

# A utilização de machine learning na classificação de perfis de atividade física e fisiológica em jogadores de futsal de elite

## Autores

João Nuno Ribeiro<sup>1</sup>; Bruno Gonçalves<sup>2</sup>; Diogo Coutinho<sup>1</sup>; João Brito<sup>3</sup>; Jaime Sampaio<sup>1</sup>; Bruno Travassos<sup>1,3</sup>

[joaonunorib@gmail.com](mailto:joaonunorib@gmail.com)

## Resumo

Atualmente com a proliferação tecnológica, o desafio passa por sintetizar os dados de modo a fornecer informações precisas aos decisores. Nesse sentido, este estudo teve como objetivos: i) identificar a colinearidade entre as variáveis de carga externa, recolhidas através de um sistema de rastreamento posicional, de modo a identificar as variáveis cinemáticas, mecânicas e metabólicas que permitem avaliar o desempenho dos jogadores; ii) definir através de algoritmos de machine learning não supervisionados perfis de atividade dos jogadores de futsal tendo por base o seu desempenho cinemático, mecânico e metabólico em competição, de modo a permitir uma maior individualização do processo de treino e recuperação.

Os dados foram recolhidos dos jogadores das equipas que participaram na Final Eight da Taça de Portugal de 2018. A atividade dos jogadores foi medida através de um sistema tecnológico de tracking com ultra-wide-band da WIMU PRO™. O teste de correlação spearman foi utilizado para verificar a colinearidade entre as variáveis, enquanto que para classificar os jogadores de acordo com os seus perfis de performance foi implementado um algoritmo de machine learning não supervisionado. De um modo geral os resultados revelaram ser possível sintetizar a atividade dos jogadores através de uma variável cinemática – distância percorrida, uma variável mecânica- desaceleração e uma variável metabólica – metabolic power. Foram identificados três perfis de atividade distintos, tendo como variável preferencial de discriminação a desaceleração. A transferência destas evidências para a prática permitirão potenciar o treino e os processos de recuperação, de forma a otimizar performance e reduzir o risco de lesão.

---

<sup>1</sup> CIDESD - Centro de Investigação em Desporto, Saúde e Desenvolvimento Humano

<sup>2</sup> Comprehensive Health Research Centre (CHRC), Universidade de Évora

<sup>3</sup> Football Portugal School, Federação Portuguesa de Futebol

*Palavras-chave:* Performance, Monitorização, Tracking, Machine Learning

## **Introdução**

Em Portugal, o futsal tem seguido uma trajetória de desenvolvimento muito consistente, situando-se, na atualidade, como um dos países de referência mundial, quer ao nível dos resultados desportivos, quer ao nível do processo de treino desportivo para alcançar esses mesmos resultados.

Ao mais alto nível de competição, o processo de treino desenvolvido pelas equipas técnicas depende muito da natureza, da validade e da transferência de conhecimento que a ciência atual consegue operacionalizar. De facto, as hipóteses a investigar têm que ser relevantes (natureza), utilizando métodos e instrumentos muito rigorosos (validade) e os processos de simplificação capazes de aportar fluidez à comunicação (transferência).

Uma das hipóteses mais relevantes para ajudar na condução do processo de treino desportivo é a da caracterização das exigências físicas e fisiológicas do jogo. Como se percebe, as equipas técnicas dificilmente conseguem preparar jogadores para responderem a um jogo que não está devidamente modelado.

O jogo de futsal apresenta exigências físicas e fisiológicas bem particulares que o distinguem dos demais desportos<sup>1</sup>. Este perfil de atividade dos jogadores não tem muita utilidade se for considerado de forma global, mas tendo por base as capacidades e características de cada jogador, bem como as próprias circunstâncias do jogo. Deste modo, o treino e o processo de monitorização associado, permitirá a monitorização e desenvolvimento individualizado das potencialidades de cada jogador, tendo por base as suas próprias capacidades e as exigências competitivas<sup>1</sup>. Nos dias atuais, a ubiquidade da tecnologia tem modificado todos os processos de treino e de monitorização. Nos desportos coletivos indoor, por exemplo, já é possível utilizar sistemas de rastreamento utilizando tecnologia de base ultra-wide-band, que permite recolher dados posicionais com grande precisão e assim, capturar dados de variáveis cinemáticas, mecânicas e metabólicas. A importância da utilização deste tipo de tecnologia foi recentemente reforçada pela FIFA, quando aprovou o uso de micro-sensores específicos e dispositivos wearable em jogos oficiais de futebol e futsal,

abrindo assim novas perspetivas para a compreensão da performance física e fisiológica dos jogadores durante os cenários competitivos <sup>4</sup>.

