

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
INSTITUTO DE COMPUTAÇÃO
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

DIEGO MATTOS MARINHO MALTA

ESCALAI: UM APLICATIVO PARA PREVISÃO DE TEMPO DE RECUPERAÇÃO
DE LESÕES EM ESCALADORES

RIO DE JANEIRO
2025

DIEGO MATTOS MARINHO MALTA

ESCALAI: UM APLICATIVO PARA PREVISÃO DE TEMPO DE RECUPERAÇÃO
DE LESÕES EM ESCALADORES

Trabalho de conclusão de curso de graduação
apresentado ao Instituto de Ciência da Com-
putação da Universidade Federal do Rio de
Janeiro como parte dos requisitos para ob-
tenção do grau de Bacharel em Ciência da
Computação.

Orientador: Prof. DSc. Marcello Goulart Teixeira
Co-orientador: Prof. Jorge Junio Moreira Antunes

RIO DE JANEIRO

2025

CIP - Catalogação na Publicação

M261e Malta, Diego Mattos Marinho
EscalAI: um aplicativo para previsão de tempo de
recuperação de lesões em escaladores / Diego Mattos
Marinho Malta. -- Rio de Janeiro, 2025.
62 f.

Orientador: Marcello Goulart Teixeira.
Coorientador: Jorge Junio Moreira Antunes.
Trabalho de conclusão de curso (graduação) -
Universidade Federal do Rio de Janeiro, Instituto
de Computação, Bacharel em Ciência da Computação,
2025.

1. inteligência artificial. 2. escalada. 3.
previsão de lesões. 4. aplicativo. 5. análise de
decisão multi-critério. I. Teixeira, Marcello
Goulart, orient. II. Antunes, Jorge Junio Moreira,
coorient. III. Título.

DIEGO MATTOS MARINHO MALTA

ESCALAI: UM APLICATIVO PARA PREVISÃO DE TEMPO DE RECUPERAÇÃO
DE LESÕES EM ESCALADORES

Trabalho de conclusão de curso de graduação
apresentado ao Instituto de Ciência da Com-
putação da Universidade Federal do Rio de
Janeiro como parte dos requisitos para ob-
tenção do grau de Bacharel em Ciência da
Computação.

Aprovado em 09 de dezembro de 2025

BANCA EXAMINADORA:

Documento assinado digitalmente
 **MARCELLO GOULART TEIXEIRA**
Data: 10/03/2026 18:05:57-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Marcello Goulart Teixeira
DSc. (UFRJ)

Documento assinado digitalmente
 **JORGE JUNIO MOREIRA ANTUNES**
Data: 07/03/2026 14:42:03-0300
Verifique em <https://validar.iti.gov.br>

Prof. Jorge Junio Moreira Antunes
BSc. (UFRJ)

Documento assinado digitalmente
 **JULIANA BAPTISTA DOS SANTOS FRANCA**
Data: 03/03/2026 15:54:51-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Juliana Baptista dos Santos
França
DSc. (UFRJ)

Documento assinado digitalmente
 **SILVANA ROSSETTO**
Data: 02/03/2026 21:51:01-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Silvana Rossetto
DSc. (UFRJ)

AGRADECIMENTOS

Agradeço aos meus familiares por me proporcionarem a oportunidade de trilhar esta caminhada e me apoiarem ao longo dela. À minha namorada, por todo apoio e companhia em todos os momentos.

Aos meus orientadores, pela confiança, pela orientação dedicada e pelas contribuições essenciais para o desenvolvimento deste trabalho.

Aos meus amigos e colegas do curso de Ciência da Computação, que proporcionaram inúmeros momentos de aprendizado, descontração e parceria durante toda a minha jornada.

RESUMO

Este trabalho apresenta o desenvolvimento do EscalAI, um aplicativo para dispositivos Android voltado à previsão do tempo de recuperação de lesões em praticantes de escalada. A motivação surge da elevada incidência de lesões nesse esporte e da baixa procura por atendimento médico pelos atletas, o que pode prolongar o tempo de afastamento e comprometer o desempenho. O sistema foi construído com arquitetura MVVM em Java no frontend e servidor em Python com FastAPI, integrando banco de dados PostgreSQL para armazenamento seguro das informações de usuários. Entre as funcionalidades do aplicativo, destacam-se o registro de hidratação, humor, dor, sono, treinos e lesões, além da geração de relatórios. A etapa de inteligência artificial utilizou dados da literatura especializada para treinar modelos de aprendizado de máquina, em especial o XGBoost, aplicando técnicas de pré-processamento, normalização e cálculo do índice de engajamento pelo método TOPSIS. Os resultados do modelo preditivo indicaram desempenho satisfatório, com MAE de 0,858 e RMSE de 1,382 mês, considerados adequados para estimativas em saúde esportiva. Adicionalmente, foi implementada regressão por quantis com conformalização para gerar intervalos de confiança de 80%, fornecendo previsões mais transparentes ao usuário. Conclui-se que o EscalAI representa uma ferramenta inovadora para apoiar escaladores na gestão de sua saúde, auxiliando na prevenção de lesões, no acompanhamento da recuperação e na conscientização da importância do atendimento médico. Como trabalhos futuros, sugere-se ampliar a base de dados com informações coletadas por usuários reais, integrar dispositivos IoT e incluir novas funcionalidades de acompanhamento por profissionais de saúde.

Palavras-chave: inteligência artificial; escalada; previsão de lesões; aplicativo; análise de decisão multi-critério.

ABSTRACT

This work presents the development of EscalAI, an Android application designed to predict the recovery time from injuries in climbing practitioners. The motivation stems from the high incidence of injuries in this sport and the low demand for medical care by athletes, which can prolong recovery periods and compromise performance. The system was built using an MVVM architecture in Java for the frontend and a Python FastAPI server, integrating a PostgreSQL database to securely store user information. Key features of the application include tracking hydration, mood, pain, sleep, training sessions, and injuries, as well as generating reports. The artificial intelligence module was trained on data from specialized literature to build machine learning models, particularly XGBoost, applying preprocessing, normalization, and calculating an engagement index using the TOPSIS method. The predictive model achieved satisfactory performance, with a MAE of 0.858 months and an RMSE of 1.382 months, considered suitable for health-related estimates. In addition, quantile regression with conformalization was implemented to produce 80% confidence intervals, providing more transparent predictions to users. EscalAI thus represents an innovative tool to support climbers in managing their health by assisting in injury prevention, recovery monitoring, and raising awareness about the importance of medical care. Future work includes expanding the dataset with information collected from real users, integrating IoT devices, and adding new features for monitoring by healthcare professionals. current use.

Keywords: artificial intelligence; climbing; injury prediction; application; multi-criteria decision analysis.

LISTA DE ILUSTRAÇÕES

Figura 1 – Esboço inicial da tela principal e requisitos das funcionalidades	13
Figura 2 – Detalhamento dos requisitos das funcionalidades	14
Figura 3 – Tela do menu principal	15
Figura 4 – Tela de monitoramento de hidratação	16
Figura 5 – Tela de monitoramento de humor	17
Figura 6 – Tela de registro de dor	18
Figura 7 – Tela de registro de sono	19
Figura 8 – Tela de seleção da área da lesão	20
Figura 9 – Tela de seleção da área da lesão	21
Figura 10 – Tela de seleção da área da lesão	22
Figura 11 – Tela de predição do tempo de recuperação	23
Figura 12 – Tela de relatórios: Água e Sono	24
Figura 13 – Tela de cadastro do aplicativo	26
Figura 14 – Tela de login do aplicativo	27
Figura 15 – Diagrama Entidade-Relacionamento do banco de dados	33

LISTA DE TABELAS

Tabela 1 – Hierarquia das áreas corporais monitoradas	52
Tabela 2 – Descrição das variáveis do conjunto de dados de treino	55
Tabela 3 – Distribuição das variáveis booleanas no conjunto de dados de treino . .	56

SUMÁRIO

1	INTRODUÇÃO	10
2	FUNCIONALIDADES	13
2.1	LEVANTAMENTO DE REQUISITOS	13
2.2	HIDRATAÇÃO	14
2.3	EMOCIONAL	15
2.4	DORES	16
2.5	REGISTRO DE SONO	17
2.6	TREINOS	18
2.7	LESÕES	18
2.7.1	Área da Lesão	19
2.7.2	Dados do Usuário e da Escalada	19
2.7.3	Informações Específicas da Lesão	20
2.7.4	Predição do Tempo de Recuperação	20
2.8	NOTIFICAÇÕES E LEMBRETES	20
2.9	RELATÓRIOS	22
2.10	DISPONIBILIZAÇÃO DO CÓDIGO-FONTE	23
3	AUTENTICAÇÃO	25
3.1	CADASTRO	25
3.2	LOGIN	25
4	DESENVOLVIMENTO DA APLICAÇÃO	28
4.1	FRONTEND	28
4.1.1	XML e MDC Android	28
4.1.2	Biblioteca Data Binding	29
4.1.3	Java	29
4.1.4	Justificativa da Escolha de Java para Android	29
4.2	BANCO DE DADOS DO SERVIDOR	30
4.2.1	Estimativa de Escalabilidade e Escolha do PostgreSQL	30
4.2.2	Comparação com Alternativas de Banco de Dados	31
4.3	BACKENDS	34
4.3.1	Servidor Python	34
4.3.2	Comparação com Frameworks Web Alternativos	34
5	TREINAMENTO DA INTELIGÊNCIA ARTIFICIAL	36

5.1	INTRODUÇÃO AO TREINAMENTO DA INTELIGÊNCIA ARTIFICIAL	36
5.2	CÁLCULO DO ÍNDICE DE ENGAJAMENTO (TOPSIS)	36
5.3	MODELO XGBOOST	37
5.3.1	Fundamentação do XGBoost	37
5.3.2	Parâmetros do XGBoost	38
5.3.3	Divisão dos Dados e Estratégia de Validação	39
5.3.3.1	métricas de avaliação	40
5.3.4	Pós-processamento e Discretização	40
5.3.5	Adequação do XGBoost ao Problema de Previsão de Lesões .	41
5.3.6	Confiança e Intervalos de Predição	41
5.3.6.1	método jackknife+ e cálculo de resíduos out-of-fold	42
5.3.6.2	conformalização dos intervalos	42
5.3.6.3	garantias teóricas de cobertura	43
5.3.6.4	justificativa da divisão dos dados	43
5.4	DADOS DO TREINO	44
5.5	PROCESSAMENTO DOS DADOS	45
5.5.1	Resultados do Modelo	46
5.5.1.1	validação cruzada e métricas out-of-fold	46
5.5.1.2	desempenho no conjunto de teste	46
5.5.1.3	intervalos de confiança e cobertura	47
6	CONCLUSÃO	49
	REFERÊNCIAS	50
	APÊNDICE A – HIERARQUIA DAS ÁREAS CORPORAIS MONITORADAS	52
	APÊNDICE B – DADOS ARMAZENADOS PARA TREINO DA INTELIGÊNCIA ARTIFICIAL	55
	APÊNDICE C – VARIÁVEIS BOOLEANAS DO CONJUNTO DE DADOS DE TREINO	56
	APÊNDICE D – TERMOS E CONDIÇÕES DE USO DO APLICATIVO	58

1 INTRODUÇÃO

A escalada é uma atividade física e esporte derivada do montanhismo que pode ser praticada tanto em rochas quanto em paredes artificiais, normalmente com a finalidade de concluir um trajeto demarcado até o pico do objeto escalado. É necessária coordenação, flexibilidade, resistência, equilíbrio e força para praticar, resultando numa grande dificuldade técnica (PEREIRA; NISTA-PICCOLO, 2010). A prática possui benefícios como várias outras atividades físicas. Porém, como todo esporte, lesões podem ocorrer ao ser praticado. As mais comuns são lesões nos dedos, ombros, calcanhares e cotovelos devido à força exercida para continuar segurando o peso do próprio corpo na parede (GERDES; HAFNER; ALDAG, 2006).

