

# ANÁLISE NOTACIONAL E APRENDIZADO DE MÁQUINAS NO CENÁRIO ESPORTIVO

 <https://doi.org/10.22533/at.ed.764122513053>

*Data de aceite: 18/06/2025*

**Rodney C. Paixão**

**Guilherme G. De Agostini**

## 1. A EVOLUÇÃO DA ANÁLISE DO DESEMPENHO ESPORTIVO

A análise do desempenho esportivo tem se consolidado como uma importante área para o avanço do esporte de alto rendimento (treinamento e competição) e da pesquisa acadêmica. Nas últimas décadas, diversos métodos têm sido aplicados para estudar o desempenho de atletas e equipes, com a análise notacional e o aprendizado de máquinas ocupando papéis centrais nesse contexto.

A análise notacional tradicionalmente se baseia na observação e categorização de eventos discretos durante uma partida ou treinamento. Por outro lado, o aprendizado de máquinas emergiu como uma metodologia que lida com grandes volumes de dados, extraindo padrões complexos e realizando previsões e classificações que seriam inviáveis com abordagens manuais.

## 2. ANÁLISE NOTACIONAL: FUNDAMENTOS, VANTAGENS E LIMITAÇÕES

A análise notacional pode ser compreendida como uma técnica de coleta e registro sistemático de eventos durante uma partida ou treinamento. Seu foco principal está em quantificar e categorizar ações esportivas discretas, como passes, finalizações, desarmes, faltas, entre outros, com o objetivo de fornecer dados objetivos sobre o desempenho de atletas e equipes. Esses dados são essenciais para o feedback técnico-tático, monitoramento do progresso e a formulação de estratégias de treinamento.

### 2.1. História da análise notacional

A análise notacional teve suas raízes no final do século XIX e início do século XX, com a observação e registro manual dos eventos em partidas esportivas. Inicialmente, foi usada sem as ferramentas e metodologias precisas que conhecemos hoje. Importantes progressos da análise notacional aconteceram nas

décadas de 1950 e 1960, especialmente em esportes como o futebol, em que o conceito de “estatísticas de jogo” começou a ganhar relevância. Adiante, um dos marcos mais importantes da análise notacional moderna foi o trabalho de pesquisadores como M. Hughes e I. Franks, que sistematizaram a técnica e a tornaram amplamente acessível a treinadores e analistas esportivos. A análise notacional passou, então, a ser vista como uma ferramenta científica crucial para a avaliação do desempenho esportivo, focando na quantificação e categorização dos eventos do jogo de forma objetiva e repetível.

A ampliação do uso da tecnologia na década de 1990 também representa um marco no campo da análise notacional. Computadores e softwares facilitaram a coleta de dados, proporcionando registros mais rápidos e menos suscetíveis a erros humanos. Isso permitiu uma análise mais precisa e abrangente, além de possibilitar a análise de grandes volumes de dados.

## 2.2. Aplicações da análise notacional em diferentes modalidades esportivas

A análise notacional tem sido amplamente utilizada em diversas modalidades esportivas, tanto coletivas quanto individuais, devido à sua simplicidade e baixo custo. A seguir, são apresentados alguns exemplos de como essa técnica é aplicada em esportes de alto rendimento:

**Futebol:** A análise notacional é utilizada para registrar eventos-chave durante uma partida, como passes, finalizações, desarmes, e até mesmo a movimentação tática das equipes. Por exemplo, um analista pode monitorar a frequência de passes bem-sucedidos entre os jogadores, o posicionamento da defesa e o número de finalizações ao gol. Esses dados são fundamentais para ajustar estratégias de jogo, identificar pontos fortes e fracos e otimizar o desempenho da equipe.

→ Um exemplo prático é o uso da análise notacional para registrar e estudar o desempenho ofensivo e defensivo de equipes durante os jogos da Premier League. As informações coletadas a partir desses registros podem ser usadas para determinar a eficácia de diferentes formações táticas, como a pressão alta ou o jogo de posse, proporcionando insights para o treinamento e a preparação de futuras partidas.

