

ÉLCIO ADILSON DA SILVA JÚNIOR

**Redução do espaço de busca em problemas de otimização multiobjetivo via simulação
utilizando a análise envoltória de dados combinada com delineamento de experimentos**

Élcio Adilson da Silva Júnior

Redução do espaço de busca em problemas de otimização multiobjetivo via simulação utilizando a análise envoltória de dados combinada com delineamento de experimentos

Dissertação apresentada à Faculdade de Engenharia e Ciências do Campus de Guaratinguetá, Universidade Estadual Paulista, para obtenção do título de Mestre em Engenharia de Produção em Gestão de Operações.

Orientador: Prof. Dr. Aneirson Francisco da Silva

Coorientador: Prof. Dr. Fernando Augusto Silva Marins


S586r	Silva Junior, Élcio Adilson da Redução do espaço de busca em problemas de otimização multiobjetivo via simulação utilizando a análise envoltória de dados combinada com delineamento de experimentos / Élcio Adilson da Silva Junior – Guaratinguetá, 2022. 86 f : il. Bibliografia: f. 78-85 Dissertação (Mestrado) – Universidade Estadual Paulista, Faculdade de Engenharia e Ciências de Guaratinguetá, 2022. Orientador: Prof. Dr. Aneirson Francisco da Silva Coorientador: Prof. Dr. Fernando Augusto Silva Marins 1. Taguchi, Métodos (Controle de qualidade). 2. Métodos de simulação. 3. Planejamento experimental. 4. Processo decisório por critério múltiplo. I. Título.
Luciana Máximo Bibliotecária CRB-8/3595	CDU 65.012.4(043)

ÉLCIO ADILSON DA SILVA JÚNIOR

**ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE
“MESTRE EM ENGENHARIA DE PRODUÇÃO”**

**PROGRAMA: ENGENHARIA DE PRODUÇÃO
CURSO: MESTRADO**

APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO


Prof. Dr. Manoel Cleber de Sampaio Alves
Coordenador

BANCA EXAMINADORA:



Prof. Dr. ANEIRSON FRANCISCO DA SILVA

Orientador - UNESP

participou por videoconferência

Documento assinado digitalmente



RAFAEL DE CARVALHO MIRANDA
Data: 09/08/2022 10:03:32-0300
Verifique em <https://verificador.iti.br>

Prof. Dr. RAFAEL DE CARVALHO MIRANDA

UNIFEI

participou por videoconferência


Prof. Dr. FABRÍCIO MACIEL GOMES

EEL/USP

participou por videoconferência

DADOS CURRICULARES

ÉLCIO ADILSON DA SILVA JÚNIOR

NASCIMENTO	04.12.1991 – Sorocaba / SP
FILIAÇÃO	Élcio Adilson da Silva Iná da Silva Pupo
2011/2016	Formação acadêmica (Bacharel em Engenharia Química) Universidade de São Paulo – USP
2017/2018	Formação Complementar (MBA em Gestão de Negócios) Universidade de São Paulo – USP

*‘A Dimas, O Primeiro.
Saúde, guerreiro.’*

AGRADECIMENTOS

Ao meu orientador e amigo, *Prof. Dr. Aneirson Francisco da Silva*, que jamais me deixou sem auxílio. Sem a sua presença, orientação, dedicação e atenção, o estudo aqui apresentado seria impossível;

Às funcionárias da Biblioteca do Campus de Guaratinguetá pela dedicação, presteza e, principalmente, pela vontade de ajudar;

Aos funcionários da Faculdade de Engenharia do Campos de Guaratinguetá pela dedicação e alegria no atendimento.

*“No more ifs, no bias, no ambiguity
No wondering whether this is it.
Clarity so brightly wrong
The image so painfully absolute”*
Meshuggah - Combustion

RESUMO

É comum o uso de técnicas de simulação a eventos discretos para avaliação de viabilidade de mudanças em cenários logísticos, industriais, hospitalares e comerciais. O setor logístico corporativo se depara com problemas complexos que requerem decisões sobre rotas de fretes, tipos de carregamentos, modais de transporte, entre outros fatores que afetam o custo e a eficiência do serviço logístico. Modelos de simulação podem auxiliar neste tipo de análise, porém, os tempos computacionais envolvidos nestas otimizações via simulação podem ser bastante extensos. Dentre os modelos matemáticos possíveis de serem utilizados em conjunto com a simulação probabilística, a Análise Envoltória de Dados (*Data Envelopment Analysis* - DEA) se apresenta como uma técnica que possibilita estabelecer um ranqueamento das Unidades Tomadoras de Decisão (*Decision Making Units* – DMUs) envolvidas no problema tratado, em termos das suas eficiências relativas, a partir da análise dos valores de suas entradas (*inputs*) e saídas (*outputs*). Esta técnica pode prover uma redução no espaço de busca e, dessa forma, auxiliar a reduzir estes tempos e trazer resultados de boa qualidade na aplicação da Otimização via Simulação. Quando associados a DEA, métodos de delineamento de experimentos também podem contribuir com a geração de matrizes de experimentos que reduzam o número de testes. Nesse trabalho foi utilizado um modelo de simulação, construído com auxílio do software *ProModel*, para investigação de um cenário logístico de carregamento de caminhões para expedição de materiais, numa empresa do setor químico, caracterizado por ser um problema multiobjetivo de decisão. Nesse contexto, um modelo DEA-BCC orientado ao insumo e ao produto foi utilizado, considerando-se como sendo as 32 DMUs, definidas com o auxílio dos arranjos experimentais das técnicas de Delineamento de Experimentos de Taguchi e de Hiper cubo Latino, compostas pelas variáveis de entrada do modelo (número de operadores, empilhadeiras, docas, turnos e tipos de carga, e as saídas dadas pelo custo médio por palete expedido e o número de caminhões carregados), visando à redução do espaço de busca de soluções. Os resultados mostraram as vantagens de se adotar tais técnicas combinadas, podendo serem citadas a redução de mais de 70% no tempo computacional na resolução do problema multiobjetivo e a redução de cerca de 97% no espaço de busca.

PALAVRAS-CHAVE: Otimização via Simulação. Análise Envoltória de Dados. Delineamento de Experimentos. Redução do Espaço de Busca. Problemas Logísticos. Expedição de Materiais.

ABSTRACT

It is common to use discrete-event simulation techniques to assess the feasibility of changes in logistical, industrial, hospital and commercial scenarios. The corporate logistics sector is faced with complex problems that require decisions about freight routes, types of shipments, modes of transport, among other factors that affect the cost and efficiency of the logistics service. Simulation models can help in this type of analysis, however, the computational times involved in these optimizations via simulation can be quite extensive. Among the mathematical models that may be used in conjunction with probabilistic simulation, Data Envelopment Analysis (DEA) is presented as a technique that makes it possible to establish a ranking of the Decision Making Units (DMUs) involved in the evaluated problem, in terms of its relative efficiencies, from the analysis of the values of its inputs and outputs. This technique is able to provide a reduction in the search space and, thus, help to reduce these times and bring good quality results in the application of Optimization via Simulation. When associated with DEA, experimental design methods can also contribute to the generation of experiment arrays that reduce the number of tests. In this work, a simulation model was used, built with the aid of the *ProModel* software, to investigate a logistical scenario of loading trucks for shipping materials, in a company in the chemical sector, characterized by being a multi-objective decision problem. In this context, an input- and output-oriented DEA-BCC model was used, considering the 32 DMUs, defined with the help of experimental arrangements of the Taguchi and Latin Hypercube Design of Experiments techniques, composed of the variables of model input (number of operators, forklifts, docks, shifts and types of cargo, and outputs given by the average cost per pallet shipped and the number of trucks loaded), in order to reduce the search space for solutions. The results showed the advantages of adopting such combined techniques, including a reduction of more than 70% in computational time in solving the multi-objective problem and a reduction of about 97% in the search space.

KEYWORDS: Optimization via Simulation. Data Envelopment Analysis. Design of Experiments. Reduction of Search Space. Logistical Problems. Shipment of Materials.

LISTA DE ILUSTRAÇÕES

Figura 1 – Resultados de publicações e citações em trabalhos com as palavras-chave " <i>Discrete event simulation</i> ", " <i>Optimization</i> " e " <i>Data Envelopment Analysis</i> "	19
Figura 2 – Diagrama das palavras-chave presentes nos artigos da base Scopus	22
Figura 3 – Classificação de pesquisa	23
Figura 4 – Fluxograma das etapas de pesquisa.....	24
Figura 5 – Gráfico do <i>software VOSViewer</i> com os artigos envolvendo a palavra-chave 'simulação a eventos discretos' desde 2018	28
Figura 6 – Gráfico do <i>software VOSViewer</i> com os artigos envolvendo a palavra-chave 'otimização via simulação' desde 2018	31
Figura 7 – Comparação de DMU's e representação do conceito de fronteira de eficiência	33
Figura 8 – Análise da Fronteira de Eficiência Invertida	39
Figura 9 – Comportamento da função <i>Desirability</i> maior, melhor, para diferentes valores de s	40
Figura 10 – Comportamento da função <i>Desirability</i> menor, melhor para diferentes valores de t	41
Figura 11 – Comportamento da função <i>Desirability target</i> para diferentes valores de s e t	42
Figura 12 – Classificação dos métodos de delineamento de experimentos mais comuns.....	44
Figura 13 – Gráfico do <i>software VOSViewer</i> com os artigos envolvendo a palavra-chave 'delineamento de experimentos' desde 2018.....	45
Figura 14 – Gráfico do <i>software VOSViewer</i> com os artigos envolvendo a palavra-chave 'delineamento de experimentos', 'otimização' e 'simulação', combinada, publicados desde 2018	46
Figura 15 – Gráfico do <i>software VOSViewer</i> com os artigos envolvendo a palavra-chave 'método de Taguchi' desde 2018	49
Figura 16 – Exemplos de quadrados latinos	50
Figura 17 – Gráfico do <i>software VOSViewer</i> com os artigos envolvendo a palavra-chave 'hipercubo latino' desde 2018.....	51
Figura 18 – Método aplicado para construção do modelo e estudo de simulação	52
Figura 19 – Fluxograma básico do modelo de simulação	55
Figura 20 – Captura de Tela do Modelo de Simulação elaborado no <i>software ProModel</i> TM ...	56
Figura 21 – Método de redução do espaço de busca proposto para o problema de OvS multiobjetivo sob estudo.....	57

Figura 22 – Gráfico dos tempos computacionais e reduções pela aplicação do DOE e DEA .	70
Figura 23 – Gráfico dos tempos computacionais e funções objetivos finais da análise de sensibilidade, considerando o espaço de busca completo	71
Figura 24 – Gráfico dos tempos computacionais e funções objetivos finais da análise de sensibilidade, considerando o espaço de busca reduzido pelo LHD e DEA BCC orientado ao produto.....	73

LISTA DE TABELAS

Tabela 1 – Comparação do número de artigos nas bases de dados Scopus e Web of Science .	18
Tabela 2 – Modelos de cálculo da razão sinal-ruído	48
Tabela 3 – Descrição dos fatores envolvidos na construção do modelo no <i>ProModel</i>	54
Tabela 4 – Descrição das variáveis de entrada do modelo	58
Tabela 5 – Descrição das variáveis de saída do modelo.....	58
Tabela 6 – Delineamento de Experimentos pelo Método de Taguchi	59
Tabela 7 – Delineamento de Experimentos pelo Método do Hipercubo Latino	60
Tabela 8 – Conjuntos de dados de análise divididos por método de DOE e orientação de DEA	61
Tabela 9 – DMUs mais eficientes de cada conjunto de dados, após ranqueamento.....	61
Tabela 10 – Novos espaços de busca reduzidos pela aplicação do DEA sobre os conjuntos de dados.....	62
Tabela 11 – Valores de L e U considerados para o cálculo da função <i>Desirability</i> de cada saída	63
Tabela 12 – Rodadas de Otimização via função <i>Desirability</i> com auxílio do <i>SimRunner</i>	64
Tabela 13 – Divisões de pesos para a análise de sensibilidade da função <i>Desirability</i> , baseados no DOE de mistura	64
Tabela 14 – Pesos aplicados na análise de sensibilidade com espaço de busca completo	65
Tabela 15 – Pesos aplicados na análise de sensibilidade com o melhor conjunto de dados	65
Tabela 16 – Resultados das simulações pelo DOE utilizando o método de Taguchi	66
Tabela 17 – Resultado das simulações pelo DOE utilizando o método do Hipercubo Latino .	67
Tabela 18 – Resultados da supereficiência para as DMUs em cada conjunto de dados.....	68
Tabela 19 – DMUs mais eficientes após ranqueamento.....	68
Tabela 20 – Novos espaços de busca reduzidos pela aplicação do DEA sobre os conjuntos de dados.....	68
Tabela 21 – Reduções nos espaços de busca após a aplicação das técnicas DOE e DEA.....	69
Tabela 22 – Resultados das rodadas de otimização utilizando a função <i>Desirability</i>	70
Tabela 23 – Resultados das funções <i>Desirability</i> na análise de sensibilidade, considerando o espaço de busca completo.....	72
Tabela 24 – Resultados das funções <i>Desirability</i> na análise de sensibilidade, considerando o espaço de busca reduzido pelo LHD e DEA BCC orientado ao produto	73

LISTA DE ABREVIATURAS E SIGLAS

DEA	<i>Data Envelopment Analysis</i> , sigla em inglês para Análise por Envoltória de Dados
DOE	<i>Design of Experiments</i> , sigla em inglês para Delineamento de Experimentos.
DMU	<i>Decision Making Unit</i> , sigla em inglês para Unidade Tomadora de Decisão.
LHD	<i>Latin Hypercube Design</i> , sigla em inglês para Projeto de Hipercubo Latino.
SED	Simulação a Eventos Discretos.
TOA	<i>Taguchi Orthogonal Arrays</i> , sigla em inglês para Arranjos Ortogonais de Taguchi
OvS	Otimização via Simulação.

SUMÁRIO

1	INTRODUÇÃO	14
1.1	CONTEXTUALIZAÇÃO E QUESTÕES DA PESQUISA	14
1.2	OBJETIVOS DA PESQUISA.....	16
1.3	JUSTIFICATIVA E RELEVÂNCIA CIENTÍFICA.....	17
1.4	MATERIAIS E MÉTODOS	22
1.5	DELIMITAÇÃO DA PESQUISA	25
1.6	ESTRUTURA DO TRABALHO	25
2	FUNDAMENTAÇÃO TEÓRICA.....	26
2.1	SIMULAÇÃO A EVENTOS DISCRETOS	26
2.2	OTIMIZAÇÃO VIA SIMULAÇÃO.....	28
2.3	ANÁLISE ENVOLTÓRIA DE DADOS	31
2.4	FUNÇÃO <i>DESIRABILITY</i>	39
2.5	DELINEAMENTO DE EXPERIMENTOS.....	42
2.5.1	Método de Taguchi.....	46
2.5.2	Hipercubo Latino	49
3	MODELAGEM DO PROBLEMA LOGÍSTICO DE EXPEDIÇÃO	52
3.1	DESCRIÇÃO DO PROBLEMA.....	52
3.2	MODELAGEM E RESOLUÇÃO.....	53
4	RESULTADOS E IMPLICAÇÕES GERENCIAIS	66
5	CONCLUSÕES	75
5.1	VERIFICAÇÃO DOS OBJETIVOS GERAIS E RESPOSTAS ÀS QUESTÕES DE PESQUISA.....	75
5.2	SUGESTÕES PARA CONTINUIDADE DO TRABALHO.....	77
5.3	IMPLICAÇÕES GERENCIAIS.....	77
	REFERÊNCIAS	78
	APÊNDICE A – Código de cálculo da função <i>Desirability</i> no modelo de <i>ProModel</i>.....	86

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E QUESTÕES DA PESQUISA

A simulação a eventos discretos (SED) oferece uma gama de funcionalidades que é de fundamental importância para estudos de tomada de decisão (PARK *et al.*, 2018). Ainda segundo os mesmos autores, a simulação possibilita aos tomadores de decisão verificar gargalos em sistemas reais, sem a necessidade de realizar mudanças no processo real. Além disso, um modelo de simulação estatisticamente validado é de grande valia para auxiliar a definição de uma mudança operacional (MARINS *et al.*, 2020). A validação, geralmente, é feita por meio de testes estatísticos ou utilizando mecanismos academicamente aceitos para comprovar relações de causalidade (GUERINI; MONETA, 2017).

De todo modo, a utilização de modelos de simulação para determinação de possíveis melhorias de sistemas produtivos podem demandar tempo computacional elevados, a depender do processo simulado (MARINS *et al.*, 2020). Contudo podem permitir poupar quantias significativas em gastos desnecessários, aumentando a eficiência dos processos investigados (KHEZRIMOTLAGH *et al.*, 2019).

A Análise Envoltória de Dados (*Data Envelopment Analysis* – DEA) é um método não paramétrico, que emprega otimização linear para avaliar a eficiência de unidades tomadoras de decisão (*Decision Making Units* – DMU) (CHARNES; COOPER; RHODES, 1978).

A DEA possibilita reduzir o intervalo de variação das variáveis de decisão que são otimizadas em problemas de otimização via simulação, quando associada a um arranjo ortogonal e incorporada a uma estratégia experimental bem definida (MIRANDA *et al.*, 2017). Além disso, também é possível realizar não somente a análise dos resultados de um determinado conjunto de DMUs, mas também, sua discriminação e ranqueamentos com base na eficiência de cada unidade tomadora de decisão (DMUs), que utiliza os mesmos recursos (*Input*) e produtos ou saídas (*Outputs*), diferenciando na escala e na magnitude (MARINS *et al.*, 2020).

Na literatura, dois modelos DEA principais recebem maior destaque: os modelos DEA - CCR e DEA - BCC. O DEA - CCR recebe essa nomenclatura em referência ao trabalho pioneiro de Charnes, Cooper e Rhodes (1978) e admite retornos constantes de escala, sendo por isso também encontrado com a nomenclatura DEA - CRS (*constant returns to scale*) (MARINS *et al.*, 2020).

O modelo DEA - BCC é recebe esta nomenclatura também em referência ao trabalho de

Banker, Charnes e Cooper (1984). Este modelo admite retornos variáveis de escalas, por isso, também pode ser chamado de DEA - VRS (*variable returns to scale*). Ambos os modelos podem ser orientados aos insumos (*inputs*) ou aos produtos (*outputs*), a depender da necessidade da análise executada (ZHU *et al.*, 2018).

