

Análise de Padrões e Disrupções no Comportamento da Rede Mundial de Transferências Futebolísticas

Eduardo Cotta

Bacharelado em Sistemas de Informação

Universidade Federal de Minas Gerais

Belo Horizonte, Brasil

eduardocotta@ufmg.br

Abstract—This study examines the evolution of the global football transfer market from 1990 to 2022 using social network analysis to understand structural changes driven by external events. Data from Transfermarkt were used to construct temporal graphs at five-year intervals, based on change point detection to capture both short- and long-term dynamics. Key metrics were calculated to identify constant and disruptive agents, and to correlate external events with shifts in network structure. Countries like France, Germany, Switzerland, and Belgium remained central over time, while the U.S., Brazil, Portugal, China, and Russia emerged as disruptive agents due to legislative, economic, or political changes. The Bosman ruling (1995) was a pivotal event, liberalizing the European market and promoting a more integrated network. Overall, the study shows that network analysis is a powerful tool for understanding the complex, globalized nature of the football transfer market.

Index Terms—Football Transfer Market, Social Network Analysis, Change Point Detection, Disruptive Agents, Bosman Ruling.

I. INTRODUÇÃO

O mercado de transferências no futebol representa um dos pilares da economia global do esporte, refletindo não apenas o dinamismo típico das modalidades coletivas, mas também as transformações econômicas e culturais ocorridas ao longo das décadas. Desde a primeira transferência registrada em 1893 — quando Jack Southworth teria sido negociado por 400 libras [20] — até a transação recorde de Neymar por 198 milhões de libras em 2017, o sistema evoluiu profundamente [11]. Tal evolução evidencia o caráter cada vez mais mercantilizado do futebol, onde clubes e atletas compartilham o objetivo de alcançar sucesso esportivo e financeiro. Como apontado por O'Neill [11], esse sistema reflete não apenas uma lógica de mercado, mas também as pressões jurídicas, culturais e políticas que moldam o futebol contemporâneo.

Diversos eventos externos — principalmente disputas judiciais — foram decisivos para a transformação desse mercado. Casos como os de George Eastham (1963) e Jean-Marc Bosman (1995), que recorreram à justiça para garantir liberdade contratual, redefiniram os direitos dos jogadores e suas relações com os clubes [11, 15]. Adicionalmente, [15] afirma que este mercado pode ser dividido em dois períodos distintos: antes e depois de 1996. Paralelamente, a globalização intensificou as desigualdades econômicas entre os países e impulsionou o crescimento de mercados emergentes como China e Qatar, muitas vezes motivados por objetivos

geopolíticos. No Brasil, essas transformações também se manifestaram, tanto na cultura esportiva quanto na legislação, especialmente após a promulgação da Lei Pelé (1998), que redefiniu o vínculo entre atletas e clubes [16].

Diante desse cenário, torna-se fundamental analisar o mercado de transferências sob a ótica da teoria de redes sociais. Essa abordagem permite não apenas observar o impacto direto de grandes eventos, como reformas legislativas e surgimento de novos mercados, mas também identificar alterações sutis na estrutura das conexões globais entre clubes e países. Compreender como essas dinâmicas se desenvolvem ao longo do tempo pode enriquecer significativamente o debate sobre o futebol global e fornecer novas ferramentas para interpretação do cenário esportivo internacional.

Com isso, este trabalho visa responder às seguintes questões de pesquisa (QP):

- 1) QP1: Quais são as estruturas centrais (países ou comunidades) na rede mundial de transferências que permanecem constantes ao longo do período analisado?
- 2) QP2: Quais países foram mais disruptivos dos padrões analisados no período escolhido? Qual foi o motivo dessa disrupção?
- 3) QP3: Quais eventos externos podem estar relacionados a mudanças notáveis (se houver) na dinâmica global de transferências?

Para responder às questões de pesquisa foram criados grafos temporais extraídos a partir dos dados disponibilizados no site Transfermarkt ¹. Para cada um dos grafos, os nós representam os países e arestas são estabelecidas entre nós que possuem atividade de transferência entre eles. Cada aresta possui um peso associado que reflete o número de transferências entre os dois países naquela direção, sendo que o país de origem representa o nó de origem da aresta.

Visando comparar as diferentes redes globais de transferências, entre 1990 e 2022, um conjunto de métricas topológicas de grafos foi definido. A definição da granularidade temporal — ou seja, o tamanho de cada intervalo de tempo — foi realizada por meio da aplicação de um algoritmo de *change point detection* (CPD) [21], utilizado para identificar anos em que ocorreram variações significativas no volume de transferências. Para complementar nossas análises,

¹<https://www.transfermarkt.com.br/>

foi realizada a detecção de comunidades dos grafos definidos, a partir da aplicação do algoritmo de Louvain [2].

Os resultados revelaram a existência de países com comportamento consistente ao longo dos intervalos analisados, tanto em métricas topológicas quanto na formação de comunidades. Esses países, denominados agentes constantes, incluem França, Alemanha, Suíça e Bélgica. Em contraste, identificaram-se agentes disruptivos, cujas métricas e padrões de comunidade variaram de forma significativa ao longo do tempo — destacam-se, nesse grupo, Estados Unidos, Brasil, Portugal, China e Rússia. Para esses agentes, uma análise histórica permitiu identificar eventos correlacionados às mudanças observadas em sua posição na rede. Vale ressaltar que um dos principais eventos associados à emergência de padrões disruptivos foi a Lei Bosman (1995) [3], que reconfigurou o mercado de transferências ao liberalizar a movimentação de jogadores entre países europeus, o que ajuda a responder a QP3.

O intervalo de tempo adotado para segmentar a análise, denominado neste trabalho como granularidade, foi definido em 5 anos com base no algoritmo de CPD proposto por Truong [21]. A partir dessa granularidade, foram construídos os grafos, calculadas as métricas e comunidades, e conduzidas as análises correspondentes. No entanto, buscou-se avaliar o impacto da variação da granularidade, a fim de verificar se a escolha sugerida pelo algoritmo seria adequada para capturar as principais dinâmicas da rede. Ao final, concluiu-se que a granularidade de 5 anos apresentou um bom equilíbrio, permitindo uma análise consistente ao longo do tempo e alinhando-se a eventos históricos relevantes, como a Lei Bosman em 1995.

