EVENTO ON-LINE
ConBRepro
XVI CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO
02 a 04 de dezembro de 2026
Inovação e Transformação Digital como Estratégia Competitiva nas Engenharias

Previsão da variabilidade da frequência cardíaca de um atleta de esportes de resistência: um trabalho experimental

João Vitor de Souza Sambugaro
Programa de Pós-Graduação em Engenharia de Produção e Sistemas - PPGEPS Multicampi - UTFPR
Ramon Gomes da Silva
Programa de Pós-Graduação em Engenharia de Produção e Sistemas - PUCPR
Karla de Jesus
Laboratório de Estudos do Desempenho Humano - Faculdade de Educação Física e Fisioterapia - UFAM
Matheus Henrique Dal Molin Ribeiro
Programa de Pós-Graduação em Engenharia de Produção e Sistemas - PPGEPS Multicampi - UTFPR

Resumo: A variabilidade da frequência cardíaca (do inglês, *heart rate variability,* HRV) constitui uma importante métrica para o monitoramento da resposta fisiológica e da recuperação em atletas de resistência. Este estudo teve como objetivo desenvolver e avaliar modelos de aprendizado de máquina para prever a HRV do dia seguinte em um atleta de resistência, utilizando dados fisiológicos provenientes de dispositivo vestível e técnicas de engenharia de atributos. Foram analisados 120 dias de dados, contendo variáveis relacionadas à HRV, frequência cardíaca, sono, atividade física, estresse e desempenho. Foram realizadas análises de estacionariedade, tendência, sazonalidade, função de autocorrelação e Ljung-Box. A modelagem foi realizada com os algoritmos Ridge, *Random Forest* (RF) e *eXtreme Gradient Boosting* (XGBoost), considerando horizonte de previsão D+1. Foram conduzidos três experimentos, envolvendo características brutas, inclusão de atributos derivados e seleção de variáveis por meio de *SHapley Additive exPlanations* (SHAP). O XGBoost apresentou o melhor desempenho com os atributos refinados, alcançando *Mean Absolute Error* (MAE) de 1,3538 ms, *Root Mean Squared Error* (RMSE) de 1,6991ms e *Coefficient of Determination* (R^2) de 0,8070. A análise SHAP evidenciou elevada relevância de variáveis relacionadas ao histórico recente da própria HRV, indicando memória temporal na série. Os resultados demonstram o potencial da integração entre análise temporal, engenharia de atributos e aprendizado de máquina para previsão individualizada da HRV e suporte ao monitoramento fisiológico no treinamento esportivo.

Palavras-chave: Previsão Fisiológica, Variabilidade da frequência cardíaca, Esportes de resistência, Aprendizado de Máquina, Séries Temporais.

Heart Rate Variability Forecasting in an Endurance Athlete: An Experimental Study

Abstract: Heart rate variability (HRV) is an important metric for monitoring physiological responses and recovery in endurance athletes. This study aimed to develop and evaluate machine learning

models to predict next-day HRV in an endurance athlete using physiological data obtained from a wearable device and feature engineering techniques. A total of 120 days of data were analyzed, including variables related to HRV, heart rate, sleep, physical activity, stress, and performance. Stationarity, trend, seasonality, autocorrelation function, and Ljung–Box analyses were performed. Modeling was conducted using Ridge, Random Forest (RF), and eXtreme Gradient Boosting (XGBoost) algorithms, considering a D+1 forecasting horizon. Three experiments were conducted, involving raw features, the inclusion of derived features, and feature selection using SHapley Additive exPlanations (SHAP). XGBoost achieved the best performance with the refined features, reaching a Mean Absolute Error (MAE) of 1.3538 ms, Root Mean Squared Error (RMSE) of 1.6991 ms, and Coefficient of Determination (R^2) of 0.8070. The SHAP analysis revealed a high relevance of variables related to the recent history of HRV itself, indicating temporal memory in the time series. The results demonstrate the potential of integrating time-series analysis, feature engineering, and machine learning for individualized HRV prediction and to support physiological monitoring in sports training.

Keywords: Physiological Prediction, Heart Rate Variability, Endurance Sports, Machine Learning, Time Series.

1. Introdução

Os esportes profissionais há muito se desenvolvem em direção a métodos de treinamento cada vez mais científicos. Um dos princípios mais fundamentais na ciência do esporte e nas práticas de treinamento é a dose relação de resposta, ou seja, a adaptação física ao estímulo de treinamento (HILMKIL *et al*., 2018). A dose, hoje chamada de carga, necessita de controle para que a resposta seja melhor prevista.

