

Implementação da DEA com AHP Gaussiano e Correção de Pearson para Avaliação de Eficiência em uma rede de restaurantes

Levy Galas Jacob

Universidade de Fortaleza

Av. Washington Soares, 1321, 60.811-905, Fortaleza - CE - Brasil

levygalasjacob@gmail.com

Plácido Rogério Pinheiro

Universidade de Fortaleza

Av. Washington Soares, 1321, 60.811-905, Fortaleza - CE - Brasil

placido@unifor.br

João Batista Furlan Duarte

Universidade de Fortaleza

Av. Washington Soares, 1321, 60.811-905, Fortaleza - CE - Brasil

furlan@unifor.br

RESUMO

Este trabalho propõe uma abordagem híbrida para avaliar a eficiência operacional em uma rede de restaurantes, combinando Análise Envoltória de Dados (DEA), Processo Analítico Hierárquico Gaussiano (AHP Gaussiano) e ajuste dos pesos com correção de Pearson. Os inputs considerados foram custos de produtos e volume de vendas; o output considerado foi o lucro bruto. O AHP Gaussiano foi utilizado para atribuir pesos aos critérios, refletindo a distribuição estatística dos dados, com posterior ajuste via correlação de Pearson para maior alinhamento com as relações empíricas. O modelo proposto (DEA-AHP/GS) foi implementado em Python. A abordagem permitiu identificar discrepâncias de eficiência entre unidades, apontando oportunidades de melhoria e subsidiando a tomada de decisões. Os achados reforçam o potencial das metodologias híbridas para benchmarking interno e aprimoramento da eficiência operacional em organizações complexas.

PALAVRAS CHAVE. DEA, AHP Gaussiano, Correlação de Pearson.

Métodos Multicritério para ajuda de Tomada de Decisão (ADM); Análise e Ciência de Dados (AS&DS); DEA; PO e IA.

ABSTRACT

This work proposes a hybrid approach to evaluate operational efficiency in a restaurant chain by combining Data Envelopment Analysis (DEA), Gaussian Analytic Hierarchy Process (Gaussian AHP), and weight adjustment using Pearson correlation. The inputs considered were product costs and sales volume; the output was gross profit. Gaussian AHP was applied to assign weights to the criteria, reflecting the statistical distribution of the data, followed by an adjustment using Pearson correlation to ensure better alignment with empirical relationships. The proposed model (DEA-AHP/GS) was implemented in Python. This approach enabled the identification of efficiency discrepancies among units, highlighting improvement opportunities and supporting decision-making. The findings reinforce the potential of hybrid methodologies for internal benchmarking and enhancing operational efficiency in complex organizations.

KEYWORDS. DEA, Gaussian AHP, Pearson correlation,

Multicriteria Decision-Making Methods (ADM), Analytics and Data Science (AS&DS), Data Envelopment Analysis (DEA), OR and AI.

1. Introdução

O setor de varejo alimentar demanda, cada vez mais, soluções orientadas por dados para otimizar processos e sustentar a eficiência operacional. O mercado de restaurantes projeta um crescimento a uma taxa composta anual (CAGR) de 1,9% entre 2024 e 2031 [Dharmadhikari 2025]. O cenário socioeconômico global impõe desafios significativos aos negócios, dificultando o controle de custos e a manutenção de margens competitivas em um mercado dinâmico e em constante transformação.

Muitos restaurantes têm adotado técnicas de melhoria de processos e inovações tecnológicas para otimizar suas operações diante dessas pressões. Ferramentas tecnológicas, como sistemas avançados de gestão e análise de dados, têm desempenhado papel crucial na melhoria da eficiência operacional e na redução de custos, conforme apontado por [Nadai 2019]. No entanto, a adoção dessas tecnologias permanece desigual no setor: grandes redes e empresas bem estruturadas conseguem incorporá-las com sucesso, enquanto estabelecimentos menores enfrentam barreiras financeiras, técnicas e culturais [Lima et al 2007], dificultando a implementação de mudanças técnicas significativas no contexto da pesquisa operacional e otimização. Estudos recentes destacam que essa disparidade persiste, especialmente em mercados emergentes [Nadai 2019][Lima et al 2007], ressaltando a necessidade de soluções escaláveis que integrem rigor técnico com aplicabilidade prática.

