



USO DE INTELIGÊNCIA ARTIFICIAL NA MODELAGEM DE OTIMIZAÇÃO DE ROTAS¹

USE OF ARTIFICIAL INTELLIGENCE IN ROUTE OPTIMIZATION MODELING

Ana Beatriz Carvalho Santos | ana.santos302@fatec.sp.gov.br | FATEC SJC

Diego Marabini | diego.marabini@fatec.sp.gov.br | FATEC SJC

Luiz Henrique Tozi | luiz.tozi2@fatec.sp.gov.br | FATEC SJC

Isabelle Cristine Gomes | Isabelle.silva17@fatec.sp.gov.br | FATEC SJC

Mariana de Cassia Oliveira | mariana.silva170@fatec.sp.gov.br | FATEC SJC

Marcus Vinicius do Nascimento | nascimento.mv@fatec.sp.gov.br | FATEC SJC

RESUMO

A capacidade de análise complexa permite a criação de rotas dinâmicas que se adaptam aos imprevistos, minimizam custos operacionais de combustível e manutenção. O presente artigo tem como objetivo realizar uma análise de dados de distribuição de uma empresa embarcadora de cargas que opera no estado de São Paulo/Brasil, buscando otimizar esse processo com o foco na redução dos custos operacionais. Para isso, foram utilizadas ferramentas tecnológicas que possibilitam uma análise detalhada, integrando inteligência artificial como suporte na interpretação dos dados, além da aplicação de conceitos logísticos para orientar soluções eficientes na tomada de decisão. O artigo apresenta uma aplicação de otimização pelo método de transportes. Os resultados demonstram que aplicação do método permitiu uma redução de custo na ordem de 24%.

Palavras-chave: Otimização. Análise de Dados. Inteligência Artificial.

ABSTRACT

The complex analysis capability allows the creation of dynamic routes that adapt to unexpected events, minimizing fuel and maintenance operating costs. This article aims to analyze distribution data from a freight forwarding company operating in the state of São Paulo/Brazil, seeking to optimize this process with a focus on reducing operating costs. To this end, technological tools were used that enable detailed analysis, integrating artificial intelligence to support data interpretation, in addition to the application of logistics concepts to guide efficient solutions in decision-making. The article presents an application of optimization using the transport method. The results demonstrate that the application of the method allowed a cost reduction of around 24%.

Keywords: Optimization. Data Analysis. Artificial Intelligence.

1 INTRODUÇÃO

A logística exerce um papel fundamental no gerenciamento eficiente de cadeias de suprimentos e distribuição de produtos, influenciando diretamente a competitividade das organizações. A otimização dos processos logísticos não só minimiza custos, mas também melhora a qualidade dos serviços prestados e a satisfação dos clientes (Moura *et al.*, 2024).

A gestão de rotas, controle de estoques e distribuição é uma tarefa complexa, principalmente quando se lida com diversos centros de produção e uma grande base de clientes espalhados geograficamente (Bowersox *et al.*, 2014; Chopra; Meindl, 2016; Sousa *et al.*, 2024).

Neste contexto, este artigo tem como objetivo a análise e otimização dos custos logísticos de uma empresa embarcadora de cargas, que possui três fábricas no estado de São Paulo e realiza a distribuição de mercadorias para 51 clientes localizados dentro do mesmo estado. A empresa busca uma solução para reduzir custos de transporte, considerando variáveis como distância, capacidade de transporte, características das demandas de cada cliente e os custos de distribuição por rota (Novaes, 2007).

A solução proposta neste trabalho envolve a aplicação de técnicas de otimização de programação linear, aliadas a ferramentas tecnológicas modernas, para modelar e resolver o problema de distribuição da empresa, com o objetivo de atingir o menor custo total possível na operação logística (Hillier; Lieberman, 2021).

Nesse sentido, este artigo busca analisar os dados na coleta e organização dos dados de distâncias, capacidades de transporte, e demanda de cada cliente, utilizando *MongoDB* como banco de dados.