Atualmente os atletas têm acesso a quantidades anteriormente inimagináveis e tipos de dados e métricas para informar seu treinamento, competição e práticas de recuperação (LUNDSTROM, 2023). Da mesma forma, pretendem melhorar seu desempenho encontrando o equilíbrio ideal entre a carga de treinamento e a recuperação (KELLMANN, 2010). Como os melhores ganhos no desempenho esportivo são geralmente alcançados com alta carga de treinamento e o tempo de recuperação mínimo, mas apropriado, atletas tendem a se equilibrar nessa linha entre fazer certo e fazer demais (HALSON, 2014).

O supertreinamento é uma demanda comum entre treinadores e atletas, sendo caracterizado pelo desequilíbrio entre estresse e recuperação. Além disso, os fatores de estresse podem ser encontrados não apenas em situações do treinamento e da competição, mas também naquelas relacionadas à extra treinamento e extra competição (ALVES *et al*., 2006).

Atletas e treinadores passaram a utilizar métricas que incluem variabilidade da frequência cardíaca (do inglês, *heart rate variability,* HRV), frequência cardíaca de repouso (FCR), potência, velocidade, aceleração, além de indicadores subjetivos como percepção subjetiva de esforço (PSE), qualidade do sono, humor e bem-estar. Esses indicadores permitem caracterizar o estado de prontidão e adaptar as cargas de treino de maneira individualizada (LUNDSTROM, 2023).

O conceito de carga de treinamento é dividido em carga externa (quantidade de trabalho) e interna (respostas fisiológicas e psicológicas) (CHAVES *et al*., 2019). Ambos os componentes são essenciais para evitar lesões, fadiga crônica, queda de desempenho e *overtraining*. Logo, a previsão de desempenho em esportes de treinamento extensivo, como triathlon (uma combinação de natação, ciclismo e corrida) podem ser benéficos para aperfeiçoar protocolos de treinamento e identificar picos (HOFFMANN *et al*., 2017).

A pesquisa na área de *Machine Learning* (ML) tem visto um aumento significativo a partir do ano de 2022 (WANG *et l.,*2026). Os modelos de ML oferecem estrutura robusta

para superar diferenças individuais das variações fisiológicas da HRV, o que o torna um ponto de pesquisa relevante para a predição de métricas fisiológicas no esporte (REICHEL *et al.,* 2024).

Destarte, o presente trabalho visou utilizar modelos de predição baseados em regressão linear e ML para prever dados fisiológicos, para variável HRV, um instante a frente, que envolvem as dinâmicas de desempenho esportivo e que corroboram com o controle de carga.

O restante deste trabalho está organizado como segue: Seção 2 detalha os trabalhos relacionados ao estudo, na seção 3 os materiais e métodos são descritos. Por sua vez, na seção 4 os resultados são apresentados, seguidos de discussão de resultados na seção 5, com conclusões apresentadas na seção 6.

2. Trabalhos relacionados

Jelinek *et al*. (2014) investigaram a predição do desempenho no futebol australiano utilizando dados dinâmicos de HRV, frequência cardíaca, *Global positioning system* (GPS) e fatores ambientais. Os autores compararam diferentes modelos de ML e utilizaram *Random Forest* (RF) para seleção de atributos, identificando a HRV e suas variáveis espectrais como importantes preditores de desempenho. Kataoka e Gray (2018), por sua vez, propuseram um sistema de predição em tempo real da potência de ciclistas do Tour de France, combinando engenharia automática de atributos e Redes Neurais Recorrentes (RNN), evidenciando a relevância da dinâmica temporal para a predição esportiva.

Em corredores recreacionais, Chickov *et al*. (2022) compararam diferentes algoritmos para predição do limiar de lactato, com RF e XGBoost apresentando os melhores resultados. Etxtegarai et al. (2018) também utilizaram técnicas de aprendizado de máquina para estimar o limiar de lactato a partir de frequência cardíaca, velocidade e evolução temporal, obtendo elevada correlação entre os valores preditos e observados. Hoffmann *et al*. (2017) compararam Regressão Linear Múltipla e Redes Neurais Artificiais para prever o tempo de prova de triatletas de elite, encontrando melhor desempenho para a *Artificial Neural Network* (ANN).

