Otimização combinatória aplicada a composição de equipes esportivas

Diego Pereira Cortinhas, Diogo Alves da Silva
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ)
R. Gen. Canabarro, 485 - Maracanã, Rio de Janeiro - RJ, 20271-204, Brazil
{diego.cortinhas,diogo.alves}@aluno.cefet-rj.br

Israel Mendonça
Faculty of Advanced Science and Technology, Kumamoto University
2-3-91, Kurokami, Chuo-ku, Kumamoto City, 860-8555, Japan
israel@cs.kumamoto-u.ac.jp

Glauco Fiorott Amorim, Pedro Henrique González
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ)
R. Gen. Canabarro, 485 - Maracanã, Rio de Janeiro - RJ, 20271-204, Brazil
{glauco.amorim, pedro.silva}@cefet-rj.br

RESUMO

Neste trabalho é proposta uma aplicação de otimização combinatória multi-objetivo em um *fantasy game*, chamado Cartola FC, visando simular o problema de composição de equipes esportivas com limite financeiro e avaliar o impacto de diferentes perfis de tomada de decisão. Neste jogo, o usuário a cada rodada tem que selecionar a melhor escalação possível para o seu time de futebol com os recursos financeiros disponíveis. A partir da análise destes dados, desenvolveu-se uma ferramenta que otimize o uso dos recursos disponíveis e auxilie o usuário a escalar um time a cada rodada, levando em consideração sua estratégia, seja ela mais voltada para maximizar a pontuação, minimizar os gastos, ou fazer um balanceamento entre as duas anteriores. A simulação permitiu avaliar o impacto de cada um dos perfis definidos, assim como determinar a validade da proposta para uma possível aplicação real.

PALAVRAS CHAVE. ε***-constraint*, Otimização Multi-objetivo, Cartola-FC.**

OA – Outras aplicações em PO, OC – Otimização Combinatória

ABSTRACT

In this work we propose an application of multi-objective combinatorial optimization in a *fantasy game*, called Cartola FC, to simulate the problem of composing sports team with limited budget and evaluate the impact of different decision-making profiles. In this game, at each round the user has to select the best possible lineup for their football team with the available financial resources. Based on the analysis of this data, we developed a tool that optimizes the use of available resources and helps the user to compose a team, in each round, taking into account their strategy, whether it is more focused on maximizing the score, minimizing expenses, or a balance between the two previous ones. The simulation made it possible to evaluate the impact of each of the defined profiles, as well as to determine the validity of the proposal for a possible real application.

KEYWORDS. ε***-constraint*, Multi-objective Optimization, Cartola-FC.**

OA – Other Applications in PO, OC – Combinatorial Optimization

https://proceedings.science/p/157480?lang=pt-br

1. Introdução

Diversos problemas de otimização combinatória fazem uso de método de otimização multi-objetivo para obter um conjunto de soluções para problemas que busquem otimizar múltiplas funções objetivo. Isto acontece pois, normalmente, não existe uma única solução que seja ótima para todos os objetivos envolvidos (Hashimoto [2004], Oliveira Camara [2021]).

O problema de escalar uma equipe em esportes coletivos pode ser modelado como um problema de otimização multi-objetivo. Esse problema pode ter muitas vezes funções que busquem otimizar determinados critérios, levando em conta determinadas restrições, os quais são conflitantes entre si, como o orçamento disponível para despender com a equipe e a qualidade dos jogadores que serão contratados. Hoje em dia, este problema da vida real pode ser simulado nas escalações de equipes em jogos de *fantasy games*. Assim como nos esportes coletivos da vida real, escalações em *fantasy games* dependem de diversos critérios e torna-se difícil chegar a uma única escalação "ótima"em cada rodada. Entre os jogos virtuais deste estilo, o mais conhecidos no Brasil é o Cartola FC, que é um *fantasy game* de futebol, criado e mantido pela empresa Globo Comunicação e Participações S.A..

O jogo é uma forma de simulação do problema da escalação de equipes em esportes coletivos da vida real, trazendo consigo o mesmo problema relacionado à otimização combinatória. Em ambos os casos, existe a necessidade de otimizar financeiramente a escalação da equipe, através da compra e escalação de jogadores, que podem valorizar ou desvalorizar, dependendo do seus respectivos desempenhos na vida real.

Dentre as abordagens existentes na literatura, que fazem simulações utilizando *fantasy games*, existem trabalhos relacionados utilizando o Cartola FC. Entre eles, existe na literatura uma ferramenta desenvolvida para predição de jogos. Essa ferramenta escala os times automaticamente para cada rodada, simulando um campeonato completo e usa estratégias baseadas em modelos estatísticos (Mota et al. [2018]).

Existem também trabalhos relacionados onde foram utilizados modelos de aprendizado de máquina para prever escalações de times possíveis de se atingirem a maior pontuação no Cartola FC (da Silva Ribeiro [2021]).