O Delineamento de Experimentos (*Design of Experiments* – DOE) é um conjunto de métodos estatísticos utilizados para condução de análises experimentais, visando a uma consolidação das variáveis de entrada (x_s) e seus respectivos níveis de variação, reduzindo o número de experimentos necessários, sem comprometer a qualidade da resposta (MONTEVECHI *et al.*, 2015).

Dentre os métodos clássicos de DOE, há uma ampla utilização dos métodos dos Arranjos Ortogonais de Taguchi (*Taguchi Orthogonal Arrays* - TOA) em trabalhos de pesquisa operacional e simulação, devido à sua baixa complexidade de uso, a boa qualidade de resposta, bem como a facilidade de avaliação dos efeitos entre variáveis (KLEIJNEN, 2010). No entanto, o projeto experimental de Hipercubo Latino (*Latin Hypercube Design* – LHD), por sua vez, é o conjunto de métodos de DOE mais comumente utilizado para criação de metamodelos voltados para simulação computacional (PARNIANIFARD *et al.*, 2020).

Em se tratando de processos logísticos, a busca por modelos de transporte mais econômicos e eficientes para matérias primas, melhorias na consolidação de carga, distribuição de produtos acabados de forma mais eficiente são questões, constantemente, abordadas por pesquisadores de organizações educacionais e empresas privadas (LOPES *et al.*, 2017; MARINS *et al.*, 2019; MATOS, 2007).

Assim, a simulação pode ser uma ferramenta útil nessa busca, conforme mostrado nos inúmeros trabalhos publicados envolvendo estudos de otimização, com aplicação de *softwares* de simulação a eventos discretos desenhados para cenários de cadeia de suprimento, tais como o ProModelTM, o *Supply Chain* GuruTM e o ArenaTM (FERREIRA, 2019; MARDANI *et al.*, 2017; MIRANDA *et al.*, 2017).

Todavia, os cenários simulados em modelos de logística e *Supply Chain*, frequentemente, envolvem um número alto de parâmetros de entrada e saída como, por exemplo, tipos de veículos, volumes movimentados, sazonalidade, diferentes rotas, disponibilidade de fornecedores, dentre outros (BARCELLOS DE PAULA; MARINS, 2018). Vários destes cenários implicam ainda em problemas de otimização multiobjetivo, que são, por natureza, mais complexos e, portanto, tendem a necessitar de tempos computacionais mais elevados para encontrar soluções ótimas (ROJAS-GONZALEZ *et al.*, 2019).

Conforme exposto em seu trabalho Miranda *et al.* (2017) propõem a associação das

técnicas DEA e DOE para redução de espaços de busca em problemas de otimização via simulação. Esta combinação de métodos foi abordada novamente em outras duas publicações, trazendo boas indicações das capacidades de entrega de respostas com boa qualidade em tempos computacionais bastante reduzidos (MARINS *et al.*, 2020; MIRANDA *et al.*, 2019).

A proposta de elaborar DMU's com base em arranjos de DOE, e aplicar a DEA com ranqueamentos por supereficiência para definir novos espaços de busca e submeter estes a rodadas de otimização via simulação será aplicada neste trabalho, porém a aplicação se dará no estudo de um problema multiobjetivo, diferenciando-se também pela aplicação de mais de uma orientação para a DEA (ao insumo e ao produto) e com a utilização de dois diferentes métodos de DOE (Arranjo Ortogonal de Taguchi e *Latin Hypercube Design*) para criar as matrizes de DMUs.

Nesse contexto, as seguintes questões de pesquisa motivaram o desenvolvimento dessa pesquisa:

- Como a otimização multiobjetivo via simulação pode ser aplicada para determinar o melhor arranjo operacional logístico estudado?
- Quais são vantagens de se combinar um modelo DEA-BCC com os Arranjos Ortogonais de Taguchi e o Hipercubo Latino, visando a redução do espaço de busca em otimizações multiobjetivo com modelos de simulação?
- Qual o melhor arranjo experimental (Taguchi ou Hipercubo Latino) para ser combinado com o modelo DEA-BCC, visando a redução do espaço de busca em otimizações multiobjetivo com modelos de simulação?
- Como aglutinar múltiplas funções objetivo em problemas de otimização multiobjetivo via simulação?

1.2 OBJETIVOS DA PESQUISA

Para buscar respostas às questões de pesquisa elencadas, o objetivo geral deste trabalho foi desenvolver uma sistemática para redução do espaço de busca, e do tempo computacional, em modelos de otimização multiobjetivo via simulação, por meio de um modelo DEA – BCC, combinado com técnicas de DOE, para problemas de expedição logística.

Os objetivos específicos, numa aplicação real para uma empresa do setor químico, foram:

- Aplicar a sistemática proposta combinando TOA e a DEA, com orientação ao produto e ao insumo.

- Aplicar a sistemática proposta combinando LHD e a DEA, com orientação ao produto e ao insumo.
- Identificar o melhor arranjo experimental (TOA ou LHD) para ser combinado com o modelo DEA-BCC, visando à redução do espaço de busca.
- Identificar a melhor orientação do DEA (insumo ou produto) para ser combinada com os métodos de DOE, , visando à redução do espaço de busca.
- Avaliar o uso da função *Desirability* como método de aglutinação para otimização via simulação multiobjetivo.

1.3 JUSTIFICATIVA E RELEVÂNCIA CIENTÍFICA

Neste trabalho foi estudado um modelo de simulação no *software ProModelTM*, que representa uma operação logística real. Os dados obtidos dessa simulação possibilitaram uma melhor alocação de recursos e resultados de expedição do processo, que permitirão uma avaliação da otimização Multiobjetivo via simulação do processo estudado, otimizando dois objetivos: maior quantidade de material expedida com o menor custo por unidade expedida.

Este trabalho possibilitou um estudo conjunto de várias variáveis de entrada x 's e, a otimização de dois objetivos. Para auxiliar na elaboração dos experimentos e na coleta dos dados, serão aplicadas técnicas de DOE e, após estes dados estarem disponíveis, serão aplicadas técnicas de DEA, visando estabelecer novos limites de variação para as variáveis de decisão.

A Tabela 1 mostra os resultados encontrados em buscas às bases *Web of Science* e *Scopus* utilizando as palavras-chaves envolvidas neste trabalho. Percebe-se que a base *Scopus* gerou um maior volume de publicação, e essa foi a base selecionada para a análise bibliométrica.

Tabela 1 – Comparação do número de artigos nas bases de dados Scopus e Web of Science


Pesquisa	Palavras chaves	Publicações		Desvio $\left(\frac{a}{b}\right) - 1$
		Scopus (a)	Web of Science (b)	
#1	"Simulation and Optimization"	7.224	5.030	43,6%
#2	"Simulation Optimization"	3.470	3.170	9,46%
#3	"Optimization via Simulation"	80	113	-29,2%
#4	"Multiobjective optimization"	54.725	16.372	234,2%
#5	"Data Envelopment Analysis"	20.004	16.872	18,5%
#6	"Design of Experiments"	34.625	15.593	122,0%
#7	"Latin Hypercube"	5.346	3.661	46,0%
#8	"Discrete Event Simulation" e "Optimization"	2.793	1.280	118,2%
#9	"Discrete Events Simulation" e "Optimization"	2.977	117	2.340%
#10	"Discrete-Event Simulation" e "Optimization"	2.977	1.412	110,8%
#11	"Discrete Event Simulation" e "Multiobjective Optimization"	113	32	253,1%
#12	"Discrete Events Simulation" e "Multiobjective Optimization"	116	0	100%
#13	"Discrete-Event Simulation" e "Multiobjective Optimization"	116	35	231,4%
#14	"Data Envelopment Analysis" e "Multiobjective Optimization"	151	45	235,5%
#15	"Taguchi" e "Multiobjective Optimization"	756	312	142,3%
#16	"Latin Hypercube" e "Multiobjective Optimization"	389	95	309,5%
#17	"Simulation and Optimization" e "Design of Experiments"	60	23	160,9%
#18	"Data Envelopment Analysis" e "Taguchi"	59	67	-11,9%
#19	"Simulation and Optimization" e "Taguchi"	32	20	60,0%
#20	"Simulation and Optimization" e "Latin Hypercube"	12	7	71,4%
#21	"Discrete Event Simulation" e "Optimization" e "Data Envelopment Analysis"	15	16	-6,2%
#22	"Discrete Events Simulation" e "Optimization" e "Data Envelopment Analysis"	16	0	100%
#23	"Discrete-Event Simulation" e "Optimization" e "Data Envelopment Analysis"	16	0	100%
#24	"Data Envelopment Analysis" e "Latin Hypercube"	4	4	0%
#25	"Simulation and Optimization" e "Data Envelopment Analysis" e "Latin Hypercube"	4	1	300%
#26	"Discrete Event Simulation" e "Optimization" e "Data Envelopment Analysis" e "Design of Experiments"	3	1	200%
#27	"Discrete Events Simulation" e "Optimization" e "Data Envelopment Analysis" e "Design of Experiments"	3	0	100%
#28	"Discrete-Event Simulation" e "Optimization" e "Data Envelopment Analysis" e "Design of Experiments"	3	0	100%
#29	"Simulation and Optimization" e "Data Envelopment Analysis"	2	2	0%
#30	"Discrete Event Simulation" e "Optimization" e "Data Envelopment Analysis" e "Design of Experiments"	2	1	100%
#31	"Discrete Events Simulation" e "Optimization" e "Data Envelopment Analysis" e "Design of Experiments"	2	0	100%
#32	"Discrete-Event Simulation" e "Optimization" e "Data Envelopment Analysis" e "Design of Experiments"	2	0	100%

Fonte: Scopus e Web of Science (2022).

Esta pesquisa contribuirá, portanto, para os estudos de simulação a eventos discretos, otimização de processos, DOE e DEA, com uma aplicação real, seguida de uma análise metódica estruturada.

A Figura 1 mostra o número de publicações de artigos, desde 2006, utilizando as palavras-chave "*Discrete event simulation*", "*Optimization*" e "*Data Envelopment Analysis*". Nesta Figura, foi possível notar dois picos de publicações, um em 2011, com 2 artigos, e outro mais recente, em 2017. Os picos de citações ocorreram nos mesmos intervalos, foi possível identificar, também, que dos 16 artigos presentes neste conjunto de dados, seis estão nos últimos 5 anos (~37,5%), indicando que se trata de temas que, ainda, possuem interesse acadêmico.

Figura 1 – Resultados de publicações e citações em trabalhos com as palavras-chave "*Discrete event simulation*", "*Optimization*" e "*Data Envelopment Analysis*"



Fonte: Scopus (2022).

A seguir, comenta-se sobre alguns desses trabalhos. Miranda *et al.* (2017) estudaram uma combinação do arranjo ortogonal de Taguchi e DEA, na redução do espaço de busca e do tempo computacional em problemas de otimização via simulação, buscando à otimização via o *toolbox SimRunner*TM. Nesse trabalho, os autores conseguiram uma redução de 97% do espaço de busca, sem comprometer a qualidade das respostas. Como sugestões de novas pesquisas, sugeriu-se:

- Aplicação do procedimento proposto em problemas de otimização Multiobjetivo.
- Investigação de outros arranjos experimentais combinadas com um DEA de forma a melhorar a eficiência e a eficácia do método proposto.
- Teste do procedimento proposto em problemas envolvendo variáveis contínuas.

- Teste do procedimento proposto usando outros otimizadores.

Shadkam e Bijari (2015) apresentaram um trabalho envolvendo simulação e otimização Multiobjetivo aplicada a um problema de seleção de fornecedores, em um modelo de *supply chain*, tratado por diferentes algoritmos. Os resultados da simulação foram tratados pelo método GDEA (*General Data Envelopment Analysis*), o qual foi possível indicar, com um nível de acurácia satisfatório, quais seriam os melhores parâmetros para a cadeia de suprimento estudada. Nesse trabalho, sugeriu-se pesquisar mais detalhadamente a robustez do método proposto usando o método de Taguchi ou usando outro algoritmo evolutivo. Ou ainda, usando metamodelos de regressão e rede neural para otimização do módulo de simulação no método proposto em outros problemas aplicados.

Rabbani *et al.* (2018) apresentaram uma abordagem de modelagem e simulação para propor uma otimização no setor de emergência de um hospital. Porém, por se tratar de um hospital de grande porte, não poderia se construir um modelo considerando, apenas, os recursos neste setor. Logo, fez-se uso de uma técnica de otimização com múltiplas respostas. Nesse trabalho, foram aplicadas técnicas de DEA aos dados de saída do modelo e houve, também, a aplicação de técnicas de delineamento de experimentos pelo método de Taguchi para definir quais cenários seriam simulados. O trabalho apresentou uma proposta de DMU's que reduziria os tempos de atendimento em até 16% na prática, e mostrou que a associação dessas técnicas pode trazer resultados promissores em termos de otimização de processos.

Hosseini *et al.* (2019) desenvolveram uma nova proposta de utilização das técnicas de DEA na forma do *Fuzzy Data Envelopment Analysis* (F-DEA), aplicado a otimização de um *layout* fabril. O F-DEA é uma nova abordagem, além das duas formas clássicas da análise por envoltória de dados, a CCR e a BCC (CHARNES *et al.*, 1978), que consistem em modelos em lógica *fuzzy* que permitem o cálculo da DMU mais eficiente, mas necessita de dados históricos para treinamento e checagem do sistema. Nesse trabalho, os dados históricos foram coletados, e em seguida, as diferentes opções foram inseridas no modelo de simulação a eventos discretos. Os resultados foram tratados com *Fuzzy DEA* e, com isso, foi possível designar a opção de *layout* com maior eficiência, sem a necessidade de testes em campo e com uma notável redução do espaço busca e, consequentemente, do tempo computacional.

Sislioglu, Celik e Ozkaynak (2019) estudaram opções de investimento para aumentar a produtividade de um terminal de containers por meio de um modelo de simulação a eventos discretos, aliado a técnicas de DEA e análises financeiras. As conclusões desse trabalho mostraram a importância do DEA na identificação da DMU mais eficiente em termos operacionais, porém também foi avaliado com alto nível de detalhamento o resultado financeiro

de cada DMU, visando obter a maior produtividade de contêineres, com o menor custo operacional possível. O modelo apresentado foi descrito como uma ferramenta flexível o bastante para realizar análises do mesmo teor, em outros conjuntos de dados, oferecendo essa possibilidade como uma oportunidade de novas pesquisas.

Keshtkar *et al.* (2020) apresentaram, novamente, as técnicas de modelagem e simulação a eventos discretos, aplicadas na busca pela redução de tempos de atendimento em ambientes hospitalares. Na elaboração da pesquisa, utilizaram-se dados reais para a confecção de um modelo de simulação, no qual foram realizados experimentos definidos com base no método de Taguchi, e cujos resultados foram analisados em um sistema de DEA - BCC, com um total de 14 DMU's. Ao final do estudo, foi possível desenvolver uma sistemática integrada de simulação, otimização, delineamento de experimentos e análise por envoltória de dados que permite identificar formas de reduzir atrasos, em diferentes áreas do atendimento hospitalar.


Marins *et al.* (2020) trouxeram, novamente, a aplicação da técnica de *Fuzzy DEA* aliada aos métodos clássicos do DEA para melhorar a eficiência e reduzir o espaço de busca. O trabalho se baseou em modelos de simulação validados, nos quais foram aplicadas as técnicas de *Fuzzy DEA* para identificação de DMU's supereficientes, ou seja, com eficiências acima de 100%, mas que, ainda, poderiam ser ranqueadas entre si. Os resultados da identificação pelo método *Fuzzy DEA*-BCC foram comparados com os resultados do *software* de otimização *SimRunner*TM para validação. Ao final do artigo, identificou-se que o método proposto pode oferecer reduções de até 97% no espaço de busca, sem comprometer a qualidade de resposta, inclusive, oferecendo respostas ainda mais otimizadas que a do *software*, em alguns casos. Como recomendações de projetos de pesquisa futuros, os autores sugeriram a aplicação do método apresentado, porém utilizando:

- Função de pertinência linear trapezoidal; (KAO; LIU, 2000).
- Funções de pertinência não lineares, como Gaussiana, Sigmóide e Curva Z; (YU, 1999).
- Outros métodos de classificação em DEA, como modelos de avaliação de eficiência cruzada; (HLADÍK, 2019; RUIZ; SIRVENT, 2016).
- Analisar a otimização multiobjetivo via simulação.
- Com outros arranjos experimentais ou estratégias, que permitem a redução do número de experimentos necessários, permitindo uma maior redução do tempo computacional e a aplicação deste método a outros objetos de estudo de áreas diferentes das aqui utilizadas, como forma de comprovar a eficiência e a eficácia do método proposto.

Na Figura 2, utilizou-se o software *VOSViewer* (YU *et al.*, 2020) para analisar os dados da base Scopus, em termos de palavras-chave, e como estas estão relacionadas entre si. Nota-se a ligação dos termos “*design of experiments*”, “*simulation optimization*” e “*multi-objective problem*” com o termo central “*data envelopment analysis*”.

Diante destes dados, espera-se que o presente trabalho contribua para a utilização de técnicas DEA combinada com os Arranjos Ortogonais de Taguchi e Hipercubo Latino, visando à redução do espaço de busca em problemas de otimização multiobjetivo via simulação. O presente projeto se mostra como uma oportunidade de inovação, seguindo as sugestões de (MARINS *et al.*, 2020).

Figura 2 – Diagrama das palavras-chave presentes nos artigos da base Scopus




Fonte: *VOSViewer* (2022).

1.4 MATERIAIS E MÉTODOS

A pesquisa deste trabalho foi classificada conforme o método sugerido por Turrioni e Mello (2012) e Bertrand e Fransoo (2002).

Figura 3 – Classificação de pesquisa



Fonte: Bertrand; Fransoo, (2002).

Dessa forma, pode-se classificar o trabalho como sendo de natureza aplicada, empírica normativa com relação a seus objetivos, pois tem como objetivo desenvolver políticas e estratégias que melhorem uma situação atual. Como meio é uma pesquisa de campo e experimental, quanto à forma de abordar o problema, uma pesquisa quantitativa. Os procedimentos técnicos são a modelagem, simulação e experimentos.