Além disso, conforme SALIBA (2021), a experiência dos praticantes de escalada pode influenciar a decisão de buscar assistência médica após uma lesão. Apesar da alta prevalência de lesões entre escaladores, muitos praticantes não buscam atendimento médico, o que pode ser um reflexo da cultura do esporte que valoriza a resistência e a superação da dor. A pesquisa realizada pela autora envolveu 913 escaladores brasileiros e revelou que 73,25% dos participantes relataram ter sofrido alguma lesão relacionada à prática da escalada. Além disso, a dissertação aponta que a falta de busca por tratamento pode estar relacionada à experiência do escalador, sugerindo que aqueles com maior tempo de prática tendem a subestimar a gravidade das lesões. Essa situação denota a necessidade de intervenções educativas que promovam a conscientização sobre a importância de buscar assistência médica, independentemente do nível de experiência, para evitar complicações e garantir a saúde dos praticantes a longo prazo.

Também nesse sentido, mesmo com lesões sendo comuns no meio dessa prática esportiva, poucos são os praticantes que procuram ajuda médica, segundo a pesquisa de GRØNHAUG e SAETERBAKKEN (2019, tradução nossa):

Ao avaliar contribuições adicionais de gênero e nível de experiência, percebe-se que a experiência é um forte preditor para não procurar atendimento médico após uma lesão. Esses achados indicam a possibilidade de que alguns daqueles que não buscam assistência médica após auto-avaliarem a lesão estejam subestimando a gravidade da lesão devido à falta de confiança nas habilidades dos profissionais de saúde.¹

Com o objetivo de auxiliar na diminuição de ocorrências e gravidade de lesões, além do acompanhamento do tratamento delas, foi desenvolvido o aplicativo EscalAI para aparelhos móveis de sistema Android. O desenvolvimento contou com o suporte de uma

¹ “When assessing further contributions of gender and level of experience, it seems that experience is a strong predictor for not seeking healthcare after an injury. These findings open up the possibility that some of those who do not seek healthcare after self-assessing the injury are underestimating the seriousness of the injury due to lack of confidence in the health professionals’ abilities.”(GRØNHAUG; SAETERBAKKEN, 2019, p. 6).

fisioterapeuta especializada em lesões esportivas, garantindo que as funcionalidades implementadas estivessem alinhadas com práticas clínicas estabelecidas e necessidades reais dos praticantes. O aplicativo oferece funcionalidades principais de monitoramento de hidratação com metas personalizadas, registro de humor emocional baseado em escala validada, avaliação de dor utilizando a Escala Visual Analógica (EVA) com classificação anatômica UIAA, controle de sono com avaliação de qualidade e duração, registro detalhado de treinos por modalidade, cadastro completo de lesões e geração de relatórios visuais para acompanhamento longitudinal. Adicionalmente, o sistema implementa notificações diárias e alarmes configuráveis para estimular a consistência no registro de dados.

O sistema utiliza um modelo de inteligência artificial baseado no algoritmo XGBoost, treinado previamente no servidor utilizando dados do estudo de SALIBA (2021). Este conjunto de dados inclui informações demográficas (idade, massa corporal, altura), frequência de prática de cada modalidade de escalada e histórico detalhado de lesões (localização anatômica, tipo de atendimento médico, diagnóstico, modalidade praticada durante o lesionamento, recidiva e tempo de afastamento para recuperação). O modelo é armazenado e executado no servidor, não ocupando recursos do dispositivo móvel do usuário, e realiza previsões em tempo real sobre o tempo de afastamento da atividade física em decorrência de lesões sofridas durante escaladas. O sistema também incorpora um índice de engajamento esportivo calculado via método TOPSIS e fornece intervalos de confiança através de predição conformalizada (método Jackknife+), quantificando a incerteza associada a cada estimativa. O custo computacional do retreinamento do modelo foi projetado para ser baixo, permitindo atualizações periódicas conforme novos dados de usuários sejam coletados, sem comprometer a disponibilidade do sistema. As novas informações inseridas pelos usuários no banco de dados serão utilizadas para retreinamento manual supervisionado da inteligência artificial, fornecendo uma coletânea crescente de dados para aprimorar continuamente a precisão das previsões.

Essa alternativa permitirá soluções mais personalizadas, podendo auxiliar no acompanhamento de outros profissionais da saúde, como fisioterapeutas, ortopedistas e outros especialistas da área. O aplicativo não servirá como substituto ao atendimento médico, inclusive, sempre chamará a atenção para este fato, mas sim para prestar apoio aos escaladores que utilizam o sistema e aumentar a procura por profissionais de saúde quando ocorrer alguma lesão.

No Capítulo 2, serão discutidas as funcionalidades implementadas no aplicativo. Em seguida, o Capítulo 3 apresenta os métodos de autenticação implementados e os métodos de segurança para garantir a integridade, confidencialidade e autenticidade das informações armazenadas e fornecidas aos usuários. Já no Capítulo 4, serão detalhadas as tecnologias escolhidas e seus objetivos no sistema, abordando práticas utilizadas no desenvolvimento como a arquitetura MVVM e orientação a objetos do aplicativo e o servidor


para conexões do aplicativo. O Capítulo 5 apresenta a análise e processamento dos dados e o treino da inteligência artificial da previsão do tempo de recuperação. Por fim, no Capítulo 6, é apresentada uma conclusão acerca de todo o trabalho desenvolvido e seus resultados.

2 FUNCIONALIDADES

2.1 LEVANTAMENTO DE REQUISITOS

O desenvolvimento do aplicativo EscalAI foi conduzido a partir de uma análise sistemática de requisitos e necessidades identificadas junto a praticantes de escalada e profissionais de saúde especializados em lesões esportivas. Foi realizada uma pesquisa sobre aplicativos existentes de registro e acompanhamento de dor com funcionalidade de localização anatômica, visando compreender as melhores práticas de interface e usabilidade para esta categoria de funcionalidade. A partir desta pesquisa inicial, foi elaborada uma lista detalhada de requisitos funcionais e não-funcionais que nortearam todo o processo de desenvolvimento, garantindo que as funcionalidades implementadas atendessem efetivamente às necessidades dos usuários finais. A Figura 1 apresenta o esboço inicial da interface e os requisitos das funcionalidades elaborados durante a fase de planejamento do projeto.


Figura 1 – Esboço inicial da tela principal e requisitos das funcionalidades



Fonte: Elaborado pelo autor (2024)

A Figura 2 detalha os requisitos específicos das funcionalidades de água, estresse, sono, dor, treino e relatórios. Estes documentos foram produzidos manualmente e serviram como base para discussões com profissionais de saúde e potenciais usuários, validando a pertinência e usabilidade das funcionalidades propostas. A abordagem metodológica adotada assegurou que o aplicativo fosse construído com foco nas demandas reais dos escaladores, incorporando feedback de fisioterapeutas durante as fases de prototipação e desenvolvimento.

Figura 2 – Detalhamento dos requisitos das funcionalidades



Fonte: Elaborado pelo autor (2024)

A tela principal do aplicativo, mostrada na Figura 3, chamada de *home*, apresenta as funcionalidades principais destacadas em forma de cards: monitoramento de hidratação, registro de humor, avaliação de dor, controle de sono, registro de treinos e acompanhamento de peso. Além destas funcionalidades primárias, o aplicativo oferece seções secundárias para visualização de relatórios, acesso a vídeos instrutivos e consulta ao histórico de registros. Cada componente da interface direciona o usuário para telas específicas com funções designadas, conforme será detalhado nas seções seguintes.

Na parte superior da tela há o nome do usuário, seu ícone de perfil e um menu expansível flutuante de opções no canto superior direito representado por um ícone de três pontos, contendo opções de encerrar a sessão do usuário, acessar as configurações do aplicativo e uma opção “sobre”, onde é possível saber mais sobre o aplicativo, pessoas responsáveis e propósito acerca do desenvolvimento do projeto.

2.2 HIDRATAÇÃO

A hidratação adequada representa um fator crítico para a saúde geral e para o desempenho esportivo, segundo Armstrong e Johnson (2018). A funcionalidade de monitoramento

Figura 3 – Tela do menu principal



Fonte: Elaborado pelo autor (2025)

de hidratação, representada na Figura 4, permite ao usuário registrar o volume de água consumido durante o dia, em mililitros, com opções para adicionar novos consumos ou reiniciar o contador, caso seja necessária a correção dos valores registrados.

O cálculo da quantidade recomendada de ingestão hídrica é personalizado conforme a massa corporal fornecida pelo usuário, aplicando-se a proporção de 0,04 litros por quilograma de peso corporal como recomendação. Esta abordagem individualizada visa estabelecer metas realistas de consumo hídrico, considerando as características biométricas específicas de cada praticante. A interface visual apresenta o progresso diário do usuário em direção à meta estabelecida.

2.3 EMOCIONAL

O humor será analisado para armazenar o estresse e a ansiedade do indivíduo, o que pode influenciar dores físicas. Assim, são armazenados dados do humor do usuário, medindo sua alegria, tristeza, ansiedade, estresse e calma, como na Figura 5, de acordo com sua própria percepção, para que possa auxiliar no acompanhamento da relação entre humor e dor física.

Figura 4 – Tela de monitoramento de hidratação



Fonte: Elaborado pelo autor (2025)

A mensuração foi realizada por meio de uma escala de 4 pontos (Discordo totalmente, Discordo parcialmente, Concordo parcialmente, Concordo totalmente). Essa escala foi selecionada pela sua simplicidade e eficácia na captação de estados emocionais subjetivos, permitindo identificar variações de humor relevantes ao longo do tempo.

2.4 DORES

A intensidade da dor é mensurada através de uma escala numérica de 1 a 10, baseada na Escala Visual Analógica (EVA), instrumento validado na literatura médica para quantificação subjetiva de dor (JENSEN; KAROLY; BRAVER, 1986). Esta abordagem padronizada permite ao usuário classificar sua percepção de dor de maneira consistente ao longo do tempo. Como na escala 0 representa que não há dor, o contador inicia do 1 na aplicação, com valor máximo de 10, conforme demonstrado na Figura 6.

O usuário pode armazenar suas dores filtrando nos campos: Área da dor, Membro da dor e “Especifique”, que no código são separados em Área Corporal N1, Área Corporal N2 e Área Corporal N3, com N representando a palavra nível. Esta divisão é baseada na Classificação Internacional de Lesões em Escalada da UIAA (UIAA, 2025), utilizada

Figura 5 – Tela de monitoramento de humor

A imagem mostra a interface de uma aplicação móvel intitulada "Humor". O título principal é "Como está seu humor?". Abaixo dele, há quatro perguntas com escalas de resposta de 5 pontos (Likert):

- Hoje me sinto/senti alegre**: A escala varia de "Discordo totalmente" a "Concordo totalmente". O cursor está posicionado no ponto "Discordo parcialmente".
- Hoje me sinto/senti triste**: A escala varia de "Discordo totalmente" a "Concordo totalmente". O cursor está posicionado no ponto "Concordo parcialmente".
- Hoje me sinto/senti ansioso(a)**: A escala varia de "Discordo totalmente" a "Concordo totalmente". O cursor está posicionado no ponto "Discordo parcialmente".
- Hoje me sinto/senti estressado(a)**: A escala varia de "Discordo totalmente" a "Concordo totalmente". O cursor está posicionado no ponto "Concordo totalmente".

Em cada escala, os pontos são rotulados como "Discordo totalmente", "Discordo parcialmente", "Concordo parcialmente" e "Concordo totalmente". No rodapé da tela, há um botão laranja com o texto "Salvar".

Fonte: Elaborado pelo autor (2025)

também na pesquisa “Prevalência de lesões musculoesqueléticas em escaladores” de SALIBA (2021). A função de filtragem de área após cada seleção foi inserida na aplicação para facilitar ao usuário indicar o local da dor com maior precisão.

As áreas do corpo separadas em seções e detalhadas encontram-se na **Tabela do Apêndice A**, contemplando todas as regiões anatômicas relevantes para a prática da escalada. A estruturação hierárquica facilita a entrada de informações pelo usuário e a posterior análise dos dados, permitindo identificar padrões de lesões específicos de determinadas modalidades e técnicas de escalada.

2.5 REGISTRO DE SONO

O sono adequado constitui um elemento fundamental na recuperação muscular e na prevenção de lesões esportivas. Conforme descrito por Milewski et al. (2014), atletas com privação crônica de sono apresentam risco significativamente elevado de desenvolver lesões musculoesqueléticas durante a prática esportiva. A funcionalidade de monitoramento do sono permite ao usuário registrar a duração e a qualidade subjetiva do período de repouso, demonstrado na Figura 7.

Para a avaliação subjetiva da qualidade do sono, foi empregada uma **escala Likert de 5 pontos**, conforme proposta de Likert (1932). Essa escala permite capturar percepções

Figura 6 – Tela de registro de dor

Avaliação de Dor

Como está sua dor hoje?

