

RECURSOS ESTATÍSTICOS PARA A ANÁLISE DE DESEMPENHO NO ESPORTE



<https://doi.org/10.22533/at.ed.764122513054>

Data de aceite: 20/06/2025

Rodney C. Paixão

Guilherme G. De Agostini

1. INTRODUÇÃO

A análise estatística é uma ferramenta indispensável para a compreensão e avaliação do desempenho esportivo, sendo crucial tanto para o monitoramento do atleta quanto para a formulação de estratégias e intervenções eficazes no esporte. Nesse contexto, os testes estatísticos paramétricos e não paramétricos desempenham um papel fundamental, fornecendo as bases para a análise rigorosa dos dados. A escolha entre esses testes depende de diversos fatores, como as características dos dados, a distribuição dos mesmos e o tamanho das amostras, além de aspectos metodológicos e dos objetivos de cada estudo.

Esse texto prioriza, portanto, um debate acessível sobre recursos estatísticos adotados no universo esportivo, explorando desde os aspectos fundamentais até

os desafios contemporâneos que têm transformado a análise de dados. Discute-se o uso de testes paramétricos e não paramétricos, suas vantagens, limitações e aplicações práticas, incluindo exemplos de esportes individuais, coletivos e adaptados (paradesporto), além de considerar como tecnologias emergentes têm impactado as abordagens analíticas.

2. BREVE PANORAMA DOS RECURSOS ESTATÍSTICOS NO ESPORTE

No contexto esportivo, especialmente à medida que os dados começaram a ser mais sistematicamente coletados sobre o desempenho de atletas, os recursos estatísticos começaram a ser amplamente adotados. À medida que o esporte profissional se expandia, com o crescimento das competições internacionais e a profissionalização dos atletas, surgiu a necessidade de avaliar o desempenho de forma mais objetiva e precisa.

Inicialmente, a aplicação de testes estatísticos no esporte era mais rudimentar e muitas vezes limitava-se à análise de variáveis simples, como tempos, distâncias e frequências. A psicometria e a bioestatística, campos que lidam com a medição e interpretação de variáveis psicológicas e biológicas, respectivamente, desempenharam um papel significativo na formação das metodologias iniciais utilizadas para medir o desempenho atlético. Esses métodos foram desenvolvidos para transformar dados brutos em informações que pudessem ser usadas para comparações válidas entre atletas e equipes, promovendo uma análise mais sistemática e científica dos esportes.

Contudo, à medida que o uso de tecnologias no esporte se expandiu e a coleta de dados se tornou mais complexa, os métodos estatísticos tradicionais passaram a ser desafiados pela crescente quantidade e complexidade dos dados gerados. Esportes de alto desempenho, com suas variáveis multifacetadas e amostras frequentemente pequenas, exigem um nível de sofisticação estatística que os testes clássicos nem sempre conseguem acomodar. O aumento da utilização de sensores, dispositivos de rastreamento de movimento, monitoramento da saúde e até mesmo das interações de equipes em jogos mais dinâmicos gerou uma vasta quantidade de dados não lineares e multivariados, que necessitavam de abordagens mais avançadas.

Essa transformação na coleta de dados exigiu que novas metodologias estatísticas fossem desenvolvidas para lidar com os desafios dos esportes modernos. O campo passou a incorporar métodos mais complexos, como os modelos de regressão não linear, análises multivariadas e, mais recentemente, o uso de inteligência artificial (IA) e aprendizado de máquina (*machine learning* – ML) para análise preditiva. Esses novos métodos permitem que os analistas de desempenho esportivo lidem com dados de uma maneira mais eficaz, extraíndo informações valiosas mesmo de conjuntos de dados de alta dimensionalidade, comuns no ambiente esportivo.

A evolução dos testes estatísticos no esporte também se reflete em uma maior ênfase na personalização da análise de dados. Com o aumento do foco na saúde e no bem-estar dos atletas, bem como no treinamento individualizado, os testes estatísticos têm se adaptado para avaliar não apenas o desempenho em termos de métricas globais, como tempo e distância, mas também para identificar padrões comportamentais e fisiológicos específicos de cada atleta. Isso requer uma análise mais detalhada e adaptada às características individuais dos esportistas, o que impulsiona a demanda por métodos de análise mais flexíveis e robustos.