Este trabalho difere dos demais que já foram realizados no que tange a criar um modelo matemático multi-objetivo que defina uma escalação de uma equipe em campeonatos de times de esporte coletivo, rodada a rodada, utilizando como dado de entrada a simulação do *fantasy game* Cartola FC, e que permita avaliar diferentes perfis na escolha da equipe. Dentre os perfis avaliados tem-se aquele que busca sempre a melhor performance, um segundo perfil que opta pela composição mais econômica disponível e um terceiro perfil que busca equilibrar os perfis anteriores. Para resolver tal modelo, é proposta a utilização da técnica ϵ-constraint, buscando assim encontrar escalações, de qualidade, de times, rodada a rodada, para diferentes perfis de jogadores virtuais e utilizando o esquema tático 4-3-3. Com isso, objetivamos estudar o impacto da utilização dos diversos perfis mostrando que o modelo pode ser utilizado em situações reais de esportes coletivos.

Para tal, a pesquisa utilizará da análise de dados de anos anteriores, mais especificamente do ano de 2019, de todas as rodadas do campeonato brasileiro (`https://github.com/henriquepgomide`).

O restante desse trabalho está organizado da seguinte forma: Na Seção 2 são apresentados os trabalhos relacionados. Na Seção 3 é apresentada a metodologia proposta, enquanto que na Seção 4 são apresentados os experimentos computacionais. Por fim, na Seção 5 são apresentadas as conclusões e trabalhos futuros.

https://proceedings.science/p/157480?lang=pt-br

2. Trabalhos Relacionados

Na área de otimização da seleção de jogadores e montagem de elencos para times em esportes coletivos em geral, já existem alguns trabalhos relacionados na literatura. Em (Mota et al. [2018]), os autores desenvolveram uma ferramenta de visualização, simulação e análise que, a partir de conjuntos de dados de anos anteriores do *fantasy game* Cartola FC, gera escalações de times usando duas estratégias distintas baseadas em modelos estatísticos para cada rodada, assim simulando um campeonato inteiro.

Além de simulações e modelos estatísticos para seleção de jogadores, existem abordagens na literatura onde a solução do problema é encontrada a partir de algoritmos de aprendizado de máquina, redes neurais e otimizações, como pode ser visto em (da Silva Ribeiro [2021]). Neste trabalho, foi proposto um modelo para predição, rodada a rodada, das escalações dos times, levando em consideração o patrimônio e esquemas táticos disponíveis para disposição dos jogadores.

De certa forma, as etapas do estudo vistas em (da Silva Ribeiro [2021]) são relativamente próximas a que apresentamos neste trabalho, porém com abordagens diferentes. As principais distinções deste trabalho em relação ao nosso é que, além da utilização de modelos de redes neurais para classificação e separação dos atletas, o autor propõe a solução do problema de otimização através da utilização de um algoritmo genético. A solução adotada no nosso trabalho busca a definição da Fronteira de Pareto através da utilização do método ε-*constraint* para a solução do problema de otimização multi-objetivo definido e escolha dessas melhores soluções, testando-as para diferentes perfis de jogadores virtuais.

Não podemos deixar de mencionar o trabalho realizado por (Gomide e Gualberto [2020]). Nele os autores realizam análises exploratórias a partir dos dados do Cartola FC com o objetivo de tentar montar um modelo preditivo para o desempenho de jogadores e placar dos jogos, tentando melhorar os índices de acerto nas escolhas das montagens do elenco no jogo. Os autores fizeram a aquisição dos dados de diversos anos através da API do Cartola FC e do site da CBF utilizando a linguagem R e utilizaram a linguagem *Python* para treinamento e geração do modelo preditivo.

Pode-se citar também o trabalho dos autores (Beliën et al. [2017]). Este apresenta um modelo de Programação Linear Inteira, para encontrar um conjunto ótimo de decisões, uma vez que já tenham os dados conhecidos de antemão, que podem ser aplicadas ao contexto de diversos *fantasy games*.

Por fim, salienta-se (de Oliveira Silveira [2021]), trabalho o qual se utiliza do algoritmo genético BRKGA para resolver o problema da otimização combinatória de escalação de time de futebol no *fantasy game* Cartola FC. No referido trabalho o autor traça um paralelo entre o problema de otimização proposto por ele e o conhecido problema de otimização combinatória da mochila. Assim como na abordagem da presente pesquisa, o autor utiliza a Base de Dados disponibilizada por Gomide e Gualberto [2020]. Para implementação da metaheurística BRKGA é utilizada uma API (*Application Programming Interface*) de código aberto escrita na linguagem de programação C++, a qual deixa ao usuário a função de implementação do decodificador e dos parâmetros das iterações do algoritmo genético. O Autor também busca comparar o desempenho das soluções encontradas ao longo das rodadas do campeonato e verifica a possibilidade de predições ao longo destas rodadas. A principal diferença entre este trabalho e o nosso é que o Autor modela o problema como um problema da mochila e utiliza um algoritmo genético para resolver o problema de otimização enquanto nossa abordagem modela de forma diferente e utilizao método ε-*constraint*.

3. Metodologia

A dinâmica da escalação do elenco nos esportes coletivos pode ser modelada como um problema de otimização multi-objetivo. Sendo, por conseguinte, um problema com finalidade de

minimizar o custo do time escalado, em qualquer unidade monetária, e maximizar a performance do time escalado no que se refere a escolha dos jogadores mais habilidosos por posição.

