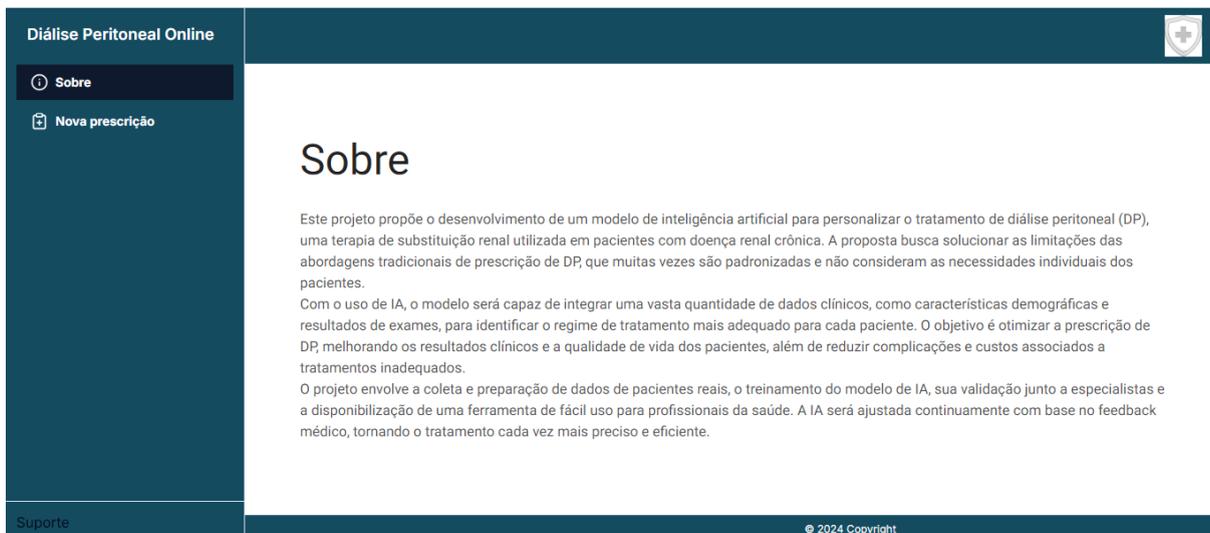
**pages/:** Contém as páginas do aplicativo, com roteamento automático baseado na estrutura de pastas.

**components/:** Armazena componentes reutilizáveis, como formulários e botões.

**api/:** Define as rotas de API para comunicação com o back-end.

Abaixo está descrito o fluxo de telas do aplicativo de DP, desenvolvido para auxiliar profissionais de saúde no monitoramento e gestão de dados relacionados ao tratamento. O site está disponível no endereço: <https://dialise-peritoneal.vercel.app/>

