

## Matriz Origem Destino para a Modelagem do Problema de Transporte rodoferroviário da soja no Estado de Goiás

Lucas Gabriel de Godoi Arriel<sup>1</sup>  
 Eliel Lucas de Oliveira Silva<sup>2</sup>  
 Jucelina Leandro Borges<sup>3</sup>  
 Maria José Pereira Dantas<sup>4</sup>  
 PUC Goiás, Goiânia, GO

O aprendizado de máquina pode apoiar processos de tomadas de decisão em muitas áreas [1]. Nikolas Servos (2020) [2] e Yued Ding (2021) [3] trazem, particularmente, diferentes modelos de Aprendizado de Máquina para otimizar o transporte de cargas, e na geração de matrizes de origem e destino (OD) [4]. Assim como Hyunmyung Kim (2001) [5] mostra diferentes aplicações com o uso de Algoritmos Genéticos.

Tendo uma vasta quantidade de trabalhos associando matrizes origem destino [4], é evidente que uma matriz origem destino (OD) pode contribuir significativamente para a solução de problemas que envolvem transporte de cargas [4]. Uma matriz OD pode ser obtida através da solução do seguinte modelo, para  $N$  origens,  $M$  destinos e  $P$  pontos de transbordos para os modais:

$$\text{Minimizar } Z = \sum_{i=1}^N \sum_{j=1}^M C_{ij} T_{ij} + \sum_{i=1}^N \sum_{k=1}^P C_{ik} T_{ik} + \sum_{k=1}^P \sum_{j=1}^M C_{kj} T_{kj} \quad (1)$$

Sujeito a:

$$\sum_{j=1}^M T_{ij} + \sum_{k=1}^P T_{ik} \leq o_i, \forall i > 0 \quad (2)$$

$$\sum_{i=1}^N T_{ij} + \sum_{k=1}^P T_{kj} \leq d_j, \forall j > 0 \quad (3)$$

$$\sum_{i=1}^N T_{ik} = \sum_{j=1}^M T_{kj}, \forall k > 0 \quad (4)$$

Parâmetros do modelo:

$C_{ij}$ : Custo total do transporte entre a origem  $i$  e o destino  $j$ .

$C_{ik}$ : Custo total do transporte entre a origem  $i$  e o ponto de transbordo  $k$ .

$C_{kj}$ : Custo total do transporte entre o ponto de transbordo  $k$  e o destino  $j$ .

$o_i$ : Oferta da origem  $i$ .

$d_j$ : Demanda do destino  $j$ .

Variáveis:

---

<sup>1</sup>lucasgabrielgarriel@hotmail.com

<sup>2</sup>eliel.lucas3000@gmail.com

<sup>3</sup>juceleandro@bol.com.br

<sup>4</sup>mjpgdantas@gmail.com

$T_{ij}$ : Quantidade transportada entre a origem  $i$  e o destino  $j$ .

$T_{ik}$ : Quantidade transportada entre a origem  $i$  e o ponto de transbordo  $k$ .

$T_{kj}$ : Quantidade transportada entre o ponto de transbordo  $k$  e o destino  $j$ .

O transporte de cargas pode gerar um grande custo de combustível e uma emissão elevada de CO<sub>2</sub>, porém o uso de rotas intermodais traz uma grande economia por parte dos gastos de uma empresa [4] e da emissão dos gases nocivos ao meio ambiente e ao ser humano [6]. Fluxos gerados por matrizes OD podem auxiliar no momento de predizer as melhores rotas para o uso do transporte e quais modais seguir [4].

O objetivo principal dessa pesquisa é gerar soluções para o problema do transporte rodoferroviário, uma vez que é possível encontrar dados atualizados do transporte rodoviário e ferroviário. Atualmente estão sendo implementados métodos para solução do problema, além da definição de instâncias usando mapas gerados no QGIS e dados públicos da Companhia Nacional de Abastecimento (CONAB), Agência Nacional de Transportes Terrestres (ANTT) e do Instituto Brasileiro de Geografia e Estatística (IBGE).

Tomando como base o projeto proposto para a região MATOPIBA por [4], a matriz OD gerada neste trabalho contempla a parte do transporte da soja no estado de Goiás feito pelos modais que serão abordados. Foram gerados mapas para estabelecer certos trechos de rodovias e ferrovias onde a soja é transportada, os quais estão sendo usados de forma a conseguir dados para matriz OD.

## Agradecimentos

Agradecimento ao CNPQ pela bolsa PIBIC.

## Referências

- [1] Shiliang Sun, Zehui Cao, Han Zhu e Jing Zhao. “A Survey of Optimization Methods From a Machine Learning Perspective”. Em: **IEEE Transactions on Cybernetics** 50.8 (ago. de 2020). Conference Name: IEEE Transactions on Cybernetics, pp. 3668–3681. ISSN: 2168-2275. DOI: 10.1109/TCYB.2019.2950779.
- [2] Nikolaos Servos, Xiaodi Liu, Michael Teucke e Michael Freitag. “Travel Time Prediction in a Multimodal Freight Transport Relation Using Machine Learning Algorithms”. en. Em: **Logistics** 4.1 (mar. de 2020), p. 1. ISSN: 2305-6290. DOI: 10.3390/logistics4010001.
- [3] Yue Ding e Xiaokun (Cara) Wang. **Multi-Dimensional Origin-Destination Freight Flow Prediction Via a Hybrid Multi-Graph Convolutional Neural Networks Based Model**. en. SSRN Scholarly Paper. Rochester, NY, set. de 2022. DOI: 10.2139/ssrn.4211064.
- [4] Andréa Leda Ramos de Oliveira, Monique Filassi, Bruna Fernanda Ribeiro Lopes e Karina Braga Marsola. “Logistical transportation routes optimization for Brazilian soybean: an application of the origin-destination matrix”. en. Em: **Ciência Rural** 51 (dez. de 2020). Publisher: Universidade Federal de Santa Maria. ISSN: 0103-8478, 1678-4596. DOI: 10.1590/0103-8478cr20190786.
- [5] Hyunmyung Kim, Seungkirl Baek e Yongtaek Lim. “Origin-Destination Matrices Estimated with a Genetic Algorithm from Link Traffic Counts”. en. Em: **Transportation Research Record** 1771.1 (jan. de 2001). Publisher: SAGE Publications Inc, pp. 156–163. ISSN: 0361-1981. DOI: 10.3141/1771-20.
- [6] Thiago Guilherme Pera. “Efeitos das mudanças tecnológicas e infraestruturais do transporte para o fomento da logística verde da soja brasileira: abordagens multiobjetivos”. pt-br. text. Universidade de São Paulo, fev. de 2022. DOI: 10.11606/T.11.2022.tde-08042022-162357.