**Basquete:** A análise notacional no basquete envolve o registro de ações como arremessos, assistências, rebotes e faltas. Além disso, também pode incluir a análise do tempo de posse de bola de cada jogador, os padrões de movimentação em quadra e o desempenho em situações específicas, como o ataque rápido ou a defesa em zonas. Essa técnica permite que os treinadores ajustem as táticas de jogo em tempo real, além de possibilitar o planejamento de estratégias contra adversários com características específicas.

→ Em jogos da NBA (*National Basketball Association*), analistas utilizam a análise notacional para identificar padrões de jogo, como a eficácia de determinados jogadores em arremessos de três pontos ou a capacidade de um time de reagir a mudanças táticas do adversário.

**Tênis:** Em esportes individuais, como o tênis, a análise notacional pode registrar o número de saques bem-sucedidos, a eficácia dos primeiros e segundos serviços, os erros não forçados, entre outros aspectos. A análise de cada ponto permite a um treinador avaliar com precisão o desempenho técnico de seu atleta e identificar áreas de melhoria.

→ No contexto profissional, a ATP (*Association of Tennis Professionals*) realiza a análise de cada jogo, registrando os aspectos do desempenho técnico dos jogadores, como o tempo de cada rally, a porcentagem de acertos de saques e a eficácia em pontos decisivos. Esses dados são usados para otimizar as táticas e a preparação física dos jogadores.

**Atletismo:** A análise notacional no atletismo, especialmente nas provas de corrida, envolve a avaliação de tempos, velocidades, mudanças de ritmo, acelerações e desacelerações. A análise detalhada do desempenho de cada atleta em termos de divisão de ritmo e estratégias de corrida permite que os treinadores forneçam um feedback técnico mais preciso.

→ Um exemplo é o uso de análise notacional nas provas de maratona, em que são registradas as fases do ritmo de corrida de cada atleta, auxiliando a identificação de pontos críticos que podem ser melhorados para otimizar o desempenho em futuras corridas.

### 2.3. Vantagens da análise notacional

A principal vantagem da análise notacional é sua simplicidade e baixo custo, pois a coleta de dados ocorre de forma rápida, acessível e objetiva. Com o uso de tabelas, planilhas e softwares, os dados podem ser registrados e armazenados facilmente para análise posterior. Além disso, ela proporciona uma base para o feedback técnico imediato, permitindo que treinadores e analistas revelem áreas de melhoria para os atletas.

### 2.4. Limitações da análise notacional

O principal desafio da análise notacional está na dependência da observação humana, que pode levar a erros, vieses subjetivos e inconsistências. Além disso, a análise notacional não é capaz de capturar a complexidade das interações dinâmicas entre os jogadores, especialmente em esportes de alta intensidade. Em muitas modalidades, os eventos não ocorrem de forma isolada; eles estão interligados por uma sequência de ações rápidas e dinâmicas que exigem uma análise mais profunda e detalhada.

Outro ponto de limitação é a dificuldade de lidar com grandes volumes de dados. Ao registrar ações de forma isolada, a análise notacional pode perder a riqueza contextual das interações contínuas que acontecem durante uma partida, como o movimento coletivo da equipe ou a estratégia global do jogo.

### 3. APRENDIZADO DE MÁQUINAS: CONCEITOS E TIPOS DE APRENDIZADO

O aprendizado de máquinas (*machine learning*), um subcampo da inteligência artificial, refere-se à capacidade de algoritmos de aprender com dados e realizar previsões ou classificações. Essa tecnologia tem ganhado destaque na análise do desempenho esportivo devido à sua habilidade de lidar com grandes volumes de dados multivariados, detectar padrões complexos e realizar previsões precisas.

O aprendizado de máquinas oferece uma forma mais eficiente de explorar dados, especialmente em esportes, onde as variáveis são numerosas e as interações entre elas são complexas. Desde o futebol até o ciclismo, os algoritmos de aprendizado de máquinas podem identificar padrões que ajudam os treinadores a desenvolver estratégias, prever lesões e otimizar o treinamento.