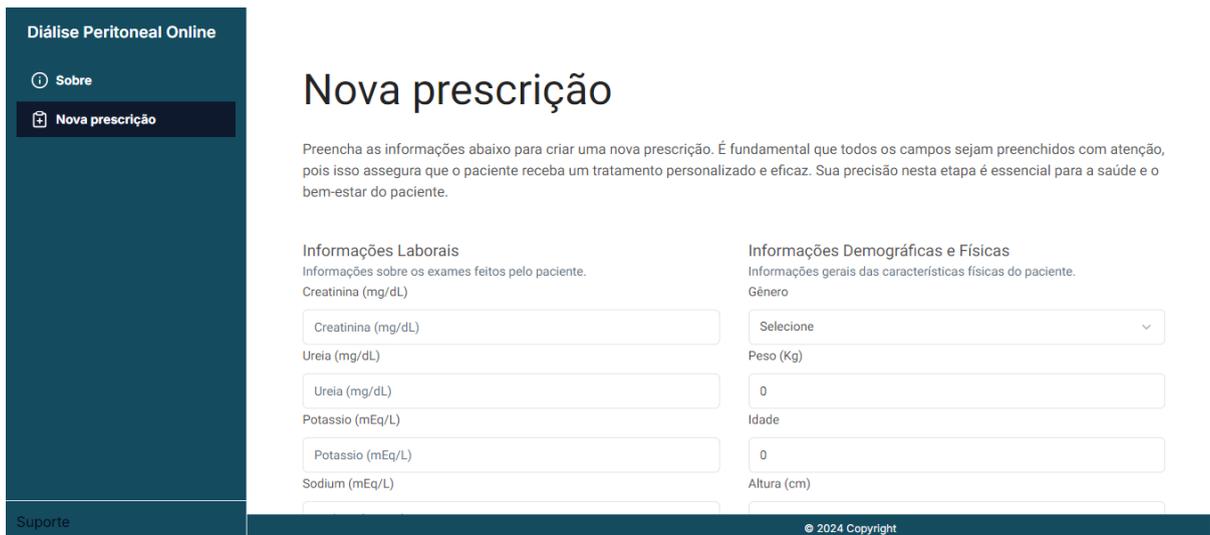
Figura 5 - Tela Principal



Fonte: elaborado pelos autores (2024)

A tela inicial, é a tela principal. Nessa tela, consta uma seção “Sobre”, onde está descrito um resumo das informações principais do projeto e links rápidos para navegar para outras seções do aplicativo. Aqui, são exibidos dados como resumo e objetivo do *site*.

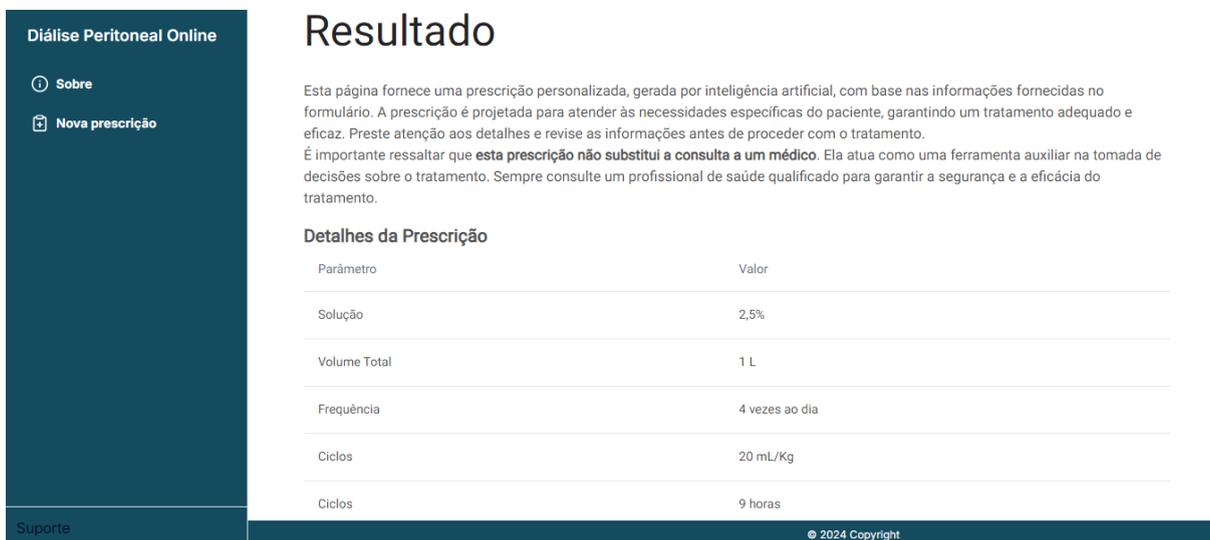
Figura 6 - Tela de Dados Clínicos



Fonte: elaborado pelos autores (2024)

Nesta tela, o usuário pode visualizar e registrar informações clínicas relevantes para o tratamento de DP. Esses dados podem incluir resultados de exames, peso, pressão arterial, entre outros indicadores importantes para o acompanhamento do estado de saúde do paciente.

Figura 7 - Tela de Resultados



Fonte: elaborado pelos autores (2024)

Essas telas e suas funcionalidades formam o núcleo do fluxo de navegação do aplicativo, cujo intuito é proporcionar uma interface organizada e intuitiva para o médico que desejar utilizar o modelo.