O tratamento e preparação dos dados utilizou linguagem Python para realizar a limpeza, transformação e análise dos dados brutos, garantindo que eles estejam prontos para a modelagem de otimização. A visualização e análise dos resultados utilizou Power BI para apresentar visualizações interativas dos dados e resultados obtidos com a otimização, facilitando a análise e a tomada de decisões.

Finalmente um desenvolvimento da modelagem de programação linear possibilitou implementar um modelo de otimização usando programação linear para minimizar o custo total de transporte, considerando as variáveis e restrições operacionais da empresa.

2 REFERENCIAL TEÓRICO

Nesta etapa da pesquisa foi apresentada a base teórica utilizada para o desenvolvimento do projeto, incluindo sua contextualização e as tecnologias empregadas na análise, tratamento e visualização de dados.

2.1 MODELOS DE DISTRIBUIÇÃO E ROTAS

Os modelos de distribuição desempenham um papel essencial na logística, sendo classificados em um-para-um, um-para-muitos e muitos-para-muitos. A Figura 1 ilustra modelo de distribuição classificado em um-para-um, ou do fornecedor para o centro de distribuição (CD).

Figura 1 | Modelo um-para-um



Fonte: Adaptado de Novaes (2007).

O modelo um-para-um, foco deste estudo, caracteriza-se pela ligação direta entre um ponto de origem e um ponto de destino, destacando-se em operações que exigem precisão e personalização, como transporte de itens sensíveis ou de alto valor (Ballou, 2006).

A Figura 2 ilustra modelo de distribuição classificado em um-para-muitos, ou seja do centro de distribuição (CD) para várias lojas.

Figura 2 | Modelo um-para-muitos




Fonte: Adaptado de Novaes (2007).

Em contrapartida, os modelos um-para-muitos e muitos-para-muitos são voltados para sistemas mais amplos e complexos, onde múltiplos pontos de conexão são necessários (Chopra; Meindl, 2016).

A Figura 3 ilustra modelo de distribuição classificado em muitos-para-muitos, ou seja, vários centros de distribuição (CD) para várias lojas.

Figura 3 | Modelo muitos-para-muitos



Fonte: Adaptado de Novaes (2007).

O desenvolvimento de ferramentas de tecnologia da informação se tornou um elemento fundamental para gestão de rotas. Essas ferramentas permitem maior precisão na definição de rotas, análise de dados em tempo real e monitoramento contínuo, contribuindo para a redução de custos e aumento da eficiência operacional (Simchi-Levi; Kaminsky, 2008).

A integração de ferramentas modernas oferece uma abordagem ágil e adaptável, capazes de atender às exigências de específicas de mercados dinâmicos e consumidores que demandam personalização e confiabilidade.

2.2 OTIMIZAÇÃO POR PROGRAMAÇÃO LINEAR

A programação linear é uma área da pesquisa operacional e da matemática aplicada voltada para a solução de problemas de otimização que visam maximizar ou minimizar uma função linear, sujeita a restrições também lineares. Seu desenvolvimento é atribuído a George B. Dantzig, que, em 1947, introduziu o método simplex, uma técnica algorítmica ainda amplamente utilizada para resolver esses problemas (Bertsimas; Tsitsiklis, 1997).

Segundo Bazaraa, Jarvis e Sherali (2010), a vantagem da programação linear está em sua capacidade de abordar problemas complexos de forma estruturada e eficiente, fornecendo soluções otimizadas em tempo razoável. Desde sua criação, tem sido aplicada em setores como logística, finanças, saúde e planejamento de recursos, desempenhando um papel crítico em áreas que exigem alocação eficiente de recursos. Em complemento, avanços recentes em softwares e algoritmos têm expandido significativamente a capacidade de resolver problemas maiores e mais complexos.