Estudos mais recentes reforçam que o desempenho dos algoritmos depende da quantidade e da estrutura dos dados. Li (2025) encontrou maior acurácia para modelos de Aprendizado Profundo, especialmente *Long Short-Term Memory* (LSTM), em grandes volumes de dados fisiológicos. Rothschild (2024), entretanto, observou que o modelo de melhor desempenho variava entre participantes, com *Least Absolute Shrinkage and Selection Operator* (LASSO), *Suport Vector Machine* (SVM) e XGBoost apresentando resultados superiores em diferentes séries. De forma semelhante, Xu (2026) observou melhor desempenho do XGBoost em um conjunto de dados relativamente reduzido. Esses achados indicam que a escolha do modelo está relacionada às características, volume e dinâmica temporal dos dados, justificando a comparação entre diferentes abordagens de ML e *Deep Learning* (DL) para a previsão de variáveis fisiológicas em atletas de resistência.

Corroborando as evidências apresentadas nos trabalhos relacionados, Alfonso et al. (2025) demonstraram que a prescrição individualizada do treinamento com base na HRV pode variar entre atletas, reforçando a necessidade de abordagens e modelos personalizados. Da mesma forma, Plews et al. (2013) ressaltam a importância do monitoramento longitudinal da HRV, considerando as características individuais de cada atleta. A variabilidade dessa medida pode ser influenciada por diferentes fatores, incluindo aspectos relacionados ao sono, ao estado emocional e psicológico, bem como às demandas e respostas decorrentes das sessões de treinamento.

3. Materiais e Métodos

3.1 Caracterização do conjunto de dados

Os dados utilizados neste estudo referem-se a 120 dias de dados pertencentes às métricas fisiológicas de um atleta de esportes de resistência (figura 1), considerando uma variável alvo HRV e 24 variáveis explicativas, as quais são apresentadas na subseção 3. Além do mais, foram tratados os *outliers* com mais de três desvios em sequência e substituídos pela mediana da coluna. Valores faltantes foram substituídos por interpolarização dos valores vizinhos. Os 120 dias de dados de HRV visíveis na figura 1 foram previamente analisados com testes de sazonalidade, tendência, função de autocorrelação (ACF) e função de autocorrelação parcial (PACF).

Figura 1 - Gráfico da série temporal relacionada ao HRV médio noturno de 120 dias

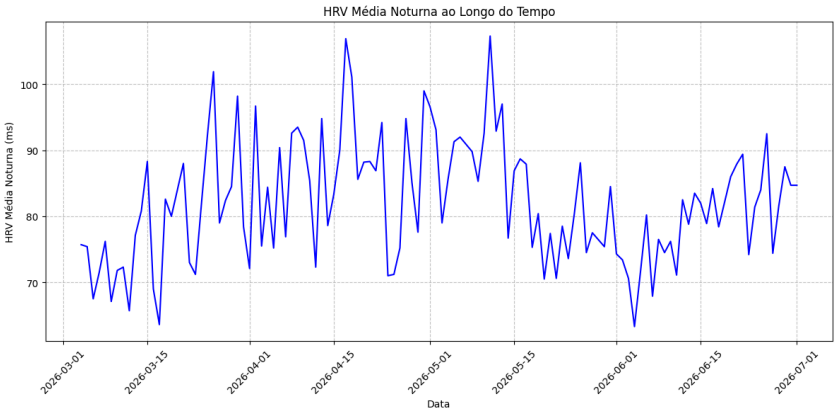

Seguindo os testes de Dickey-Fuller Aumentado (ADF) este rejeitou a hipótese nula de presença de raiz unitária ($p < 0,05$), indicando que a série temporal da HRV é estacionária.

A componente de tendência obtida pela decomposição temporal apresentou apenas oscilações de baixa frequência, não sugerindo evidências de crescimento ou declínio persistente ao longo do período em análise.

Da mesma forma, a componente sazonal apresentou baixa amplitude devido a retirada da componente sazonal, não indicando por si só ausência de sazonalidade. Entretanto, quando realizado o teste de Ljung-Box aplicado aos resíduos, este indicou autocorrelação significativa ($p < 0,05$), demonstrando que parte da estrutura temporal permaneceu não explicada pela decomposição, justificando a utilização de variáveis defasadas e modelos de aprendizado de máquina para capturar essas dependências.