#### 4.5.4 COMPARAÇÃO COM OUTRAS TECNOLOGIAS

A escolha de React.js e Next.js para o desenvolvimento do sistema de prescrição personalizada de DP foi fundamentada em uma análise criteriosa das alternativas disponíveis no mercado. Tecnologias como Angular, Vue.js e até mesmo frameworks mais recentes foram consideradas, mas o conjunto de funcionalidades oferecido por React.js e Next.js provou ser o mais adequado para os requisitos do projeto.

Uma das vantagens mais evidentes do React.js em relação a ferramentas como Angular é sua simplicidade e flexibilidade. Enquanto o Angular é um framework completo com uma abordagem mais opinativa, o React.js se posiciona como uma biblioteca focada exclusivamente no desenvolvimento de interfaces de usuário. Isso permitiu que a equipe tivesse maior liberdade para escolher outras ferramentas complementares, como bibliotecas para gerenciamento de estado e manipulação de dados, conforme a necessidade do projeto. Além disso, o React.js é conhecido por seu menor tempo de aprendizado, o que foi um ponto crítico para um projeto com prazos apertados.

O Vue.js, por outro lado, também é amplamente elogiado por sua simplicidade e facilidade de uso. No entanto, uma limitação identificada foi sua menor adoção no mercado corporativo em comparação ao React.js. Por ser um projeto que demanda escalabilidade e manutenção no longo prazo, a escolha de React.js garantiu acesso a uma comunidade maior, mais madura e com maior disponibilidade de recursos e bibliotecas. A robustez da comunidade do React também se traduz em atualizações constantes e suporte a tecnologias de ponta, como renderização reativa e integração com back-ends modernos.

Quando analisado em conjunto com o Next.js, o React.js se diferencia ainda mais das alternativas. O Next.js adiciona capacidades avançadas que tornam o desenvolvimento de aplicações otimizadas significativamente mais eficiente. A renderização no servidor (*Server Side Rendering* ou SSR), uma funcionalidade nativa do Next.js, oferece uma vantagem considerável sobre frameworks concorrentes. Embora Angular e Vue.js também permitam SSR, a configuração nesses frameworks pode ser complexa e menos intuitiva. No Next.js, a integração é

nativa e pode ser implementada com apenas algumas alterações na estrutura do código, o que reduz o tempo de desenvolvimento e aumenta a eficiência.

Outro fator decisivo foi o suporte nativo do Next.js à geração de páginas estáticas (SSG). Diferentemente do Angular e Vue.js, onde a geração de páginas estáticas requer bibliotecas externas ou configurações adicionais, o Next.js permite criar e servir páginas estáticas diretamente. Essa funcionalidade foi crucial para implementar páginas que não demandam atualizações frequentes, como a seção "Sobre o Projeto", garantindo carregamento quase instantâneo e menor consumo de recursos do servidor.

A modularidade do Next.js também simplifica o roteamento e a estruturação do projeto. Enquanto frameworks como Angular utilizam configurações extensas de roteamento baseadas em arquivos de configuração centralizados, o Next.js permite que o roteamento seja gerado automaticamente com base na estrutura de diretórios. Isso resultou em um desenvolvimento mais ágil e na redução de erros relacionados a configurações manuais.

Por fim, a integração com APIs também foi um ponto de destaque. Embora tecnologias concorrentes ofereçam formas robustas de comunicação com back-ends, o Next.js possibilitou a criação de rotas de API no próprio projeto, eliminando a necessidade de um servidor dedicado exclusivamente para esse propósito. Essa característica foi essencial para simplificar o fluxo de dados entre o front-end e o banco de dados, aumentando a segurança e reduzindo a complexidade geral do sistema.

Ao comparar React.js e Next.js com alternativas como Angular e Vue.js, é evidente que a combinação escolhida oferece maior flexibilidade, desempenho e suporte à evolução do sistema. Esses fatores foram decisivos para atender às demandas técnicas e operacionais do projeto de prescrição personalizada de DP.

