

Previsão de lesões de esportistas utilizando técnicas de aprendizagem de máquina em uma revisão de literatura

João Vítor Corrêa Soares¹

¹Centro de Informatica – Universidade Federal da Paraíba (UFPB)

João Pessoa – PB – Brasil

joaovitorsoares0802@gmail.com

Abstract. *Sports injuries pose a significant concern within collective sports, leading to a growing demand for tools that aid in predicting such occurrences. This article presents a literature review focused on the application of Machine Learning in predicting injuries among athletes in collective sports, encompassing studies published between 2018 and 2025. A total of 21 articles were analyzed, revealing diversity in the Machine Learning algorithms employed, including Random Forest, Decision Tree, Neural Networks, and Time Series Analysis. The main factors considered in the predictions include training load, individual athlete characteristics, and psychological aspects. Results indicate that, despite the promising potential of these approaches, limitations persist regarding the quality of the data used in model development and the lack of external validation to confirm prediction efficacy in practical contexts. The study also explores the application of similar models in injury rehabilitation through movement monitoring. Finally, it is recommended that data collection methods be standardized and that the interpretability of predictions be enhanced through Explainable AI techniques.*

Resumo. *As lesões esportivas representam uma preocupação significativa no contexto dos esportes, gerando uma demanda crescente por ferramentas que auxiliem na previsão dessas ocorrências. Este artigo apresenta uma revisão da literatura, focada na aplicação de Aprendizado de Máquina, na previsão de lesões em atletas, abrangendo estudos publicados entre 2018 e 2025. Foram analisados 21 artigos, revelando uma diversidade nos algoritmos de Aprendizado de Máquina empregados, incluindo Floresta aleatória, Árvore de decisão, Redes Neurais e Análise de Séries Temporais com redes Memória de Longo e Curto Prazo. Os principais fatores considerados nas previsões incluem carga de treino, características individuais dos atletas e aspectos psicológicos. Os resultados sugerem que, apesar do potencial promissor dessas abordagens, existem limitações relacionadas à qualidade dos dados utilizados na construção dos modelos e à falta de validação externa, que confirme a eficácia das previsões em contextos práticos. O estudo também explora a aplicação de modelos similares na reabilitação de lesões, por meio do monitoramento de movimentos. Por fim, recomenda-se a padronização dos métodos de coleta de dados e a melhoria da interpretabilidade das previsões, por meio de técnicas de Inteligência Artificial Explicável.*

Catálogo na publicação
Seção de Catalogação e Classificação

S676p Soares, João Vítor Corrêa.

Previsão de lesões de esportistas utilizando técnicas de aprendizagem de máquina em uma revisão de literatura / João Vítor Corrêa Soares. - João Pessoa, 2025.

16 f.

Orientação: Thaís Gaudencio do Rêgo.

TCC (Graduação) - UFPB/CI.

1. Inteligência artificial. 2. Previsão de lesões esportivas. 3. Aprendizagem de máquina. 4. Esportes de alto rendimento. I. Rêgo, Thaís Gaudencio do. II. Título.

UFPB/CI

CDU 004.8

1. Introdução:

No esporte de alta intensidade, as lesões representam uma das maiores preocupações para atletas e instituições esportivas, pois, dependendo de sua gravidade, podem impactar significativamente a carreira dos atletas, a performance das equipes e até a economia da indústria esportiva. Um estudo de 2015, por exemplo, apontou que o impacto financeiro das lesões nas quatro principais ligas de futebol profissional alcançou 14 milhões de dólares naquele ano [1].

Em resposta a esse desafio, a medicina esportiva tem avançado no tratamento e na prevenção de lesões, integrando exames como hemogramas, eletrocardiogramas, radiografias e ressonâncias magnéticas na rotina dos atletas [1, 5, 13]. Além disso, há um monitoramento rigoroso da carga de treinamento, com o objetivo de manter os atletas em forma, sem sobrecarregar músculos e articulações. No entanto, mesmo com esses avanços, a alta incidência de lesões continua sendo uma preocupação constante no cenário esportivo.