De fato, a evolução dos testes estatísticos no esporte reflete um panorama de constante adaptação e inovação. Com a crescente sofisticação das ferramentas e metodologias, os profissionais de análise de desempenho têm agora à disposição uma gama de técnicas que não apenas possibilitam uma avaliação mais precisa e aprofundada, mas também abrem novas possibilidades para otimizar o desempenho atlético, sempre com a responsabilidade de considerar as limitações dos dados e as implicações éticas dessas análises.

3. TESTES PARAMÉTRICOS

Amplamente utilizados na análise de dados esportivos, os testes paramétricos são baseados em alguns pressupostos fundamentais, os quais:

- i. Normalidade: Os dados devem seguir uma distribuição normal ou gaussiana. Isso significa que a maioria dos valores deve se concentrar ao redor da média, com menos valores distantes das extremidades.
- ii. Homogeneidade das variâncias: A variância dos dados em cada grupo deve ser aproximadamente a mesma, ou seja, a dispersão dos dados em cada grupo não deve ser significativamente diferente.
- iii. Natureza intervalar ou proporcional: Os dados devem ser mensurados em escalas intervalares ou proporcionais, onde as diferenças entre os valores têm um significado claro e constante.

Quando esses pressupostos são atendidos, os testes paramétricos oferecem a vantagem de um maior poder estatístico. Isso significa que eles são mais eficazes para detectar diferenças reais entre grupos, permitindo uma análise mais precisa e sensível. Abaixo, estão alguns testes paramétricos amplamente adotados no ambiente esportivo e exemplos de aplicação.

3.1. Teste t de Student

O teste t de Student é um dos testes paramétricos mais amplamente utilizados para verificar se há uma diferença estatisticamente significativa entre as médias de dois conjuntos de dados. Existem duas principais variações do teste t, cada uma adequada a diferentes desenhos experimentais: o teste t para amostras independentes (não pareado) e o teste t para amostras dependentes (pareado).

3.1.1. Teste t para amostras independentes (não pareado): utilizado quando se deseja comparar as médias de dois grupos distintos, sem relação entre os indivíduos de cada grupo. É ideal quando os grupos são formados por sujeitos diferentes, como em ensaios comparativos entre intervenções.

Exemplo prático no esporte:

Imagine um estudo que investigue o desempenho de corredores de maratona em dois tipos distintos de treinamento: um grupo segue um programa de treinamento convencional, enquanto o outro adota um programa baseado em treinos intervalados de alta intensidade. O teste t para amostras independentes pode ser aplicado para comparar a média dos tempos de corrida entre os dois grupos e verificar se o programa com treinos intensivos resulta em um desempenho significativamente melhor. Desde que os pressupostos de normalidade e homogeneidade de variância sejam atendidos, o teste permite avaliar se a diferença observada nas médias é estatisticamente relevante.

3.1.2. Teste t para amostras dependentes (pareado): utilizado quando os mesmos indivíduos são avaliados em dois momentos diferentes ou sob duas condições distintas. Esse teste leva em consideração a relação entre as medições, tornando-se mais sensível às mudanças dentro do próprio sujeito.

Exemplo prático no esporte:

Suponha-se um estudo que avalia a potência muscular de um grupo de atletas antes e após um ciclo de suplementação com creatina. Como se trata das mesmas pessoas sendo medidas em dois momentos (pré e pós-intervenção), aplica-se o teste t pareado. O objetivo é verificar se houve uma diferença estatisticamente significativa na média da potência muscular após a suplementação, controlando as variabilidades individuais.

3.2. Análise de Variância (ANOVA)

A ANOVA é um teste paramétrico utilizado quando há mais de dois grupos a serem comparados. Ela permite determinar se existem diferenças significativas nas médias de três ou mais grupos. A ANOVA é muito utilizada em estudos que envolvem diferentes condições experimentais ou grupos de atletas com características variadas.