#### **4.5.5 CONSIDERAÇÕES**

Durante o desenvolvimento, enfrentamos desafios relacionados à segurança dos dados e ao desempenho do sistema. Além disso, a otimização dos componentes e a

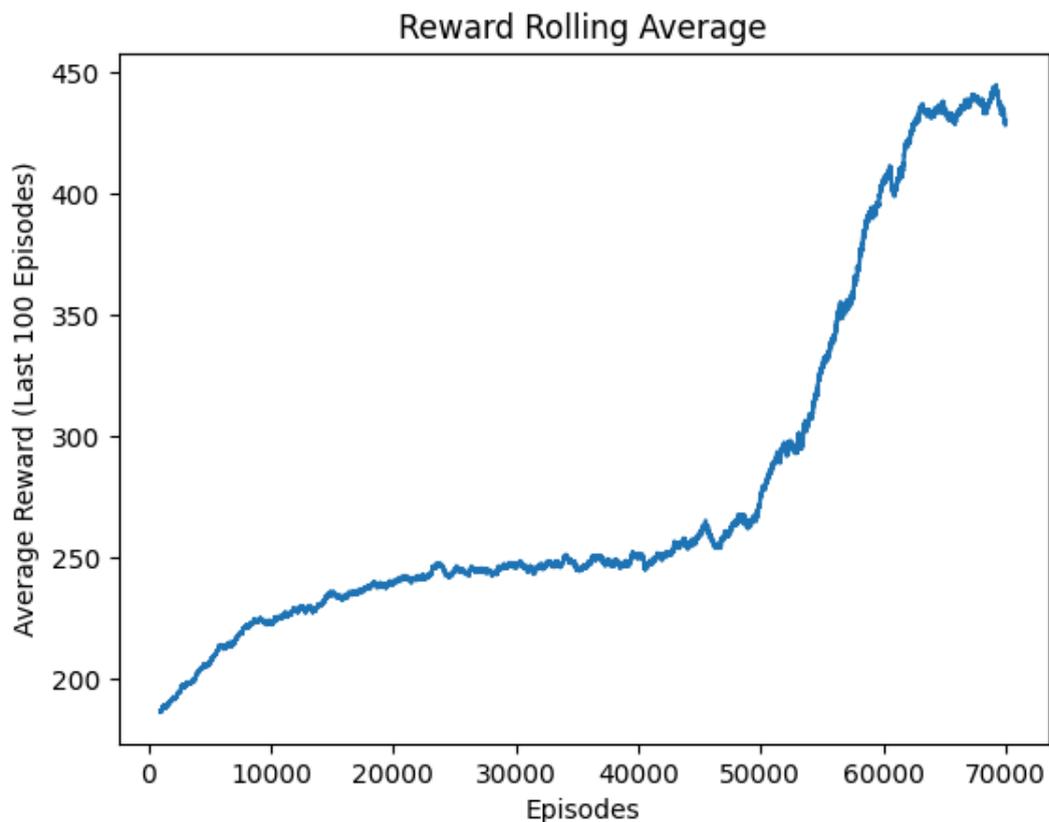
utilização do *Document Object Model* (DOM) virtual ajudaram a melhorar a performance da aplicação.

A implementação de React.js e Next.js no projeto de prescrição de DP mostrou-se altamente eficaz. Essas tecnologias não apenas atenderam às necessidades funcionais, mas também proporcionaram uma base robusta para futuras expansões do sistema.

## 5. RESULTADOS

Os resultados obtidos a partir do treinamento do modelo de AR indicam um desempenho satisfatório na personalização da prescrição de DP, atendendo às necessidades individuais dos pacientes. Durante o treinamento, observou-se um aumento consistente na média das recompensas acumuladas por episódio, conforme evidenciado pela figura 8. A recompensa média dos últimos 100 episódios ultrapassou o 400 de um máximo teórico de 500, demonstrando a capacidade do modelo de ajustar suas decisões com base nas características clínicas de cada paciente. Esse comportamento reflete uma convergência estável do modelo para uma política de decisão otimizada, alcançada após um número significativo de interações com o ambiente de treinamento.

