



UM ESTUDO SOBRE VIESES EM ORDENAMENTOS OBTIDOS POR MÉTODOS DE APOIO À DECISÃO MULTICRITÉRIO

Palavras-Chave: MÉTODO DE APOIO À DECISÃO MULTICRITÉRIO, ORDENAMENTO, ENVIESAMENTO, EQUIDADE, EVOLUÇÃO DIFERENCIAL

Autores:

PEDRO CARDOSO ISHARA, FCA, UNICAMP

Prof. Dr. LEONARDO TOMAZELI DUARTE (orientador), FCA, UNICAMP

GUILHERME DEAN PELEGRINA (coautor), FCA, UNICAMP

INTRODUÇÃO:

O presente documento se trata do resumo da pesquisa desenvolvida no âmbito do Programa Institucional de Bolsas de Iniciação Científica (PIBIC) da Unicamp. O trabalho aborda um problema ainda pouco explorado na literatura, o qual tem a ver com a equidade em modelos de apoio à decisão multicritério (MCDA). Tais modelos são muito utilizados principalmente para auxiliar na tomada de decisões. Entretanto, quando usados para ordenar pessoas, esses modelos podem amplificar vieses relacionados a um determinado grupo social.

Nesse sentido, a pesquisa foi estruturada a fim de criar um modelo de MCDA que leva em conta essa possibilidade de lidar com desbalanços de equidade, e, assim, diminuir as disparidades entre os membros de cada grupo social no ordenamento. Com relação à organização do presente resumo, descreveremos o contexto do problema e a metodologia utilizada pelo bolsista durante a vigência do programa. Na sequência serão apresentados os resultados e, por fim, apresentaremos as conclusões do trabalho realizado.

DESCRIÇÃO DO PROBLEMA:

O projeto foi desenvolvido inicialmente com uma etapa de estudos dos métodos de apoio à decisão multicritério (MCDA, do inglês *multiple*

criteria decision aiding) [1, 2, 3, 4, 5, 6] e dos conceitos de equidade em ordenamentos [7, 8, 9, 10, 11, 12]. O problema de equidade em ordenamentos ainda aparece como um campo pouco explorado, mas uma área próxima com mais literatura é a de equidade em modelos de aprendizado de máquina [13, 14]. Nesse contexto, e de modo a introduzir a problemática abordada no projeto, considere um cenário no qual há candidatos postulantes a uma posição. Esse caso pode ser visto como um exemplo típico de aplicação dos métodos de MCDA de modo a se obter um ordenamento de tais candidatos avaliadas por múltiplos critérios, tais como experiência no ramo, fluência em idiomas, algum conhecimento técnico específico, dentre outros.

Matematicamente, em um problema de decisão multicritério, o elemento central é a chamada matriz de decisão \mathbf{X} , composta pelas avaliações de n alternativas $a_i, i = 1, \dots, n$ considerando um conjunto de m critérios $c_j, j = 1, \dots, m$. Assim, um dado elemento da matriz \mathbf{X} , expresso por $x_{i,j}$, representa o valor atribuído à alternativa i em relação ao critério j .

A abordagem mais popular em MCDA é baseada na teoria do valor, que, por sua vez, se apoia num processo de agregação das avaliações multicriteriais, de modo a se obter um valor global para cada um dos critérios, e, conseqüentemente, um ordenamento dos mesmos. Um dos métodos de agregação mais

utilizados é a soma ponderada [3], a qual consiste de um método de agregação linear e na qual o valor global da alternativa i é dado por:

$$p_i = \sum_{j=1}^m x_{i,j} w_j, \quad (1)$$

onde w_j representam os parâmetros que, *grosso modo*, estão associados às importâncias relativas dos critérios (pesos).