II. REFERENCIAL TEÓRICO

O futebol, além de ser um esporte com grande apelo emocional mundialmente, tem-se consolidado como uma atividade economicamente lucrativa, movimentando bilhões de reais todos os anos. Essa relevância econômica e cultural tem despertado o interesse de pesquisadores, gerando estudos sobre diferentes aspectos da modalidade. No entanto, apesar do crescente número de trabalhos acadêmicos, poucos abordam a dinâmica do mercado de transferências em uma perspectiva topológica e temporal, como proposto neste trabalho.

Um dos primeiros estudos que explora a migração de jogadores em um contexto globalizado é apresentado por Maguire [10]. Embora tenha uma abordagem sociológica, sua pesquisa discute os impactos dessa migração no desenvolvimento global do esporte, sendo um marco na compreensão da expansão internacional do futebol.

Diversos trabalhos na literatura utilizam os conceitos de análise de redes sociais (Social Network Analysis - SNA) em estudos esportivos. Por exemplo, o trabalho de Hagen, Wäsche e Brandes [6] apresenta uma tipologia das diversas abordagens possíveis ao se utilizar SNA no esporte, mostrando como essa metodologia pode ser explorada para mapear relações complexas e interações dentro de redes esportivas.

A visão topológica do mercado de transferências é abordada em LEE, Hong e Jung [8] e em Li, Zhou e Stanley [9], que

buscam identificar métricas significativas na rede global de transferências. Enquanto LEE, Hong e Jung [8] exploram um recorte específico da janela de transferências do verão de 2014, Li, Zhou e Stanley [9] analisam um período mais amplo, de 1990 a 2016, oferecendo uma perspectiva cronológica das transformações no mercado. Já Safdari and De Bacco [17] apresentam uma técnica que utiliza a persistência das comunidades em grafos temporais como referência para identificar interações anômalas e mudanças estruturais ao longo do tempo, aplicando sua metodologia, inclusive, ao contexto de transferências de jogadores de futebol como estudo de caso.

No contexto brasileiro, Onody e De Castro [12] apresentam um estudo específico sobre o futebol brasileiro, analisando grafos bipartidos entre clubes e jogadores. Além disso, os autores constroem um grafo de jogadores que atuaram simultaneamente, explorando a evolução temporal de métricas da rede formada. Os resultados apresentados sugerem que o aumento das transferências pode estar relacionado a mudanças nas dinâmicas dessas métricas, uma ideia diretamente alinhada ao escopo deste trabalho. Os autores em Felix et al. [4], além de realizar análises topológicas, utilizam um método de descoberta de comunidades com sobreposição, a fim de identificar diferentes papéis para um país em várias comunidades.

Este trabalho, diferentemente de estudos anteriores como [4] e [17], propõe uma ampliação do uso das técnicas apresentadas nesses artigos para analisar, em um período mais extenso (1990 a 2022), as mudanças topológicas da rede em conjunto com as variações na estrutura das comunidades. O objetivo é identificar padrões e rupturas na rede mundial de transferências, relacionando essas dinâmicas com eventos históricos potencialmente impactantes.

III. METODOLOGIA

Esta seção apresenta os passos metodológicos para o desenvolvimento do trabalho.

A. Dados Coletados e Modelagem Matemática

Por meio de técnicas de *web scraping* aplicadas ao site Transfermarkt ², foram coletados, tratados e organizados de forma estruturada dados sobre transferências envolvendo aproximadamente 190 ligas. O período considerado abrange os anos de 1990 a 2022. Cada registro de transferência contém informações sobre o jogador envolvido, o clube e a liga/país de origem, o clube e a liga/país de destino, além do valor da transferência e a indicação de seu tipo (definitiva ou por empréstimo). É relevante destacar que transferências cujos países de origem e destino são os mesmos foram excluídas na construção dos grafos, com o objetivo de focar exclusivamente nas movimentações internacionais de jogadores. Quando um jogador encerra seu contrato com um clube, seu país/liga de destino é registrado como "Free Agent" (agente livre). O mesmo ocorre quando o atleta assina com um novo time sem estar vinculado a nenhum clube no momento da transferência. A Tabela I contém uma lista do top 10 países com maior número de transferências no período analisado.

²<https://www.transfermarkt.com.br/>

País	Número de Transferências
Inglaterra	19923
Brasil	16505
Portugal	14100
Espanha	13581
Alemanha	13294
França	12787
Itália	11458
Bélgica	11204
Argentina	10091
Rússia	8970

Tabela I: Lista dos 10 países com maior número de transferências entre 1990 e 2022.

Os grafos construídos neste trabalho seguem uma definição semelhante à proposta por Félix [4]. Seja $P = \{p_1, \dots, p_n\}$ o conjunto de países considerados. A rede de transferências de jogadores é modelada como um grafo dirigido $G = (V, E)$, em que cada vértice $v_i \in V$ representa um país $p_i \in P$, e cada aresta $e_{ij} \in E$ representa uma transferência de jogador do país p_i para o país p_j . Define-se ainda uma função de ponderação $f : e_{ij} \mapsto w_{ij}$, que associa a cada aresta $e_{ij} \in E$ um peso $w_{ij} \geq 0$, correspondente ao número de transferências realizadas do país p_i para o país p_j , caso existam transações nessa direção.

Cada grafo analisado representa todas as interações em um determinado intervalo de tempo. Para definir o tamanho deste intervalo, utilizamos um algoritmo de detecção de pontos de mudança (CPD) aplicado à série temporal do número anual de transferências. O algoritmo adotado foi o *Pruned Exact Linear Time* (PELT) [21], com implementação fornecida pela biblioteca ruptures³ em Python. Os pontos de mudança identificados foram os anos de 1994, 1999, 2004, 2009, 2014, 2019 e 2023. Como o intervalo inicial dos dados começa em 1990 e os segmentos analisados foram padronizados em blocos de cinco anos, os intervalos definidos foram: 1990–1995, 1995–2000, 2000–2005, 2005–2010, 2010–2015, 2015–2020, 2020–2025 (sendo que os dados incluem apenas até o fim de 2022).

Com o objetivo de avaliar a adequação do algoritmo PELT na identificação dos pontos de mudança para esta aplicação, também foram realizadas as análises descritas nas seções seguintes utilizando granularidades alternativas de 3 e 7 anos. Vale destacar que os intervalos que abrangem dados apenas após 2020 (2020–2025 e 2020–2023) apresentaram grande discrepância em relação aos demais, por ser um período incompleto, motivo pelo qual foi desconsiderado das análises.