Ao longo dos anos, e tendo por base o conhecimento desenvolvido em outros desportos <sup>2, 3</sup>, a monitorização das exigências competitivas através de dados posicionais tem sido realizada através de variáveis de carga externa <sup>2, 5, 6</sup>. A carga externa pode ser classificada em três grandes categorias: (a) cinemática, que quantifica os deslocamentos durante o exercício; (b) mecânica, que quantifica a exigência muscular durante o exercício; e (c) metabólica, que quantifica de forma indireta, tendo por base as exigências cinemáticas e mecânicas, a energia despendida durante o exercício <sup>11</sup>. Com estes dados de carga externa é possível criar perfis de desempenho individualizados<sup>4</sup>, através do trabalho realizado pelos jogadores durante o jogo, tendo por base as variáveis: (i) distância percorrida; (ii) distância percorrida a diferentes intensidades; (iii) aceleração e desaceleração; (iv) impactos em diferentes intensidades; ou algoritmos específicos que permitem o cálculo da carga individual (i.e., Player load) ou da potência metabólica (i.e., Metabolic power) <sup>3, 5, 6</sup>.

Apesar do recente aumento de publicações para a caracterização das exigências do futsal nos últimos anos, a maioria dos estudos procurou a caracterização geral do jogo sem atender aos diferentes perfis de jogadores que constituem uma equipa, e tendo por base sistemas de tracking baseados em análise de vídeo <sup>14-18</sup>. Que tenhamos conhecimento e até ao momento, apenas dois estudos investigaram os dados de exigência física utilizando tecnologia wearable (*GPS* ou acelerómetros) em jogos oficiais de futsal e com jogadores de elite, ambos da Liga Profissional de Espanha. Num destes estudos, os autores procuraram caracterizar a repetição dos cenários de maior exigência física do jogo comparando com os dados semanais do treino <sup>19</sup>. Os autores concluíram que a sessão de treino dois dias antes da competição é a mais parecida com as exigências cinemáticas e mecânicas da competição. Noutro estudo, descreveram-se as exigências físicas de acordo com as posições dos jogadores em campo <sup>20</sup>, e os autores verificaram que os jogadores que atuam na posição de fixo têm menos distância percorrida de alta intensidade ao longo do jogo que os jogadores que atuam na posição de ala. No que diz respeito às acelerações e desacelerações os autores não verificaram diferenças significativas entre posições.

Sabendo que hoje o acesso a este tipo de informação é cada vez mais comum e de fácil utilização, urge a adoção de métodos diferenciados que potenciem, não apenas

a descrição das exigências globais das modalidades, mas sim a identificação da informação que permite melhorar a individualização do processo de treino, contribuindo para melhorar a prestação individual de cada jogador ao serviço da equipa<sup>7-9</sup>. Neste sentido, a utilização de técnicas de machine learning que permitam a identificação das variáveis mais relevantes para explicar o rendimento desportivo ou mesmo a definição de perfis de atividade de rendimento será fundamental para suportar as decisões de treinadores e profissionais da modalidade<sup>10</sup>. Do mesmo modo, este processo deverá permitir uma resposta às necessidades do treinador em tempo útil, através de variáveis fiáveis e informativas para os objetivos pretendidos<sup>11</sup>. Neste sentido, este estudo teve como objetivos: i) identificar a colinearidade entre variáveis analisadas, de modo a identificar as variáveis que permitem de forma simplificada informar o treinador sobre o estado dos seus jogadores e sua prestação; ii) utilizar processos de machine learning não supervisionado para classificar perfis de atividade dos jogadores de futsal tendo por base as exigências cinemáticas, mecânicas e metabólicas do jogo, de modo a permitir uma maior compreensão dos impactos da competição de forma individualizada.

## **Materiais e Métodos**

A amostra foi composta por 28 jogadores de futsal (idade:  $24.1 \pm 3.4$  anos), do sexo masculino, pertencentes a oito equipas de futsal que participaram na Final Eight da Taça de Portugal de 2018 e que aceitaram participar no estudo.

Os critérios de inclusão foram os seguintes: (1) ser jogador de campo; (2) não reportar qualquer tipo de limitação física ou lesão; e (3) jogar em ambas as partes de cada jogo. Todos os jogos foram realizados no mesmo pavilhão. O protocolo do estudo seguiu as normas e regras aprovadas pela Comissão de Ética da Universidade da Beira Interior (CE-UBI-Pj-2018-029) conforme as recomendações da Declaração de Helsinki.