Ao tratar de ordenamentos envolvendo, por exemplo, pessoas, há risco de problemas relacionados a certos enviesamentos. Por exemplo, uma fonte de enviesamento pode ser uma escolha de um critério (ou um conjunto de critérios) que prejudicam indivíduos pertencentes a um determinado grupo social. Evidentemente, tal problema pode ser abordado a partir de uma cuidadosa discussão dos critérios. Entretanto, nem sempre é possível identificar a introdução de vieses a partir do conjunto de critérios utilizados. Nesse contexto, cabe notar que se os pesos dos critérios forem atribuídos sem levar em consideração a presença de alternativas (indivíduos) que possam ser sistematicamente prejudicados, o ordenamento resultante pode levar a soluções altamente imparciais.

METODOLOGIA:

Frente a esse problema de ordenamentos enviesados, foi iniciada uma fase de definição de uma metodologia para atuação. Foi definido que seria utilizada a linguagem de programação Python para o desenvolvimento de um algoritmo que atuasse no ajuste automático dos pesos dos critérios a fim de minimizar a distância entre o grupo socialmente prejudicado (grupo sensível ou grupo protegido) e o grupo socialmente beneficiado, principalmente nas primeiras posições do ordenamento. Isso se dá pois, considerando um ordenamento maior, com n elementos, estes poderão ser agrupados para análise e apresentação em grupos com k elementos, sendo chamado de *top-k* a quantidade de candidatos agrupados no primeiro grupo (no topo) do ordenamento [15].

Muitos ordenamentos são feitos somente para a obtenção do *top-k* e, dessa forma, para

quantificar o enviesamento foi utilizada uma métrica baseada na divergência de Kullback-Leibler (*rKL*) [16, 17], que, de certo modo, expressa uma divergência entre a proporção de alternativas protegidas nos topos das listas (*top-k*) e a proporção desse mesmo grupo sensível em todo conjunto de alternativas. Tal métrica, matematicamente, é dada por:

$$rKL = \sum_{k=10,20,\dots}^n \frac{D_{KL}(P||Q)}{\log_2 k} \quad (2)$$

onde

$$D_{KL}(P||Q) = \sum_k P * \log \frac{P}{Q}, P = \frac{S_k}{k} \text{ e } Q = \frac{S_n}{n}, \quad (3)$$

em que S_k é o número de pessoas do grupo sensível no *top-k* e S_n , o número de pessoas do mesmo grupo na população total (n). É possível perceber que em um cenário mais justo, a medida *rKL* se aproxima de zero.

Inicialmente foi feita uma análise exaustiva com dados sintéticos de acordo com uma distribuição normal, separados em grupo protegido e não protegido e com três critérios. Na sequência, as alternativas do grupo sensível apresentaram um de seus três critérios multiplicados por um fator de enviesamento que altera entre 0 e 1, sendo 0 totalmente enviesado e 1 totalmente livre de vies. Dessa forma, foi desenvolvido o algoritmo que, com tais dados enviesados, consegue reconhecer o enviesamento e indicar qual conjunto de pesos que deixará o ordenamento mais justo em relação aos critérios de equidade utilizados. Após a realização de diferentes testes, foi possível identificar o critério enviesado, de tal maneira que, com intuito de eliminar tal viés, a estratégia mais direta seria justamente anular o peso referente a um dado critério, limitando, assim, a sua influência no processo de agregação.

A partir do entendimento da análise exaustiva, o algoritmo foi modificado para uma meta-heurística que busca minimizar a função objetivo apresentada em (2). Para tal, foi utilizada, então, a evolução diferencial (ED) que é estocástica por natureza [18]. Para isso, foi utilizada a biblioteca do Scipy que possui a evolução diferencial como uma de suas ferramentas e é utilizada para encontrar o mínimo de uma função, sendo ideal

para a problemática do trabalho [19, 20]. Assim, foi desenvolvido um método que recebe como dados de entrada as alternativas, quais delas pertencem ao grupo sensível e qual o k desejado para a criação do *top-k*. Com tais informações de entrada, o algoritmo, através de um método de otimização, indica quais pesos minimizam a função objetivo de (2) e qual o valor da mesma para esses pesos.