Neste trabalho utilizou-se um modelo de simulação a eventos discretos previamente validado para simular diferentes cenários de expedição de carga, em um armazém logístico. As entradas e saídas deste serão explicadas, detalhadamente, adiante. Para definição dos parâmetros de entrada de cada execução do modelo a fim de encontrar os pontos otimizados dos objetivos, foram utilizados dois métodos diferentes de DOE: o método de Taguchi e o Hipercubo Latino. Cada um destes métodos sugeriu um determinado número de experimentos e um ajuste específico.

As DMUs aplicadas nesta análise consistem nas combinações de diferentes ajustes para 5 variáveis de entrada do modelo: x_1 – número de operadores, x_2 – número de docas ativas no armazém, x_3 – número de empilhadeiras, x_4 – tipo de carga e x_5 – número de turnos nos quais a operação ocorrerá. Todos estes parâmetros de entrada são atribuídos como números inteiros, restritos às faixas de variação pré-estabelecidas para cada variável de entrada. As saídas do modelo explorado consistem em: y_1 – custo médio por caminhão carregado e y_2 – número total de paletes expedidos.

Os resultados das simulações executadas junto a seus conjuntos de dados de entrada são alimentados pela aplicação de um modelo DEA-BCC para avaliação das DMU's e determinação dos arranjos de maior eficiência, ou seja, que apresentam a melhor combinação de baixo custo de operação e alto número de caminhões expedidos. Na Figura 4 é exibido o fluxograma das

etapas de pesquisa desenvolvidas neste trabalho.

Figura 4 – Fluxograma das etapas de pesquisa



Fonte: Adaptado de Miranda *et al.* (2017).

O fluxograma aplicado neste trabalho diferencia-se da sistemática proposta por Miranda *et al.* (2017) por três fatores principais:

- A diferenciação de métodos de DOE para criação das matrizes de DMUs.
- A aplicação do modelo DEA - BCC com orientações ao insumo e ao produto.
- A possibilidade de aplicação em problemas de otimização via simulação multiobjetivo, utilizando a função *Desirability* como método de aglutinação.

1.5 DELIMITAÇÃO DA PESQUISA

Este trabalho se limitará ao estudo do modelo descrito no item anterior, modelo este que será executado conforme a matriz de experimentos estipulada pelo arranjo adequado ao estudo, contemplando seu número de variáveis de entrada e saída. Após a execução destes experimentos, estruturados com o auxílio das duas técnicas de DOE, o trabalho se dedicará à aplicação das técnicas de DEA, com duas diferentes orientações, nas bases de dados construídas pelos resultados do experimento. Esta etapa consistirá na avaliação dos diferentes modelos de DEA e da qualidade das conclusões fornecidas por cada um deles, sobre a eficiência dos arranjos de variáveis de entrada comparadas às múltiplas saídas do modelo simulado.

O modelo de simulação estudado foi construído com base em medições de tempos e observações operacionais em um cenário real, operado dentro de uma planta logística de uma empresa multinacional, localizada no Vale do Paraíba. As observações e dados utilizados no modelo foram validados e ajustados conforme a realidade estudada, porém não será feita menção à empresa em questão, nem medições futuras visando alterar o modelo ou os dados utilizados nas distribuições de probabilidade envolvidas nos cálculos executados pelo *software ProModelTM*.

1.6 ESTRUTURA DO TRABALHO

Esse trabalho está organizado em mais quatro Capítulos, além dessa Introdução. No Capítulo 2 está o referencial teórico relacionado aos temas: Simulação a Eventos Discretos, Simulação e Otimização, Análise Envoltória de Dados, Delineamento de Experimentos, Método de Taguchi e Hipercubo Latino. O Capítulo 3 aborda a descrição e modelagem do problema aqui tratado. Em seguida, no Capítulo 4, descreve-se a aplicação do modelo e os resultados encontrados, e, finalizando, no Capítulo 5 se encontram as conclusões, as verificações dos objetivos e sugestões para estudos futuros, sendo seguidas pelas referências bibliográficas utilizadas para a elaboração desse texto.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 SIMULAÇÃO A EVENTOS DISCRETOS

A SED é uma técnica de construção de modelos matemáticos baseados em fenômenos ordenados no tempo. Cada um destes fenômenos pode ocorrer em determinado instante e marca uma alteração no estado do sistema simulado (LAMPERTI *et al.*, 2021).

Os modelos de SED são, frequentemente, utilizados em pesquisas de auxílio à tomada de decisão, devido à capacidade de simular os impactos das mudanças de processo e operação em situações reais, sem que estas mudanças precisem ter efeito ou que ocorram interferências no processo simulado, permitindo que, apenas a mudança com o melhor resultado (caso exista) seja feita, após todas as execuções do modelo e análises necessárias (GONÇALVES *et al.*, 2019).

A construção de um modelo de SED, geralmente, inclui uma ou mais etapas de coleta de dados, que ocorrem previamente à construção do modelo. Durante a elaboração de um modelo, conjuntos de dados de entrada devem ser inseridos no sistema e seus respectivos dados de entrada devem ser coletados e analisados para validar a convergência do modelo proposto em relação ao processo real, bem como a reprodutibilidade dos processos simulados (YU; HAN, 2021).

Os métodos de SED podem prover, portanto, auxílios importantes no teste de hipóteses de melhoria em processos reais, porém, para que esta aplicação seja satisfatória, frequentemente é necessário combinar SED com técnicas de otimização. Conforme será explorado na sessão seguinte com mais detalhes, essas técnicas consistem em abordagens mono ou multiobjetivo focadas em maximizar, minimizar ou atingir um determinado valor específico para variáveis de saída do sistema de simulação (ČERVENÁNSKÁ *et al.*, 2021).

Desde a década de 1970, diversos softwares vêm sendo desenvolvidos e atualizados em vias de facilitar a experiência do usuário na criação, edição e análise destes modelos de simulação. Um destes software é o *ProModel*, desenvolvido pela *ProModel Corporation*. A utilização dessa ferramenta em trabalho de otimização via simulação é frequente em trabalhos envolvendo modelos de atendimento a clientes, processos de manufatura, logística e *supply chain* (NOVRISAL *et al.*, 2017).

De forma geral, os *softwares* de SED apresentam estruturas, equações e outros recursos matemáticos organizados na forma de uma interface digital que facilita a elaboração de estudos de cenários do tipo ‘e se?’, ou seja, cenários que consistem em avaliar os efeitos da

implementação de políticas ou de mudanças de estado em sistemas e fenômenos reais, por meio de modelos de simulação.

Por se tratar de um ambiente computacional isolado, a SED garante que as implicações reais destas políticas em estudo não afetarão os processos reais, e, assim, evita-se a tomada de decisões inadequadas para atingimento do melhor desempenho possível destes sistemas (DEMIR *et al.*, 2018).

Com estas vantagens computacionais em vista, os campos de pesquisa envolvendo SED crescem anualmente, e novas aplicações nos ramos de segurança em aeroportos, efetividade no atendimento de clientes em filas, tempos de espera em processos fabris, desenhos de páginas para internet, entre outras, vêm sendo investigadas com o auxílio de métodos de simulação, indicando hipóteses de otimização, em vários ramos da ciência (JANER RUBIO; ROSSETTI, 2018).

Durante ambas as etapas de validação, tanto do modelo conceitual, quanto do modelo computacional, é essencial que os dados e os pontos de medição do modelo apresentem o máximo de convergência possível, visando, assim, garantir que o modelo conceitual represente com a maior acuracidade o que deverá ser construído no computador e, que o modelo computacional seja capaz de gerar as mesmas respostas que o processo real, dado um determinado conjunto de entradas (MONTEVECHI *et al.*, 2015).

Na Figura 5 utilizou-se, novamente, o *software VOSViewer* para avaliar um conjunto de dados extraído da base *Scopus*, contemplando os artigos publicados, entre 2018 e 2022, contendo o termo “*discrete event simulation*”. Nesta Figura 5, foi possível notar uma vasta gama de tópicos associados à simulação a eventos discretos, destacando-se as palavras-chaves métodos discretos, tomada de decisão, otimização, simulação computacional e controladores.

Ao condensar essas interações, é possível simular o comportamento geral do sistema, assim, a simulação torna-se uma técnica muito útil para planejamentos logísticos estratégicos e táticos, nos quais o horizonte de tempo do estudo é, relativamente, extenso (BADRI *et al.*, 2013). Além disso, como uma versão artificial de um sistema real, ou um ‘gêmeo digital’, a simulação pode atuar como uma ferramenta experimental para o desenvolvimento de novas estratégias ou políticas que não haviam sido cogitadas ou que não pareciam viáveis em uma primeira análise dos fatores físicos, permitindo, assim, a comparação de diversos cenários, sem implicar interrupções no sistema real (SOPHA *et al.*, 2021).

Fu (1994) definiu um problema de OvS, com um único objetivo, como sendo:

$$\min f(\theta) \quad (1)$$

sujeito a $\theta \in \Theta$

sendo $f(\theta) = E[\psi(\theta, \omega)]$ o valor esperado do desempenho do sistema estimado, a partir de amostras do modelo de simulação; e $\psi(\theta, \omega)$ valores de desempenho observados segundo parâmetros de entrada discretos ou contínuos, pertencentes a um conjunto viável Θ .

É comum que os problemas de modelagem envolvendo casos reais impliquem em otimizações com mais de um objetivo. Por isso, outros pesquisadores apresentam, também, modelagens de otimização multiobjetivo (MIRANDA *et al.*, 2017). Para Steponavičė; Ruuska; Miettinen, (2014) um problema de otimização multiobjetivo pode ser formulado como representado por (2):

$$\min_x E\{f(\phi(x, \omega))\} \quad (2)$$

sujeito a $x \in S$

sendo que $E\{\cdot\}$ indica o valor esperado, f é o valor do vetor da função objetivo, ϕ é o modelo estocástico, x é o vetor decisão, ω é um vetor randômico que representa a estocasticidade no modelo, e S é o conjunto viável.

Frequentemente, é necessária também a combinação de softwares e técnicas de análise adicionais aos modelos de OvS. Devido ao elevado volume de dados e à alta complexidade das relações que precisam ser contempladas pelos modelos de simulação que serão submetidos às rotinas de otimização, é comum que outras soluções digitais (como os softwares *Microsoft Excel*, *Microsoft Access*, e bases de dados como *Google Maps*, *Bing Maps*, *OpenStreetMaps* entre outros) sejam agregadas aos softwares já mencionados (como o *ProModel* e o *Supply Chain Guru*) (PROSSER *et al.*, 2021).

Adicionalmente a softwares e tecnologias digitais, métodos matemáticos também podem ser agregados a estudos de OvS. Esses métodos podem contemplar desde técnicas de pré-


tratamento de dados de entrada até análises otimizadas dos dados de saída. Em ambos os casos, as combinações de técnicas matemáticas podem implicar em reduções de tempo de pesquisa, seja por parte do pesquisador, seja tempo computacional de processamento dos modelos (AJU *et al.*, 2021).

Os estudos de OvS tem como sua principal desvantagem em relação a otimização tradicional justamente os elevados tempos computacionais, devido à complexidade dos algoritmos envolvidos na varredura dos espaços de busca. É comum que modelos de OvS tenham tempos de execução acima de horas, e quanto mais objetivos estas otimizações tiverem, maiores tendem a ser estes tempos (HORNG; LIN, 2017).

Nesse âmbito, a combinação de DEA e DOE, conforme proposto por Miranda *et al.* (2014), Miranda *et al.* (2017) e Silva *et al.* (2021), se apresenta como um importante auxílio no campo da OvS, visando trazer soluções de boa qualidade, com potenciais de redução notáveis tanto em espaço de busca, quanto em tempo computacional. A aplicação da sistemática em um problema multiobjetivo não foi explorada nestes três trabalhos e, portanto, é uma abordagem promissora para pesquisa, tendo em vista os tempos computacionais ainda mais elevados deste tipo de problema, quando comparados a modelos mono objetivo (AZIMI; FARHADI, 2018).

A Figura 6 mostra um panorama das palavras-chave encontradas em uma pesquisa na base de dados *Scopus*, considerando artigos publicados, entre 2018 e 2022, contendo o termo ‘*optimization via simulation*’. Nota-se uma presença mais concentrada de trabalhos envolvendo otimização multiobjetivo, análise de sensibilidade, métodos iterativos, aprendizagem por reforço (uma técnica de *machine learning*) e algoritmos genéticos.

Figura 6 – Gráfico do *software VOSViewer* com os artigos envolvendo a palavra-chave 'otimização via simulação' desde 2018



Fonte: *VOSViewer* (2022).

2.3 ANÁLISE ENVOLTÓRIA DE DADOS

A DEA é definida como um método não paramétrico de determinação de eficiência para operações com múltiplas entradas e saídas. Dessa forma, o método não requer a delimitação das interações desses parâmetros e não se restringe às medidas únicas entre insumos e produtos, sendo necessários apenas os conjuntos de dados de entrada e saída do sistema estudado para sua aplicação (FERREIRA; GOMES, 2012).

Embora os primeiros registros de estudos de DEA tenham surgido na teoria da produção microeconômica, de acordo com Ferreira e Gomes (2012), o trabalho de Farrell (1957) trouxe uma primeira proposta de métodos de análise mais robustos, que objetivavam criar uma métrica de eficiência genérica, que considerasse os insumos e os produtos de qualquer empresa.

Os trabalhos de Farrel (1957) culminaram nos estudos dos pesquisadores Charnes, Cooper e Rhodes (1978). Charnes, Cooper e Rhodes (1978) trouxeram a primeira abordagem estruturada do DEA como um método de cálculo, utilizado na ocasião para comparar a eficiência técnica de instituições públicas de ensino, mas sem a necessidade de converter os diversos parâmetros de entrada e saída deste estudo em uma base única nem estabelecer considerações arbitrárias sobre os fatores (CHARNES *et al.*, 1978). Esses autores apresentaram

o conceito de DMU como sendo uma entidade responsável pelo processo de transformação das entradas da análise em suas saídas. Estas DMU's, em aplicações reais, podem se traduzir em lojas, fábricas, *tollers*, transportadoras, centros de distribuição, entre outros (COOK; SEIFORD, 2009).

Para Mariano, Almeida e Rebelatto (2006), uma das formas mais adequadas para avaliar o desempenho de uma DMU é relacionar os insumos e produtos de cada DMU analisada. Cooper, Seiford e Tone (2007) propuseram a relação de insumos e produtos, de acordo com (3):

$$Produtividade = \frac{\text{produção (outputs)}}{\text{insumos (inputs)}} \quad (3)$$

A eficiência de uma DMU é outro importante conceito, pode ser definida como a divisão entre um indicador de desempenho e o seu correspondente máximo (MARIANO *et al.*, 2006). Com base nisso, a eficiência de uma DMU pode ser calculada por (4):


$$Eficiência = \frac{P}{P_{m\acute{a}x}} \quad (4)$$

sendo P a produtividade da DMU atual em análise e $P_{m\acute{a}x}$ a produtividade máxima dentre as DMU's analisadas.

O conceito de eficiência é importante para trabalhos em que é necessário propor uma classificação entre as DMU's. A eficiência é tratada como um número real que estará sempre na faixa de 0 a 1. Caso a eficiência de uma determinada DMU seja 1, esta é considerada eficiente, do contrário é ineficiente (MIRANDA *et al.*, 2017).

Esse conceito pode ser exemplificado com a representação da Figura 7, na qual os números de vendedores e vendas de uma determinada loja estão demarcados, nos eixos x e y , respectivamente. O encontro desses dois pontos mostra a razão vendas/vendedor em cada um dos 8 pontos, nomeados de A até H. A inclinação da reta ligando cada ponto à origem corresponde à razão vendas/vendedor, e a maior inclinação é alcançada pela linha da origem até B. Essa linha é chamada de fronteira de eficiência. A fronteira de eficiência sempre tocará um ou mais pontos do conjunto de dados, e assim, todos os demais pontos não-eficientes estarão envolvidos por essa linha, originando aí o nome da Análise Envoltória de Dados (COOPER; SEIFORD; TONE, 2007).

Figura 7 – Comparação de DMU's e representação do conceito de fronteira de eficiência



Fonte: Adaptado de Cooper; Seiford; Tone, (2007).

Existem duas formas de uma DMU não eficiente se tornar eficiente. A primeira é denominada de orientação a *inputs*, nela reduzem-se os recursos, mantendo-se constante os produtos. A segunda forma é denominada de orientação a *outputs*, na qual se mantêm constantes os recursos, enquanto se aumenta a produção (CHARNES *et al.*, 1978).

O modelo DEA - CCR desenvolvido inicialmente pelos pesquisadores Charnes, Cooper e Rhodes (1978) leva o nome dos autores, normalmente abreviado como CCR. Utilizando programação linear, procura-se, para cada DMU, maximizar a razão entre a soma ponderada das saídas e a soma ponderada das entradas, utilizando como variável de decisão os pesos.

Supondo que existam n DMUs: $DMU_1, DMU_2, \dots, DMU_n$, que utilizem m entradas e s saídas, as variáveis de entrada e saída para cada uma das $j = 1, \dots, n$ DMUs são selecionadas de forma a obedecer aos seguintes critérios:

- Há dados numéricos positivos para cada entrada e saída.
- As variáveis e a escolha das DMU's devem refletir o interesse dos gestores ou analistas na avaliação de desempenho.
- Devem-se preferir menores quantidades de entradas e maiores quantidades de saídas de modo que o índice de eficiência reflita esse princípio.
- As unidades de medidas das diferentes entradas e saídas não precisam ser as mesmas.

Inicialmente, o modelo de programação fracionária pode ser orientado aos insumos (*inputs*) ou aos produtos (*outputs*). Para cada uma dessas orientações, um conjunto de equações e inequações diferente é aplicado. Existem dois diferentes modelos de DEA CCR, multiplicador e envelope, e para cada um desses modelos, existe uma orientação ao produto e ao insumo do processo estudado (CHARNES *et al.*, 1978).