#### 3.1. Aprendizado Supervisionado

No aprendizado supervisionado um modelo é treinado com um conjunto de dados rotulado, ou seja, os dados de entrada já possuem a resposta conhecida. O objetivo do modelo é aprender a associar as características dos dados de entrada às suas respectivas saídas ou rótulos.

Futebol: Um exemplo prático é a aplicação de modelos supervisionados para prever o resultado de uma partida com base em dados históricos. Variáveis como número de gols, posse de bola, finalizações e passes completados podem ser usadas para treinar o modelo. O aprendizado supervisionado identifica padrões no histórico de resultados passados e pode prever o desempenho de equipes em jogos futuros. Modelos semelhantes são usados para determinar as melhores formações táticas e identificar os jogadores mais valiosos dentro de uma equipe.

Tênis: No tênis, um modelo supervisionado pode ser treinado para prever o vencedor de um jogo com base em dados como a porcentagem de acertos de saques, a eficácia nos pontos de break, a quantidade de erros não forçados e o tempo médio de rally. Esses dados rotulados, com resultados passados de partidas, ajudam a identificar as variáveis que mais influenciam o sucesso de um jogador e a prever o resultado de futuras partidas.

#### 3.2. Aprendizado não supervisionado

O aprendizado não supervisionado lida com conjuntos de dados nos quais as respostas ou rótulos não estão disponíveis. O objetivo aqui é identificar padrões ou estruturas subjacentes nos dados sem uma orientação explícita sobre o que procurar.

Basquete: Em uma equipe de basquete, pode-se usar aprendizado não supervisionado para analisar o estilo de jogo de cada jogador com base em comportamentos durante as partidas, como o número de passes, rebotes e tentativas de arremesso. O modelo pode

agrupar jogadores que compartilham comportamentos semelhantes, identificando, por exemplo, jogadores mais defensivos ou mais focados em assistências. Esses agrupamentos ajudam os treinadores a entender as interações entre os jogadores e a ajustar a tática da equipe.

Ciclismo: No ciclismo, modelos de aprendizado não supervisionado podem ser usados para identificar padrões de desempenho dos ciclistas em diferentes condições de corrida. Por exemplo, é possível agrupar dados de várias corridas para entender como variáveis como velocidade média, potência gerada e tempo de recuperação variam entre os ciclistas, ajudando a otimizar o treinamento e a estratégia para competições específicas.

### 3.3. Aprendizado por reforço

O aprendizado por reforço é uma abordagem em que um agente aprende a tomar decisões por meio de recompensas e punições com base em suas ações em um ambiente. O objetivo é maximizar uma função de recompensa ao longo do tempo, adaptando-se continuamente ao contexto.

Tênis: No tênis, um modelo de aprendizado por reforço pode ser treinado para ajustar a estratégia de saque do jogador com base nas respostas do adversário. Se o adversário retorna o saque com eficiência em uma determinada zona, o modelo é recompensado por sugerir mudanças no ritmo e localização do saque, ajustando-se ao longo da partida. O modelo aprende a adaptar suas decisões para maximizar as chances de ganhar pontos.

Esportes Coletivos: Em modalidades em que a dinâmica do jogo muda rapidamente, um modelo de aprendizado por reforço pode ser utilizado para ajustar as táticas de defesa e ataque de uma equipe durante a partida. O modelo pode aprender a se adaptar às mudanças no jogo, como a movimentação do adversário, e tomar decisões de forma autônoma, maximizando as chances de sucesso em cada jogada.

## 4. OUTRAS APLICAÇÕES DO APRENDIZADO DE MÁQUINAS NO ESPORTE

A capacidade do aprendizado de máquinas em lidar com grandes volumes de dados e identificar padrões complexos tem permitido a otimização de diversos aspectos do desempenho esportivo. Entre os quais:

### 4.1. Previsão de desempenho

A previsão de desempenho é uma das aplicações mais notáveis do aprendizado de máquinas no esporte. Com a coleta de dados sobre treinos, condições físicas, estatísticas de jogos anteriores e até informações psicológicas, os algoritmos de aprendizado de máquinas são capazes de prever como um atleta ou uma equipe se comportará em competições futuras.