Para analisar as características temporais das diferentes janelas de transferência de jogadores, foram calculadas métricas topológicas de centralidade — grau (número de conexões diretas de um país com outros), betweenness (medida de quantas vezes um país aparece nos caminhos mínimos entre outros países) e closeness (inverso da soma das distâncias mínimas de um país para todos os demais, indicando sua acessibilidade na rede). Além disso, foram avaliadas a assorta-

tividade do grafo, que indica a tendência de países com grau similar se conectarem, e a distribuição do peso das arestas, refletindo o volume de transferências entre pares de países.

É importante destacar que o cálculo da centralidade de grau seguiu a metodologia proposta por Opsahl [13]. Essa abordagem propõe uma métrica que combina duas dimensões: o número de conexões (*grau*) e o peso das arestas (volume de transferências), permitindo ajustar a influência relativa de cada uma por meio de um parâmetro α .

A centralidade ponderada de grau para um vértice i é dada por:

$$C_D^{w\alpha}(i) = k_i^{(1-\alpha)} \cdot s_i^\alpha \quad (1)$$

onde:

- k_i é o grau de entrada (ou saída) do vértice i (número de países com os quais há conexão),
- s_i é a soma dos pesos das arestas incidentes em i (volume total de transferências),
- $\alpha \in [0, 1]$ é um parâmetro que define o peso relativo entre o número de conexões e o volume transferido.

Neste trabalho, foi adotado $\alpha = 0,5$, de modo a atribuir pesos iguais às duas dimensões, equilibrando a análise entre países com muitos parceiros comerciais e aqueles com menos conexões, mas com alta intensidade de transferências.

Além disso, foram elaborados rankings com os 10 países mais influentes em cada um dos principais indicadores de centralidade — grau, betweenness e closeness — permitindo identificar os agentes mais relevantes da rede em diferentes critérios.

B. Detecção de comunidades

Para aprofundar as análises, além da extração de métricas topológicas em cada intervalo de tempo, foi aplicado um algoritmo de detecção de comunidades aos grafos gerados. O objetivo foi identificar agrupamentos mais coesos de países na rede de transferências, possibilitando observar a evolução dessas comunidades ao longo do tempo.

O algoritmo de Louvain [2] foi aplicado neste trabalho por sua eficiência computacional e adequação à análise de grafos ponderados. Trata-se de um método heurístico baseado na otimização da modularidade, proposto para extrair a estrutura de comunidades em redes de grande escala. Segundo os autores, o algoritmo supera outros métodos de detecção de comunidades conhecidos em termos de tempo de computação. No contexto desta pesquisa, sua utilização permitiu identificar agrupamentos coesos de países com padrões semelhantes de transferência, sendo a direção das arestas desconsiderada, uma vez que esse fator apresentou impacto limitado na formação das comunidades.

C. Definição do papel dos países na movimentação dos jogadores

A partir da classificação dos países nas métricas, foi possível analisar as variações ocorridas em diferentes granularidades e intervalos de tempo, identificando os países que mantiveram

³<https://github.com/deepcharles/ruptures>

posições consistentes nas principais métricas de centralidade da rede. De forma análoga, ao se examinar as comunidades, foi possível apontar os países que conservaram seus papéis ao longo do tempo.

Para identificar os agentes disruptivos, foram analisados países que apresentaram comportamentos fora do padrão esperado. Por exemplo, quando um país passou a se destacar repentinamente em alguma métrica de centralidade, isso indicou uma alteração na estrutura da rede, possivelmente associada a algum evento específico ocorrido naquele contexto. A mesma lógica foi aplicada à análise das comunidades, sendo desejável que houvesse correlação entre as métricas e as comunidades, o que contribuiu para enriquecer a análise.

Com essas análises, foi possível classificar os países como constantes ou disruptivos, o que contribuiu diretamente para a resposta às questões de pesquisa propostas.

D. Proposição de correlação entre eventos e agentes disruptivos

Após a seleção dos países identificados como agentes disruptivos, foi realizada uma pesquisa bibliográfica com o objetivo de encontrar estudos relacionados à história do mercado futebolístico em cada um deles. Buscou-se compreender se as mudanças observadas na rede de transferências poderiam ser fundamentadas por transformações econômicas, políticas ou estruturais no futebol local.

Para alguns países, foram encontradas referências consistentes que correlacionavam o desenvolvimento do mercado de transferências com aspectos históricos, econômicos e políticos. Em outros casos, especialmente onde existiu uma barreira linguística para os estudos encontrados, as informações encontradas foram mais escassas. Ainda assim, foi possível reunir boas referências para a maioria dos países analisados, o que contribuiu para validar as mudanças identificadas na rede e aprofundar a compreensão dos fenômenos observados.

IV. ANÁLISE E RESULTADOS

Esta seção apresenta os resultados obtidos no trabalho. A análise está organizada em quatro eixos principais: primeiro, validamos a escolha da granularidade temporal utilizada; segundo, exploramos a topologia da rede por meio de métricas de centralidade; terceiro, investigamos a formação e evolução das comunidades de países; e, por fim, discutimos os diferentes papéis que os agentes (países) desempenham na rede, conectando-os a eventos do mundo real para responder às questões de pesquisa que nortearam este estudo.

A. Validação da Escolha da Granularidade Temporal

O primeiro passo da metodologia consistiu em segmentar a rede de transferências em intervalos de tempo, facilitando a análise da dinâmica estrutural. Para isso, utilizou-se o algoritmo de CPD [21], que indicou a granularidade de 5 anos como ideal. Com o intuito de validar essa escolha e verificar a sensibilidade das métricas às variações temporais, realizaram-se comparações adicionais com granularidades de 3 e 7 anos.




Fig. 1: Variação da assortatividade do grafo no intervalo entre 1990 e 2020.




Fig. 2: Variações da Rússia na sua centralidade de grau no intervalo de 1990 a 2020 com granularidade de 3 anos de intervalo.




Fig. 3: Variações da Rússia na sua centralidade de grau no intervalo de 1990 a 2020 com granularidade de 5 anos de intervalo.

