



Instituto Politécnico de Coimbra
Instituto Superior de Contabilidade
e Administração de Coimbra

Diana Sofia Almeida Assunção

Análise e gestão de dados em futebol – *Social Network Analysis*

Análise e gestão de dados em futebol – *Social Network Analysis*

Diana Sofia Almeida Assunção

ISCAC | 2021

Coimbra, Janeiro de 2021



Instituto Politécnico de Coimbra

Instituto Superior de Contabilidade
e Administração de Coimbra

Diana Sofia Almeida Assunção

**Análise e gestão de dados em futebol – *Social Network
Analysis***

Trabalho de projeto submetido ao Instituto Superior de Contabilidade e Administração de Coimbra para cumprimento dos requisitos necessários à obtenção do grau de **Mestre em Sistemas de Informação de Gestão**, realizado sob a orientação da Professora Doutora Isabel Maria Mendes Pedrosa e coorientação do Professor Doutor Rui Manuel Sousa Mendes e do Professor Doutor Fernando Manuel Lourenço Martins.

Coimbra, Janeiro de 2021

TERMO DE RESPONSABILIDADE

Declaro ser a autora deste projeto, que constitui um trabalho original e inédito, que nunca foi submetido a outra Instituição de ensino superior para obtenção de um grau acadêmico ou outra habilitação. Atesto ainda que todas as citações estão devidamente identificadas e que tenho consciência de que o plágio constitui uma grave falta de ética, que poderá resultar na anulação do presente projeto.

“Dentro de nós mora um amor gigante que supera qualquer ódio que possamos ter na vida. Um amor puro que nos transcende e a ele somos sempre fiéis. Não se explica. É um amor que só se sente. Um amor que se chama Benfica”

*Guilherme Cabral in Desabafo de um
Bicampeão*

Aos meus pais e à Nina.

AGRADECIMENTOS

Qualquer obra, e em especial um trabalho final de Mestrado, dificilmente poderá ser levada a bom porto, sem a existência de apoios institucionais e pessoais da mais diversa ordem. De uns e de outros retirei proveitos, não podendo deixar de agradecer o quão determinantes foram para a sua concretização. Todo o meu reconhecimento e gratidão vão para:

A professora Isabel Pedrosa por me ter dado a oportunidade de desenvolver este tema com ela, enquanto minha orientadora. Foi um privilégio trabalhar, mais uma vez, com uma das professoras que mais admiro em tantos anos de escolaridade.

Os professores Doutor Rui Mendes e Fernando Martins, pelo constante acompanhamento, por toda a disponibilidade e apoio prestados na recolha de dados e no desenvolvimento de todo este projeto.

Os meus pais por me apoiarem em todas as horas, por me motivarem, por me aturarem quando é dia de Benfica, por me fazerem acreditar nos meus sonhos e em todos os meus objetivos de vida. Que as minhas conquistas sejam sempre as vossas conquistas.

Os Winx por partilharem mais uma fase das nossas vidas comigo, pela motivação, pela ajuda prestada ao longo deste trabalho e por todos os momentos de desanúvio. Que estejamos sempre unidos para aplaudirmos os feitos uns dos outros

A Rute por estar presente desde sempre e para sempre. És a minha pessoa.

O Conde e o Curado, pela motivação constante, por acreditarem em mim, por me dizerem inúmeras vezes o quanto se inspiram em mim e por admirarem toda esta paixão. Um dia vamos estar todos onde queremos estar.

A todos os meus amigos que me perguntaram vezes sem conta “como vai a tese?” por me pressionarem e motivarem a chegar ao fim deste projeto. Posso dizer com orgulho que esta pergunta foi rematada para golo e que os 3 pontos são nossos.

O Duda e o Tito por todo o auxílio prestado. O maior dos sucessos para vocês.

A todos, o meu franco e profundo agradecimento.

RESUMO

Em competições de futebol de alto rendimento desportivo é crucial a análise relativa aos desempenhos coletivos de cariz tático e individual. Assim se identificam as principais características e padrões táticos e se fornece informação relevante passível de auxiliar o treinador na compreensão das particularidades da sua equipa, e das dos adversários, na tomada de decisão em contexto de jogo e no aperfeiçoamento do treino.

No jogo de futebol o movimento contínuo e constante dos jogadores é pautado por eventos e momentos críticos e disruptivos, que em muitos casos asseguram vantagens ofensivas favoráveis para a vitória competitiva.

É neste contexto que o presente projeto pretende preencher uma lacuna existente na literatura. Na essência, no plano da gestão de dados e economia do tratamento de informação, pretende-se saber se a análise parcial do jogo, considerando instantes indexados a eventos críticos, reflete o mesmo fenómeno que a sua análise integral do jogo.

Recorrendo à ferramenta de análise uPATO e a modelos matemáticos associados à *Social Network Analysis* (SNA), analisámos um jogo da época 2019/2020 da *UEFA Champions League* - Sport Lisboa e Benfica vs Olympique Lyonnais.

Os resultados obtidos mostram limitações relativas à representatividade dos fenómenos coletivos da equipa e do comportamento individual dos jogadores, quando se analisam apenas alguns eventos críticos face à análise global do jogo. Contudo, a exclusiva análise dos momentos críticos do jogo é relevante no estudo das estratégias ofensivas e na identificação dos jogadores mais relevantes nestes eventos. A sua associação com o conhecimento resultante da SNA da totalidade do jogo, poderá potenciar a gestão do comportamento dos jogadores mais eficazes ao longo de todo o jogo e, dos mais relevantes nos eventos críticos. Esta informação é fundamental para análise complementar dos eventos críticos na compreensão do comportamento dos jogadores e das equipas.

Palavras-chave: eventos críticos, análise de desempenho tático, tomada de decisão, tratamento de informação, *social network analysis*

ABSTRACT

In high performance football competitions, it is crucial to analyze the team's tactical and individual performance. Therefore, the main characteristics and tactical patterns are identified, and relevant information is provided to assist the coach in understanding the particularities of his team, and of his opponents, in making decisions in the context of the game and in improving the training.

In the football game, the continuous and constant movement of the players is guided by critical and disruptive events and moments, which in many cases ensure favorable offensive advantages for competitive victory.

It is in this context that the present project aims to fill a gap in the literature. Essentially, in terms of data management and economization of information processing times, it is intended to know whether the partial analysis of the game, regarding instants indexed to critical events, reflects the same phenomenon as the integral analysis of the game.

Using the uPATO analysis tool and mathematical models associated to social network analysis (SNA), we analyzed a UEFA Champions League game of the 2019/2020 season between Sport Lisboa e Benfica and Olympique Lyonnais.

The results obtained show limitations related to the representativeness of the collective phenomena of the team and the individual behavior of the players, when only a few critical events are analyzed instead of the overall analysis of the game. However, the exclusive analysis of the critical moments of the game is relevant in the study of offensive strategies and in the identification of the most relevant players in these events. Its association with the knowledge resulting from the SNA of the entire game, may enhance the management of the behavior of the most effective players throughout the game and, of the most relevant in critical events. This information is essential for a complementary analysis of critical events in understanding the behavior of players and teams.

Keywords: critical events, tactical performance analysis, decision making, information processing, social network analysis

ÍNDICE GERAL

1	INTRODUÇÃO	1
1.1	Motivação e problema de investigação.....	1
1.2	Questão de Investigação	3
1.3	Estrutura.....	4
1.4	Contribuição.....	4
2	REVISÃO DA LITERATURA	5
2.1	Inteligência Artificial no Futebol.....	5
2.2	Análise de desempenho tático individual e coletivo.....	8
2.2.1	Tecnologias de análise de desempenho	11
2.2.2	<i>Social Network Analysis</i>	14
2.2.2.1	Modelos matemáticos para a análise da interação de jogadores.....	15
2.2.3	Padrões.....	21
2.2.4	Eventos críticos de jogo	23
3	ESTUDO.....	27
3.1	Natureza do estudo.....	27
3.2	Metodologia.....	27
3.2.1	Caracterização da amostra	28
3.2.2	Protocolo de análise de jogo	28
3.3	Análise dos dados	30
4	RESULTADOS	33
4.1	Análise Micro	33
4.2	Análise Macro.....	45
4.3	Discussão de Resultados	53
5	CONCLUSÃO	57
	REFERÊNCIAS BIBLIOGRÁFICAS	59

ÍNDICE DE FIGURAS

Figura 3.1 - Hierarquia da ocorrência dos eventos críticos durante um jogo	29
Figura 4.1 – Valores de Degree Centrality do SLB	34
Figura 4.2 – Valores de Degree Centrality do OL	35
Figura 4.3 – Valores de Closeness Centrality do SLB	37
Figura 4.4 – Valores de Closeness Centrality do OL	37
Figura 4.5 – Valores de Betweenness Centrality do SLB.....	39
Figura 4.6 – Valores de Betweenness Centrality do OL.....	40
Figura 4.7 – Valores de Degree Prestige do SLB	42
Figura 4.8 – Valores de Degree Prestige do OL	42
Figura 4.9 – Valores de Eigenvector Centrality do SLB	44
Figura 4.10 – Valores de Eigenvector Centrality do OL	44
Figura 4.11 – Valores de Network Density do SLB e do OL	46
Figura 4.12 – Valores de Network Heterogeneity do SLB e do OL.....	47
Figura 4.13 – Valores de Reciprocity do SLB e do OL.....	48
Figura 4.14 – Valores de (out-in) - Assortativity Coefficient do SLB e OL	49
Figura 4.15 – Valores de (in-out) - Assortativity Coefficient do SLB e do OL	51
Figura 4.16 – Valores de in - Assortativity Coefficient do SLB e do OL	52
Figura 4.17 – Valores de out - Assortativity Coefficient do SLB e do OL	53

ÍNDICE DE TABELAS

Tabela 2.1 – Modelos matemáticos para análise Micro (Individual)	15
Tabela 2.2 - Modelos matemáticos para análise Meso (Sujeito - Grupo).....	18
Tabela 2.3 - Modelos matemáticos para análise Macro (Global)	19
Tabela 2.4 - Eventos críticos de jogo.....	23
Tabela 3.1 – Modelos Matemáticos selecionados	30
Tabela 3.2 - Correspondência entre eventos de jogo e a sua codificação (SLB).....	31
Tabela 3.3 - Correspondência entre eventos de jogo e a sua codificação (OL).....	31
Tabela 4.1 – Matriz de valores de Degree Centrality do SLB	33
Tabela 4.2 – Matriz de valores de Degree Centrality do OL.....	34
Tabela 4.3 – Matriz de valores de Closeness Centrality do SLB	36
Tabela 4.4 – Matriz de valores de Closeness Centrality do OL	36
Tabela 4.5 – Matriz de valores de Betweenness Centrality do SLB.....	38
Tabela 4.6 – Matriz de valor de Betweenness Centrality do OL.....	38
Tabela 4.7 – Matriz de valores de Degree Prestige do SLB	40
Tabela 4.8 – Matriz de valores de Degree Prestige do OL	41
Tabela 4.9 – Matriz de valores de Eigenvector Centrality do SLB	43
Tabela 4.10 – Matriz de valores de Eigenvector Centrality do OL	43
Tabela 4.11 – Matriz de valores de Network Density do SLB.....	45
Tabela 4.12 – Matriz de valores de Network Density do OL.....	45
Tabela 4.13 – Matriz de valores de Network Heterogeneity do SLB.....	46
Tabela 4.14 – Matriz de valores de Network Heterogeneity do OL.....	46
Tabela 4.15 – Matriz de valores de Reciprocity do SLB.....	47
Tabela 4.16 – Matriz de valores de Reciprocity do OL.....	48
Tabela 4.17 – Matriz de valores de (out-in) - Assortativity Coefficient do SLB	49
Tabela 4.18 – Matriz de valores de (out-in) - Assortativity Coefficient do OL	49
Tabela 4.19 – Matriz de valores de (in-out) - Assortativity Coefficient do SLB	50
Tabela 4.20 – Matriz de valores de (in-out) - Assortativity Coefficient do OL	50
Tabela 4.21 – Matriz de valores de in - Assortativity Coefficient do SLB	51
Tabela 4.22 – Matriz de valores de in - Assortativity Coefficient do OL	51
Tabela 4.23 – Matriz de valores de out - Assortativity Coefficient do SLB	52
Tabela 4.24 – Matrizes de valores de out - Assortativity Coefficient do OL.....	52

Lista de abreviaturas, acrónimos e siglas

AC – *Assortativity Coefficient*

BC – *Betweenness Centrality*

CC – *Closeness Centrality*

CLC – *Clustering Coefficient*

DC – *Degree Centrality*

DP – *Degree Prestige*

EC – *Eigenvector Centrality*

GD – *Graph Distance*

N/A – Não Aplicável

NC – *Network Centralization*

ND – *Network Density*

NH – *Network Heterogeneity*

NI – *Network Intensity*

OL – *Olympique Lyonnais*

PR – *Page Rank*

R - *Reciprocity*

SC – *Scaled Connectivity*

SLB – *Sport Lisboa e Benfica*

TL – *Total Links*

uPATO – *Ultimate Performance Analysis Tool*

1 INTRODUÇÃO

Neste capítulo introdutório é apresentada uma perspetiva global acerca do presente trabalho. Desta forma, este capítulo inicia-se com uma breve exposição e enquadramento do tema, fundamentando-se a motivação para a escolha do mesmo. Em seguida, definimos a questão de investigação, à qual o presente trabalho dará resposta ao longo do desenvolvimento deste trabalho de investigação. Por fim, a estrutura do relatório é exposta de forma resumida.

1.1 Motivação e problema de investigação

O futebol é um desporto de massas que move multidões e que desperta grandes paixões (Mendes, 2017), mas para além disto, é um jogo desportivo que tem vindo a evoluir acentuadamente no continente europeu, estando assim no centro de diversos projetos de investigação científica nos últimos anos de forma a ser possível obter uma melhor perceção e entendimento da análise do jogo e da *performance* individual e coletiva. As novas tecnologias e a inteligência artificial têm vindo a ser utilizadas com este objetivo.

Através da análise de grandes conjuntos de dados históricos, a inteligência artificial pode ser utilizada no reconhecimento de padrões, pontos fortes e pontos fracos dos jogadores e da sua equipa (Joshi, 2019). As novas tecnologias e a inteligência artificial são empregues na área da análise de desempenho tático, de forma a suportar o treinador e respetiva equipa técnica na tomada de decisão.

É consensual que a área de análise de desempenho tático individual e coletivo é de grande importância tanto para os treinadores como para os jogadores de futebol (Carpita et al., 2016; Clemente, Couceiro, Martins, & Mendes, 2014; Clemente, José, et al., 2016; Clemente, Martins, & Mendes, 2016a; Di Salvo et al., 2007; Garganta, 2009).

Um dos grandes objetivos da análise de jogo é a identificação dos pontos positivos e dos pontos negativos que necessitam de melhorias e de ser trabalhados mais arduamente, sempre numa lógica de potenciar o rendimento coletivo da equipa e também individual (Benfica, 2019).

A análise de jogo fornece informações essenciais para otimizar e melhorar a estratégia utilizada, potenciando determinados momentos e aspetos do jogo em função do adversário que irá defrontar, tomar decisões cada vez mais bem suportadas e sustentar um ciclo permanente de *feedback* entre a equipa técnica e os jogadores. Na prática, hoje em dia, os jogadores recebem estas informações de uma forma suave e apelativa, sendo que, por vezes, são estes que mostram o interesse em obter e procurar ter conhecimento de informações específicas (Benfica, 2019).

A revolução que ocorre atualmente no futebol não estaria disponível sem as tecnologias avançadas de análise de desempenho com base no vídeo, na interação entre jogadores e na georreferenciação (Kröckel, 2019).

A área da análise de desempenho tático no futebol continua a desenvolver-se e a literatura não olha apenas para as estatísticas e indicadores básicos, mas também para as interações entre os jogadores que poderão estar limitadas por fatores como, por exemplo, o resultado ou o local de jogo. A análise de redes humanas, baseada na teoria de grafos, é um tipo de análise que auxilia a observação de padrões que são produzidos da interação entre os jogadores (Wasserman & Faust, 1994). Ao traçar as interações entre os jogadores como uma rede, é viável utilizar modelos matemáticos em diferentes níveis de análise, como ao nível do jogador, subgrupo e equipa, observar como estes se modificam ao longo do tempo e vinculá-las a resultados bem ou mal sucedidos (Kröckel, 2019). Por outras palavras, é relevante identificar os jogadores que mais contribuem para a equipa, entender a cooperação entre os colegas de equipa e o quão independente é um jogador específico e, por fim, conhecer a equipa como um todo.

Deste modo, a análise de redes humanas permitirá o reconhecimento e a identificação de padrões de comportamento tanto da sua equipa como da do seu adversário, tornando-se numa ferramenta poderosa para auxiliar o treinador a conhecer melhor a sua equipa e para apoiar a sua tomada de decisão. O conhecimento que a equipa técnica tem, acerca do adversário, permite-lhes planificar e preparar ainda melhor o treino, possibilitando a abordagem e a potenciação de certos momentos e aspetos do jogo, em função do adversário que irá defrontar e das suas respetivas especificidades.

O jogo de futebol emerge do entrelaçamento das ações desenvolvidas pelos jogadores e equipa e também de eventos críticos que surgem no decorrer dos mesmos (Garganta, 2001). Estes eventos críticos podem ser precedidos por períodos de instabilidade no

equilíbrio entre o comportamento das duas equipas em campo, sendo pertinente ter em consideração qual o impacto destes no desempenho tático da equipa. Consequentemente, para a análise de jogo, a identificação deste tipo de eventos é considerada como uma tarefa importante (Liu, Hopkins, et al., 2016).

Apesar da importância da identificação de eventos críticos de jogo e considerando os avanços recentes na análise de desempenho tático, detetou-se e identificou-se uma lacuna na literatura. Existe uma carência de estudos que suportem a tomada de decisão dos treinadores tendo em conta a diferenciação dos eventos críticos de jogo e respetivos instantes significativos, ou seja, existe uma falha na literatura no que se refere à informação relevante que um jogo completo pode fornecer em comparação com instantes críticos que mostram as verdadeiras dinâmicas do jogo.

Deste modo, este projeto, de uma perspetiva académica, examina uma área e questões que ainda não foram suficientemente investigadas na literatura científica, incitando o preenchimento da lacuna acima identificada. Portanto, este projeto investiga as interações existentes entre jogadores, através da análise de redes humanas, detetando padrões nestas. Para além disso, é um dos primeiros que reconhece as situações de jogo que devem ser consideradas como críticas e os instantes em que é pertinente proceder a uma análise focada em certo evento de jogo. Por outro lado, o presente trabalho define as informações úteis que uma análise pré e pós eventos críticos pode fornecer ao treinador e respetiva equipa técnica, investigando as vantagens e desvantagens da potencialidade da utilização de uma abordagem baseada na análise do jogo completo face à análise do jogo com eventos críticos.