## 4.2. Detecção de lesões

A prevenção de lesões é outra área em que o aprendizado de máquinas tem demonstrado resultados satisfatórios. Usando dados de movimento (obtidos com o uso de sensores como acelerômetros e giroscópios) e métricas fisiológicas (como a carga de treino e a variabilidade da frequência cardíaca), os algoritmos podem identificar padrões que precedem lesões.

## 4.3. Análise tática

O aprendizado de máquinas é amplamente utilizado para análise tática em esportes coletivos, permitindo que treinadores e analistas obtenham insights detalhados sobre o comportamento de jogadores e equipes durante uma partida. Os algoritmos de aprendizado de máquinas podem processar dados de movimento em tempo real e gerar informações táticas para ajustar estratégias de jogo de maneira dinâmica.

## 4.4. Scouting e segmentação de perfis

O scouting e a segmentação de perfis de jogadores é uma aplicação crescente do aprendizado de máquinas. Os algoritmos podem analisar o comportamento de um jogador, seu estilo de jogo e seu desempenho em diferentes cenários, ajudando na identificação de talentos e na escolha de jogadores que melhor se ajustem às necessidades de uma equipe.

## 4.5. Personalização do treinamento

Uma das aplicações mais promissoras do aprendizado de máquinas no esporte é a personalização do treinamento. Os modelos podem analisar dados de desempenho individuais de atletas, como ritmo de corrida, potência gerada, recuperação e outras métricas de treinamento, para criar planos de treinamento personalizados que atendam às necessidades específicas de cada jogador.

## 5. INTEGRAÇÃO DE ANÁLISE NOTACIONAL E APRENDIZADO DE MÁQUINAS

A integração entre análise notacional e aprendizado de máquinas representa um marco significativo no estudo e otimização do desempenho esportivo. Afinal, essa união reflete a convergência de duas abordagens metodológicas complementares: a análise quantitativa de eventos esportivos (análise notacional) e a capacidade dos algoritmos de aprender e identificar padrões a partir de grandes volumes de dados (aprendizado de máquinas). A partir dessa integração, surge uma poderosa ferramenta que permite uma análise mais profunda e precisa do desempenho de atletas e equipes, além de fornecer insights valiosos para ajustes táticos e estratégicos durante o treinamento e a competição.

Os dados notacionais, que registram eventos discretos como passes, finalizações e desarmes, podem servir como entrada para modelos de aprendizado de máquinas, permitindo que esses modelos identifiquem padrões complexos e relações não lineares entre as variáveis. Além disso, ao combinar esses dados com informações contínuas de movimento (como a posição dos jogadores no campo, a velocidade e a aceleração), é possível obter uma análise mais completa e dinâmica do desempenho.

Futebol: A integração entre análise notacional e aprendizado de máquinas pode ser aplicada para prever o resultado de uma partida ou identificar a estratégia tática mais eficaz. Por exemplo, dados notacionais sobre passes, finalizações e desarmes, quando combinados com dados de movimento de jogadores (obtidos por GPS e acelerômetros), podem alimentar modelos de ML que analisam o comportamento coletivo da equipe durante diferentes situações de jogo. Esses modelos podem identificar padrões de jogo que levam ao sucesso (ou fracasso) e prever quais jogadores estão mais propensos a cometer erros ou realizar ações decisivas durante a partida. Além disso, a integração de dados notacionais e de movimento pode ajudar a ajustar táticas em tempo real, com base no comportamento do adversário e na posição dos jogadores em campo.

Basquete: Os dados de movimentação dos jogadores e as ações registradas, como arremessos, passes e rebotes, podem ser combinados em um modelo de aprendizado de máquinas para prever o sucesso de estratégias ofensivas e defensivas. A integração de dados sobre os movimentos dos jogadores e suas interações com a bola permite modelar a dinâmica do jogo, ajudando a identificar quando e onde a equipe adversária tende a ser mais vulnerável. Isso permite que os treinadores ajustem as estratégias durante a partida, tomando decisões informadas sobre mudanças de formação ou estilo de jogo.