Figura 8 - Média móvel das recompensas obtidas pelo modelo

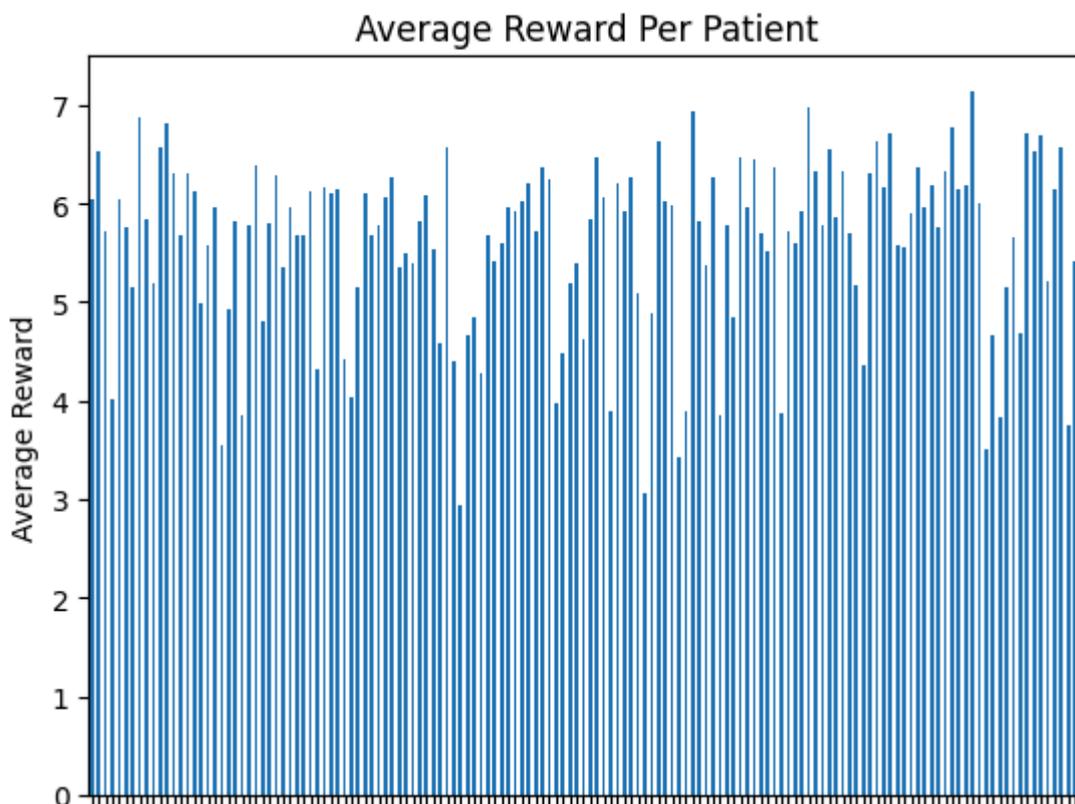


Fonte: elaborado pelos autores (2024)

A análise da recompensa média por paciente mostrou uma distribuição uniforme, com a maioria dos pacientes recebendo valores médios superiores a 5 (com um

máximo de 10). Isso indica que o modelo foi capaz de personalizar as prescrições de maneira eficaz, adaptando parâmetros como volume total da solução, frequência de ciclos e duração das sessões às condições específicas de cada paciente. A variação moderada nos resultados reflete as diferenças nas condições clínicas individuais, o que reforça a relevância do uso de técnicas baseadas em IA para capturar nuances fisiológicas e demográficas.

Figura 9 - Média de recompensas por paciente



Fonte: elaborado pelos autores (2024)

O processo de tratamento e pré-processamento dos dados foi essencial para garantir a qualidade do treinamento. Técnicas como *forward filling* foram aplicadas para lidar com dados ausentes, resultando em um conjunto de dados adequado para o aprendizado do modelo. A discretização dos parâmetros clínicos foi fundamental para reduzir a complexidade computacional e acelerar o aprendizado, permitindo ao modelo identificar padrões de prescrição com maior eficiência.