Nesse contexto, os métodos de apoio à decisão multicritério se apresentam como ferramentas valiosas. A Análise Envoltória de Dados (DEA) destaca-se como uma metodologia robusta para tomada de decisão e benchmarking com base na eficiência operacional, permitindo a comparação de desempenho relativo entre unidades decisórias (DMUs) [Cooper et al. 2007]. Embora a DEA seja amplamente estabelecida, sua integração com o Processo Analítico Hierárquico Gaussiano (AHP Gaussiano) — que substitui comparações pareadas por estimativas estatísticas de pesos [Dos Santos et al. 2021] — e com a correção de Pearson (para mitigar a sensibilidade a outliers [Okwonu et al. 2020]) ainda é inexplorada. Essa lacuna motiva a pergunta de pesquisa deste estudo:

“Como um framework híbrido DEA-AHP Gaussiano, ajustado por correlação de Pearson, pode aprimorar o benchmarking de eficiência em redes de restaurantes em comparação com métodos convencionais?”

Diante desse cenário, propõe-se:

- Aproveitar a robustez estatística do AHP Gaussiano para lidar com grandes volumes de dados ruidosos, típicos do varejo [Dos Santos, 2021];
- Aplicar a correção de Pearson para alinhar os pesos com os padrões empíricos dos dados, reduzindo correlações espúrias [Cohen et al. 2009];
- Oferecer uma solução escalável, adaptável tanto a grandes redes quanto a pequenos estabelecimentos.

Este artigo está estruturado da seguinte forma: a Seção 2 revisa os fundamentos da DEA; a Seção 3 apresenta o AHP Gaussiano; a Seção 4 detalha a correção de Pearson. A Seção 5 descreve o método híbrido, que é aplicado aos dados de restaurantes na Seção 6. As conclusões e limitações são discutidas na Seção 7. Ao integrar esses métodos, busca-se contribuir tanto com o debate acadêmico (por exemplo, conectando DEA e métodos estatísticos de apoio à decisão [Gomes et al., 106]) quanto com o benchmarking de eficiência no varejo alimentar.

2. DEA (Data Envelopment Analysis)

A Análise Envoltória de Dados (DEA) é um método não paramétrico que avalia a eficiência relativa de unidades tomadoras de decisão (DMUs) por meio de programação linear. Desenvolvida por Charnes, Cooper e Rhodes [Charnes et al. 1978], a DEA tornou-se um marco no benchmarking operacional, especialmente em setores de serviços como o varejo alimentar [Huguenin 2012]. Diferentemente de abordagens paramétricas, a DEA constrói uma fronteira empírica de eficiência com base nos dados observados, evitando suposições restritivas sobre formas funcionais [Cooper et al. 2007]. Essa flexibilidade a torna ideal para comparar DMUs heterogêneas - uma necessidade crítica em redes de restaurantes, onde as unidades frequentemente

operam sob condições distintas.

A DEA calcula a eficiência como a razão entre saídas ponderadas e entradas ponderadas [Gomes et al. 2021]. Dois modelos principais dominam as aplicações:

- **CRS (Retornos Constantes de Escala):** assume relações proporcionais entre insumos e produtos, sendo adequado para operações em escala ideal [Huguenin 2012].
- **VRS (Retornos Variáveis de Escala):** considera ineficiências de escala, sendo mais aplicável a cenários reais como o varejo alimentar, onde DMUs operam em escalas subótimas devido a restrições de mercado [Meza et al. 2005][Huguenin 2012].

Matematicamente, a DEA resolve para cada DMU o seguinte problema:

$$\max \theta_k = \frac{\sum_{r=1}^s u_r y_{rk}}{\sum_{i=1}^m v_i x_{ik}}$$

Sujeito a:

$$\frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{i=1}^m v_i x_{ij}} \leq 1 \quad \forall j, u_i, v_i \geq 0$$

Onde x_{ij} e y_{rj} representam os insumos e produtos, respectivamente, e u_r e v_i são os pesos atribuídos. As DMUs eficientes ($\theta = 1$) formam a fronteira de eficiência, enquanto $\theta < 1$ indica ineficiência [Meza et al. 2005].

Estratégias de Orientação [Huguenin 2012]

- **Orientação a insumos:** Minimiza o uso de recursos mantendo os níveis de produção. Essa abordagem é crítica para setores com alta sensibilidade a custos, como o varejo alimentar, onde a redução de desperdícios impacta diretamente as margens.
- **Orientação a produtos:** Maximiza os produtos gerados sem aumento nos insumos, sendo útil para a expansão da produção em redes já consolidadas.