1.2 Questão de Investigação

Para abordar a carência na literatura acima identificada, este projeto visa responder a seguinte questão de investigação: Podem ser reduzidos os custos de tempo e de gestão de dados para análise do jogo de futebol e do padrão do comportamento dos jogadores (nível micro) e da equipa (nível macro) que lhes estão subjacentes?

1.3 Estrutura

Para alcançar o propósito deste trabalho, delineamos o plano numa abordagem em 5 capítulos.

A revisão da literatura é discutida no capítulo 2. Este capítulo fornece uma base teórica e conceitual, que apresenta o tema e os principais conceitos da análise de dados desportivos em futebol que precisam de ser compreendidos para o acompanhamento do trabalho. Trata-se principalmente da inteligência artificial no futebol, de análise de desempenho tático individual e coletivo e das tecnologias disponíveis, da análise de redes humanas e modelos matemáticos, padrões e eventos críticos de jogo. No fim deste capítulo, o leitor estará familiarizado com o estado da arte referente a estes conceitos.

No capítulo 3, Metodologia e Dados, definiu-se a natureza do projeto e o protocolo de análise de jogo, a recolha de dados e escolha dos eventos críticos de jogo e as ferramentas tecnológicas a utilizar para o desenvolvimento deste trabalho.

Os resultados deste projeto são apresentados e discutidos no capítulo 4.

Por fim, no capítulo 5, estão presentes as conclusões do presente projeto, as suas limitações e as recomendações para estudos futuros.

1.4 Contribuição

Através deste estudo, é expectável que o nosso contributo possa ser relevante na redução de recursos temporais, humanos e de volume de dados na análise de fenómenos humanos complexos, como é o caso do contexto da análise de redes humanas que é utilizada para a tomada de decisões que potenciem o desempenho humano individual e coletivo.

2 REVISÃO DA LITERATURA

Este capítulo expõe uma visão geral dos principais termos e conceitos relacionados com a análise de dados desportivos em futebol e que contribuem para sua melhor compreensão.

2.1 Inteligência Artificial no Futebol

O Futebol, enquanto jogo desportivo, evolui de forma acentuada no mundo e em particular na Europa. Tal reflete-se nos métodos de treino e no enquadramento socioeconómico desta modalidade coletiva. A sua compreensão e a necessidade de o rentabilizar conduz à inevitável análise do jogo, dos seus protagonistas e da interação entre estes.

Atualmente, a inteligência artificial tem vindo a ser utilizada com este propósito (Wallace, 2019). Desta forma, a inteligência artificial pode ser utilizada em várias vertentes nesta modalidade: na tomada de decisões ao nível organizacional (Ward et al., 2019); no recrutamento e otimização do investimento no jogador, ou seja, na compra de jogadores (Mehr & Shirazi, 2012; Mosele, 2018); no acompanhamento da *performance* do jogador e na prevenção de lesões (Claudino et al., 2019; Henriques, 2018; Kampakis, 2016; Mosele, 2018; Rossi et al., 2018); na análise de informação tática (Cintia et al., 2015; Joshi, 2019; Memmert & Rein, 2018; Mosele, 2018; Rein & Memmert, 2016); na previsão de resultados (Bunker & Thabtah, 2019; Fialho et al., 2019; Min et al., 2008); na linha de golo, ajudando o árbitro na tomada de decisão em determinados lances de remate e golo (Wallace, 2019); no *tracking* da bola (Kamble et al., 2019).

Como atualmente as ligas de futebol europeias estão a tornar-se cada vez mais competitivas, as novas tecnologias podem ajudar a melhorar o desempenho desportivo dos atletas ou da equipa.

A ligação criada entre a ciência e a tecnologia para aumentar a eficiência desportiva tem sido apresentada como um caminho com um futuro promissor (Claudino et al., 2019). Pottala (2018) afirma que o impacto da inteligência artificial no desporto é significativo e continuará a crescer. Portanto, os clubes e as equipas começam a procurar por vantagens

na mudança da forma de jogar, com a ajuda da inteligência artificial, de modo a tornarem-se melhores que os seus adversários. Por exemplo, existem dados históricos dos jogadores que podem ser recolhidos, tratados e analisados de forma a prever o futuro, podendo isto trazer vantagens para os clubes, pois, ao conhecer bem o seu adversário estatisticamente e historicamente, o treinador consegue maximizar a *performance* dos seus jogadores de acordo com o seu oponente.

No que se refere ao acompanhamento da *performance* dos jogadores, Mosele (2018) afirma que a introdução de sistemas de inteligência artificial, em conjunto com *wearable technology*, consegue apoiar um acompanhamento eficaz de todos os fatores relevantes que podem afetar a condição física dos jogadores. Existem cada vez mais registos detalhados de jogos de futebol obtidos por meio de tecnologias de *tracking* de última geração, para além dos dados de treino físicos recolhidos através de *wearable technology* (e.g., *realtracksystems* em <http://www.realtracksystems.com>).

Contudo, a enorme quantidade de dados torna-se num obstáculo no que se refere a modelos de tomada de decisões táticas (Rein & Memmert, 2016). Passámos de um mundo de carência para um mundo onde há uma enorme abundância de dados e de informação, tornando-se imperativo ter conhecimento sobre que dados devemos utilizar para assegurar que são tomadas as melhores decisões, sendo fundamental rentabilizar a utilização de instrumentos e metodologias para alcançar os melhores resultados possíveis (Mendes, 2017).

De acordo com Rein e Memmert (2016), a motivação para a análise de desempenho desportivo de uma equipa é evidente. À medida que mais dados são disponibilizados e sem assistência computacional é praticamente impossível extrair informações consideradas relevantes dos dados (Grunz et al., 2012).

O futebol, tal como outras modalidades, tem um número extremamente elevado de características diretamente relacionadas com o resultado e a *performance*, existindo uma limitação no processamento de elevado conjunto de dados e correspondente informação, sendo necessária a utilização de técnicas de alto desempenho como a inteligência artificial que é útil no processamento destes dados (Fialho et al., 2019). Os *sport scientists* devem ser capazes de desenvolver estruturas de análise sistemática (Ward et al., 2019), utilizando o seu conhecimento científico e do desempenho humano. De forma a serem capazes de contribuir amplamente na melhoria da *performance* desportiva, ajudando vários

departamentos dentro da sua organização, tais como o departamento médico, de *coaching* e até mesmo o do recrutamento. Assim, *data scientists*, *sport scientists*, analistas de dados e profissionais da área desportiva devem ser capazes de trabalhar em conjunto, de modo a conseguirem tratar e analisar grandes quantidades de dados, facilitando o trabalho à equipa técnica dos clubes de futebol.

Passfield e Hopker (2017) afirmam que, cada vez mais, atletas e treinadores reconhecem que os dados detalhados de alta qualidade podem ser utilizados para informar a tomada de decisão objetiva relativa a aspetos de treino e de desempenho. Contudo, Memmert e Rein (2018) afirmam que todo o potencial da avaliação de desempenho por meio do *Big Data* está longe de ser alcançado devido às necessidades que os clubes de topo têm sentido e devido à falta de visão confiável sobre os processos subjacentes do desempenho bem-sucedido do futebol, ao nível da análise de jogo. Os autores afirmam que é necessário ter em consideração questões relativas à maneira de modelar o futebol de tal forma que conclusões relevantes sejam tiradas, apoiando assim as abordagens modernas de *coaching*. É dado novamente ênfase ao facto de que uma análise rigorosa de grande conjuntos de dados pode aprimorar o conhecimento relativo às ciências do desporto, informando treinadores de estratégias competitivas e permitindo a abertura a novas investigações e descobertas nesta área (Passfield & Hopker, 2017).

Os sistemas de inteligência artificial podem ser utilizados no aconselhamento da compra e venda de jogadores de futebol tal como Mehr e Shirazi (2012) sugeriram no seu trabalho científico. Estes sistemas são baseados em opiniões de profissionais de *scouting*, de jogadores e até de gestores desportivos e apresentam várias opções de jogadores, em *ranking*, de acordo com as suas características táticas e pessoais, para a posição pretendida.

Para além disto, também existe um certo potencial da inteligência artificial no que se refere à estimativa de valor dos jogadores, vinculando o valor ao desempenho efetivo do mesmo, ajudando assim a equipa de *scouting* a avaliar adequadamente os jogadores e o impacto que poderão trazer à equipa, evitando-se a ocorrência de más transferências e consequente prejuízo financeiro (Mosele, 2018).

Cintia et al. (2015) mostram que existe um grande potencial para aumentar a compreensão do desempenho das equipas de futebol. Através de um conjunto de indicadores de desempenho baseados nos passes realizados durante vários jogos de futebol, observaram

uma forte correlação entre estes e o sucesso de uma equipa, ou seja, o desempenho da equipa durante um jogo de futebol depende em certa parte dos passes realizados entre os jogadores.

De acordo com Joshi (2019), a inteligência artificial pode ser utilizada na identificação de padrões na tática, forças e fraquezas dos adversários enquanto a preparação para os jogos decorre. Isto ajuda os treinadores a elaborar estratégias e planos detalhados de treino e/ou de jogo tendo por base a avaliação dos adversários, aumentando assim a probabilidade de vitória. Mosele (2018) afirma que a inteligência artificial pode e deve ser empregue com sucesso nesta área, apoiando a preparação tática do treinador e dos jogadores, tornando clara e quantificável a evolução das equipas ao longo dos jogos, criando assim um histórico da mesma.

2.2 Análise de desempenho tático individual e coletivo

No que se refere à análise de desempenho tático ao nível dos desportos coletivos, segundo Garganta (2009), a investigação tem estado mais orientada para uma vertente de *performance* física dos jogadores, deixando de parte o estudo do desempenho tático das equipas. Desta forma, é crucial alterar esta situação, pois a informação sobre o desempenho tático pode ser vantajosa tanto para uma equipa técnica como para os jogadores enquanto equipa.

Assim, através da análise da informação de desempenho tático, é essencial identificar as principais características e exigências táticas para que seja possível adequar os treinos mais especificamente e aprimorando o desempenho enquanto equipa (Garganta, 2009). Este tipo de análise pode ser realizado em tempo real, no intervalo do jogo ou após o jogo, e dependendo de quando esta é feita, o foco é diferente, o que deve ser refletido no processo de análise (Janetzko et al., 2015).

O futebol é considerado o desporto mais popular no mundo, tanto em termos de participação como também de adeptos e espectadores. Como consequência, o futebol tem usufruído de múltiplas investigações científicas nos últimos anos, sendo possível uma melhor perceção desta modalidade e sua melhoria (Borrie et al., 2002). Deste modo,

vários autores têm focado o seu trabalho científico de investigação na área do desporto, mais especificamente na análise do desempenho tático de equipas de futebol.

Clemente, Couceiro, Martins e Mendes (2014), através do estudo de cinco jogos oficiais de uma equipa da Primeira Liga Profissional de Futebol Português, destacam que os modelos matemáticos de *network*, tais como a organização da equipa (coeficiente de *cluster*), a conectividade entre jogadores (*scaled connectivity*) e o(s) jogador(es) *centroid*, podem ser um instrumento poderoso para auxiliar os treinadores no entendimento das características da sua equipa, ajudando assim na tomada de decisão e no aperfeiçoamento do treino tendo por base a análise de jogo.

Noutro artigo, foram analisados os golos marcados e concedidos por uma equipa da Primeira Liga Portuguesa ao longo de uma época completa, utilizando métodos de análise de *network* de forma a identificar tendências da equipa durante as jogadas de ataque próprias e do seu adversário (Clemente et al., 2016a). Os autores afirmam que, apesar da sua abordagem reduzir o potencial de entendimento dos padrões de jogo, esta aumenta a possibilidade de identificar processos de eficácia que podem estar ocultos devido a um grande conjunto de dados de sequências de passes completas.

Clemente et al. (2016a) concluíram também que os modelos matemáticos para a análise da interação de rede podem proporcionar uma nova visão e compreensão dos comportamentos dos jogadores da equipa, fornecendo aos analistas de desporto informações complementares à análise tradicional.

A abordagem de *network* foi utilizada por Clemente, José, et al. (2016) para investigar, através de níveis de centralidade, a influência de variáveis situacionais como o tipo de liga competitiva (comparação entre a Liga Espanhola e a *Premier League*), a pontuação na liga em causa e a posição tática dos jogadores. Chegou-se à conclusão de que as diferentes ligas e pontuações não tiveram influência estatística nos níveis de centralidade de cooperação como equipa, mas as posições táticas dos jogadores sim.

No que se refere à centralidade, Clemente, Couceiro, Martins, Mendes, et al. (2014) realizaram uma revisão à metodologia do *centroid* ponderado de forma a incluir as posições do guarda-redes e da bola na análise do jogo. Os autores optaram por este procedimento, pois apesar dos movimentos do guarda-redes serem um pouco mais limitados em relação aos restantes jogadores, estes não podem ser excluídos do cálculo do *centroid*, ou seja, se a bola estiver mais próxima do guarda-redes, este será mais

relevante do que qualquer outro jogador mais avançado. Portanto, os autores concluem que a inclusão das posições de todos os membros da equipa e da posição da bola permite uma maior compreensão dos comportamentos da equipa, melhorando a análise dos jogos e permitindo uma rápida tomada de decisão durante o decorrer de um jogo.

A análise do desempenho tático de uma equipa também se pode basear nos dados posicionais e no comportamento dos jogadores em dois campos de tamanhos diferentes, tal como Morillo-Baro et al. (2015) examinaram, ou seja, os autores estudaram se o comportamento dos jogadores se alterava ao reduzir o tamanho do campo em que jogavam. Este tipo de adaptação do campo é usualmente utilizado pelos treinadores de futebol no treino diário para aumentar a pressão da equipa com a posse de bola e para reduzir o tempo de tomada de decisão do jogador.

Di Salvo et al. (2007) estudaram as diferenças entre as posições táticas de jogo e a exigência ao nível da distância percorrida pelos jogadores de futebol de elite em cada uma das suas posições durante o jogo, pois existe um consenso nas ciências do desporto que o treino mais eficaz de preparação de atletas para um nível superior ao normal é aquele que replica as condições de desempenho competitivo. Portanto, os autores concluem que os treinadores ao prescreverem um treino devem ter em consideração os requisitos específicos das posições de jogo dos jogadores, garantindo assim que estes cumpram da melhor forma as suas responsabilidades táticas durante o jogo.

A relação entre o resultado dos jogos de futebol (vitória, derrota ou empate) e um conjunto de variáveis, que descrevem as ações decorrentes do jogo foi investigada através da análise de 4 épocas da liga italiana profissional de futebol (Carpita et al., 2016). O principal objetivo desta investigação foi eleger, dentro de inúmeras variáveis, aquelas que mais afetavam a probabilidade de ganhar um jogo e reconhecer as regularidades ao longo das 4 épocas (por exemplo, o número de oportunidades de golo criadas pela equipa visitante e pela equipa que joga em casa ou o número de ações defensivas pelas duas equipas). Assim, os autores concluem que análises estatísticas dos jogos conseguem ajudar os profissionais desportivos a entender melhor o que precisam e necessitam fazer, sendo útil definir uma estratégia de ataque ou de defesa durante o jogo que está a decorrer. É de salientar que todos os autores referidos chegam a um consenso comum de que a análise de desempenho tático individual e coletivo é uma área de grande importância para os treinadores e jogadores de futebol. Sendo que um dos principais objetivos da análise

de jogo é identificar os pontos fortes que podem ser construídos e os pontos fracos que insinuam áreas de melhoria, os treinadores têm a possibilidade de servir, por exemplo, da análise de desempenho dos adversários e tentar combater os seus pontos fortes e explorar ainda mais os pontos fracos (Carling et al., 2005).

A análise de jogo fornece informações pertinentes e essenciais para otimizar as sessões de treino, melhorar a estratégia adotada e tomar decisões mais conscientes durante os jogos, sendo que o treinador e respetiva equipa técnica deverão utilizar esta análise como um ciclo permanente de feedback. Posto isto, variáveis como o modelo de jogo, esquema tática e outras associadas à intervenção dos treinadores podem ser determinantes no momento de restringir a organização da equipa enquanto um todo e a flexibilidade do jogo, ou seja, a perceção e conhecimento destas variáveis otimizará o desempenho tático da equipa (Clemente, Martins, & Mendes, 2016b).

Com os desenvolvimentos atuais no futebol, Janetzko et al. (2015) afirmam que os treinadores querem decidir cada vez menos por intuição própria, mas mais com base em factos e valores concretos recolhidos de uma vasta gama de meios e métodos que têm vindo a ser aperfeiçoados ao longo dos anos, procurando assim, através da análise de jogo, benefícios para aumentarem os seus conhecimentos e melhorarem a *performance* desportiva dos jogadores e das equipas (Garganta, 2001).

Posto isto, a análise do desempenho tático pode possibilitar a configuração de modelos de atividade dos jogadores e das equipas, a identificação da correlação da eficácia de processos e a obtenção de resultados positivos, a promoção de métodos de treino que garantam uma maior especificidade e o desenvolvimento de modelos de análise que reflitam a dinâmica das equipas, indiciando tendências evolutivas e ajudando a simular e a prever o seu comportamento no futuro (Garganta, 2001, 2009).

2.2.1 Tecnologias de análise de desempenho

O desempenho tático nos jogos depende da qualidade das ações dos jogadores no espaço e no tempo durante o jogo para se ser bem-sucedido. Nas últimas décadas, têm-se utilizado técnicas e abordagens para a identificação do comportamento individual e coletivo dos jogadores, de modo a que seja possível definir métodos e objetivos para

explorar os pontos fracos e prevenir os pontos fortes do adversário (Clemente et al., 2016b).

Como os treinadores se esforçam constantemente para melhorar o desempenho dos atletas, a introdução da tecnologia da informação no ambiente desportivo é um grande passo para alcançar esse objetivo. Os principais intervenientes de um jogo de futebol, os jogadores, têm de ter acesso aos melhores dados, para que seja possível tomar as melhores decisões e errar o menos possível (Mendes, 2017). Portanto, tendo em isto em consideração e que o feedback é um fator importante na melhoria do desempenho das habilidades desportivas dos jogadores, os avanços nas tecnologias da informação tornaram possível o aumento e aperfeiçoamento deste feedback que os atletas recebem durante o treino ou jogos (Liebermann et al., 2002).

A tecnologia moderna tem tido um impacto tão profundo no desporto que atletas e treinadores consideram imprescindível a informação que deriva dos avanços tecnológicos.

No que se refere ao futebol, as inovações tecnológicas levaram a novas possibilidades de captura de informações espaço-temporais precisas e relativas a todos os jogadores, desvendando a dinâmica e complexidade dos jogos de futebol (Memmert et al., 2017; Ric et al., 2017). Para isto acontecer, existem vários tipos de tecnologias de análise de desempenho com base no vídeo, na interação e na georreferenciação.