Exemplo prático no esporte:

Suponha que um pesquisador queira comparar o impacto de diferentes tipos de suplementos (proteína, carboidrato, placebo) no desempenho de ciclistas durante uma competição. A ANOVA pode ser usada para comparar as médias de desempenho (tempo total ou distância percorrida) entre os três grupos. Se os dados passarem nos testes de normalidade e homogeneidade de variância, a ANOVA ajudará a identificar se algum suplemento tem um efeito significativamente diferente sobre o desempenho dos atletas. Se a ANOVA indicar uma diferença significativa, testes *post-hoc* podem ser realizados para identificar quais grupos apresentam diferenças nas médias.

3.3. Correlação de Pearson

O coeficiente de correlação de Pearson é utilizado para medir a intensidade e a direção de uma relação linear entre duas variáveis quantitativas. Esse teste é particularmente útil para entender como uma variável pode influenciar outra.

Exemplo prático no esporte:

No futebol, um técnico pode querer investigar se existe uma relação entre o número de gols marcados por um jogador e o número de passes completados durante uma partida. O coeficiente de correlação de Pearson pode ser usado para medir essa relação. Se o valor do coeficiente for próximo de 1, isso indicaria uma correlação forte e positiva entre as duas variáveis — ou seja, à medida que o número de passes aumenta, o número de gols também tende a aumentar.

3.4. Regressão Linear Simples

A regressão linear simples é utilizada para modelar a relação entre uma variável dependente e uma variável independente. No contexto esportivo, ela é útil para prever um valor com base em outro.

Exemplo prático no esporte:

Um exemplo típico de regressão linear simples seria prever o tempo de um corredor em uma maratona com base no seu tempo de treino semanal. Aqui, a variável dependente seria o tempo da maratona e a variável independente seria o total de horas de treinamento. A regressão linear simples ajudaria a entender até que ponto o aumento nas horas de treinamento pode levar à melhoria no tempo da maratona.

3.5. Regressão Linear Múltipla

A regressão linear múltipla é uma extensão da regressão linear simples, permitindo que várias variáveis independentes sejam analisadas ao mesmo tempo. Isso é útil quando se deseja entender como múltiplos fatores podem influenciar uma variável dependente.

Exemplo prático no esporte:

No caso de uma pesquisa sobre o desempenho atlético, podemos querer analisar como diferentes fatores — como idade, número de horas de treino e dieta — influenciam o tempo de um corredor na maratona. A regressão linear múltipla poderia ser usada para modelar essa relação, ajudando a entender como cada fator contribui para o desempenho global.

3.6. Aspectos Complementares

Embora os testes paramétricos sejam muito poderosos, sua aplicação inadequada pode resultar em falhas significativas na interpretação dos dados. Quando os pressupostos não são atendidos (ex.: dados assimétricos, com variância heterogênea ou quando os dados são de natureza ordinal) o uso de testes paramétricos pode levar a resultados

inválidos. Portanto, antes de aplicar qualquer teste paramétrico, é crucial realizar uma análise dos dados para verificar se os pressupostos estão sendo cumpridos. Caso contrário, os resultados podem ser comprometidos, o que prejudica a validade do estudo e a confiabilidade das conclusões.

4. TESTES NÃO PARAMÉTRICOS

Os testes não paramétricos são ferramentas essenciais quando os dados não atendem aos pressupostos necessários para os testes paramétricos. Eles são extremamente úteis em contextos esportivos, já que amostras pequenas, dados ordinais ou distribuições assimétricas são relativamente comuns. A principal desvantagem dos testes não paramétricos é que, em geral, eles têm menor poder estatístico, o que significa que são menos sensíveis para detectar diferenças reais quando comparados aos testes paramétricos.

Dito isso, ao compreender as características e as aplicações desses testes, os profissionais da área de análise de desempenho esportivo podem escolher a metodologia mais adequada para suas análises, garantindo resultados precisos e robustos, mesmo em cenários com dados complexos e desafiadores. Abaixo, seguem algumas das principais características dos testes não paramétricos:

- i. Não exigem normalidade: Ao contrário dos testes paramétricos, que pressupõem que os dados sigam uma distribuição normal, os testes não paramétricos podem ser aplicados a dados que não atendem a esse pressuposto. Isso é comum em dados esportivos, que podem ser assimétricos ou ter distribuições irregulares.
- ii. Adequados para dados ordinais e assimétricos: Quando os dados são de natureza ordinal, como classificações ou escores de percepção de esforço (por exemplo, em questionários de percepção de cansaço dos atletas), ou quando as distribuições são assimétricas, os testes não paramétricos são mais adequados. Isso se aplica a variáveis em que a escala de medição não é intervalar, como a escala de classificação de desempenho de atletas.
- iii. Robustez em amostras pequenas: Testes não paramétricos são particularmente úteis quando se trabalha com amostras pequenas, onde os pressupostos dos testes paramétricos (como normalidade e homogeneidade de variâncias) podem ser difíceis de verificar ou não são atendidos. Muitas vezes, em estudos esportivos com grupos de atletas ou em situações de campo, é comum lidar com amostras pequenas, onde esses testes se mostram eficazes.

Abaixo, estão alguns testes não paramétricos amplamente adotados no ambiente esportivo e exemplos de aplicação.

4.1. Teste de Mann-Whitney

É um dos testes não paramétricos mais utilizados para comparar duas amostras independentes, sendo uma alternativa ao teste t de Student quando os pressupostos de normalidade não são atendidos.

Exemplo prático no esporte:

Considere que um pesquisador queira comparar o tempo de recuperação de dois grupos de atletas: um grupo que segue um método de recuperação ativa (como exercícios leves) e outro que segue um método de recuperação passiva (descanso completo). Como os dados de recuperação podem não seguir uma distribuição normal, o teste de Mann-Whitney pode ser utilizado para comparar os tempos de recuperação entre os dois grupos, sem a necessidade de pressupostos de normalidade.

4.2. Teste de Wilcoxon

É utilizado para comparar duas amostras relacionadas ou pareadas. Ele é a alternativa não paramétrica ao teste t para amostras pareadas, sendo eficaz quando os dados não seguem uma distribuição normal.

Exemplo prático no esporte:

Um exemplo clássico de aplicação do teste de Wilcoxon seria um estudo que investigue a mudança no nível de força de atletas antes e depois de um período de treinamento. Ao medir a força de cada atleta antes e após o programa de treinamento, podemos aplicar o teste de Wilcoxon para verificar se houve uma mudança significativa na força, considerando que os dados podem ser assimétricos ou não seguir uma distribuição normal.

4.3. Kruskal-Wallis

O teste de Kruskal-Wallis é uma versão não paramétrica da ANOVA e é utilizado para comparar três ou mais grupos independentes. Ele é útil quando se quer testar se existem diferenças significativas nas distribuições de mais de dois grupos, mas sem a suposição de normalidade dos dados.

Exemplo prático no esporte:

Um estudo deseja comparar o desempenho em uma corrida de resistência de três grupos de corredores, cada um seguindo um tipo diferente de treinamento (ex.: treinamento intervalado de alta intensidade, treinamento de resistência tradicional e controle). Como os dados de tempo de corrida podem não ser normalmente distribuídos, o teste de Kruskal-Wallis pode ser utilizado para determinar se existe uma diferença significativa entre as distribuições dos tempos dos três grupos.

4.4. Friedman

O teste de Friedman é a versão não paramétrica da ANOVA de medidas repetidas e é utilizado para comparar três ou mais grupos relacionados. Ele é útil quando se tem dados de amostras repetidas, como medições de um mesmo grupo em diferentes momentos.

Exemplo prático no esporte:

Em uma pesquisa sobre o efeito de diferentes tipos de alimentação (por exemplo, dieta rica em carboidratos, dieta rica em proteínas e dieta rica em gorduras) no desempenho de corredores em uma corrida de 10 km, o teste de Friedman pode ser utilizado para comparar os tempos dos corredores em cada tipo de dieta, medidos em diferentes momentos (por exemplo, após uma semana de dieta, duas semanas e três semanas). O teste de Friedman ajudará a identificar se há uma diferença significativa entre os tempos nas diferentes dietas, mesmo sem pressupor normalidade nos dados.

4.5. Correlação de Spearman

O coeficiente de correlação de Spearman é utilizado para medir a força e direção de uma relação entre duas variáveis. Ele é uma alternativa não paramétrica ao coeficiente de correlação de Pearson e é útil quando os dados são ordinais ou não seguem uma relação linear.