Para as análises serem feitas, foram gerados dados sintéticos da mesma forma que durante a análise exaustiva (sendo principalmente utilizados os dados com o tamanho n de amostras igual a 1000, o *top-k* igual a 50 e o nível de enviesamento do critério 1 igual a 0,7). Além disso, para o correto funcionamento da evolução diferencial foi utilizada como estratégia a “*rand2exp*” a qual, após estudos e análises exaustivas, se mostrou como a melhor estratégia para o problema a fim de evitar mínimos locais. Assim, foi criado o algoritmo para a evolução diferencial.

Durante esses primeiros estudos com o método de otimização foram utilizados três critérios, para ser possível a comparação de resultados com a análise exaustiva de todos os pesos. Para concluir o trabalho, o algoritmo foi usado para um caso com dados reais obtidos através do *The World Bank* [21]. Na análise do método proposto com esses dados reais, foi considerado um problema de ordenamento de países de acordo com um determinado conjunto de critérios. Para tal, foram considerados como alternativas 88 países e como critérios a porcentagem de crianças em idade de escola primária que estão fora da escola, a inflação, a expectativa de vida ao nascer e a taxa de desemprego. Além disso, foi utilizado como critério de diferenciação dos grupos o fato de o país estar classificado como desenvolvido ou subdesenvolvido [22] e para o k foi utilizado o valor 15.

Assim, após tratar os dados e normalizá-los, de modo que os critérios sejam transformados para escalas equivalentes, foi possível executar o algoritmo proposto e comparar os resultados de uma simples agregação de pesos iguais (0,25 de peso para cada um dos 4 critérios) com os resultados da agregação com os pesos que o algoritmo sugeriu.

RESULTADOS E DISCUSSÃO:

De modo a validar a proposta da redução de enviesamento dos critérios, foi proposto um caminho de três partes. Na primeira, foi feita uma análise exaustiva com todos os pesos possíveis para um problema com três critérios e teve como objetivo entender mais a problemática e definir quais seriam os passos para de fato resolver o problema. Na segunda, foi feito o algoritmo com a evolução diferencial e testado inicialmente com dados sintéticos e comparados com a análise exaustiva. O método proposto foi também testado, na terceira parte, com dados reais.

Análise exaustiva

Durante a análise de todos os pesos, tendo o terceiro peso (w_3) multiplicado pelo fator 3 de enviesamento de 0,7 o esperado era que para minimizar a função objetivo de distância entre a proporção no *top-k* e na população geral, a influência desse terceiro critério fosse minimizada, ou seja, w_3 mais próximo de zero. É possível notar pela Figura 1 que tal hipótese foi confirmada durante esse teste, uma vez que a função é minimizada em cima da reta $w_1 = w_2 = 0,5$, ou seja, anulando o peso w_3 , que é justamente o peso associado ao critério enviesado. Isso mostra o bom funcionamento, nessa análise exaustiva, do algoritmo proposto.

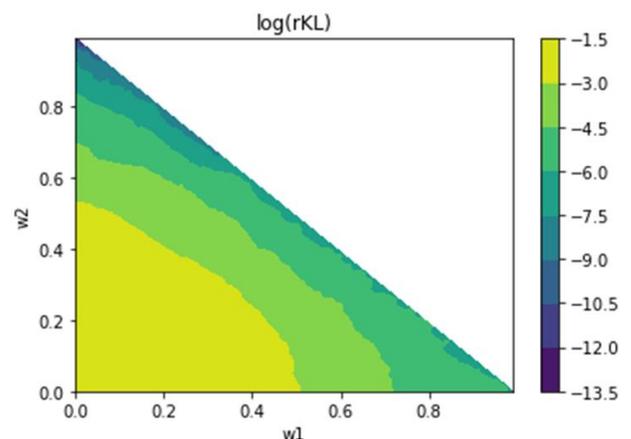


Figura 1: Resultado de todos os pesos em relação à função objetivo rKL .