Área da dor
 Seleccione a área
 Cabeça e pescoço

Membro da dor
 Seleccione o membro
 Cabeça/face

Especifique:
 Seleccione
 Testa

Intensidade da Dor **5**

1 10

Salvar

Fonte: Elaborado pelo autor (2025)

graduais quanto à qualidade do descanso, permitindo análises longitudinais e mantendo consistência dos registros. É feito o questionamento ao usuário de "Minha qualidade de sono foi excelente", com as possibilidades de resposta sendo "discordo totalmente", "discordo parcialmente", "indiferente", "concordo parcialmente" e "concordo totalmente".

2.6 TREINOS

A escalada é subdividida em diversas modalidades com características técnicas distintas e padrões específicos de exigência física. Para melhor padronização de dados, serão utilizados seis tipos de atividades, sendo três delas as modalidades de escalada mais comuns no Brasil: Escalada Tradicional Brasileira, Escalada Boulder, Escalada Esportiva, Outras Modalidades de Escalada, Musculação e Outras Atividades Físicas, como mostrado na Figura 8, com a quantidade de tempo em horas sendo registrada.

2.7 LESÕES

O registro de lesões constitui uma funcionalidade central do aplicativo, desenvolvida com base nos dados coletados por SALIBA (2021) sobre a prevalência de lesões entre

Figura 7 – Tela de registro de sono



Fonte: Elaborado pelo autor (2025)

escaladores brasileiros. Esta funcionalidade permite o cadastro detalhado de informações sobre lesões relacionadas à prática da escalada, possibilitando a predição do tempo de recuperação através de algoritmos de inteligência artificial. As lesões registradas são listadas na tela de **Registros de Lesões**, ilustrada na Figura 9, permitindo editar uma lesão, concluí-la, prever o tempo ou registrar uma lesão.

Ao selecionar **Registrar nova lesão**, o usuário acessará a tela de **Registro de Lesão**, com diversos campos para preenchimento e detalhamento da lesão e características do usuário, como demonstrado na Figura 10.

2.7.1 Área da Lesão

A primeira seção concentra-se na localização anatômica da lesão por meio de um sistema hierárquico de classificação, ilustrado na Figura.

2.7.2 Dados do Usuário e da Escalada

A segunda seção coleta informações biométricas básicas do usuário, incluindo massa corporal (kg) e altura (cm), além do grau de escalada brasileiro praticado. A terceira

Figura 8 – Tela de seleção da área da lesão

Registro de Escalada e Treinos

Registre sua atividade física

Tipo de Atividade
Selecione o tipo de atividade

Duração da Atividade **1.0 horas**
0.5h 4h

Resumo de Atividades Hoje

Tipo de Atividade	Horas
Musculação	3.0h
Outras Modalidades de Escalada	2.5h
Escalada Tradicional Brasileira	2.5h
Escalada Boulder	3.0h

Registrar Atividade

Fonte: Elaborado pelo autor (2025)

seção aborda a experiência e frequência de prática do usuário.

2.7.3 Informações Específicas da Lesão

A quarta seção coleta dados específicos sobre o episódio da lesão atual, como se é reincidência, se houve busca por atendimento médico, tipo de profissional que atendeu, qual o diagnóstico e qual modalidade de escalada praticada durante o lesionamento.


2.7.4 Predição do Tempo de Recuperação

Após o registro completo das informações, o sistema utiliza algoritmos de inteligência artificial treinados com os dados para prever o tempo estimado de afastamento necessário para a recuperação completa da lesão, ilustrado na Figura 11.

2.8 NOTIFICAÇÕES E LEMBRETES

Para estimular o engajamento contínuo dos usuários com o aplicativo e garantir a consistência no registro de dados, o sistema implementa um mecanismo de notificações diárias. Este recurso foi desenvolvido com base na compreensão de que a coleta regular de

Figura 9 – Tela de seleção da área da lesão



Fonte: Elaborado pelo autor (2025)

métricas de saúde é fundamental para o funcionamento adequado dos algoritmos preditivos e para o acompanhamento efetivo da condição física do escalador.

O aplicativo envia notificações em dois momentos estratégicos do dia: pela manhã, incentivando o registro de dados relativos ao sono da noite anterior e estabelecendo metas para o dia; e pela noite, lembrando o usuário de registrar as atividades realizadas, consumo hídrico, níveis de dor e estado emocional. Esta abordagem dual visa capturar informações em momentos em que o usuário tem maior disponibilidade e consciência sobre suas condições físicas e emocionais.

Adicionalmente, o aplicativo oferece funcionalidade de alarmes configuráveis para consumo de água, permitindo que o usuário estabeleça intervalos personalizados para lembretes de hidratação. Esta funcionalidade reconhece que a manutenção de níveis adequados de hidratação ao longo do dia requer lembretes periódicos, especialmente durante períodos de atividade física intensa. O usuário pode ajustar a frequência e horários dos alarmes conforme suas necessidades individuais e rotina diária, promovendo assim a aderência às metas de hidratação estabelecidas.

Figura 10 – Tela de seleção da área da lesão

Fonte: Elaborado pelo autor (2025)

2.9 RELATÓRIOS

A funcionalidade de relatórios disponibiliza dados coletados ao longo de um determinado período, como gráficos ou tabelas, habilitando o usuário a acompanhar a evolução de hábitos e seus padrões para alterá-los ou mantê-los. A Figura 12 mostra a tela inicial dessa funcionalidade.

Esta funcionalidade serve como ferramenta de automonitoramento para os usuários, permitindo identificar correlações entre diferentes aspectos da saúde e facilitando discussões mais informadas com profissionais de saúde. O sistema gera automaticamente gráficos para quatro categorias principais de dados:

- **Consumo de Água:** Apresenta a evolução diária do consumo hídrico durante a semana, permitindo identificar padrões de hidratação e verificar se as metas estabelecidas estão sendo alcançadas consistentemente.
- **Duração do Sono:** Exibe o tempo total de sono registrado em cada dia, facilitando a identificação de irregularidades no padrão de descanso que podem impactar no

Figura 11 – Tela de predição do tempo de recuperação

A imagem mostra a interface de um aplicativo Android com o título "Registro de Lesão". A interface é organizada em seções:

- Informações sobre sua lesão:** Inclui um campo "Modalidade praticada durante a lesão" com uma lista suspensa selecionando "Musculação".
- Datas da Lesão:**
 - "Data de início da lesão": Campo com o formato DD/MM/AAAA, preenchido com "19/08/2025".
 - "Data de conclusão/recuperação (opcional)": Campo com o formato DD/MM/AAAA, atualmente vazio.
- Previsão de Tempo de Recuperação:**
 - Um botão laranja com o ícone de uma calculadora e o texto "Prever Tempo de Recuperação".
 - Um card de resultado com o título "Previsão de Tempo de Recuperação" que mostra:
 - Tempo estimado: **3.5 - 7 meses**
 - Tempo de afastamento moderado. Lesão de média gravidade. (Confiância: 80%)
 - Um botão laranja "Salvar" abaixo do card.
 - Um botão cinza "Concluir Lesão" na base da tela.

Fonte: Elaborado pelo autor (2025)


desempenho esportivo e na recuperação de lesões.

- **Tabela de Dores:** Mostra o início da dor, a duração e há quanto tempo está sem dor.
- **Duração de Treinos:** Mostra o tempo total dedicado às atividades de treinamento diariamente, calculado pela soma de todas as modalidades praticadas no dia. Esta visualização auxilia no monitoramento da carga de treinamento semanal.
- **Níveis de Humor:** Apresenta a variação dos cinco aspectos emocionais monitorados (alegria, tristeza, ansiedade, estresse e calma), permitindo correlacionar estados emocionais com outros fatores de saúde e desempenho.

2.10 DISPONIBILIZAÇÃO DO CÓDIGO-FONTE

O código-fonte completo do aplicativo Android e do servidor backend, incluindo os scripts de treinamento do modelo de inteligência artificial, foi disponibilizado publicamente para fins acadêmicos e de reprodutibilidade científica. Os repositórios estão hospedados na plataforma GitHub e podem ser acessados através dos endereços: <https://github.com/diegmalta/EscalAI> para o aplicativo e https://github.com/diegmalta/EscalAI_server_public para o servidor backend. Esta disponibilização segue as boas práticas de pesquisa

Figura 12 – Tela de relatórios: Água e Sono



Fonte: Elaborado pelo autor (2025)

científica em computação, permitindo que outros pesquisadores e desenvolvedores possam auditar, validar, reproduzir os resultados apresentados neste trabalho, ou mesmo estender as funcionalidades implementadas.

3 AUTENTICAÇÃO

A autenticação representa um componente fundamental para a segurança e integridade do sistema EscalAI, uma vez que o aplicativo manipula informações sensíveis de saúde e dados pessoais dos usuários. Este capítulo apresenta os mecanismos implementados para cadastro e login de usuários, detalhando as técnicas de criptografia e validação empregadas para garantir que apenas usuários autorizados possam acessar e modificar suas informações. O sistema adota práticas estabelecidas de segurança da informação, incluindo hash de senhas com algoritmos robustos e autenticação baseada em tokens, assegurando tanto a confidencialidade quanto a autenticidade das sessões de usuário.

3.1 CADASTRO

A tela de cadastro é acessada na tela inicial do aplicativo, em que está o Login, por meio de um botão. Na tela de cadastro estão disponíveis os campos Email, Nome, Sobrenome, Data de Nascimento, Celular, Senha, Confirmar Senha e concordar com os termos e condições de uso do aplicativo, como demonstrado na Figura 13. Os termos e condições de uso estão descritos no Apêndice D

Nesta etapa são feitas diferentes verificações: se o email possui o caractere “@” e um caractere “.” após ele, de forma a configurar um formato de email; se os textos inseridos em senha e confirmar senha são exatamente iguais entre si; se o usuário possui uma data de nascimento acima de 13 anos; e se todos estes campos estão preenchidos, incluindo o de concordância com os termos de uso do aplicativo. Estes termos podem ser acessados ao clicar no texto “Acessar termos de uso” destacado em azul.

As informações de cada usuário são armazenadas em um banco de dados conectado pela aplicação. O armazenamento de senhas utiliza o algoritmo bcrypt (DEVELOPERS, 2025), baseado no cifrador Blowfish, que aplica *hashing* e *salting* automáticos com custo ajustável, reforçando a segurança contra ataques de força bruta. Desta forma, toda senha possui uma codificação única no banco, impossibilitando a obtenção da senha original mesmo em caso de vazamento.

3.2 LOGIN

Para realizar o login, é necessário inserir o email e a senha registrados no cadastro nos respectivos campos e, em seguida, pressionar o botão de Login, presente na Figura 14. Caso seja encontrado um campo no banco de dados que corresponda ao email e senha inseridos, o usuário entrará em sua conta com sucesso. Caso contrário, o aplicativo

Figura 13 – Tela de cadastro do aplicativo

A imagem mostra a tela de cadastro do aplicativo EscalAI. No topo, há o logo "EscalAI" em laranja e o texto "Criar conta" em laranja. Abaixo, há sete campos de entrada com bordas arredondadas e laranjas: "Email", "Nome", "Sobrenome", "Data de Nascimento", "Celular", "Senha" e "Confirmar senha". Abaixo dos campos, há o texto "Li e aceito os Termos e Condições de Uso [aqui](#)" em laranja. Abaixo disso, há uma caixa de seleção desmarcada com o texto "Eu concordo com os termos e condições de uso do aplicativo EscalAI". No final, há um botão laranja com o texto "Criar conta".

Fonte: Elaborado pelo autor (2025)

notifica que não há conta com os valores inseridos de email e/ou senha. Além da opção de login, a tela possui botões para recuperação de senha, denotado por “Esqueci minha senha”, e um botão de criação de conta, que leva à tela de Cadastro.

Ao realizar o login, o usuário recebe um token de autenticação, utilizado para validar suas requisições junto ao servidor sem a necessidade de reenviar as credenciais a cada acesso. Esses tokens seguem o padrão JSON Web Token, contendo informações codificadas sobre o usuário e o tempo de expiração da sessão. Cada token é assinado com o algoritmo HMAC-SHA256 (HS256), garantindo a integridade e autenticidade das sessões e prevenindo modificações não autorizadas no conteúdo. Essa abordagem permite o gerenciamento seguro de autenticação em aplicações distribuídas, com baixo custo computacional e sem necessidade de manter o estado de sessão no servidor.