A análise dos dados posicionais no futebol permite que a distribuição espacial dos jogadores durante os jogos seja descrita, através da utilização do sistema de posicionamento global (GPS), com a finalidade de melhorar a compreensão da situação tática relacionada com a dinâmica comportamental dos jogadores (Clemente et al., 2016b; Ric et al., 2017). Um exemplo da utilização de tecnologias de análise de desempenho com base na georreferenciação é o caso apresentado pelos autores Ric et al. (2017), que, ao rastrear os dados posicionais dos jogadores, pretenderam compreender se as restrições espaciais dos jogadores afetaram o seu comportamento tático e as interações entre os mesmos. Concluiu-se que a combinação de eventos de bola e dados posicionais pode ajudar os treinadores a entender o efeito de uma restrição espacial no comportamento individual e coletivo, sendo assim possível promover uma melhor exploração dos jogadores a nível coordenativo.

Nos últimos anos, vários sistemas de análise desportiva foram desenvolvidos possuindo informação que pode ser utilizada com variados propósitos como o feedback imediato, indicação de áreas que requerem melhoria de desempenho, avaliação e como um mecanismo de procura seletiva através da gravação em vídeo do jogo (Liebermann et al., 2002).

Atualmente, a capacidade para obter informação em tempo real em situação de treino e/ou de competição aumentou significativamente, colocando-se assim o desafio de conseguir sintetizar o conjunto de informações obtidas de modo a potenciar a tomada de decisão dos treinadores e, para tal, as tecnologias de análise de desempenho com base no vídeo são indispensáveis para treinadores e restante equipa técnica recolherem informação sobre a atividade individual e coletiva durante o treino e em momentos de competição de forma a tornar a análise mais objetiva, precisa e fiável (Brito de Souza et al., 2019; Lourenço, 2016). Existem algumas possibilidades para o rastreamento e análise de desempenho com base no vídeo, como por exemplo, o Datatrax ou o Prozone3 (Clemente et al., 2016b), sendo que este último sistema de vídeo e de *tracking* semiautomático foi utilizado por Monteiro et al. (2015) para caracterizar relações espaço-temporais existentes entre os jogadores intervenientes em ações defensivas.

Cada tipo de abordagem fornece informações diferentes sobre o desempenho individual e coletivo. Para o caso da análise de redes humanas aplicada ao desporto e especificamente ao futebol, os métodos semi-computacionais baseados no observador humanos são os mais adequados. Um exemplo de sistema que permite a concretização de uma análise com base na interação é o uPATO (*Ultimate Performance Analysis Tool*) que permite, a título de exemplo, a inserção de ações individuais e coletivas, sendo estas codificadas e possibilitando que seja feita uma análise através de procedimentos de rede, criando um gráfico em rede referente às jogadas realizadas entre os jogadores.

A análise de redes humanas tem sido utilizada nos últimos anos na identificação de propriedades dos gráficos e na medição dos níveis de centralidade dos jogadores e/ou das posições táticas na organização e dinâmica coletiva (Clemente et al., 2016b).

2.2.2 Social Network Analysis

Social Network Analysis (SNA), também conhecida como análise de redes humanas, é baseada na teoria de grafos, um estudo matemático relacionado com conjunto de vértices que se encontram ligados por arestas (Clemente et al., 2016b; Wasserman & Faust, 1994).

Com base na dinâmica que ocorre nos jogos, é possível considerar o futebol como um jogo de cooperação-oposição que depende das interações. Para a análise desta dinâmica, é possível utilizar técnicas e métodos baseados na análise de redes humanas (Clemente et al., 2016b). Uma rede humana, como é uma equipa de futebol, é constituída por vértices (também chamados de nós ou nodos) e arestas (também chamadas arcos), em que os vértices são representados pelo número de jogadores da equipa e as arestas são representadas pelas linhas que unem um vértice ao outro (Clemente et al., 2016b).

Resumidamente, a abordagem de rede destaca as interações estabelecidas pelos jogadores da equipa e entre a equipa adversária como um foco principal da análise de desempenho. Neste tipo de abordagem, os jogadores são vistos como nós da rede que estão conectados através de variáveis relevantes de informação, por exemplo, uma ação de passe da bola, sustentando padrões complexos de interação de colegas de equipa (Ribeiro et al., 2017). Esta abordagem fornece também uma metodologia útil para medir e analisar a comunicação entre colegas de equipa, ajudando assim a entender os seus processos e propriedades e para isso são utilizados modelos matemáticos de análise de rede. Para analisar o desempenho coletivo das equipas, é imperativo entender e determinar que parâmetros são relevantes para alcançar os principais objetivos da observação de jogo, ou seja, é importante saber obrigatoriamente o que queremos observar, com que propósito o iremos fazer e determinar, por exemplo, que modelos matemáticos podem fornecer informações importantes à equipa técnica e aos analistas (Clemente et al., 2016b; Mendes, 2017). A observação é um fator decisivo para que seja possível elaborar uma recolha de dados e uma análise efetivas e fundamentadas do que realmente nos interessa, permitindo ter mais certezas e errar cada vez menos.

2.2.2.1 Modelos matemáticos para a análise da interação de jogadores

Os modelos matemáticos de análise da interação em rede são uma ferramenta poderosa capaz de ajudar os treinadores a conhecerem ainda melhor a sua equipa e de apoiar a sua tomada de decisão, complementando os métodos de análise mais tradicionais, por exemplo, através da análise da complexidade de padrões dinâmicos nas tendências de coordenação interpessoal que surgem dentro e entre as equipas em diferentes níveis de análise (Clemente, Couceiro, et al., 2015; Ribeiro et al., 2017).

Considera-se que a mensuração dos comportamentos táticos entre jogadores e equipas permitirá, num futuro próximo, a avaliação da representatividade, por exemplo, das tarefas realizadas em situação de treino em relação aos comportamentos evidenciados em jogo, ou seja, uma maior compreensão dos efeitos do treino para o jogo (Monteiro et al., 2015).

Desta forma, a análise de redes humanas tem sido aplicada no futebol em diferentes níveis: 1) análise Micro ou análise de nível individual; 2) análise Meso que se foca na contribuição dos jogadores para o desempenho da equipa, ou seja, interação sujeito-grupo; e 3) análise Macro referente à interação global da equipa.

Para entender melhor o desempenho das equipas, importa caracterizar a contribuição individual de cada jogador, através da análise Micro. Além disso, é muito importante identificar os jogadores que mais contribuem para o processo das equipas e como os jogadores cooperam entre si (Clemente, Couceiro, Martins, & Mendes, 2014). Ao longo da revisão da literatura, foram recolhidos vários modelos matemáticos para uma análise Micro de redes humanas no futebol, tendo uma visão geral dos mesmos na tabela 2.1 .

Tabela 2.1 – Modelos matemáticos para análise Micro (Individual)

Modelo	Definição	Estudos
<i>Betweenness Centrality</i> (BC)	<p>Capta o número de vezes que um nodo liga outros dois nodos que não se ligam, servindo de ponte entre estes dois. Sem este nodo, a distância entre os dois nodos que não se ligam será maior.</p> <p>No contexto do futebol, um jogador com um elevado BC é considerado como um jogador central. Sem este jogador, a equipa teria que reajustar muitas das suas interações devido à sua dependência neste jogador.</p> <p>(Clemente et al., 2016b; Clemente, Martins, Mendes, et al., 2016; Silva et al., 2019)</p>	<p>Clemente, Martins, Mendes, et al. (2016)</p> <p>Clemente et al. (2016a)</p> <p>Gonçalves et al. (2017)</p> <p>Srinivasan (2017)</p> <p>Kröckel et al. (2017)</p> <p>Castellano e Echeazarra (2019)</p> <p>Moreira (2017)</p>

Modelo	Definição	Estudos
		Kröckel (2019)
<i>Centroid</i>	<p>Define o nodo localizado de forma mais central na rede.</p> <p>Em termos desportivos, um jogador com um elevado <i>centroid</i>, em comparação com o valor médio de <i>centroid</i>, é o jogador responsável por fazer a bola circular entre os colegas de equipa, sendo considerado o elemento central.</p> <p>(Clemente, Couceiro, Martins, & Mendes, 2014)</p>	<p>Frencken et al. (2012)</p> <p>Clemente, Couceiro, Martins, Mendes, et al. (2014)</p> <p>Morillo-Baro et al. (2015)</p> <p>Clemente, Couceiro, Martins, & Mendes (2014)</p> <p>Clemente et al. (2013)</p> <p>Lorenzo-martínez et al. (2020)</p> <p>Clemente, Martins, Couceiro, Mendes, et al. (2014)</p> <p>Clemente, Couceiro, Martins, Mendes, et al. (2013)</p> <p>Buldú et al. (2019)</p>
<i>Closeness Centrality (CC)</i>	<p>Indica a distância geodésica das ligações de um nodo com os restantes nodos da rede.</p> <p>No futebol, um jogador que tenha um valor elevado de CC realizou a maioria dos passes da equipa, sendo considerado como o jogador responsável por distribuir a bola pela equipa.</p> <p>(Clemente et al., 2016a; Silva et al., 2019)</p>	<p>Clemente, Martins, Mendes, et al. (2016)</p> <p>Clemente et al. (2016a)</p> <p>Srinivasan (2017)</p> <p>Clemente, Mendes e Martins (2014)</p> <p>Gonçalves et al. (2017)</p> <p>Kröckel et al. (2017)</p> <p>Castellano e Echeazarra (2019)</p> <p>Moreira (2017)</p> <p>Kröckel (2019)</p>
<i>Degree Centrality (DC)</i>	<p>Revela o quão central um nodo é, ou seja, representa o quão importante o nodo é para ajudar a ligar os nodos uns aos outros.</p> <p>No contexto do futebol, significa que os jogadores com maiores DC são aqueles que mais contribuíram para as tentativas ofensivas da sua equipa através dos seus passes para os restantes jogadores da sua equipa. Estes jogadores podem ser considerados como os influenciadores da equipa.</p> <p>(Clemente, José, et al., 2016; Silva et al., 2019)</p>	<p>Clemente, Martins, Mendes, et al. (2016)</p> <p>Clemente et al. (2016a)</p> <p>Clemente, José, et al. (2016)</p> <p>Clemente, Martins, et al. (2015)</p> <p>McClean et al. (2018)</p> <p>Clemente, Mendes e Martins (2014)</p> <p>Kröckel et al. (2017)</p> <p>Castellano e Echeazarra (2019)</p>
<i>Degree Prestige (DP)</i>	<p>Representa o nodo que obteve mais conexões dos outros nodos, sendo considerado o nodo prestigiado.</p> <p>Em termos desportivos, um jogador com um elevado DP pode significar que se trata de um jogador que se encontra, usualmente, bem posicionado</p>	<p>Clemente, Martins, Mendes, et al. (2016)</p> <p>Clemente, José, et al. (2016)</p>

Modelo	Definição	Estudos
	<p>proporcionando aos restantes jogadores um trajeto de passes fácil, promovendo o seu número de passes recebidos com sucesso. Este jogador pode ser considerado como crucial para o desenvolvimento ofensivo da sua equipa, pois recebe a bola com maior frequência do que os restantes jogadores durante um momento de ataque da equipa.</p> <p>(Clemente, José, et al., 2016; Clemente et al., 2016b; Clemente, Martins, Mendes, et al., 2016)</p>	<p>Clemente, Martins, et al. (2015)</p> <p>Castellano e Echeazarra (2019)</p>
<p><i>Eigenvector Centrality (EC)</i></p>	<p>Define a importância de um nodo na rede através da atribuição de pontuações a todos os nodos da rede tendo por base o número de conexões que eles têm e a importância dos nodos aos quais se conectam. Dois fatores que contribuem para o aumento do EC são: um maior número de ligações diretas com outros nodos e estar conectado a outros nodos que, por sua vez, também possuem um elevado EC.</p> <p>Um jogador com um elevado EC é um jogador que possui um grande número de interações e que interage com vários colegas de equipa que também são considerados importantes na rede, sugerindo que este jogador possui um papel de regulador central.</p> <p>Um jogador com um baixo EC é um jogador periférico, que interage pouco e quando o faz é com jogadores pouco centrais.</p> <p>(Buldú et al., 2019; Clemente et al., 2016b; Kröckel et al., 2017; Silva et al., 2019)</p>	<p>Buldú et al. (2019)</p> <p>Cotta et al. (2013)</p> <p>Kröckel et al. (2017)</p> <p>Kröckel (2019)</p>
<p><i>Page Rank (PR)</i></p>	<p>O PR é um modelo recursivo de popularidade e de importância que segue o princípio de que um nodo é popular se tiver conexões com outros nodos considerados populares.</p> <p>Assim, futebolisticamente, o PR atribui a cada jogador a probabilidade de este ter a bola após um número razoável de passes ter sido feito. (Silva et al., 2019)</p>	<p>Clemente, José, et al. (2016)</p> <p>Srinivasan (2017)</p> <p>Kröckel et al. (2017)</p> <p>Castellano e Echeazarra (2019)</p> <p>Kröckel (2019)</p>

No futebol, a cooperação existente entre os colegas de equipa é um aspeto relevante, sendo importante entender como estes cooperam e o quão autónomo ou dependente é um jogador em específico. A análise Meso permite identificar interações específicas entre colegas de equipa e padrões de interação (Clemente et al., 2016b; Silva et al., 2019). A tabela 2.2 mostra os modelos matemáticos utilizados na investigação para a realização de uma análise Meso.

Tabela 2.2 - Modelos matemáticos para análise Meso (Sujeito - Grupo)

Modelo	Definição	Estudos
<i>Clustering Coefficient (CC)</i>	<p>Mede o grau de interconectividade na vizinhança do nodo, ou seja, revela se o nodo promove uma conectividade entre os restantes.</p> <p>Um jogador com um elevado valor de CC é parte de um subgrupo de jogadores coeso que apresentam várias interações entre si.</p> <p>(Clemente, Couceiro, Martins e Mendes, 2014; Clemente et al., 2016b; Clemente, Martins, Couceiro, Mendes, et al., 2014; Silva et al., 2019)</p>	<p>Clemente, Couceiro, Martins e Mendes (2014)</p> <p>Clemente, Martins, Mendes, et al. (2016)</p> <p>Clemente, Martins, et al. (2015)</p> <p>Clemente et al. (2016a)</p> <p>Clemente, Martins, Couceiro, Mendes, et al. (2014)</p> <p>Pina et al. (2017)</p> <p>Buldú et al. (2019)</p> <p>Cotta et al. (2013)</p> <p>Kröckel et al. (2017)</p> <p>Moreira (2017)</p> <p>Kröckel (2019)</p>
<i>Scaled Connectivity (SC)</i>	<p>Revela os índices do nível máximo de conectividade de cada nodo, sendo considerado como um modelo matemático relacionado com o nível de cooperação de um determinado nodo.</p> <p>Para a análise do futebol, os valores mais elevados (tende para 1) indicam que um jogador joga com a maioria da equipa, não tendo preferências específicas. O oposto (tende para 0) sugere que o jogador tinha preferências específicas para jogar com apenas certos colegas de equipa.</p> <p>(Clemente, Martins, Couceiro, Mendes, et al., 2014)</p>	<p>Clemente, Couceiro, Martins e Mendes (2014)</p> <p>Clemente, Martins, Couceiro, Mendes, et al. (2014)</p>

As propriedades globais de uma rede providenciam informações essenciais relativamente à organização da equipa enquanto um todo, sendo o mais importante conhecer como é a sua *performance* a nível global. Isto é possível através da realização de uma análise Macro. A tabela 2.3. mostra os vários modelos utilizados por investigadores no seu trabalho científico para explicar a *performance* da equipa como um todo.

Tabela 2.3 - Modelos matemáticos para análise Macro (Global)

Modelo	Definição	Estudos
<i>Assortativity Coefficient (AC)</i>	<p>Calcula a correlação entre as características de cada par de nodos conectados, sendo que pode ser definido como a tendência dos nodos de se ligarem a nodos com nodos semelhantes.</p> <p>O valor deste coeficiente encontra-se entre -1 e 1. Um elevado valor positivo significa que os jogadores conectados tendem a partilhar propriedades semelhantes. Um valor negativo alto significa que os jogadores ligados tendem a possuir propriedades muito diferentes. Caso o valor seja próximo de 0 significa que não há forte associação dos valores de propriedade entre os jogadores conectados.</p> <p>(SAGE Publications, 2019)</p>	<p>Meghanathan (2016)</p> <p>Moreira (2017)</p> <p>Lee et al. (2015)</p> <p>Kröckel (2019)</p>
<i>Graph Distance (GD)</i>	<p>É o comprimento do caminho mais curto entre dois nodos.</p> <p>Uma equipa com um valor baixo de GD é uma equipa onde entre dois jogadores existe um conjunto de jogadores que interagem muito entre si.</p> <p>(Clemente, Martins, Mendes, et al., 2016; Silva et al., 2019)</p>	<p>Clemente, Martins, Mendes, et al. (2016)</p>
<i>Network Centralization (NC)</i>	<p>Verifica o nível de distribuição de uma rede.</p> <p>Para análise de futebol, uma centralização que tende para 0 (valores mais baixos de NC) indica que todos os jogadores possuem o mesmo nível de interação durante o jogo. Caso tenda para 1 (valores mais elevados de NC), sugere que existe um jogador chave e que a equipa tem tendência para jogar com este jogador, aumentando a heterogeneidade e a dependência nele.</p> <p>(Clemente, Couceiro, et al., 2015; Clemente, Martins, Couceiro, et al., 2014)</p>	<p>Grund (2012)</p> <p>Clemente, Couceiro, et al. (2015)</p> <p>Clemente, Martins, Couceiro, Mendes, et al. (2014)</p>
<i>Network Density (ND)</i>	<p>Resulta do rácio entre o total de conexões e o total de conexões que poderiam existir se cada nodo estivesse ligado a todos os outros nodos. É um modelo matemático que mede o relacionamento total entre os nodos da rede.</p> <p>No contexto do futebol, uma equipa com um elevado valor de densidade (tende para 1) é uma equipa altamente coesa, cujos jogadores dependem uns dos outros e que cooperam na totalidade entre si.</p> <p>(Clemente, Couceiro, et al., 2015; Silva et al., 2019)</p>	<p>Clemente, Couceiro, et al. (2015)</p> <p>Grund (2012)</p> <p>Clemente, Martins, Mendes, et al. (2016)</p> <p>Clemente, Martins, et al. (2015)</p> <p>Pina et al. (2017)</p> <p>Clemente, Martins, Couceiro, Mendes, et al. (2014)</p> <p>Kröckel et al. (2017)</p> <p>Moreira (2017)</p> <p>Kröckel (2019)</p>

Modelo	Definição	Estudos
<i>Network Heterogeneity</i> (NH)	<p>Representa a variação da conectividade entre os nodos.</p> <p>Uma equipa de futebol que contenha um elevado NH é uma equipa onde existe uma grande variância no número de interações em que cada jogador participa, sendo que isto pode resultar, por exemplo, do facto de existirem jogadores mal posicionados o que implica a terem um baixo número de conexões. Uma elevada variação da conectividade entre os jogadores revela um processo interacional com pouca coesão entre os jogadores.</p> <p>Os menores valores sugerem uma maior participação no mesmo tempo, portanto, uma participação mais homogênea.</p> <p>(Clemente, Couceiro, et al., 2015; Clemente et al., 2016b; Clemente, Martins, Couceiro, et al., 2014)</p>	<p>Clemente, Couceiro, et al. (2015)</p> <p>Clemente, Martins, Couceiro, Mendes, et al. (2014)</p>
<i>Reciprocity</i> (R)	<p>A reciprocidade é a tendência de existência de mutualidades nas ligações entre os nodos da rede, ou seja, é um modelo matemático que calcula a proporção de bidirecionais (conexão de A para B e de B para A, por exemplo) que existem na rede em relação ao TL.</p> <p>No futebol, uma equipa com alta reciprocidade é aquela em que a maioria dos relacionamentos são recíprocos.</p> <p>(Clemente et al., 2016b; Lusher et al., 2010; Silva et al., 2019)</p>	<p>Lusher et al. (2010)</p> <p>Moreira (2017)</p> <p>Kröckel (2019)</p>
<i>Total Links</i> (TL)	<p>Capta o número de ligações totais entre todos os nodos da rede.</p> <p>Um elevado TL é um indicador de uma cooperação forte entre os jogadores da equipa. Esta equipa foi a que teve o controlo do jogo visto que tiveram o maior número de interações, que devem ser resultado de uma grande posse de bola.</p> <p>(Clemente et al., 2016b; Silva et al., 2019)</p>	<p>Clemente, Martins, Mendes, et al. (2016)</p> <p>Clemente, Martins, et al. (2015)</p> <p>Kröckel et al. (2017)</p>
<i>Transitivity</i>	<p>Este modelo permite identificar tríades (conjunto de três nodos) equilibradas e o estado natural para o qual tendem as relações triádicas.</p> <p>A transitividade permite identificar a capacidade de a tríade de jogadores atuar de forma equilibrada e não com tendências como passar para o mesmo jogador. Uma equipa com um elevado valor de transitividade é uma equipa onde se formam e ocorrem vários triângulos de interações</p> <p>(Clemente et al., 2016b; Lusher et al., 2010; Silva et al., 2019)</p>	<p>Lusher et al. (2010)</p> <p>Moreira (2017)</p> <p>Kröckel (2019)</p>

2.2.3 Padrões

Sistemas com muitos elementos a interagir dinamicamente, como o caso de um jogo de futebol, podem produzir padrões ricos e variados de comportamentos que são claramente diferentes do comportamento de jogadores individuais (Clemente, Couceiro, Martins, & Mendes, 2013).