Por que hibridizar DEA com AHP Gaussiano neste estudo?

Embora a DEA seja amplamente documentada, sua integração com o AHP Gaussiano e a correção de Pearson aborda duas limitações importantes nas aplicações ao varejo alimentar:

- **Subjetividade na alocação de pesos:** A DEA tradicional permite distribuições irreais de pesos [Dyson et al. 1988]; nosso método híbrido restringe os pesos com base em rigor estatístico (ver Seção 3).
- **Sensibilidade a outliers:** A correção de Pearson mitiga distorções causadas por dados anômalos (ver Seção 4), um problema conhecido em estudos de eficiência no setor de restaurantes [Okwonu et al. 2020].

3. AHP Gaussiano

O Processo Analítico Hierárquico (AHP) é um método consagrado de apoio à decisão multicritério que estrutura problemas de forma hierárquica por meio de comparações pareadas [Saaty 2008]. No entanto, sua dependência de julgamentos subjetivos o torna suscetível a viesescognitivos - um desafio documentado tanto na gestão de projetos de software [Almeida et al. 2011] quanto no design de experiência do usuário [Mendes et al. 2008] - e a inconsistências, especialmente em conjuntos de dados grandes, como os encontrados em análises de eficiência no varejo alimentar [Dos Santos, 2021].

O AHP Gaussiano supera essas limitações ao:

- Substituir as comparações pareadas por métricas estatísticas (desvio padrão, média);
- Incorporar a distribuição normal para tratar a incerteza dos dados [Rodrigues et al. 2025][Dos Santos, 2021];
- Adotar uma abordagem coevolutiva inspirada em pesquisas de IHC (Interação Humano-Computador), na qual refinamentos estatísticos iterativos substituem testes subjetivos com usuários [Mendes et al. 2008].

No AHP Gaussiano, os pesos são derivados objetivamente por meio do Fator Gaussiano:

$$\text{Fator Gaussiano} = \frac{\sigma_i}{\mu_i}$$

Onde:

- σ_i representa o desvio padrão do critério i
- μ_i representa a média do critério i

Etapas principais na hibridação com o DEA (para a obtenção dos pesos):

1. Calcular os fatores gaussianos para todos os critérios;
2. Normalizar os fatores para obter os pesos.

Vantagens para Benchmarking no Varejo Alimentar:

- Reduz a subjetividade ao eliminar comparações pareadas manuais [Dos Santos, 2021];
- Prioriza automaticamente métricas mais voláteis (ex: variação nas vendas), com base na ponderação gaussiana;
- Alinha-se à DEA ao fornecer uma ponderação estatisticamente robusta para análise de eficiência (ver Seção 5).

Aplicação:

No estudo de caso com a rede de restaurantes (Seção 6), o AHP Gaussiano atribuiu maior peso ao:

- Lucro bruto ($\sigma = \text{R\$ } 908.706,00$) em relação ao volume de vendas ($\sigma = \text{R\$ } 52.740$),
- Validação feita por meio da correção de Pearson para mitigar efeitos de outliers [Cohen et al. 2009].

4. Correlação de Pearson

O coeficiente de correlação produto-momento de Pearson, formalizado por Karl Pearson (1896) [Okwonu et al. 2020], quantifica relações lineares entre variáveis ($-1 \leq r \leq +1$), sendo que valores $|r| < 0,2$ indicam correlação negligenciável. Embora fundamental, este método enfrenta dois desafios críticos no contexto de benchmarking de eficiência:

Sensibilidade a Outliers:

- **Exemplo:** Um estudo sobre renda versus pressão arterial ($n = 120$) mostrou que o coeficiente r caiu de 0,88 para 0,7 após a adição de apenas um outlier [Okwonu et al. 2020].
- **Implicação para DEA:** Outliers em dados de restaurantes (ex: picos de vendas em feriados, notas fiscais alimentadas incorretamente no sistema) podem distorcer os rankings de eficiência caso não sejam tratados adequadamente.

Suposição de Linearidade:

- O método falha em capturar relações não lineares, comuns em métricas operacionais como a dinâmica custo-volume-lucro [Wu et al. 2024].