Com o desenvolvimento de tecnologias de inteligência artificial (IA), especialmente o aprendizado de máquina (do inglês, *Machine Learning* - ML), surgiu a recomendação de utilizar essas ferramentas como aliadas na previsão de lesões no esporte profissional [2]. O ML, um ramo da IA, consiste no desenvolvimento de algoritmos capazes de aprender a partir de dados e tomar decisões baseadas nesses padrões [3]. Para obter resultados, é fundamental a utilização de bases de dados de alta qualidade, contendo informações relevantes para a previsão de lesões.

Este artigo tem como objetivo realizar uma revisão da literatura sobre o uso do ML na previsão de lesões em esportes de alto rendimento. A intenção é compreender o estado atual da aplicação dessas tecnologias, identificar suas limitações e sugerir possíveis áreas de aprimoramento.

2. Métodos:

Esta seção descreve os métodos empregados na condução da pesquisa e seleção dos estudos utilizados nesta revisão de literatura. São detalhadas as estratégias de busca, as palavras-chave utilizadas e os critérios de inclusão e exclusão adotados, para garantir a relevância e qualidade dos artigos selecionados.

2.1. Estratégia de Pesquisa:

Para a seleção dos estudos, utilizou-se a ferramenta de busca Google Scholar, com foco em artigos publicados entre 2018 e 2025. A estratégia de busca envolveu o uso de palavras-chave em inglês e português, com o objetivo de abranger uma amostra representativa e internacional da literatura disponível. Entre os termos empregados destacam-se: “machine learning” ou “aprendizado de máquina”, “AI”, “artificial intelligence”, “IA” ou “inteligência artificial”, “sports” ou “esportes”, “players”, “esportistas” ou “jogadores”, “sports analytics” ou “análise de esportes”, “data science” or “ciência de dados”, “injury risk” or “risco de lesão” e “injury prediction” or “prevenção de lesão”. A utilização dessas palavras-chave permitiu refinar os resultados da busca e garantir que os artigos selecionados refletissem o uso contemporâneo da IA no contexto dos esportes.

2.2. Critérios de inclusão e exclusão:

Os critérios de inclusão foram: (1) artigos que abordassem a aplicação de técnicas de IA no contexto esportivo; (2) que envolvessem a análise de lesões ou a previsão de desempenho atlético; (3) que possuem foco em dados reais relacionados aos atletas. Em contrapartida, os critérios de exclusão foram: (1) estudos que não abordassem diretamente a área esportiva; (2) artigos que não apresentassem relação com o uso de IA; (3) exclusão de estudos que utilizassem unicamente métodos estatísticos tradicionais, sem empregar algoritmos de ML; (4) estudos que não considerassem atletas em contexto competitivo. Além disso, não foram realizadas restrições quanto aos esportes abordados pelos artigos.

Essa estratégia visou garantir uma revisão abrangente e precisa, capturando os avanços na aplicação de IA, para a previsão e prevenção de lesões no esporte de alto rendimento, de modo a mapear o estado atual da pesquisa na área.

2.3. Análise do processo de filtragem

A partir da aplicação das palavras-chave previamente definidas, foram identificados, inicialmente, 145 artigos. Após a remoção de duplicatas e a aplicação dos critérios de inclusão e exclusão, esse número foi progressivamente reduzido. Adicionalmente, foram considerados critérios complementares de relevância, como o número de citações, sendo priorizados estudos com mais de 10 citações, a fim de assegurar seu impacto e reconhecimento na área. Ao término desse processo de triagem e refinamento, foi definida a amostra final de estudos que compõem a presente revisão.

2.4. Artigos selecionados:

Após a pesquisa inicial, foram selecionados 21 artigos científicos para compor a base desta revisão de literatura, sobre o uso de IA na previsão de lesões em atletas de esportes profissionais. Dentre esses, 7 artigos se enquadram como revisões de literatura, oferecendo um panorama dos desenvolvimentos tecnológicos aplicados nos últimos anos. Esses artigos fornecem uma visão geral das tendências de pesquisa e dos desafios enfrentados pela comunidade científica, na tentativa de aprimorar a precisão dos modelos de previsão de lesões.

Entre os restantes, 7 artigos são estudos empíricos que propõem e avaliam diferentes abordagens de inteligência artificial para a previsão de lesões, utilizando algoritmos de aprendizado de máquina supervisionado como árvores de decisão, regressão logística e redes neurais e, em menor escala, técnicas não supervisionadas. Esses estudos foram selecionados por seu rigor metodológico e relevância para o tema, destacando-se pela aplicação de modelos preditivos em contextos esportivos profissionais, como futebol, basquete e outras modalidades de alto rendimento.