Algoritmo de ordenamento equânime (via ED): experimentos com dados sintéticos e reais

Após obtermos um entendimento do funcionamento do algoritmo proposto via uma inspeção exaustiva da função objetivo adotada, partimos para uma abordagem na qual a minimização desta função objetivo foi conduzida pelo método de otimização evolução diferencial (ED); consideramos a implementação desse método disponível no pacote Scipy. Nesse sentido, inicialmente, foram feitos todos os estudos com dados sintéticos, sendo comparados com o esperado pela teoria e com a situação investigada na análise exaustiva. Em tais análises, o algoritmo de otimização apresentou resultados bem condizentes com o esperado e muito bons quando comparados com a análise exaustiva.

Por fim, foi testado o algoritmo de otimização com dados reais de 88 países. No caso com dados reais, o *top-k* foi consideravelmente melhorado em relação à métrica de equidade utilizada. Na situação, a população geral foi dividida em 59,09% de países pertencentes ao grupo sensível. Os resultados do *top-k* encontram-se na Tabela 1, na qual o índice de grupo igual a 1 significa um país pertencente ao grupo sensível enquanto igual a 0, não sensível.

Tabela 1: Resultados do *top-15* da simulação com países.

Adequação com pesos iguais		Adequação com pesos indicados pela ED	
Índice do país	Índice do grupo	Índice do país	Índice do grupo
64	1	64	1
74	0	41	1
58	0	74	0
41	1	58	0
4	0	42	1
38	0	61	1
5	0	4	0
73	0	84	1
18	1	5	0
37	1	18	1
27	0	22	1
47	0	47	0
69	0	49	1
28	0	69	0

26	0	38	0
Participação no <i>top-15</i>	26,67%	Participação no <i>top-15</i>	53,33%

Conclui-se que, com a adequação de pesos iguais para todos os critérios, o *top-15* teve uma participação de somente 26,67% de países pertencentes ao grupo sensível. Já após a adequação dos pesos indicados pelo algoritmo com a evolução diferencial, a participação do grupo protegido aumentou para 53,33% entre os 15 primeiros países do ordenamento. Vê-se, assim, a eficácia do algoritmo proposto, o qual conseguiu aproximar muito da proporção da população geral apenas com a indicação de outros pesos (vide Tabela 2).

Tabela 2: Vetor de pesos recomendados pelo algoritmo.

W ₁	W ₂	W ₃	W ₄
0,26309	0,18466	0,11464	0,43761

CONCLUSÕES:

A partir da definição do tema do projeto foi analisado o problema apresentado e foram buscadas formas de minimizar a discrepância entre os grupos. Para tal, foi escolhido atuar nos pesos no método de soma ponderada. Dessa forma, foi encaminhado o trabalho com a criação inicial de modelos mais limitados para a resolução do problema, mas que davam maior entendimento do mesmo. Assim, foi feito o algoritmo de análise exaustiva de todos os pesos para, posteriormente, ser evoluído para um algoritmo de otimização com a função objetivo de minimizar a distância entre a proporção do grupo sensível no *top-k* e na população geral.

Nessa linha, os resultados encontrados foram bem positivos, reafirmadores e esclarecedores, bons para o encaminhamento do problema durante o trabalho e mostrando-se uma boa abertura de um tema ainda pouco explorado na literatura.

Além disso, foi possível perceber que apesar de o algoritmo conseguir resolver o problema e indicar pesos que realmente fazem o ordenamento ser mais justo (conforme o critério de equidade utilizado) e poder ser utilizado para

a geração de ordenamentos como previsto, o algoritmo também pode ser muito útil na identificação de critérios enviesados, a fim de auxiliar na escolha de critérios.

Dessa forma, é possível utilizar o algoritmo proposto tanto para gerar o ordenamento após a definição final dos critérios utilizados, quanto para ajudar no processo anterior à criação dos ordenamentos, que é o de definir quais serão os critérios utilizados.

Assim, o trabalho mostrou-se bem consistente com o proposto, apresentando até outros resultados interessantes e não previstos inicialmente. Dessa forma, acredita-se que a pesquisa contribuiu com esse campo de trabalhos em equidade em métodos de MCDA, com bons resultados e uma boa abertura para novos trabalhos.