Neste projeto, a programação linear é aplicada para otimizar os custos de transporte de uma empresa embarcadora de cargas, que possui três fábricas e cinquenta e um clientes no estado de São Paulo/Brasil. Considerando restrições de capacidade de produção nas fábricas e demandas específicas dos clientes, o modelo busca minimizar os custos logísticos atuais, promovendo maior eficiência no processo e alinhando-se às melhores práticas do mercado.

3 METODOLOGIA

Com uma base de dados fornecida em formato CSV (*comma-separated values*), foi utilizada a linguagem Python para o tratamento dos dados, que, posteriormente, foram armazenados no sistema de gerenciamento de banco de dados MongoDB.

Lutz (2013) define a linguagem Python como altamente produtiva, com suporte extensivo para integração e automação, tornando-a uma escolha natural para a resolução de problemas de desenvolvimento. Por sua vez, Banker (2011) caracteriza o MongoDB como uma solução que preenche a lacuna entre a simplicidade dos bancos de dados não relacionais e a robustez exigida por aplicações corporativas, fornecendo uma abordagem eficiente para o gerenciamento de grandes volumes de dados.

A linguagem Python foi aplicada por meio da biblioteca “PuLP”, desenvolvida para modelar problemas de maneira simples e flexível e resolver questões de programação linear.

Beazley e Jones (2013) destacam a abundância de bibliotecas que a linguagem Python oferece, permitindo a resolução de problemas complexos com eficácia. Para a visualização dos dados originais e otimizados, foi utilizado o Power BI, uma ferramenta de Business Intelligence desenvolvida pela Microsoft para a criação de relatórios interativos e dashboards visuais.

Collie e Singh (2016) definem o Power BI como uma ferramenta revolucionária para a análise de dados, capacitando usuários não técnicos a criar análises complexas de forma simples e intuitiva.

3.1 COMPOSIÇÃO E TRATAMENTO DOS DADOS

Conforme mencionado anteriormente, os dados foram fornecidos no formato .CSV, organizados em três arquivos distintos:

- i. “Fabrica.csv”: Este arquivo apresenta a lista das três fábricas, incluindo seus códigos e localizações, especificadas por latitude e longitude.
- ii. “Clientes.csv”: Similar ao arquivo anterior, este contém informações sobre os 51 clientes, listando seus códigos e localizações com latitude e longitude.
- iii. “Rotas.csv”: Contém dados operacionais referentes ao ano de 2021, incluindo os códigos de fábricas e clientes para correlação. Cada linha representa uma operação, com informações relevantes como volumetria, peso, distância percorrida e custo da operação.

Os dados foram correlacionados por meio dos códigos de clientes e fábricas, facilitando a compreensão da origem e destino das operações de distribuição. Esse processo foi realizado utilizando a linguagem Python e a biblioteca Pandas, que permite acessar e manipular dados em arquivos nos formatos .csv e .xlsx de maneira simples e intuitiva.

Após a integração entre os arquivos, os dados foram armazenados no MongoDB, na database “Dados” e na collection “Dados Iniciais”.


Cada rota operacional foi organizada como um document, contendo todas as informações necessárias para dar início à análise dos dados. Vale destacar que o MongoDB oferece fácil exportação de dados nos formatos .csv e .json, além de permitir integração eficiente com a linguagem Python.

3.2 PAINEL DE VISUALIZAÇÃO

Após o tratamento e o armazenamento dos dados no banco de dados, foi gerado um relatório que foi posteriormente importado para o Power BI. O objetivo desse processo foi compreender o funcionamento atual da operação.

No primeiro painel desenvolvido (Figura 4), foi realizada uma análise de uma das restrições que seriam utilizadas posteriormente na otimização: a capacidade de produção de cada fábrica. Com os dados de rotas, que incluem as quantidades originadas em cada fábrica, foram elaborados gráficos para avaliar a eficiência de produção e distribuição de cada unidade.

Figura 4 | Produtividade mensal das fábricas



Fonte: Elaborado pelos Autores (2024).