A análise revelou que o intervalo de 3 anos oferece maior precisão na detecção de mudanças imediatas, como as provocadas pela Lei Bosman, ao capturar melhor o contexto pré e pós dezembro de 1995, conforme demonstram os dados na Tabela III, na qual se observa a grande variação de valores nos anos que cercam o evento. No entanto, essa granularidade falha ao representar alterações mais duradouras, como o aumento da assortatividade ao longo do tempo visto na Figura 1 para a granularidade de 5 anos. Em contraste, o intervalo de 7 anos evidencia de forma clara transformações de longo prazo, especialmente nas métricas de grau — como pode ser observado na Tabela V, que exibe variações constantes nessas métricas ao longo do tempo —, mas dilui variações pontuais e abruptas, tornando-as menos perceptíveis.

A análise comparativa dos gráficos de centralidade de grau




Fig. 4: Variações da Rússia na sua centralidade de grau no intervalo de 1990 a 2020 com granularidade de 5 anos de intervalo.




Fig. 5: Variações dos EUA na sua centralidade de grau no intervalo de 1990 a 2020 com granularidade de 3 anos de intervalo.




Fig. 6: Variações dos EUA na sua centralidade de grau no intervalo de 1990 a 2020 com granularidade de 5 anos de intervalo.

para cada país revela como a granularidade temporal pode levar a interpretações divergentes sobre a relevância e a trajetória dos atores na rede. No caso da Rússia, a alta centralidade observada no período 2004-2011 é uma característica exclusiva do recorte de 7 anos, como mostra a Figura 4. Isso contrasta com as granularidades menores, nas quais seu protagonismo diminui após 2005, conforme ilustrado pelas Figuras 2 e 3.

Analogamente, a consolidação dos Estados Unidos como um polo central é datada em momentos distintos, dependendo da figura analisada. A ascensão dos EUA a partir de 2008 é detectada na janela de 3 anos, conforme mostra a Figura 5. Já na janela de 5 anos, essa ascensão começa a partir de 2010, como pode ser visto na Figura 6. Por fim, a Figura 7 ilustra que, na janela de 7 anos, a ascensão dos EUA ocorre




Fig. 7: Variações dos EUA na sua centralidade de grau no intervalo de 1990 a 2020 com granularidade de 7 anos de intervalo.

apenas no período consolidado de 2011-2018. Apesar dessa divergência, a análise histórica aprofundada, discutida em seções posteriores, corrobora que a ascensão norte-americana de fato se inicia a partir de 2008, validando a maior sensibilidade do intervalo de 3 anos para este evento específico.

Conclui-se, portanto, que cada granularidade de tempo oferece perspectivas distintas sobre a dinâmica da rede de transferências. Apesar das contribuições específicas das granularidades de 3 e 7 anos, a segmentação em intervalos de 5 anos revelou-se a mais equilibrada, permitindo uma análise consistente ao longo do tempo, com número adequado de cortes e alinhamento com marcos históricos relevantes. Dessa forma, todos os demais resultados analisados a seguir são extraídos dos grafos construídos considerando a granularidade de 5 anos.

B. Análise Topológica da Rede

A Figura 8 mostra a evolução da centralidade de grau em países que se destacaram nessa métrica durante o período analisado. Por outro lado, a Figura 9 ilustra a evolução da centralidade de proximidade (closeness) para um subconjunto desses mesmos países.

A análise das métricas de centralidade ao longo das janelas de 5 anos revela a posição estrutural dos diferentes países na rede. França, Alemanha, Suíça e Bélgica, por exemplo, mantiveram posições de destaque especialmente em centralidade de grau, sendo frequentemente intermediários relevantes nas movimentações de jogadores. A Bélgica, em particular, conservou protagonismo até 2020. Em contraste, a Inglaterra, nomeada como “United Kingdom”, destaca-se como o país com o maior número absoluto de transferências entre 1990 e 2022 (visto na Tabela I), embora não apresente centralidade de grau elevada, visto que seu volume de trocas se concentra em um número relativamente pequeno de parceiros.

Observam-se também ascensões notáveis. A partir de 2007, dados de centralidade de grau mostram um crescimento significativo da influência dos Estados Unidos. O Brasil também apresenta uma ascensão consistente nas métricas de centralidade, tanto de grau quanto de *closeness*, ao longo das últimas décadas. Portugal, por sua vez, já figurava entre os países com maior centralidade de grau entre 2000 e 2005, e o aumento




Fig. 8: Principais países e variações na sua centralidade de grau no intervalo de 1990 a 2020.




Fig. 9: Principais países e variações na sua centralidade de grau no intervalo de 1990 a 2020.

observado em suas métricas de centralidade ao longo do tempo indica uma tendência de consolidação.

Outros países exibem dinâmicas de ascensão e queda. A Rússia aparece com destaque em sua Centralidade de Grau de Saída (Out-Degree Centrality) entre 1995 e 2005 (Figura 11). Essa métrica reflete o papel relevante da Rússia como exportadora no período, embora sua centralidade tenha caído significativamente após essa data. Já a China, a partir de 2005, passa a figurar entre os dez países mais centrais em métricas como centralidade de grau, mantendo essa posição até aproximadamente 2015, quando enfrenta uma queda nesta métrica.

C. Exploração das Comunidades

A Tabela II exhibe as comunidades que foram geradas para cada um dos intervalos de tempo que analisamos. Para cada comunidade, a tabela destaca os nomes dos países mais relevantes.

A análise das comunidades revela a formação de blocos de países com interações comerciais mais intensas. Primeiramente, identifica-se um núcleo estável na Europa Ocidental, com França, Alemanha, Suíça e Bélgica permanecendo frequentemente na mesma comunidade, com possível rivalidade frente à do Reino Unido. Esta última, por sua vez, demonstra estabilidade em suas conexões, com a Inglaterra (United




Fig. 10: Gráfico comparativo da evolução do Grau Total (eixo esquerdo, azul) e da Soma do Peso das Arestas (eixo direito, laranja) para a Inglaterra, em intervalos de 5 anos, de 1990 a 2020.




Fig. 11: Variação da métrica de centralidade do grau de saída para Rússia no intervalo de 1990 a 2025.

Kingdom) quase sempre inserida no mesmo grupo que os demais países do Reino Unido e nações nórdicas.