Para simular o que seria o montante (em reais) da equipe de um determinado esporte coletivo, foi utilizada a unidade monetária do Cartola FC, chamada de *Cartoleta*. O jogador virtual possui na rodada inicial do campeonato uma quantidade de 100 Cartoletas para montar o seu time. Este valor é decrementado da soma dos custos de todos os jogadores escalados pelo jogador virtual na rodada. Após o fim da rodada, o time escalado é vendido e o valor de Cartoletas obtido na venda dos jogadores é somado ao valor de Cartoletas que o jogador virtual porventura ainda tivesse.

O problema proposto pode ser definido matematicamente conforme a Equação 1:

$$Opt = \{S \subset \Psi | \forall s \in S, \nexists \bar{s} \in S, \text{tal que } f_1(\bar{s}) > f_1(s) \wedge f_2(\bar{s}) < f_2(s)\} \tag{1}$$

A Equação 1 descreve que para todo s, vetores soluções, pertencente a S, não existe solução $\bar{s}$, em S, que domine s em ambos os objetivos (f_1, f_2). Assim, o neste trabalho busca-se determinar S, de forma que S defina a fronteira de Pareto-ótima para o problema.

3.1. Modelo Matemático

Uma das formas de se resolver um problema de otimização é através da modelagem matemática, definindo as funções objetivo a serem otimizadas e suas restrições, para em seguida resolvê-lo utilizando uma técnica adequada.

Afim de representar o problema de composição de equipe em esportes coletivos como um problema de otimização multi-objetivo, a decisão de escolher um jogador para uma determinada posição foi representada como uma variável de decisão. Posto isso, definiu-se a variável $y_{ij}, \forall i \in P, j \in J$ como a variável de decisão que representa a escolha de um jogador $j \in J$ para a posição $i \in P$ no time a ser escalado. A cada jogador $j \in J$ associou-se os valores a_j e c_j que representam, respectivamente, a eficiência do jogador e o seu custo de mercado. Além disso, tem se que P, o conjunto das posições no time a ser escalado, consiste nas posições atacante, goleiro, lateral, meia, técnico e zagueiro. Por fim, o problema apresentado de otimização de composição de equipe esportiva pode ser representado como descrito a seguir:

$$\max \quad f_1(y) = \sum_{i \in P} \sum_{j \in J} a_j y_{ij} \tag{2}$$

$$\min \quad f_2(y) = \sum_{i \in P} \sum_{j \in J} c_j y_{ij} \tag{3}$$

$$\text{s.a.} \quad \sum_{i \in P} \sum_{j \in J} c_j y_{ij} \leq C, \tag{4}$$

$$\sum_{j \in \Gamma_i} y_{ij} = q_i, \qquad \forall i \in P \tag{5}$$

$$\sum_{i \in P} y_{ij} \leq 1, \qquad \forall j \in J \tag{6}$$

$$y_{ij} \in \{0, 1\}, \qquad \forall i \in P, j \in J \tag{7}$$

Os objetivos propostos são encontrar soluções que maximizem os valores encontrados na Função $f_1(y)$ e minimizem os valores encontrados na Função $f_2(y)$, ambas sujeitas as restrições do problema. A Restrição 4 garante que o custo total do time escolhido não ultrapasse o capital disponível (C). Por sua vez, as Restrições 5, garantem que para cada posição i, $i \in P$, dentre os

jogadores que podem jogar na posição $i \in P$ (Γ_i), sejam escalados exatamente q_i jogadores. Já as Restrições 6 garante que um jogador $j \in J$ será escalado no máximo em uma única posição i, $i \in P$. As Restrições 7 definem o domínio das variáveis y_{ij}. Desta forma, y_{ij} assume valor 1 se o jogador j, $j \in J$ é escolhido na posição i, $i \in P$ e 0 caso não seja escolhido.

Ao mesmo tempo que o modelo está sujeito a não ultrapassar o valor total do orçamento disponível, representado por C, e as demais restrições do problema, já apresentadas, ele busca encontrar soluções que minimizem os custos de montagem do elenco e que maximizem o somatõrio das eficiências dos jogadores escolhidos, em termos de possível valorização dos mesmos. Busca-se alcançar estes dois objetivos aplicando o método ε-*constraint*, como é explicado na Seção 3.2.

3.2. Método ε-*constraint*

O método ε-*constraint* é um dos métodos clássicos utilizados para tratar problemas de otimização multi-objetivo (MOPs). Este método converte MOPs para subproblemas de otimização mono-objetivo. O método transforma todos os objetivos do problema, com exceção de um deles, em restrições. Em suma, no método ε-*constraint*, buscou-se otimizar uma das funções objetivo usando as outras funções objetivo como restrições do problema, incorporando-as na parte de restrição do modelo (Mavrotas [2009]).

O limite superior destas restrições é determinado variando ε. Variando este valor e, assim, resolvendo diversos subproblemas, podemos determinar a fronteira de Pareto(Bérube et al. [2007]). Devido a grande quantidade de subproblemas que podem ser gerados e a dificuldade de estabelecer um esquema eficiente para variar o ε, este método vem sendo integrado dentro de outras heurísticas e esquemas de soluções iterativas, mas ainda se mostra eficaz para determinar a fronteira de Pareto em situações particulares como problemas de otimização combinatória bi-objetivos (BOCO),(Bérube et al. [2007]), como o problema proposto a ser resolvido do Cartola FC.