## Desenho

Foi usada uma pesquisa observacional para medir e analisar a carga externa dos jogadores que participaram na Final Eight da Taça de Portugal de 2018. Os quatro jogos dos quartos de final e os dois jogos das semifinais tiveram um mínimo de 48h de intervalo entre eles. De acordo com as regras oficiais de futsal, foram jogadas duas partes de 20 minutos de tempo efetivo.

## Metodologia

A atividade dos jogadores foi medida através de um sistema tecnológico de tracking com ultra-wide-band da WIMU PRO™ (Realtrack Systems, Almeria, Espanha). Os dispositivos foram ligados 10 a 15 minutos antes do aquecimento e colocados nos jogadores através dos coletes de neopreno (Figura 1).

Os dados do início até ao fim do jogo, com exceção do intervalo e do minuto de pausa que cada equipa técnica pode pedir em cada parte do jogo, foram analisadas através do software SPRO (Realtrack Systems SL, Almeria, Espanha). A precisão e confiabilidade destes dispositivos foram anteriormente verificadas e validadas <sup>21</sup>.



Figura 1. Dispositivo Wimu

Dos dados posicionais, as variáveis foram extraídas com base nas três principais categorias de carga externa<sup>11</sup>: (a) cinemática; (b) mecânica; e (c) metabólica. Consultar **tabela 1** para verificar os detalhes das variáveis consideradas. Os valores relativos (tempo efetivo de jogo) de cada variável foram calculados.

**Tabela 1.** Variáveis de carga externa investigadas no estudo

Dimensão	Variável	Sub-Variável	Unidade	Descrição	
Cinemática	Distância Total Percorrida (m)	Total	m	Distância total percorrida em m	
		Total	m/min	Distância total percorrida em m/min	
	Distância Percorrida Relativa (m.min <sup>-1</sup> )	Walking	[0-6 Km/h]	m/min	Distância total percorrida entre os 0-6 Km/h por minuto
		Jogging	[6.1-12Km/h]	m/min	Distância total percorrida entre os 6.1-12 Km/h por minuto
		Running	[12.1-18 Km/h]	m/min	Distância total percorrida entre os 12.2-18 Km/h por minuto
		Sprinting	[18.1-30 Km/h]	m/min	Distância total percorrida entre os 18.1-30 Km/h por minuto
	Sprintes	Total	SPR/n/min	Frequência > 18 Km/h durante > 1s numa janela de 1 min	
Velocidade Máxima (Km/h)	Max	Speed <sub>AVG</sub>	Velocidade máxima média		
Mecânica	Impactos (Imp/min)	Total	IMP/n/min	Total impactos realizados por minuto > 5g force	
	Acelerações	Total	ACC [>2 m /s <sup>2</sup> ] n/min	Numero de ACC por minuto	
	Desacelerações	Total	DEC [>-2 m/s <sup>2</sup> ] n/min	Numero de DEC por minuto	
	Saltos	Total	JUM/n/min 400ms flight time	Numero total de saltos por minuto	
	Dynamic Stress Load (a.u)	Total	DSL/a.u/min	Total de impactos ponderados acima de 2g por minuto	
	Player Load (a.u)	Total	PL/a.u/min	Carga acumulado no acelerómetro nos 3 eixos	
Metabólica	Metabolic Power (W/Kg)	Total	MP/min	Produto da velocidade e custo energético da inclinação e aceleração	
	High Metabolic Load Distance (W/Kg)	Total	HMLD/min	Distância percorrida por um jogador quando a potência metabólica é > 25,5Kw/kg (corresponde a uma velocidade > 19,8 km/h)	

## Procedimentos estatísticos

A normalidade dos dados foi verificada através do teste de Kolmogorov-Smirnov.

O teste de correlação de Spearman foi utilizado para verificar a colinearidade entre as variáveis. A exploração de dados foi conduzida com base na matriz de correlação que é produzida pela função “corrplot” na linguagem de programação em R. Os critérios adotados para categorizar as magnitudes das correlações (r) foram as seguintes: 0,1, trivial; >0,1-0,3, pequeno; >0,3-0,5, moderado; 0,5-0,7, grande; >0,7-0,9 muito grande; e >0,9-1,0, quase perfeito<sup>23</sup>. Foram utilizados correlogramas em que a intensidade da cor aumenta à medida que a correlação se aproxima de um. Os coeficientes de correlação “vermelhos” realçam um coeficiente negativo e os “azuis” coeficientes positivos.