Ao final do treinamento, as prescrições geradas pelo modelo foram comparadas com diretrizes clínicas estabelecidas e validadas por especialistas na área. A

concordância observada entre as recomendações do modelo e as práticas clínicas reforça a viabilidade da solução proposta em um cenário real. Apesar do sucesso, desafios como a limitação do conjunto de dados e a necessidade de validação em tempo real com pacientes reais ainda representam barreiras importantes a serem superadas. Adicionalmente, futuros aprimoramentos no modelo poderão incluir a incorporação de dados complementares, como biomarcadores mais específicos e informações comportamentais dos pacientes, para aumentar ainda mais a precisão e a eficácia das prescrições.

## 5.1 TESTES E VALIDAÇÕES

Com o objetivo de testar o modelo treinado com dados reais, foi aplicado um slicing de 80/20 do conjunto total de dados para verificar suas prescrições com as feitas por médicos nefrologistas. Em razão dos limites computacionais enfrentados pela representação de estados e ações, o modelo foi capaz de realizar adequações e prescrições iniciais minimamente adequadas à realidade dos pacientes. Na tabela 7, é possível perceber um bom nível de proximidade com o tratamento verdadeiro, contudo, isso também se deve ao fato do paciente possuir um histórico de exames e prescrições grandes (maior que um ano).

Tabela 7 - Exemplo de prescrição fornecida por um médico e pelo modelo ao longo do tempo para um mesmo paciente

date	Volume	Cycles	Duration	Calcium	Potassium	Glucose	Insulin	Action
2016-05-03	1500	4	10	2,5	0	1,5	36	[1600.0, 7.0, 11.0, 2.5, 0, 3.0, 0]
2017-10-24	1500	5	12	2,5	0	2	36	[1600.0, 4.0, 10.0, 2.5, 0, 2.0, 0]

Fonte: elaborado pelos Autores (2024)

Dadas as restrições às saídas do modelo causadas pela discretização dos dados, o modelo foi capaz de se aproximar numericamente de prescrições reais com uma precisão considerável para casos mais comuns e com quantidades mais altas de *data points*. Ao realizar essa análise, é importante lembrar os intervalos possíveis para cada parâmetro do tratamento que foram definidos no item 4.3.5.

Contudo, apesar de identificar os padrões presentes nas primeiras prescrições e ser capaz de adequar o tratamento ao longo do tempo, o modelo encontrou dificuldade

para estabelecer bons critérios de prescrição nos primeiros meses de ajustes do tratamento, conforme é mostrado na tabela 8.

Tabela 8 - Exemplo de prescrição fornecida por um médico e pelo modelo, mas com menor quantidade de *data points*

date	Volume	Cycles	Duration	Calcium	Potassiu m	Glucose	Insulin	Action
2020-09-25	2000	5	10	3,5	0	2,5	0	[1600.0, 9.0, 11.0, 2.5, 0, 1.25, 0]
2021-01-25	2000	5	10	3,5	0	2,5	0	[1600.0, 9.0, 11.0, 2.5, 0, 1.25, 0]

Fonte: elaborado pelos (2024)

Para casos com menor quantidade de exames ao longo do tempo, o modelo não foi capaz de se aproximar da prescrição real, mantendo uma prescrição mais padronizada e menos adequada às características do paciente em questão, o que é perceptível ao comparar a quantidade de ciclos da prescrição e a glicose da prescrição real com a gerada.

Esses resultados destacam o potencial da IA na personalização de tratamentos médicos, demonstrando que o uso de AR pode otimizar parâmetros terapêuticos, reduzir complicações e melhorar a qualidade de vida dos pacientes. A aplicação prática do modelo, após validação adicional, pode representar um avanço significativo no campo da nefrologia e no uso de tecnologias inteligentes na medicina personalizada.

## 6. CONCLUSÕES E TRABALHOS FUTUROS

Os resultados apresentados neste trabalho demonstram o potencial do uso de IA, especificamente do AR, para a personalização da prescrição de DP. O modelo desenvolvido foi capaz de ajustar parâmetros críticos de tratamento, como volume de solução, frequência de trocas e duração das sessões, levando em consideração as condições clínicas individuais dos pacientes.