O modelo DEA CCR fracionário multiplicador com orientação ao *input* é dado por (5) – (8).

$$\max \theta = \left(\frac{\sum_{r=1}^s u_r y_{r0}}{\sum_{i=1}^m v_i x_{i0}} \right) \quad (5)$$

$$\frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{i=1}^m v_i x_{ij}} \leq 1, j = 1, 2, \dots, n \quad (6)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (7)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (8)$$

O modelo DEA CCR fracionário multiplicador com orientação ao *output* é dado por (9) – (12).

$$\min \theta = \left(\frac{\sum_{i=1}^m v_i x_{i0}}{\sum_{r=1}^s u_r y_{r0}} \right) \quad (9)$$

$$\frac{\sum_{i=1}^m v_i x_{ij}}{\sum_{r=1}^s u_r y_{rj}} \geq 1, j = 1, 2, \dots, n \quad (10)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (11)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (12)$$

sendo que $j \in (1, \dots, n)$ representa o índice da DMU j , y_{rj} é o valor da $r \in (1, \dots, s)$ variável de saída para $j \in (1, \dots, n)$ DMU, x_{ij} é o valor do insumo $i \in (1, \dots, m)$ variável de entrada para a $j \in (1, \dots, n)$ DMU, u_r é o peso dado para a $r \in (1, \dots, s)$ variável de saída; v_i é o peso dado para a $i \in (1, \dots, m)$ variável de entrada, θ é a eficiência relativa de DMU₀, que é a DMU sob análise; y_{r0} e x_{i0} são os parâmetros vinculados aos *Outputs* e *Inputs* da DMU sob análise.

A linearização do modelo representado por (5) – (8) é conhecido como modelo multiplicador com orientação ao *input* e está contemplado pelas expressões (13) – (17). Esse modelo é conhecido com CCR ou modelo com retornos constantes de escala (*Return constant to Scale* – CRS), e foi proposto por Charnes *et al.* (1978):

$$\max \theta = \sum_{r=1}^s u_r y_{r0} \quad (13)$$

$$\sum_{i=1}^m v_i x_{i0} = 1 \quad (14)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0, j = 1, 2, \dots, n \quad (15)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (16)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (17)$$

A linearização do modelo representado por (9) – (12) é conhecido como modelo multiplicador com orientação ao *output* e está contemplado pelas expressões (18) – (22). Esse modelo é conhecido com CCR ou modelo com retornos constantes de escala (*Constant Return to Scale* – CRS), e foi proposto por Charnes *et al.* (1978):

$$\min \theta = \sum_{i=1}^m v_i x_{i0} \quad (18)$$

$$\sum_{r=1}^s u_r y_{r0} = 1 \quad (19)$$

$$\sum_{i=1}^m v_i x_{ij} - \sum_{r=1}^s u_r y_{rj} \geq 0, j = 1, 2, \dots, n \quad (20)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (21)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (22)$$

Além do modelo CCR tradicional, Banker, Charnes e Cooper (1984) propuseram o modelo BCC, o qual parte da suposição de que o retorno constante de escala, utilizado como premissa no modelo CCR, poderia ser reconsiderado para, assim, admitir retornos variáveis de escala, na qual é acrescida a variável livre c_0 , de modo que $c_0 \in \mathbb{R}$ (FRIED *et al.*, 2008).

O modelo DEA-BCC multiplicador com orientação ao *input* é dado por (23) – (28):

$$\max \theta = \sum_{r=1}^s u_r y_{r0} + c_0 \quad (23)$$

$$\sum_{i=1}^m v_i x_{i0} = 1 \quad (24)$$

$$\sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} + c_0 \leq 0, j = 1, 2, \dots, n \quad (25)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (26)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (27)$$

$$c_0 \in \mathbb{R}, c_0 \rightarrow \text{fator de escala} \quad (28)$$

O modelo DEA-BCC multiplicador com orientação ao *output* é dado por (29) – (34):

$$\min \theta = \sum_{i=1}^m v_i x_{i0} + c_0 \quad (29)$$

$$\sum_{r=1}^s u_r y_{r0} = 1 \quad (30)$$

$$\sum_{i=1}^m v_i x_{ij} - \sum_{r=1}^s u_r y_{rj} + c_0 \geq 0, j = 1, 2, \dots, n \quad (31)$$

$$u_r \geq 0, r = 1, 2, \dots, s \quad (32)$$

$$v_i \geq 0, i = 1, 2, \dots, m \quad (33)$$

$$c_0 \in \mathbb{R}, c_0 \rightarrow \text{fator de escala} \quad (34)$$

sendo que $j \in (1, \dots, n)$ é o índice da DMU j ; y_{rj} é o valor da $r \in (1, \dots, s)$ variável de saída para $j \in (1, \dots, n)$; x_{ij} é o valor da DMU $i \in (1, \dots, m)$ variável de entrada para $j \in (1, \dots, n)$; u_r é o peso dado para a DMU $r \in (1, \dots, s)$ variável de saída; v_i é o peso dado para $i \in (1, \dots, m)$ variável de entrada, θ é a eficiência relativa da DMU₀, que é a DMU sob análise; y_{r0} e x_{i0} são os parâmetros vinculados aos *Outputs* e *Inputs* da DMU sob análise.

Em termos de ranqueamento, ou seja, de classificação ordenada de DMU's, os modelos convencionais de DEA, CCR e BCC, são normalmente desenvolvidos em um modo de autoavaliação, que permite a análise de eficiência de cada DMU pela aplicação de um conjunto de pesos favoráveis para essa mensuração (HATAMI-MARBINI *et al.*, 2022).

Existem muitas abordagens para classificar completamente DMUs eficientes e ineficientes. De acordo com Adler, Friedman e Sinuany-Stern (2002), os métodos de classificação foram divididos em seis grupos:

- Avaliação de uma matriz de eficiência cruzada - as unidades são autoavaliadas e avaliadas pelos pares;
- Método da supereficiência - classifica pela exclusão da unidade que está sendo pontuada do programa linear duplo e uma análise da mudança na Fronteira de Pareto;
- Basear-se em *benchmarking* - as unidades são altamente classificadas se forem escolhidas como um alvo útil para muitas outras unidades;
- Técnicas estatísticas multivariadas - geralmente são aplicadas após a classificação dicotômica DEA;
- Classificar as unidades ineficientes por meio de medidas proporcionais de ineficiência;
- Requerer a coleta de informações adicionais e preferenciais dos tomadores de decisão e combinar a abordagem DEA e metodologias de decisão de múltiplos critérios.

Modelos DEA clássicos consideram DMUs com $w_0 = 1$ como eficientes e DMUs com $w_0 < 1$ como ineficientes. Essa situação ocorre, caso haja a possibilidade de que várias DMUs tenham $w_0 = 1$; ou seja, torna-se complexo diferenciar entre DMUs.

Para resolver essa limitação, Andersen e Petersen (1993) propuseram um conceito conhecido como supereficiência, que determina a diferença entre as DMUs que apresentam $\theta = 1$. A supereficiência consiste em retirar do modelo a restrição $(\sum_{i=1}^m v_i x_{ij} - \sum_{r=1}^s u_r y_{rj} + c_0 \geq 0, j = 1, 2, \dots, n; j \neq 0)$, sendo $j \neq 0$ diz respeito a DMU0, que é a DMU sob análise. Em seguida, analisar a mudança na fronteira de eficiência, permitindo que as demais DMU's eficientes atinjam eficiências acima de 1 (ANDERSEN; PETERSEN, 1993).

Segundo Miranda *et al.* (2017), Marins *et al.* (2020) e Khare *et al.* (2021) as vantagens da utilização da supereficiência como método de ranqueamento incluem:

- o uso do método da supereficiência não aumentar a complexidade matemática envolvida na análise.
- a modelagem em VBA - Excel realizada consumir aproximadamente os mesmos tempos computacionais obtidos na resolução dos modelos, com ou sem supereficiência, e, por

apresentarem baixa ordem de grandeza, permitirem uma rápida interação de especialistas;

- a ocorrência menos frequente de soluções infactíveis (COOPER; SEIFORD; TONE, 2007).

Porém, existem outras técnicas de ranqueamento possíveis e com diferentes interesses de aplicação, visto que esse ranqueamento implica em uma capacidade discriminatória limitada, devido à possível existência de mais de uma DMU eficiente e, também, pela subjetividade da atribuição dos pesos sobre cada variável estudada (FU, 2021).

A eficiência cruzada é uma possibilidade de ranqueamento que propõe alternativas que permitem:

- Gerar um *ranking* completo das DMU's (DOYLE; GREEN, 1994).
- Evitar ponderações de peso irrealistas no DEA, devido à ausência de restrições de peso propostas por especialistas (ANDERSON; HOLLINGSWORTH, 2002).
- Diferenciar desempenhos altos e baixos mesmo dentre as DMU's eficientes (BOUSSOFIANE *et al.*, 1991).

Devido a essas vantagens e as desvantagens já conhecidas das técnicas tradicionais de ordenação de DMU's, a utilização de eficiência cruzada tem sido, extensivamente estudada, desde a década de 90 (KAO; LIU, 2022). O propósito da eficiência cruzada consiste em determinar o ranqueamento pela comparação da DMU em relação a si mesma e a seus pares. Porém diferentes abordagens de agregação e consideração dos pesos relativos para essas comparações são possíveis, conforme avaliado por Fu *et al.* (2022).


A abordagem de fronteira invertida é outra opção para ranquear DMU's eficientes, durante a aplicação da DEA. Esse método, proposto por Entani *et al.* (2002), consiste em utilizar os *inputs* do DEA no lugar de seus *outputs* e vice-versa, propondo, assim, uma métrica da ineficiência de cada DMU.

Com essa métrica combinada ao resultado de eficiência da aplicação padrão do DEA, o método de fronteira invertida permite calcular a denominada eficiência composta, conforme ilustrado na Figura 8 e expresso por (35), que permite uma melhor discriminação dos resultados da DEA, para algumas aplicações específicas (GOBBO *et al.*, 2021):

$$E_k^* = \frac{(\theta_k^S - \theta_k^I + 1)}{2} \quad (35)$$

sendo E_k^* a eficiência composta da DMU k , θ_k^S a eficiência padrão (*standard*) calculada pela DEA para a DMU k e θ_k^I a eficiência invertida para a DMU k .

Figura 8 – Análise da Fronteira de Eficiência Invertida



Fonte: Moreira; Mello; Meza, (2019).

2.4 FUNÇÃO *DESIRABILITY*

Os estudos de OvS multiobjetivo frequentemente utilizam métodos de aglutinação para as variáveis de saída do processo sob análise. Estes métodos são constituídos, em sua maioria, por equações ponderadas por pesos, que utilizam diferentes artifícios matemáticos para converter as diferentes saídas do sistema e uni-las em um único parâmetro de análise (KALKAN *et al.*, 2022).

A função *Desirability* foi desenvolvida por Derringer e Suich (1980), e por meio dela cada objetivo é transformado em uma variável de grandeza adimensional, denominada *Desirability* individual d_i , que depois é agregada a uma única variável resposta, denominada *Desirability* geral D .

Essa função é baseada na ideia de que a qualidade de um produto ou processo se torna completamente inaceitável, caso uma das suas características fique fora do limite desejável (CANDIOTI *et al.*, 2014).

De acordo com Montgomery (2019), o objetivo é garantir que todas as respostas fiquem dentro dos critérios almejados e, ao mesmo tempo, obter o melhor valor para uma resposta unificada. Derringer e Suich (1980) afirmam que esse objetivo é garantido ao aglutinar múltiplas respostas em uma única função, que deve, posteriormente, ser otimizada por meio de um algoritmo de otimização não linear (SILVA *et al.*, 2021).

Uma vantagem deste método é a que a utilização da média geométrica para cálculo do parâmetro D , que a solução global seja alcançada de maneira balanceada, permitindo desta forma que todas as respostas atinjam os valores esperados e direcionando o algoritmo a se aproximar das especificações impostas (RODRIGUES *et al.*, 2015).

Silva *et al.* (2019 e 2021) apresentaram sistemáticas para calcular funções *Desirability*

para três situações distintas:


- *Desirability* maior, melhor: abordagem utilizada quando o objetivo deve ser maximizado, como está em (36):

$$d = \begin{cases} 0, & \text{se } y_i < L_i \\ \left[\frac{y_i - L_i}{U_i - L_i} \right]^s, & \text{se } L_i \leq y_i \leq U_i \\ 1, & \text{se } y_i > U_i \end{cases} \quad (36)$$

sendo L_i e U_i , respectivamente, o menor e o maior valor aceitável para o objetivo, y_i o valor da função objetivo obtido e s o peso estipulado pelo analista para determinar o quão importante é y_i ficar o mais próximo possível do U_i .

É ilustrado, na Figura 9, o comportamento da função *Desirability* maior, melhor, em função de valores para y_i e s .

Figura 9 – Comportamento da função *Desirability* maior, melhor, para diferentes valores de s



Fonte: Candiotti (2014).


- *Desirability* menor, melhor: abordagem utilizada, quando o objetivo deve ser minimizado, como está em (37):

$$d = \begin{cases} 0, & \text{se } y_i > U_i \\ \left[\frac{y_i - U_i}{L_i - U_i} \right]^t, & \text{se } L_i \leq y_i \leq U_i \\ 1, & \text{se } y_i < L_i \end{cases} \quad (37)$$

sendo as variáveis U_i , L_i e y_i análogas ao explicado para *Desirability* maior, melhor e t o valor estipulado pelo analista para o quão importante é y_i ficar o mais próximo possível de L_i .

É ilustrado, na Figura 10, o comportamento da função *Desirability* menor, melhor, em função de valores de y_i e t .

Figura 10 – Comportamento da função *Desirability* menor, melhor para diferentes valores de t



Fonte: Candiotti (2014).


- *Desirability target* ou objetivo: abordagem utilizada quando o objetivo é atingir determinado valor, como está em (38):

$$d = \begin{cases} \left[\frac{y_i - L_i}{T_i - L_i} \right]^s, & \text{se } L_i \leq y_i \leq T_i \\ \left[\frac{y_i - U_i}{T_i - U_i} \right]^t, & \text{se } T_i \leq y_i \leq U_i \\ 0, & \text{se } y_i \leq L_i \text{ ou } y_i \geq U_i \end{cases} \quad (38)$$

sendo T_i o valor alvo a ser atingido pelo objetivo. Nesse caso, L_i e U_i os valores mínimo e máximo toleráveis que, quando são extrapolados, a função retorna valor zero.

É ilustrado, na Figura 11, o comportamento da função *Desirability target* em função de valores de y_i , s e t .

Figura 11 – Comportamento da função *Desirability target* para diferentes valores de s e t



Fonte: Candioti (2014).

Em (39) está a função aglutinadora *Desirability* geral, com pesos w_i para cada objetivo, utilizados como critério de priorização entre os objetivos, esta é uma média geométrica das d_i funções normalizadas (SILVA *et al.*, 2019):

$$D = \left(\prod_{i=1}^p d_i^{w_i} \right)^{\frac{1}{\sum_{i=1}^p w_i}} \quad (39)$$

sendo i o número de objetivos formulados pela função *Desirability* individual, d_i a função *Desirability* individual do objetivo i e w_i o peso atribuído ao objetivo i .

2.5 DELINEAMENTO DE EXPERIMENTOS

O DOE é um conjunto de métodos estatísticos focados em delinear e organizar a execução de experimentos científicos, considerado um elemento crucial para o sucesso da pesquisa acadêmica, ao longo de várias décadas (LEME *et al.*, 2014).

Segundo Montgomery (2017), considera-se o DOE como a conjunção de técnicas auxiliares à geração e análise de rotinas experimentais, nas quais é possível que diversos fatores sejam variados, intencionalmente ao mesmo tempo, ao invés de variar apenas um fator de cada vez, fixando os demais.

As vantagens de construir a matriz de experimentos com auxílio do DOE contemplam:

- A redução do número de experimentos necessários para avaliação, quando comparado com o espaço de busca completo das variáveis analisadas (SWISHER *et al.*, 2000).
- A possibilidade de avaliar efeitos de interação entre as variáveis com uma precisão elevada (GONÇALVES *et al.*, 2019).
- A possibilidade de avaliar efeitos de interação entre os fatores em diferentes níveis (FENG *et al.*, 2020).


Ao longo dos anos, os estudos no campo do DOE trouxeram novas possibilidades de aplicação, e técnicas diferentes foram testadas e validadas como novas formas de criar e analisar as matrizes de experimento.

Dentre essas técnicas, destacam-se: o Arranjo Ortogonal de Taguchi (*Taguchi Orthogonal Array - TOA*), o Método de Superfície de Resposta (*Response Surface Method - RSM*) e, mais recentemente, o HLD. Cada uma dessas técnicas apresenta prós e contras que as tornam mais adequadas para tipos de estudos específicos, e, eventualmente, é comum encontrar trabalhos comparando a eficácia de dois ou mais métodos (CHONG *et al.*, 2021).

Assim, desenhos experimentais são considerados o método mais eficiente para identificar e otimizar os fatores significativos para alcançar um resultado satisfatório devido às suas vantagens, como fornecer informações precisas com um número mínimo de execuções experimentais, identificar as interações dos fatores e permitir otimizações de múltiplas respostas (BAIGMOHAMMADI *et al.*, 2020).

A Figura 12 mostra uma visão geral de como os métodos de delineamento de experimentos mais comumente encontrados na literatura podem ser classificados, com relação à técnica e à aplicação (NARENDERAN *et al.*, 2019).

Figura 12 – Classificação dos métodos de delineamento de experimentos mais comuns




Fonte: Adaptado de Narendaran *et al.* (2019).

É importante ressaltar que embora o LHD seja classificado como um delineamento de experimentos, esta técnica não se enquadra em nenhuma das duas classificações, pois trata-se de um design gerado de forma randomizada.


A Figura 13 mostra um gráfico das palavras-chave encontradas em uma pesquisa na base de dados *Scopus*, considerando artigos publicados, entre 2018 e 2022, contendo o termo ‘*desing of experiments*’, gerado com auxílio do *software VOSViewer*.

Nota-se uma presença de vários tópicos de estudo em diversas áreas de especialização, porém uma relação mais próxima com o tema ‘*design of experiments*’ é percebida nos trabalhos envolvendo otimização, *machine learning*, método dos elementos finitos.



Na Figura 14, um novo gráfico foi construído com base nas publicações realizadas em 2018, considerando as palavras ‘design of experiments’, ‘simulation’ e ‘simulation’.

Figura 14 – Gráfico do software VOSViewer com os artigos envolvendo a palavra-chave 'delineamento de experimentos', 'otimização' e 'simulação', combinada, publicados desde 2018



Fonte: VOSViewer (2022).

2.5.1 Método de Taguchi

O TOA é uma técnica de DOE modificado que teve suas primeiras contribuições feitas pelo pesquisador japonês Dr. Genichi Taguchi, na década de 1940, cerca de 25 anos após a introdução do DOE original por R.A. Fisher. Taguchi desenvolveu o método em questão focando, primariamente, em produzir materiais de alta qualidade, mantendo um baixo custo de manufatura. O método acabou por ser nomeado em homenagem ao seu criador com a evolução dos estudos dessa técnica (ROY, 2001).