Figura 2 - Decomposição da série da HRV

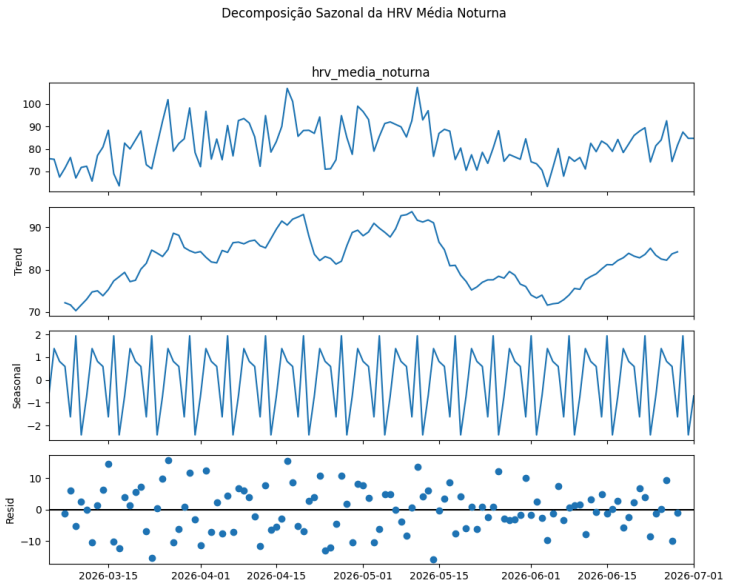

Analisando a figura 3 identificamos correlação para os intervalos 3 e 4 que estão fora da amplitude de confiança. Ou seja, ainda existe estrutura temporal na série que não pode ser explicada pela decomposição temporal. Assim sendo, este fator indica que informações anteriores podem ser melhor exploradas por modelos mais complexos, para o fim de entender a relação entre as variáveis no presente, passado e futuro.

Figura 3 - Teste de ACF para os resíduos

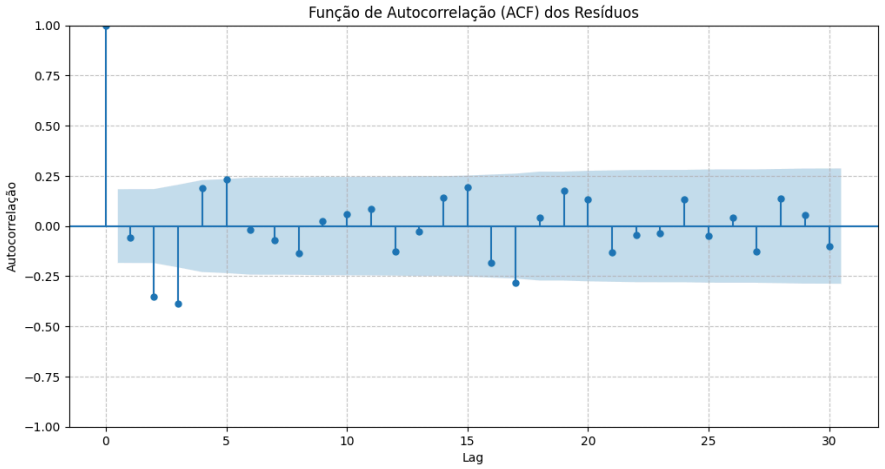

Visando a figura 4, os testes de ACF indicam que nos primeiros atrasos existe grande correlação com o anterior. Indicando mais uma vez que como o HRV vai responder no dia seguinte é muito influenciado pelo dia anterior, apresentando memória temporal. Quando realizado o teste de PACF, visível na figura 5, foi verificado que o primeiro atraso novamente apresenta forte indicação de informação para o seguinte, porém essa relevância cai fortemente para cada novo atraso já adentrando no intervalo de confiança.

Figura 4 - ACF da série temporal de HRV

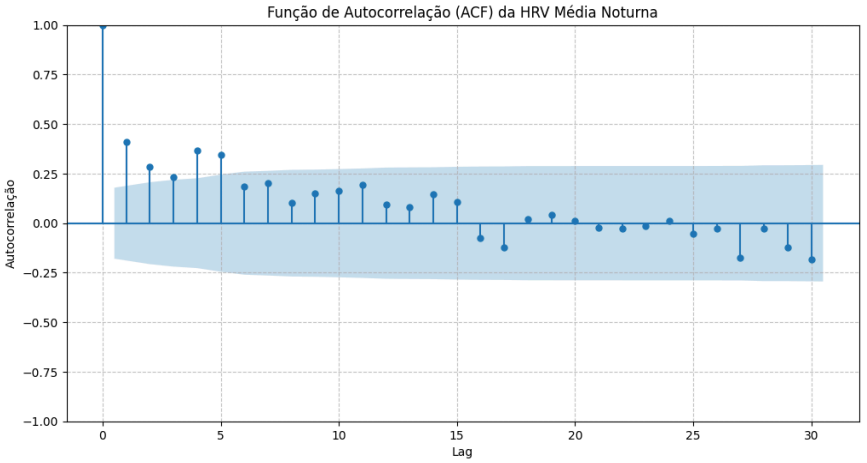

Quando realizado o teste de PACF, visível na figura 5, foi verificado que o primeiro atraso novamente apresenta forte indicação de informação para o seguinte, porém essa relevância cai fortemente para cada novo atraso já adentrando no intervalo de confiança.