Neste trabalho, utiliza-se a correlação de Pearson como ferramenta de ajuste de pesos para detectar e atenuar relações espúrias entre inputs (ex: volume de vendas) e outputs (ex: lucro) [Cohen et al. 2009]; aprimorar os pesos do AHP Gaussiano por meio da multiplicação pelo valor médio global das correlações do critério (ver Seção 5):

$$w_i^{\text{corrected}} = w_i^{\text{Gaussian}} \cdot \overline{r_i}$$

Onde $\overline{r_i}$ é a média das correlações de Pearson do critério i com as demais variáveis.

Dado esse contexto, o coeficiente de Pearson pode ser utilizado como critério de otimização para o desenvolvimento de mecanismos de redução de ruído [Cohen et al. 2009] em diversas aplicações. O uso da técnica é documentado em sistemas de estabilização de imagem [Liu et al. 2019] e em algoritmos baseados em transformadores [Wu et al. 2024].

5. Modelo Proposto

O desenvolvimento do método híbrido multicritério proposto, que integra a Análise Envoltória de Dados (DEA) com o Processo Analítico Hierárquico Gaussiano (AHP Gaussiano) e a correção de Pearson, segue etapas similares ao DEA clássico, sendo a única modificação concentrada na etapa de cálculo dos pesos.

Para a definição dos pesos, incorpora-se uma análise estatística baseada na média, no desvio-padrão e no fator gaussiano, este último sendo normalizado para gerar os pesos conforme o AHP Gaussiano. Após a obtenção dos pesos, aplica-se a correção de Pearson, que consiste em multiplicar cada peso pelo valor médio global dos coeficientes de correlação entre os critérios de entrada (inputs) e saída (outputs).




Fig. 1. Etapas do DEA - AHP/GS

O método híbrido foi aplicado a um conjunto de dados de uma rede de restaurantes, abrangendo o período de agosto de 2023 a abril de 2024, em que cada unidade de negócio foi considerada como uma Unidade Tomadora de Decisão (DMU). As variáveis selecionadas como insumos foram o volume total de vendas e o custo total, enquanto a variável de saída considerada foi o Lucro Bruto de cada DMU.

Tabela 1. Resumo de dados do grupo de restaurantes

DMU	Inputs		Output
Restaurante	Quantidade Vendida	Custo Total (R\$)	Lucro Bruto (R\$)
RESTAURANTE A	233655	1673115.11	3241039.50
RESTAURANTE B	165480	1112546.22	1538799.72
RESTAURANTE C	137177	953469.73	1564098.94
RESTAURANTE D	111187	918028.02	1239982.62

Em seguida, foram calculados a média, o desvio padrão, o fator Gaussiano, o fator Gaussiano normalizado e o coeficiente de correlação de Pearson global. O fator Gaussiano normalizado foi então multiplicado pelo coeficiente de correlação de Pearson global para obtenção dos pesos finais.

Tabela 2. Calculo dos pesos detalhados (Etapa AHP Gaussiano)

Input/Output	Média	Desvio padrão	Fator Gaussiano	Fator Gaussiano normalizado	Correlação global de Pearson	Pesos
Quantidade Vendida	161874,75	52740,33552	0,32580952	0.679789	0.979546927	0.665885
Custo Total (R\$)	1164289,8	349604,8056	0,30027302	0.626508	0.979546927	0.613694
Lucro Bruto (R\$)	1895980,2	908706,1152	0,47928038	1.000000	0.979546927	0.979547

O procedimento padrão do DEA foi executado utilizando os pesos calculados, seguindo as etapas a seguir. As variáveis de entrada e saída foram normalizadas, e a pontuação de eficiência para cada DMU foi obtida por meio da divisão da soma ponderada das saídas normalizadas pela soma ponderada das entradas normalizadas. O método de normalização escolhido foi (Valor/valorMáximo), de forma a manter a proporcionalidade dos dados e preservar propriedades estatísticas como média, mediana e desvio padrão.

Tabela 3. Inputs and outputs normalizados

DMU	Inputs normalizados		Output normalizado
Restaurante	Quantidade Vendida	Custo Total (R\$)	Lucro Bruto (R\$)
RESTAURANTE A	1.000000	1.000000	1.000000
RESTAURANTE B	0.708224	0.664955	0.474786
RESTAURANTE C	0.587092	0.569877	0.482592
RESTAURANTE D	0.475860	0.548694	0.382588