Esse método consiste em uma estratégia de minimização de número de experimentos, baseada na aplicação de arranjos ortogonais saturados, ou seja, matrizes de experimentos que não contemplam o espaço de busca completo de todas variáveis e fatores, mas sim, um pequeno número de experimentos, focados em trazer uma precisão e robustez de análise.

As matrizes de Taguchi podem ser encontradas na literatura em diversos formatos, construídas de forma padrão, visando facilitar a escolha do pesquisador, tendo em mãos, apenas, 2 informações: o número de parâmetros p e o número de níveis de variação para cada parâmetro l (CHONG *et al.*, 2021).

As etapas gerais envolvidas no Método Taguchi são as seguintes (ROY, 1990):

1. Definir o objetivo do processo ou, mais especificamente, um valor alvo para uma medida de desempenho do processo. O alvo de um processo, também, pode ser um mínimo ou máximo. O desvio na característica de desempenho do valor alvo é usado para definir a função de perda para o processo.
2. Determinar os parâmetros de projeto que afetam o processo. Parâmetros são variáveis dentro do processo que afetam a medida de desempenho, e que podem ser, facilmente, controladas. O número de níveis em que os parâmetros devem ser variados deve ser especificado. Aumentar o número de níveis para variar um parâmetro aumenta o número de experimentos a serem conduzidos.
3. Criar matrizes ortogonais para o desenho dos parâmetros, indicando o número e as condições de cada experimento. A seleção das matrizes ortogonais é baseada no número de parâmetros e nos níveis de variação de cada parâmetro.
4. Conduzir os experimentos indicados na matriz completa para coletar dados sobre o efeito na medida de desempenho, preferencialmente em ordem aleatória.
5. Analisar os dados para determinar os efeitos e interações dos diferentes parâmetros na medida de desempenho.

Em contraste com os delineamentos estatísticos clássicos, o design de Taguchi propõe um projeto fatorial fracionário geral, com base em um número selecionado de fatores e níveis de variação por fator para identificar o menor número de experimentos a serem realizados (RAZA *et al.*, 2022).

Os principais fatores e interações que são propensos a serem significativos, bem como os níveis em que eles são variados devem ser definidos, previamente, por um especialista. Com base nesse conhecimento, as matrizes ortogonais de Taguchi são selecionadas avaliando o benefício entre tempo de execução, utilização de recursos e qualidade dos resultados (MEDAN *et al.*, 2017).

Os efeitos de vários parâmetros diferentes na característica final de desempenho em um arranjo saturado de experimentos podem ser examinados usando o arranjo ortogonal proposto por Taguchi. Uma vez determinados os parâmetros que afetam um processo e que podem ser controlados, devem ser determinados os níveis em que esses parâmetros devem ser variados.

Determinar quais níveis de uma variável testar, requer uma compreensão profunda do processo, incluindo o valor mínimo, máximo e atual do parâmetro. Além disso, é importante considerar a existência de ruídos no arranjo, ou seja, de parâmetros que afetam o processo, mas

que, entretanto, não podem ser controlados. Ao criar um arranjo de Taguchi, o modelador deve se atentar a essas condições, para não escolher uma matriz com poucos experimentos, que acabe por inviabilizar a análise de efeitos (SUN *et al.*, 2018).

Após as rodadas experimentais, o efeito de cada variável pode ser estudado com base na relação sinal-ruído razão (S/R) (*signal-noise ratio*, *S/N Ratio* ou *SNR*), isto é, maximizar ou minimizar as razões S/R.

A relação sinal-ruído mede os desvios de resposta em relação ao valor alvo sob influência de diferentes condições de ruídos ambientes, alheios ao controle do processo proposto pelo DOE (PANDA; SARKAR, 2022). Existem 3 diferentes equações para cálculo da razão sinal-ruído, exibidos na Tabela 2.

Tabela 2 – Modelos de cálculo da razão sinal-ruído

Razão Sinal- Ruído	Objetivo	Equação	
Maior-melhor	Maximização	$S/R = -10 * \log \left(\frac{\sum \frac{1}{y^2}}{n} \right)$	(40)
Nominal-melhor (<i>target</i>)	Aproximação de um valor objetivo	$S/R = -10 * \log(\sigma^2)$	(41)
Menor-melhor	Minimização	$S/R = -10 * \log \left(\frac{\sum y^2}{n} \right)$	(42)

Fonte: Hussein *et al.*, (2022)


sendo *S/R* a razão sinal-ruído, *y* o resultado do experimento avaliado em cada rodada, *n* o número de experimentos e σ o desvio padrão calculado para o espaço amostral avaliado.

A Figura 15 mostra um gráfico das palavras-chave encontradas em uma pesquisa na base de dados *Scopus*, considerando artigos publicados, entre 2018 e 2022, contendo o termo ‘*taguchi method*’, gerado com auxílio do *software VOSViewer*.

Diversos tópicos aparecem associados ao tema, porém os mais próximos contemplam trabalhos envolvendo as palavras-chave otimização multiobjetivo, delineamento de experimentos, estudo controlado, eficiência, e alguns termos técnicos de Engenharia, tais como tensão, fricção, microscopia, dureza de superfície, entre outros.

são 2 parâmetros de entrada (n), que foram divididos em 7 intervalos iguais (m). Para cada cruzamento desses intervalos, um ponto foi atribuído, de forma a não permitir *overlaps* de intervalos, mas cobrindo de forma equiprobabilística o espaço amostral completo. Quando se constrói esse raciocínio com dois eixos, tem-se uma figura popularmente chamada de quadrado latino. Quando 3 ou mais eixos são avaliados, tem-se o chamado hipercubo latino (FENG *et al.*, 2020).

Figura 16 – Exemplos de quadrados latinos



Fonte: Adaptado de Luo; Ji; Lu, (2019).

A Figura 17 mostra um panorama das palavras-chave encontradas em uma pesquisa na base de dados *Scopus*, considerando artigos publicados, entre 2018 e 2022, contendo o termo ‘*latin hypercube*’. Nota-se uma presença mais concentrada de trabalhos envolvendo otimização, métodos de Monte Carlo, análises de incerteza, delineamento de experimentos, e, novamente, algoritmos genéticos.


3 MODELAGEM DO PROBLEMA LOGÍSTICO DE EXPEDIÇÃO

3.1 DESCRIÇÃO DO PROBLEMA

O modelo de simulação aplicado nos estudos foi construído com base em observações operacionais e medições de tempos, em uma operação logística de uma empresa localizada na região do Vale do Paraíba, interior do estado de São Paulo, que não será identificada. A validação do modelo foi feita comparando os dados do ERP da empresa, em diferentes condições operacionais, com os dados de saída do modelo, parametrizado para simular as mesmas condições.

A Figura 18 mostra o fluxograma do método aplicado para construção e validação do modelo conceitual, construção e validação do modelo computacional, baseado em dados operacionais, seguida pela realização das simulações e avaliação dos resultados (MONTEVECHI *et al.*, 2007).

Figura 18 – Método aplicado para construção do modelo e estudo de simulação



Fonte: Adaptado de Montevechi *et al.* (2007).

A operação consiste em um prédio de expedição central, equipado com 9 docas para atracamento de caminhões a serem carregados. Devido à disponibilidade de recursos e pessoas, essas docas não são sempre utilizadas simultaneamente, e o número de docas ativas é uma das variáveis de entrada do modelo.

Os recursos envolvidos consistem em pessoas do time operacional, empilhadeiras para movimentação das cargas paletizadas. Estes também serão variáveis de entrada para o sistema simulado. Para que um palete seja movimentado, é necessário que haja uma empilhadeira e um operador de movimentação disponíveis, simultaneamente. Este par de recursos será mantido ocupado até que a movimentação do palete em questão seja finalizada.

Os paletes para carregamento serão tratados como uma quantidade irrestrita dentro do modelo, pois na operação real, nenhum caminhão é direcionado para o carregamento sem que sua carga esteja disponível no armazém, portanto, não é necessário simular um evento no qual o carregamento de um caminhão seria interrompido por restrições do recurso palete. Para esses paletes, existem 4 tipos diferentes de consolidação de carga que implicam em tempos diferentes para movimentação pelas empilhadeiras, devido à estabilidade do material paletizado. Esse tipo de carga também é uma das variáveis exploradas pelo modelo.

Essa operação funciona em dois turnos, e a distribuição de recursos (operadores e equipamentos) dentre os turnos operacionais também será tratada como uma das variáveis de entrada. Como uma das variáveis de saída, o modelo exibirá, ao fim de cada simulação, o número de paletes carregados dentro do expediente.

3.2 MODELAGEM E RESOLUÇÃO

O software *ProModel*TM fornece dentro de suas funcionalidades uma ferramenta para atrelar os custos operacionais de cada recurso e operação, a ser contabilizado por hora trabalhada ou evento ocorrido, conforme preferência do usuário. Ao fim de cada rodada de simulação, essa ferramenta permite calcular o custo total envolvido na operação, este custo é a segunda variável de saída a ser estudada.


A Figura 19 mostra o fluxograma operacional utilizado para construção do modelo, baseado nas informações presentes, na Tabela 3, na qual estão listadas as variáveis, recursos, entidades e locais empregados pelo software para execução da simulação. A Figura 20 mostra uma captura de tela do software *ProModel*, ilustrando o modelo após sua construção e validação.

Tabela 3 – Descrição dos fatores envolvidos na construção do modelo no *ProModel*

Fator	Tipo	Descrição
Portaria	Local	Ponto de entrada e saída dos caminhões no modelo
Doca	Local	Ponto de atracamento dos caminhões, onde ocorre o carregamento dos paletes
Armazém	Local	Ponto de entrada dos paletes no modelo
Área de Separação	Local	Ponto onde os paletes são acumulados até que ocorra a movimentação para dentro do caminhão
Portaria	Local	Ponto de entrada e saída dos caminhões no modelo
Doca	Local	Ponto de atracamento dos caminhões, onde ocorre o carregamento dos paletes
Caminhão	Entidade	Consiste em cada caminhão que passa pela portaria e se dirige a uma das docas
Paletes	Entidade	Consiste em cada um dos paletes que será movimentado pelos operadores e carregado em um dos caminhões
Turnos	Variável	Número de turnos ativos, utilizado para calcular por quanto tempo o modelo será executado em cada replicação
Docas	Variável	Número de docas em operação
Operadores	Variável	Número de operadores de movimentação de carga disponíveis
Empilhadeiras	Variável	Número de empilhadeiras de carga disponíveis
Carga	Variável	Número de paletes a ser carregado em cada caminhão, sorteado individualmente para cada caminhão, com base em uma distribuição de dados coletada na operação


Fonte: Autor (2022).

Figura 19 – Fluxograma básico do modelo de simulação



Fonte: Autor (2022).

Figura 20 – Captura de Tela do Modelo de Simulação elaborado no software ProModel™



Fonte: ProModel™ (2022).

A sistemática, conforme demonstrado na Figura 21, consiste na avaliação de um problema de otimização multiobjetivo via simulação, visando a redução do espaço de busca pela combinação das técnicas de DOE e DEA.


O procedimento se inicia com a validação do modelo de simulação e, em seguida, a definição de quais serão as variáveis de entrada a serem estudadas, e quais são os parâmetros de saída a serem otimizados, bem como seus objetivos. Em se tratando de uma otimização multiobjetivo, há sempre ao menos 2 parâmetros de saída. No caso do modelo estudado a validação foi feita pela comparação direta dos dados de saída das execuções do modelo com os dados sistêmicos da empresa, tanto para as quantidades operadas, quanto para os custos estimados da operação.

Em seguida, os arranjos de DOE para cada método são elaborados, de forma a atender as condições da regra de ouro do DEA, tendo em consideração o número de parâmetros de entrada. Com as matrizes de experimentos geradas, tem-se a definição das DMUs para estudo, e executa-se então o modelo de simulação.

Os resultados das simulações conforme os arranjos experimentais de cada técnica de DOE são então tratados pela análise do DEA – BCC, em duas orientações diferentes. Com isto, é possível identificar e ranquear as DMUs eficientes em cada conjunto de dados e, por fim, propor novos espaços de busca menores, que estarão compreendidos dentro da faixa de variação das duas DMUs mais eficientes de cada conjunto de dados. Estes espaços de busca são

finalmente utilizados, junto a função *Desirability*, num algoritmo de otimização.

Figura 21 – Método de redução do espaço de busca proposto para o problema de OvS multiobjetivo sob estudo



Fonte: Autor (2022).

A seguir, passa-se a descrever cada etapa da sistemática proposta para resolver o problema logístico de expedição da empresa objeto do estudo.

Etapa 1: Determinação das variáveis de decisão e seus níveis de variação

Na Tabela 4 estão as variáveis de decisão e seus respectivos limites de variação.

Tabela 4 – Descrição das variáveis de entrada do modelo

Entradas	Variável	Mínimo	Máximo
x_1	Número de Operadores	2	18
x_2	Número de Docas ativas	1	9
x_3	Número de Empilhadeiras	1	9
x_4	Tipo de Carga	1	4
x_5	Número de turnos	1	2

Fonte: Autor (2022).

Etapa 2: Determinação das variáveis de saída a serem otimizadas

Na Tabela 5 estão os fatores de saída (produtos) do modelo e seus objetivos, que serão utilizados para a análise do DEA.

Tabela 5 – Descrição das variáveis de saída do modelo

Saídas	Variável	Objetivo
y_1	Custo médio por caminhão carregado	Minimizar
y_2	Número de paletes expedidos	Maximizar

Fonte: Autor (2022).

Etapas 3 e 4: Seleção do Arranjo de Taguchi e de Hipercubo Latino, e geração das matrizes de experimentos

Com o arranjo dos dados iniciais destas simulações, foram criadas matrizes de experimentos com 32 execuções por dois diferentes métodos de DOE: o método de Taguchi e o método do Hipercubo Latino. Essas matrizes estão na Tabela 6 – Delineamento de Experimentos pelo Método de Taguchi e na Tabela 7 – Delineamento de Experimentos pelo Método do Hipercubo Latino. O número de 32 execuções foi determinado de forma a atender

a regra de ouro do DEA, a qual recomenda que o número de variáveis de entrada e saídas não exceda um terço do número de DMU's.

Tabela 6 – Delineamento de Experimentos pelo Método de Taguchi

Variável	X1	X2	X3	X4	X5
Experimento	Número de Operadores	Número de Docas ativas	Número de Empilhadeiras	Tipo de carga	Número de turnos
1	5	3	5	3	1
2	1	4	3	2	2
3	5	8	2	0	2
4	9	1	9	0	1
5	4	5	2	3	1
6	8	2	5	0	2
7	9	2	6	3	2
8	4	4	8	1	1
9	7	1	1	3	1
10	1	7	4	3	1
11	2	5	5	1	2
12	4	1	4	2	2
13	2	3	6	2	1
14	5	2	3	1	1
15	7	5	7	2	1
16	6	2	8	2	1
17	8	9	8	3	2
18	2	4	9	3	2
19	1	3	7	0	2
20	8	6	2	2	1
21	9	7	2	1	2
22	3	8	5	2	1
23	1	8	1	1	1
24	5	7	1	2	2
25	7	3	4	1	2
26	4	6	6	0	2
27	3	4	4	0	1
28	3	1	7	1	2
29	2	9	3	0	1
30	6	5	1	0	2
31	3	6	3	3	2
32	6	9	9	1	1

Fonte: Autor (2022).

Tabela 7 – Delineamento de Experimentos pelo Método do Hipercubo Latino

Variável	x₁	x₂	x₃	x₄	x₅
Experi- mento	Número de Operadores	Número de Docas ativas	Número de Empilhadeiras	Tipo de carga	Número de turnos
1	8	5	8	2	1
2	4	4	5	1	1
3	6	8	5	1	2
4	6	2	3	2	1
5	7	7	8	2	1
6	1	8	1	2	2
7	2	7	3	4	2
8	9	9	6	4	1
9	4	1	1	3	1
10	1	3	7	1	2
11	2	1	7	3	2
12	5	6	1	1	1
13	3	7	7	1	1
14	2	6	4	1	1
15	3	5	4	1	1
16	9	4	1	1	1
17	8	6	3	3	1
18	1	5	9	3	2
19	7	3	4	2	2
20	6	1	8	1	1
21	3	9	1	1	1
22	4	2	2	1	1
23	3	1	5	2	1
24	6	5	7	4	1
25	2	3	2	3	1
26	8	4	6	2	1
27	7	7	6	3	1
28	8	8	4	4	1
29	5	2	9	2	1
30	1	1	2	3	2
31	6	2	2	3	1
32	5	3	6	1	1

Fonte: Autor (2022).

Etapa 5: Execução do modelo de simulação

Os dois arranjos experimentais foram carregados no *software* e os experimentos foram realizados de forma randomizada até que todas as execuções dos dois arranjos de DOE fossem cumpridas.

Etapa 6: Determinação do cenário de supereficiência DEA-BCC

Com base nos resultados das simulações propostas pelas duas tabelas de DOE, foi possível a aplicação do modelo DEA BCC orientado aos insumos e aos produtos, visando identificar, por meio de métricas de supereficiência, quais seriam as DMU's mais eficientes em cada orientação. Isso proporcionou quatro conjuntos de dados diferentes, conforme contemplado, na Tabela 8.

Tabela 8 – Conjuntos de dados de análise divididos por método de DOE e orientação de DEA

Conjunto de Dados	Método de DOE	Orientação do DEA - BCC
1	Taguchi	Insumo
2	Taguchi	Produto
3	LHD	Insumo
4	LHD	Produto

Fonte: Autor (2022).

A aplicação do DEA – BCC em cada conjunto de dados possibilitou estabelecer um ranqueamento das 32 DMUs, conforme será mostrado no capítulo 4. Quando ordenadas em ordem decrescente, novos espaços de busca puderam ser identificados considerando-se o *range* entre as duas primeiras posições, conforme exposto na Tabela 9.

Tabela 9 – DMUs mais eficientes de cada conjunto de dados, após ranqueamento

Conjunto de Dados	Método de DOE	Orientação do DEA - BCC	DMU mais eficiente	Segunda DMU mais eficiente
1	Taguchi	Insumo	3	9
2	Taguchi	Produto	10	29
3	LHD	Insumo	6	10
4	LHD	Produto	6	16

Fonte: Autor (2022).