Figura 5 - PACF da série de HRV

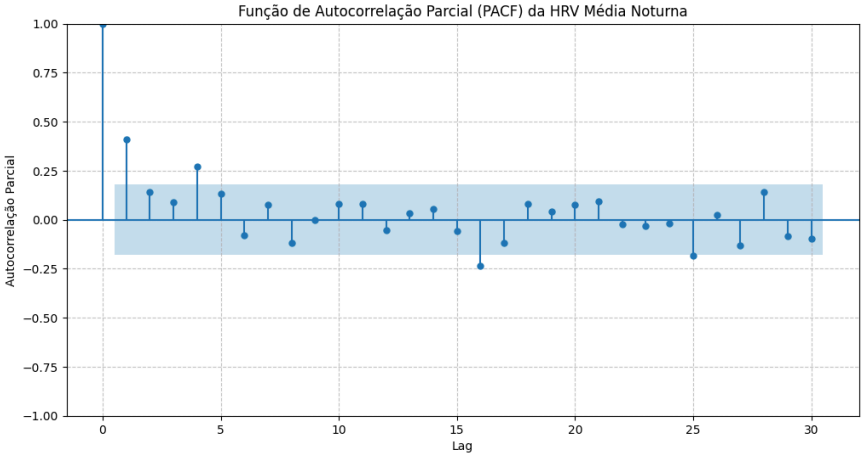

3.2 Métodos

A modelagem seguiu com os dados originais junto à criação de atributos relacionados aos dados coletados. Para a etapa de previsão da variável alvo, foram usadas as estratégias RF, regressão ridge e XGBoost. Objetivando capturar a variabilidade da variável alvo foram delineados os seguintes experimentos: (a) 24 atributos, (b) 40 atributos (sendo 16 deles criados); e, (c): refinamento dos atributos usados através do uso da ferramenta SHAP com apenas nove atributos imputados no modelo. Visto isso, os dados foram particionados em dois subconjuntos, sendo 70% dos dados destinados ao treinamento dos modelos, e 30% restantes foram utilizados para a etapa de teste, com o fim de avaliar o desempenho preditivo dos modelos.

Todos os modelos tinham como horizonte de previsão um instante à frente. Essa decisão veio da análise de outros artigos de mesmo conceito (Jelinek *et al*., 2014; Kataoka *et al*., 2019; Chickov *et al*. 2022; Tirtho *et al*., 2022) além de aplicabilidade prática, uma vez que seria ideal que o treinador tivesse um dia de previsão para ajustes das cargas.

Os dados fisiológicos analisados neste estudo foram coletados por meio de um dispositivo vestível (*wearable*), modelo *Garmin Forerunner* 970, utilizado pelo atleta durante o período de monitoramento. O dispositivo foi empregado para o registro contínuo de variáveis relacionadas à frequência cardíaca, variabilidade da frequência cardíaca (HRV), sono e atividade física.

A tabela 1 mostra a categoria dos atributos, em quais experimentos estes foram utilizados e a descrição junto ao nome dos mesmos.

Tabela 1 — Descrição e Classificação do Conjunto de Atributos por Tipo de Engenharia

Categoria / Tipo	Experimento	Quantidade	Variáveis / Atributos	Descrição / Transformação
Variáveis Originais	A	24	fc_repouso, fc_minima, fc_maxima, hrv_media_noturna, hrv_minimo_noturno, hrv_maximo_noturno, hrv_semanal_media, hrv_status_num, duracao_total_min, sono_profundo_min, sono_leve_min, sono_rem_min, acordado_min, score_sono, respiracao_media, respiracao_minima, respiracao_maxima, passos_total, distancia_km, calorias_ativas, minutos_intensidade_moderada, minutos_intensidade_vigorosa, vo2max_corrida, stress_medio, body_battery_max	Dados brutos coletados diretamente pelo relógio inteligente.
Médias Móveis	B e C	10	hrv_media_7d, hrv_media_14d, fc_repouso_7d, fc_repouso_14d, sono_score_7d, passos_7d, passos_28d, calorias_7d, stress_7d, battery_7d	Médias calculadas em janelas deslizantes (7, 14 e 28 dias) para capturar tendências.
Desvio Padrão	B e C	1	hrv_desvio_7d	Variabilidade da HRV calculada em janela deslizante de 7 dias.
Lag de atributos (Lags Temporais)	B e C	30	hrv_media_noturna_lag1/3/7, fc_repouso_lag1/3/7, score_sono_lag1/3/7, duracao_total_min_lag1/3/7, passos_total_lag1/3/7, calorias_ativas_lag1/3/7, minutos_intensidade_vigorosa_lag1/3/7, vo2max_corrida_lag1/3/7, stress_medio_lag1/3/7, body_battery_max_lag1/3/7	Defasagens temporais de 1, 3 e 7 dias para 10 métricas base (captura de histórico).
Razão Aguda/Crônica (ACWR)	B e C	2	acwr_calorias, acwr_passos	Proporção entre carga de curto prazo (aguda) e longo prazo (crônica).