## **5.1. Vantagens da integração para analistas e treinadores**

A utilização integrada de análise notacional e aprendizado de máquinas traz inúmeras vantagens para os profissionais envolvidos na análise de desempenho esportivo. Uma das maiores vantagens é que ela permite que os analistas e treinadores se beneficiem da objetividade da notação, ao mesmo tempo em que aproveitam a profundidade e a sofisticação das análises computacionais. A análise notacional fornece dados fáceis de interpretar e comunicar, enquanto os modelos de aprendizado de máquinas oferecem insights baseados em dados complexos e multidimensionais que seriam impossíveis de identificar por meio de simples observação humana. Além disso, a velocidade e a escala da análise também são amplificadas com a integração. Modelos de aprendizado de máquinas podem processar grandes volumes de dados em tempo real, o que permite aos treinadores ajustar suas estratégias durante o jogo ou o treinamento, antes que as oportunidades se percam.

## 6. DESAFIOS E CONSIDERAÇÕES PRÁTICAS

Embora a integração entre análise notacional e aprendizado de máquinas represente uma evolução significativa na análise do desempenho esportivo, essa combinação também apresenta desafios práticos substanciais. Esses desafios devem ser enfrentados para garantir a efetividade e a aplicabilidade dos modelos de aprendizado de máquinas em contextos esportivos reais.

### 6.1. Coleta e qualidade dos dados

O sucesso das técnicas de aprendizado de máquinas depende diretamente da qualidade dos dados utilizados. Dados imprecisos, desorganizados ou incompletos podem comprometer seriamente os resultados da análise, levando a previsões incorretas e estratégias mal fundamentadas. A coleta de dados de alta qualidade é fundamental, pois o aprendizado de máquinas baseia-se em padrões que emergem desses dados. No esporte, a variedade de fontes de dados – como sistemas de captura de movimento, sensores vestíveis (como GPS e acelerômetros) e registros notacionais manuais – torna a padronização e organização dos dados um desafio adicional.

É importante que a coleta de dados seja realizada de forma sistemática e precisa, com validação constante para garantir a integridade das informações. A falta de consistência nos dados (como variações na precisão dos sensores ou erros humanos nos registros notacionais) pode prejudicar o treinamento dos modelos e afetar a confiança nas análises geradas.

### 6.2. Treinamento e capacitação

Outro desafio significativo está relacionado ao treinamento e capacitação dos profissionais do esporte, como treinadores, analistas e outros membros da equipe técnica. A adoção de aprendizado de máquinas não é apenas uma questão de integrar ferramentas tecnológicas, mas também de adquirir conhecimento técnico sobre como essas ferramentas funcionam e como interpretar seus resultados.

O aprendizado de máquinas exige uma compreensão sólida de ciência de dados, estatísticas e, em muitos casos, programação. No entanto, muitos profissionais do esporte podem não ter formação técnica nessas áreas. Para garantir que a integração de aprendizado de máquinas seja bem-sucedida, é essencial que os treinadores e analistas adquiram uma formação contínua em ciência de dados, além de compreender os métodos tradicionais de análise notacional, para que possam fazer a conexão entre a teoria e a prática de maneira eficaz. Investir em treinamento especializado para a equipe técnica é, portanto, uma etapa crucial para maximizar os benefícios dessas tecnologias no esporte.

### 6.3. Interpretação dos resultados

A interpretação dos resultados gerados por modelos de aprendizado de máquinas pode ser um desafio, pois os algoritmos frequentemente produzem previsões e classificações complexas, cujos processos internos nem sempre são facilmente compreendidos. A natureza das redes neurais, por exemplo, pode ser considerada uma “caixa-preta”, onde os padrões e decisões que o modelo toma não são sempre transparentes, tornando a interpretação uma tarefa complexa.

Além disso, os resultados de aprendizado de máquinas devem ser contextualizados dentro da dinâmica do esporte. Por exemplo, um modelo pode prever o desempenho de um jogador com base em dados históricos, mas não leva em consideração fatores como o estado emocional do atleta, a qualidade do adversário ou as condições ambientais do jogo. Por isso, é crucial que os profissionais envolvidos na análise do desempenho esportivo tenham uma abordagem crítica e bem-informada ao interpretar os resultados, garantindo que as previsões sejam ajustadas conforme o contexto da competição e as particularidades de cada atleta ou equipe.