3.3 MODELO DE OTIMIZAÇÃO

Após o tratamento e a construção do visualizador de dados, a análise de otimização foi realizada com base em modelo de Programação Linear em código Python.

A Figura 5 ilustra o início da estruturação do código, realizando a importação das bibliotecas necessárias para a realização da otimização. Foram utilizadas as bibliotecas Pulp (otimização) e Pandas (manipulação de dados).

Figura 5 | Bibliotecas da linguagem de programação

```
from pulp import *  
import pandas as pd
```

Fonte: Elaborado pelos Autores (2024).

Em seguida, o problema de otimização linear foi definido utilizando o comando `LpProblem`, configurando o objetivo de minimizar os custos de transporte. Além da definição do problema de minimização, foram criadas as variáveis de decisão, que representaram os pares de rotas (fábrica-cliente).

A estrutura dessas variáveis (Figura 6) foi definida por um código composto por dois ou três dígitos, onde o primeiro indicava a fábrica (1, 2 ou 3) e o segundo representava o cliente (1 a 51), totalizando 153 combinações de rotas possíveis.

Figura 6 | Definição das variáveis de controle

```
x11 = LpVariable('x11', lowBound = 0)  
x12 = LpVariable('x12', lowBound = 0)  
x13 = LpVariable('x13', lowBound = 0)  
x14 = LpVariable('x14', lowBound = 0)  
x15 = LpVariable('x15', lowBound = 0)  
x16 = LpVariable('x16', lowBound = 0)  
x17 = LpVariable('x17', lowBound = 0)  
x18 = LpVariable('x18', lowBound = 0)  
x19 = LpVariable('x19', lowBound = 0)  
x110 = LpVariable('x110', lowBound = 0)
```

Fonte: Elaborado pelos Autores (2024).

A próxima etapa da programação consistiu na definição da função objetivo da otimização utilizando o atributo += do objeto LpProblem. Após isso, foram estabelecidas as restrições do problema, começando pela capacidade de produção das fábricas, onde se atribuiu o limite máximo de unidades para cada ponto de origem. Em seguida, foram incluídas as restrições baseadas nas demandas de cada cliente conforme ilustrada na Figura 7.

Figura 7 | Atribuindo regras de restrições

```
transp += x11 + x21 + x31 == 7919100
transp += x12 + x22 + x32 == 6934500
transp += x13 + x23 + x33 == 5768400
transp += x14 + x24 + x34 == 2590200
transp += x15 + x25 + x35 == 6579300
transp += x16 + x26 + x36 == 3157200
transp += x17 + x27 + x37 == 6193500
transp += x18 + x28 + x38 == 4688700
```

Fonte: Elaborado pelos Autores (2024).

Com as variáveis, a função objetivo e as restrições devidamente definidas, aplicou-se o método “.solve()” da biblioteca Pulp. Esse comando roda o algoritmo SIMPLEX para a busca de solução ótima do problema.

Para visualizar os resultados obtidos, foi utilizado o comando print para exibir as quantidades a serem transportadas em cada rota representada pelas variáveis (Figura 8).

Figura 8 | Resultados obtidos

```
for v in transp.variables(): print (v.name, '=', v.varValue)

x146 = 0.0
x147 = 4940400.0
x148 = 3808200.0
x149 = 5117400.0
x15 = 6579300.0
x150 = 4259100.0
x151 = 5162400.0
x16 = 0.0
x17 = 6193500.0
x18 = 3133900.0
x19 = 7296600.0
x21 = 7919100.0
x210 = 4181400.0
```

Fonte: Elaborado pelos Autores (2024).

3.4 INTEGRAÇÃO COM INTELIGÊNCIA ARTIFICIAL

Após a etapa de otimização, foi realizada a integração de um sistema de inteligência artificial por meio da API da OpenAI, amplamente conhecida como ChatGPT, uma das pioneiras no atual e expressivo crescimento das aplicações de Inteligência Artificial.