A análise dos resultados revelou um aumento consistente na recompensa média ao longo do treinamento, indicando que o modelo aprendeu a otimizar suas decisões para melhorar os desfechos esperados. Além disso, a comparação entre as prescrições geradas pelo modelo e as diretrizes clínicas validadas por especialistas confirmou a viabilidade da abordagem em cenários reais.

A utilização de técnicas robustas de pré-processamento e integração de dados foi fundamental para garantir a qualidade do treinamento, assegurando a completude e a consistência necessárias para o aprendizado do modelo. Contudo, é importante ressaltar que o conjunto de dados utilizado, embora suficiente para os experimentos realizados, apresenta limitações em termos de abrangência e diversidade, o que pode impactar a generalização do modelo para populações clínicas mais amplas.

Ainda assim, entre as principais contribuições deste trabalho, destacam-se o desenvolvimento de um modelo funcional baseado em AR, a aplicação de técnicas de IA na área de nefrologia e a proposta de uma solução prática para otimizar a personalização da DP. Esses resultados representam um avanço significativo na utilização de tecnologias inteligentes para a medicina personalizada, com impacto potencial na melhoria da qualidade de vida dos pacientes e na redução de complicações associadas à terapia.

Para o desenvolvimento futuro, algumas direções promissoras foram identificadas. A primeira envolve a ampliação e diversificação do conjunto de dados, com a inclusão de informações provenientes de diferentes contextos, regiões e condições clínicas. Essa abordagem visa aumentar a diversidade e a robustez do modelo, permitindo a incorporação de novos parâmetros clínicos, como biomarcadores avançados e histórico de comorbidades, para melhorar ainda mais a personalização das prescrições. Outra linha de trabalho essencial é a utilização de modelos mais

robustos, como Redes Neurais Profundas baseadas em Deep Q-Networks (DQN). Esses modelos têm o potencial de capturar padrões mais complexos, lidando com estados e ações de alta dimensionalidade e oferecendo prescrições ainda mais precisas e adaptativas. Além disso, a substituição de valores discretizados por variáveis contínuas, tanto nas entradas quanto nas ações do modelo, pode aumentar a granularidade das decisões, permitindo ajustes mais finos e personalizados em parâmetros críticos, como concentração de solutos e volume de solução dialisante.

A validação clínica do modelo em ambientes reais será essencial para avaliar sua aplicabilidade prática e aceitação por médicos e pacientes. Essa etapa permitirá o refinamento contínuo do modelo com base em dados reais e feedback dos usuários. A integração do sistema com dispositivos de monitoramento remoto, como sensores de fluxo e pressão, representa outra direção promissora, possibilitando ajustes em tempo real das prescrições com base no estado clínico dinâmico dos pacientes. Além disso, a exploração de algoritmos mais avançados, como *Proximal Policy Optimization* (PPO) e *Advantage Actor-Critic* (A2C), pode trazer políticas de decisão ainda mais sofisticadas e otimizadas para ambientes complexos como este.