Por fim, os 7 artigos adicionais são pesquisas que, embora não focadas diretamente na aplicação de IA para a previsão de lesões, oferecem informações relevantes para a compreensão do contexto esportivo e da utilização de tecnologias avançadas para monitoramento e análise de desempenho. Esses estudos fornecem uma base complementar às reflexões desta revisão, contribuindo para o entendimento do papel da IA no gerenciamento de riscos de lesões em atletas profissionais.

Além disso, pode-se citar que os artigos utilizados foram todos lançados no período de 2018 até 2025 com o objetivo de filtrar as pesquisas mais atuais relacionadas ao tema desta revisão. Outra informação importante é que os artigos utilizados foram publicados em revistas de diversos países diferentes como a “Mobile Information Systems”, do Reino Unido, a “SciTePress”, de Portugal, o “Journal of Sports Science and Medicine”, da Turquia, a “Frontiers in Psychology”, que se encontra na Suíça e “The American Journal of Sports Medicine”, dos Estados Unidos.

Dentre os artigos apresentando estudos empíricos, há uma variedade entre os esportes abordados por eles como mostra o gráfico abaixo:

Figura 1. Gráfico com Variedade de Esportes



Fonte: Autoria Própria (2025)

A análise do gráfico revela uma predominância de estudos direcionados ao futebol. Tal concentração pode ser atribuída à ampla popularidade da modalidade em nível global, bem como à sua natureza física, caracterizada por frequentes contatos e impactos, os quais aumentam o risco de lesões. Nesse contexto, a previsão de lesões desponta como um tema relevante na literatura, visando à redução dos impactos negativos decorrentes dessas ocorrências, tanto no desempenho esportivo, quanto nos aspectos econômicos associados.

3. Resultados:

Nesta seção, são apresentados e discutidos os artigos selecionados para a revisão de literatura. Além da classificação dos tipos de estudos analisados, detalha-se como cada um contribui para o entendimento das aplicações de IA na previsão e prevenção de lesões em atletas. Os artigos são agrupados de acordo com os métodos de ML empregados, com foco nas suas aplicações e resultados, incluindo também uma análise das limitações enfrentadas e das possíveis melhorias sugeridas pelos autores.

3.1. Fatores levados em consideração no desenvolvimento:

Após análise dos artigos escolhidos, foi identificado que os estudos analisados concentram-se no desenvolvimento de ferramentas de predição de lesões em atletas por meio de técnicas de ML, com foco em lesões não contusas, ou seja, aquelas que não resultam de impactos diretos. Essa escolha se justifica pelo fato de que, embora as lesões decorrentes de contusões representem cerca de 60% dos acidentes em esportes de contato, como basquete e futebol, tais colisões são, em sua maioria, imprevisíveis e inevitáveis [6,19].

Os artigos revisados destacam a importância de diversos fatores que influenciam o risco de lesões, incluindo aspectos externos, como problemas relacionados ao treinamento e ao sobre-treinamento [6, 9, 20], e características individuais dos atletas, como idade, peso, nutrição, tipos de movimento realizados e até o estado psicológico [9, 10, 11, 15].

De acordo com o artigo de revisão intitulado “Machine Learning Applications to Sports Injury: A Review” [16], a maioria das aplicações de ML voltadas para a previsão de lesões enfoca fatores relacionados ao atleta. Isso ocorre em função do avanço das ciências do esporte e da análise de dados, que têm promovido o uso de dispositivos de monitoramento para os atletas, tanto durante as atividades em campo, quanto fora dele. Esses dispositivos coletam informações relevantes, como a frequência cardíaca durante *sprints* e a distância percorrida em cada jogo, possibilitando a geração de dados importantes para o desenvolvimento de modelos preditivos [6, 14, 15, 20].