Essa integração viabilizou o acesso à base de dados do projeto, possibilitando interpretar os dados ampliando as perspectivas analíticas por meio de respostas dinâmicas e contextuais, contribuindo significativamente para a profundidade das análises realizadas.

O protótipo do *Chatbot* foi desenvolvido a partir da interface do ChatGPT, utilizando Python como linguagem de programação para a estruturação da ferramenta, e a biblioteca Flask para a criação da interface em HTML.

A consulta de dados é realizada por meio do acesso à base de dados armazenada no MongoDB, a qual está integrada às demais ferramentas do projeto, garantindo a continuidade e a consistência das informações entre os diferentes componentes.

4 RESULTADOS E DISCUSSÕES


Os resultados da otimização realizada no modelo de distribuição, bem como a análise dos impactos gerados pelas mudanças implementadas. O resultado obtido reflete a eficiência da abordagem aplicada e a eficácia das ferramentas utilizadas.

A otimização aplicada ao modelo de distribuição resultou em uma redução significativa no valor total do frete. O valor inicial dos custos era de R\$ 59.941.259,06, e após a otimização, os custos finais passaram para R\$ 45.596.291,91.

Esse resultado demonstra uma melhoria substancial na eficiência da operação logística, evidenciando a efetividade da solução adotada.

Como ilustrado na Figura 9, os custos totais de transporte foram reduzidos em 23,93%, representando uma diminuição de R\$ 14.334.967,15 nos gastos relacionados ao transporte.

Figura 9 | Resultados alcançados com a otimização



Fonte: Elaborado pelos Autores (2024).

A análise dos resultados sugere que a aplicação de ferramentas tecnológicas para otimização de rotas e distribuição não apenas atingiu a meta de redução de custos, mas também permitiu a identificação de pontos críticos (gargalos) na operação que, antes da análise, não eram claramente visíveis (Silva *et al.*, 2024).

O uso de modelos avançados de otimização e a integração com plataformas de monitoramento de desempenho foram cruciais para a detecção dessas ineficiências, permitindo ajustes precisos no processo logístico.

A redução de custos, em termos absolutos, é um indicativo de que a solução aplicada foi bem-sucedida, não apenas no aspecto financeiro, mas também no aprimoramento da capacidade operacional da empresa. Além disso, a solução tecnológica proporcionou uma visão mais detalhada e em tempo real das operações, permitindo um maior controle e flexibilidade para a gestão logística.

5 CONSIDERAÇÕES FINAIS

O projeto atingiu seu objetivo de entregar uma solução de otimização, integrada a ferramentas tecnológicas, especialmente com a inteligência artificial complementando a experiência e interatividade do usuário.

Este trabalho utilizou uma combinação de ferramentas tecnológicas para otimizar os custos logísticos e melhorar a gestão operacional. A base de dados foi tratada e armazenada no MongoDB com a ajuda da linguagem Python, enquanto a visualização foi feita no Power BI para análise interativa.

A otimização do transporte foi realizada por meio de programação linear, utilizando a biblioteca PuLP, considerando restrições de capacidade e demanda. Além disso, a integração com inteligência artificial, através da API do ChatGPT, proporcionou uma nova interface de consulta aos dados, ampliando as possibilidades analíticas e promovendo uma gestão mais eficiente e informada das operações logísticas.

A otimização do modelo de distribuição resultou em uma redução significativa dos custos de transporte, com uma diminuição de 23,93%, o que corresponde a R\$ 14.334.967,15, passando de R\$ 59.941.259,06 para R\$ 45.596.291,91.

A aplicação de ferramentas tecnológicas possibilitou a identificação de gargalos operacionais, além de aprimorar a eficiência logística da empresa.

A integração dessas soluções não apenas reduziu custos, mas também proporcionou maior controle e flexibilidade na gestão das operações.