Table 4. Inputs e outputs normalizados e pesados

DMU	Inputs normalized and weighted		Output normalized and weighted
Restaurante	Quantidade Vendida	Custo Total (R\$)	Lucro Bruto (R\$)
RESTAURANTE A	0.665885	0.613694	0.979547
RESTAURANTE B	0.472898	0.409206	0.466360
RESTAURANTE C	0.392016	0.350696	0.474027
RESTAURANTE D	0.317743	0.337660	0.375798

Table 5. DEA Gaussiano - Resultados detalhados

DMU	Inputs Normalizados e Pesados	Output Normalizados e Pesados	Eficiência	Eficiência Relativa	Ranking
RESTAURANTE A	1.283113	0.982252	0.765523	1	1
RESTAURANTE C	0.742712	0.474027	0.638238	0,833	2
RESTAURANTE D	0.655403	0.375798	0.573384	0,75	3
RESTAURANTE B	0.882104	0.466360	0.528690	0,69	4




Fig. 2. Fronteira de eficiência DEA Gaussiano

Após a conclusão dos procedimentos descritos, foi obtido um ranking de eficiência, na figura 2, de todos os restaurantes pertencentes ao grupo empresarial. Observa-se que o Restaurante B, último colocado no benchmark ficou mais distante da fronteira de eficiência.



Fig. 3. Link para o repositório DEA - AHP/GS no Github

No QR code disponibilizado na figura 3, é possível acessar o Github para mais detalhes, como base de dados e jupyter notebook com o método.

6. Análise dos resultados

A aplicação do método híbrido DEA-AHP Gaussiano com correção de Pearson às quatro unidades da rede de restaurantes permitiu identificar diferenças significativas nos níveis de eficiência operacional. A Tabela 5 apresenta os valores de eficiência, eficiência relativa e o ranking final das DMUs.

Inicialmente, os pesos dos critérios foram calculados com base no fator Gaussiano normalizado, ajustado pelo coeficiente de correlação de Pearson (Tabela 2). Esse processo reduziu a subjetividade típica da alocação de pesos na DEA tradicional, garantindo que variáveis mais correlacionadas ao desempenho global recebessem maior influência no modelo. Como resultado, a variável Lucro Bruto apresentou o maior peso (0,979547), seguida por Quantidade Vendida (0,665885) e Custo Total (0,613694).

Os resultados do modelo DEA Gaussiano (Tabela 5) revelam que o Restaurante A obteve a maior eficiência (0,765523), ocupando o primeiro lugar no ranking. Essa unidade apresentou simultaneamente altos valores ponderados de output (0,982252) e inputs compatíveis com sua produção, evidenciando uma gestão equilibrada entre custos e geração de receita.

O Restaurante C alcançou a segunda posição (eficiência 0,638238), beneficiando-se de um desempenho intermediário tanto em vendas quanto em lucro, mas com custos relativamente controlados. O Restaurante D apresentou eficiência de 0,573384, ocupando o terceiro lugar, limitado principalmente por seu menor output ponderado (0,375798). Por fim, o Restaurante B obteve a menor eficiência (0,528690), reflexo de um lucro bruto ponderado baixo (0,466360) em relação ao montante de recursos empregados.

A análise evidencia que, embora nenhuma unidade tenha atingido a fronteira de eficiência ($\theta = 1$), há diferenças relevantes na utilização dos recursos disponíveis. Além disso, observa-se que a hibridização DEA-AHP Gaussiano contribuiu para priorizar métricas economicamente mais significativas, como o lucro, mitigando vieses que poderiam ocorrer em um modelo DEA puro.

Esses achados oferecem subsídios gerenciais para a realocação de recursos e definição de estratégias de melhoria. Por exemplo, os restaurantes B e D poderiam adotar práticas de controle de custos e aumento de ticket médio para melhorar sua posição no ranking, enquanto o restaurante A pode servir de benchmark interno para eficiência operacional.

7. Conclusão

Este estudo propôs e implementou um método híbrido de apoio à decisão multicritério, combinando a Análise Envoltória de Dados (DEA), o Processo Analítico Hierárquico Gaussiano (AHP Gaussiano) e a correlação de Pearson. A metodologia seguiu a estrutura clássica do DEA, diferenciando-se na etapa de cálculo dos pesos, na qual foram incorporados os métodos

estatísticos do AHP Gaussiano. A correção de Pearson foi aplicada para ajustar os pesos de acordo com a correlação global entre os critérios de entrada e saída, assegurando maior robustez e alinhamento dos resultados com as relações observadas nos dados.