O método ε-*constraint* foi aplicado no modelo definido na Seção 3.2, de forma que a função $f_2(y)$ foi convertida em uma nova restrição para o problema, conforme descrito na Restrição (8). A restrição (4) foi então removida e as demais Restrições (5), (6) e (7) permanecem como restrições a serem levadas em consideração para o problema.

$$\begin{aligned} \max \quad & f_1(y) = \sum_{i \in P} \sum_{j \in J} a_j y_{ij} \\ \text{s.a.} \quad & \sum_{i \in P} \sum_{j \in J} c_j y_{ij} \leq \varepsilon, \\ & (5) - (7), \end{aligned} \tag{8}$$

tal que ε varia em T, onde T é um intervalo que tem seu limite inferior definido como o valor do time mais barato possível a cada rodada, com a utilização do esquema tático escolhido *a priori*, e seu limite superior C é dado pela quantidade de Cartoletas que o jogador virtual vai ter na rodada analisada.

Vale destacar que a escolha da função $f_2(y)$ em detrimento da função $f_1(y)$ foi feita levando em consideração que, semanticamente, o objetivo principal do problema é ter o time com os jogadores de melhor proficiência. Ademais, para a função $f_2(y)$, conforme explicado, os limites inferiores e superiores de ε estão bem definidos e claros, diferentemente da função $f_1(y)$.

A Figura 1 representa o fluxograma de como o método ε-*constraint* foi aplicado para resolver o modelo.

Foram utilizados como dados de entrada os dados de cada rodada, como jogadores disponíveis, custo dos jogadores, *scout* e média de pontuação deles, além da quantidade de Cartoletas disponíveis para escalação do time naquela rodada. Após a montagem do modelo, a função objetivo

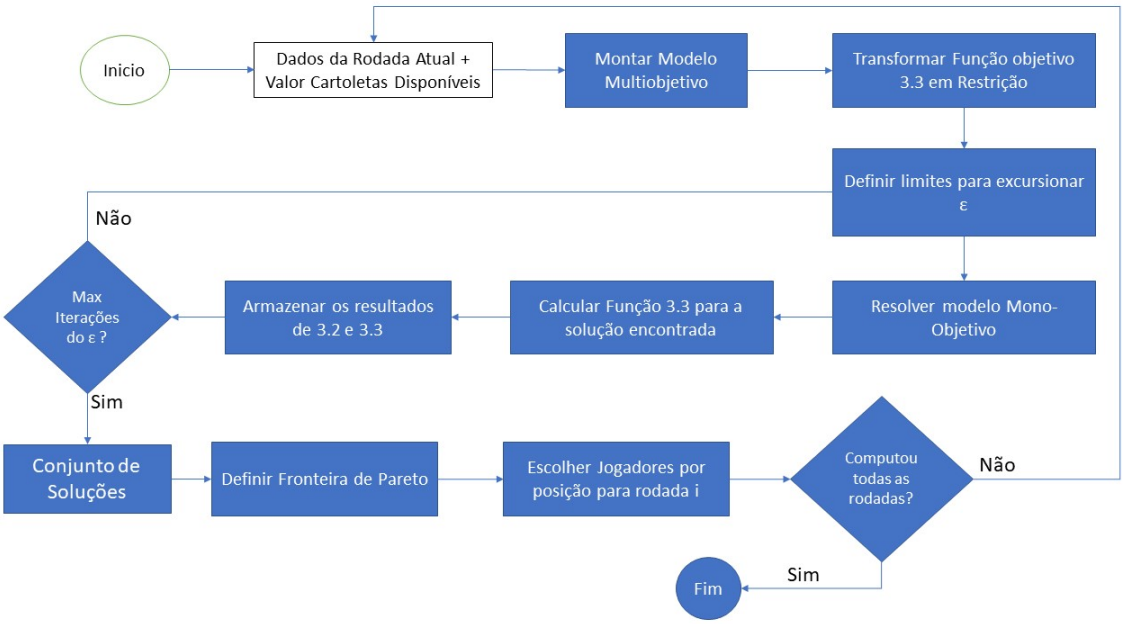

Figura 1: Fluxograma do método *ε-constraint* aplicado na resolução do Modelo proposto

de minimizar os custos dos jogadores escolhidos, Função $f_2(y)$, foi transformada em uma nova restrição para o problema.

Foram definidos os limites para variação dos valores de ε, tendo como seu limite inferior o valor do time mais barato na rodada e sendo incrementado pelo custo do jogador mais barato escolhido naquele time. O seu limite superior então é definido como o máximo do valor de Cartoletas disponíveis pelo jogador virtual na rodada.

Em seguida, foi resolvido o modelo mono-objetivo encontrando a solução para a Função objetivo $f_1(y)$ e calculada a Função objetivo $f_2(y)$. Foram armazenadas então as duas soluções das funções objetivo. Esse processo foi repetido até atingir-se o máximo de iterações de ε. Após a definição deste conjunto de soluções de $f_1(y)$ e $f_2(y)$, definimos a fronteira de Pareto-ótima das soluções e escolhemos os jogadores para a rodada que está sendo analisada. O mesmo processo foi repetido em cada rodada do campeonato, assim obtendo as escalações dos times para todas as rodadas.