Etapa 7 e 8: Ranqueamento das DMU's eficientes e Definição de novos ranges de variação para as variáveis de decisão

Conforme explicado, as duas DMU's mais eficientes de cada conjunto de dados trouxeram novos espaços de busca reduzido propostos, dispostos na Tabela 10.

Tabela 10 – Novos espaços de busca reduzidos pela aplicação do DEA sobre os conjuntos de dados

Variável	x_1		x_2		x_3		x_4		x_5	
Descrição	Operadores		Docas ativas		Empilhadeiras		Tipo de carga		Turnos	
Limites	Inferior	Superior	Inferior	Superior	Inferior	Superior	Inferior	Superior	Inferior	Superior
Espaço de busca completo	1	9	1	9	1	9	1	4	1	2
DEA BCC Insumos - DOE Taguchi	9	9	2	7	2	6	2	4	2	2
DEA BCC Produtos - DOE Taguchi	7	8	1	2	1	5	1	4	1	2
DEA BCC Insumos - DOE LHD	1	7	3	8	1	4	2	2	2	2
DEA BCC Produtos - DOE LHD	1	4	1	8	1	1	2	3	1	2

Fonte: Autor (2022).

Etapa 9: Otimização do modelo de simulação

Estes novos espaços de busca foram utilizados em conjunto com o otimizador nativo do software *ProModel* conhecido, comercialmente, como *SimRunner*. Nessa aplicação, primeiramente foi executada uma rodada de otimização pelo algoritmo nativo do *SimRunner* colocando como parâmetros de objetivo a minimização da variável de saída y_1 (custo médio por veículo carregado) e a maximização da variável de saída y_2 (quantidade de paletes expedidos).

Cabe informar que a forma pela qual o *SimRunner* otimiza várias funções é por meio de uma aglutinação, feita pela soma simples dessas funções, ou seja, não levando em consideração as diferentes grandezas escalares e unidades de medida. Contudo o uso da função *Desirability* dentro do *SimRunner* contorna esses graves problemas matemáticos.

Para trazer mais robustez ao estudo foi proposta uma abordagem diferenciada para esta otimização: ao invés de utilizar o algoritmo otimizador do *SimRunner*, uma função *Desirability* ponderada, dada por (41), foi aplicada para converter as duas variáveis de saída em um parâmetro de otimização único, para o qual buscou-se a maximização. Este parâmetro único é obtido pela média geométrica das funções *Desirability* individuais de cada objetivo, sendo d_1 a função objetivo do custo (39), que deve ser minimizado e, d_2 , a função objetivo da quantidade (40), que deve ser maximizada. O código utilizado no *software* para cálculo da função *Desirability* está no Apêndice A.

$$d_1 = \begin{cases} 1, y_1 < L \\ \left[\frac{y_1 - U}{L - U} \right]^R, L < y_1 < U \\ 0, y_1 > U \end{cases} \quad (39)$$

$$d_2 = \begin{cases} 0, y_2 < L \\ \left[\frac{y_2 - L}{U - L} \right]^R, L < y_2 < U \\ 1, y_2 > U \end{cases} \quad (40)$$

$$D = (d_1^{0,5} \times d_2^{0,5}) \quad (41)$$

Os valores de L e U para as variáveis y_1 e y_2 foram definidos com base na experiência do time de modelagem envolvido e com consultas ao time de operação da empresa na qual o modelo foi inspirado, conforme demonstrado na Tabela 11.

Tabela 11 – Valores de L e U considerados para o cálculo da função *Desirability* de cada saída

Output	Descrição	Função <i>Desirability</i>	L	U
y_1	Custo médio por veículo carregado (R\$)	d_1	13,00	119,00
y_2	Quantidade de paletes expedidos	d_2	17	223

Fonte: Autor (2022).

Esta função *Desirability* foi, inicialmente, testada com pesos iguais, divididos 50% para cada variável y_1 e y_2 . Com essa estrutura de otimização, o procedimento de busca com o espaço completo, seguido pelas rodadas com espaços de busca reduzidos pelo DEA foi executado. Os resultados também foram coletados, conforme está na Tabela 12.

Tabela 12 – Rodadas de Otimização via função *Desirability* com auxílio do *SimRunner*

Rodada	Nome	Descrição
1	Otimização via <i>Desirability</i> - Base	Espaço de busca completo
2	Otimização via <i>Desirability</i> - Conjunto 1	Limites de busca propostos pelas duas DMU's supereficientes - DEA BCC I Taguchi
3	Otimização via <i>Desirability</i> - Conjunto 2	Limites de busca propostos pelas duas DMU's supereficientes - DEA BCC O Taguchi
4	Otimização via <i>Desirability</i> - Conjunto 3	Limites de busca propostos pelas duas DMU's supereficientes - DEA BCC I LHD
5	Otimização via <i>Desirability</i> - Conjunto 4	Limites de busca propostos pelas duas DMU's supereficientes - DEA BCC O LHD

Fonte: Autor (2022).

Visando, também, a melhor compreensão da resposta da técnica aplicada, uma análise de sensibilidade foi realizada, atribuindo diferentes pesos aos componentes da função *Desirability* geral do modelo, e executando rodadas de otimização com o espaço de busca completo. Os pesos de cada saída nas diferentes interações da análise de sensibilidade foram definidos com base em um DOE de mistura, para 2 componentes, com 5 experimentos, que resultou na Tabela 13.

Tabela 13 – Divisões de pesos para a análise de sensibilidade da função *Desirability*, baseados no DOE de mistura

Experimento	% Componente A (y_1)	% Componente B (y_2)
1	0	100
2	25	75
3	50	50
4	75	25
5	100	0

Fonte: Autor (2022).

Os experimentos 1 e 5 do DOE proposto tiveram pequenas mudanças nos percentuais, sendo alterados para proporções de 1% y_1 e 99% y_2 , e 99% y_1 e 1% y_2 , respectivamente. Esta alteração foi adotada para manter a simulação multiobjetivo. O experimento 3 apresentava proporções iguais para ambas saídas, sendo o que já havia sido testado na primeira parte do trabalho.

Desta forma, a análise de sensibilidade para os componentes da função *Desirability* foi desempenhada conforme mostrado na Tabela 14.

Tabela 14 – Pesos aplicados na análise de sensibilidade com espaço de busca completo

Rodada	Nome	Descrição
6	Análise de Sensibilidade - Rodada 1 - Espaço de Busca Completo	Peso 75% na variável y_1 (custo) e 25% na variável y_2 (quantidade)
7	Análise de Sensibilidade - Rodada 2 - Espaço de Busca Completo	Peso 25% na variável y_1 (custo) e 75% na variável y_2 (quantidade)
8	Análise de Sensibilidade - Rodada 3 - Espaço de Busca Completo	Peso 99% na variável y_1 (custo) e 1% na variável y_2 (quantidade)
9	Análise de Sensibilidade - Rodada 4 - Espaço de Busca Completo	Peso 1% na variável y_1 (custo) e 99% na variável y_2 (quantidade)

Fonte: Autor (2022).

Em seguida, a configuração de DEA e DOE com melhor resultado na etapa de avaliação das técnicas, também, foi submetida a esta análise de sensibilidade, conforme está na Tabela 15.

Tabela 15 – Pesos aplicados na análise de sensibilidade com o melhor conjunto de dados

Rodada	Nome	Descrição
10	Análise de Sensibilidade - Rodada 5 - Melhor conjunto de dados	DEA BCC O LHD - peso 75% na variável y_1 custo e peso 25% na variável y_2 (quantidade)
11	Análise de Sensibilidade - Rodada 6 - Melhor conjunto de dados	DEA BCC O LHD - peso 25% na variável y_1 custo e peso 75% na variável y_2 (quantidade)
12	Análise de Sensibilidade - Rodada 7 - Melhor conjunto de dados	DEA BCC O LHD - peso 99% na variável y_1 custo e peso 1% na variável y_2 (quantidade)
13	Análise de Sensibilidade - Rodada 8 - Melhor conjunto de dados	DEA BCC O LHD - peso 1% na variável y_1 custo e peso 99% na variável y_2 (quantidade)

Fonte: Autor (2022).

4 RESULTADOS E IMPLICAÇÕES GERENCIAIS

Ambas as matrizes de experimentos do Capítulo 3, uma elaborada com auxílio do arranjo ortogonal de Taguchi, mostrada na Tabela 6, e uma elaborada com o auxílio do LHD, mostra na Tabela 7, foram carregadas no modelo de simulação como parâmetros de entrada e, ao final de 30 execuções de cada experimento, os resultados de saída foram coletados, conforme exibido na Tabela 16 e na Tabela 17. Os valores exibidos para as saídas y_1 e y_2 são a média das 30 execuções em cada conjunto de DMU's.

Tabela 16 – Resultados das simulações pelo DOE utilizando o método de Taguchi

Variável	y_1	y_2
Experimento	Custo Unitário da Operação	Número de Paletes expedidos
1	R\$ 44,10	46
2	R\$ 74,13	130
3	R\$ 93,17	233
4	R\$ 24,80	38
5	R\$ 58,10	58
6	R\$ 84,20	178
7	R\$ 52,07	114
8	R\$ 59,93	91
9	R\$ 13,53	19
10	R\$ 82,60	61
11	R\$ 101,00	209
12	R\$ 39,50	87
13	R\$ 39,03	55
14	R\$ 37,03	58
15	R\$ 62,77	62
16	R\$ 30,70	46
17	R\$ 85,97	140
18	R\$ 75,80	132
19	R\$ 88,73	192
20	R\$ 67,73	60
21	R\$ 98,47	219
22	R\$ 86,20	63
23	R\$ 28,60	98
24	R\$ 79,50	139
25	R\$ 86,53	190
26	R\$ 119,13	222
27	R\$ 58,00	97
28	R\$ 52,63	112
29	R\$ 87,10	115
30	R\$ 85,73	208
31	R\$ 84,57	134
32	R\$ 88,40	106

Fonte: Autor (2022).

Tabela 17 – Resultado das simulações pelo DOE utilizando o método do Hipercubo Latino

Variável	y₁	y₂
Experimento	Custo Unitário da Operação	Número de Paletes expedidos
1	R\$ 69,47	98
2	R\$ 61,97	92
3	R\$ 105,50	233
4	R\$ 34,20	61
5	R\$ 85,90	105
6	R\$ 85,77	211
7	R\$ 85,30	139
8	R\$ 85,03	68
9	R\$ 13,17	17
10	R\$ 88,73	192
11	R\$ 41,87	86
12	R\$ 28,17	96
13	R\$ 86,30	109
14	R\$ 82,40	110
15	R\$ 64,63	101
16	R\$ 31,60	78
17	R\$ 66,03	64
18	R\$ 84,93	140
19	R\$ 86,53	190
20	R\$ 24,10	37
21	R\$ 15,30	106
22	R\$ 31,90	57
23	R\$ 22,17	34
24	R\$ 65,83	58
25	R\$ 43,57	52
26	R\$ 61,60	90
27	R\$ 79,47	63
28	R\$ 83,37	62
29	R\$ 38,37	62
30	R\$ 34,10	79
31	R\$ 25,93	43
32	R\$ 49,57	82

Fonte: Autor (2022).

Com base nos resultados das duas tabelas, foi possível a execução do modelo DEA - BCC orientado aos insumos e aos produtos. Após a aplicação, a supereficiência foi utilizada como método de ranqueamento das DMUs. Os resultados de eficiência para cada DMU, em cada conjunto de dados, foram ordenados em ordem decrescente, conforme Tabela 18. É possível notar que em cada conjunto de dados há diferentes resultados de eficiência para as DMUs, resultando em diferentes ranqueamentos, que proporcionarão diferentes reduções do espaço de busca.

Tabela 18 – Resultados da supereficiência para as DMUs em cada conjunto de dados

Conjunto de Dados	1		2		3		4	
DOE	Taguchi		Taguchi		LHD		LHD	
Orientação do DEA-BCC	Insumo		Produto		Insumo		Produto	
Ranking	DMU	Eficiência	DMU	Eficiência	DMU	Eficiência	DMU	Eficiência
#1	3	906%	10	401%	6	477%	6	430%
#2	9	260%	29	292%	10	225%	16	286%
...								

Fonte: Autor (2022).

As duas DMU's mais eficientes pela análise em cada conjunto de dados, destacadas em negrito na Tabela 18, foram escolhidas para gerar os novos espaços de busca reduzidos, conforme está na Tabela 19.

Tabela 19 – DMUs mais eficientes após ranqueamento

Conjunto de Dados	Método de DOE	Orientação do DEA BCC	DMU mais eficiente	Segunda DMU mais eficiente
1	Taguchi	Insumo	3	9
2	Taguchi	Produto	10	29
3	LHD	Insumo	6	10
4	LHD	Produto	6	16

Fonte: Autor (2022).

Com isso, os limites para o espaço de busca das primeiras 5 rodadas de otimização foram definidos conforme exibidos na Tabela 20.

Tabela 20 – Novos espaços de busca reduzidos pela aplicação do DEA sobre os conjuntos de dados

Variável	x_1		x_2		x_3		x_4		x_5	
Descrição	Operadores		Docas ativas		Empilhadeiras		Tipo de carga		Turnos	
Limites	Inferior	Superior	Inferior	Superior	Inferior	Superior	Inferior	Superior	Inferior	Superior
Espaço de busca completo	1	9	1	9	1	9	1	4	1	2
DEA BCC Insumos - DOE Taguchi	9	9	2	7	2	6	2	4	2	2
DEA BCC Produtos - DOE Taguchi	7	8	1	2	1	5	1	4	1	2
DEA BCC Insumos - DOE LHD	1	7	3	8	1	4	2	2	2	2
DEA BCC Produtos - DOE LHD	1	4	1	8	1	1	2	3	1	2

Fonte: Autor (2022).

A aplicação combinada dos métodos de DOE e DEA combinados trouxe uma redução notável no número de possibilidades existentes em cada espaço de busca, com resultados acima de 97% de redução de experimentos em todos os conjuntos de dados, conforme está na Tabela 21.

Tabela 21 – Reduções nos espaços de busca após a aplicação das técnicas DOE e DEA

Descrição	Total de Experimentos	% de redução	Variações de x_1	Variações de x_2	Variações de x_3	Variações de x_4	Variações de x_5
Espaço de busca completo	5.832	-	9	9	9	4	2
DEA BCC							
Insumos - DOE	90	98%	1	6	5	3	1
Taguchi							
DEA BCC							
Produtos - DOE	160	97%	2	2	5	4	2
Taguchi							
DEA BCC							
Insumos - DOE	168	97%	7	6	4	1	1
LHD							
DEA BCC							
Produtos - DOE	128	98%	4	8	1	2	2
LHD							

Fonte: Autor (2022).

Durante as primeiras avaliações, discutiu-se sobre utilizar o algoritmo de otimização padrão do *software SimRunner*. Entretanto, a utilização do algoritmo do *SimRunner* implica em dois problemas principais, identificados durante esta análise:

- A dificuldade da interpretação do valor numérico da função objetivo final.
- A falta de clareza sobre o método de aglutinação aplicado pelo *software*.

Considerando esses dois pontos, as rodadas de otimização foram feitas utilizando a função *Desirability* como método de aglutinação apresentado, anteriormente, por (39) – (41). Os resultados dessas otimizações estão na Tabela 22.


Tabela 22 – Resultados das rodadas de otimização utilizando a função *Desirability*

Rodada	Tempo Computacional	Nº de experimentos	Função Objetivo Final	x_1	x_2	x_3	x_4	x_5
1. Espaço de busca completo	00:23	155	0,63	4	3	1	2	2
2. Taguchi + DEA Input	00:11	59	0,57	9	2	3	2	2
3. Taguchi + DEA Output	00:09	79	0,61	7	2	1	1	2
4. LHD + DEA Input	00:16	92	0,59	7	3	1	2	2
5. LHD + DEA Output	00:17	102	0,63	4	3	1	2	2

Fonte: Autor (2022).

A análise dos dados mostra resultados promissores na associação das técnicas. Conforme os resultados exibidos graficamente na Figura 22, foi possível reduzir tempo computacional de mais de 50% em duas das quatro otimizações testadas com o auxílio do DEA e do DOE para redução dos espaços de busca. Nota-se também que os valores das funções objetivo finais têm diferenças pequenas em alguns casos, podendo indicar que modulações mais sutis nas variáveis de entrada implicariam em resultados próximos do ótimo. Isso pode trazer vantagens quando se considera as possibilidades de ponderação de pesos diferentes nas saídas da modelagem multiobjetivo.

Figura 22 – Gráfico dos tempos computacionais e reduções pela aplicação do DOE e DEA




Fonte: Autor (2022).

A rodada 5, utilizando o conjunto de dados elaborado com o auxílio do LHD e do DEA - BCC orientado ao produto trouxe o mesmo resultado da rodada de otimização com o espaço amostral completo. Isso reforça a hipótese de que a combinação de DEA e DOE pode ser capaz de trazer uma redução do espaço de busca, ao mesmo tempo, encontrando o ponto ótimo determinado por uma varredura do espaço de busca completo.

Análise de Sensibilidade – Função *Desirability*

Após estas rodadas, foi feita uma análise de sensibilidade do modelo e do método aplicado, variando os pesos atribuídos a cada variável de saída no cálculo da função *Desirability* geral. Os pesos foram variados tomando por base um DOE de mistura, conforme explorado na Tabela 13, e foram executadas 4 rodadas de otimização com o espaço de busca completo, em cada configuração de pesos estipulada, conforme Tabela 14. Os resultados destas otimizações estão na Figura 23.

Figura 23 – Gráfico dos tempos computacionais e funções objetivos finais da análise de sensibilidade, considerando o espaço de busca completo



Fonte: Autor (2022).

Nesta análise, a rodada 6 atribuiu um peso de 75% a variável de saída y_1 (correspondente ao custo médio por veículo expedido) e um peso de 25% a variável de saída y_2 (correspondente a quantidade total de paletes expedidos). A rodada 7 atribuiu os pesos de forma invertida, com 25% a variável y_1 e 75% variável de saída y_2 .

As rodadas 8 e 9 atribuíram pesos mais drásticos a cada variável, sendo o peso 99% para

a variável y_1 e 1% para a variável y_2 na rodada 8 e o inverso na rodada 9.

Na Tabela 23, mostram-se os componentes d_1 e d_2 , bem como os valores ótimos encontrados para cada parâmetro de entrada do modelo.