Apesar da crescente atenção à individualização das análises, a carga de treino e de minutos jogados continua sendo um fator amplamente reconhecido na etiologia das lesões de tecidos moles. Atletas de basquete que ultrapassam a carga de 100 minutos jogados, nos últimos 3 jogos, têm mais chances de sofrer lesões de tecidos moles não relacionadas a contatos, em comparação com aqueles que mantêm essa carga dentro dos limites recomendados. Essa relação direta reforça a importância do monitoramento da carga de treinamento e de minutos jogados no contexto da prevenção de lesões [6].

3.2. Modelos Preditivos de Lesões em Atletas

Na análise dos estudos que utilizaram ML para a predição de lesões, destacam-se algoritmos como Floresta Aleatória e Árvore de decisão. Esses algoritmos foram empregados para identificar as variáveis mais relevantes e aumentar a acurácia da previsão em modelos que lidam com grandes conjuntos de dados. Exemplos dessa abordagem incluem os estudos “A Field-Based Approach to Determine Soft Tissue Injury Risk in Elite Futsal Using Novel Machine Learning Techniques” [14], “A

Preventive Model For Hamstring Injuries in Professional Soccer: Learning Algorithms” [9] e “Predicting ACL injury using machine learning on data from an extensive screening test battery of 880 female elite athletes” [11].

Além disso, as Redes Neurais Artificiais (ANNs) foram utilizadas para capturar relações não lineares entre variáveis, como entre os dados fisiológicos dos atletas e o risco de lesão [6, 20]. Frequentemente, essas redes foram combinadas com Máquinas de Vetor de Suporte (do inglês, *Support Vector Machines* - SVM), que se mostraram eficazes para separar grupos de atletas em risco de lesão, daqueles que não apresentam tal risco, facilitando as decisões dos modelos preditivos [15, 14, 11]. Um exemplo é o estudo “Predicting Injury and Illness with Machine Learning in Elite Youth Soccer” [15], que utilizou essas técnicas não apenas para prever lesões, mas também para monitorar o risco de doenças, utilizando variáveis como a qualidade do sono e a frequência cardíaca dos atletas.

Um dos métodos de previsão que mais se destaca é a aprendizagem profunda (do inglês, *Deep Learning* – DL), conforme exemplificado no estudo “A deep learning approach to injury forecasting in NBA basketball” [6]. Neste trabalho, os autores empregam um modelo de DL, baseado na arquitetura denominada “METIC”, capaz de processar variáveis como histórico de lesões, estatísticas individuais dos jogadores e dados de atividades durante os jogos, com o objetivo de prever o risco de lesões futuras.

Outra abordagem identificada foi o uso de Análise de Séries Temporais com redes Memória de Longo e Curto Prazo (do inglês, *Long Short-Term Memory* - LSTM). Esse método permite acompanhar a evolução do risco de lesão ao longo do tempo, de acordo com as mudanças nos dados de cada atleta. O artigo “Sports Injury Rehabilitation Intervention Algorithm Based on Visual Analysis Technology” [20] demonstra o uso do LSTM como uma técnica de reconhecimento de ações humanas a partir de dados sensoriais, comparando seu desempenho com outras arquiteturas de redes neurais, como Redes Neurais Convolucionais (do inglês, *Convolutional Neural Network* - CNN). O objetivo é identificar movimentos relacionados a lesões esportivas, contribuindo para a detecção e prevenção de riscos.

Por fim, o algoritmo Agrupamento *K-Means* foi empregado de forma mais específica, como no estudo “Predicting Injury and Illness with Machine Learning in Elite Youth Soccer: A Comprehensive Monitoring Approach over 3 Months” [15]. Neste caso, o *K-Means* foi utilizado para agrupar os jogadores em grupos de acordo com variáveis como aptidão física, estado de saúde e perfil de recuperação dos

jogadores .

A distribuição e frequência dos métodos de IA usados nos artigos pode ser visualizada na tabela abaixo:

Tabela 1. Tabela com métodos de IA utilizados nos artigos

Método	Frequência	Artigos
SVM	3	[15,14, 11]
Árvore de Decisão	3	[14, 9, 11]
<i>K-Means</i>	1	[15]
AdaBoost	1	[14]
KNN	1	[14]
SMOTE	1	[9]
Floresta Aleatória	1	[11]
CNN	1	[20]
METIC	1	[6]
Classificação de texto	1	[10]
ANN's	2	[6, 20]
LSTM	1	[20]