A formação de novas comunidades dinâmicas também é um resultado central. O Brasil exerce papel crucial na estruturação de uma comunidade com Portugal e diversas nações da Ásia Oriental, conforme mostrado na Figura 12. Essa comunidade é consolidada pela presença consistente da China desde 1995, embora no intervalo da referida figura o número de transferências entre os países esteja bem abaixo. Em paralelo, observa-se a maior inserção dos Estados Unidos em grupos com países da América Latina.

Mesmo antes da ascensão de Portugal nas métricas de centralidade ao longo do tempo, o país já possuía uma base sólida na rede, ancorada em uma forte parceria com o Brasil. A análise do subgrafo de sua comunidade entre 2000 e 2005 evidencia essa conexão precoce, como vemos na Figura 13. Isso ajuda a explicar por que, apesar da tendência de consolidação ser mais visível em períodos posteriores, Portugal já figurava entre os países com maior centralidade de grau entre 2000 e 2005.

Observa-se uma mudança grande na composição dos blocos europeus: enquanto no período de 1990-1995 os agrupamentos eram mais definidos geograficamente e culturalmente, no intervalo subsequente (1995-2000) há a formação de um megabloco altamente diversificado (Comunidade 0). Este novo agrupamento passa a incluir a maior parte da Europa, além de regiões da África e da Ásia, evidenciando uma desestruturação

Subgrafo centrado em Brasil (arestas com peso > 45)




Fig. 12: Comunidade do Brasil no intervalo 2015 a 2020 com nós filtrados pelo peso da aresta mínimo 45.

Subgrafo centrado em Russia (arestas com peso > 30)




Fig. 14: Comunidade da Rússia no intervalo 2010 a 2015 com nós filtrados pelo peso da aresta mínimo 30.

Subgrafo centrado em Portugal (arestas com peso > 50)




Fig. 13: Comunidade de Portugal no intervalo 2000 a 2005 com nós filtrados pelo peso da aresta mínimo 50.

Subgrafo centrado em Russia (arestas com peso > 30)




Fig. 15: Comunidade da Rússia no intervalo 2015 a 2020 com nós filtrados pelo peso da aresta mínimo 30.

das antigas fronteiras em favor de um mercado mais integrado.

A análise das comunidades formadas até 2005 evidencia um bloco coeso no Leste Europeu, no qual a Ucrânia e a Bielorrússia ocupam posições de destaque ao lado da Rússia. Contudo, uma mudança estrutural ocorre a partir de 2005, período que marca o início de uma queda expressiva na centralidade russa na rede global.

Apesar da queda em sua centralidade global, a Rússia continua a exercer influência regional, mantendo um número elevado de conexões no mercado local. No entanto, sua atuação internacional exibe uma mudança de padrão a partir de 2014, com um declínio expressivo nas transferências com a Ucrânia, que até então era seu principal parceiro, como pode ser visto na Figura 14 (pré-2014). Em paralelo a essa queda, nota-se um crescimento acentuado nas transferências de jogadores russos na categoria "passe livre", especialmente entre 2015 e 2020, conforme ilustrado na Figura 15.

D. Análise dos Papéis dos Países e seu Contexto Histórico

A análise da rede revelou um cenário dinâmico, com papéis distintos desempenhados por diferentes países ao longo do tempo. A compreensão desses papéis, sejam eles constantes ou disruptivos, emerge do cruzamento da estrutura da rede com uma série de eventos históricos, políticos e econômicos que moldaram o futebol global.

Foi identificado um núcleo de agentes constantes, notadamente um bloco da Europa Ocidental formado por França, Alemanha, Suíça e Bélgica, que atuaram como intermediários chave e mantiveram a estabilidade de suas posições. Adicionalmente, o Reino Unido demonstrou uma constância particular, consolidando-se como o maior mercado em volume absoluto de transferências e mantendo uma comunidade coesa com seus vizinhos britânicos e nórdicos.

Ao contrário de agentes constantes como França e Bélgica, outros países atuaram como agentes disruptivos, alterando significativamente a dinâmica da rede; isso será explicitado a nos parágrafos a seguir.

A ascensão dos Estados Unidos, por exemplo, está diretamente ligada a estratégias de internacionalização da Major League Soccer (MLS). Conforme destacam Gillett e Tennent (2020) [5], a chegada de jogadores de renome como David Beckham em 2007 marcou um ponto de inflexão na atratividade da liga. Além disso, segundo Holub [7], a introdução da regra dos "Designated Players" permitiu aos clubes excederem o teto salarial, viabilizando a contratação de estrelas que elevaram o prestígio e a capacidade de negociação da MLS.

De forma semelhante, a disrupção causada pelo Brasil teve raízes em mudanças legais e fatores socioculturais. Rodrigues e Caetano [16] argumentam que a promulgação da Lei Pelé, associada ao Caso Bosman na Europa, catalisou a exportação de jogadores brasileiros. Fatores econômicos, como diferenças cambiais, e o valor simbólico reforçado pelas conquistas nas Copas do Mundo de 1994 e 2002, também impulsionaram essa proeminência, tornando o jogador brasileiro como um ativo valioso no mercado global.

Portugal também se consolidou como um polo central, transformando-se em um grande exportador. Silva [19] aponta que a "Golden Generation" e os efeitos da decisão Bosman iniciaram essa mudança nos anos 1990. Posteriormente, os investimentos em infraestrutura e academias de base, especialmente após a Eurocopa de 2004, transformaram clubes como Benfica, Porto e Sporting em verdadeiras "incubadoras de talentos" de alto rendimento.

A trajetória da China foi marcada por uma ascensão rápida e um declínio igualmente notável. Como mostra Yang (2016) [22], a ascensão a partir de 2005 foi fruto de um projeto estatal para fortalecer a liga, com pesado investimento em estrelas internacionais, apoiado por grandes conglomerados. Contudo, o modelo se mostrou insustentável, e a partir de 2019, medidas restritivas como tetos salariais foram impostas, explicando a queda de sua centralidade, como mostrado por PELEJA [14].

Finalmente, a Rússia apresenta um caso de disrupção por meio de ascensão e posterior declínio. Após o colapso da URSS, o país se tornou um polo exportador para nações do antigo bloco soviético, uma estrutura herdada do ecossistema fechado do futebol soviético, como aponta Andreev [1]. A disrupção veio com sua queda, influenciada por fatores como a imposição de um limite a jogadores estrangeiros em 2005 e, mais tarde, por eventos políticos que impactaram severamente sua atuação internacional.