Figura 14 – Tela de login do aplicativo



Fonte: Elaborado pelo autor (2025)

4 DESENVOLVIMENTO DA APLICAÇÃO

A aplicação utiliza diversas tecnologias para a construção das telas e da lógica do programa. Por ser uma aplicação voltada para celulares, o desenvolvimento foi feito em uma ferramenta de código para sistemas Android, o Android Studio.

4.1 FRONTEND

O *frontend* do aplicativo engloba todos os componentes responsáveis pela interface gráfica e interação direta com o usuário. Esta seção aborda as tecnologias, bibliotecas e padrões arquiteturais adotados para o desenvolvimento da camada de apresentação do sistema. Os termos técnicos aqui utilizados, como *frontend*, *backend*, *Model-View-ViewModel* (MVVM), *Data Binding*, entre outros, são mantidos em inglês por representarem nomenclaturas padronizadas e amplamente estabelecidas na literatura técnica de engenharia de software, sendo assim reconhecidos internacionalmente pela comunidade acadêmica e profissional da área.

4.1.1 XML e MDC Android

As interfaces foram desenvolvidas em XML e Material Components for Android (MDC Android), utilizando Material Design 3 (MD3), um sistema de guias, componentes e ferramentas de código aberto para facilitar a implementação das telas (GOOGLE, 2024). Inicialmente, as interfaces foram construídas utilizando apenas XML, aproveitando seus recursos para organizar os elementos visuais. No entanto, conforme o projeto evoluiu e a necessidade de componentes mais sofisticados se tornou evidente, foi adotado o MDC Android, uma implementação nativa dos princípios de Material Design da Google.

O MD3, a versão mais recente do sistema de design da Google, foi incorporado ao projeto por oferecer:

- **Consistência visual:** Proporciona uma linguagem visual unificada em toda a aplicação, com padrões de cor, tipografia e espaçamento predefinidos.
- **Componentes prontos para uso:** Fornece elementos de interface como botões, campos de texto, cartões e barras de navegação que já implementam as melhores práticas de usabilidade.
- **Adaptabilidade:** Permite a personalização de temas e componentes para atender às necessidades específicas do aplicativo, mantendo a coerência visual.

4.1.2 Biblioteca Data Binding

De forma a integrar FrontEnd e BackEnd de forma eficiente, utilizamos a biblioteca Data Binding, parte da Android Jetpack, que permite valores dinâmicos na tela gerados pelo BackEnd da aplicação (DEVELOPERS, 2024). O Data Binding foi crucial para implementar o padrão de arquitetura MVVM (Model-View-ViewModel), pois permite a vinculação direta entre os elementos da interface e os objetos ViewModel. Esta abordagem permitiu criar interfaces dinâmicas que respondem às mudanças de estado da aplicação sem a necessidade de manipulação dos elementos da UI no código Java.

4.1.3 Java

A linguagem de programação utilizada é Java (ORACLE, 2024), utilizando princípios de orientação a objetos. Esta linguagem foi escolhida por sua robustez, portabilidade e ampla adoção no desenvolvimento de aplicações Android. Além disso, Java oferece um ecossistema maduro, com bibliotecas e frameworks bem estabelecidos que facilitam o desenvolvimento de software de alta qualidade.

A arquitetura MVVM foi adotada para organizar o código da aplicação, proporcionando uma separação clara de responsabilidades entre os diferentes componentes do sistema e um acoplamento melhor definido entre as funções de cada classe para conectar back e front da aplicação. Esta arquitetura é particularmente adequada para aplicações Android, pois se integra naturalmente com os componentes do Android Jetpack, como o Data Binding e o LiveData (DEVELOPERS, 2024).

Os principais componentes da arquitetura MVVM implementada são:

- Model: Representa os dados e a lógica de negócios da aplicação, incluindo entidades, repositórios e fontes de dados.
- View: Responsável pela apresentação visual dos dados ao usuário, composta por Activities, Fragments e layouts XML.
- ViewModel: Atua como intermediário entre o Model e a View, transformando os dados do Model em um formato adequado para exibição e fornecendo estados e ações para a View.

A implementação da arquitetura MVVM trouxe diversas vantagens ao projeto, como manutenção simplificada, reutilização de código e ciclo de vida gerenciado, uma vez que ViewModels sobrevivem a mudanças de configuração.

4.1.4 Justificativa da Escolha de Java para Android

Embora Kotlin seja atualmente a linguagem recomendada pelo Google para desenvolvimento Android nativo, Java mantém vantagens significativas: documentação extensa

e madura acumulada ao longo de décadas, ecossistema robusto com ampla disponibilidade de bibliotecas testadas em produção, e familiaridade prévia do desenvolvedor com a linguagem e suas ferramentas, o que acelerou significativamente o desenvolvimento. Adicionalmente, Java oferece retrocompatibilidade garantida com versões anteriores do Android, facilitando o suporte a dispositivos mais antigos e ampliando o alcance potencial do aplicativo.

Alternativas consideradas incluíram Kotlin, que oferece sintaxe mais concisa e recursos modernos como corrotinas nativas, porém demandaria curva de aprendizado adicional; e frameworks multiplataforma como React Native, que permitiria compilação para iOS, mas introduziria camadas de abstração adicionais e além de necessitar de tempo para aprendizado de uma nova linguagem. A escolha por desenvolvimento nativo em Java garantiu acesso direto às APIs do Android, maior controle sobre o ciclo de vida dos componentes e um início mais ágil para o desenvolvimento.

4.2 BANCO DE DADOS DO SERVIDOR

4.2.1 Estimativa de Escalabilidade e Escolha do PostgreSQL

Para fundamentar a escolha do sistema gerenciador de banco de dados, foi realizada uma estimativa de escalabilidade baseada em dados de estudos sobre aplicativos de saúde e monitoramento esportivo. Considerando uma base inicial conservadora de 100 usuários ativos nos primeiros seis meses, com projeção de crescimento para 1.000 usuários no primeiro ano e potencial de 10.000 usuários em três anos, e assumindo que cada usuário gera em média 7 registros diários (hidratação, sono, humor, dor, 2-3 treinos), projeta-se um volume de aproximadamente 2,5 milhões de registros anuais com 1.000 usuários ativos, e 25 milhões de registros anuais com 10.000 usuários. Esta volumetria demanda um SGBD robusto capaz de lidar eficientemente com crescimento exponencial de dados.

O PostgreSQL foi selecionado devido à sua capacidade de escalar o tamanho e complexidade de dados, além de conseguir ser simples e relacional, característica essencial para um sistema que gerencia múltiplas entidades interconectadas como usuários, lesões, engajamento esportivo, métricas de sono, humor e hidratação (GROUP, 2024). A arquitetura do banco de dados, conforme evidenciado no diagrama entidade-relacionamento, apresenta um modelo relacional com tabelas interdependentes (USER, LESAO, ENGAJAMENTO, DOR, HUMOR, SONO, TREINO, AGUA), conforme ilustrado na Figura 15, demandando um SGBD que ofereça suporte à integridade referencial e simplicidade pela conformidade com o padrão SQL e suporte a tipos de dados JSON.

O escalonamento previsto para o aplicativo considera um crescimento gradual da base de usuários, com cada praticante gerando entre 5 a 10 registros diários distribuídos entre as diferentes funcionalidades de monitoramento. Esta projeção resulta em um acúmulo significativo de dados históricos ao longo do tempo, uma vez que o sistema mantém todos

os registros para análise longitudinal e aprimoramento contínuo do modelo preditivo. A complexidade das operações no banco de dados é elevada devido à necessidade de executar consultas com múltiplos JOINS entre tabelas relacionadas, agregações temporais para geração de relatórios, e queries complexas para alimentar o modelo de inteligência artificial. Adicionalmente, o sistema requer integridade referencial forte para garantir consistência entre lesões, métricas de saúde e dados de engajamento de cada usuário, além de suportar operações de leitura e escrita concorrentes de múltiplos usuários acessando o aplicativo simultaneamente.

O armazenamento de dados JSON facilita o armazenamento de pesos calculados dinamicamente na tabela ENGAJAMENTO, onde os dados são utilizados para armazenar configurações de ponderação do algoritmo TOPSIS. Além disso, o sistema armazena data e hora para rastreamento temporal de lesões, treinos e métricas de saúde, área em que o PostgreSQL oferece suporte nativo robusto com tipos de dados especializados como date, datetime e timestamp.

A escalabilidade e performance do PostgreSQL são fundamentais para um sistema que pode gerar grandes volumes de dados ao longo do tempo, especialmente considerando o monitoramento contínuo de múltiplos usuários com registros diários de diversas métricas. O suporte a índices avançados, incluindo índices parciais e funcionais, otimiza consultas frequentes como busca de usuários por e-mail e filtros temporais, enquanto a capacidade de particionamento de tabelas permite gerenciar eficientemente o crescimento histórico de dados. A integração com o framework FastAPI do Python e a biblioteca SQLAlchemy, implementados no código, fornece compatibilidade de modo a facilitar o desenvolvimento de APIs RESTful simples com validação automática de dados e mapeamento objeto-relacional eficiente.

Do ponto de vista de segurança e confiabilidade, o PostgreSQL oferece recursos robustos de autenticação, autorização e criptografia de dados, essenciais para um sistema que manipula informações sensíveis de saúde e dados pessoais de usuários.

4.2.2 Comparação com Alternativas de Banco de Dados


Foram avaliadas diversas alternativas de sistemas gerenciadores de banco de dados antes da decisão final. O MySQL, embora amplamente utilizado e com performance comparável ao PostgreSQL para operações simples, apresenta limitações no suporte a tipos de dados JSON complexos e em recursos avançados de indexação, além de licenciamento mais restritivo. Bancos de dados NoSQL como MongoDB ofereceriam maior flexibilidade de esquema, mas sacrificariam a integridade referencial forte necessária para garantir consistência entre as múltiplas entidades do sistema (usuários, lesões, métricas de saúde), e não forneceriam suporte nativo a transações ACID tão robusto quanto sistemas relacionais.

SQLite foi considerado inadequado devido à arquitetura do aplicativo com servidor centralizado e necessidade de acesso concorrente por múltiplos usuários, uma vez que

SQLite é otimizado para uso local em dispositivo único. Bancos de dados em memória como Redis, apesar de performance excepcional, não foram viáveis como solução primária devido à necessidade de persistência duradoura dos dados históricos para análise longitudinal, embora possam ser considerados futuramente como camada de cache para consultas frequentes.

A escolha final do PostgreSQL foi reforçada por benchmarks disponíveis na literatura que demonstram performance superior em consultas complexas com JOINS e agregações, características centrais para o funcionamento do sistema EscalAI. Adicionalmente, o PostgreSQL oferece extensibilidade através de plugins e tipos de dados customizados, permitindo futuras expansões do sistema sem necessidade de migração de tecnologia.

Figura 15 – Diagrama Entidade-Relacionamento do banco de dados



Fonte: Elaborado pelo autor (2025)

4.3 BACKENDS

4.3.1 Servidor Python

O servidor do aplicativo EscalAI foi desenvolvido utilizando o framework FastAPI (RAMÍREZ, 2024a), uma biblioteca de Python para construção de APIs web de alta performance. A arquitetura adota o padrão REST (Representational State Transfer). A escolha do FastAPI foi motivada pelas necessidades específicas do aplicativo: previsões em tempo real de recuperação de lesões, cálculo do índice de engajamento TOPSIS sob demanda, processamento de queries complexas envolvendo múltiplas tabelas relacionadas, geração dinâmica de relatórios com agregações temporais, e suporte a múltiplos usuários realizando requisições simultâneas. Estas operações demandam alta performance e baixa latência para garantir uma experiência responsiva ao usuário. Adicionalmente, o FastAPI oferece facilidades como tipagem estática nativa com Python type hints, validação automática de dados através do Pydantic, documentação interativa gerada automaticamente e suporte assíncrono para operações de entrada e saída, características que simplificaram significativamente o desenvolvimento. A familiaridade prévia do desenvolvedor com Python e frameworks web também contribuiu para a decisão, permitindo um desenvolvimento mais ágil e focado na lógica de negócio e nos algoritmos de inteligência artificial.