Segundo Garganta (2009), a observação dos padrões de jogo fornecem informações relevantes de como as equipas gerem as diferentes fases e momentos de jogo, sendo estas utilizadas no momento da tomada de decisões relativas ao planeamento de treino e à estratégia a ser empregue em cada partida.

O futebol é um jogo bastante dinâmico, pois as táticas e estratégias mudam com o tempo e, conseqüentemente, estes padrões observados variam de acordo com diversas variáveis, como, por exemplo, o estado do jogo, ou seja, o resultado, o tipo de competição em que o jogo se insere, o tempo decorrido, a qualidade e identidade da equipa adversária, o tamanho do campo, o local do jogo (em casa ou fora) e o próprio estilo de jogo das equipas determinam os padrões específicos das suas interações (Barreira et al., 2013, 2014; Bradley et al., 2014; Clemente et al., 2016b; Gómez et al., 2012; Janetzko et al., 2015; Lago-Peñas et al., 2011; Lago-Peñas e Lago-Ballesteros, 2011; Liu, Gómez, et al., 2016; Machado et al., 2014).

A análise de desempenho tático também se foca na observação de padrões que são produzidos ao longo dos jogos, área à qual vários autores se têm dedicado a investigar. É crucial que esta análise permita tanto ao treinador e respetiva equipa técnica como aos jogadores em campo reconhecer e identificar rapidamente os padrões de comportamento do seu adversário, procedendo a ajustes com o objetivo de impedir situações de perigo ou tirar proveito das suas fragilidades (Mendes, 2017).

Por exemplo, Barreira et al. (2013) examinaram, com base na observação de 7 jogos da FIFA World Cup 2010, se existiam diferenças nos padrões de ataque entre as duas partes dos jogos observados, através de análises estatísticas e sequenciais. Os autores concluíram que estatisticamente não existiram diferenças entre as duas partes dos jogos analisados, contudo, a nível sequencial, o estudo mostrou que os padrões respeitantes a ataques bem-sucedidos diferem significativamente da primeira para a segunda parte, sendo assim importante ter em consideração a faceta sequencial do desempenho ao

analisar o comportamento tático ofensivo no futebol. De forma semelhante, Machado et al. (2014) investigaram a influência do resultado momentâneo do jogo na elaboração dos padrões ofensivos no futebol de elite, a partir da análise dos jogos das equipas semifinalistas da FIFA World Cup 2010. Três em quatro das equipas estudadas, em situação de derrota momentânea, tiveram dificuldade em entrar na grande área do adversário, de modo que foram obrigadas a realizar cruzamentos mais frequentemente e a aproveitar-se das violações das leis do jogo por parte do adversário para conseguirem criar situações de golo. No entanto, estas três equipas, quando se encontravam em vantagem, utilizaram com mais frequência comportamentos de drible e passes mais longos para criar situações de golo, estando esta observação em concordância com os resultados obtidos por Paixão et al. (2015). Com base nos resultados que obtiveram, Machado et al. (2014) destacam a importância de manter a identidade e integridade dos comportamentos táticos das equipas, tendo sempre em mente o modelo de jogo idealizado e treinado pelos treinadores. Através do conhecimento estrutural dos padrões ofensivos eficazes, pretende-se que os padrões influenciem a equipa técnica, no sentido de procurar maior congruência entre os princípios a adotar na preparação e nos jogos propriamente ditos (Machado et al., 2013).

Como as táticas gerais do futebol envolvem uma relação permanente entre os padrões de jogo ofensivo e defensivo, Barreira et al. (2014) exploraram os padrões de recuperação de bola como um indicador de desempenho, através da análise das jogadas de ataque feitas pelas equipas semifinalistas da FIFA World Cup 2010, e verificaram que a recuperação direta da posse de bola nas zonas médio-defensivas aumenta a eficácia do ataque. Consequentemente, os treinadores devem ter em consideração este indicador tático aquando a organização do processo de treino da equipa, sendo fundamental a melhoria da organização defensiva coletiva e, simultaneamente, os momentos de transição rápida.

Estilo de jogo e prováveis padrões de movimento podem ser simulados como modelos físicos ou como cenários de realidade virtual controlados por computador (Carling et al., 2005). Os autores Memmert et al. (2017) afirmam que, por exemplo, através de uma hierarquia de várias redes neurais artificiais, é possível classificar automaticamente padrões táticos complexos e característicos, formações de grupos táticos e as suas mudanças dinâmicas e interações tendo por base os dados posicionais dos jogadores.

2.2.4 Eventos críticos de jogo

De acordo com Janetzko et al. (2015), jogos de futebol não são apenas compostos por movimentos contínuos dos jogadores, pois existem também momentos incisivos e críticos no decorrer dos mesmos.

No futebol, eventos críticos de jogo, como tentativa de golo, podem ser precedidos por períodos de instabilidade no equilíbrio entre o comportamento das duas equipas (Frencken et al., 2012), modificando assim a visão do jogo tanto dos jogadores como da equipa técnica. Os eventos críticos podem ser considerados como momentos chave, pois os momentos chave, em qualquer modalidade, são referidos como ações de jogo que estimulam a energia, excitação e atração do público (Penumala et al., 2019). A identificação deste tipo de eventos é considerada como uma tarefa importante para a análise de jogo (Liu, Hopkins, et al., 2016) e a caracterização das ações no jogo com maior influência na vitória pode ser útil na projeção de estilos de jogo que melhoram o desempenho das equipas (Brito de Souza et al., 2019).

Os treinadores e jogadores deverão ter em consideração de que forma é que os jogadores da equipa adversária reagem no decorrer do jogo quando um evento crítico ocorre, sendo essencial estabelecer objetivamente qual é o impacto destas variáveis de evento no desempenho da equipa (Lago-Peñas et al., 2011), podendo utilizar isto como uma aplicação prática nas rotinas de treino.

Através da análise de uma época da 1ª Liga Portuguesa de futebol, Pratas et al. (2016) chegaram à conclusão que indicadores de desempenho como os remates para golo, sanções e substituições permitem prever o tempo em que o primeiro golo é marcado pelas equipas que jogam em casa. Os autores afirmam que este tipo de descoberta pode ser útil para os treinadores quando estes planeiam táticas de ataque e tomam decisões durante o decorrer do jogo, sendo que também pode ser vantajoso aplicar exercícios de jogo tático, durante as sessões de treino, melhorando as oportunidades de remate e golo, e dão também destaque à importância dos exercícios defensivos.

Vários autores tomaram a decisão de controlar estatisticamente nos seus estudos e consequentes análises variáveis como, por exemplo, número de cartões amarelos e vermelhos mostrados ao longo dos jogos, número de cantos e faltas, não mencionando que estas variáveis se referem eventos críticos e de grande importância no jogo

(Castellano et al., 2012; Lago-Peñas et al., 2011; Liu, Gómez, et al., 2016; Paul e Mitra, 2008). Contudo, apesar de não explicarem o porquê do uso dessas variáveis, ao selecioná-las para análise indicam indiretamente que são momentos marcantes do decorrer do jogo e, assim, essas variáveis foram consideradas na tabela seguinte. Adicionalmente, Castellano et al. (2012) consideram que, através de uma análise comparativa ao longo do tempo, como análise de três campeonatos mundiais de clubes, é possível identificar que variáveis de jogo é que se tornaram mais importantes e relevantes no futebol.

Após a análise de cerca de 380 jogos da época 2012/2013 da Primeira Liga Espanhola, Liu, Gómez, et al. (2016) chegaram à conclusão que a sua pesquisa utilizou os dados de desempenho de jogos inteiros que podem não mostrar as verdadeiras dinâmicas das mesmas e recomendam que, em estudos futuros, seja feita uma divisão dos jogos por metade ou apenas por 15 minutos para uma análise mais profunda do jogo relativamente ao desempenho da equipa. Assim, a diferenciação dos momentos de jogo e respetivos períodos significativos de jogo é fundamental (Kim et al., 2019).

Memmert et al. (2017) definiram como o período crítico os 30 segundos anteriores a um evento crítico, enquanto Janetzko et al. (2015) analisaram questões específicas, algumas relacionadas apenas com jogadores em específico e outras com a equipa, que se desenvolvem antes de eventos críticos, em determinados intervalos de tempo de 2, 5 e 10 segundos.

Na tabela 2.4, são apresentados os eventos críticos que surgem na literatura.

Tabela 2.4 - Eventos críticos de jogo

Evento crítico de jogo	Autor e ano
Cartões	Janetzko et al. (2015) Liu, Hopkins, et al. (2016) Liu, Gómez, et al. (2016) Pratas et al. (2016) Lago-Peñas & Lago-Ballesteros (2011) Paul & Mitra (2008) Castellano et al. (2012) Lago-Peñas et al. (2011) Brito de Souza et al. (2019)
Cruzamento	Janetzko et al. (2015) Liu, Hopkins, et al. (2016) Bradley et al. (2014) Gómez et al. (2012) Liu, Gómez, et al. (2016) Lago-Peñas & Lago-Ballesteros (2011) Lago-Peñas et al. (2011) Jonsson et al. (2003) Brito de Souza et al. (2019)
Falta	Janetzko et al. (2015)

Evento crítico de jogo	Autor e ano
	Liu, Hopkins, et al. (2016) Bradley et al. (2014) Gómez et al. (2012) Liu, Gómez, et al. (2016) Lago-Peñas e Lago-Ballesteros (2011) Paul & Mitra (2008) Castellano et al. (2012) Lago-Peñas et al. (2011) Jonsson et al. (2003) Brito de Souza et al. (2019)
Fora de jogo	Janetzko et al. (2015) Liu, Hopkins, et al. (2016) Liu, Gómez, et al. (2016) Lago-Peñas & Lago-Ballesteros (2011) Castellano et al. (2012)
Golo	J. L. Wallace & Norton (2014) Frencken et al. (2012) Janetzko et al. (2015) Bradley et al. (2014) Gómez et al. (2012) Lago-Peñas e Lago-Ballesteros (2011) Memmert et al. (2017) Paul & Mitra (2008) Castellano et al. (2012)
Lançamento	Wallace & Norton (2014) Frencken et al. (2012)
Lesão de jogador	Wallace & Norton (2014)
Pontapé de baliza	Wallace & Norton (2014) Frencken et al. (2012)
Pontapé de canto	Wallace & Norton (2014) Frencken et al. (2012) Bradley et al. (2014) Pratas et al. (2016) Paul & Mitra (2008) Castellano et al. (2012) Lago-Peñas et al. (2011) Brito de Souza et al. (2019)
Pontapé livre	Wallace e Norton (2014) Frencken et al. (2012) Bradley et al. (2014) Pratas et al. (2016) Brito de Souza et al. (2019)
Remate	Wallace & Norton (2014) Liu, Hopkins, et al. (2016) Bradley et al. (2014) Gómez et al. (2012) Liu, Gómez, et al. (2016) Lago-Peñas & Lago-Ballesteros (2011) Castellano et al. (2012) Lago-Peñas et al. (2011) Jonsson et al. (2003) Brito de Souza et al. (2019)
Remate à baliza	Janetzko et al. (2015) Liu, Hopkins, et al. (2016) Liu, Gómez, et al. (2016) Pratas et al. (2016) Lago-Peñas & Lago-Ballesteros (2011) Paul & Mitra (2008) Castellano et al. (2012)

Análise e gestão de dados em futebol – Social Network Analysis

Evento crítico de jogo	Autor e ano
	Lago-Peñas et al. (2011)
Substituições	Wallace & Norton (2014) Pratas et al. (2016)

3 ESTUDO

3.1 Natureza do estudo

O nosso estudo é considerado de natureza quantitativa pelo facto de os dados recolhidos terem sido recolhidos e analisados de forma quantitativa recorrendo a modelos matemáticos para o efeito (Cohen et al., 2007, p. 283; Sousa e Baptista, 2011, p. 53).

3.2 Metodologia

Para a realização do presente projeto, adotou-se uma metodologia dividida em quatro fases: apreciação do estado da literatura, seriação das variáveis de estudo, neste caso, os modelos matemáticos, recolha e tratamento de dados e, por fim, análise dos dados obtidos e conclusões finais.

O desenvolvimento da primeira fase obedece a uma estrutura sistemática tendo por base uma investigação tradicional, apoiada num estudo exploratório com natureza quantitativa, no qual, recorreremos ao método de pesquisa bibliográfica e documental, possibilitando assim que o projeto se encontre devidamente fundamentado.

Deste modo, procurou-se consultar o máximo de trabalhos científicos publicados em revistas científicas da área da inteligência artificial, desporto e futebol e obras relevantes relacionados com as matérias em estudo, na base de dados *Scopus*, *b-on*, *Google Scholar* e no *Research Gate*.

Nesta primeira fase foi importante compreender e investigar o estado da arte da inteligência artificial na área futebolística e perceber de que forma a análise de desempenho tático individual e coletivo tem sido realizada nos últimos anos e através de que tecnologias tem tido por base. Para além disto, foi também pertinente abordar determinados conceitos como os modelos matemáticos de rede, padrões e eventos críticos de jogo.

Portanto, na segunda fase, a parte prática relativa a esta investigação, procedemos à recolha e tratamento dos dados necessários para o estudo. Esta fase será explicada na secção 3.3.

Por último e numa terceira fase, faremos uma análise dos dados obtidos e tiraremos as conclusões finais mais pertinentes.

3.2.1 Caracterização da amostra

Os dados utilizados neste trabalho foram recolhidos através da observação e visualização da transmissão televisiva do jogo de futebol entre o *Sport Lisboa e Benfica* (SLB) e o *Olympique Lyonnais* (OL), conhecido como *Lyon*, a contar para a fase de grupos da edição 2019/2020 da *UEFA Champions League*. A escolha do jogo considerou o elevado nível de rendimento desportivo das equipas envolvidas da competição analisada.

3.2.2 Protocolo de análise de jogo

Como foi explicitado na secção anterior, numa segunda fase, procedemos à recolha e tratamento dos dados necessários para o estudo.

Previamente à observação da transmissão televisiva dos dois jogos selecionados para a recolha de dados, estipulou-se que este caso de estudo iria possuir duas vertentes de análise de dados, pois um dos objetivos desta investigação é entender, através dos eventos críticos de jogo, que análise é mais importante e útil para a equipa técnica de um clube de futebol: a análise do jogo completo ou a análise parcial pré e pós situação crítica de jogo. Tendo isto em consideração, determinou-se que seria necessário recolher as interações realizadas entre os jogadores das duas equipas durante o jogo completo e também de forma parcial. Destas duas perspetivas de análise de jogo a que mereceu mais importância nesta fase de observação foi a análise parcial pré e pós evento crítico de jogo, porque foi crucial identificar os eventos críticos de jogo que são citados na literatura e realizar uma seleção dos que serão considerados para o estudo. A tabela 2.4. – Eventos críticos de jogo, apresentada no capítulo 2, contém os eventos críticos de jogo que foram citados na

literatura consultada, sendo possível verificar quais surgiram com maior frequência. Tendo isto em consideração, ordenando por eventos, é possível ter a percepção de que os que são mais vezes citados são a falta, o remate, os cartões, o cruzamento, o golo, o remate à baliza e o pontapé de canto.

Assim, inicialmente foram selecionados os seguintes: remate à baliza, golo, pontapé de canto, substituição e pontapé livre.

Após a seleção inicial dos eventos críticos de jogo, existiu a necessidade de os ordenar por grau de importância, de ocorrência e relevância no decorrer do jogo, de forma a compreender se deveríamos proceder à análise parcial contando com estes 5 eventos críticos de jogo. É possível observar esta ordenação na figura 3.1. Por exemplo, as substituições de jogadores são consideradas como um evento crítico que causam a mudança do comportamento tático das equipas, devendo os treinadores fazer mais substituições, por exemplo, ofensivas, para melhorar as oportunidades de golo (Lorenzo-martínez et al., 2020), contudo, depois de uma primeira observação dos dois jogos, chegou-se à conclusão que as substituições de jogadores não deveriam ser consideradas nos eventos críticos escolhidos, pois, nos jogos em causa, não traziam valor ao estudo devido à sua falta de relevância no decorrer dos mesmos.

Resumidamente, para a análise, foram escolhidos os remates à baliza, remates e golos.




Figura 3.1 - Hierarquia da ocorrência dos eventos críticos durante um jogo

Por fim e tendo em consideração os modelos matemáticos recolhidos nas tabelas 2.1, 2.2 e 2.3, para analisar as interações entre os jogadores de ambas as equipas (SLB e OL) de forma individual (análise micro) e do grupo em geral (análise macro) foram selecionados os modelos matemáticos apresentados na tabela 3.1:

Tabela 3.1 – Modelos Matemáticos selecionados

Modelo Matemático	Abreviatura	Tipo de Análise
<i>Betweenness Centrality</i>	BC	Micro
<i>Closeness Centrality</i>	CC	
<i>Degree Centrality</i>	DC	
<i>Degree Prestige</i>	DP	
<i>Eigenvector Centrality</i>	EC	
<i>Assortativity Coefficient</i>	AC	Macro
<i>Network Density</i>	ND	
<i>Network Heterogeneity</i>	NH	
<i>Reciprocity</i>	R	

Em todos os modelos matemáticos são calculados os valores estandardizados.