3.3. Etapas do estudo

A primeira etapa consistiu em coletar e organizar os dados brutos do campeonato brasileiro de 2019, extraídos da base disponibilizada por (Gomide e Gualberto [2020]), em um banco de dados. Para tal, foi desenvolvido um programa[1], escrito na linguagem de programação *Python*. O programa utiliza a *API Rest*, oferecida pelo *Github*, para baixar conteúdos de seus repositórios e salvar no respectivo banco de dados do *MySQL*. As informações são utilizadas para formar o conjunto de soluções do problema.

A partir do conjunto de soluções encontradas para cada rodada, foi determinada a fronteira de Pareto, ou seja, o conjunto das soluções em que nenhum objetivo possa ser melhorado sem

[1]O código-fonte de todos os programas desenvolvidos utilizando a linguagem *Python*, estão disponíveis em: `https://github.com/DiegoCortinhas/sportsAnalytics`

https://proceedings.science/p/157480?lang=pt-br

deteriorar o outro e que dominem os demais conjuntos de soluções. Este é o conjunto de soluções eficientes que foram estudados no trabalho.

No presente contexto, foi denominado como *score* do jogador virtual a soma das proficiências reais obtidas de cada jogador escolhido em cada posição na rodada. Foi escolhido como capitão o jogador que mais pontuou neste time e sua pontuação foi dobrada ao ser considerada no cálculo do *score* total da equipe.

Na abordagem do presente trabalho, foi realizada uma simulação utilizando os dados do ano de 2019 do campeonato brasileiro definindo três perfis de jogadores virtuais. Estes perfis utilizaram diferentes soluções pertencentes a fronteira de Pareto, sendo que cada perfil seguiu uma estratégia específica diferente para jogar o *fantasy game*. O propósito da segmentação de perfis é entender o comportamento das estratégias dos jogadores virtuais e tentar verificar se existe alguma estratégia que se destaca.

O Perfil 1 simula o jogador virtual que possui a característica de optar por um time que economize mais o recurso financeiro, assim a escolha de soluções deste jogador reflete onde a função objetivo de minimização do custo foi priorizada. O Perfil 2, por sua vez, simula o jogador virtual que prefere optar por um time que busque os jogadores com as melhores pontuações, rodada a rodada. Assim, a escolha de soluções deste jogador reflete onde a função objetivo de maximização do *score* foi priorizada. Além disso, com o objetivo de buscar um meio termo entre as funções de minimização do custo e maximização do *score*, surge o Perfil 3. A escolha de soluções deste jogador virtual reflete um conjunto de soluções que balanceia as duas funções.

4. Experimentos Computacionais

Para entender o impacto da estratégia de cada perfil de jogador virtual, foram realizadas simulações tomando como base o critério de decisão de cada um dos três perfis de jogadores virtuais com o esquema tático 4-3-3. Estas simulações consistiram em executar o programa desenvolvido para cada um dos três perfis de jogadores virtuais sequencialmente da primeira até a última rodada do campeonato.

Em cada rodada, foram registradas todas as escalações feitas pelo algoritmo, incluindo os respectivos jogadores escolhidos, pontuação alcançada pelo elenco, quantos pontos o jogador virtual possuía no início da rodada e quantos pontos ele terminou a rodada. Além do aspecto da performance, a evolução financeira de cada perfil de jogador virtual também foi analisada.

4.1. Análise geral

Analisando as possibilidades de pontuação, sabemos que independentemente do esquema tático escolhido, a máxima pontuação final do jogador virtual, caso ele não tivesse limitação financeira, seria próxima dos 7.000 pontos. Vale destacar que o campeão, na vida real, do *Fantasy Game* Cartola FC no ano de 2019 obteve 3.258,99 pontos ao final da temporada, menos de 50% do total de pontos em relação ao limite superior da pontuação máxima calculada. (Fonte: Cartola-Campeão [2019])

Após execução do modelo, considerando os três perfis de jogadores virtuais, obtivemos pontuações apresentadas na Tabela 1.Nesta tabela é possível notar que as soluções encontradas na simulação, assim como esperado, diferem bastante em termos de pontuação total encontrada pelos diferentes perfis de jogadores virtuais.

Analisando os resultados obtidos, pode-se notar que os valores são coerentes com os perfis estabelecidos. O Jogador virtual de Perfil 1 obtém o pior resultado, pois sua estratégia é escolher os jogadores minimizando o custo em detrimento da proficiência dos atletas. Já o Jogador virtual de Perfil 2 encontra soluções que retornam as maiores pontuações, pois, ao contrário do Perfil 1, ele utiliza todo o dinheiro disponível para selecionar os atletas com a maior proficiência possível.

Esquema Tático	Perfil 1: Jogador Menor custo (Pontos)	Perfil 2: Jogador Maior *score* (Pontos)	Perfil 3: Jogador Balanceado (Pontos)
4-3-3	62,32	1938,46	1399,00

Tabela 1: Pontuação Acumulada ao final da rodada 38

Salienta-se ainda que as soluções encontradas pelo Perfil 3 se mostram coerentes na pontuação encontrada ao final do campeonato.

Os resultados apresentados na Tabela 1 são importantes, mas se faz necessário analisar o quanto cada perfil ganhou ou perdeu em cada rodada, isto é, a variação das cartoletas. Esse resultado é apresentado na Figura 2.