4.3.2 Comparação com Frameworks Web Alternativos

A decisão pelo FastAPI envolveu análise comparativa com outros frameworks Python estabelecidos. Django, framework full-stack mais maduro e popular, foi considerado mas apresentaria funcionalidades excessivas para as necessidades do projeto, uma vez que inclui sistema de templates, ORM proprietário, painel administrativo e outras ferramentas voltadas para aplicações web tradicionais, introduzindo complexidade desnecessária para uma API RESTful. Flask, embora mais leve e flexível, não oferece suporte nativo a programação assíncrona e requer configuração manual de validação de dados, documentação e serialização, resultando em maior tempo de desenvolvimento.

Estudos de benchmarks comparativos entre frameworks Python demonstram que FastAPI apresenta performance significativamente superior ao Flask e Django em operações de alto throughput, aproximando-se da performance de frameworks como Node.js e Go, o que é particularmente relevante para operações de previsão em tempo real que envolvem cálculos computacionalmente intensivos. A arquitetura assíncrona nativa do FastAPI, baseada em Starlette e Pydantic, permite processar múltiplas requisições concorrentes de forma eficiente sem bloqueio de threads, característica essencial para escalar o sistema conforme o número de usuários aumenta.

A geração automática de documentação OpenAPI pelo FastAPI eliminou a necessidade de manter documentação separada, reduzindo inconsistências e facilitando a integração

com o aplicativo Android. A tipagem estática com Python type hints, além de melhorar a qualidade do código e facilitar manutenção, permite detecção de erros em tempo de desenvolvimento ao invés de runtime, aumentando a confiabilidade do sistema.

O sistema implementa um modelo de dados relacional robusto utilizando SQLModel (RAMÍREZ, 2024b), que combina as funcionalidades do SQLAlchemy (SQLAlchemy Project, 2026) com a tipagem do Pydantic. O módulo de autenticação implementa um sistema seguro baseado em JWT com suporte a tokens de acesso e atualização. A implementação utiliza bcrypt para hash de senhas e python-jose para geração e validação de tokens. Isso garante abordagens seguras de autenticação. Além disso, ele possui validação de entrada com Schemas Pydantic para sanitização de dados e controle de acesso com um Middleware de autenticação em endpoints protegidos. Esta arquitetura robusta e modular permite ao sistema EscalAI processar dados sensíveis de saúde e treinamento de forma segura e escalável, fornecendo uma base sólida para análise preditiva e monitoramento de engajamento em escalada.

5 TREINAMENTO DA INTELIGÊNCIA ARTIFICIAL

Este capítulo apresenta o desenvolvimento e treinamento do modelo de inteligência artificial responsável pela predição do tempo de recuperação de lesões em escaladores. O sistema preditivo constitui o componente central do aplicativo EscalAI, combinando técnicas de aprendizado de máquina, métodos de tomada de decisão multicritério e predição conformalizada para fornecer estimativas confiáveis e estatisticamente fundamentadas. São detalhados o cálculo do índice de engajamento esportivo via método TOPSIS, a arquitetura e treinamento do modelo XGBoost com distribuição de Poisson, a implementação de intervalos de confiança através do método Jackknife+, e as métricas de avaliação que validam o desempenho do sistema. O modelo foi treinado previamente utilizando dados históricos de lesões em escaladores brasileiros e é executado no servidor, garantindo predições em tempo real sem comprometer os recursos do dispositivo móvel do usuário.

5.1 INTRODUÇÃO AO TREINAMENTO DA INTELIGÊNCIA ARTIFICIAL

O treinamento da Inteligência Artificial do aplicativo visa integrar múltiplas fontes de dados relacionadas à prática da escalada, com o objetivo de identificar padrões e realizar previsões sobre o tempo de recuperação de lesões. O processo envolve desde a coleta e tratamento das informações até a modelagem e avaliação dos algoritmos utilizados. Na estrutura do sistema, o cálculo do índice de engajamento e o modelo de previsão de lesões trabalham de forma complementar. O primeiro fornece uma métrica quantitativa do envolvimento do escalador, enquanto o segundo aplica técnicas de aprendizado de máquina para estimar o tempo de afastamento. Essa combinação possibilita uma análise integrada entre comportamento, carga de treino e fatores de risco, contribuindo para a personalização das recomendações e o aprimoramento contínuo do sistema preditivo.

5.2 CÁLCULO DO ÍNDICE DE ENGAJAMENTO (TOPSIS)

Em paralelo à previsão de lesões, o aplicativo calcula o índice de engajamento do escalador utilizando a técnica TOPSIS (HWANG; YOON, 1981). O TOPSIS é um método de tomada de decisão multicritério que avalia alternativas com base em sua distância de uma solução ideal positiva e de uma solução ideal negativa. No contexto do aplicativo, ele quantifica o nível de envolvimento do usuário com a escalada. O cálculo do engajamento considera variáveis de entrada, como frequência e horas de escalada em diferentes modalidades, graus de escalada atingidos e tempo de experiência. Essas variáveis são combinadas para as pontuações de engajamento:

- **Score com Pesos de Entropia:** uma pontuação em que os pesos são determinados pela entropia, atribuindo maior relevância a variáveis com maior variabilidade ou informação, refletindo a importância relativa de cada critério para o engajamento do escalador.

O cálculo dos pesos por entropia baseia-se no conceito de incerteza proposto por (SHANNON, 1948), em que a entropia E_j de cada critério j é definida como:

$$E_j = -k \sum_{i=1}^m p_{ij} \ln(p_{ij})$$

em que p_{ij} representa a proporção normalizada do valor da alternativa i no critério j , e $k = 1/\ln(m)$ é um fator de normalização. A partir dessa medida, os pesos w_j são obtidos como:

$$w_j = \frac{1 - E_j}{\sum_{j=1}^n (1 - E_j)}$$

Critérios com maior variabilidade entre as alternativas recebem pesos mais altos. Isso reflete sua maior importância no cálculo do índice de engajamento. O índice de engajamento é armazenado no banco de dados e serve como feedback para o usuário, além de ser utilizado como uma feature (`Climber_Engagement`) no modelo de previsão de lesões, demonstrando a interconexão entre os diferentes módulos do aplicativo e fornecendo uma abordagem holística na análise de dados.

5.3 MODELO XGBOOST

O modelo de previsão de lesões implementado no aplicativo utiliza o algoritmo XGBoost (*Extreme Gradient Boosting*), proposto por (CHEN; GUESTRIN, 2016). O XGBoost é uma técnica de aprendizado supervisionado baseada em gradient boosting, na qual um conjunto de árvores de decisão é construído sequencialmente, cada uma corrigindo os erros das anteriores, de modo a minimizar uma função de perda. O algoritmo é amplamente reconhecido por sua eficiência computacional, capacidade de lidar com dados esparsos e robustez contra *overfitting*, sendo frequentemente empregado em competições de aprendizado de máquina e aplicações reais de previsão.

5.3.1 Fundamentação do XGBoost

O XGBoost implementa o método de *gradient boosting* com otimizações e regularizações adicionais. Dado um conjunto de treinamento com vetores de características $\mathbf{x}_i$ e valores-alvo y_i (tempo de afastamento em meses), o modelo constrói um preditor através da soma sequencial de múltiplas árvores de decisão. Cada árvore contribui com uma parte da predição final, e o processo iterativo foca em corrigir os erros cometidos pelas árvores anteriores.

O treinamento do modelo minimiza uma função objetivo que equilibra dois componentes: (i) o erro de predição, medido pela discrepância entre valores preditos e reais, e (ii) a complexidade do modelo, controlada por termos de regularização. Esta formulação pode ser expressa como:

$$\mathcal{L}(\phi) = \sum_{i=1}^n \ell(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (5.1)$$

onde ℓ representa a função de perda, $\hat{y}_i$ são as predições, K é o número de árvores, e Ω penaliza a complexidade de cada árvore através de dois parâmetros: γ , que controla o número de folhas, e λ , que penaliza a magnitude dos pesos atribuídos às folhas.

Em cada iteração, uma nova árvore é ajustada aos resíduos (erros) do modelo atual, utilizando informações de primeira e segunda derivada da função de perda (gradiente e Hessiana). Esta abordagem baseada em derivadas de segunda ordem permite ao XGBoost convergir mais rapidamente e com maior precisão do que métodos que utilizam apenas o gradiente.

Para determinar a melhor divisão em cada nó da árvore, o algoritmo calcula o ganho de informação associado a cada possível partição dos dados. O ganho ótimo para dividir um conjunto de instâncias em dois subconjuntos (esquerdo e direito) é dado por:

$$\text{Gain} = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (5.2)$$

onde G e H representam, respectivamente, a soma dos gradientes e das Hessianas das instâncias em cada subconjunto. Divisões com ganho negativo não são realizadas, controlando assim o crescimento da árvore e prevenindo *overfitting*.

5.3.2 Parâmetros do XGBoost

No aplicativo, o modelo foi treinado para prever o tempo de afastamento em meses utilizando uma distribuição de Poisson, apropriada para dados de contagem não-negativos. A função de perda de Poisson penaliza predições através da log-verossimilhança negativa, adequando-se à natureza discreta da variável alvo. Os parâmetros finais selecionados são:

- **Profundidade máxima (max_depth):** 6 níveis, limitando a complexidade de cada árvore e reduzindo o risco de *overfitting*.
- **Taxa de aprendizado (eta):** 0,1, controlando a contribuição de cada árvore ao ensemble.
- **Número de rodadas (n-rounds):** até 2000 iterações, com *early stopping* em 50 rodadas sem melhoria para evitar treinamento excessivo.

- **Parâmetro de regularização γ :** 0, indicando que a penalização pelo número de folhas não foi necessária dada a profundidade limitada.
- **Fração de amostragem de colunas (`colsample_bytree`):** 1, utilizando todas as variáveis em cada árvore.
- **Peso mínimo do filho (`min_child_weight`):** 1, valor padrão que controla a divisão mínima dos nós.
- **Subamostragem (`subsample`):** 1, utilizando todas as instâncias em cada iteração.

5.3.3 Divisão dos Dados e Estratégia de Validação

O conjunto de dados foi dividido em dois subconjuntos disjuntos utilizando amostragem aleatória com semente fixa (`random_state=100`) para garantir reprodutibilidade:

- **Conjunto de treino+calibração (80%):** utilizado para o ajuste do modelo através de validação cruzada e para a calibração dos intervalos de confiança via predição conformalizada out-of-fold.
- **Conjunto de teste (20%):** reservado exclusivamente para avaliação final do desempenho, permanecendo completamente isolado até a etapa de teste.

A divisão dupla maximiza o uso dos dados. A validação cruzada k-fold de 10 dobras gera predições out-of-fold (OOF), permitindo usar 100% dos dados de treino tanto para avaliação quanto para calibração dos intervalos, sem precisar de um conjunto de calibração separado. Para avaliar a robustez e capacidade de generalização do modelo, foi empregada validação cruzada de 10 dobras (*10-fold cross-validation*) no conjunto de treino+calibração. Neste procedimento, o conjunto é dividido em 10 subconjuntos aproximadamente iguais. Em cada uma das 10 iterações, 9 subconjuntos são usados para treinamento e 1 para validação, alternando sistematicamente. Crucialmente, este processo gera predições out-of-fold para cada instância do conjunto de treino: cada observação é predita exatamente uma vez por um modelo que não a viu durante o treinamento. Estas predições OOF são então agregadas para calcular métricas de desempenho sobre os 100% do conjunto de treino+calibração. Ao final, obtém-se tanto uma estimativa média do desempenho por fold quanto métricas agregadas sobre todas as predições OOF, fornecendo uma avaliação robusta da capacidade de generalização do modelo. A métrica de avaliação principal foi o Erro Absoluto Médio (MAE), complementada por métricas adicionais: Erro Quadrático Médio (MSE), Raiz do Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Médio (MAPE), todas definidas formalmente a seguir.

5.3.3.1 métricas de avaliação

As métricas utilizadas para avaliar o desempenho do modelo são definidas matematicamente como: **Erro Absoluto Médio (MAE)**:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5.3)$$

O MAE mede a média das diferenças absolutas entre valores preditos $\hat{y}_i$ e reais y_i , fornecendo uma interpretação direta do erro médio na mesma unidade da variável alvo (meses).