3.3 Análise dos dados

Posteriormente à escolha e seleção dos eventos críticos de jogo, procedeu-se ao tratamento dos dados do confronto entre Benfica e *Lyon*. Este tratamento de dados foi realizado através da utilização de uma ferramenta de análise de desempenho, o uPATO. O objetivo principal da ferramenta uPATO é modernizar a forma como a análise de jogo é realizada e utilizada em desportos coletivos, como por exemplo no futebol. Esta ferramenta é um *software* científico que possibilita a codificação das interações praticadas em qualquer desporto coletivo. Sucintamente, o observador tem a possibilidade de escolher o número de jogadores que pretende analisar, auxiliando-o assim a codificar qualquer tipo de jogo com mais de três jogadores. Para além disto, permite também a introdução de dados baseados em matrizes de adjacência e a integração de vários modelos matemáticos que são utilizados na análise de desportos coletivos (Clemente et al., 2016b; Martins et al., 2018; Silva et al., 2019).

Utilizando a ferramenta uPATO, foi treinada a observadora na análise dos dados de jogos de futebol. Sendo que, para o efeito, o treino intraobservador e interobservador, foi concretizado, com validação de dois observadores considerados experts na observação e análise de jogos desportivos coletivos, ambos docentes em instituições do ensino superior público português com formação em Ciências do Desporto. Os valores de concordância, superiores a 80% - fórmula de Bellacak - foram alcançados depois do processo de treino,

momento a partir do qual se assumiu a autonomia da investigadora para desenvolver o trabalho de pesquisa (Mendes et al., 2012).

Para calcular os modelos matemáticos selecionados anteriormente, foi necessário construir várias matrizes de adjacência onde constavam o número de interações que cada jogador realizou durante o jogo, utilizando a ferramenta uPATO. Assim, através das matrizes é possível ter a percepção dos jogadores e do número de vezes que interagiram com os seus colegas de equipa. É de referir que foram criadas matrizes por cada parte do jogo, pelo jogo completo e por cada parte do jogo antes e depois de 15 segundos do evento crítico ocorrido de cada equipa.

Após a elaboração das matrizes de adjacência necessárias, os valores dos modelos matemáticos escolhidos para usar neste estudo foram calculados com base no *software* uPATO.

O jogo entre o *Sport Lisboa e Benfica* e o *Lyon* foi analisado e os valores dos modelos matemáticos previamente selecionados das duas equipas foram calculados.

Os resultados destes modelos são apresentados na subsecção 4.1 (Análise Micro) e 4.2. (Análise Macro).

Tabela 3.2 - Correspondência entre eventos de jogo e a sua codificação (SLB)

SLB	
Evento de jogo	Codificação
Primeiro Golo	B1
Remate	B2
Remate	B3
Remate	B4
Remate à Baliza	B5
Segundo Golo	B6
Somatório Remates	Σ_R
Somatório Golos	Σ_G

Adicionalmente e, de forma a auxiliar na observação e análise dos resultados, a tabela 3.2 e 3.3 apresentam a correspondência entre os eventos de jogo e a sua codificação.

Tabela 3.3 - Correspondência entre eventos de jogo e a sua codificação (OL)

OL	
Evento de jogo	Codificação
Remate	L1
Remate	L2
Primeiro Golo	L3
Remate à Baliza	L4
Remate	L5

Análise e gestão de dados em futebol – Social Network Analysis

OL	
Somatório Remates	Σ_R

4 RESULTADOS

4.1 Análise Micro

A leitura da tabela 4.1 mostra que os jogadores do SLB com valores mais elevados de DC na 1ª parte foram o SLB5, SLB4 e SLB9, sendo que, na 2ª parte, apenas o SLB9 não manteve o seu valor elevado, passando o SLB1 a ser considerado. Globalmente, podemos constatar que os jogadores SLB4, SLB5 e SLB1 foram os que obtiveram valores mais elevados de DC. O jogador SLB5 obteve valores superiores de DC em dois momentos críticos (B4 e B5) e no Σ_R do que globalmente. O jogador SLB4 apenas obteve um valor superior de DC ao obtido na análise global. O jogador SLB1 alcançou piores valores de DC no evento crítico em que esteve presente, não retratando o que de facto ocorreu no contexto do jogo.

Tabela 4.1 – Matriz de valores de *Degree Centrality* do SLB

Jogador	1ª	2ª	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
SLB1	0,109	0,104	0,107	0,000	0,000	0,077	0,091	0,000	0,000	0,000	0,000
SLB2	0,078	0,104	0,090	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB3	0,078	0,067	0,073	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB4	0,124	0,141	0,132	0,000	0,077	0,000	0,091	0,167	0,000	0,000	0,000
SLB5	0,140	0,117	0,129	0,000	0,077	0,231	0,364	0,333	0,000	0,000	0,000
SLB6	0,016	0,000	0,008	0,000	0,000	0,000	0,000	0,000	0,077	0,000	0,077
SLB7	0,098	0,086	0,093	0,000	0,000	0,000	0,000	0,167	0,000	0,000	0,000
SLB8	0,047	0,086	0,065	0,000	0,000	0,000	0,000	0,000	0,077	0,000	0,077
SLB9	0,124	0,086	0,107	0,000	0,000	0,077	0,091	0,000	0,000	0,000	0,000
SLB10	0,093	0,018	0,059	0,077	0,000	0,154	0,273	0,000	0,077	0,000	0,077
SLB11	0,036	0,025	0,031	0,000	0,000	0,077	0,091	0,000	0,077	0,000	0,077

Quanto ao OL (tabela 4.2), os jogadores que auferem os valores mais elevados de DC na 1ª e 2ª parte e também globalmente são o OL1, OL2 e OL3. O jogador OL1 possui valores mais elevados no Σ_R e no evento crítico L3, contudo em L2 e L5 o valor de DC é menor do que se obteve na análise global. Apesar dos jogadores OL2 e OL3 se destacarem globalmente, não participaram em nenhum dos eventos críticos selecionados e analisados.

Tabela 4.2 – Matriz de valores de *Degree Centrality* do OL

Jogador	1 ^a	2 ^a	G	L1	L2	L5	Σ_R	L4	L3
OL1	0,110	0,123	0,116	0,000	0,077	0,077	0,154	0,000	0,154
OL2	0,205	0,145	0,178	0,000	0,000	0,000	0,000	0,000	0,000
OL3	0,175	0,141	0,159	0,000	0,000	0,000	0,000	0,000	0,000
OL4	0,065	0,048	0,057	0,000	0,000	0,000	0,000	0,000	0,000
OL5	0,110	0,097	0,104	0,000	0,000	0,077	0,077	0,000	0,000
OL6	0,049	0,070	0,059	0,000	0,000	0,077	0,077	0,000	0,077
OL7	0,065	0,022	0,045	0,077	0,000	0,000	0,077	0,000	0,000
OL8	0,099	0,066	0,084	0,000	0,000	0,000	0,000	0,077	0,077
OL9	0,065	0,101	0,082	0,000	0,000	0,000	0,000	0,000	0,000
OL10	0,030	0,040	0,035	0,000	0,077	0,000	0,077	0,000	0,000
OL11	0,027	0,018	0,022	0,000	0,077	0,000	0,077	0,077	0,000

Os jogadores SLB4, SLB5, SLB1, OL1, OL2 e OL3 foram os jogadores que mais contribuíram nos momentos ofensivos através dos seus passes, sendo assim influenciadores na forma de jogo da sua equipa.

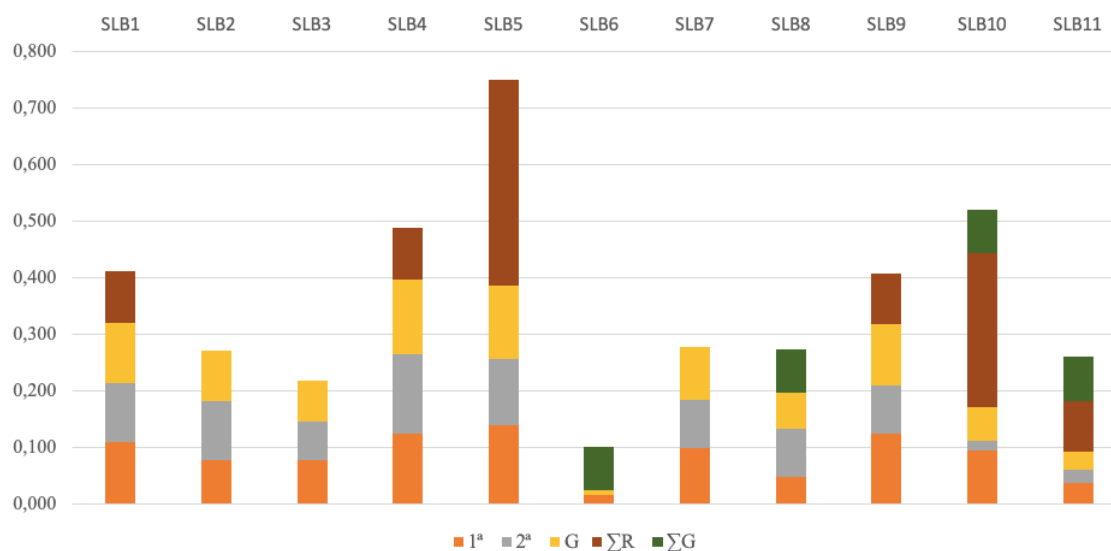


Figura 4.1 – Valores de *Degree Centrality* do SLB

Os gráficos de barras foram criados para cada modelo para que seja mais simples tecer entre os jogadores, análise global e análise de eventos críticos de jogo.

Com base na observação no gráfico de barras que representa os valores obtidos para DC do SLB (figura 4.1), verifica-se que 4 jogadores (SLB5, SLB6, SLB10 e SLB11) alcançaram valores mais elevados em Σ_R do que na análise global. Os jogadores SLB6, SLB8, SLB10 e SLB11 também obtiveram melhores valores de DC no Σ_G . Através deste gráfico, também é possível ter a percepção de que, por exemplo, o jogador SLB2 não esteve envolvido em nenhum dos somatórios de eventos selecionados.




Figura 4.2 – Valores de *Degree Centrality* do OL

No que se refere ao OL (figura 4.2), constata-se que os jogadores OL1, OL6, OL7, OL10 e OL11 são os que têm valores mais elevados de DC no Σ_R do que na análise global do jogo.

Analisando a tabela 4.3, entende-se que, na 1ª parte do jogo, os jogadores SLB1, SLB4 e SLB5 foram os que apresentaram valores mais elevados de CC, enquanto que, na 2ª parte, foram os jogadores SLB2, SLB3 e SLB4 que mais se destacaram. Numa análise global, verifica-se que os jogadores SLB3, SLB4 e SLB5 foram considerados peças fundamentais na execução dos passes do SLB, sendo que são responsáveis pela distribuição da bola pelos elementos da equipa. Os jogadores SLB4 e SLB5 alcançaram valores mais elevados de CC nos eventos críticos B3 e B5, contudo nos Σ_R e Σ_G o mesmo não aconteceu. Não obstante a importância do jogador SLB3 globalmente, não participou em qualquer evento crítico.

Tabela 4.3 – Matriz de valores de *Closeness Centrality* do SLB

Jogador	1 ^a	2 ^a	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
SLB1	2,495	1,747	2,363	0,000	0,000	1,444	1,083	0,000	0,000	0,000	0,000
SLB2	1,966	1,863	2,427	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB3	2,203	1,877	2,656	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB4	2,662	2,198	2,972	0,000	4,333	0,000	1,040	5,200	0,000	0,000	0,000
SLB5	2,272	1,797	2,801	0,000	13,000	2,600	2,000	6,500	0,000	0,000	0,000
SLB6	0,974	0,000	0,806	0,000	0,000	0,000	0,000	0,000	4,333	0,000	4,333
SLB7	2,721	1,646	2,605	0,000	0,000	0,000	0,000	2,600	0,000	0,000	0,000
SLB8	1,515	1,500	2,023	0,000	0,000	0,000	0,000	0,000	4,333	0,000	4,333
SLB9	2,122	1,569	2,478	0,000	0,000	1,857	1,368	0,000	0,000	0,000	0,000
SLB10	2,228	1,008	2,325	13,000	0,000	2,167	2,000	0,000	4,333	0,000	4,333
SLB11	1,201	0,969	1,328	0,000	0,000	1,625	1,300	0,000	2,167	0,000	2,167

A interpretação da tabela 4.4 indica que os jogadores OL1, OL2, OL3 são os que detêm os valores de CC mais elevados na equipa do OL, na 1^a e 2^a parte e na globalidade do jogo. Embora os jogadores OL2 e OL3 sejam dos mais relevantes globalmente, não participaram nos eventos críticos eleitos. O jogador OL1 alcançou um melhor valor de CC no evento L5, contudo, nos restantes, não obteve semelhante relevo.

Tabela 4.4 – Matriz de valores de *Closeness Centrality* do OL

Jogador	1 ^a	2 ^a	G	L1	L2	L5	Σ_R	L4	L3
OL1	5,027	2,172	4,197	0,000	2,167	13,000	1,857	0,000	3,250
OL2	5,884	2,506	4,410	0,000	0,000	0,000	0,000	0,000	0,000
OL3	5,950	2,416	4,426	0,000	0,000	0,000	0,000	0,000	0,000
OL4	4,461	1,650	3,478	0,000	0,000	0,000	0,000	0,000	0,000
OL5	4,085	2,130	3,742	0,000	0,000	1,300	0,520	0,000	0,000
OL6	2,568	1,374	2,558	0,000	0,000	4,333	1,083	0,000	2,167
OL7	2,648	1,149	2,170	13,000	0,000	0,000	2,167	0,000	0,000
OL8	3,803	1,704	3,153	0,000	0,000	0,000	0,000	2,167	1,300
OL9	2,938	1,963	3,140	0,000	0,000	0,000	0,000	0,000	0,000
OL10	3,208	1,584	3,111	0,000	4,333	0,000	4,333	0,000	0,000
OL11	1,911	0,896	1,837	0,000	13,000	0,000	13,000	4,333	0,000

Examinando o gráfico que representa os valores calculados para o modelo matemático CC do SLB (figura 4.3), entende-se que nenhum jogador obteve melhores resultados na análise do Σ_R do que aqueles que obteve na análise global. No entanto, os jogadores SLB6,

SLB8, SLB10 e SLB11 alcançaram resultados superiores na análise do Σ_G do que na análise global do jogo.



Figura 4.3 – Valores de *Closeness Centrality* do SLB

No que diz respeito ao OL, através da figura 4.4, verifica-se que apenas dois jogadores atingiram valores superiores de CC no Σ_R do que na análise global do jogo.




Figura 4.4 – Valores de *Closeness Centrality* do OL

Tendo por base a tabela 4.5, depreende-se que os jogadores com maior valor de BC no decorrer da 1ª parte do jogo foram o SLB1, SLB4 e SLB7, enquanto que, na 2ª parte, passaram a ser considerados o SLB5 e o SLB8 em conjunto com o SLB1. No entanto, de forma global, os jogadores SLB1, SLB4 e SLB5 foram os que atingiram os valores mais elevados de BC, sendo estes jogadores tidos em conta como jogadores influentes

fundamentais na criação de jogadas. Segundo os valores obtidos neste modelo matemático, os jogadores SLB1 e SLB4 não participaram em nenhum dos eventos críticos escolhidos, mas nos modelos CC e DC estes são considerados como participantes nos eventos. Isto pode indicar uma limitação do modelo BC. Os valores do jogador SLB5 para os eventos críticos são todos inferiores aos obtidos na análise global, contrariando também a tendência que se tem notado neste jogador.

Tabela 4.5 – Matriz de valores de *Betweenness Centrality* do SLB

Jogador	1 ^a	2 ^a	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
SLB1	0,135	0,125	0,166	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB2	0,071	0,050	0,077	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB3	0,026	0,013	0,013	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB4	0,179	0,074	0,192	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB5	0,122	0,163	0,263	0,000	0,006	0,038	0,077	0,006	0,000	0,000	0,000
SLB6	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,019	0,000	0,019
SLB7	0,218	0,008	0,119	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB8	0,026	0,111	0,068	0,000	0,000	0,000	0,000	0,000	0,013	0,000	0,013
SLB9	0,022	0,059	0,054	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SLB10	0,087	0,000	0,119	0,000	0,000	0,038	0,077	0,000	0,006	0,000	0,006
SLB11	0,000	0,000	0,000	0,000	0,000	0,019	0,026	0,000	0,000	0,000	0,000

A interpretação da tabela 4.6 indica que, na 1^a parte, os jogadores do OL com valores mais elevados de BC foram OL1, OL2 e OL3, sendo que, na 2^a parte, apenas o OL1 não manteve o seu valor, passando o OL5 a ser considerado. Numa análise global, os jogadores OL1, OL2 e OL3 foram os mais fundamentais e centrais para o OL, sendo que a equipa demonstra certa dependência neles. Apesar dos jogadores OL2 e OL3 serem dos mais relevantes globalmente, a análise dos eventos críticos não retorna valores para o modelo BC. O jogador OL1 não obteve semelhante relevo da globalidade na análise dos eventos.

Tabela 4.6 – Matriz de valor de *Betweenness Centrality* do OL

Jogador	1 ^a	2 ^a	G	L1	L2	L5	Σ_R	L4	L3
OL1	0,186	0,269	0,343	0,000	0,000	0,019	0,077	0,000	0,038
OL2	0,311	0,295	0,314	0,000	0,000	0,000	0,000	0,000	0,000
OL3	0,250	0,321	0,288	0,000	0,000	0,000	0,000	0,000	0,000
OL4	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
OL5	0,045	0,301	0,131	0,000	0,000	0,000	0,000	0,000	0,000
OL6	0,006	0,103	0,109	0,000	0,000	0,026	0,064	0,000	0,032

Jogador	1 ^a	2 ^a	G	L1	L2	L5	Σ_R	L4	L3
OL7	0,006	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
OL8	0,038	0,179	0,103	0,000	0,000	0,000	0,000	0,000	0,000
OL9	0,000	0,013	0,038	0,000	0,000	0,000	0,000	0,000	0,000
OL10	0,000	0,013	0,000	0,000	0,013	0,000	0,064	0,000	0,000
OL11	0,000	0,000	0,000	0,000	0,013	0,000	0,038	0,013	0,000

Examinando a figura 4.5, conseguimos ter a percepção de que para vários jogadores o valor de BC não foi calculado tanto no Σ_R como também no Σ_G , concluindo que este modelo matemático pode não ser o mais adequado para a análise de eventos com um curto espaço de tempo. Apesar disto, o jogador SLB11 e o SLB6 obtiveram um valor de BC maior no Σ_R e Σ_G , respectivamente, do que os valores obtidos na análise global.