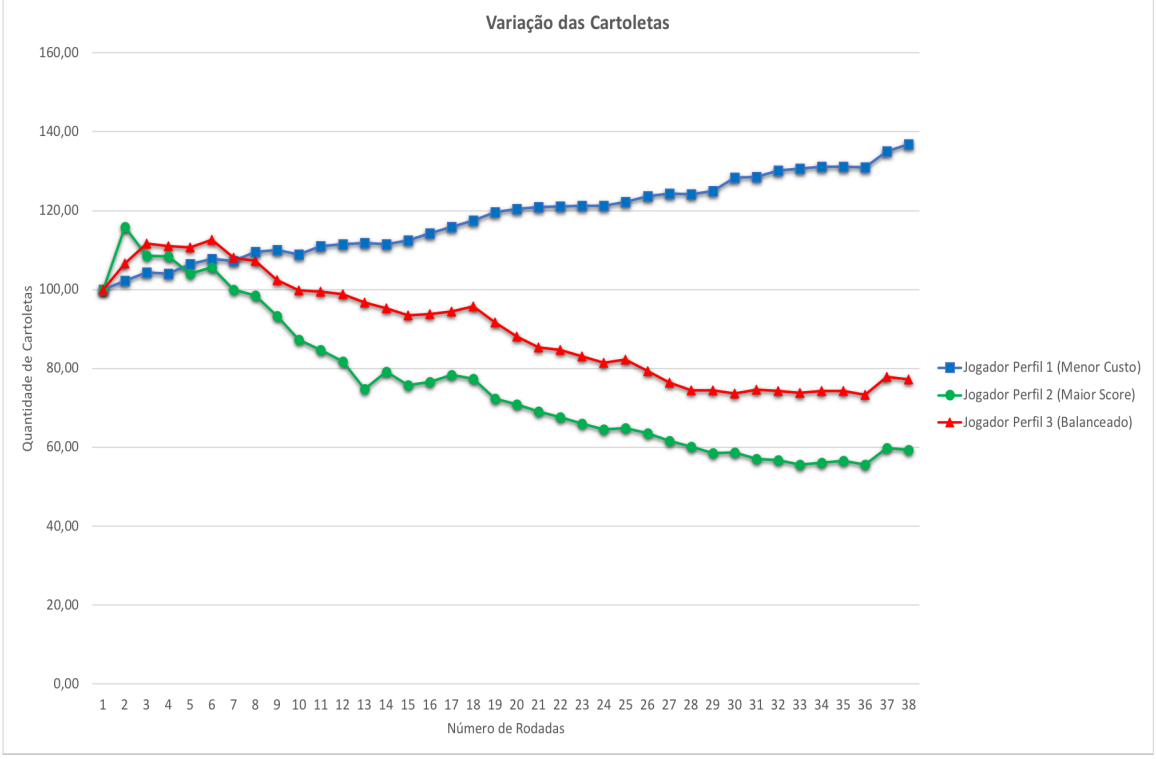

Figura 2: Variação das cartoletas para cada Jogador Virtual nas 38 rodadas.

Algumas análises importantes podem ser retiradas desse resultado. É possível verificar no gráfico que o Perfil 1 consegue aumentar seu 'capital inicial em cada rodada. Isso se deve ao fato de que este perfil escolhe os atletas com custos baixos, isto é, aqueles que nas rodadas anteriores possuem *scores* baixos. Isto aumenta a margem para que esses jogadores possam pontuar melhor na rodada seguinte e aumentarem seu valor de mercado.

No sentido oposto, a quantidade de cartoletas do Perfil 2 decai rodada a rodada. Este perfil termina o campeonato com a menor número de cartoletas entre todos os perfis. A explicação é semelhante a dada anteriormente. Como o Perfil 2 escolhe os jogadores mais caros e, por conseguinte,

os mais bem ranqueados, não existe uma margem muito grande para que esses jogadores aumentem sua pontuação na rodada seguinte, o que leva a uma possível desvalorização. Esse movimento é perceptível nas primeiras rodadas. Tanto para o Perfil 2 quanto para o Perfil 3, existe um ganho da primeira para a segunda rodada e, a partir daí, há uma desvalorização constante das cartoletas. Na primeira rodada, os jogadores possuem um *score* previsto pelo jogo baseado em informações dos campeonatos anteriores. Esse *score* não se aproxima do potencial total que o jogador pode alcançar nos jogos. Por isso, ao se escolher atletas com as melhores proficiências pode levar a uma valorização, pois a tendência de uma maior pontuação é grande. Entretanto, essa tendência não se sustenta visto que o atleta pode ter alcançado seu melhor desempenho.

A curva do jogador com Perfil 3 é semelhante à do jogador com Perfil 2, mas as perdas são suavizadas pela conduta determinada para este perfil. Vale lembrar que este perfil tem um compromisso entre custo e proficiência.

Um dos principais objetivo deste estudo é entender o impacto do uso das estratégias discutidas na subseção anterior e suas implicações no resultado final de cada perfil. A Figura 3 nos ajuda a entender o comportamento dos jogadores virtuais.