Quanto à pergunta de pesquisa: “Como um modelo híbrido DEA/AHP Gaussiano, ajustado via correlação de Pearson, pode aprimorar o benchmarking de eficiência em redes de restaurantes em comparação com métodos convencionais?”, os resultados indicam que o modelo proposto aprimora o benchmarking ao reduzir a subjetividade na atribuição de pesos, incorporar rigor estatístico na priorização de variáveis e tornar a fronteira de eficiência menos suscetível a distorções causadas por outliers ou fatores extremos. Em comparação ao DEA tradicional, a hibridização proposta se propõe a entregar resultados mais consistentes e alinhados com a estrutura estatística real dos dados, proporcionando um diagnóstico mais confiável para suporte à decisão.

O uso do AHP Gaussiano foi justificado pela necessidade de eliminar o viés de julgamentos subjetivos presentes no AHP clássico e em parte das aplicações de DEA, substituindo pesos obtidos por programação linear (onde cada DMU é livre para modelar suas restrições de forma a maximizar sua eficiência, muitas vezes não traduzindo a realidade da operação e onde as unidades frequentemente operam sob condições distintas) por métricas derivadas de distribuições estatísticas (média, desvio padrão e fator Gaussiano). Essa abordagem permitiu atribuir pesos de forma objetiva, priorizando automaticamente critérios mais voláteis ou relevantes, como o Lucro Bruto, sem a necessidade de intervenção subjetiva.

No entanto, é importante destacar que este estudo avaliou apenas quatro DMUs (restaurantes) em um período específico. No DEA, a quantidade de unidades tomadoras de decisão influencia diretamente a confiabilidade e a estabilidade da fronteira de eficiência estimada: quanto menor o número de unidades, maior a probabilidade de que variações individuais impactem a fronteira, aumentando a sensibilidade a outliers e dificultando a generalização dos resultados. Essa limitação exige cautela na interpretação, reforçando a necessidade de estudos com um número maior de unidades para ampliar o poder analítico do modelo e fortalecer as conclusões, além de aplicações do DEA Gaussiano em outras indústrias e contextos de otimização e benchmarking.

Apesar dessa limitação, a aplicação do método híbrido demonstrou viabilidade técnica e relevância prática, identificando tanto as unidades mais eficientes quanto aquelas com maior potencial de melhoria. Essa informação pode ser diretamente incorporada em ciclos de gestão como o PDCA (Planejar, Executar, Verificar, Agir) e outras ferramentas corporativas, permitindo intervenções mais direcionadas e objetivas.

Do ponto de vista teórico, a integração do AHP Gaussiano e da correção de Pearson ao DEA contribui para a literatura ao aproximar métodos determinísticos da validação estatística, oferecendo um framework replicável e adaptável para diferentes setores. Como trabalhos futuros, recomenda-se:

- (i) ampliar a amostra de DMUs para fortalecer a robustez da fronteira de eficiência;
- (ii) aplicar o método em outros segmentos econômicos;
- (iii) incorporar técnicas de aprendizado de máquina e inteligência artificial para refinamento da análise; e
- (iv) explorar integrações com dashboards interativos, facilitando a interpretação e aplicação gerencial dos resultados.

Em síntese, a proposta apresentada avança em relação ao DEA tradicional ao restringir pesos com base em critérios estatísticos robustos e ao aplicar correção de Pearson para mitigar distorções, constituindo uma ferramenta mais confiável e adaptada aos desafios contemporâneos de análise de eficiência no varejo alimentar e em outros contextos organizacionais.

8. Agradecimentos

O primeiro autor agradece à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), por meio da bolsa nº 88887.798679/2022-00. O segundo e o terceiro autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), por meio da bolsa nº 306435/2023-3.