Erro Quadrático Médio (MSE):

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5.4)$$

O MSE penaliza quadraticamente os erros, atribuindo maior peso a desvios maiores, sendo sensível a outliers. **Raiz do Erro Quadrático Médio (RMSE)**:

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5.5)$$

O RMSE retorna o erro à mesma escala da variável alvo, mantendo a sensibilidade do MSE a erros maiores. **Erro Percentual Absoluto Médio (MAPE)**:

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5.6)$$

O MAPE expressa o erro em termos percentuais relativos ao valor real de cada predição, sendo particularmente informativo para comparar erros em diferentes ordens de grandeza.

Na prática, o erro absoluto médio de aproximadamente 0,8 meses indica que o modelo, em média, erra menos de um mês na estimativa do tempo de afastamento, sendo um resultado considerado adequado para o contexto clínico de reabilitação esportiva.

5.3.4 Pós-processamento e Discretização

As predições do modelo são pós-processadas para garantir interpretabilidade clínica e consistência com a resolução temporal dos dados de treinamento. Todos os valores preditos são discretizados em múltiplos de 0,5 meses através de arredondamento ao meio-mês mais próximo. Esta discretização reflete a precisão com que escaladores tipicamente reportam o tempo de afastamento e evita predições com precisão artificial excessiva.

Adicionalmente, as predições são limitadas ao intervalo clinicamente razoável de 1 a 7 meses. O limite inferior de 1 mês corresponde a lesões leves que requerem afastamento mínimo, enquanto o limite superior de 7 meses cobre lesões graves que exigem recuperação prolongada. Valores fora desta faixa foram raramente observados nos dados de treinamento e são truncados para evitar predições implausíveis.

5.3.5 Adequação do XGBoost ao Problema de Previsão de Lesões

A escolha do XGBoost para o problema de previsão de tempo de afastamento por lesões justifica-se por diversas características que alinham-se às peculiaridades dos dados e requisitos da aplicação:

- **Robustez a outliers e dados ruidosos:** A regularização explícita através dos parâmetros γ e λ , combinada com *early stopping*, previne *overfitting* mesmo com variabilidade nos dados de entrada.
- **Capacidade de capturar interações complexas:** As árvores de decisão naturalmente modelam interações não-lineares entre variáveis sem necessidade de especificação manual, capturando padrões como o efeito moderador do engajamento sobre o histórico de lesões.
- **Eficiência computacional:** Implementações otimizadas permitem treinamento rápido mesmo com busca em grade de hiperparâmetros e validação cruzada, viabilizando o retreinamento periódico do modelo conforme novos dados são coletados.
- **Tratamento nativo de dados esparsos:** Variáveis *dummy* resultam em matrizes esparsas (com muitos zeros), que o XGBoost manipula eficientemente através de estruturas de dados especializadas.
- **Flexibilidade de funções objetivo:** A distribuição de Poisson é adequada para dados de contagem não-negativos como o tempo de afastamento, e pode ser facilmente incorporada como função objetivo customizada.
- **Interpretabilidade:** As medidas de importância de features facilitam a validação clínica do modelo, permitindo verificar se as variáveis mais influentes são condizentes com o conhecimento médico-esportivo sobre lesões em escalada.

A integração da predição conformalizada via Jackknife+, aliada à discretização pós-processamento e à incorporação do índice de engajamento calculado via TOPSIS, torna o sistema preditivo robusto, interpretável e clinicamente relevante para auxiliar escaladores na compreensão do tempo de recuperação esperado e da incerteza associada a esta estimativa.

5.3.6 Confiança e Intervalos de Predição

Além da predição pontual do tempo de afastamento, o sistema implementa **predição conformalizada** para estimar intervalos de confiança que quantificam a incerteza da predição. Enquanto a predição pontual fornece um valor único esperado, os intervalos de confiança informam o intervalo plausível onde o valor real provavelmente se encontra,

aspecto fundamental em aplicações clínicas onde a quantificação confiável da incerteza é tão importante quanto a predição em si. A metodologia adotada baseia-se em *Conformal Prediction* (VOVK; GAMMERMAN; SHAFER, 2005), uma técnica que fornece garantias estatísticas válidas de cobertura para intervalos de predição, implementada através da biblioteca MAPIE (*Model Agnostic Prediction Interval Estimator*) (MAPIE Contributors, 2021). Especificamente, utiliza-se o método *Jackknife+* (BARBER et al., 2021), uma extensão do método *Jackknife* tradicional que produz intervalos adaptativos, permitindo que a largura do intervalo varie de acordo com a incerteza local de cada predição.

5.3.6.1 método jackknife+ e cálculo de resíduos out-of-fold

O método Jackknife+ implementado pelo MAPIE utiliza predições out-of-fold geradas via validação cruzada k-fold para calibrar intervalos de confiança. Diferentemente de métodos de regressão por quantis que requerem modelos separados para diferentes quantis, o Jackknife+ trabalha diretamente com o modelo de ponto (XGBoost) e utiliza a distribuição empírica dos resíduos absolutos obtidos durante a validação cruzada.

O processo funciona da seguinte forma: Durante a calibração com k-fold, o MAPIE treina um modelo XGBoost para cada fold. Cada modelo gera predições out-of-fold para as instâncias que não foram vistas durante o treino. Para cada instância i no conjunto de treino+calibração, calcula-se o resíduo absoluto:

$$r_i = |y_i - \hat{y}_i^{\text{OOF}}| \quad (5.7)$$

onde $\hat{y}_i^{\text{OOF}}$ é a predição out-of-fold (gerada por um modelo que não viu y_i durante o treinamento). Estes resíduos absolutos formam uma distribuição empírica que captura os erros típicos do modelo em diferentes regiões do espaço das features.

O método Jackknife+ utiliza esta distribuição de resíduos absolutos para construir intervalos adaptativos e assimétricos. Diferentemente de métodos que assumem resíduos simétricos ou homoscedásticos, o Jackknife+ permite que a largura e forma do intervalo variem conforme a instância, adaptando-se naturalmente à heteroscedasticidade dos dados sem necessidade de modelar quantis explicitamente.

5.3.6.2 conformalização dos intervalos

A conformalização garante que os intervalos construídos tenham cobertura probabilística válida, ou seja, que a proporção de valores reais contidos nos intervalos seja pelo menos igual ao nível de confiança especificado. O processo de calibração conformal via MAPIE segue três etapas principais: **Etapla 1 - Validação cruzada k-fold para calibração:** O conjunto de treino+calibração (80% dos dados totais) é dividido em $k = 10$ folds. Para cada fold j , um modelo XGBoost é treinado nos outros $k - 1$ folds e gera predições out-of-fold para as instâncias do fold j . Este processo garante que cada instância do conjunto de treino+calibração receba uma predição de um modelo que nunca a

viu, evitando otimismo nas estimativas de incerteza. **Etapa 2 - Cálculo dos scores de não-conformidade:** Para cada instância i no conjunto de treino+calibração, o MAPIE calcula um *score* de não-conformidade que quantifica o quão bem o modelo prediz aquela instância. No método Jackknife+, este score é o resíduo absoluto out-of-fold:

$$s_i = |y_i - \hat{y}_i^{\text{OOF}}| \quad (5.8)$$

Adicionalmente, o Jackknife+ armazena informações sobre qual fold gerou cada predição, permitindo construir intervalos adaptativos que consideram a variabilidade entre os diferentes modelos treinados. **Etapa 3 - Construção dos intervalos conformalizados:** Para uma nova instância $\mathbf{x}_{\text{new}}$, o MAPIE treina um modelo final em todo o conjunto de treino+calibração e gera uma predição pontual $\hat{y}_{\text{new}}$. O intervalo conformalizado é então construído utilizando a distribuição empírica dos scores de não-conformidade. Para um nível de confiança de 80% ($\alpha = 0,2$), o MAPIE calcula o quantil apropriado $q_{1-\alpha}$ dos scores de calibração, produzindo o intervalo:

$$C_\alpha(\mathbf{x}_{\text{new}}) = [\hat{y}_{\text{new}} - q_{1-\alpha}^+, \hat{y}_{\text{new}} + q_{1-\alpha}^+] \quad (5.9)$$

onde $q_{1-\alpha}^+$ incorpora um ajuste adicional baseado na diversidade das predições dos diferentes folds, característica distintiva do método Jackknife+ que garante cobertura válida mesmo com amostras finitas.

5.3.6.3 garantias teóricas de cobertura

A predição conformalizada oferece garantias matemáticas sobre a cobertura dos intervalos. Sob a hipótese de permutabilidade (ou seja, assumindo que os dados de calibração e os dados futuros são amostrados da mesma distribuição), o método garante que:

$$P(Y_{\text{new}} \in C_\alpha(\mathbf{x}_{\text{new}})) \geq 1 - \alpha \quad (5.10)$$

onde $C_\alpha(\mathbf{x}_{\text{new}})$ é o intervalo de predição conformalizado. Esta garantia é válida independentemente do modelo base utilizado (XGBoost, neste caso), sendo uma propriedade do método conformal, não do modelo preditivo. Em termos práticos, para um nível de confiança de 80%, espera-se que pelo menos 80% das predições futuras tenham seus valores reais dentro dos intervalos construídos. O método Jackknife+ oferece uma vantagem adicional sobre métodos conformais mais simples: ele produz intervalos assimétricos que podem se expandir mais para um lado do que para o outro, dependendo da distribuição local dos resíduos. Esta assimetria permite capturar melhor a heteroscedasticidade dos dados, produzindo intervalos mais informativos e eficientes.

5.3.6.4 justificativa da divisão dos dados

A adoção de uma divisão dupla (80% treino+calibração, 20% teste) combinada com validação cruzada k-fold para calibração conformal representa uma estratégia eficiente que maximiza o uso dos dados disponíveis:

- **Eficiência no uso dos dados:** Ao utilizar 80% dos dados para treino+calibração através de predições out-of-fold, o sistema efetivamente usa 100% destes dados tanto para treinamento quanto para calibração, sem necessidade de um terceiro conjunto de calibração separado. Esta abordagem é mais eficiente do que uma divisão tripla tradicional (por exemplo, 60% treino, 20% calibração, 20% teste), que resultaria em menos dados disponíveis para o treinamento do modelo.
- **Calibração robusta via out-of-fold:** O uso de validação cruzada k-fold para gerar scores de não-conformidade garante que cada predição de calibração seja produzida por um modelo que nunca viu aquela instância, evitando otimismo nas estimativas de incerteza. Simultaneamente, múltiplos modelos são treinados (um por fold), e suas predições agregadas fornecem uma estimativa mais robusta da variabilidade do modelo.
- **Validação rigorosa:** A validação cruzada 10-fold aplicada aos 80% fornece uma estimativa robusta do desempenho com medida de variabilidade, calculando métricas tanto por fold individual quanto agregadas sobre todas as predições OOF.
- **Teste final imparcial:** O conjunto de teste de 20% permanece completamente isolado durante todo o processo de desenvolvimento, fornecendo uma avaliação final não-enviesada do desempenho tanto da predição pontual quanto da cobertura dos intervalos.

Esta arquitetura permite:

- **Treino+Calibração (80%):** validação cruzada 10-fold que simultaneamente (i) avalia o desempenho do modelo através de predições OOF, e (ii) gera os scores de não-conformidade necessários para calibração conformal, utilizando eficientemente 100% dos dados disponíveis nesta camada.
- **Teste Final (20%):** avaliação definitiva e imparcial, incluindo verificação empírica da cobertura dos intervalos conformalizados.

5.4 DADOS DO TREINO

A base de dados utilizada para o desenvolvimento do aplicativo de previsão de lesões e para a análise apresentada é composta por um conjunto de arquivos de tabelas *Excel* com informações detalhadas sobre escaladores e suas experiências com lesões, obtidos do estudo de SALIBA (2021). Esses dados são utilizados na análise preditiva para o treinamento da inteligência artificial do aplicativo, permitindo a identificação de padrões. A coleta e organização desses dados foram realizadas para capturar diferentes variáveis que podem influenciar a ocorrência e a recuperação de lesões na escalada. Os principais dados estão listados nas **Tabelas dos Apêndices B e C**.