Figura 4.5 – Valores de *Betweenness Centrality* do SLB

Como podemos observar na figura 4.6, o OL não possui um único jogador com valores de BC maiores na análise do Σ_R do que na globalidade. Adicionalmente, vários jogadores não têm valores para este modelo matemático, por exemplo, para a 1^a e 2^a parte.




Figura 4.6 – Valores de *Betweenness Centrality* do OL

A análise da tabela 4.7 indica que os jogadores do SLB com os valores de DP mais elevados na 1ª parte foram o SLB5, SLB9 e o SLB4, enquanto que, na segunda parte, foram o SLB1, SLB5 e o SLB8. Mas, numa análise global, verificamos que os jogadores SLB5, SLB8 e SLB9 foram considerados como jogadores cruciais para o desenvolvimento ofensivo da equipa, devido ao facto de receberem a bola com maior frequência do que os restantes jogadores no decorrer dos momentos de ataque. Apesar da sua relevância na globalidade do jogo, os jogadores SLB8 e SLB9 atingiram valores inferiores na análise dos eventos escolhidos do que na análise global, não refletindo a sua importância e participação no jogo. O jogador SLB5 alcançou melhores valores de DP no evento B4, B5 e no Σ_R do que na globalidade. É de notar que, para o evento B6, não foram calculados quaisquer valores, indicando que este modelo têm uma limitação com eventos com curto espaço de tempo e com poucas interações entre jogadores.

Tabela 4.7 – Matriz de valores de *Degree Prestige* do SLB

Jogador	1ª	2ª	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
SLB1	0,078	0,104	0,090	0,000	0,000	0,077	0,091	0,000	0,000	N/A	0,000
SLB2	0,067	0,067	0,067	0,000	0,000	0,000	0,000	0,000	0,000	N/A	0,000
SLB3	0,036	0,037	0,037	0,000	0,000	0,000	0,000	0,000	0,000	N/A	0,000
SLB4	0,098	0,092	0,096	0,000	0,000	0,000	0,000	0,167	0,000	N/A	0,000
SLB5	0,145	0,123	0,135	0,000	0,077	0,154	0,273	0,333	0,000	N/A	0,000
SLB6	0,036	0,000	0,020	0,077	0,000	0,000	0,091	0,000	0,154	N/A	0,154
SLB7	0,098	0,055	0,079	0,000	0,000	0,000	0,000	0,000	0,000	N/A	0,000
SLB8	0,088	0,117	0,101	0,000	0,000	0,000	0,000	0,000	0,077	N/A	0,077

Jogador	1 ^a	2 ^a	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
SLB9	0,124	0,080	0,104	0,000	0,000	0,077	0,091	0,000	0,000	N/A	0,000
SLB10	0,093	0,055	0,076	0,000	0,000	0,154	0,182	0,000	0,077	N/A	0,077
SLB11	0,073	0,031	0,053	0,000	0,077	0,154	0,273	0,000	0,000	N/A	0,000

A tabela 4.8 indica que os jogadores do OL que detêm os valores de DP mais elevados na 1^a e 2^a parte e na globalidade do jogo são o OL1, OL2, OL3. Estes jogadores proporcionaram aos restantes colegas de equipa um trajeto de passes acessível. O jogador OL1 alcançou um melhor valor de DP no evento L4, mas, nos restantes, o mesmo não aconteceu. Independentemente dos jogadores OL2 e OL3 serem dos mais essenciais globalmente, não participaram nos eventos críticos preferidos.

Tabela 4.8 – Matriz de valores de *Degree Prestige* do OL

Jogador	1 ^a	2 ^a	G	L1	L2	L5	Σ_R	L4	L3
OL1	0,118	0,123	0,120	0,000	0,000	0,077	0,077	0,000	0,154
OL2	0,183	0,115	0,151	0,000	0,000	0,000	0,000	0,000	0,000
OL3	0,152	0,128	0,141	0,000	0,000	0,000	0,000	0,000	0,000
OL4	0,034	0,026	0,031	0,000	0,000	0,000	0,000	0,000	0,000
OL5	0,106	0,093	0,100	0,000	0,000	0,000	0,000	0,000	0,000
OL6	0,053	0,088	0,069	0,000	0,000	0,077	0,077	0,077	0,154
OL7	0,068	0,022	0,047	0,000	0,000	0,000	0,000	0,000	0,000
OL8	0,110	0,084	0,098	0,000	0,000	0,077	0,077	0,000	0,000
OL9	0,084	0,075	0,080	0,000	0,077	0,000	0,077	0,000	0,000
OL10	0,049	0,044	0,047	0,077	0,077	0,000	0,154	0,000	0,000
OL11	0,042	0,031	0,037	0,000	0,077	0,000	0,077	0,077	0,000

Com base na observação no gráfico de barras que representa os valores obtidos para DP do SLB (figura 4.7), verifica-se que 5 jogadores: SLB1, SLB5, SLB6, SLB10 e SLB11 alcançaram valores superiores em Σ_R do que na análise global. O jogador SLB6 obteve também melhores valores de DP no Σ_G .




Figura 4.7 – Valores de *Degree Prestige* do SLB

Através da figura 4.8, percebemos que, na equipa do OL, apenas os jogadores OL6, OL10 e OL11 detêm valores de DP superiores no Σ_R do que na análise completa do jogo.




Figura 4.8 – Valores de *Degree Prestige* do OL

Através da observação da tabela 4.9, notamos que os jogadores do SLB com valores mais elevados de EC na 1ª parte foram o SLB4, SLB5 e o SLB9, enquanto que, na 2ª parte, os jogadores SLB1, SLB2 e SLB4 foram os que mais se sobressaíram. Globalmente, percebe-se que os jogadores SLB4, SLB5 e SLB9 foram os que alcançaram os valores mais elevados. Apesar da relevância do jogador SLB4 na globalidade do jogo, os seus valores de EC foram inferiores em qualquer evento crítico escolhido. O jogador SLB5

alcançou valores mais elevados de EC nos eventos críticos B4, B5 e no Σ_R do que na globalidade, enquanto o SLB9 atingiu os maiores valores no evento B4 e no Σ_R .

Tabela 4.9 – Matriz de valores de *Eigenvector Centrality* do SLB

Jogador	1ª	2ª	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
SLB1	0,206	0,327	0,280	-1,000	0,000	0,190	0,145	0,000	0,000	-1,000	0,000
SLB2	0,222	0,390	0,300	-1,000	0,000	0,000	0,000	0,000	0,000	-1,000	0,000
SLB3	0,307	0,255	0,297	-1,000	0,000	0,000	0,000	0,000	0,000	-1,000	0,000
SLB4	0,447	0,455	0,472	-1,000	-1,000	0,000	0,338	0,369	0,000	-1,000	0,000
SLB5	0,455	0,325	0,381	-1,000	0,000	0,629	0,639	0,652	0,000	-1,000	0,000
SLB6	0,036	0,000	0,026	-1,000	0,000	0,000	0,000	0,000	0,471	-1,000	0,471
SLB7	0,312	0,291	0,319	-1,000	0,000	0,000	0,000	0,326	0,000	-1,000	0,000
SLB8	0,143	0,290	0,203	-1,000	0,000	0,000	0,000	0,000	0,673	-1,000	0,673
SLB9	0,414	0,228	0,336	-1,000	0,000	0,363	0,338	0,000	0,000	-1,000	0,000
SLB10	0,305	0,059	0,199	-1,000	0,000	0,572	0,517	0,000	0,404	-1,000	0,404
SLB11	0,075	0,063	0,080	-1,000	0,000	0,330	0,273	0,000	0,404	-1,000	0,404

A interpretação da tabela 4.10 sugere que os jogadores do OL com valores mais elevados de EC na 1ª parte foram OL2, OL3 e OL4, sendo que, na 2ª parte, apenas o OL4 não manteve o seu valor, passando o OL9 a ser considerado. Numa análise global, os jogadores OL1, OL2 e OL3 foram os mais centrais e os que interagem com jogadores também considerados importantes para a equipa.

Tabela 4.10 – Matriz de valores de *Eigenvector Centrality* do OL

Jogador	1ª	2ª	G	L1	L2	L5	Σ_R	L4	L3
OL1	0,285	0,340	0,309	-1,000	-0,707	0,000	-0,333	0,000	0,614
OL2	0,572	0,460	0,536	-1,000	0,000	0,000	0,000	0,000	0,000
OL3	0,546	0,502	0,530	-1,000	0,000	0,000	0,000	0,000	0,000
OL4	0,291	0,196	0,265	-1,000	0,000	0,000	0,000	0,000	0,000
OL5	0,276	0,272	0,280	-1,000	0,000	-0,577	-0,333	0,000	0,000
OL6	0,112	0,148	0,135	-1,000	0,000	-0,577	-0,667	0,000	0,350
OL7	0,148	0,036	0,116	-1,000	0,000	0,000	-0,333	0,000	0,000
OL8	0,268	0,197	0,252	-1,000	0,000	0,000	0,000	1,000	0,264
OL9	0,143	0,355	0,251	-1,000	0,000	0,000	0,000	0,000	0,000
OL10	0,061	0,104	0,083	-1,000	-0,707	0,000	-0,333	0,000	0,000
OL11	0,043	0,032	0,042	-1,000	0,000	0,000	0,000	0,000	0,000

Tendo em consideração a tabela 4.9 e 4.10, é possível ter a perceção de que parte dos valores de EC associados à análise dos eventos críticos são negativos, o que pode indicar uma limitação deste modelo matemático quando este tipo de evento de curto espaço

temporal é analisado, devido ao facto das matrizes de adjacência para estes estão preenchidas com poucas interações entre jogadores.

Com base na observação do gráfico de barras que representa os valores obtidos para o EC do SLB (figura 4.9), confere-se que 4 jogadores (SLB5, SLB9, SLB10 e SLB11) atingiram valores mais elevados de EC na análise Σ_R do que na globalidade. Os jogadores SLB6, SLB8, SLB10 e SLB11 também conseguiram melhores valores na análise Σ_G .




Figura 4.9 – Valores de *Eigenvector Centrality* do SLB

Em relação ao OL, observando a figura 4.10, nenhum jogador obteve valores superiores na análise Σ_R , devido ao facto de estarem a ser calculados valores negativos que são uma limitação deste modelo.




Figura 4.10 – Valores de *Eigenvector Centrality* do OL

4.2 Análise Macro

A leitura da tabela 4.11 mostra que a equipa do SLB obteve o valor de ND mais elevado na 2ª parte do jogo, sendo que todos os seus valores na análise de eventos críticos foram muito próximos de 0. É possível reparar que para o evento B6 não existe resultado do cálculo deste modelo matemático, existindo assim indícios de que este modelo não é adequado para análise com poucas interações entre jogadores.

Tabela 4.11 – Matriz de valores de *Network Density* do SLB

1ª	2ª	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
0,118	0,128	0,122	0,005	0,011	0,044	0,030	0,016	0,022	N/A	0,022

Através de observação da tabela 4.12, notamos que a equipa do OL também manteve um valor mais elevado de DC na 2ª parte do jogo e que todos os seus valores calculados na análise dos eventos críticos estão muito próximos de 0.

Tabela 4.12 – Matriz de valores de *Network Density* do OL

1ª	2ª	G	L1	L2	L5	Σ_R	L4	L3
0,085	0,113	0,096	0,005	0,016	0,022	0,044	0,016	0,033

Examinando a figura 4.11, conseguimos ter a perceção de que o SLB foi a equipa que obteve valores de ND mais próximos de 1 na 1ª e 2ª parte, como também na globalidade do jogo, demonstrando que foi uma equipa bastante coesa, cujos jogadores colaboram muito entre si. No que se refere à análise dos eventos críticos, o SLB alcançou valores muito próximos de 0, sendo que o seu valor de ND mais elevado neste caso foi no seu Σ_R . A equipa do OL alcançou um valor de ND mais elevado no seu Σ_R do que o SLB nos seus dois Σ_R e Σ_G .




Figura 4.11 – Valores de *Network Density* do SLB e do OL

Analisando a tabela 4.13, entende-se que foi na análise do evento crítico B2 que o SLB obteve o valor mais elevado de NH, sendo que nos restantes eventos, à exceção do B6, manteve-se esta tendência de valores muito elevados de NH. Desta forma, percebe-se que o SLB se mostrou com um processo de interações com pouca coesão entre os seus jogadores, o que entra em concordância com os valores obtidos no modelo ND em que o SLB mostrou menos cooperação entre jogadores na análise dos eventos críticos.

Tabela 4.13 – Matriz de valores de *Network Heterogeneity* do SLB

1ª	2ª	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
0,630	0,606	0,574	3,606	2,449	1,581	1,535	1,700	1,581	inf	1,581

No que se refere ao OL (tabela 4.14), a equipa apresentou-se com uma grande variância no número de interações em que cada jogador participa na análise de eventos críticos, mais especificamente no evento L1, onde obteve o valor mais elevado de NH. Tal como o SLB, o OL demonstrou pouca coesão em todos os eventos críticos selecionados para a análise.

Tabela 4.14 – Matriz de valores de *Network Heterogeneity* do OL

1ª	2ª	G	L1	L2	L5	Σ_R	L4	L3
0,853	0,630	0,711	3,606	1,915	1,581	1,090	1,915	1,453

Com base na observação do gráfico de barras que representa os valores obtidos para o modelo NH das duas equipas (figura 4.12), o SLB demonstrou novamente que foi a

equipa mais coesa na 1ª e 2ª parte e na sua globalidade, apesar de ser a equipa que atingiu os valores mais elevados na análise dos eventos críticos. Estes valores da análise dos eventos não demonstram o que efetivamente aconteceu no decorrer do jogo. O OL também obteve valores maiores nesta análise do que na análise global. Isto indica que, como as matrizes de adjacência dos eventos possuem poucas e variadas interações, as duas equipas obtêm os seus maiores valores de heterogeneidade na análise dos eventos críticos.




Figura 4.12 – Valores de *Network Heterogeneity* do SLB e do OL

A compreensão da tabela 4.15 indica que, para o modelo matemático *Reciprocity*, os melhores valores do SLB foram obtidos na globalidade do jogo. No que se refere à análise dos eventos críticos, constatamos que para o B2, B3, B1, B6 e Σ_G não existe resultado do cálculo, o que pode indicar uma limitação deste modelo, não sendo o mais apropriado para analisar momentos com poucas interações entre jogadores.

Tabela 4.15 – Matriz de valores de *Reciprocity* do SLB

1ª	2ª	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
0,622	0,491	0,635	N/A	N/A	0,250	0,182	0,333	N/A	N/A	N/A

Através da tabela 4.16, verificamos que os valores do OL para o modelo R são mais elevados na globalidade, apesar destes se manterem um pouco constantes entre a 1ª e a 2ª parte. É de notar que, tal como aconteceu com o SLB, apenas um dos eventos críticos possui este modelo calculado, frisando novamente para a limitação que este modelo traz para a análise de eventos de curto espaço de tempo e de poucas interações entre jogadores.

Tabela 4.16 – Matriz de valores de *Reciprocity* do OL

1 ^a	2 ^a	G	L1	L2	L5	Σ_R	L4	L3
0,700	0,687	0,735	N/A	N/A	N/A	N/A	N/A	0,333

Observando a figura 4.13, tem-se a percepção de que para ambas as equipas os valores de R foram mais elevados na análise global do jogo, sendo que o OL é a equipa em que existe mais reciprocidade de passes entre os jogadores. O SLB foi a única equipa que possui cálculos deste modelo para um dos seus somatórios de eventos. A análise do Σ_G e o Σ_R do SLB e do OL, respetivamente, não detêm qualquer valor calculado associado a si do modelo R.




Figura 4.13 – Valores de *Reciprocity* do SLB e do OL

A leitura da tabela 4.17 mostra que a equipa do SLB alcançou o valor de (*out-in*) – AC mais positivo e mais perto de 1 na 1^a parte do jogo, sendo que os jogadores que passam mais a bola conectaram-se com os jogadores que mais a recebem. Na análise global do jogo, como o valor obtido é próximo de 0, não existiu uma grande ligação e preferência dos jogadores nas suas interações. A equipa no evento B5, B1 e no Σ_G alcançaram os valores mais negativos e mais próximos de -1, demonstrando assim que os jogadores ligados tendem a possuir propriedades diferentes.

Tabela 4.17 – Matriz de valores de (*out-in*) - Assortativity Coefficient do SLB

1 ^a	2 ^a	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
0,166	0,045	0,028	inf	inf	-0,290	-0,311	-0,333	-0,333	inf	-0,333

O OL possui o valor de (*out-in*) – AC mais elevado no Σ_R , enquanto que, na 1^a e 2^a parte e na globalidade do jogo, obtiveram valores muito próximos de 0, demonstrando que os jogadores não tiveram grande conexão entre si. Na análise do L3, os jogadores do OL que passam mais a bola não tenderam a interagir tanto com os que mais recebem a mesma.

Tabela 4.18 – Matriz de valores de (*out-in*) - Assortativity Coefficient do OL

1 ^a	2 ^a	G	L1	L2	L5	Σ_R	L4	L3
0,037	0,017	0,013	inf	inf	inf	0,333	inf	-0,333

Como podemos constatar através da figura 4.14, a equipa do OL foi a que obteve o valor mais elevado de (*out-in*) – AC, tendo isto ocorrido na análise do Σ_R , ou seja, neste somatório de remates do OL, os jogadores que passam mais a bola preferiram interagir com jogadores que a mais recebem. No que diz respeito ao SLB, foram as análises dos Σ_R e Σ_G que atingiram os valores mais negativos.




Figura 4.14 – Valores de (*out-in*) - Assortativity Coefficient do SLB e OL

A interpretação dos valores da tabela 4.19 diz-nos que na 1^a parte os jogadores do SLB que mais passes recebem estão ligados aos jogadores que mais efetuam o passe da bola; isto apenas se observou na 1^a parte do jogo, visto que, na 2^a parte e na globalidade, os

jogadores não possuíram uma forte associação aos jogadores com quem estão a interagir. O valor mais negativo foi calculado na análise do evento B3. Referimos que para os eventos B1, B6 e Σ_G não foram calculados os valores deste modelo, pressupondo desta forma que também será um modelo limitador.

Tabela 4.19 – Matriz de valores de (*in-out*) - Assortativity Coefficient do SLB

1 ^a	2 ^a	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
0,049	-0,056	-0,076	inf	-1,000	-0,143	-0,360	-0,304	N/A	N/A	N/A

Na 1^a e 2^a parte e de uma forma global, a equipa do OL tem valores de (*in-out*) – AC muito próximos de 0, o que significa que os seus jogadores não partilham uma forte ligação com os jogadores com quem interagiram. Foi no evento L2 e no L4 que os jogadores do OL que mais passes recebem demonstraram menos preferências em estarem conectados com jogadores que mais passes efetuam.