Dentre todos os acontecimentos, a Decisão Bosman em 1995 emerge como o evento externo de maior impacto sistêmico [15]. Seus efeitos, como o aumento expressivo no volume de transferências e a desestruturação das comunidades geográficas, criaram um mercado de fato globalizado. Enquanto a decisão Bosman abriu as fronteiras, outros eventos como a Lei Pelé e as políticas nacionais na China e na Rússia funcionaram como potentes motores de mudança local, explicando as trajetórias específicas dos agentes disruptivos dentro desse novo cenário mundial.

V. CONCLUSÃO E TRABALHOS FUTUROS

Este estudo evidenciou a utilidade da Análise de Redes Sociais para compreender as dinâmicas do mercado global de transferências de jogadores entre 1990 e 2022. A segmentação temporal em intervalos de cinco anos permitiu observar como eventos externos — como a Lei Bosman — e a ascensão de países disruptivos, como Estados Unidos e China, transformaram a estrutura da rede. Enquanto nações como França e Alemanha mantiveram posições estáveis, outros países alteraram significativamente seu papel por fatores legislativos, econômicos ou políticos, como ocorreu com o Brasil após a Lei Pelé. A pesquisa também destacou a importância da granularidade temporal na identificação de padrões e na formação de comunidades. No conjunto, o trabalho oferece uma base sólida para investigações futuras sobre o mercado do futebol, ressaltando o papel central da interconexão global nas transformações do setor.

Apesar dos resultados alcançados, é importante reconhecer as limitações do presente estudo, que, por sua vez, abrem caminho para futuras investigações. A principal limitação refere-se à escassez de registros de transferências na década de 1990, o que, embora não tenha inviabilizado a análise, indica que bases de dados mais completas poderiam enriquecer o estudo de eventos como as leis Bosman e Pelé. No âmbito metodológico, uma limitação importante foi a dificuldade de aplicar algoritmos de detecção de comunidades com sobreposição que fossem compatíveis com grafos ponderados e direcionados; avanços futuros poderiam vir com o uso de métodos mais sofisticados que combinem essas características. De forma análoga, seria interessante empregar algoritmos de detecção de ponto de mudança que operem diretamente sobre estruturas de grafos, uma abordagem estudada durante a pesquisa, mas não aplicada devido à sua complexidade técnica [18].

Por fim, uma futura abordagem multidisciplinar — com a participação de especialistas em história do futebol, ciências sociais e economia — poderia ampliar significativamente a qualidade e a profundidade da análise aqui iniciada.

REFERENCES

- [1] Roman Andreev. *The Business World of Russian Football : Issues and Prospects*. Bachelor's thesis. 2020. URL: <http://www.theseus.fi/handle/10024/354527>.
- [2] Vincent D Blondel et al. "Fast unfolding of communities in large networks". In: *Journal of Statistical Mechanics: Theory and Experiment* 2008.10 (Oct. 2008), P10008. ISSN: 1742-5468. DOI: 10.1088/1742-5468/2008/10/p10008. URL: <http://dx.doi.org/10.1088/1742-5468/2008/10/P10008>.
- [3] *Case C-415/93: Union Royale Belge des Sociétés de Football Association ASBL v Jean-Marc Bosman*. dezembro 1995. URL: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=celex:61993CJ0415> (visited on 06/27/2025).

- [4] Lucas G. S. Felix et al. “A Social Network Analysis of Football with Complex Networks”. In: *Anais Estendidos do XXV Simpósio Brasileiro de Sistemas Multimídia e Web*. Florianópolis: SBC, 2019, pp. 47–50. DOI: 10.5753/webmedia_estendido.2019.8134. URL: https://sol.sbc.org.br/index.php/webmedia_estendido/article/view/8134.
- [5] Alex Gillett and Kevin Tennent. *The Growth of Major League Soccer: Commentary, Analysis Explanations from the Literature*. June 2020. DOI: 10.13140/RG.2.2.30818.35521.
- [6] Alexander Woll Hagen Wäsche Geoff Dickson and Ulrik Brandes. “Social network analysis in sport research: an emerging paradigm”. In: *European Journal for Sport and Society* 14.2 (2017), pp. 138–165. DOI: 10.1080/16138171.2017.1318198. eprint: <https://doi.org/10.1080/16138171.2017.1318198>. URL: <https://doi.org/10.1080/16138171.2017.1318198>.
- [7] Hannah Holub. “The Marquee effect : a study of the effect of designated players on revenue and performance in major league soccer”. Honors Theses. University of Richmond, 2016. URL: <https://scholarship.richmond.edu/honors-theses/849>.
- [8] Sangmin LEE, Inho Hong, and Woo-Sung Jung. “A Network Approach to the Transfer Market of European Football Leagues”. In: *New Physics: Sae Mulli* 65 (Apr. 2015), pp. 402–409. DOI: 10.3938/NPSM.65.402.
- [9] Ming-Xia Li, Wei-Xing Zhou, and H. Eugene Stanley. “Network analysis of the worldwide footballer transfer market”. In: *EPL (Europhysics Letters)* 125.1 (Feb. 2019), p. 18005. ISSN: 1286-4854. DOI: 10.1209/0295-5075/125/18005. URL: <http://dx.doi.org/10.1209/0295-5075/125/18005>.
- [10] Joseph Maguire. “Preliminary Observations on Globalisation and the Migration of Sport Labour”. In: *The Sociological Review* 42.3 (1994), pp. 452–480. DOI: 10.1111/j.1467-954X.1994.tb00097.x. eprint: <https://doi.org/10.1111/j.1467-954X.1994.tb00097.x>. URL: <https://doi.org/10.1111/j.1467-954X.1994.tb00097.x>.
- [11] Mark O’Neill. *The History of the Football Transfer System*. Acesso em: 04 nov. 2024. July 2024. URL: <https://www.sportlawmusings.com/post/the-history-of-the-football-transfer-system>.
- [12] Roberto Onody and Paulo De Castro. “Complex network study of Brazilian soccer players”. In: *Physical review. E, Statistical, nonlinear, and soft matter physics* 70 (Oct. 2004), p. 037103. DOI: 10.1103/PhysRevE.70.037103.
- [13] Tore Opsahl, Filip Agneessens, and John Skvoretz. “Node centrality in weighted networks: Generalizing degree and shortest paths”. In: *Social Networks* 32.3 (2010), pp. 245–251. DOI: 10.1016/j.socnet.2010.03.006.
- [14] PELEJA. *O que ninguém te contou sobre o fracasso do futebol na China*. 2025. URL: http://www.youtube.com/watch?v=_qaDIoRf4I (visited on 06/27/2025).
- [15] Juliano Oliveira Pizarro. “A GLOBALIZAÇÃO E O FUTEBOL: O PROCESSO DA ACENTUAÇÃO DE DESIGUALDADE”. In: *(SYN)THESIS* 14.1 (Nov. 2021), pp. 39–59. DOI: 10.12957/synthesis.2021.63708. URL: <https://www.e-publicacoes.uerj.br/synthesis/article/view/63708>.
- [16] Francisco Rodrigues and Sidney Caetano. “COMÉRCIO INTERNACIONAL DE JOGADORES BRASILEIROS DE FUTEBOL”. In: *Revista TOMO* (Oct. 2009), p. 167. DOI: 10.21669/tomo.v0i15.493.
- [17] Hadiseh Safdari and Caterina De Bacco. “Community detection and anomaly prediction in dynamic networks”. In: *Communications Physics* 7.1 (Dec. 2024), p. 397. ISSN: 2399-3650. DOI: 10.1038/s42005-024-01889-y. URL: <https://doi.org/10.1038/s42005-024-01889-y>.
- [18] Ali Salmasnia et al. “A two-stage model for change point detection in large-scale weighted directed social networks using a MEWMA chart”. In: *Social Network Analysis and Mining* 13 (Apr. 2023). DOI: 10.1007/s13278-023-01067-y.
- [19] Pedro Guilherme Fernandes Fragoso da Silva. “Exploring the Impact of Portuguese Football Players in the Top 5 Leagues: A Brand Analysis”. MA thesis. UNL, 2024.
- [20] John Simkin. *Football Transfer System*. Atualizado em: jan. 2020. Acesso em: 04 nov. 2024. Sept. 1997. URL: <https://spartacus-educational.com/Ftransfer.htm>.
- [21] Charles Truong, Laurent Oudre, and Nicolas Vayatis. “Selective review of offline change point detection methods”. In: *Signal Processing* 167 (Feb. 2020), p. 107299. ISSN: 0165-1684. DOI: 10.1016/j.sigpro.2019.107299. URL: <http://dx.doi.org/10.1016/j.sigpro.2019.107299>.
- [22] Shuo Yang. “An economic history of Chinese football: 1994 - 2016”. In: *workingpaper* (June 2016), pp. 1994–2016.