A coleta de dados no aplicativo para o processamento pela Inteligência Artificial ocorre de forma a registrar o histórico de atividades de escalada e detalhes sobre lesões. Os dados são inseridos pelos usuários através da interface do aplicativo e armazenados em um banco de dados relacional no servidor, conforme indicado neste trabalho. Essa abordagem oferece a manutenção da integridade e centralização das informações. Os dados brutos coletados incluem:

- **Informações do usuário:** idade, sexo, massa corporal, altura e tempo total de experiência em escalada.
- **Dados de atividade:** frequência e horas dedicadas a diferentes modalidades (muro indoor, escalada esportiva, boulder, escalada tradicional brasileira e alta complexidade), bem como o grau máximo atingido.
- **Dados de lesões:** presença de dor, modalidade praticada no momento da lesão, diagnóstico médico, tipo e local da lesão, tempo de afastamento, profissional de tratamento procurado e ocorrência de recidiva.
- **Histórico de lesões:** número total de lesões e reincidências registradas para o mesmo usuário.

Além disso, os dados coletados apresentam correlações importantes entre variáveis, onde fatores de risco foram identificados, sendo as principais:

- Baixo engajamento e maior risco de lesão;
- Idade mais avançada e maior tempo de recuperação;
- Modalidade de escalada e tipo de lesão mais prevalente;
- Histórico de lesões e probabilidade de reincidência.

5.5 PROCESSAMENTO DOS DADOS

Os limites calculados pelo MAPIE são ajustados para garantir interpretabilidade clínica e razoabilidade. Primeiro, todos os valores são discretizados em múltiplos de 0,5 meses através de arredondamento ao meio-mês mais próximo, refletindo a precisão com que escaladores tipicamente reportam o tempo de afastamento. Segundo, os limites são restritos ao intervalo $[1, 7]$ meses, que cobre o espectro de tempos de afastamento observados nos dados de treinamento. Terceiro, garante-se que o limite inferior não seja maior que a predição pontual, e que o limite superior não seja menor que ela, mantendo a coerência do intervalo centrado na predição. Além disso, uma largura mínima de 0,5 meses é imposta para evitar intervalos degenerados em casos de alta confiança, garantindo que

sempre haja alguma quantificação explícita de incerteza. O sistema retorna ao usuário três informações complementares:

1. **Tempo previsto:** predição pontual do modelo XGBoost (valor esperado)
2. **Intervalo mínimo:** limite inferior do intervalo de 80% de confiança
3. **Intervalo máximo:** limite superior do intervalo de 80% de confiança

Esta apresentação permite que o usuário compreenda tanto o valor mais provável (tempo previsto) quanto a incerteza associada (amplitude do intervalo), facilitando decisões informadas sobre o planejamento da recuperação e retorno à prática esportiva.

5.5.1 Resultados do Modelo

O desempenho do modelo XGBoost foi avaliado em múltiplas etapas, fornecendo uma visão abrangente de sua capacidade preditiva, consistência e confiabilidade.

5.5.1.1 validação cruzada e métricas out-of-fold

A validação cruzada de 10 dobras aplicada ao conjunto de treino+calibração (80% dos dados) gerou tanto métricas por fold quanto métricas agregadas sobre todas as predições out-of-fold: **Métricas por fold:** O MAE médio foi de $0,824 \pm 0,103$ meses. Os scores individuais de MAE nas dobras foram: [0,698; 0,892; 0,858; 0,714; 0,815; 0,826; 0,994; 0,926; 0,867; 0,649] meses. A variação relativamente pequena entre as dobras (desvio padrão de 0,103 meses) indica ausência de sobreajuste (*overfitting*) e sugere que o modelo possui boa capacidade de generalização. **Métricas agregadas out-of-fold:** Calculadas sobre todas as predições OOF do conjunto de treino+calibração (100% dos 80% de dados):

- **MAE (OOF):** 0,824 meses
- **RMSE (OOF):** 1,334 meses
- **MSE (OOF):** 1,779 meses²
- **MAPE (OOF):** 24,70%

Estas métricas OOF fornecem uma estimativa não-enviesada do desempenho esperado do modelo em dados novos, pois cada predição foi gerada por um modelo que nunca viu aquela instância específica durante o treinamento.

5.5.1.2 desempenho no conjunto de teste

No conjunto de teste final (20% dos dados, completamente isolado durante o desenvolvimento), o modelo apresentou as seguintes métricas:

- **MAE (Erro Absoluto Médio):** 0,792 meses, indicando que, em média, as previsões do modelo diferem do valor real em aproximadamente 24 dias. Este valor é ligeiramente inferior ao MAE da validação cruzada (0,824 meses), confirmando que o modelo generalizou adequadamente para dados não vistos.
- **RMSE (Raiz do Erro Quadrático Médio):** 1,334 meses. O fato do RMSE ser consideravelmente maior que o MAE (aproximadamente 68% maior) indica a presença de alguns casos com desvios mais pronunciados. Esta diferença é esperada, pois o RMSE, definido pela Equação (3), penaliza quadraticamente erros maiores, sendo mais sensível a outliers. A similaridade entre o RMSE no teste (1,334) e o RMSE OOF (1,334) demonstra consistência no desempenho.
- **MAPE (Erro Percentual Absoluto Médio):** 24,70%. Esta métrica, definida pela Equação (4), expressa o erro em termos relativos ao valor real de cada previsão. Um MAPE de 24,70% significa que, em média, as previsões desviam-se cerca de um quarto do valor real. Esta métrica é particularmente informativa em contextos onde a magnitude relativa do erro é relevante: um erro absoluto de 1 mês representa 50% de erro relativo para uma lesão de 2 meses, mas apenas 17% para uma lesão de 6 meses. O MAPE captura essa nuance, refletindo que o modelo tende a ter maior erro percentual relativo em lesões de curta duração, possivelmente devido à maior variabilidade individual nesses casos e à menor margem absoluta para erro.

5.5.1.3 intervalos de confiança e cobertura

Os intervalos de confiança construídos via predição conformalizada (MAPIE Jackknife+) apresentaram as seguintes características no conjunto de teste:

- **Cobertura empírica:** 86,9%, superando o nível nominal de 80%. Isto significa que 86,9% das previsões no conjunto de teste tiveram seus valores reais contidos dentro dos intervalos de 80% de confiança construídos. Esta cobertura ligeiramente superior ao nominal é um resultado positivo, indicando que o método é conservador e confiável. A cobertura acima do nominal (mas não excessivamente acima) demonstra que o procedimento de calibração conformal via out-of-fold funcionou adequadamente, fornecendo garantias estatísticas válidas mesmo em dados completamente não vistos.
- **Largura média dos intervalos:** 3,36 meses. Esta largura representa um equilíbrio entre precisão e confiabilidade: intervalos muito estreitos resultariam em cobertura insuficiente (abaixo de 80%), tornando-os não-confiáveis, enquanto intervalos excessivamente largos teriam alta cobertura, mas seriam pouco informativos para o usuário. A largura de aproximadamente 3,4 meses fornece informação útil sobre

a incerteza da predição, permitindo que usuários e profissionais de saúde planejem adequadamente o período de recuperação, considerando tanto o cenário mais provável quanto variações possíveis.

6 CONCLUSÃO

O presente trabalho apresentou o desenvolvimento e a avaliação do aplicativo EscalAI, concebido para auxiliar escaladores na prevenção e previsão de lesões. A partir de uma base de dados composta por informações detalhadas sobre escaladores e suas experiências com lesões (SALIBA, 2021), foi possível estruturar um modelo de aprendizado de máquina capaz de estimar o tempo de afastamento necessário para a recuperação, contribuindo para um acompanhamento mais assertivo e individualizado.

O modelo preditivo implementado com XGBoost alcançou resultados satisfatórios, evidenciados pelas métricas obtidas que demonstram consistência dos dados e robustez estatística. A utilização de conformalização permitiu estimar intervalos de confiança realistas, ampliando a transparência do sistema para o usuário, de forma a ele compreender que não é uma estimativa exata, o que é particularmente relevante no contexto da saúde esportiva.

Apesar dos resultados promissores, algumas limitações foram identificadas. A principal é a quantidade restrita e heterogênea de dados, o que pode introduzir viés histórico e comprometer a generalização do modelo em populações diferentes. Ademais, o uso de dados autorrelatados pode acarretar inconsistências ou imprecisões.

Para trabalhos futuros, propõe-se a realização de avaliação sistemática do aplicativo com usuários reais, incluindo escaladores de diferentes níveis de experiência e modalidades praticadas. Esta avaliação seria fundamental para validar a usabilidade da interface, a clareza das informações apresentadas e a acurácia das previsões em contextos práticos de uso. Adicionalmente, recomenda-se a implementação de estratégias de ludificação (*gamification*) e outros mecanismos de retenção de usuários, tais como sistema de conquistas, desafios semanais e rankings entre praticantes, visando aumentar o engajamento a longo prazo e garantir a qualidade da base de dados coletada.

Outras melhorias incluem a adequação completa dos sistemas à Lei Geral de Proteção de Dados (LGPD), o aumento da segurança dos dados dos usuários através de criptografia de ponta a ponta e auditorias de segurança, e a integração com dispositivos IoT como smartwatches, permitindo coleta automática de métricas fisiológicas sem necessidade de inserção manual pelo usuário. A ampliação dos métodos de autenticação para incluir grandes provedores de e-mail (Google, Microsoft) ou redes sociais facilitaria o processo de cadastro e login. Por fim, sugere-se adicionar funcionalidades específicas que possibilitem acompanhamento remoto por profissionais de saúde, como fisioterapeutas e ortopedistas, permitindo que estes monitorem a evolução de seus pacientes e ajustem planos de tratamento baseados nos dados coletados pelo aplicativo.

REFERÊNCIAS

- ARMSTRONG, L.; JOHNSON, E. Water intake, water balance, and the elusive daily water requirement. **Nutrients**, v. 10, n. 12, p. 1928, dez. 2018. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/30563134/>. Acesso em: 12 set. 2025.
- BARBER, R. F. et al. Predictive inference with the jackknife+. **The Annals of Statistics**, Institute of Mathematical Statistics, v. 49, n. 1, p. 486–507, 2021.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: **Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. [S.l.: s.n.], 2016. p. 785–794.
- DEVELOPERS, A. **Android Jetpack e Data Binding**. 2024. <https://developer.android.com/jetpack/androidx/releases/databinding>. Acesso em: 12 set. 2025.
- DEVELOPERS bcrypt. **bcrypt: password hashing for Python**. 2025. <https://pypi.org/project/bcrypt/>. Acesso em: 12 set. 2025.
- GERDES, E. M.; HAFNER, J. W.; ALDAG, J. C. Injury patterns and safety practices of rock climbers. **The Journal of Trauma: Injury, Infection, and Critical Care**, v. 61, n. 6, p. 1517–1525, dez. 2006.
- GOOGLE. **Material Design 3**. 2024. <https://m3.material.io>. Acesso em: 12 set. 2025.
- GROUP, P. G. D. **PostgreSQL: Documentação Oficial**. 2024. <https://www.postgresql.org/docs/>. Acesso em: 12 set. 2025.
- GRØNHAUG, G.; SAETERBAKKEN, A. No pain no gain: a survey of use of healthcare and reasons not to seek healthcare by norwegian climbers with chronic injuries. **BMJ Open Sport & Exercise Medicine**, v. 5, n. 1, p. e000513, maio 2019.
- HWANG, C.-L.; YOON, K. **Multiple Attribute Decision Making: Methods and Applications — A State-of-the-Art Survey**. [S.l.]: Springer-Verlag, 1981.
- JENSEN, M. P.; KAROLY, P.; BRAVER, S. The measurement of clinical pain intensity: A comparison of six methods. **Pain**, v. 27, n. 1, p. 117–126, 1986. Artigo clássico que valida a Escala Visual Analógica (EVA).
- LIKERT, R. **A Technique for the Measurement of Attitudes**. Columbia university, 1932. (A Technique for the Measurement of Attitudes, Nº 136-165). Disponível em: <https://books.google.com.br/books?id=9rotAAAAYAAJ>.
- MAPIE Contributors. **MAPIE: Model Agnostic Prediction Interval Estimator**. 2021. <https://github.com/scikit-learn-contrib/MAPIE>. Acesso em: 31 out. 2025.
- MILEWSKI, M. D. et al. Chronic lack of sleep is associated with increased sports injuries in adolescent athletes. **Journal of Pediatric Orthopaedics**, v. 34, n. 2, p. 129–133, 2014.
- ORACLE. **Java Documentation**. 2024. <https://docs.oracle.com/en/java/>. Acesso em: 12 set. 2025.

PEREIRA, D. W.; NISTA-PICCOLO, V. L. Escalada: um esporte na ponta dos dedos. **Revista Brasileira de Ciência e Movimento**, v. 18, n. 1, p. 73–80, maio 2010.