Categoria / Tipo	Experimento	Quantidade	Variáveis / Atributos	Descrição / Transformação
Derivadas do Sono	B e C	2	eficiencia_sono, deficit_sono_acumulado	Métricas sintetizadas para avaliar qualidade e privação de sono.
Atributos de Intensidade	B e C	1	proporcao_vigorosa	Proporção de tempo gasto em intensidade vigorosa em relação ao total.
Atributos Temporais	B e C	4	dia_semana, fim_de_semana, mes, dia_mes	Variáveis de calendário para capturar padrões rotineiros e sazonalidade.
Atributos selecionados pelo SHAP	C	9	hrv_media_7d, hrv_media_noturna_lag1, hrv_semanal_media, hrv_maximo_noturno, hrv_minimo_noturno, passos_7d, hrv_media_14d, passos_14d, stress_7d	Variáveis de cunho fisiológico junto a métricas de quantidade.

Visto isso, as medidas de desempenho utilizadas foram: *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE) e *Coefficient of Determination* (R^2) para comparação e validação dos métodos e modelos.

$$MAE = (1/n) \times \Sigma |y_i - \hat{y}_i|$$
$$RMSE = \sqrt{[(1/n) \times \Sigma(y_i - \hat{y}_i)^2]}$$
$$R^2 = 1 - [\Sigma(y_i - \hat{y}_i)^2 / \Sigma(y_i - \bar{y})^2]$$

Nas Equações, yi é o valor observado, y^i é o valor estimado pelo modelo, $\bar{y}$ é a média dos valores observados, n é o número de observações e i representa a i-ésima observação (i=1,…,n). O MAE representa o erro médio absoluto, o RMSE a raiz do erro quadrático médio e o R2 o coeficiente de determinação.

4. Resultados

A tabela 2 detalha as medidas de desempenho dos modelos utilizados no estudo.

Tabela 2 — Desempenho Preditivo dos Modelos por Experimento

Experimento	Configuração dos atributos	Modelo	MAE (ms)	RMSE (ms)	R^2
Experimento A	Dados Brutos	XGBoost	1.5306	1.9141	0.7551
		Random Forest	1.9609	2.3120	0.6427

Experimento	Configuração dos atributos	Modelo	MAE (ms)	RMSE (ms)	R^2
		Ridge	1.7673	2.0923	0.7073
Experimento B	Todos os atributos	XGBoost	1.4598	1.7224	0.8017
		Random Forest	1.7687	2.2016	0.6760
		Ridge	1.6267	2.1294	0.6969
Experimento C	Atributos Refinados (SHAP)	XGBoost	1.3538	1.6991	0.8070
		Random Forest	1.7551	2.2284	0.6680
		Ridge	1.4219	1.8391	0.7739

Os atributos utilizados no experimento C obtidos através do SHAP tiveram grau de relevância apresentados na Figura 6.

Figura 6 - Gráfico obtido pela ferramenta SHAP para o modelo XGBoost



O experimento C, junto ao uso da ferramenta SHAP, identificou quais das variáveis tiveram maior relevância para a previsão do modelo. Os atributos com maior impacto se destacam por serem variações do HRV sugerindo que a informação histórica da própria variável foi predominante na previsão realizada pelo modelo. De outra forma, a métrica de passos teve influência sobre o modelo tendo em vista a denotação do esporte do atleta evidenciado. Na medida em que o valor dos passos sobe, influenciado pelos treinos

realizados pelo mesmo, evidenciam um maior volume de treinos concretizados, provocando alterações sobre a variável fisiológica HRV.

5. Discussão

O XGBoost teve maior eficiência por construir árvores sequenciais que acabam se baseando na anterior para correção interativa. Como o HRV tem comportamento linear, as árvores tiveram maior facilidade de prever o futuro. Como o *dataset* possui 120 amostras, o XGBoost teve eficácia maior que o RF por ter boosting sequencial, fazendo com que os erros anteriores pudessem ser corrigidos. Além do mais, o XGBoost é mais resistente a colinearidades, uma vez que os atributos mais importantes para prever o HRV são as variantes de HRV, selecionando os atributos com maior ganho de informação.