## 7. REFERÊNCIAS

- Nature Editorial Board. (2024) "Time to sound the alarm about the hidden epidemic of kidney disease". In: Springer Nature. v. 628, p. 7-8. 03/04/2024 <https://doi.org/10.1038/d41586-024-00961-5>
- Grassmann A, Gioberge S, Moeller S, et al. (2005) "ESRD patients in 2004: global overview of patient numbers, treatment modalities and associated trends". *Nephrology Dialysis Transplantation*, v. 20, i. 12, p. 2587–2593.
- Galli, E.G., Taietti, C. e Borghi, M. (2011) "Personalization of Automated Peritoneal Dialysis Treatment Using a Computer Modeling System", *Advances in Peritoneal Dialysis*, Vol. 27, 90–96, 2011.
- Milan Manani, S., Crepaldi, C., Giuliani, A., Virzì, G. M., Garzotto, F., Riello, C., ... & Ronco, C. (2018) "Remote monitoring of automated peritoneal dialysis improves personalization of dialytic prescription and patient's independence", In: *Blood Purification*, 46(2), 111-117.
- John, O., & Jha, V. (2019) "Remote patient management in peritoneal dialysis: an answer to an unmet clinical need". *Remote patient management in peritoneal dialysis*, 197, 99-112.
- American Journal of Kidney Diseases. (2006) "Clinical Practice Guidelines for Peritoneal Dialysis Adequacy", Volume 48, Suplemento 1, 98-129,
- Lindholm, B.; Krediet, R. T. (2009) "Peritoneal Dialysis: From Basic Concepts to Clinical Excellence". In: *Contributions to Nephrology*. Basel: Karger, vol. 163.
- Chakraborty, C.; Bhattacharya, M.; Pal, S.; Lee, S.-S. (2024) "From machine learning to deep learning: Advances of the recent data-driven paradigm shift in medicine and healthcare". *Current Research in Biotechnology*, v. 7. ISSN 2590-2628.
- Aragão Pereira, J.P. Franco Brandão, A.A. Bevilacqua, J.d.S. Côrrea-Giannella, M.L.C. (2022) "A Multi-Agent Approach Used to Predict Long-Term Glucose Oscillation in Individuals with Type 1 Diabetes". *Appl. Sci.* 2022, 12, 9641. <https://doi.org/10.3390/app12199641>
- M. Zhang, Y. Hu, and T. Wang. (2005) "Selection of peritoneal dialysis schemes

- based on multi-objective fuzzy pattern recognition". In: Sheng Wu Yi Xue Gong Cheng Xue Za Zhi, vol. 22, no. 2, pp. 335–338, 2005
- Alexandru Burlacu A., Adrian Iftene, Daniel Jugrin, Iolanda Valentina Popa, Paula Madalina Lupu, Cristiana Vlad, Adrian Covic. (2020) "Using Artificial Intelligence Resources in Dialysis and Kidney Transplant Patients: A Literature Review". In: BioMed Research International, Volume 2020, Article ID 9867872, disponível em <https://doi.org/10.1155/2020/9867872>
- NKUDIC, NIDDKD and NIH. (2024) "dialys.gif". In: National Kidney and Urologic Diseases Information Clearinghouse, National Institute of Diabetes and Digestive and Kidney Diseases, National Institutes of Health, USA - <http://kidney.niddk.nih.gov/kudiseases/pubs/yourkidneys/images/dialys.gif>, Public Domain, <https://commons.wikimedia.org/w/index.php?curid=1490875>, 2024
- Jameson, J.; Fauci, A. S.; Kasper, D. L.; Hauser, S. L.; Longo, D. L.; Loscalzo, J. (2018) "Acute Kidney Injury". In: Jameson, J.; Fauci, A. S.; Kasper, D. L.; Hauser, S. L.; Longo, D. L.; Loscalzo, J. (Eds.). Harrison's Principles of Internal Medicine. 20th ed. New York: McGraw-Hill Education, 2018. p. 2099-2111.
- Russell, J. S.; Norvig, P. (2010) "Artificial Intelligence A Modern Approach", Pearson Education, 3ª edição.
- Sutton, R. S.; Barto, A. G. (2018) "Reinforcement Learning, An Introduction", The MIT Press, 2ª edição.
- Auguste, B. L.; Bargman J. M. (2023) "Peritoneal Dialysis Prescription and Adequacy in Clinical Practice: Core Curriculum 2023", American Journal of Kidney Diseases Volume 81, Issue 1, Janeiro de 2023, p. 100-109.
- Python. (2024) Disponível em: <https://www.python.org/>. Acesso em: 30 set. 2024.
- NEXT.JS. Disponível em: <https://nextjs.org/>. Acesso em: 15 out. 2024.
- REACT.JS. Disponível em: <https://reactjs.org/>. Acesso em: 25 out. 2024.
- JUPYTER. Disponível em <https://jupyter.org/>. Acesso em: 01 dez. 2024
- GIT. Disponível em <https://github.com/>. Acesso em: 08 dez. 2024