Tabela 4.20 – Matriz de valores de (*in-out*) - Assortativity Coefficient do OL

1 ^a	2 ^a	G	L1	L2	L5	Σ_R	L4	L3
0,001	0,037	-0,008	inf	-0,500	-0,333	-0,043	-0,500	-0,286

Através da figura 4.15, temos a perceção de que modo se encontram os valores do modelo (*in-out*) – AC para ambas as equipas, sendo que o SLB foi a equipa que alcançou o valor mais positivo (na 1^a parte) e o valor mais negativo (no Σ_R). O Σ_G não tem um valor a si associado devido à possível limitação deste modelo matemático.




Figura 4.15 – Valores de (in-out) - Assortativity Coefficient do SLB e do OL

Os valores do modelo *in* – AC calculados para a equipa do Benfica são maioritariamente negativos (tabela 4.21). Na 1ª parte, os jogadores que mais passes recebem mantiveram uma ligação com os jogadores que mais passes recebem, contudo, o mesmo não ocorreu no evento B2, por exemplo, em que o valor do modelo se encontra no extremo negativo de valores possíveis. Para o evento B6, não foi calculado um valor.

Tabela 4.21 – Matriz de valores de *in* - Assortativity Coefficient do SLB

1ª	2ª	G	B2	B3	B4	Σ _R	B5	B1	B6	Σ _G
0,136	-0,007	0,022	-1,000	-0,333	-0,333	-0,349	-0,557	-0,714	N/A	-0,714

Observando a tabela 4.22 é possível constatar que todos os valores calculados para a equipa do OL são negativos. O valor calculado para o evento crítico L1 é o valor mais negativo, o que significa que os jogadores que mais recebem a bola não tendem a passar bola para jogadores com esta mesma característica. Os valores obtidos da análise da 1ª e 2ª parte e do jogo completo são os valores mais próximos de 0.

Tabela 4.22 – Matriz de valores de *in* - Assortativity Coefficient do OL

1ª	2ª	G	L1	L2	L5	Σ _R	L4	L3
-0,024	-0,021	-0,032	-1,000	-0,200	-0,143	-0,418	-0,200	-0,600

Com base na análise do gráfico de barras que representa os valores obtidos para o modelo *in* – AC de ambas as equipas, verifica-se que o SLB foi a equipa que alcançou o valor

mais positivo (na 1ª parte) e o valor mais negativo (no Σ_G), ao passo que o OL manteve os seus valores muito próximos de 0.




Figura 4.16 – Valores de *in - Assortativity Coefficient* do SLB e do OL

À semelhança do que adveio da análise dos valores do modelo *in - AC* do SLB, através da tabela 4.23, verificamos que os valores *out - AC* da equipa são maioritariamente negativos e que para o evento B6 não foi calculado um valor. No evento B2, o valor do modelo encontra-se no extremo negativo, demonstrando assim que os jogadores que mais passaram não mostraram preferência na ligação a jogadores que também mais passes realizam. Os únicos valores positivos, 1ª e 2ª parte, alcançados são bastante próximos de 0.

Tabela 4.23 – Matriz de valores de *out - Assortativity Coefficient* do SLB

1ª	2ª	G	B2	B3	B4	Σ_R	B5	B1	B6	Σ_G
0,061	0,046	-0,001	-1,000	-0,333	-0,362	-0,485	-0,333	inf	N/A	inf

Para o modelo *out - AC*, a equipa do OL alcançou o seu valor mais elevado na 2ª parte do jogo, ou seja, os jogadores que mais passes realizam estiveram ligados a jogadores que também mais passes realizam, contudo, o mesmo não ocorreu no decorrer do evento L1.

Tabela 4.24 – Matrizes de valores de *out - Assortativity Coefficient* do OL

1ª	2ª	G	L1	L2	L5	Σ_R	L4	L3
0,071	0,100	0,045	-1,000	-0,200	-0,143	-0,418	-0,200	-0,500

Explorando a figura 4.17, o SLB possui o valor mais próximo do extremo negativo de valores possíveis no Σ_R , enquanto que o OL alcançou o valor mais positivo para este modelo na 2ª parte do jogo. Como o valor global do SLB é tão próximo de 0, acaba por não ter relevo na representação gráfica.




Figura 4.17 – Valores de *out - Assortativity Coefficient* do SLB e do OL

4.3 Discussão de Resultados

A análise de redes humanas e os seus múltiplos modelos matemáticos podem ajudar na investigação de novas abordagens do estudo de interações entre jogadores e as ações da equipa enquanto um todo.

Em estudos anteriores, como o de Liu, Gómez, et al. (2016), recomendou-se a divisão dos jogos de futebol em curtos espaços de tempo para uma perspetiva de análise mais profunda do jogo e das dinâmicas existentes entre as equipas. Assim, o objetivo principal deste projeto foi a investigação das vantagens e desvantagens da potencialidade da utilização de uma abordagem baseada na análise do jogo completo face à análise do jogo pré e pós eventos críticos. Para o efeito, procedemos à análise do jogo da *UEFA Champions League* da fase de grupos da edição 2019/2020 onde se confrontou o SLB com o OL.

Analisando os valores obtidos para ambas as equipas para o modelo DC, percebe-se que o SLB1, SLB4, SLB5, OL1, OL2 e OL3 estiveram em destaque numa análise global do jogo. Apesar da distinção do jogador SLB1 na globalidade do jogo, este obteve um valor pior de DC no único evento (B4) em que participou e no Σ_R . Para os jogadores OL2 e OL3 semelhante situação ocorreu, ou seja, apesar da sua importância na globalidade do jogo, estes não participaram em nenhum dos eventos escolhidos. Portanto, desta forma, é possível concluir que, não obstante a sua importância e relevância no decorrer do jogo, para os jogadores SLB1, OL2 e OL3, o modelo DC não retrata de todo o ocorrido na totalidade do jogo. Observando apenas os somatórios dos eventos, 4 jogadores do SLB obtiveram valores superiores de DC na análise do Σ_R e do Σ_G do que na análise completa do jogo, enquanto que, no OL, 5 jogadores alcançaram também valores mais elevados no seu Σ_R . Por conseguinte, através do modelo DC, não é possível obter uma perspetiva idêntica de destaque dos jogadores entre a análise completa de jogo e análise de eventos críticos.

Globalmente, os jogadores SLB3, SLB4 e SLB5 foram os que alcançaram os valores mais elevados de CC, contudo, observando a análise de eventos críticos, constata-se que o SLB3 não participou em qualquer evento e o SLB4 e o SLB5 apenas aumentaram o seu destaque nos eventos B3 e B5. Novamente, OL1, OL2 e OL3 mostraram com distinção a sua importância na globalidade do jogo, sendo que apenas o OL1 teve melhor valor de CC num dos eventos escolhidos. Na equipa do SLB, nenhum jogador obteve melhores resultados na análise Σ_R , contudo, na análise Σ_G , apenas 36,36% dos jogadores alcançaram o seu auge para este modelo, enquanto que, na equipa do OL, somente 2 jogadores conseguiram ter mais importância no Σ_R do que no decorrer da totalidade do jogo.

No modelo BC, os jogadores SLB1, SLB4 e SLB5 foram os que atingiram os valores mais elevados globalmente. Contudo, é no modelo BC que detetamos a primeira limitação, pois, segundo este, os jogadores SLB1 e SLB4 não participaram em nenhum dos eventos críticos, mas nos restantes modelos estes jogadores são considerados com participantes em vários modelos. Para além disto, e contrariando o padrão para o jogador SLB5, todos os seus valores calculados para a análise dos eventos são inferiores à análise global. Adicionalmente, para jogadores de ambas as equipas, não foram calculados vários valores de Σ_R e de Σ_G , evidenciando que, para além da limitação acima explícita, o modelo de BC pode não ser adequado para uma análise de eventos com um curto espaço de tempo

(15 segundos pré evento + 15 segundos pós evento) e com poucas interações entre jogadores. Desta forma, recomendamos que em futuros estudos se aumente o tempo de análise dos eventos críticos para ser possível ter a perceção de que este modelo é mesmo limitativo.

No que se refere ao DP, constatamos que o SLB5, SLB8 e SLB9 foram os jogadores com os valores mais elevados na equipa, contudo os jogadores SLB8 e SLB9 obtiveram valores inferiores nos eventos críticos em que participaram do que na globalidade. Na equipa do OL, os jogadores OL1, OL2 e OL3 destacaram-se novamente, mas o jogador OL1 apenas teve um melhor valor de DP no evento L4, enquanto que nos restantes eventos em que participou o mesmo não aconteceu; e os jogadores OL2 e OL3 não participaram em nenhum evento. Na equipa do SLB, apenas 5 jogadores tiveram maior destaque no Σ_R do que na globalidade, no entanto no Σ_G somente 1 jogador se destacou em relação ao jogo como um todo. Enquanto que, na equipa do OL, 3 jogadores alcançaram melhores valores de DP na análise de eventos críticos. Assim, com base na análise dos eventos, não conseguimos de facto retratar o que se passou no contexto do jogo. À semelhança do modelo BC, o modelo DP apresenta uma limitação relativamente à análise de matriz de adjacência compostas por um baixo número de interações de entre jogadores.

Relativamente ao EC, constata-se que 4 jogadores do SLB alcançaram melhores valores na análise de Σ_R e também no Σ_G , ao passo que, no OL, nenhum jogador teve valores positivos na análise de Σ_R para este modelo. Deste modo, verificou-se que parte dos valores calculados do modelo EC foram negativos para ambas as equipas na análise dos eventos, indicando que também este modelo possui uma limitação.

Em relação ao ND, ambas as equipas atingiram o valor mais elevado para este modelo na 2ª parte do jogo, sendo este valor superior aos obtidos nos somatórios dos remates e de golo de cada uma. Este modelo matemático possui a mesma limitação apresentada para os modelos BC, DP e EC.

Como tanto o SLB e o OL apresentaram valores mais elevados para ND na 2ª parte (análise global do jogo), os valores de NH calculados são elevados para os eventos de ambas as equipas, mostrando-se bastante coesas de uma forma global, contudo, em contexto de evento crítico, não conseguiram manter esta cooperação de equipa. Isto salienta a concordância dos valores obtidos no modelo ND e no NH.

Para o modelo R, ambas as equipas atingiram os valores mais elevados na análise global do jogo, visto que foram poucos os eventos críticos de cada uma que apresentaram valores calculados. O SLB é a única equipa que detem cálculos efetuados para um dos seus somatórios de eventos, o Σ_R . Como o modelo R calcula a tendência de existência de mutualidades nas ligações entre os jogadores e como as matrizes de adjacência dos eventos críticos estão compostas por um número limitado de interações entre jogadores, não existem dados suficientes para a realização do cálculo. Desta forma, o modelo R apresenta-se também como um modelo matemático com limitações.

Por fim, temos o modelo AC, para o qual foram calculadas 4 variantes: *out-in*, *in-out*, *out* e *in*. Sendo que destas 4 variantes, damos destaque à *in-out*, devido ao facto de ter sido detetado limitações semelhantes às encontradas em modelos anteriormente mencionados.

Resumidamente, numa perspetiva de análise micro, foram escolhidos 5 modelos matemáticos para proceder à análise do jogo completo e à análise pré e pós eventos críticos e apenas 2 não apresentaram qualquer tipo de limitação. Numa perspetiva de análise macro, foram escolhidos 4 modelos para a realização da análise e apenas 1 não apresentou qualquer tipo de limitação. Os modelos BC, DP, EC, ND, R e AC são limitativos no que se refere à análise de eventos críticos com uma duração de 30 segundos (15 segundos pré evento + 15 segundos pós evento), pois as interações entre os jogadores foram poucas, acabando por se produzir matrizes de adjacência limitadas.

5 CONCLUSÃO

Este estudo tinha como objetivo explorar a inexistência de investigação publicada no que se refere à informação que a análise de um jogo completo pode fornecer em relação à análise de momentos críticos de jogo.

Foram definidos três tipos de eventos críticos do jogo - golo, remate e remate à baliza – e, considerados intervalos de tempo de análise pré e pós evento de 15 segundos. Através da análise de redes humanas, procedeu-se à análise do jogo globalmente, por eventos e somatórios ou adição de eventos.

Os resultados obtidos permitem concluir que utilizando a análise dos momentos críticos ou da sua adição, não conseguimos retratar a realidade que se infere pela análise do tempo total de jogo. Este facto reflete-se, por exemplo, quando um jogador se destaca na análise global do jogo, mas tal poder não ocorre no estudo do seu comportamento e desempenho no âmbito dos eventos críticos.

Embora fosse expectável obter resultados mais coincidentes entre os diferentes tipos de análise – eventos críticos vs tempo total do jogo -, ambos os tipos de dados permitem gerar informação vantajosa para poder ser usada pelo treinador e respetiva equipa técnica. As opções estratégicas da equipa durante o jogo e em eventos críticos podem derivar de tomadas de decisão considerando o carácter complementar das duas abordagens que realizamos.

Observando as duas análises realizadas, o treinador consegue ter a perceção de quais os jogadores mais relevantes globalmente e os que são mais preponderantes nos momentos de remate, remate à baliza e de golo. Desta forma, é possível a equipa técnica estudar estratégias de modo a potenciar e rentabilizar a ação individual de todos os jogadores, para serem mais eficazes, quer os que se apresentam mais nos momentos críticos, quer os que mais rendem no conjunto do jogo completo.

Em suma, no que respeita à questão principal de pesquisa deste trabalho, “Podem ser reduzidos os custos de tempo e de gestão de dados para análise do jogo de futebol e do padrão do comportamento dos jogadores (nível micro) e da equipa (nível macro) que lhes estão subjacentes?”, concluímos que não. Apesar do exposto, realça-se a importância da análise complementar dos eventos críticos na compreensão do complexo e dinâmico comportamento dos jogadores e das equipas.

Assumimos como uma mais valia nesta pesquisa a cooperação entre áreas do conhecimento, como as Tecnologias de Informação e as Ciências do Desporto, expressando-se num trabalho de investigação aplicada interdisciplinar, relevante para as áreas dos sistemas de informação e do desporto.

É conhecida a vantagem da análise de informações na tomada de decisões. A opção pela análise mais consistente dos dados, viável com contributo de várias perspetivas, complementares e convergentes, geram competência para deliberações mais assertivas e apropriadas.

Entre as principais limitações e consequentes recomendações para estudos futuros destacamos o número de jogos analisados, os instantes pré e pós ocorrência de um evento crítico e os modelos matemáticos. Deste modo, sugerimos que, em futuras investigações, seja feita a análise de mais jogos, e não apenas de um, de forma a ser possível detetar possíveis padrões nas equipas analisadas e para um melhor resultado investigacional.

Adicionalmente, propomos que, futuramente, para a deteção de possíveis padrões seja utilizada a inteligência artificial em conjunto com a análise de redes humanas.

Relativamente aos instantes dos eventos críticos, deverá ser tido em conta que 15 segundos pré e pós evento é bastante curto, pois são realizadas poucas interações entre jogadores nesse período de tempo, sugerindo assim que, no futuro, seja analisado em que instantes é importante analisar os eventos críticos de jogo.

Ao nível dos modelos matemáticos, constata-se que vários modelos possuem limitações no que se refere a matrizes de adjacência com poucas interações. Ao elevar os instantes dos eventos críticos analisados, estas limitações dos modelos em causa poderão deixar de existir, contudo, caso não aconteça, sugerimos que os modelos limitativos sejam substituídos por outros.

Para estudos futuros, propomos também que seja definida que tipo de informação relevante que pode ser encontrada na análise tática de jogo pré e pós evento crítico e que, tendo isto por base, sejam apresentadas as vantagens e desvantagens da utilização de uma abordagem do jogo completo face à de eventos críticos.

REFERÊNCIAS BIBLIOGRÁFICAS

- Barreira, D., Garganta, J., Guimarães, P., Machado, J., & Anguera, M. T. (2014). Ball recovery patterns as a performance indicator in elite soccer. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, 228(1), 61–72. <https://doi.org/10.1177/1754337113493083>
- Barreira, D., Garganta, J., Pinto, T., Valente, J., & Anguera, T. (2013). Do attacking game patterns differ between first and second halves of soccer matches in the 2010 FIFA World Cup? *Science and Football VII: The Proceedings of the Seventh World Congress on Science and Football, September 2014*, 193–198. <https://doi.org/10.4324/9780203131879>
- Benfica, S. L. e. (2019). *Conhece a Equipa Técnica Campeã Nacional*. <https://www.youtube.com/watch?v=0z2IPgHw-Sc>
- Borrie, A., Jonsson, G., & Magnusson, M. (2002). Temporal pattern analysis and its applicability in sport: An explanation and exemplar data. *Journal of Sports Sciences*, 20(10), 845–852. <https://doi.org/10.1080/026404102320675675>
- Bradley, P. S., Lago-Peñas, C., Rey, E., & Sampaio, J. (2014). The influence of situational variables on ball possession in the English Premier League. *Journal of Sports Sciences*, 32(20), 1867–1873. <https://doi.org/10.1080/02640414.2014.887850>
- Brito de Souza, D., López-Del Campo, R., Blanco-Pita, H., Resta, R., & Del Coso, J. (2019). An Extensive Comparative Analysis of Successful and Unsuccessful Football Teams in LaLiga. *Frontiers in Psychology*, 10(November), 1–8. <https://doi.org/10.3389/fpsyg.2019.02566>
- Buldú, J. M., Busquets, J., Echegoyen, I., & Seirullo, F. (2019). Defining a historic football team: Using Network Science to analyze Guardiola's F.C. Barcelona. *Scientific Reports*, 9(1), 1–14. <https://doi.org/10.1038/s41598-019-49969-2>
- Bunker, R. P., & Thabtah, F. (2019). A machine learning framework for sport result prediction. *Applied Computing and Informatics*, 15(1), 27–33. <https://doi.org/10.1016/j.aci.2017.09.005>
- Carling, C., Williams, A. M., & Reilly, T. (2005). *Handbook of soccer match analysis: a systematic approach to improving performance*.
- Carpita, M., Sandri, M., Simonetto, A., & Zuccolotto, P. (2016). Discovering the drivers of football match outcomes with data mining. *Quality Technology and Quantitative Management*, 12(4), 561–577. <https://doi.org/10.1080/16843703.2015.11673436>
- Castellano, J., Casamichana, D., & Lago, C. (2012). The use of match statistics that discriminate between successful and unsuccessful soccer teams. *Journal of Human Kinetics*, 31(1), 139–147. <https://doi.org/10.2478/v10078-012-0015-7>
- Castellano, J., & Echeazarra, I. (2019). Network-based centrality measures and physical demands in football regarding player position: Is there a connection? A preliminary study. *Journal of Sports Sciences*, 37(23), 2631–2638. <https://doi.org/10.1080/02640414.2019.1589919>
- Cintia, P., Giannotti, F., Pappalardo, L., Pedreschi, D., & Malvaldi, M. (2015). The harsh rule of the goals: Data-driven performance indicators for football teams. *Proceedings of the 2015 IEEE International Conference on Data Science and Advanced Analytics, DSAA 2015, December*.