Para classificar os jogadores de acordo com os seus perfis de performance ao longo de todo o jogo, foi implementado um algoritmo de machine learning não supervisionado, mais especificamente, uma análise de classificação automática em duas etapas, com critério de Schwartz's Bayesian. Esta análise foi usada para constituir automaticamente grupos de desempenho de jogadores o mais diferentes possível e identificar as variáveis que maximizam a distância entre esses mesmos grupos <sup>22</sup>. Posteriormente, foi utilizada uma ANOVA simples, para testar diferenças nas variáveis dependentes de acordo com os grupos obtidos no procedimento de classificação automática.

## Resultados

### Colinearidade entre variáveis de Carga Externa

A Figura 2 apresenta o nível de magnitude das correlações entre todas as variáveis utilizadas no estudo. As variáveis que revelaram maior número de associações foram as seguintes: distância percorrida, desaceleração, metabolic power e o jogging. Por sua vez, o número total de impactos, player load, dynamic stress load e o número de saltos não revelaram qualquer tipo de correlação com as outras variáveis. A única correlação negativa encontrada foi entre metabolic power e o jogging.

### Classificação do Perfil Físico dos Jogadores de Futsal

Através do algoritmo de machine learning não supervisionado, os jogadores foram classificados em três grupos distintos de acordo com o perfil de exigência de carga externa obtido: elevado, médio e baixo (**tabela 2**), contendo respetivamente 4.5%, 84.2% e 11.2% dos casos. A desaceleração (variável mecânica), walking, sprinting, jogging, distância percorrida e o metabolic power foram em ordem decrescente as variáveis que mais contribuíram para a discriminação do perfil dos jogadores. A desaceleração revelou diferenças significativas entre todos os perfis ( $p < 0.001$ ), enquanto as outras variáveis reportadas apenas revelaram diferenças significativas entre perfis elevados e médios e entre elevados e baixos ( $p < 0.005$ ).

**Tabela 2.** Cluster de classificação dos perfis físicos dos jogadores de futsal

Variáveis	Elevado	Médio	Baixo	Sig. (p)	PI
	M ± DP	M ± DP	M ± DP		
<i>Cinematico</i>					
Distância Percorrida/ min	364 ± 180	231 ± 46	185 ± 102	** , ++	0.992
Walking/min (0-6 km/h)	249.2 ± 120.3	100 ± 29.5	114.7 ± 64.2	** , ++	1
Jogging/min (6-12 km/h)	82.2 ± 67.3	80.5 ± 13.2	43.9 ± 37.8	+ , #	0.997
Running/min (12-18km/h)	49.8 ± 53.5	30.8 ± 15.3	16.1 ± 17.6	+	0.825
Sprinting/min (>18km/h)	26.7 ± 31.5	8.2 ± 3.18	3.9 ± 3.3	** , ++	1
Sprints (N/min)	3.0 ± 1.0	2.0 ± 1.0	2.0 ± 1.0		0.126
<i>Mecânico</i>					
ACC (N/min)	5 ± 1	6 ± 2	3 ± 2	##	0.979
DEC (N/min)	10 ± 4	5 ± 1	2 ± 2	** , ++ , ##	1
N.º de Saltos (N/min)	1 ± 1.3	0.6 ± 0.6	0.5 ± 0.46		0.376
Total de Impactos (N/min)	42 ± 27	29 ± 16	75 ± 86	##	0.968
Player Load (a.u/min)	4.3 ± 0.7	4.3 ± 1.3	6.2 ± 5.7		0.634
DSL (a.u/min)	20.7 ± 11	14.4 ± 7.9	17.2 ± 11.2		0.312
<i>Metabólico</i>					
Metabolic Power/min	16.9 ± 32.5	1.4 ± 2.6	1 ± 0.6	** , ++	0.989
HMLD/min	24.8 ± 2.3	22.9 ± 11.2	21.3 ± 7.6		0.077

M= Media; SD= Desvio Padrão; PI = Preditor de importância; \* p<0.05 Elevado com Médio; \*\*p<0.001 Elevado com Médio; + p<0.05 Elevado com Baixo; ++p<0.001 Elevado com Baixo; # p<0.05 Medio com Baixo; ## p<0.001 Medio com Baixo






Figura 2. Matriz de Correlação das variáveis de carga externa

## Discussão

Este estudo teve como objetivos: i) identificar a colinearidade entre variáveis analisadas, de modo a identificar as variáveis que permitem de forma simplificada informar o treinador sobre o estado dos seus jogadores e sua prestação; ii) definir através de algoritmos de machine learning não supervisionados perfis de atividade dos jogadores de futsal tendo por base as exigências cinemáticas, mecânicas e metabólicas do jogo, de modo a permitir uma maior compreensão de forma individualizada dos impactos da competição.