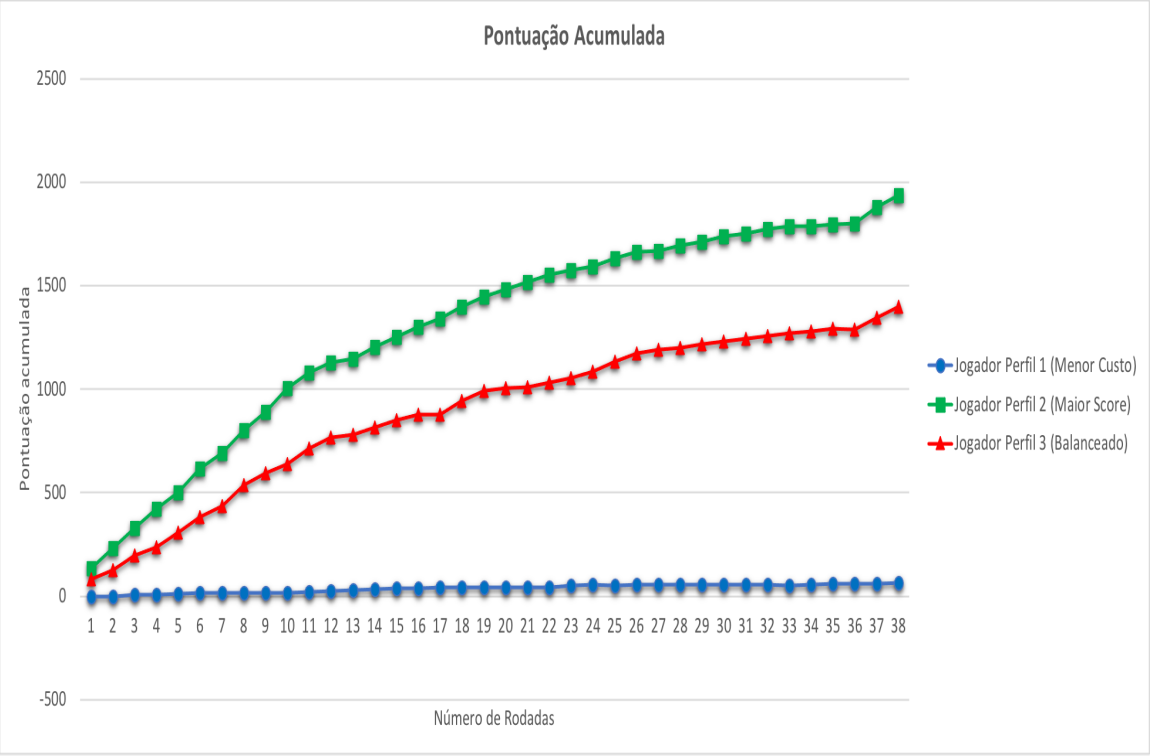

Figura 3: Pontuação Acumulada para cada Jogador Virtual nas 38 rodadas.

Como visto anteriormente, os perfis tendem a focar na otimização de um objetivo mais que o outro. Os Perfis 1 e 2 são os casos extremos, sendo que o Perfil 1 foca em minimizar a quantidade de cartoletas gastas na rodada e o Perfil 2 foca em maximizar performance do elenco. Nas subseções a seguir é feito a discussão do comportamento de cada perfil adotado em separado e em mais detalhes.

4.2. Impacto de minimizar o custo

O Perfil 1 joga de forma conservadora e minimizar a quantidade de cartolas utilizadas em cada rodada. No entanto, como pode ser visto na Figura 3, isto faz com que esse perfil se torne o com menos pontuação em cada rodada e consequentemente o com a menor pontuação no final do campeonato. Embora jogar de forma conservadora nos permita guardar mais cartolas para uma futura contratação de maior custo, esta mesma reduz drasticamente a quantidade de pontos que o perfil faz por rodada. Na realidade, a recompensa de utilizar esta estratégia é tão baixa que todos os outros perfis conseguem obter mais pontos na primeira rodada do que o Perfil 1 consegue durante todo o campeonato.

4.3. Impacto de maximizar performance

Na subseção anterior observamos que minimizar o custo por rodada não é uma estratégia que recompensará o jogador, nesta seção analisamos o desempenho do Perfil 2, em que ele tenta maximizar a performance do time a cada rodada. Como podemos observar na Figura 3, no final das 38 rodadas, este foi o jogador obteve a maior pontuação. Porém se compararmos o desempenho de cada jogador ao longo do campeonato, podemos observar que a vitória obtida por este jogador se deve a pontuação que ele obteve na primeira metade do campeonato.

Uma discussão importante é o impacto do preditor para a valorização dos jogadores nas rodadas seguintes. Como descrito anteriormente, a métrica escolhida foi a média das atuações anteriores. Foi possível observar que, com o passar das rodadas, as soluções de jogadores escolhidos começaram a apresentar médias menores e com isso mais jogadores com pontuações mais baixas e até em alguns casos com pontuações zeradas começaram a ser escolhidos nas soluções, o que acarretava em diminuição do dinheiro disponível. Este fato também impactou a pontuação final do jogador virtual deste perfil.

4.4. Impacto de ser balanceado

Na prática, nem sempre vai se optar pela escalação de um time com o menor custo possível ou pela solução do time com maior *score* possível e que gaste todos os recursos financeiros. Muitas vezes o pode-se optar pela seleção de um time que balanceie o custo total e a pontuação do time escolhido. Para representar essa situação foi proposto o Perfil 3.