RAMÍREZ, S. **FastAPI Documentation**. 2024. <https://fastapi.tiangolo.com/>. Acesso em: 12 set. 2025.

RAMÍREZ, S. **SQLModel Documentation**. 2024. <https://sqlmodel.tiangolo.com/>. Acesso em: 12 set. 2025.

SALIBA, G. F. **Prevalência de lesões musculoesqueléticas em escaladores**. 96 p. Dissertação (Dissertação (Mestrado em Ciências da Reabilitação)) — Centro Universitário Augusto Motta, Rio de Janeiro, 2021.

SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, v. 27, n. 3, p. 379–423, 1948. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/j.1538-7305.1948.tb01338.x>.

SQLAlchemy Project. **SQLAlchemy Documentation**. 2026. Acesso em: 7 jan. 2026. Disponível em: <https://docs.sqlalchemy.org/>.

UIAA, U. I. des Associations d'Alpinisme. **International Climbing and Mountaineering Federation**. 2025. Acesso em: 14 out. 2025. Disponível em: <https://www.theuiaa.org/grades-standards/rock-climbing/>.

VOVK, V.; GAMMERMAN, A.; SHAFER, G. **Algorithmic Learning in a Random World**. New York: Springer, 2005. ISBN 978-0-387-00152-4.

APÊNDICE A – HIERARQUIA DAS ÁREAS CORPORAIS MONITORADAS

A Tabela 1 apresenta a estrutura hierárquica completa utilizada para o registro anatômico das lesões e áreas de dor.

Tabela 1 – Hierarquia das áreas corporais monitoradas

Área Corporal N1	Área Corporal N2	Área Corporal N3
Cabeça e pescoço	Cabeça/face	Testa
		Nuca
	Pescoço/coluna cervical	Pescoço anterior
		Pescoço posterior
		Coluna cervical
		Trapézio direito
		Trapézio esquerdo
Membros superiores	Ombro/clavícula	Ombro direito
		Ombro esquerdo
		Clavícula direita
		Clavícula esquerda
		Escápula direita
		Escápula esquerda
	Braço	Bíceps direito
		Bíceps esquerdo
		Tríceps direito
		Tríceps esquerdo
	Cotovelo	Cotovelo direito
		Cotovelo esquerdo
	Antebraço	Antebraço direito anterior
		Antebraço direito posterior
		Antebraço esquerdo anterior
		Antebraço esquerdo posterior
	Punho	Punho direito
		Punho esquerdo
	Mão/dedos/polegar	Palma da mão direita
<i>Continua na próxima página</i>		

Tabela 1 – Continuação

Área Corporal N1	Área Corporal N2	Área Corporal N3
		Costa da mão direita
		Palma da mão esquerda
		Costa da mão esquerda
		Polegar direito
		Indicador direito
		Dedo médio direito
		Anelar direito
		Dedo mínimo direito
		Polegar esquerdo
		Indicador esquerdo
		Dedo médio esquerdo
		Anelar esquerdo
		Dedo mínimo esquerdo
Tronco	Esterno/costela/torácica	Esterno
		Costela direita
		Costela esquerda
		Tórax anterior
		Tórax posterior
		Coluna torácica
		Peitoral direito
		Peitoral esquerdo
	Abdome	Abdome superior
		Abdome inferior
		Abdome lateral direito
		Abdome lateral esquerdo
	Lombar/sacro	Lombar direita
		Lombar esquerda
		Sacro
		Cóccix
Membros inferiores	Quadril/virilha	Quadril direito
		Quadril esquerdo
		Virilha direita
		Virilha esquerda
		Glúteo direito
		Glúteo esquerdo
	Coxa	Coxa direita anterior
Continua na próxima página		

Tabela 1 – Continuação

Área Corporal N1	Área Corporal N2	Área Corporal N3
		Coxa direita posterior
		Coxa esquerda anterior
		Coxa esquerda posterior
	Joelho	Joelho direito
		Joelho esquerdo
		Patela direita
		Patela esquerda
	Perna/tendão calcâneo	Perna direita anterior
		Perna direita posterior
		Perna esquerda anterior
		Perna esquerda posterior
		Panturrilha direita
		Panturrilha esquerda
		Tendão calcâneo direito
		Tendão calcâneo esquerdo
	Tornozelo	Tornozelo direito
		Tornozelo esquerdo
		Maléolos direito
		Maléolos esquerdo
	Pé/dedos do pé	Dorso do pé direito
		Planta do pé direito
		Dorso do pé esquerdo
		Planta do pé esquerdo
		Calcanhar direito
		Calcanhar esquerdo
		Dedos do pé direito
		Dedos do pé esquerdo
		Hálux direito
		Hálux esquerdo

Fonte: Elaborado pelo autor (2025).

APÊNDICE B – DADOS ARMAZENADOS PARA TREINO DA INTELIGÊNCIA ARTIFICIAL

A Tabela 2 apresenta os dados numéricos de treino e estatísticas acerca deles.

Tabela 2 – Descrição das variáveis do conjunto de dados de treino

Variável	Descrição	Média	SD	CV (%)	Mín.	Máx.
IDADE	Idade do escalador (anos)	36,03	9,3	25,81	12,0	66,0
IMC	Índice de Massa Corporal	22,6	2,5	11,06	15,62	32,87
N_LESAO	Número de lesão por escalador	1,77	0,99	56,06	1,0	5,0
CLIMBER ENGAGEMENT	Índice de engajamento de escalada	0,24	0,07	30,07	0,04	0,5
CLIMBER ENGAGEMENT QTDE LESAO	Índice de engajamento de escalada	0,44	0,33	74,12	0,04	2,52
TEMPO DE AFASTAMENTO	Tempo de afastamento (dias)	2,38	2,07	87,09	0,0	7,0

Fonte: Elaborado pelo autor (2025)

APÊNDICE C – VARIÁVEIS BOOLEANAS DO CONJUNTO DE DADOS DE TREINO

A Tabela 3 apresenta as contagens e proporções dos valores dos dados booleanos de treino.

Tabela 3 – Distribuição das variáveis booleanas no conjunto de dados de treino

Variável	False (0)	True (1)
Diagnóstico NÃO	976 (67,68%)	466 (32,32%)
Diagnóstico SIM	466 (32,32%)	976 (67,68%)
Dor NÃO	869 (60,26%)	573 (39,74%)
Dor SIM	573 (39,74%)	869 (60,26%)
Lesão diagnosticada ARTROSE	1411 (97,85%)	31 (2,15%)
Lesão diagnosticada CISTO/SI- NOVITE/CAPSULITE	1432 (99,31%)	10 (0,69%)
Lesão diagnosticada CONTRA- TURA/CONTUSÃO	1381 (95,77%)	61 (4,23%)
Lesão diagnosticada ENTORSE	1324 (91,82%)	118 (8,18%)
Lesão diagnosticada EPICONDI- LITE	1439 (99,79%)	3 (0,21%)
Lesão diagnosticada ESTIRA- MENTO	1340 (92,93%)	102 (7,07%)
Lesão diagnosticada FRATURA	1375 (95,35%)	67 (4,65%)
Lesão diagnosticada HERNIAS DE DISCO	1423 (98,68%)	19 (1,32%)
Lesão diagnosticada LESÕES PATELARES/FASCITE PLAN- TAR	1419 (98,40%)	23 (1,60%)
Lesão diagnosticada OMBRO	1389 (96,32%)	53 (3,68%)
Lesão diagnosticada OUTRAS LESÕES NÃO DEFINIDAS	915 (63,45%)	527 (36,55%)
Local da lesão ANTEBRAÇO	1418 (98,34%)	24 (1,66%)
Local da lesão COTOVELO	1302 (90,29%)	140 (9,71%)
Local da lesão DEDO DA MÃO	1098 (76,14%)	344 (23,86%)
Local da lesão OMBRO	1140 (79,06%)	302 (20,94%)
<i>Continua na próxima página</i>		

Tabela 3 – Continuação

Variável	False (0)	True (1)
Modalidade ALTA COMPLEXIDADE	1392 (96,53%)	50 (3,47%)
Modalidade BOULDER	1165 (80,79%)	277 (19,21%)
Modalidade ESCALADA ESPORTIVA	1033 (71,64%)	409 (28,36%)
Modalidade MURO INDOOR	946 (65,60%)	496 (34,40%)
Profissional de tratamento FISIOTERAPEUTA	1068 (74,06%)	374 (25,94%)
Profissional de tratamento ORTOPEDISTA	963 (66,78%)	479 (33,22%)
Recidiva NÃO	560 (38,83%)	882 (61,17%)
Recidiva SIM	882 (61,17%)	560 (38,83%)
Sexo FEMININO	1028 (71,29%)	414 (28,71%)

Fonte: Elaborado pelo autor (2025)

APÊNDICE D – TERMOS E CONDIÇÕES DE USO DO APLICATIVO

Ao utilizar o aplicativo **EscalAI**, o usuário concorda com os termos descritos neste documento. Caso não concorde, recomenda-se não utilizar o aplicativo.

1. SOBRE O APLICATIVO

O **EscalAI** é um aplicativo desenvolvido exclusivamente para fins acadêmicos, como parte de um Trabalho de Conclusão de Curso (TCC).

O objetivo do aplicativo é:

- Registrar treinos e informações de saúde esportiva relacionadas à escalada;
- Acompanhar lesões e hábitos que influenciam prevenção e recuperação;
- Utilizar um modelo experimental de Inteligência Artificial para estimar tempo de recuperação de lesões.

Atenção: O aplicativo não substitui avaliação médica ou profissional da saúde.

2. PÚBLICO-ALVO

O uso do aplicativo é permitido apenas para usuários com idade igual ou superior a 18 anos.

3. INFORMAÇÕES COLETADAS

O aplicativo coleta os seguintes dados:

Dados pessoais de identificação

- Nome
- E-mail
- Telefone

Finalidade:

- Autenticação e manutenção da conta;
- Possibilidade de comunicação com o usuário, quando necessário.

Esses dados:

- Não serão utilizados para treinar a Inteligência Artificial;
- Não serão utilizados em pesquisas científicas;
- Não serão compartilhados com terceiros.

Dados de uso e esportivos

- Idade e sexo;
- Informações sobre treinos;
- Ocorrência e tipo de lesões;
- Hábitos de saúde (ex.: sono e hidratação);
- Modalidade e frequência de prática de escalada.

Esses dados serão utilizados para:

- Funcionamento do aplicativo;
- Treinamento e evolução do modelo de Inteligência Artificial;
- Pesquisa científica acadêmica, exclusivamente para o TCC.

Esses dados serão sempre:

- Anonimizados;
- Não associados ao nome, e-mail ou telefone do usuário;
- Utilizados apenas para fins acadêmicos.

4. SEGURANÇA DOS DADOS

Os dados são armazenados em servidor privado mantido pelo desenvolvedor para fins acadêmicos.

Medidas adotadas:

- Controle de acesso ao banco de dados;
- Separação entre dados pessoais e dados utilizados para pesquisa.

5. INTELIGÊNCIA ARTIFICIAL E RESPONSABILIDADE

As previsões realizadas pelo aplicativo são estimativas experimentais e podem conter erros.

O sistema:

- Atua somente como ferramenta de apoio e monitoramento;
- Não oferece diagnóstico, tratamento, prescrição ou orientação médica.

O usuário deve sempre procurar um profissional de saúde para avaliação e tratamento quando necessário.

6. LIMITAÇÃO DE RESPONSABILIDADE

O usuário reconhece que:

- O aplicativo é experimental;
- Podem ocorrer falhas ou imprecisões;
- A utilização é voluntária e sob responsabilidade exclusiva do usuário;
- O desenvolvedor e a instituição acadêmica não se responsabilizam por decisões tomadas com base nas informações fornecidas pelo aplicativo.

7. EXCLUSÃO E RETENÇÃO DE DADOS

- O usuário pode solicitar a exclusão de dados pessoais (nome, e-mail e telefone);
- Dados acadêmicos anonimizados já utilizados em pesquisas não podem ser vinculados ao usuário e poderão ser mantidos para fins científicos.

Solicitações devem ser feitas pelo e-mail: **escalai@gmail.com**.

8. ACEITAÇÃO DOS TERMOS

Ao utilizar o **EscalAI**, o usuário declara ter lido e concordado integralmente com estes termos.