De um modo geral, os resultados revelaram ser possível sintetizar a atividade dos jogadores através de uma variável cinemática - distância percorrida, uma variável mecânica - desaceleração e uma variável metabólica – metabolic power, bem como três perfis de atividade distintos, tendo sobretudo por base a variável desaceleração.

A análise das variáveis cinemáticas revelou correlações fortes entre a distância percorrida com walking, jogging e running, o que significa que a distância percorrida possui capacidade descritiva para os intervalos de velocidade até 18km/h. Deste modo, a utilização da variável distância percorrida necessita ser complementada por uma variável como seja o sprinting, permitindo inclusivamente desempenhar um papel importante como indicador de aptidão aeróbica<sup>5</sup>. Estes resultados reforçam a necessidade de individualizar intervalos de velocidade, para se conhecer melhor a resposta física que os atletas têm no treino e que permita a comparação entre perfis de jogadores<sup>34</sup>.

Ao nível da avaliação das variáveis mecânicas, as desacelerações revelaram uma forte correlação com todas as variáveis cinemáticas exceto com o walking e uma correlação significativa também com a aceleração. Considerando a relação entre a desaceleração e a maioria das variáveis cinemáticas, pode sugerir-se que a desaceleração é a variável mais robusta para analisar as exigências físicas dos jogadores de futsal <sup>32</sup>, permitindo inclusive sintetizar as exigências mecânicas e cinemáticas do jogo de futsal.

Na análise das variáveis metabólicas apenas o metabolic power demonstrou uma correlação positiva com a distância percorrida por minuto e walking e uma correlação negativa com jogging. Esta evidência sugere que o metabolic power pode ser menos sensível a reportar cenários de exigência física elevada<sup>12</sup>.

Em suma, consideramos que o futsal é uma modalidade desportiva de grande exigência mecânica onde especialmente as desacelerações são preponderantes para a ação dos jogadores em campo. Consideramos que esta deverá ser a variável preferencial a reportar para a descrição das exigências da modalidade, sobretudo porque também permitem inferir o nível de dano muscular resultante<sup>13</sup>. A análise da distância total percorrida e dos sprints em conjugação com a desaceleração permitirá uma melhor distinção entre exigências de moderada e de alta intensidade. A variável metabólica representada pelo metabolic power, não sendo essencial, poderá ser utilizada como complemento das anteriores.

De facto, o futsal é caracterizado por um conjunto de esforços de alta intensidade e de grande exigência técnica e tática <sup>13</sup>. No entanto, o modo como cada jogador realiza e interpreta as necessidades do jogo é diferenciado<sup>7, 9, 14</sup>, potenciando o surgimento de diferentes perfis de atividade com implicações nas análises individuais de

performance desportiva<sup>26</sup>. Neste sentido, os resultados através da análise de machine learning revelaram três grupos distintos e que foram classificados de acordo com o seu nível de exigência: elevada, média e baixa. A maioria dos jogadores analisados foi classificado com perfil médio. A interpretação destes dados permite-nos perceber globalmente quais são os valores de referência de cada perfil de modo a uma intervenção mais individualizada sobre cada jogador. A variável que melhor discriminou cada um dos perfis, em linha com o observado anteriormente, foi a variável mecânica desaceleração. As variáveis cinemáticas distância percorrida, walking, jogging e sprinting revelaram também alguma capacidade discriminatória entre perfis, nomeadamente entre o perfil elevado e o perfil baixo.

Tendo por base as exigências do jogo de futsal em que exige grande solicitação de ações intermitentes, como sprints repetidos ou mudanças de direção<sup>24 19, 25</sup>, a desaceleração permite identificar e caracterizar os jogadores que apresentam maior intensidade no jogo associada a este tipo de ações<sup>12, 30</sup>. De forma interessante, os jogadores mais intensos foram os que apresentaram valores mais elevados em termos mecânicos e cinemáticos. Através dos métodos de machine learning utilizados é possível agrupar os jogadores pelo seu perfil físico, tal como já o é também em termos de recuperação<sup>27</sup>, permitindo no futuro uma associação mais clara entre exigências de esforço e recuperação. De forma concreta, será que o perfil de recuperação mais lenta ou mais rápida está associado com um perfil exigência elevada, média e baixa ou essa relação tem por base características individuais independentemente do perfil de esforço? Estas são questões determinantes para melhorar o processo de individualização do treino para o futuro.