Algo interessante de ver é que as medidas de desempenho do Ridge variaram com o acréscimo ou decréscimo de atributos. Quando acrescentado novos atributos os desempenhos caíram, bem como quando retiradas, os desempenhos subiram novamente, indicando que o modelo se comporta melhor com menos dados.

Outrossim, é válido ressaltar que o MAE dá uma estimativa de erro em milissegundos (ms) que é a componente métrica da aferição da HRV.

Algumas das dificuldades de implementação de outros modelos se faz primeiramente pelo tamanho da amostragem de dados do *dataset*, também pela volatilidade dos dados de HRV uma vez que são muito sensíveis a fatores externos que são imensuráveis. Assim, os dados obtidos para este trabalho se encaixam em um deles uma vez que o atleta passou por uma viagem e uma prova de maratona altamente demandante fisiologicamente.

Assim sendo, os experimentos demonstraram que a combinação entre engenharia de atributos, seleção de variáveis e algoritmos de aprendizado de máquina possibilita elevada capacidade preditiva para a HRV em atletas de resistência. A condução não somente dos métodos, mas das variáveis é imprescindível para observar melhores resultados para séries fisiológicas.

A figura 7 ilustra os valores reais em vista do previsto dos modelos XGBoost, RF e Ridge junto aos valores de medida de desempenho MAE e R2.

Figura 7 - Real vs Previsto para os modelos testados

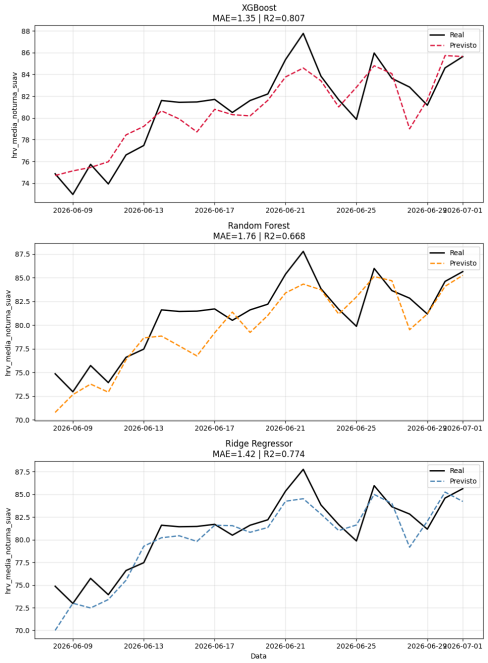

Por outro lado, apesar de resultados promissores e que corroboram com a literatura existente, o trabalho apresenta diversas lacunas que necessitam de maior evidência. Uma destas se faz pelas limitações decorrentes da utilização de dados provenientes de um único atleta e de um período relativamente curto de monitoramento.

6. Conclusões

O estudo teve como objetivo desenvolver e avaliar modelos de aprendizado de máquina capazes de prever a variabilidade da frequência cardíaca (HRV) do dia seguinte em um atleta de resistência, utilizando dados fisiológicos coletados por dispositivos vestíveis e técnicas de engenharia de atributos.

À priori, os resultados das análises dos dados da série apresentaram comportamento estacionário junto a uma estrutura temporal de curto prazo que foi explorada por meio de defasagem das variáveis e de médias móveis. Neste sentido, a incorporação de atributos aos modelos ajudou na assertividade dos mesmos e a análise SHAP evidenciou que o histórico recente da HRV é responsável pelas informações e previsão do dia seguinte.

Estudos futuros podem incluir inúmeros atletas, diferentes modalidades esportivas de resistência, diferentes horizontes de previsão e a incorporação de novas variáveis bem como maiores intervalos, visando maior generalização dos modelos preditivos e maior acurácia. Por ser uma variável fisiológica, a HRV se comporta de formas diferentes para cada pessoa, o que pode indicar modelos diferentes para cada grupo, o que seria de suma relevância identificar.

Assim sendo, os resultados evidenciam que a integração dos dispositivos de análise fisiológica junto à análise temporal aplicada ao aprendizado de máquina representa uma estratégia promissora para monitorar e prever de maneira individual estados futuros de prontidão fisiológica atlética para o suporte à tomada de decisão no treinamento esportivo.

Referências

ALVES, Rodrigo Nascimento; COSTA, Leonardo Oliveira Pena; SAMULSKI, Dietmar Martin. Monitoramento e prevenção do supertreinamento em atletas. Revista Brasileira de Medicina do Esporte, v. 12, n. 5, p. 291-296, 2006. DOI: 10.1590/S1517-86922006000500013.