<https://doi.org/10.1109/DSAA.2015.7344823>

- Claudino, J. G., Capanema, D. de O., de Souza, T. V., Serrão, J. C., Pereira, A. C. M., & Nassis, G. P. (2019). Current Approaches to the Use of Artificial Intelligence for Injury Risk Assessment and Performance Prediction in Team Sports: a Systematic Review. *Sports Medicine - Open*, 5(28). <https://doi.org/10.1186/s40798-019-0202-3>
- Clemente, F., Couceiro, M. S., Martins, F. L., & Mendes, R. (2013). An online tactical metrics applied to football game. *Research Journal of Applied Sciences, Engineering and Technology*, 5(5), 1700–1719. <https://doi.org/10.19026/rjaset.5.4926>
- Clemente, F., Couceiro, M. S., Martins, F. L., & Mendes, R. (2014). Using network metrics to investigate football team players' connections: A pilot study. *Motriz. Revista de Educacao Fisica*, 20(3), 262–271. <https://doi.org/10.1590/S1980-65742014000300004>
- Clemente, F., Couceiro, M. S., Martins, F. L., & Mendes, R. (2015). Using network metrics in soccer: A macro-analysis. *Journal of Human Kinetics*, 45(1), 123–134. <https://doi.org/10.1515/hukin-2015-0013>
- Clemente, F., Couceiro, M. S., Martins, F. L., Mendes, R., & Figueiredo, A. (2013). Measuring tactical behaviour using technological metrics: Case study of a football game. *International Journal of Sports Science and Coaching*, 8(4), 723–739. <https://doi.org/10.1260/1747-9541.8.4.723>
- Clemente, F., Couceiro, M. S., Martins, F. L., Mendes, R., & Figueiredo, A. (2014). Sistemas Inteligentes para el análisis de fútbol: Centroides ponderados. *Ingenieria e Investigacion*, 34(3), 70–75. <https://doi.org/10.15446/ing.investig.v34n3.43602>
- Clemente, F., José, F., Oliveira, N., Martins, F. L., Mendes, R., Figueiredo, A., Wong, D. P., & Kalamaras, D. (2016). Network structure and centralization tendencies in professional football teams from Spanish La Liga and English Premier Leagues. *Journal of Human Sport and Exercise*, 11(3), 376–389. <https://doi.org/10.14198/jhse.2016.113.06>
- Clemente, F., Martins, F. L., Couceiro, M. S., Mendes, R., & Figueiredo, A. (2014). A network approach to characterize the teammates' interactions on football: A single match analysis. *Cuadernos de Psicología Del Deporte*, 14(3), 141–148.
- Clemente, F., Martins, F. L., Kalamaras, D., Oliveira, J., Oliveira, P., & Mendes, R. (2015). The social network analysis of Switzerland football team on FIFA World Cup 2014. *Journal of Physical Education and Sport*, 15(1), 136–141. <https://doi.org/10.7752/jpes.2015.01022>
- Clemente, F., Martins, F. L., & Mendes, R. (2015). How team sports behave as a team? General network metrics applied to sports analysis. *Sports Science*, 8, 81–87.
- Clemente, F., Martins, F. L., & Mendes, R. (2016a). Analysis of scored and conceded goals by a football team throughout a season: A network analysis. *Kinesiology*, 48(1), 103–114. <https://doi.org/10.26582/k.48.1.5>
- Clemente, F., Martins, F. L., & Mendes, R. (2016b). *Social Network Analysis Applied to Team Sports Analysis*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-25855-3>
- Clemente, F., Martins, F. L., Mendes, R., & Silva, F. (2016). Social network measures to match analysis in soccer: A survey. *Journal of Physical Education and Sport*, 16(3), 823–830. <https://doi.org/10.7752/jpes.2016.03130>

- Clemente, F., Mendes, R., & Martins, F. L. (2014). Applying Centrality Metrics To Identify the Prominent Football Players. *VIII Congreso Internacional de La Asociación Española de Ciencias Del Deporte*, April, 583–586. <https://doi.org/10.13140/2.1.3171.2968>
- Cohen, L., Manion, L., & Morrison, K. (2007). *Research Methods in Education* (6ª edição). Routledge.
- Cotta, C., Mora, A. M., Merelo, J. J., & Merelo-Molina, C. (2013). A network analysis of the 2010 FIFA world cup champion team play. *Journal of Systems Science and Complexity*, 26(1), 21–42. <https://doi.org/10.1007/s11424-013-2291-2>
- Di Salvo, V., Baron, R., Tschan, H., Montero, F. J. C., Bachl, N., & Pigozzi, F. (2007). Performance characteristics according to playing position in elite soccer. *International Journal of Sports Medicine*, 28(3), 222–227. <https://doi.org/10.1055/s-2006-924294>
- Fialho, G., Manhães, A., & Teixeira, J. P. (2019). Predicting Sports Results with Artificial Intelligence - A Proposal Framework for Soccer Games. *Procedia Computer Science*, 164, 131–136. <https://doi.org/10.1016/j.procs.2019.12.164>
- Frencken, W., de Poel, H., Visscher, C., & Lemmink, K. (2012). Variability of inter-team distances associated with match events in elite-standard soccer. *Journal of Sports Sciences*, 30(12), 1207–1213. <https://doi.org/10.1080/02640414.2012.703783>
- Garganta, J. (2001). A análise da performance nos jogos desportivos. Revisão acerca da análise do jogo. *Revista Portuguesa de Ciências Do Desporto*, 2001(1), 57–64. <https://doi.org/10.5628/rpcd.01.01.57>
- Garganta, J. (2009). Trends of tactical performance analysis in team sports: bridging the gap between research, training and competition. *Revista Portuguesa de Ciências Do Desporto*, 9(1), 81–89. http://www.scielo.mec.pt/scielo.php?pid=S1645-05232009000100008&script=sci_arttext&tlng=es
- Gómez, M. A., López, M., Lago-Peñas, C., & Sampaio, J. (2012). Effects of game location and final outcome on game-related statistics in each zone of the pitch in professional football. *European Journal of Sport Science*, 12(5), 393–398. <https://doi.org/10.1080/17461391.2011.566373>
- Gonçalves, B., Coutinho, D., Santos, S., Lago-Penas, C., Jiménez, S., & Sampaio, J. (2017). Exploring team passing networks and player movement dynamics in youth association football. *PLoS ONE*, 12(1). <https://doi.org/10.1371/journal.pone.0171156>
- Grund, T. U. (2012). Network structure and team performance: The case of English Premier League soccer teams. *Social Networks*, 34(4), 682–690. <https://doi.org/10.1016/j.socnet.2012.08.004>
- Grunz, A., Memmert, D., & Perl, J. (2012). Tactical pattern recognition in soccer games by means of special self-organizing maps. *Human Movement Science*, 31(2), 334–343. <https://doi.org/10.1016/j.humov.2011.02.008>
- Henriques, F. (2018). *How Can Big Data Help Football Clubs Achieve Competitive Advantage*. Católica Business - Business & Economics.
- Janetzko, H., Sacha, D., Stein, M., Schreck, T., Keim, D. A., & Deussen, O. (2015). Feature-driven visual analytics of soccer data. *2014 IEEE Conference on Visual Analytics Science and Technology, VAST 2014 - Proceedings*, 13–22.

<https://doi.org/10.1109/VAST.2014.7042477>

- Jonsson, G. K., Bjarkadottir, S. H., Gislason, B., Borrie, A., & Magnusson, M. S. (2003). Detection of real-time patterns in sports interactions in football. *L'ethologie Applique Aujourd'hui*, 3, 37–46.
- José Sousa, M., & Sales Baptista, C. (2011). *COMO FAZER INVESTIGAÇÃO, DISSERTAÇÕES, TESES E RELATÓRIOS - SEGUNDO BOLONHA*. Pactor.
- Joshi, N. (2019). *Here's How AI Will Change The World Of Sports!* Forbes. <https://www.forbes.com/sites/cognitiveworld/2019/03/15/heres-how-ai-will-change-the-world-of-sports/#1086b9e2556b>
- Kamble, P. R., Keskar, A. G., & Bhurchandi, K. M. (2019). A deep learning ball tracking system in soccer videos. *Opto-Electronics Review*, 27(1), 58–69. <https://doi.org/10.1016/j.opelre.2019.02.003>
- Kampakis, S. (2016). *Predictive modelling of football injuries* (Issue April) [University College London]. <http://arxiv.org/abs/1609.07480>
- Kim, J., James, N., Parmar, N., Ali, B., & Vučković, G. (2019). Determining unstable game states to aid the identification of perturbations in football. *International Journal of Performance Analysis in Sport*, 19(3), 302–312. <https://doi.org/10.1080/24748668.2019.1602439>
- Kröckel, P. (2019). *Big Data Event Analytics in Football for Tactical Decision Support*. Friedrich-Alexander-Universität Erlangen-Nürnberg.
- Kröckel, P., Piazza, A., & Neuhofer, K. (2017). Dynamic network analysis of the Euro2016 final: Preliminary results. *5th International Conference on Future Internet of Things and Cloud Workshops*, 114–119. <https://doi.org/10.1109/FiCloudW.2017.98>
- Lago-Peñas, C., & Lago-Ballesteros, J. (2011). Game location and team quality effects on performance profiles in professional soccer. *Journal of Sports Science and Medicine*, 10(3), 465–471.
- Lago-Peñas, C., Lago-Ballesteros, J., & Rey, E. (2011). Differences in performance indicators between winning and losing teams in the UEFA Champions League. *Journal of Human Kinetics*, 27(1), 135–146. <https://doi.org/10.2478/v10078-011-0011-3>
- Lee, S., Hong, I., & Jung, W. S. (2015). A network approach to the transfer market of european football leagues. *New Physics: Sae Mulli*, 65(4), 402–409. <https://doi.org/10.3938/NPSM.65.402>
- Liebermann, D. G., Katz, L., Hughes, M. D., Bartlett, R. M., McClements, J., & Franks, I. M. (2002). Advances in the application of information technology to sport performance. *Journal of Sports Sciences*, 20(10), 755–769. <https://doi.org/10.1080/026404102320675611>
- Liu, H., Gómez, M. A., Gonçalves, B., & Sampaio, J. (2016). Technical performance and match-to-match variation in elite football teams. *Journal of Sports Sciences*, 34(6), 509–518. <https://doi.org/10.1080/02640414.2015.1117121>
- Liu, H., Hopkins, W. G., & Gómez, M. A. (2016). Modelling relationships between match events and match outcome in elite football. *European Journal of Sport Science*, 16(5), 516–525. <https://doi.org/10.1080/17461391.2015.1042527>

- Lorenzo-martínez, M., Rein, R., Garnica-Caparrós, M., Memmert, D., & Rey, E. (2020). The Effect of Substitutions on Team Tactical Behavior in Professional Soccer. *Research Quarterly For Exercise and Sport*.
- Lourenço, F. G. B. (2016). *Práticas de Observação e Análise de Jogo*. Universidade de Lisboa.
- Lusher, D., Robins, G., & Kremer, P. (2010). The application of social network analysis to team sports. *Measurement in Physical Education and Exercise Science*, 14(4), 211–224. <https://doi.org/10.1080/1091367X.2010.495559>
- Machado, J. C., Barreira, D., & Garganta, J. (2013). Eficácia ofensiva e variabilidade de padrões de jogo em futebol. *Revista Brasileira de Educação Física e Esporte*, 27(4), 667–677. <https://doi.org/10.1590/s1807-55092013000400014>
- Machado, J. C., Barreira, D., & Garganta, J. (2014). A influência do resultado momentâneo do jogo nos padrões de ataque em equipes de futebol de elite. *Revista Brasileira de Cineantropometria e Desempenho Humano*, 16(5), 545–554. <https://doi.org/10.5007/1980-0037.2014v16n5p545>
- Martins, F., Silva, F., Clemente, F., Gomes, A., Correia, A., Nguyen, Q. T., Sequeiros, J. B., Ribeiro, J. S., & Lopes, V. (2018). *Ultimate Performance Analysis Tool (uPATO)*. <https://upato.it.ubi.pt>
- McLean, S., Salmon, P. M., Gorman, A. D., Stevens, N. J., & Solomon, C. (2018). A social network analysis of the goal scoring passing networks of the 2016 European Football Championships. *Human Movement Science*, 57(September), 400–408. <https://doi.org/10.1016/j.humov.2017.10.001>
- Meghanathan, N. (2016). Assortativity Analysis of Real-World Network Graphs based on Centrality Metrics. *Computer and Information Science*, 9(3), 7. <https://doi.org/10.5539/cis.v9n3p7>
- Mehr, M. G., & Shirazi, H. (2012). An Expert System for Advising to Buy a FootballPlayer Using Visual Prolog. *Intelligent Information Management*, 04(04), 134–137. <https://doi.org/10.4236/iim.2012.44020>
- Memmert, D., Lemmink, K. A. P. M., & Sampaio, J. (2017). Current Approaches to Tactical Performance Analyses in Soccer Using Position Data. *Sports Medicine*, 47(1), 1–10. <https://doi.org/10.1007/s40279-016-0562-5>
- Memmert, D., & Rein, R. (2018). Match analysis, Big Data and tactics: current trends in elite soccer. *Deutsche Zeitschrift Für Sportmedizin*, 69, 65–72. <https://doi.org/10.5960/dzsm.2018.322>
- Mendes, A. (2017). *Scouting, O Futebol (re)nasce aqui* (2ª Edição). Chiado Editora.
- Mendes, R., Clemente, F., Rocha, R., & Damásio, S. (2012). Observação como instrumento no processo de avaliação em Educação Física. *Revista Científica Exedra*, 6, 57–70. <http://www.exedrajournal.com/docs/N6/04-Edu.pdf>
- Min, B., Kim, J., Choe, C., Eom, H., & McKay, R. I. B. (2008). A compound framework for sports results prediction: A football case study. *Knowledge-Based Systems*, 21(7), 551–562. <https://doi.org/10.1016/j.knosys.2008.03.016>
- Monteiro, R., Travassos, B., Duarte, R., & Marques, P. (2015). Sucesso defensivo no futebol: Análise de tendências espaço-temporais. *Centro de Pesquisa e Desenvolvimento Desportivo - Comité Olímpico de Portugal*, 1–7.

- Moreira, S. F. (2017). *Efeito de jogos lúdico-recreativos de cooperação-oposição no nível de atividade física e nas interações em crianças no 1º Ciclo do Ensino Básico*. Escola Superior de Educação de Coimbra.
- Morillo-Baro, J. P., Reigal, R. E., & Hernández-Mendo, A. (2015). How dots behave in two different pitch sizes? Analysis of tactical behavior based on position data in two soccer field sizes. *RICYDE: Revista Internacional de Ciencias Del Deporte*, 11(41), 226–244. <https://doi.org/10.5232/ricyde>
- Mosele, J. (2018). *Artificial Intelligence In The Sport Industry*. Politecnico Di Milano.
- Paixão, P., Sampaio, J., Almeida, C. H., & Duarte, R. (2015). How does match status affects the passing sequences of top-level European soccer teams? *International Journal of Performance Analysis in Sport*, 15(1), 229–240. <https://doi.org/10.1080/24748668.2015.11868789>
- Passfield, L., & Hopker, J. G. (2017). A mine of information: Can sports analytics provide wisdom from your data? *International Journal of Sports Physiology and Performance*, 12(7), 851–855. <https://doi.org/10.1123/ijsp.2016-0644>
- Paul, S., & Mitra, R. (2008). How predictable are the FIFA worldcup football outcomes? An empirical analysis. *Applied Economics Letters*, 15(15), 1171–1176. <https://doi.org/10.1080/13504850601007117>
- Penumala, R., Sivagami, M., & Srinivasan, S. (2019). Automated Goal Score Detection in Football Match Using Key Moments. *Procedia Computer Science*, 165(2019), 492–501. <https://doi.org/10.1016/j.procs.2020.01.017>
- Pina, T. J., Paulo, A., & Araújo, D. (2017). Network characteristics of successful performance in association football. A study on the UEFA champions league. *Frontiers in Psychology*, 8(JUL). <https://doi.org/10.3389/fpsyg.2017.01173>
- Pottala, M. (2018). *Artificial Intelligence in Sports* (Issue May). Centria University of Applied Sciences.
- Pratas, J. M., Volossovitch, A., & Carita, A. I. (2016). The effect of performance indicators on the time the first goal is scored in football matches. *International Journal of Performance Analysis in Sport*, 16(1), 347–354. <https://doi.org/10.1080/24748668.2016.11868891>
- Rein, R., & Memmert, D. (2016). Big data and tactical analysis in elite soccer: future challenges and opportunities for sports science. *SpringerPlus*, 5(1). <https://doi.org/10.1186/s40064-016-3108-2>
- Ribeiro, J., Silva, P., Duarte, R., Davids, K., & Garganta, J. (2017). Team Sports Performance Analysed Through the Lens of Social Network Theory: Implications for Research and Practice. *Sports Medicine*, 47(9), 1689–1696. <https://doi.org/10.1007/s40279-017-0695-1>
- Ric, A., Torrents, C., Gonçalves, B., Torres-Ronda, L., Sampaio, J., & Hristovski, R. (2017). Dynamics of tactical behaviour in association football when manipulating players' space of interaction. *PLoS ONE*, 12(7). <https://doi.org/10.1371/journal.pone.0180773>
- Rossi, A., Pappalardo, L., Cintia, P., Iaia, F. M., Fernández, J., & Medina, D. (2018). Effective injury forecasting in soccer with GPS training data and machine learning. *PLoS ONE*, 13(7), 1–15. <https://doi.org/10.1371/journal.pone.0201264>

- SAGE Publications, L. (2019). *Learn About Assortativity Coefficient in Python With Data From UK Faculty Dataset* (2008). <https://methods.sagepub.com/base/download/DatasetStudentGuide/assortativity-in-ukfaculty-2008-python>
- Silva, F. G. M., Correia, A. F. P. P., Clemente, F., Martins, F. L., & Nguyen, Q. T. (2019). *Ultimate Performance Analysis Tool (uPATO) Implementation of Network Measures Based on Adjacency Matrices for Team Sports*. Springer.
- Srinivasan, B. (2017). A Social Network Analysis of Football - Evaluating Player and Team Performance. *2017 9th International Conference on Advanced Computing, ICoAC 2017*, 242–246. <https://doi.org/10.1109/ICoAC.2017.8441301>
- Wallace, F. (2019). *How Artificial Intelligence Is Shaping The Future Of Football*. HeadStuff. <https://www.headstuff.org/topical/ai-football/>
- Wallace, J. L., & Norton, K. I. (2014). Evolution of World Cup soccer final games 1966-2010: Game structure, speed and play patterns. *Journal of Science and Medicine in Sport*, 17(2), 223–228. <https://doi.org/10.1016/j.jsams.2013.03.016>
- Ward, P., Windt, J., & Kempton, T. (2019). Business intelligence: How sport scientists can support organization decision making in professional sport. *International Journal of Sports Physiology and Performance*, 14(4), 544–546. <https://doi.org/10.1123/ijsp.2018-0903>
- Wasserman, S., & Faust, K. (1994). *Social Network Analysis: Methods and Applications*. Cambridge University Press.