Esses resultados reforçam a importância da adoção de tecnologias de otimização para alcançar melhorias operacionais e estratégicas substanciais.

REFERÊNCIAS

- BALLOU, R. H. Gerenciamento da cadeia de suprimentos/ Logística empresarial. 5. ed. Porto Alegre: Bookman, 2006.
- BANKER, K. (2011). MongoDB in Action. Manning Publications. ISBN: 9781935182870.
- BAZARAA, M. S., JARVIS, J. J., & SHERALI, H. D. (2010). Linear Programming and Network Flows (4ª ed.). John Wiley & Sons.
- BEAZLEY, D., & JONES, B. K. (2013). Python Cookbook: Recipes for Mastering Python 3 (3ª ed.). O'Reilly Media.
- BERTSIMAS, D.; TSITSIKLIS, J. N. Introduction to Linear Optimization. Athena Scientific, Belmont, 1997.
- BOWERSOX, Donald J.; CLOSS, David J.; BOWERSOX, John C. Gestão Logística da Cadeia de Suprimentos. 4. Ed. Porto Alegre: AMGH, 2014.
- CHOPRA, S.; MEINDL, P. Gestão da cadeia de suprimentos. 6. ed. São Paulo: Pearson, 2016.
- COLLIE, R., & SINGH, A. (2016). Power Pivot and Power BI: The Excel User's Guide to DAX, Power Query, Power BI & Power Pivot in Excel 2010-2016. Holy Macro! Books.
- HILLIER, F.; LIEBERMAN, G. J. Introduction to operations research. 9. ed. New York: McGraw-Hill, 2021.
- LUTZ, M. (2013). Learning Python (5ª ed.). O'Reilly Média.
- MARABINI, Diego. Ferramenta de BI Integrada a Banco de Dados em SQL para Análise de Custos de Frete. *In: Science & Business Connection*, nº2, 2024, São José dos Campos. Resumos. São José dos Campos.
- MOURA, RA DE, SANTOS, DFA, GOUSSAIN, BGS, OLIVEIRA, MR DE, & SILVA, MB (2024). Projeto de Experimentos (DoE) para não especialistas em estatística na indústria alimentícia: ensaios com pipoca. *Revista De Gestão Social e Ambiental*, 18 (10), e09308. <https://doi.org/10.24857/rgsa.v18n10-229>
- MOURA, R., MARQUES, D., COSTA, J., & SILVA, M. (2021). A urbanidade da higiene ocupacional na era digital e o negacionismo social da antecipação e prevenção. 2021. *Revista Sodebras [on-line]*, 16(184), 29-33. ISSN 1809-3957. DOI: <https://doi.org/10.29367/issn.1809-3957.16.2021.184.29>
- NOVAES, A. G. Logística e gerenciamento da cadeia de distribuição: estratégia, operação e avaliação. 3. ed. Rio de Janeiro: Elsevier, 2007
- SILVA, E. A.; CAMARGO, A. A.; SILVA, M. B.; MOURA, R. A. (2024). Neuroergonomía y Tecnologías inmersivas para lograr un envejecimiento saludable sin dolor y además sin ortesis. *Revista Ciências Exatas*. V.30. N 2, 2024. Taubaté/SP/Brasil. ISSN: 1516-2893. Unitau. DOI: <https://doi.org/10.69609/1516-2893.2024.v30.n2.a3916>
- SIMCHI-LEVI, D., KAMINSKY, P., & SIMCHI-LEVI, E. (2008). Designing and Managing the Supply Chain: Concepts, Strategies, and Case Studies (3ª ed.). McGraw-Hill Irwin.
- SOUSA, V. J. DE RICHETTO, M. R. S., MOURA, R. A. DE, OLIVEIRA, M. R. DE, & SILVA, M. B. (2024). Analysis of management practices in a non-governmental organization. *Revista De Gestão Social E Ambiental*, 18(11), e09646. <https://doi.org/10.24857/rgsa.v18n11-045>