De forma geral, nota-se que a opção por trabalhar com 2 turnos (variável de entrada x_5) somente é atribuída pela otimização, nos cenários em que o peso da variável y_1 (custo) na função *Desirability* geral é reduzido. Alguns parâmetros, como quantidade de empilhadeiras e tipo de carga (variáveis de entrada x_3 e x_4), parecem ter pouca influência na função *Desirability* geral.

Dentre as configurações exploradas para o espaço de busca completo na análise de sensibilidade, a rodada 8 em que se atribuiu um peso de 99% a variável y_1 (custo), trouxe o maior valor atingido para a função *Desirability* geral. Isto não implica, entretanto, que este seja o melhor ajuste da modelagem, apenas mostra que a lógica de atribuição de pesos realmente permite atingir valores de saída diferentes, com base nas configurações do modelador.

Tabela 23 – Resultados das funções *Desirability* na análise de sensibilidade, considerando o espaço de busca completo

Rodada	Função Objetivo Final (D)	d_1	d_2	y_1	y_2	x_1	x_2	x_3	x_4	x_5
6. 75% custo + 25% quantidade	0,77	0,88	0,52	25,72	116	4	9	1	1	1
7. 25% custo + 75% quantidade	0,73	0,52	0,81	63,88	56	4	4	1	1	2
8. 99% custo + 1% quantidade	0,89	0,89	0,55	24,66	110	2	8	1	1	1
9. 1% custo + 99% quantidade	0,78	0,49	0,78	67,06	62	8	5	1	1	2

Fonte: Autor (2022).


As possibilidades de atribuição de pesos dentro do cálculo da função *Desirability* são inúmeras e trazem uma customização importante pelo ponto de vista gerencial, pois, em situações corporativas reais seria comum atribuir pesos maiores para o fator custo, porém, sem desconsiderar totalmente a influência do fator quantidade expedida.

É importante ressaltar também que o modelo estudado não propõe soluções nulas quando o objetivo da otimização se concentra mais em minimizar custo do que maximizar quantidades, pois, uma possível lacuna da análise ocorreria caso o *software* simplesmente sugerir zerar as quantidades operadas, visando maximizar o benefício financeiro do sistema simulado. Neste estudo, nenhuma condição neste sentido foi observada.

Em sequência a essa primeira análise de sensibilidade, uma nova análise foi realizada, agora utilizando não mais o espaço de busca completo, mas sim o espaço de busca reduzido

pela aplicação do LHD e do DEA BCC orientado ao produto, conforme está disposto na Tabela 15. Os resultados estão na Figura 24.

Figura 24 – Gráfico dos tempos computacionais e funções objetivos finais da análise de sensibilidade, considerando o espaço de busca reduzido pelo LHD e DEA BCC orientado ao produto



Fonte: Autor (2022).

Tabela 24 – Resultados das funções *Desirability* na análise de sensibilidade, considerando o espaço de busca reduzido pelo LHD e DEA BCC orientado ao produto

Rodada	Função Objetivo Final	d_1	d_2	y_1	y_2	x_1	x_2	x_3	x_4	x_5
10. 75% custo + 25% quantidade	0,72	0,81	0,51	33,14	118	4	8	1	2	1
11. 25% custo + 75% quantidade	0,73	0,5	0,83	66,00	52	3	8	1	2	1
12. 99% custo + 1% quantidade	0,88	0,88	0,57	25,72	106	2	8	1	2	1
13. 1% custo + 99% quantidade	0,75	0,66	0,75	49,04	69	4	8	1	2	1

Fonte: Autor (2022).

Na Tabela 24, encontram-se os resultados dos componentes d_1 e d_2 , bem como os valores ótimos encontrados para cada parâmetro de entrada nesta nova análise. O espaço de busca reduzido apresentava uma pequena faixa para variação dos níveis, mas, ainda assim, foi possível notar alguma diferenciação na variável de entrada x_1 (operadores). Dentre as configurações exploradas, a rodada 12, em que se atribuiu um peso de 99% à variável y_1 (custo), trouxe o

maior valor atingido para a função *Desirability* geral.

5 CONCLUSÕES

Este capítulo é composto pelas respostas encontradas às questões de pesquisa, verificação do cumprimento dos objetivos, conclusões desta pesquisa e propostas de próximos passos.

5.1 VERIFICAÇÃO DOS OBJETIVOS GERAIS E RESPOSTAS ÀS QUESTÕES DE PESQUISA

Retomando às questões de pesquisa, têm-se as seguintes observações:

- Como a otimização multiobjetivo via simulação pode ser aplicada para determinar o melhor arranjo operacional logístico estudado?

A OvS proporcionou a sugestão de um arranjo operacional específico focado em atender ambos os objetivos da companhia na qual o modelo foi inspirado. A otimização multiobjetivo via simulação trouxe uma visão de alocação de recursos, distribuições de turnos e equipamentos e consolidação de cargas que não seria óbvia do ponto de vista gerencial, pois envolvia ajustes intermediários das variáveis de entrada, mas que pôde auxiliar no atingimento de uma operação otimizada em termos de custo e produtividade logística. Isso foi possível graças ao modelo validado que permitia uma análise realista da operação via simulação e, especialmente, às técnicas de DOE e DEA que, aliadas, permitiram encontrar soluções em tempos viáveis, sem precisar percorrer o espaço de busca total.

- Quais são vantagens de se combinar um modelo DEA-BCC com os Arranjos Ortogonais de Taguchi e o Hipercubo Latino?

A associação da técnica DEA - BCC orientada aos insumos e aos produtos com os métodos de DOE de Taguchi e LHD trouxe uma possibilidade de redução notável no espaço de busca do modelo estudado. Em cada aplicação, foi possível encontrar espaços de busca com reduções na casa dos 97% e que culminaram em reduções de tempo computacional acima de 50%. Esses espaços de busca reduzidos permitiram encontrar uma solução otimizada idêntica à encontrada pela otimização, considerando o espaço de busca completo, comprovando que a associação desses métodos não compromete a qualidade da resposta indicada.

- Qual o melhor arranjo experimental (Taguchi ou Hipercubo Latino) para ser combinado com o modelo DEA-BCC, visando à redução do espaço de busca?

A combinação do DEA - BCC orientado ao produto com o LHD trouxe o melhor resultado, encontrando a mesma solução do espaço de busca completo, com reduções de tempo computacional de 26% na otimização com a função *Desirability*. Embora, o problema estudado

tenha tempos de execução relativamente pequenos, existem modelos de simulação muito mais complexos, cujos experimentos podem consumir várias horas de tempo computacional para serem rodados, especialmente quando se trata de otimizações multiobjetivo, que são naturalmente mais complexas. Ao aplicar a sistemática proposta neste trabalho em um destes modelos, uma redução de 26% pode representar economias de tempo e poder computacional muito representativas.

- Como aglutinar múltiplas funções objetivo em problemas de otimização multiobjetivo via simulação?

Durante as discussões do trabalho, duas diferentes estratégias de otimização foram avaliadas: uma utilizando o algoritmo nativo de função objetivo do *SimRunner* e outra utilizando a função *desirability* como função objetivo. A otimização pelo algoritmo embutido do *SimRunner* foi descartada devido a preocupações sobre o método de aglutinação aplicado pelo software. As análises dos resultados da simulação mostraram grande dificuldade de interpretação dos valores da função objetivo gerada pelo *SimRunner*. Em contrapartida, a função *Desirability* trouxe uma forma simples de normalizar os resultados e apresentá-los como um número positivo entre 0 e 1, que indica quão desejável o resultado é para a simulação estudada. A análise de sensibilidade desempenhada, também, indicou boas respostas da função *Desirability*, permitindo que o modelador possa atribuir pesos a saídas específicas do modelo que possam ser mais desejáveis que outras, em algum cenário. Isto é particularmente interessante pela perspectiva gerencial, facilitando o direcionamento da otimização multiobjetivo para os *outputs* que tiverem maior relevância, sem comprometer o rigor matemático da solução aplicada e sem depender de algoritmos nativos de *softwares* comerciais.

Com relação aos objetivos estipulados para este trabalho, tem-se que a sistemática foi aplicada com sucesso na pesquisa desempenhada. Os métodos de DEA-BCC foram aplicados em duas orientações (insumos e produtos) e dois diferentes métodos de DOE foram utilizados (Taguchi e LHD).

Com todas essas combinações, foi possível encontrar reduções de espaço de busca que propiciaram reduções de tempo computacional, embora nem todas tenham encontrado, exatamente, a mesma solução otimizada pelo espaço de busca completo.

Assim, foi possível identificar o melhor modelo de DEA - BCC como sendo o modelo orientado aos produtos, e o melhor método de DOE como sendo o *Latin Hypercube Design*, pois, para esta aplicação específica, a associação dessas técnicas trouxe o melhor resultado, atingindo, exatamente, a mesma parametrização encontrada pela otimização com espaço de busca completo.

5.2 SUGESTÕES PARA CONTINUIDADE DO TRABALHO

Como proposta para futuras pesquisas, sugere-se incluir mais funções objetivo em modelos de otimização via simulação, visando assim, averiguar o desempenho da função *Desirability* e a influência dos pesos em estudos mais complexos e com espaços de busca maiores. Neste trabalho, o problema explorado tinha apenas dois objetivos, permitindo relativamente poucas combinações de pesos conforme foi averiguado com o auxílio do DOE de mistura na análise de sensibilidade. Em problemas mais complexos, com mais objetivos, mais variações de pesos seriam possíveis e diferentes orientações gerenciais para a otimização poderiam ser analisadas, validando também as capacidades de aglutinação da função *Desirability* em problemas de OvS mais robustos.

Em termos da sistemática de associação do DOE com DEA para redução do espaço de busca, novos trabalhos poderiam seguir com a exploração de diferentes métodos de DOE e, adicionalmente, avaliar em diferentes contextos a orientação do DEA-BCC ao produto e ao insumo, buscando delimitar em quais situações estas orientações possam ser mais ou menos viáveis para atingimento de respostas de boa qualidade após a redução do espaço de busca.

5.3 IMPLICAÇÕES GERENCIAIS

As hipóteses de otimização operacional avaliadas neste trabalho foram também discutidas paralelamente com especialistas da empresa na qual o modelo foi inspirado. Pelo ponto de vista prático, as configurações otimizadas poderiam realmente ser empregadas em vias de conseguir maximizar o atendimento e minimizar o custo da operação.

Pela perspectiva acadêmica, há outros trabalhos orientados a otimização de resultados operacionais onde o DEA-BCC orientado aos insumos se mostra a técnica de análise de dados mais eficiente, porém haveria ainda um interesse em averiguar esta constatação em outros cenários. O mesmo ocorre com o LHD, que já havia sido encontrado como melhor opção de DOE em trabalhos envolvendo simulação, porém ainda há espaço para proposições de explicações mais específicas sobre estas características.

REFERÊNCIAS

- AJU, D. E.; ONYELOWE, K. C.; ALANEME, G. U. Constrained vertex optimization and simulation of the unconfined compressive strength of geotextile reinforced soil for flexible pavement foundation construction. **Cleaner Engineering and Technology**, London, v. 5, p. 100287, 2021. Disponível em: <https://doi.org/10.1016/j.clet.2021.100287>. Acesso em: 06 jan. 2022.
- ANDERSEN, P.; PETERSEN, N. C. A Procedure for Ranking Efficient Units in Data Envelopment Analysis. **Management Science**, Washington DC, v. 39, n. 10, p. 1261–1264, 1993.
- ANDERSON, T. R.; HOLLINGSWORTH, K. The fixed weighting nature of a cross-evaluation model. **Journal of Productivity Analysis**, Washington DC, v. 17, p. 249–255, 2002.
- AZIMI, P.; FARHADI, N. Developing a New Integrated Bi-Objective Model for Buffer and Process Time Optimization Problem using Optimization via Simulation Approach. **Mathematical Models and Computer Simulations**, Moscow, v. 10, n. 3, p. 373–386, 2018.
- BADRI, H.; BASHIRI, M.; HEJAZI, T. H. Integrated strategic and tactical planning in a supply chain network design with a heuristic solution method. **Computers and Operations Research**, London, v. 40, n. 4, p. 1143–1154, 2013. Disponível em: <http://dx.doi.org/10.1016/j.cor.2012.11.005>. Acesso em: 06 jan. 2022.
- BAIGMOHAMMADI, M.; PATEL, V.; NAGARAJA, S.; RAMALINGAM, A.; MARTINEZ, S.; PANIGRAHY, S.; MOHAMED, A. A. E. S.; SOMERS, K. P.; BURKE, U.; HEUFER, K. A.; PEKALSKI, A.; CURRAN, H. J. Comprehensive Experimental and Simulation Study of the Ignition Delay Time Characteristics of Binary Blended Methane, Ethane, and Ethylene over a Wide Range of Temperature, Pressure, Equivalence Ratio, and Dilution. **Energy and Fuels**, Washington DC, v. 34, n. 7, p. 8808–8823, 2020.
- BARCELLOS DE PAULA, L.; MARINS, F. A. S. Algorithms applied in decision-making for sustainable transport. **Journal of Cleaner Production**, [s. l.], v. 176, p. 1133–1143, 2018.
- BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations and Production Management**, London, v. 22, n. 2, p. 241–264, 2002.
- BOUSSOFIANE, A.; DYSON, R. G.; THANASSOULIS, E. Applied data envelopment analysis. **European Journal of Operational Research**, London, v. 52, n. 1, p. 1–15, 1991.
- ČERVEŇANSKÁ, Z.; VAŽAN, P.; JUHÁS, M.; JUHÁSOVÁ, B. Multi-criteria optimization in operations scheduling applying selected priority rules. **Applied Sciences (Switzerland)**, London, v. 11, n. 6, 2021.
- CHARNES, A.; COOPER, W. W.; RHODES, E. Measuring the efficiency of decision making units. **European Journal of Operational Research**, London, v. 2, n. 6, p. 429–444, 1978.

CHONG, B. W.; OTHMAN, R.; JAYA, R. P.; HASAN, M. R. M.; SANDU, A. V.; NABIAŁEK, M.; JEŽ, B.; PIETRUSIEWICZ, P.; KWIATKOWSKI, D.; POSTAWA, P.; ABDULLAH, M. M. A. B. Design of experiment on concrete mechanical properties prediction: A critical review. **Materials**, London, v. 14, n. 8, p. 1–17, 2021.

COOK, W. D.; SEIFORD, L. M. Data envelopment analysis (DEA) - Thirty years on. **European Journal of Operational Research**, London, v. 192, n. 1, p. 1–17, 2009.

COOPER, W. W. W. W.; SEIFORD, L. M. L. M.; TONE, K. **Data Envelopment Analysis: A Comprehensive Text with Models, Applications, References and DEA-Solver Software**, London, Springer, 2nd ed., 2007.

DA SILVA, A. F.; MARINS, F. A. S.; DA SILVA OLIVEIRA, J. B.; DIAS, E. X. Multi-objective optimization and finite element method combined with optimization via Monte Carlo simulation in a stamping process under uncertainty. **International Journal of Advanced Manufacturing Technology**, London, 2021.

DATE, P. **Taguchi Designs**. Deli. [2016]. Disponível em: https://rpubs.com/prasanna_date/236025. Acesso em 26 ago. 2022.

DEMIR, E.; SOUTHERN, D.; RASHID, S.; LEB CIR, R. A discrete event simulation model to evaluate the treatment pathways of patients with cataract in the United Kingdom. **BMC Health Services Research**, London, v. 18, n. 1, p. 1–15, 2018.

DERRINGER, G.; SUICH, R. Simultaneous Optimization of Several Response Variables. **Journal of Quality Technology**, London, v. 12, n. 4, p. 214–219, 1980.

DOYLE, J.; GREEN, R. Efficiency and Cross-Efficiency in DEA: Derivations, Meanings and Uses. **Journal of the Operational Research Society**, London, v. 38, n. 6, p. 509–514, 1994.

ENTANI, T.; MAEDA, Y.; TANAKA, H. Dual models of interval DEA and its extension to interval data. **European Journal of Operational Research**, London, v. 136, n. 1, p. 32–45, 2002.

FANTI, M. P.; IACOBELLIS, G.; UKOVICH, W.; BOSCHIAN, V.; GEORGOULAS, G.; STYLIOS, C. A simulation based Decision Support System for logistics management. **Journal of Computational Science**, London, v. 10, p. 86–96, 2015. Disponível em: <http://dx.doi.org/10.1016/j.jocs.2014.10.003>. Acesso em: 13 abr. 2020.

FARRELL, M. J. The Measurement of Productive Efficiency <http://www.jstor.org/stab>. **Journal of the Royal Statistical Society. Series A (General)**, London, v. 120, n. 3, p. 253–290, 1957. Disponível em: <http://goo.gl/AFhm2N>. Acesso em 06 jan. 2022.

FENG, Q. Q.; LIU, L.; ZHOU, X. Automated multi-objective optimization for thin-walled plastic products using Taguchi, ANOVA, and hybrid ANN-MOGA. **International Journal of Advanced Manufacturing Technology**, London, v. 106, n. 1–2, p. 559–575, 2020.

FERREIRA, C. M. C.; GOMES, A. P. **Introdução à análise envoltória de dados: teoria, modelos e aplicações**. Viçosa, Editora UFV, 2012.

FRIED, H. O.; LOVELL, C. A. K.; SCHMIDT, S. S. **The measurement of productive efficiency and productivity growth**. Oxford, Oxford University Press, v. 15, n. 1, p. 583–605, 2008.

FU, Y. DEA cross-efficiency aggregation based on preference structure and acceptability analysis. **International Transactions In Operational Research**, Washington DC, v. 0, p. 1–25, 2021.

FU, M. C. Optimization via simulation: A review. **Annals of Operations Research**, Washington DC, v. 53, n. 1, p. 199–247, 1994.

GOBBO, S. C. de O.; MARIANO, E. B.; GOBBO, J. A. Combining social network and data envelopment analysis: A proposal for a Selection Employment Contracts Effectiveness index in healthcare network applications. **Omega (United Kingdom)**, London, v. 103, 2021.

GOLFARELLI, M.; RIZZI, S. What-if simulation modeling in business intelligence. **International Journal of Data Warehousing and Mining**, Washington DC, v. 5, n. 4, p. 24–43, 2009.