Fonte: Autoria Própria (2025)

3.2. Aplicação na Reabilitação de Atletas

Além da utilização de modelos de ML para prever lesões, essa tecnologia também está sendo aplicada para auxiliar na recuperação de atletas. Um exemplo disso é o estudo "Sports Injury Rehabilitation Intervention Algorithm Based on Visual Analysis Technology" [20], no qual os pesquisadores empregaram técnicas de análise visual, para monitorar os movimentos corporais dos atletas durante a reabilitação. O método utilizado no estudo reconhece o corpo humano em vídeos, extraindo informações detalhadas sobre a estrutura esquelética. A partir da identificação dos pontos articulares, os movimentos dos atletas são acompanhados em tempo real, permitindo a detecção de variações nos padrões de movimento.

Essas variações são analisadas por meio do algoritmo *K-Means*, mencionado anteriormente na Seção 3.2 deste artigo, para agrupar atletas com padrões

semelhantes de movimento e recuperação. Com base nessas análises, os planos de treinamento e reabilitação podem ser ajustados de forma personalizada, melhorando a eficácia das intervenções e reduzindo o risco de reincidência de lesões. Esse uso de ML tem o objetivo de realizar um acompanhamento mais adaptativo do processo de recuperação, beneficiando a reabilitação ao otimizar os exercícios, de acordo com as necessidades individuais de cada atleta.

3.3. Nível de sucesso dos modelos estudados

Para avaliar o nível de sucesso dos modelos preditivos, é essencial entender os conceitos de Curva característica de operação do receptor (do inglês, *Receiver Operating Characteristic Curve* - ROC) e Área abaixo da curva COR (do inglês, *Area Under the ROC Curve* - AUC). A curva ROC traça uma comparação entre a taxa de falsos positivos (FP) e a taxa de verdadeiros positivos (VP) de um modelo, enquanto a AUC quantifica a área abaixo dessa curva, variando de 0,0 a 1,0. Quanto mais próxima de 1,0 for a AUC, melhor é a capacidade do modelo de distinguir entre classes e, portanto, maior sua precisão preditiva.

A análise dos estudos revisados mostrou que os níveis de sucesso variam significativamente, de acordo com os métodos de ML utilizados em cada modelo. Um exemplo disso é encontrado no estudo "A Preventive Model For Hamstring Injuries in Professional Soccer: Learning Algorithms" [9], que alcançou uma AUC de 0,837, indicando uma precisão considerada pelos autores do artigo como alta na previsão de lesões no tendão isquiotibial, utilizando os algoritmos de Floresta de decisão aleatória e Árvore de decisão. Esse resultado destaca a robustez do modelo e sua capacidade de identificar jogadores com alto risco de lesão.

Por outro lado, o artigo "A Deep Learning Approach to Injury Forecasting in NBA Basketball" [6] demonstra que o modelo desenvolvido atingiu uma precisão considerável na previsão de lesões, com diferentes métricas de desempenho, incluindo uma alta taxa de acurácia (por exemplo, até 99,8%) e áreas sob a curva ROC que variam de acordo com o tipo de lesão. Embora não forneça uma única métrica de AUC para todas as categorias, os resultados indicam um nível de precisão que supera a simples intuição humana na previsão de lesões. Além disso, o estudo enfatiza a importância de identificar fatores de risco, como cargas de treino e minutos jogados, contribuindo para intervenções mais eficazes na gestão da carga de treino e prevenção de lesões em atletas profissionais.

No estudo "A Field-Based Approach to Determine Soft Tissue Injury Risk in Elite

Futsal Using Novel Machine Learning Techniques" [14], os resultados mostraram um AUC variando entre 0,701 e 0,767. O modelo apresentou uma taxa de VP de 85% e uma taxa de verdadeiros negativos (TN) de 62%, sugerindo uma capacidade promissora de prever lesões em jogadores de futsal. Além disso, o modelo é de fácil implementação, pois utiliza medidas simples de amplitude de movimento (do inglês, *Range of movement* - ROM) e pode ser aplicado rapidamente, mostrando bom potencial para uso prático.