BIBLIOGRAFIA

- [1] GRECO, S., FIGUEIRA, J., & EHRGOTT, M. (2016). *Multiple criteria decision analysis* (Vol. 37). New York: Springer.
- [2] HWANG, C., YOON, K. (2012). *Multiple Attribute Decision Making: Methods and Applications A State-of-the-Art Survey*. Alemanha: Springer Berlin Heidelberg.
- [3] Keeney, R. L., Raiffa, H., & Meyer, R. F. (1993). *Decisions with multiple objectives: preferences and value trade-offs*. Cambridge university press.
- [4] Pelegrina, G. D. *Multicriteria decision making: dealing with criteria interactions by means of latent variable* (Doctoral dissertation, Universidade Estadual de Campinas (UNICAMP). Faculdade de Engenharia Elétrica e de Computação).
- [5] POMEROL, J. C., & BARBA-ROMERO, S. (2012). *Multicriterion decision in management: principles and practice* (Vol. 25). Springer Science & Business Media.
- [6] Triantaphyllou, E., & Baig, K. (2005). The impact of aggregating benefit and cost criteria in four MCDA methods. *IEEE Transactions on Engineering Management*, 52(2), 213-226.
- [7] Castillo, C. (2019). Fairness and transparency in ranking. In *ACM SIGIR Forum* (Vol. 52, No. 2, pp. 64-71). New York, NY, USA: ACM.
- [8] Cavicchia, M. (2015). *How to fight implicit bias. With conscious thought, diversity expert tells NABE*. American Bar Association: Bar Leader, 40.
- [9] Celis, L. E., Mehrotra, A., & Vishnoi, N. K. (2020, January). Interventions for ranking in the presence of implicit bias. In *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency* (pp. 369-380).
- [10] Kleinberg, J., & Raghavan, M. (2018). *Selection problems in the presence of implicit bias*. arXiv preprint arXiv:1801.03533.
- [11] Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2019). *A survey on bias and fairness in machine learning*. arXiv preprint arXiv:1908.09635.
- [12] Verma, S., & Rubin, J. (2018). Fairness definitions explained. In *2018 IEEE/ACM international workshop on software fairness (fairware)* (pp. 1-7). IEEE.
- [13] Gao, R., & Shah, C. (2020). Toward creating a fairer ranking in search engine results. *Information Processing & Management*, 57(1), 102138.
- [14] Geyik, S. C., Ambler, S., & Kenthapadi, K. (2019). Fairness-aware ranking in search & recommendation systems with application to linkedin talent search. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* (pp. 2221-2231).
- [15] Zehlike, M., Bonchi, F., Castillo, C., Hajian, S., Megahed, M., & Baeza-Yates, R. (2017, November). Fa* ir: A fair top-k ranking algorithm. In *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management* (pp. 1569-1578).
- [16] Yang, K., & Stoyanovich, J. (2017, June). Measuring fairness in ranked outputs. In *Proceedings of the 29th international conference on scientific and statistical database management* (pp. 1-6).
- [17] Zehlike, M., Yang, K., & Stoyanovich, J. (2021). Fairness in ranking: A survey. *arXiv preprint arXiv:2103.14000*.
- [18] Storn, R., Price, K. Differential Evolution – A Simple and Efficient Heuristic for global Optimization over Continuous Spaces. *Journal of Global Optimization* 11, 341–359 (1997).
- [19] Das, Swagatam & Suganthan, Ponnuthurai. (2011). Differential Evolution: A Survey of the State-of-the-Art.. *IEEE Trans. Evolutionary Computation*. 15. 4-31.
- [20] Scipy.Optimize.Differential_Evolution. Acesso em: 24 maio 2022. Disponível em: https://docs.scipy.org/doc/scipy/reference/generated/scipy.optimize.differential_evolution.html.
- [21] DataBank - World Development Indicators. The World Bank. Acesso em: 4 jul. 2022, em: <https://databank.worldbank.org/source/world-development-indicators>
- [22] Tavares, M. D. C. (2018). Celso furtado e o Brasil.