Referências

- Almeida, L. H. et al. (2011). A Multi-criteria Model for Planning and Fine-Tuning Distributed Scrum Projects. In *Anais da Sixth International Conference on Global Software Engineering*, IEEE, p. 75–83. doi:10.1109/ICGSE.2011.36.
- Charnes, A., Cooper, W. W. e Rhodes, E. (1978). Measuring the Efficiency of Decision-Making Units. *European Journal of Operational Research*, 2(6): 429–444.
- Cohen, I. et al. (2009). Pearson Correlation Coefficient. In *Noise Reduction in Speech Processing*, p. 1–4.
- Cooper, W. W., Seiford, L. M. e Tone, K. (2007). *Data Envelopment Analysis: A Comprehensive Text with Models, Applications, References and DEA-Solver Software*. 2ª ed., Springer.
- Dos Santos, M., De Araújo Costa, I. P. e Gomes, C. F. S. (2021). Multicriteria Decision-Making in the Selection of Warships: A New Approach to the AHP Method. *International Journal of the Analytic Hierarchy Process*, 13(1).
- Dyson, R. G. e Thanassoulis, E. (1988). Reducing Weight Flexibility in Data Envelopment Analysis. *Journal of the Operational Research Society*, 39(6): 563–576.
- Dharmadhikari, S. (2025). Europe Full-Service Restaurants Market Report 2025. Cognitive Market Research. www.cognitivemarketresearch.com/regional-analysis/europe-full-service-restaurants-market-report. Acessado: 13 Jan. 2025.
- Gomes, C. F. S. et al. (2021). Ordering of Warships for the Brazilian Navy Using the New Method: AHP-Gaussian with Pearson's Correlation. In IOS Press, ed., *Modern Management Based on Big Data II and Machine Learning and Intelligent Systems III*, p. 104–111.
- Huguenin, J.-M. (2012). *Data Envelopment Analysis (DEA): A Pedagogical Guide for Decision Makers in the Public Sector*. Swiss Graduate School of Public Administration.
- Liu, J., Zhang, Y. e Zhao, Q. (2019). The Video Stabilisation Algorithm is Based on the Pearson Correlation Coefficient. In *Anais do 2019 International Conference on Advanced Mechatronic Systems (ICAMechS)*, IEEE, p. 289–293.
- Lima, M. S., Carrieri, A. e Pimentel, T. D. (2007). Resistência à Mudança Gerada pela Implementação de Sistemas de Gestão Integrada (ERP): Um Estudo de Caso. *Revista Gestão e Planejamento*, 8(1): 89–105. revistas.unifacs.br/index.php/rgb/article/view/258.
- Meza, L. A., Gomes, E. G. e Neto, L. B. (2005). Curso de Análise de Envoltória de Dados. In *Anais do XXXVII Simpósio Brasileiro de Pesquisa Operacional*, p. 2520–2547.

Mendes, M. et al. (2008). A Co-evolutionary Interaction Design of Digital TV Applications Based on Verbal Decision Analysis of User Experiences. In Lytras, M. D. et al. (eds.), *The Open Knowledge Society: A Computer Science and Information Systems Manifesto*, Springer, p. 732–741, *Communications in Computer and Information Science*, vol. 19. doi:10.1007/978-3-540-87783-7_89.

Nadai, S. (2019). Ganhos com Implantação de ERP no Setor de Compras de uma Empresa do Setor Alimentício. In *Anais do X Congresso de Logística das Faculdades de Tecnologia do Centro Paula Souza - FatecLog Guarulhos*.

Okwonu, F. Z., Asaju, B. L. e Arunaye, F. I. (2020). Breakdown Analysis of Pearson Correlation Coefficient and Robust Correlation Methods. In *IOP Conference Series: Materials Science and Engineering*, p. 012065.

Pinheiro, P. R. e Rodrigues, T. S. (2024). Optimisation of Regression Models for Rental Price Recommendations: An Integrated Approach Using PyCaret and Gaussian Analytic Hierarchy Process. In Silhavy, R. e Silhavy, P. (eds.), *Lecture Notes in Networks and Systems*, vol. 1119, Springer, p. 504–512.

Rodrigues, T. S. e Pinheiro, P. R. (2025). Hyperparameter Optimization in Generative Adversarial Networks (GANs) Using Gaussian AHP. *IEEE Access*, 13: 770–788.

Saaty, T. L. (1994). Highlights and Critical Points in the Theory and Application of the Analytic Hierarchy Process. *European Journal of Operational Research*, 74(3): 426–447.

Saaty, T. L. (2008). Relative Measurement and Its Generalisation in Decision Making Are Why Pairwise Comparisons Are Central in Mathematics for Measuring Intangible Factors in the Analytic Hierarchy/Network Process. *RACSAM - Revista de la Real Academia de Ciencias Exactas, Físicas y Naturales. Serie A. Matemáticas*, 102(2): 251–318.

Wu, L. (2024). Automatic Scoring Model for English Compositions Using Bidirectional Encoder Representations from Transformer with Pearson Correlation Coefficient. In *Anais do 2024 International Conference on Integrated Intelligence and Communication Systems (ICIICS)*, IEEE, p. 1–5.