Pode-se perceber que as pontuações encontradas ao longo das 38 rodadas, assim como suas pontuações médias, estão abaixo das pontuações e pontuações médias, respectivamente, do Perfil 2, o que já era esperado. Dado a forma balanceada de jogo, o jogador do Perfil 3 não utilizava todas as Cartoletas que tinha disponíveis a cada rodada. Então as soluções de jogadores encontradas a cada rodada tendiam a ter médias mais próximas do valor de suas pontuações reais.

Após a análise dos três perfis, é possível destacar uma situação interessante. Como discutido anteriormente, os Perfis 2 e 3 têm como tendência perder cartoletas, mas aumentar a pontuação no decorrer das rodadas, o que é o oposto do Perfil 1. Isso aponta para uma estratégia de se utilizar um Perfil híbrido, isto é, usar uma abordagem nas rodadas iniciais e alterar para outra abordagem após um determinado número de rodadas. Um exemplo pode ser usar o Perfil 1 nas primeiras rodadas com o objetivo de aumentar o aporte financeiro, obter mais informações sobre a performance dos jogadores e mudar para o Perfil 2, escolhendo os melhores jogadores, já com um montante maior para sustentar, por mais tempo, esse perfil.

5. Conclusão e Trabalhos Futuros

Este trabalho tratou do problema de composição de equipes esportivas através da modelagem e resolução de um problema de otimização multi-objetivo. Para avaliar a metodologia desenvolvida utilizou-se o *fantasy game* Cartola FC e criou-se três perfis de jogadores virtuais propostos, o que permitiu simular diversos perfis, que, dentre outros, podem ser gerentes de clubes de

esportes coletivos. Neste sentido, foi possível refletir certas consequências das características dos perfis na escolha do elenco escalado.

Durante a análise feita no presente trabalho, ficou perceptível que o grau de incerteza do fator de predição escolhido impactou diretamente nas escolhas das soluções para os diferentes perfis. Mesmo assim os experimentos mostraram que o Perfil 2 ainda apresentou as maiores pontuações totais. Cabe destacar também que quanto maior a acurácia da previsão melhor será a estratégia utilizada pelo Perfil 2 em relação aos demais perfis, no quesito performance.

Um dos pontos que seria possível explorar em trabalhos futuro seria o fator de predição para escalação de elencos. Nesse trabalho, o fator de predição utilizado para a pontuação dos jogadores escalados nos elencos foi a média de pontuação deles durante o campeonato até o início da rodada analisada. Os resultados obtidos, contudo, demonstram que esse método de predição foi pouco preciso. Portanto, seria interessante a avaliação de um novo método para realizar essa etapa de predição das proficiências.

Outro ponto sugerido como trabalho futuro é evoluir o programa desenvolvido de forma a permitir que o esquema tático seja escolhido de forma dinâmica, ou seja, deixando que o jogador virtual possa variá-lo a cada rodada.

Referências

Beliën, J., Goossens, D., e Reeth, D. V. (2017). Optimization modelling for analyzing fantasy sport games. *INFOR: Information Systems and Operational Research*, 55(4):275–294. URL https://doi.org/10.1080/03155986.2017.1279899.

Bérube, J.-F., Gendreau, M., e Potvin, J.-Y. (2007). An exact ε-constraint method for bi-objective combinatorial optimization probles - aplication to the traveling salesman problem with profits. *Department of Computer Science and Operations Research(DIRO) of the Université de Montreal*.

Cartola-Campeão (2019). Campeão PRO de 2019 conta detalhes da campanha e confessa: Senti o peso no final. https://ge.globo.com/cartola-fc/noticia/campeao-pro-de-2019-conta-detalhes-da-campanha-e-confessa-senti-o-peso-no-final.ghtml. Acessado: 01 mar. 2022.

da Silva Ribeiro, L. E. (2021). Predição de escalações para o jogo CartolaFC utilizando aprendizado de máquina e otimização. Trabalho de Conclusão de Curso, UFU (UNIVERSIDADE FEDERAL DE UBERLÂNDIA), Uberlândia, Brasil.

de Oliveira Silveira, B. (2021). Aplicação de BRKGA para otimização combinatória em Fantasy Game. Trabalho de Conclusão de Curso, UFF (Universidade Federal Fluminense), Niterói, Brasil.

Gomide, H. e Gualberto, A. (2020). *CaRtola: Extração de dados da API do CartolaFC, análise exploratória dos dados e modelos preditivos em R e Python*. URL https://github.com/henriquepgomide/caRtola.

Hashimoto, K. (2004). Técnicas de otimização combinatória multiobjetivo aplicadas na estimação do desempenho elétrico de redes de distribuição. Trabalho de Conclusão de Curso, USP (Escola Politécnica da Universidade de São Paulo), São Paulo, Brasil.

Mavrotas, G. (2009). Effective implementation of the ε-constraint method in multi-objective mathematical programming problems. *Applied mathematics and computation*, 213(2):455–465.

Mota, E., Coimbra, D., e Peixoto, M. (2018). Cartola fc data analysis: A simulation, analysis, and visualization tool based on cartola fc fantasy game. *SBSI'18: Proceedings of the XIV Brazilian Symposium on Information Systems*.

Oliveira Camara, M. V. (2021). *Abordagens Multiobjetivo para alguns problemas de localização de facilidades*. PhD thesis, Instituto Alberto Luiz de Coimbra de Pós-Graduação e Pesquisa de Engenharia da Universidade Federal do Rio de Janeiro - COPPE UFRJ.