Outros estudos, embora não tenham fornecido métricas específicas de AUC, sugerem melhorias nas previsões de lesões. O artigo "Sports Injury Rehabilitation Intervention Algorithm Based on Visual Analysis Technology" [20] propôs um modelo baseado em análise visual, que demonstrou ser eficaz no reconhecimento de padrões de movimento, auxiliando na reabilitação de lesões. Similarmente, o estudo "Predicting Injury and Illness with Machine Learning in Elite Youth Soccer: A Comprehensive Monitoring Approach over 3 Months" [15] indicou que o uso de um monitoramento holístico ao longo do tempo pode melhorar a previsão de lesões e doenças, embora a precisão do modelo possa ser refinada com mais dados e um período de estudo maior.

No artigo "Prediction Model of Juvenile Football Players' Sports Injury Based on Text Classification Technology of Machine Learning" [10], a inovação do modelo estava na extração de características através da classificação de texto, o que resultou em melhorias na previsão de lesões. No entanto, os autores indicam que mais dados são necessários para validar o modelo em cenários reais, especialmente devido ao pequeno número de amostras.

Por fim, o estudo "Predicting ACL Injury Using Machine Learning on Data From an Extensive Screening Test Battery of 880 Female Elite Athletes" [11] apresentou uma conclusão mais crítica. Apesar de utilizar um conjunto de dados abrangente com diversas variáveis (antropométricas, clínicas, genéticas, neuromusculares e biomecânicas), a capacidade preditiva do modelo para lesões no ligamento cruzado anterior (LCA) foi considerada insuficiente para aplicação clínica. Isso ressalta a dificuldade em desenvolver modelos precisos para lesões complexas, como as de LCA, e aponta a necessidade de mais estudos para determinar que tipos de dados e abordagens de ML seriam mais eficazes.

3.4. Desafios e limitações

Apesar dos resultados promissores, diversos desafios e limitações foram identificados, dificultando a implementação efetiva dessa tecnologia no ambiente esportivo. Um dos principais obstáculos é a qualidade e uniformidade dos dados

utilizados nas pesquisas. Os dados variaram significativamente em termos de qualidade entre os estudos, o que compromete a consistência dos resultados. Além disso, a grande heterogeneidade dos dados (diferentes fontes, métodos de coleta e variáveis consideradas) dificulta a replicação das previsões em diferentes grupos de atletas, ou em novos contextos esportivos.

Outro desafio crítico é a falta de validação externa nos estudos analisados. Nenhum dos artigos revisados realizou testes em populações externas para verificar se os modelos desenvolvidos podem ser generalizados para outros grupos de atletas ou modalidades esportivas. Isso levanta preocupações sobre a capacidade de adaptação dos modelos em cenários reais, onde as condições podem variar substancialmente.

Além disso, a complexidade inerente a muitos dos modelos de ML como redes neurais profundas, traz desafios relacionados à interpretabilidade. Embora esses modelos possam apresentar alta precisão preditiva, a dificuldade em explicar os padrões e as razões por trás das previsões torna sua aplicação mais difícil no cotidiano de equipes médicas e de treinamento. Sem uma compreensão clara dos fatores que influenciam as decisões dos modelos, profissionais de saúde e treinadores podem hesitar em adotar plenamente essas ferramentas para orientar intervenções preventivas ou terapêuticas.

3.5. Melhorias possíveis e Perspectivas futuras

Diante das limitações identificadas, torna-se imprescindível uma melhor organização no desenvolvimento de modelos preditivos. Um dos passos fundamentais é a padronização dos métodos de coleta de dados nas pesquisas, visando garantir a qualidade e a uniformidade das bases de dados utilizadas. Essa padronização contribuirá para aumentar a confiabilidade dos resultados obtidos e facilitar a comparação entre diferentes estudos.

Além disso, é crucial realizar testes externos com os modelos existentes e aqueles que vierem a ser desenvolvidos, aplicando-os em populações de atletas distintas daquelas utilizadas para a criação dos modelos. Esses testes também devem ser expandidos para atletas de outras modalidades esportivas, o que permitirá validar a generalização dos modelos e facilitar sua aplicação prática no esporte.