APÊNDICE

A. Tabelas

Tabela II: Tabela com as comunidades e seus principais países nos intervalos entre 1990 e 2022.

Intervalo	Comunidade 0	Comunidade 1	Comunidade 2	Comunidade 3	Comunidade 4	Comunidade 5
1990-1995	Belarus, China, Lithuania, Russia, South Korea, Ukraine	Czechia	Ireland, Norway, Scotland, United Kingdom, Wales	Algeria, Egypt, Saudi Arabia, Zambia	Austria, Croatia, Denmark, France, Germany, Netherlands, Nigeria, Romania, South Africa, Switzerland, Türkiye, Venezuela	Argentina, Brazil, Canada, Greece, Japan, Portugal, Serbia, Thailand, United States, Uruguay
1995-2000	Algeria, Austria, Croatia, Czechia, Egypt, France, Germany, Greece, Netherlands, Nigeria, Romania, Serbia, Switzerland, Thailand, Türkiye, United Arab Emirates, Zambia	Denmark, Ireland, Norway, Scotland, South Africa, United Kingdom, Wales	Belarus, Lithuania, Russia, Ukraine	Argentina, Brazil, Canada, China, Iraq, Japan, Portugal, Saudi Arabia, South Korea, United States, Uruguay, Venezuela	-	-
2000-2005	Austria, Croatia, Czechia, Germany, Greece, Serbia, Türkiye	Canada, Denmark, Ireland, Norway, Scotland, United Kingdom, Wales	Belarus, Iraq, Lithuania, Romania, Russia, Ukraine, United Arab Emirates	Algeria, France, Netherlands, Nigeria, Switzerland, Thailand	Argentina, Brazil, China, Egypt, Japan, Portugal, Saudi Arabia, South Korea, United States, Uruguay, Venezuela	South Africa, Zambia
2005-2010	Austria, Belarus, Croatia, Czechia, Greece, Lithuania, Romania, Russia, Serbia, Ukraine	Argentina, Canada, United States, Uruguay, Venezuela	Denmark, Nigeria, Norway, South Africa, Zambia	Ireland, Scotland, United Kingdom, Wales	Brazil, China, Iraq, Japan, Portugal, South Korea, Thailand, United Arab Emirates	Algeria, Egypt, France, Germany, Netherlands, Saudi Arabia, Switzerland, Türkiye
2010-2015	Belarus, Croatia, Czechia, Lithuania, Russia, Serbia, Ukraine	Brazil, China, Egypt, Iraq, Japan, Nigeria, Portugal, Saudi Arabia, South Korea, Thailand, United Arab Emirates	Ireland, Scotland, United Kingdom, Wales	Algeria, Austria, France, Germany, Greece, Netherlands, Romania, Switzerland, Türkiye	Denmark, Norway, South Africa, Zambia	Argentina, Canada, United States, Uruguay, Venezuela
2015-2020	Austria, Belarus, Croatia, Czechia, Lithuania, Romania, Russia, Serbia, Ukraine	Algeria, Egypt, Iraq, Nigeria, Saudi Arabia, South Africa, Zambia	France, Germany, Greece, Ireland, Netherlands, Scotland, Switzerland, Türkiye, United Kingdom, Wales	Denmark, Norway	Argentina, Canada, United States, Uruguay, Venezuela	Brazil, China, Japan, Portugal, South Korea, Thailand, United Arab Emirates

Tabela III: Tabela com as variações das métricas com a granularidade dos intervalos fixada em 3 anos.