Exemplo prático no esporte:

Em um estudo que examine a relação entre a experiência de um treinador e a performance de seus atletas, o coeficiente de Spearman pode ser utilizado para verificar se há uma correlação entre o número de anos de experiência do treinador (variável ordinal) e o desempenho dos atletas (ex.: tempo de corrida ou pontos conquistados) em uma competição.

5. ERRO TIPO I E TIPO II: DEFINIÇÃO E CONCEITOS BÁSICOS

Quando se realiza uma análise estatística em qualquer estudo, incluindo os realizados no contexto da análise de desempenho no esporte, o objetivo é testar uma hipótese sobre um determinado conjunto de dados. Os erros tipo I e tipo II são dois conceitos fundamentais na inferência estatística, e entender a diferença entre eles é crucial para garantir que os resultados da pesquisa sejam válidos e confiáveis.

5.1. Erro Tipo I (Falso Positivo)

O erro tipo I ocorre quando rejeitamos a hipótese nula (H_0) quando ela é, de fato, verdadeira. Em termos mais simples, significa que encontramos uma diferença ou efeito que não existe na realidade. Esse erro é frequentemente denominado “falso positivo” porque estamos afirmando que há um efeito significativo (por exemplo, uma diferença no desempenho de atletas) quando, na verdade, ele não existe.

Como exemplo prático pode-se considerar um pesquisar que esteja testando a eficácia de um novo regime de treinamento para melhorar o tempo de corrida de atletas. Um erro tipo I ocorreria se o pesquisador rejeitasse a hipótese nula (de que o novo regime de treinamento não tem efeito) e concluísse que o treinamento realmente melhora o desempenho, quando, na realidade, qualquer melhoria observada fosse simplesmente devido ao acaso.

5.2. Erro Tipo II (Falso Negativo)

O erro tipo II ocorre quando não rejeitamos a hipótese nula (H_0) quando ela é, de fato, falsa. Em outras palavras, significa que não conseguimos identificar um efeito ou diferença significativa, mesmo que ela realmente exista. Esse erro é chamado de “falso negativo”, pois estamos afirmando que não há diferença ou efeito, quando, na realidade, existe.

Como exemplo prático, no mesmo estudo sobre o regime de treinamento, um erro tipo II ocorrerá se o pesquisador não conseguir detectar que a nova abordagem de treinamento realmente melhora o tempo de corrida, mesmo que ele tenha um efeito positivo, e concluir que não há diferença entre os grupos.

5.3. Pressupostos e Causas dos Erros Tipo I e Tipo II

A ocorrência de erros tipo I e tipo II está intimamente ligada aos pressupostos estatísticos, ao tamanho da amostra e à natureza dos dados. Em muitos casos, o tipo de erro que ocorrerá depende de como o estudo é desenhado e das condições em que os testes estatísticos são aplicados.

Portanto, os erros tipo I e tipo II estão frequentemente relacionados ao nível de significância (α) e ao poder estatístico do teste:

- ✓ Nível de significância (α): O nível de significância define a probabilidade de cometer um erro tipo I. Comumente $\alpha=0,05$, o que significa que há uma chance de 5% de rejeitar a hipótese nula quando ela é verdadeira. Se α for muito baixo, o risco de cometer um erro tipo I diminui, mas o risco de erro tipo II aumenta.
- ✓ Poder estatístico ($1 - \beta$): O poder estatístico é a probabilidade de detectar um efeito quando ele realmente existe (ou seja, a probabilidade de evitar um erro tipo II). Se o poder do teste for baixo, a chance de cometer um erro tipo II aumenta.

O tamanho da amostra também tem grande impacto na ocorrência desses erros. Amostras pequenas têm maior probabilidade de gerar resultados imprecisos, tanto para erros tipo I quanto tipo II. Em amostras pequenas, os testes estatísticos têm menor poder, o que aumenta a chance de cometer erros tipo II, pois o teste pode não detectar diferenças reais nos dados. Por outro lado, amostras grandes, embora aumentem o poder, podem levar a erros tipo I devido a testes excessivamente sensíveis a pequenas diferenças que não são relevantes.