Outro ponto de destaque é a necessidade da adoção de técnicas de IA explicável, que ajudam a interpretar os resultados e esclarecem o papel de cada variável na tomada de decisão dos modelos. Exemplos dessas técnicas incluem explicações agnósticas de modelos interpretáveis locais (do inglês, *Local Interpretable*

Model-agnostic Explanations - LIME), Explicações Aditivas de Shapley (do inglês, *SHapley Additive exPlanations* - SHAP) e Mapas de Saliência. O uso dessas abordagens melhora a transparência dos modelos, promovendo maior confiança em suas previsões.

Por fim, o uso crescente de tecnologias de monitoramento em tempo real, como sensores vestíveis e dispositivos GPS, tem contribuído significativamente para a melhoria da qualidade dos dados utilizados no treinamento de modelos de ML, como destacado no estudo “Predicting ACL Injury Using Machine Learning on Data From an Extensive Screening Test Battery of 880 Female Elite Athletes” [11]. Esses dispositivos permitem a coleta de dados mais precisos e detalhados, favorecendo tanto o avanço das pesquisas na área, quanto a realização de ajustes mais eficazes nas cargas de treino, o que potencializa a eficácia dos modelos preditivos.

4. Conclusão

A revisão de literatura sobre o uso de ML para a previsão de lesões em atletas de alto nível evidenciou um campo tecnicamente promissor e em constante progresso. Os avanços tecnológicos nessa área demonstram um potencial transformador para a medicina esportiva, permitindo maior segurança e qualidade de vida para os atletas, além de uma gestão mais eficiente da performance e saúde.

Os métodos de ML investigados, como Floresta de Decisão Aleatória, Árvore de Decisão, CNNs e técnicas de classificação de texto, ilustram a capacidade dessa tecnologia de prever lesões com variados níveis de eficácia. No entanto, a diversidade de abordagens reflete a necessidade urgente de padronização nos processos e aprimoramento na eficiência dos modelos. Além disso, desafios como a heterogeneidade dos dados, a ausência de validação externa e a dificuldade em interpretar modelos mais complexos devem ser superados, para que tais tecnologias possam ser aplicadas, de forma consistente, em contextos clínicos.

Por outro lado, estudos como “A Preventive Model For Hamstring Injuries in Professional Soccer: Learning Algorithms” [9] e “A Field-Based Approach to Determine Soft Tissue Injury Risk in Elite Futsal Using Novel Machine Learning Techniques” [14] reportaram resultados promissores. Esses modelos, apesar de ainda apresentarem limitações, demonstraram uma precisão moderada a alta, indicando seu potencial como ferramentas valiosas no monitoramento e prevenção de lesões por equipes médicas.

Além da previsão de lesões, as tecnologias de ML também têm mostrado impacto

positivo no processo de reabilitação. O estudo “Sports Injury Rehabilitation Intervention Algorithm Based on Visual Analysis Technology” [20] utilizou análise visual para monitorar e aprimorar a recuperação de atletas lesionados. Embora ajustes ainda sejam necessários para melhorar a acurácia do modelo, essa abordagem ressalta o potencial dessas tecnologias na otimização dos processos de reabilitação.

Em síntese, o campo de ML aplicado à medicina esportiva, apresenta uma perspectiva técnica bastante promissora. O avanço dessa área dependerá não apenas do avanço das técnicas de ML, mas também da adoção prática dessas ferramentas por profissionais da saúde e equipes técnicas. À medida que os modelos se tornem mais interpretáveis e sejam validados em cenários clínicos, sua aplicação poderá se consolidar como essencial na prevenção, tratamento e reabilitação de lesões esportivas.

Referências:

1. GUEST, S. A. P. SAP BrandVoice: The crippling cost of sports injuries. *Forbes*. Disponível em: <https://www.forbes.com/sites/sap/2015/08/11/the-crippling-cost-of-sports-injuries/>. Acesso em: 22 jul. 2021.
2. BEAL, R.; NORMAN, T. J.; RAMCHURN, S. D. Artificial intelligence for team sports: A survey. *The Knowledge Engineering Review*, v. 34, 2019. Disponível em: <https://doi.org/10.1017/S0269888919000225>.
3. KUHN, M.; JOHNSON, K. *Applied predictive modeling*. New York: Springer, 2013.
4. VAN EETVELDE, H. et al. Machine learning methods in sport injury prediction and prevention: a systematic review. *Journal of Experimental Orthopaedics*, v. 8, p. 27, 2021. Disponível em: <https://doi.org/10.1186/s40634-021-00346-x>.
5. CLAUDINO, J. G. et al. Current approaches to the use of artificial intelligence for injury risk assessment and performance prediction in team sports: a systematic review. *Sports Medicine - Open*, v. 5, p. 28, 2019. Disponível em: <https://doi.org/10.1186/s40798-019-0202-3>.
6. COHAN, Alexander; SCHUSTER, Jake; FERNANDEZ, Jose. A deep learning approach to injury forecasting in NBA basketball. *Journal of Sports Analytics*, v. 7, n. 2, p. 277-289, 2021. DOI: 10.3233/JSA-200529.
7. RICHTER, C.; O'REILLY, M.; DELAHUNT, E. Machine learning in sports science: challenges and opportunities. *Sports Biomechanics*, v. 23, n. 8, p. 961–967, 2021. Disponível em: <https://doi.org/10.1080/14763141.2021.1910334>.
8. AMENDOLARA, A. et al. An overview of machine learning applications in sports injury prediction. *Cureus*, v. 15, n. 9, e46170, 2023. DOI: <10.7759/cureus.46170>.
9. AYALA, F. et al. A preventive model for hamstring injuries in professional soccer: Learning algorithms. *International Journal of Sports Medicine*, v. 40, n. 05, p. 344-353, 2019.

10. HE, K. Prediction model of juvenile football players' sports injury based on text classification technology of machine learning. *Mobile Information Systems*, 2021, 2955215, 10 p. Disponível em: <https://doi.org/10.1155/2021/2955215>.
11. JAUHIAINEN, S. et al. Predicting ACL injury using machine learning on data from an extensive screening test battery of 880 female elite athletes. *The American Journal of Sports Medicine*, v. 50, n. 11, p. 2917-2924, 2022. DOI: <10.1177/03635465221112095>.
12. MAJUMDAR, A. et al. Machine learning for understanding and predicting injuries in football. *Sports Medicine - Open*, v. 8, p. 73, 2022. Disponível em: <https://doi.org/10.1186/s40798-022-00465-4>.
13. EDOUARD, P.; VERHAGEN, E.; NAVARRO, L. Machine learning analyses can be of interest to estimate the risk of injury in sports injury and rehabilitation. *Annals of Physical and Rehabilitation Medicine*, v. 65, n. 4, 2022. p. 101431.
14. RUIZ-PÉREZ, I. et al. A field-based approach to determine soft tissue injury risk in elite futsal using novel machine learning techniques. *Frontiers in Psychology*, v. 12, 2021. p. 610210.
15. HALLER, N. et al. Predicting injury and illness with machine learning in elite youth soccer: A comprehensive monitoring approach over 3 months. *Journal of Sports Science and Medicine*, v. 22, n. 3, p. 476-487, 2023. DOI: <10.52082/jssm.2023.476>.
16. SIGURDSON, H.; CHAN, J. H. Machine learning applications to sports injury: A review. *icSPORTS*, v. 2021, p. 157-168, 2021.
17. HAMMES, F. et al. Artificial Intelligence in Elite Sports—A Narrative Review of Success Stories and Challenges. *Frontiers in Sports and Active Living*, v. 4, p. 861466, 2022. DOI: 10.3389/fspor.2022.861466.
18. BARTLETT, R. Artificial intelligence in sports biomechanics: new dawn or false hope? *Journal of Sports Science and Medicine*, v. 5, n. 4, p. 474-479, 2006.
19. GISSANE, C. et al. Injury rates in rugby league football: Impact of change in playing season. *The American Journal of Sports Medicine*, v. 31, p. 954-958, 2003.

20. CHEN, X.; YUAN, G. Sports injury rehabilitation intervention algorithm based on visual analysis technology. *Mobile Information Systems*, 2021, 9993677, 8

p. Disponível em: <https://doi.org/10.1155/2021/9993677>.

21. CLOSE, G. L.; SALE, C.; BAAR, K.; BERMON, S. Nutrition for the prevention and treatment of injuries in track and field athletes. *International Journal of Sport Nutrition and Exercise Metabolism*, v. 29, n. 2, p. 189-197, 2019.

Disponível em: <https://doi.org/10.1123/ijsnem.2018-0290>.