ALFONSO, Carla; CLARKE, David C.; CAPDEVILA, Lluis. Individual training prescribed by heart rate variability, heart rate and well-being scores in experienced cyclists. Scientific Reports, v. 15, art. 34023, 2025.

CHAVES, Rodrigo Gambaro; FERREIRA, Thiago Henrique Nunes; TAVARES, Lucas Duarte. Estratégias de recuperação e controle de carga de treinamento. São Paulo: Conselho Regional de Educação Física da 4ª Região – CREF4/SP, 2019.

CHICKOV, V. et al. Machine learning for predicting lactate threshold in recreational runners. Sensors, v. 22, n. 23, 2022.

ETXEGARAI, U. et al. Estimation of lactate threshold with machine learning techniques in recreational runners. Machine Learning and Knowledge Extraction, v. 1, n. 1, p. 211–227, 2018.

HALSON, Shona L. Monitoring training load to understand fatigue in athletes. Sports Medicine, v. 44, supl. 2, p. S139–S147, 2014. DOI: 10.1007/s40279-014-0253-z.

HILMKIL, A. et al. Towards machine learning on data from professional cyclists. In: WORLD CONGRESS OF PERFORMANCE ANALYSIS OF SPORT, 12., 2018, Opatija. Proceedings [...]. Opatija: Faculty of Kinesiology, University of Zagreb, 2018. p. 168–176.

HOFFMANN, M. D. et al. Predicting race performance in elite triathletes using machine learning techniques. Journal of Sports Sciences, v. 35, n. 12, p. 1201–1208, 2017.

JELINEK, Herbert F. et al. Using meta-regression data mining to improve predictions of performance based on heart rate dynamics for Australian football. Applied Soft Computing, v. 14, p. 81–87, 2014. DOI: 10.1016/j.asoc.2013.08.010.

KATAOKA, Yasuyuki; GRAY, Peter. Real-time power performance prediction in Tour de France. In: INTERNATIONAL CONFERENCE ON BIG DATA AND SMART COMPUTING, 2018. Proceedings [...]. [S.l.]: IEEE, 2018.

KELLMANN, Michael. Preventing overtraining in athletes in high-intensity sports and stress/recovery monitoring. Scandinavian Journal of Medicine & Science in Sports, v. 20, supl. 2, p. 95–102, 2010. DOI: 10.1111/j.1600-0838.2010.01192.x.

LI, Xinyue. Deep learning to promote health through sports and physical training. Frontiers in Public Health, v. 13, art. 1583581, 2025. DOI: 10.3389/fpubh.2025.1583581.

LUNDSTROM, C. J.; FOREMAN, N. A.; BILTZ, G. Practices and applications of heart rate variability monitoring in endurance athletes. International Journal of Sports Medicine, v. 44, n. 1, p. 9–19, 2023. DOI: 10.1055/a-1864-9726.

PLEWS, D. J.; LAURSEN, P. B.; STANLEY, J.; KILDING, A. E.; BUCHHEIT, M. Training adaptation and heart rate variability in elite endurance athletes: opening the door to effective monitoring. *Sports Medicine*, v. 43, n. 9, p. 773–781, 2013. DOI: 10.1007/s40279-013-0071-8.

REICHEL, Thomas; HACKER, Sebastian; PALMOWSKI, Jana; BOßLAU, Tim Konstantin; FRECH, Torsten; TIREKOGLOU, Paulos; WEYH, Christopher; BOTHUR, Evita; SAMEL, Stefan; WALSCHEID, Rüdiger; KRÜGER, Karsten. Neurophysiological markers for monitoring exercise and recovery cycles in endurance sports. Journal of Sports Science and Medicine, v. 21, n. 3, p. 446-457, 2022.

ROTHSCHILD, Jeffrey A. et al. Predicting daily recovery during long-term endurance training using machine learning analysis. European Journal of Applied Physiology, v. 124, n. 11, p. 3279–3290, 2024. DOI: 10.1007/s00421-024-05530-2.

TIRTHO, A. H. et al. Cricketer's tournament wise performance prediction and squad selection using machine learning and multi-objective optimization. Applied Soft Computing, v. 122, 2022.

WANG, Zhongyang; HU, Jing; YU, Wenbing. Mapping HRV in sports science: from monitoring to machine learning. Frontiers in Sports and Active Living, v. 7, 2026. DOI: https://doi.org/10.3389/fspor.2025.1714962.

XU, Xuezhu. Multi-sensor fusion outperforms single indicators for fatigue prediction in university soccer players: a machine learning approach. Frontiers in Physiology, v. 17, art. 1775906, 2026. DOI: 10.3389/fphys.2026.1775906.