## 7. PERSPECTIVAS

A integração de técnicas tradicionais, como a análise notacional, com métodos avançados de aprendizado de máquinas, representa um avanço transformador na análise do desempenho esportivo. As abordagens complementares têm o potencial de revolucionar a maneira como treinadores, analistas e atletas abordam o treinamento, a avaliação de desempenho e a tomada de decisões estratégicas no esporte de alto rendimento.

A combinação dessas abordagens permite uma análise mais robusta e abrangente do comportamento de atletas e equipes, proporcionando insights valiosos sobre padrões de desempenho, estratégias táticas e até a detecção precoce de lesões. Além disso, ela contribui para a personalização do treinamento, adaptando-o às necessidades específicas de cada atleta, e para o ajuste de estratégias em tempo real durante as competições, com base em dados atualizados.

O futuro da análise do desempenho esportivo será cada vez mais moldado pela evolução das tecnologias de coleta de dados e pela integração com a inteligência artificial. Com o aprimoramento da precisão dos sensores, o aumento da capacidade computacional e a melhoria dos algoritmos de aprendizado de máquinas, será possível coletar e processar dados em tempo real com um nível de detalhe nunca antes imaginado. Isso permitirá que a análise do desempenho seja mais precisa, mais rápida e mais eficaz, beneficiando atletas, equipes e treinadores.

No entanto, para que essas tecnologias realmente alcancem seu potencial, é fundamental que os profissionais da área estejam preparados para lidar com a complexidade dessas ferramentas. A formação contínua e a atualização de conhecimentos, especialmente nas áreas de ciência de dados e análise de desempenho, serão cruciais para garantir que as aplicações de aprendizado de máquinas sejam eficazes e contextualizadas, alinhadas às necessidades específicas de cada modalidade esportiva.

Tomados em conjunto, todos esses fatores reforçam que a integração de análise notacional e aprendizado de máquinas não é apenas uma inovação técnica, mas uma oportunidade de levar o esporte de alto rendimento a novos patamares de excelência. Essa combinação representa uma fronteira promissora para a inovação contínua, onde a ciência do esporte e as tecnologias emergentes se encontram para moldar o futuro do treinamento e do desempenho atlético.

## REFERÊNCIAS

BEATO, M. *et al.* An educational review on machine learning: a SWOT analysis for implementing machine learning techniques in football. **Int J Sports Physiol Perform**, v. 20, n. 2, p. 183-191, 2025.

CHMAIT, N.; WESTERBEEK, H. Artificial intelligence and machine learning in sport research: an introduction for non-data scientists. **Front Sports Act Living**, v. 3, p. 682287, 2021.

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 Med Open**, v. 5, n. 1, p. 28, 2019.

DRUST, B. Performance analysis research: meeting the challenge. **J Sports Sci**, v. 28, n. 9, p. 921-2, 2010.

EDOUARD, P.; VERHAGEN, E.; NAVARRO, L. Machine learning analyses can be of interest to estimate the risk of injury in sports injury and rehabilitation. **Ann Phys Rehabil Med**, v. 65, n. 4, p. 101431, 2022.

FRANKS, I.; HUGHES, M. **Notational analysis of sport: systems for better coaching and performance in sport**. 2. ed. Routledge, 2004. 321 p. ISBN 0415290058.

HUGHES, M.; FRANKS, I. M.; FRANKS, I. M. **Essentials of performance analysis in sport**. 2. ed. Routledge, 2015. p. ISBN 9781138022997.

LI, J. Machine learning-based analysis of defensive strategies in basketball using player movement data. **Sci Rep**, v. 15, n. 1, p. 13887, 2025.

NASSIS, G. P. *et al.* A review of machine learning applications in soccer with an emphasis on injury risk. **Biol Sport**, v. 40, n. 1, p. 233-239, 2023.

REIS, F. J. J. *et al.* Artificial intelligence and machine learning approaches in sports: concepts, applications, challenges, and future perspectives. **Braz J Phys Ther**, v. 28, n. 3, p. 101083, 2024.