## **Conclusões e Aplicações Práticas**

Neste estudo através dos dados de tracking e análise de machine learning, verificámos que o recurso a variáveis de carga externa, nomeadamente associadas à dimensão mecânica do movimento como sejam acelerações assumem um papel determinante na compreensão das exigências do jogo de Futsal. Fruto das características do futsal as acelerações permitem caracterizar a atividade dos jogadores bem como determinar o seu perfil de desempenho. A associação da variável desaceleração com as variáveis distância total percorrida e sprinting permite

uma caracterização mais pormenorizada e fazer a distinção entre ações de média e alta intensidade.

A avaliação da atividade dos jogadores de futsal com recurso a variáveis de carga externa não deverá considerar os valores gerais dos jogadores, mas a identificação de perfis de desempenho, sobretudo tendo por base a variável mecânica desaceleração. A transferência destas evidências para o processo de treino são muito significantes, na medida em que conhecendo a intensidade do jogo e as especificidades do desempenho de cada jogador, será possível potenciar as tarefas de treino e de recuperação, de forma a otimizar a performance de cada jogador e reduzir o risco de lesão.

### Referências Bibliográficas

1. Spyrou K, Freitas TT, Marín-Cascales E, Alcaraz PE. Physical and physiological match-play demands and player characteristics in futsal: a systematic review. *Frontiers in psychology*. 2020;11
2. Coutts AJ, Crowcroft S, Kempton T. Developing athlete monitoring systems. *Sport, Recovery, and Performance: Interdisciplinary Insights*. 2017;
3. Bourdon PC, Cardinale M, Murray A, et al. Monitoring athlete training loads: consensus statement. *International journal of sports physiology and performance*. 2017;12(s2):S2-161-S2-170.
4. Buchheit. Monitoring training status with HR measures: do all roads lead to Rome? *Frontiers in physiology*. 2014;5:73.
5. Malone JJ, Jaspers A, Helsen W, Merks B, Frencken WG, Brink MS. Seasonal training load and wellness monitoring in a professional soccer goalkeeper. *International journal of sports physiology and performance*. 2018;13(5):672-675.
6. Martín-García A, Casamichana D, Díaz AG, Cos F, Gabbett TJ. Positional differences in the most demanding passages of play in football competition. *Journal of sports science & medicine*. 2018;17(4):563.
7. Rago V, Brito J, Figueiredo P, Krstrup P, Rebelo A. Application of individualized speed zones to quantify external training load in professional soccer. 2020;
8. Rago V, Brito J, Figueiredo P, et al. Methods to collect and interpret external training load using microtechnology incorporating GPS in professional football: a systematic review. *Research in Sports Medicine*. 2020;28(3):437-458.
9. Illa J, Fernandez D, Reche X, Carmona G, Tarragó JR. Quantification of an Elite Futsal Team's Microcycle External Load by Using the Repetition of High and Very High Demanding Scenarios. *Frontiers in Psychology*. 2020;11

10. Claudino JG, de Oliveira Capanema D, de Souza TV, Serrão JC, Pereira ACM, Nassis GP. Current approaches to the use of artificial intelligence for injury risk assessment and performance prediction in team sports: a systematic review. *Sports medicine-open*. 2019;5(1):1-12.
11. Coutts AJ. Working fast and working slow: the benefits of embedding research in high-performance sport. *International journal of sports physiology and performance*. 2016;11(1):1-2.
12. Dubois R, Paillard T, Lyons M, McGrath D, Maurelli O, Prioux J. Running and metabolic demands of elite rugby union assessed using traditional, metabolic power, and heart rate monitoring methods. *Journal of sports science & medicine*. 2017;16(1):84.
13. Gatin PB, Hunkin SL, Fahrner B, Robertson S. Deceleration, acceleration, and impacts are strong contributors to muscle damage in professional Australian football. *The Journal of Strength & Conditioning Research*. 2019;33(12):3374-3383.
14. Nunes NA, Gonçalves B, Davids K, Esteves P, Travassos B. How manipulation of playing area dimensions in ball possession games constrains physical effort and technical actions in under-11, under-15 and under-23 soccer players. *Research in Sports Medicine*. 2020:1-15.