	INTERVALO DE 3									
	1990-1993 to 1993-1996	1993-1996 to 1996-1999	1996-1999 to 1999-2002	1999-2002 to 2002-2005	2002-2005 to 2005-2008	2005-2008 to 2008-2011	2008-2011 to 2011-2014	2011-2014 to 2014-2017	2014-2017 to 2017-2020	2017-2020 to 2020-2023
Average Degree	10.41%	29.14%	9.03%	22.52%	18.30%	11.63%	3.42%	8.07%	4.93%	3.61%
Max Degree	7.61%	27.27%	-1.59%	11.29%	14.49%	3.16%	9.82%	4.47%	0.00%	-3.74%
Min Degree	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
Average Edge Weight	9.06%	18.46%	5.23%	5.16%	13.99%	14.25%	8.77%	9.00%	8.64%	7.27%
Max Edge Weight	47.37%	-14.68%	7.44%	33.77%	27.83%	30.13%	-5.84%	34.71%	38.50%	-16.28%
Min Edge Weight	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
Average Degree Centrality	-6.32%	24.42%	3.02%	17.66%	9.59%	8.95%	-2.97%	5.12%	6.09%	0.28%
Max Degree Centrality	-8.70%	22.63%	-7.02%	6.87%	6.06%	0.69%	3.03%	1.61%	1.10%	-6.83%
Min Degree Centrality	-15.15%	-3.65%	-5.52%	-3.97%	-7.36%	-2.40%	-6.18%	-2.73%	1.10%	-3.21%
Average In-Degree Centrality	-6.32%	24.42%	3.02%	17.66%	9.59%	8.95%	-2.97%	5.12%	6.09%	0.28%
Average Out-Degree Centrality	-6.32%	24.42%	3.02%	17.66%	9.59%	8.95%	-2.97%	5.12%	6.09%	0.28%
Max In-Degree Centrality	-15.15%	21.80%	-8.34%	1.94%	10.09%	-3.59%	10.04%	-1.71%	-5.21%	1.09%
Max Out-Degree Centrality	-11.62%	13.69%	-3.92%	12.03%	0.58%	9.16%	-7.28%	6.53%	6.60%	-7.20%
Average Closeness Centrality	-7.66%	5.92%	5.15%	2.74%	6.01%	5.54%	-3.71%	2.11%	1.27%	-2.29%
Average Betweenness Centrality	-14.09%	-11.22%	2.98%	-12.58%	-7.57%	0.64%	-8.24%	-2.83%	0.28%	-4.41%
Degree Assortativity	-30.37%	3.61%	-7.10%	-17.49%	10.32%	0.40%	-7.02%	-11.73%	-17.28%	-5.04%
Number of Connected Components	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
Largest Component Size	17.70%	3.76%	5.80%	4.11%	7.89%	2.44%	6.55%	2.79%	-1.09%	3.30%

Tabela IV: Tabela com as variações das métricas com a granularidade dos intervalos fixada em 5 anos.

INTERVALO DE 5						
	1990-1995 to 1995-2000	1995-2000 to 2000-2005	2000-2005 to 2005-2010	2005-2010 to 2010-2015	2010-2015 to 2015-2020	2015-2020 to 2020-2025
Average Degree	38.43%	32.56%	30.20%	9.24%	11.26%	-5.49%
Max Degree	36.00%	9.56%	16.78%	10.92%	9.84%	-15.09%
Min Degree	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
Average Edge Weight	26.98%	10.46%	23.74%	19.70%	15.71%	-15.06%
Max Edge Weight	11.31%	23.17%	51.55%	22.79%	71.47%	-38.93%
Min Edge Weight	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
Average Degree Centrality	22.74%	27.46%	18.78%	-0.10%	10.09%	-4.48%
Max Degree Centrality	20.59%	5.35%	6.53%	1.43%	8.68%	-14.19%
Min Degree Centrality	-11.33%	-3.85%	-8.77%	-8.56%	-1.06%	1.07%
Average In-Degree Centrality	22.74%	27.46%	18.78%	-0.10%	10.09%	-4.48%
Average Out-Degree Centrality	22.74%	27.46%	18.78%	-0.10%	10.09%	-4.48%
Max In-Degree Centrality	17.17%	0.05%	6.63%	0.59%	3.94%	-8.65%
Max Out-Degree Centrality	5.72%	17.87%	2.03%	1.13%	13.68%	-12.97%
Average Closeness Centrality	8.05%	9.78%	10.59%	-1.97%	3.02%	-3.65%
Average Betweenness Centrality	-9.41%	-4.27%	-8.08%	-9.87%	-4.65%	6.45%
Degree Assortativity	-17.06%	-19.39%	13.05%	-11.17%	-10.67%	-30.36%
Number of Connected Components	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
Largest Component Size	12.69%	3.97%	9.55%	9.30%	1.06%	-1.05%

Tabela V: Tabela com as variações das métricas com a granularidade dos intervalos fixada em 7 anos.

INTERVALO DE 7				
	1990-1997 to 1997-2004	1997-2004 to 2004-2011	2004-2011 to 2011-2018	2011-2018 to 2018-2025
Average Degree	46.47%	44.16%	15.26%	1.71%
Max Degree	29.27%	13.84%	15.47%	-5.74%
Min Degree	0.00%	0.00%	0.00%	0.00%
Average Edge Weight	31.18%	30.02%	26.64%	-2.74%
Max Edge Weight	13.00%	68.14%	62.63%	-7.77%
Min Edge Weight	0.00%	0.00%	0.00%	0.00%
Average Degree Centrality	33.33%	30.75%	3.80%	1.18%
Max Degree Centrality	17.67%	3.25%	3.98%	-6.23%
Min Degree Centrality	-8.97%	-9.30%	-9.95%	-0.52%
Average In-Degree Centrality	33.33%	30.75%	3.80%	1.18%
Average Out-Degree Centrality	33.33%	30.75%	3.80%	1.18%
Max In-Degree Centrality	10.81%	0.42%	5.55%	-9.65%
Max Out-Degree Centrality	19.77%	7.63%	2.19%	-1.51%
Average Closeness Centrality	6.70%	15.04%	-3.55%	-0.22%
Average Betweenness Centrality	-16.84%	-7.82%	-16.80%	5.33%
Degree Assortativity	-12.40%	3.37%	-12.34%	-23.23%
Number of Connected Components	0.00%	0.00%	0.00%	0.00%
Largest Component Size	9.79%	10.19%	10.98%	0.52%