GONÇALVES, A. T. T.; FAGUNDES, L. D.; MIRANDA, R. de C.; LIMA, R. da S. Discrete event simulation as a decision-making tool for end-of-life tire reverse logistics in a Brazilian city consortium. **Environmental Science and Pollution Research**, Berlin, v. 26, n. 23, p. 23994–24009, 2019.

GUERINI, M.; MONETA, A. A method for agent-based models validation. **Journal of Economic Dynamics and Control**, Amsterdam, v. 82, p. 125–141, 2017.

HARREL, C. R.; MOTT, J. R. .; BATEMAN, R. E.; BOWDEN, R. G.; GOGG, T. J. **Simulação: Otimizando os sistemas**. São Paulo, Editora Belge, 2002.

HATAMI-MARBINI, A.; HEKMAT, S.; AGRELL, P. J. **A strategy-based framework for supplier selection: a grey PCA-DEA approach**. Springer, Berlin, v. 22. Disponível em: <https://doi.org/10.1007/s12351-020-00556-8>. Acesso em: 24 mar. 2022.

HE, C.; ZHU, L.; TIAN, W. Sensitivity analysis of urban building layout on energy consumption. **Journal of Harbin Institute of Technology**, Beijing, v. 50, n. 4, p. 180, 2018.

HLADÍK, M. Universal efficiency scores in data envelopment analysis based on a robust approach. **Expert Systems with Applications**, London, v. 122, p. 242–252, 2019.

HORNG, S. C.; LIN, S. S. Ordinal optimization based metaheuristic algorithm for optimal inventory policy of assemble-to-order systems. **Applied Mathematical Modelling**, Washington DC, v. 42, p. 43–57, 2017. Disponível em: <http://dx.doi.org/10.1016/j.apm.2016.10.002>. Acesso em: 16 jun. 2022.

HOSSEINI, Z.; NAVAZI, F.; SIADAT, A.; MEMARI, P.; TAVAKKOLI-MOGHADDAM, R. A tailored fuzzy simulation integrated with a fuzzy DEA method for a resilient facility layout problem: A case study of a refrigerator injection process. **IFAC-PapersOnLine**, London, v. 52, n. 13, p. 541–546, 2019. Disponível em: <https://doi.org/10.1016/j.ifacol.2019.11.214>. Acesso em: 05 ago. 2021.

HUSSEIN, M.; DARKO, A.; ELTOUKHY, A. E. E.; ZAYED, T. Sustainable Logistics Planning in Modular Integrated Construction Using Multimethod Simulation and Taguchi Approach. **Journal of Construction Engineering and Management**, Washington DC, v. 148, n. 6, 2022.

JANER RUBIO, M. L.; ROSSETTI, M. D. Simulation Modeling of a Prototype Designed to Address the Congestion of Passengers and Items at the Composure Area of Security Checkpoints. **Transportation Research Record**, Washington DC, v. 2672, n. 29, p. 59–68, 2018.

KALKAN, O.; CELEN, A.; BAKIRCI, K. Multi-objective optimization of a mini channeled cold plate for using thermal management of a Li-Ion battery. **Energy**, Berlin, v. 251, 2022.

KAO, C.; LIU, S. T. Fuzzy efficiency measures in data envelopment analysis. **Fuzzy Sets and Systems**, Amsterdam, v. 113, n. 3, p. 427–437, 2000.

KAO, C.; LIU, S. T. Group decision making in data envelopment analysis: A robot selection application. **European Journal of Operational Research**, London, v. 297, n. 2, p. 592–599, 2022. Disponível em: <https://doi.org/10.1016/j.ejor.2021.05.013>. Acesso em: 15 ago. 2021.

KESHTKAR, L.; RASHWAN, W.; ABO-HAMAD, W.; ARISHA, A. A hybrid system dynamics, discrete event simulation and data envelopment analysis to investigate boarding patients in acute hospitals. **Operations Research for Health Care**, Amsterdam, v. 26, p. 100266, 2020. Disponível em: <https://doi.org/10.1016/j.orhc.2020.100266>. Acesso em: 05 ago. 2021.

KHARE, R.; VILLURI, V. G. K.; CHAURASIA, D. Urban sustainability assessment: The evaluation of coordinated relationship between BRTS and land use in transit-oriented development mode using DEA model. **Ain Shams Engineering Journal**, Cairo, v. 12, n. 1, p. 107–117, 2021. Disponível em: <https://doi.org/10.1016/j.asej.2020.08.012>. Acesso em: 16 jun. 2022.

KHEZRIMOTLAGH, D.; ZHU, J.; COOK, W. D.; TOLOO, M. Data envelopment analysis and big data. **European Journal of Operational Research**, London, v. 274, n. 3, p. 1047–1054, 2019. Disponível em: <https://doi.org/10.1016/j.ejor.2018.10.044>. Acesso em: 28 mai. 2021.

KIM, J. B.; HWANG, K. Y.; KWON, B. I. Optimization of two-phase in-wheel IPMSM for wide speed range by using the kriging model based on latin hypercube sampling. **IEEE Transactions on Magnetics**, Washington DC, v. 47, n. 5, p. 1078–1081, 2011.

KLEIJNEN, J. P. C. Sensitivity analysis of simulation models: An overview. **Procedia - Social and Behavioral Sciences**, Amsterdam, v. 2, n. 6, p. 7585–7586, 2010.

LAMPERTI, G.; ZANELLA, M.; ZHAO, X. Diagnosis of deep discrete-event systems. **Journal of Artificial Intelligence Research**, Washington DC, v. 69, p. 1473–1532, 2021.

LEME, R. C.; PAIVA, A. P.; STEELE SANTOS, P. E.; BALESTRASSI, P. P.; GALVÃO, L. de L. Design of experiments applied to environmental variables analysis in electricity utilities

efficiency: The Brazilian case. **Energy Economics**, Amsterdam, v. 45, p. 111–119, 2014. Disponível em: <http://dx.doi.org/10.1016/j.eneco.2014.06.017>. Acesso em: 28 mar. 2022.

LOPES, H. dos S.; LIMA, R. da S.; LEAL, F.; NELSON, A. de C. Scenario analysis of Brazilian soybean exports via discrete event simulation applied to soybean transportation: The case of Mato Grosso State. **Research in Transportation Business and Management**, Amsterdam, v. 25, n. February, p. 66–75, 2017. Disponível em: <https://doi.org/10.1016/j.rtbm.2017.09.002>. Acesso em: 20 abr. 2020.

LUO, J.; JI, Y.; LU, W. Comparison of Surrogate Models Based on Different Sampling Methods for Groundwater Remediation. **Journal of Water Resources Planning and Management**, Washington DC, v. 145, n. 5, p. 04019015, 2019.

MARDANI, A.; ZAVADSKAS, E. K.; STREIMIKIENE, D.; JUSOH, A.; KHOSHNOUDI, M. A comprehensive review of data envelopment analysis (DEA) approach in energy efficiency. **Renewable and Sustainable Energy Reviews**, London, v. 70, n. December, p. 1298–1322, 2017. Disponível em: <http://dx.doi.org/10.1016/j.rser.2016.12.030>. Acesso em: 13 abr. 2020.

MARIANO, E. B.; ALMEIDA, M. R.; REBELATTO, D. a. N. Peculiaridades da Análise por Envoltória de Dados. **XII SIMPEP - Simpósio de engenharia de produção**, Brasília, v. 12, p. 11, 2006.

MARINS, F. A. S.; DA SILVA, A. F.; MIRANDA, R. D. C.; MONTEVECHI, J. A. B. J. A. B. A comprehensive review of data envelopment analysis (DEA) approach in energy efficiency. **European Journal of Operational Research**, London, v. 25, n. 4, p. 66–75, 2019. Disponível em: <http://dx.doi.org/10.1016/j.rser.2016.12.030>. Acesso em: 22 mai. 2021.

MARINS, F. A. S.; DA SILVA, A. F.; MIRANDA, R. de C.; MONTEVECHI, J. A. B. A new approach using fuzzy DEA models to reduce search space and eliminate replications in simulation optimization problems. **Expert Systems with Applications**, London, v. 144, 2020.

MATOS, D. A. D. E. Logística reversa , balanced scorecard e os programas de reciclagem de recursos da USP / São Carlos e da UFSCAR. **Simpósio de Engenharia de Produção Universidade Federal de Goiás – Regional Catalão**, Goiânia, 2007.

MIRANDA, R. de C.; MONTEVECHI, J. A. B.; DA SILVA, A. F.; MARINS, F. A. S. Increasing the efficiency in integer simulation optimization: Reducing the search space through data envelopment analysis and orthogonal arrays. **European Journal of Operational Research**, London, v. 262, n. 2, p. 673–681, 2017.

MIRANDA, R. de C.; MONTEVECHI, J. A. B. J. A. B.; DA SILVA, A. F.; MARINS, F. A. S. Redução do espaço de busca em problemas de Otimização via Simulação utilizando Análise Envoltória de Dados e Arranjos Ortogonais de Taguchi. **European Journal of Operational Research**, London, v. 12, n. 1, p. 383–398, 2019. Disponível em: <http://jise.info/issues/volume1no4/21.pdf>. Acesso em: 13 abr. 2020.

MIRANDA, R. D. C.; MONTEVECHI, J. A. B.; SILVA, A. F. Da; MARINS, F. A. S. A new approach to reducing search space and increasing efficiency in simulation optimization problems via the fuzzy-DEA-BCC. **Mathematical Problems in Engineering**, London, v.

2014, n. May, 2014.

MONTEVECHI, J. A. B.; DE OLIVEIRA, M. L. M.; LEAL, F.; DE PINHO, A. F. Analysis of the applicability of the IDEF-SIM modeling technique to the stages of a discrete event simulation project. **Proceedings - Winter Simulation Conference**, Washington DC, v. 2015-Janua, p. 950–961, 2015.

MONTEVECHI, J. A.; PINHO, A.; LEAL, F.; MARINS, F. A. S. Application of design of experiments on the simulation of a process in an automotive industry. **Proceedings of the Winter Simulation Conference - WSC 2007**, Washington, DC, p. 354–360, 2007.

MONTGOMERY, D. C. **Design and analysis of experiments**. 8th ed. New Jersey, John Wiley & Sons, 2017.

MOREIRA, L. S.; MELLO, J. C. C. B. S. de; MEZA, L. A. Aplicação de fronteira dea parabólica para dimensionamento de equipes em estações ferroviárias do Rio de Janeiro. **Simpósio Brasileiro de Pesquisa Operacional**, Limeira, p. 1473–1486, 2019.

NARENDERAN, S. T.; MEYYANATHAN, S. N.; KARRI, V. V. S. R. Experimental design in pesticide extraction methods: A review. **Food Chemistry**, Amsterdam, v. 289, n. March, p. 384–395, 2019. Disponível em: <https://doi.org/10.1016/j.foodchem.2019.03.045>. Acesso em: 11 abr. 2022.

NOVRISAL, D.; HAMANI, N.; ELMHAMED, A.; SOEMARDI, T. Performance improvement of baggage handling system in the soekarno-hatta international airport. **Springer Proceedings in Complexity**, Berlin, p. 383–384, 2017.

ÓLAFSSON, S.; KIM, J. Simulation optimization. **Winter Simulation Conference Proceedings**, Washington D.C., v. 1, p. 79–84, 2002.

PANDA, S.; SARKAR, P. Abrasion resistance of copper slag aggregate concrete designed by Taguchi method. **Materials Today: Proceedings**, Amsterdam, n. xxxx, 2022. Disponível em: <https://doi.org/10.1016/j.matpr.2022.02.545>. Acesso em 10 abr. 2022.

PARK, S. J.; OK, C.; HA, C. A stochastic simulation-based holistic evaluation approach with DEA for vendor selection. **Computers and Operations Research**, Singapore, v. 100, p. 368–378, 2018. Disponível em: <https://doi.org/10.1016/j.cor.2017.08.005>. Acesso em 07 set. 2021.

PARNIANIFARD, A.; ZEMOUCHE, A.; IMRAN, M. A.; WUTTISITTIKULKIJ, L. Robust simulation-optimization of dynamic-stochastic production/inventory control system under uncertainty using computational intelligence. **Uncertain Supply Chain Management**, Montreal, v. 8, n. 4, p. 633–648, 2020.

PROSSER, W.; SPISAK, C.; HATCH, B.; MCCORD, J.; TIEN, M.; ROCHE, G. Designing supply chains to meet the growing need of vaccines: evidence from four countries. **Journal of Pharmaceutical Policy and Practice**, London, v. 14, n. 1, p. 1–10, 2021. Disponível em: <https://doi.org/10.1186/s40545-021-00368-x>.

RABBANI, M.; FARSHBAF-GERANMAYEH, A.; YAZDANPARAST, R. A simulation optimization approach for integrated resource allocation in an emergency department,

pharmacy, and lab. **Intelligent Decision Technologies**, Amsterdam, v. 12, n. 2, p. 187–212, 2018.

RAZA, A.; AHRENDT, H.; HABIB-UR-RAHMAN, M.; HÜGING, H.; GAISER, T. Using the Taguchi experimental design for assessing within-field variability of surface run-off and soil erosion risk. **Science of The Total Environment**, Amsterdam, v. 828, p. 154567, 2022. Disponível em: <https://doi.org/10.1016/j.scitotenv.2022.154567>. Acesso em: 10 abr. 2022.

RODRIGUES, D. M.; DA SILVA, A. F.; AUGUSTO, F.; MARINS, S.; DIAS, É. X.; ROBERTO, J.; LUCHE, D. Utilização da Otimização Multiobjetivo em Problemas de Delineamento de Experimentos Com Múltiplas Respostas. **Simpósio Brasileiro de Pesquisa Operacional**, São Paulo, p. 1473–1486, 2015.

ROJAS-GONZALEZ, S.; JALALI, H.; VAN NIEUWENHUYSE, I. A stochastic-kriging-based multiobjective simulation optimization algorithm. **Proceedings - Winter Simulation Conference**, Washington D.C., v. 2018-Decem, p. 2155–2166, 2019.

ROY, R. K. **A Primer on the Taguchi Method**. New Jersey, John Wiley & Sons, 1990.

ROY, R. K. **Design of Experiments using the Taguchi Approach**. New Jersey, John Wiley & Sons, 2001.

RUIZ, J. L.; SIRVENT, I. Ranking decision making units: The cross-efficiency evaluation. **International Series in Operations Research and Management Science**, Amsterdam, v. 239, p. 1–29, 2016.

SHADKAM, E.; BIJARI, M. Multi-objective simulation optimization for selection and determination of order quantity in supplier selection problem under uncertainty and quality criteria. **International Journal of Advanced Manufacturing Technology**, London, 2015.

SISLIOGLU, M.; CELIK, M.; OZKAYNAK, S. A simulation model proposal to improve the productivity of container terminal operations through investment alternatives. **Maritime Policy and Management**, London, v. 46, n. 2, p. 156–177, 2019. Disponível em: <https://doi.org/10.1080/03088839.2018.1481544>. Acesso em: 07 ago. 2021.

SOPHA, B. M.; SAKTI, S.; PRASETIA, A. C. G.; DWIANSARINOPA, M. W.; CULLINANE, K. Simulating long-term performance of regional distribution centers in archipelagic logistics systems. **Maritime Economics and Logistics**, London, v. 23, n. 4, p. 697–725, 2021.

STEPONAVIČE, I.; RUUSKA, S.; MIETTINEN, K. A solution process for simulation-based multiobjective design optimization with an application in the paper industry. **CAD Computer Aided Design**, London, v. 47, p. 45–58, 2014.

SUN, X.; WU, C. C.; CHEN, L. R. An Automated Warehouse Sorting System for Small Manufacturing Enterprise Applying Discrete Event Simulation. **Proceedings of 2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference**, Washington DC, p. 1597–1601, 2018.

SWISHER, J. R.; HYDEN, P. D.; JACOBSON, S. H.; SCHRUBEN, L. W. Survey of

simulation optimization techniques and procedures. **Winter Simulation Conference Proceedings**, Washington DC, v. 1, p. 119–128, 2000.

VERA CANDIOTI, L.; DE ZAN, M. M.; CÁMARA, M. S.; GOICOECHEA, H. C. Experimental design and multiple response optimization. Using the desirability function in analytical methods development. **Talanta**, Amsterdam, v. 124, p. 123–138, 2014. Disponível em: <http://dx.doi.org/10.1016/j.talanta.2014.01.034>. Acesso em: 10 abr. 2022.

YU, C. Comments on " Fuzzy programming with nonlinear. **Fuzzy Sets and Systems**, Amsterdam, v. 101, p. 109–113, 1999.


YU, S.; HAN, J. Virtual reality platform-based conceptual design and simulation of a hot cell facility. **International Journal of Advanced Manufacturing Technology**, London, v. 116, n. 1–2, p. 487–505, 2021.

YU, Y.; LI, Y.; ZHANG, Z.; GU, Z.; ZHONG, H.; ZHA, Q.; YANG, L.; ZHU, C.; CHEN, E. A bibliometric analysis using VOSviewer of publications on COVID-19. **Annals of Translational Medicine**, Hong Kong, v. 8, n. 13, p. 816–816, 2020.

ZHU, Q.; WU, J.; SONG, M. Efficiency evaluation based on data envelopment analysis in the big data context. **Computers and Operations Research**, London, v. 98, p. 291–300, 2018. Disponível em: <http://dx.doi.org/10.1016/j.cor.2017.06.017>. Acesso em: 10 abr. 2014.

APÊNDICE A – Código de cálculo da função *Desirability* no modelo de *ProModel*

Lógica de Finalização



```

1 //cálculo de desirability de custo
2 {
3     If v_custo_total > 119 Then
4     {
5         v_desirability_custo = 0
6     }
7     Else
8     {
9         If v_custo_total >= 13 Then
10        {
11            v_desirability_custo = ((v_custo_total-119)/(13-119))
12        }
13        Else
14        {
15            v_desirability_custo = 1
16        }
17    }
18 }
19 //cálculo de desirability de qtde
20 {
21     If v_qtde_total < 17 Then
22     {
23         v_desirability_qtde = 0
24     }
25     Else
26     {
27         If v_qtde_total <= 233 Then
28         {
29             v_desirability_qtde = ((v_qtde_total-17)/(233-17))
30         }
31         Else
32         {
33             v_desirability_qtde = 1
34         }
35     }
36 }
37
38 //cálculo de desirability geral
39 {
40 v_desirability = (v_desirability_custo**0.5)*(v_desirability_qtde**0.5)
41 }

```