6. IMPACTO DAS NOVAS TECNOLOGIAS NA ANÁLISE DE DADOS

A revolução digital no esporte tem gerado grandes volumes de dados, que são coletados de diversas fontes, como dispositivos vestíveis (*wearable devices*), plataformas de rastreamento de movimento, sensores de desempenho e aplicativos de monitoramento físico. Essa abundância de dados gerou a necessidade de novas abordagens para a análise e interpretação dos resultados, e é nesse cenário que a IA e o ML têm ganhado destaque. A utilização de algoritmos avançados tem permitido que treinadores, analistas e pesquisadores extrapolem os limites das metodologias tradicionais e obtenham insights mais profundos sobre o desempenho esportivo.

O uso de IA e ML no esporte tem permitido o desenvolvimento de modelos preditivos que consideram uma ampla gama de variáveis, desde aspectos biomecânicos e fisiológicos até fatores psicológicos. Essas técnicas são particularmente eficazes em esportes coletivos, já que as interações dinâmicas entre os jogadores e as situações de jogo são complexas e difíceis de modelar com abordagens tradicionais. Por exemplo, modelos de redes neurais e árvores de decisão têm sido usados para prever o desempenho de jogadores em tempo real, levando em consideração variáveis como velocidade, distância percorrida, esforço físico e até o comportamento tático.

Esses avanços, no entanto, não substituem a importância dos testes estatísticos clássicos, que continuam sendo essenciais para validar os resultados obtidos por modelos computacionais e garantir a confiabilidade das conclusões. A integração das abordagens estatísticas tradicionais com tecnologias emergentes representa uma convergência metodológica e tecnológica que tem transformado a análise do desempenho esportivo.

7. CONCLUSÃO

A análise do desempenho no esporte é uma área dinâmica e em constante evolução, impulsionada tanto por avanços estatísticos quanto pelas inovações tecnológicas. A escolha entre testes paramétricos e não paramétricos continua a ser uma decisão crucial, que depende das características dos dados, do tipo de estudo e dos objetivos da pesquisa. De fato, a integração de métodos tradicionais com tecnologias emergentes abre novas possibilidades para otimizar a avaliação e o aprimoramento do desempenho esportivo. É fundamental que os profissionais se mantenham atualizados, não apenas em relação às ferramentas e métodos mais recentes, mas também em relação às regulamentações que regem o uso de dados sensíveis. A análise de desempenho esportivo, portanto, deve ser conduzida de maneira holística, equilibrando inovações tecnológicas, rigor técnico e responsabilidade ética.

REFERÊNCIAS

- AKOGLU, H. User's guide to correlation coefficients. *Turk J Emerg Med*, v. 18, n. 3, p. 91-93, 2018.
- ALTMAN, D. G.; BLAND, J. M. Statistics notes: variables and parameters. *BMJ*, v. 318, n. 7199, p. 1667, 1999.
- ATKINSON, G.; NEVILL, A. M. Statistical methods for assessing measurement error (reliability) in variables relevant to sports medicine. *Sports Med*, v. 26, n. 4, p. 217-38, 1998.
- 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, W. A big data approach to forecast injuries in professional sports using support vector machine. *Mobile Networks and Applications*, 2024.
- MESQUIDA, C. *et al.* Replication concerns in sports and exercise science: a narrative review of selected methodological issues in the field. *R Soc Open Sci*, v. 9, n. 12, p. 220946, 2022.
- MISHRA, P. *et al.* Application of student's t-test, analysis of variance, and covariance. *Ann Card Anaesth*, v. 22, n. 4, p. 407-411, 2019.
- O'DONOGHUE, P. **Research methods for sports performance analysis**. 1. ed. Routledge, 2010. p. ISBN 9780415496230.
- SEOW, D.; MASSEY, A. Correlation between preseason body composition and sports injury in an English Premier League professional football team. *BMJ Open Sport Exerc Med*, v. 8, n. 2, p. e001193, 2022.
- WANG, K.; WANG, L.; SUN, J. The data analysis of sports training by ID3 decision tree algorithm and deep learning. *Scientific Reports*, v. 15, n. 1, p. 15060, 2025.