

Inteligência Artificial na Seleção de Equipamentos Portuários: Otimizando Decisões com Modelos Generativos

Artificial Intelligence in Port Equipment Selection: Optimizing Decisions with Generative Models
Inteligencia Artificial en la Selección de Equipos Portuarios: Optimizando Decisiones con Modelos Generativos

Recebido
Received
Recibido
14 jun. 2025
Jun 14, 2025
14 jun. 2025

Aceito
Accepted
Aceptado
15 nov. 2025
Nov 15, 2025
15 nov. 2025

Publicado
Published
Publicado
05 jan. 2026
Jan 05, 2026
05 jan. 2026

<https://git.fateczl.edu.br>

e_ISSN
2965-3339

DOI
10.5281/zenodo.20214738

São Paulo

v. 4 | n. 2
v. 4 | i. 2

e42008

Janeiro/Março
January/March
Enero/Marzo

2026



Luiz Filipe de Lara Lima¹
luiz.lima61@fatec.sp.gov.br

Luiz Felipe Rampazzo¹
luiz.rampazzo@fatec.sp.gov.br

Vitor Daniel Oliveira da Silva¹
vitor.silva244@fatec.sp.gov.br

Álvaro Camargo Prado¹
alvaro.prado@fatec.sp.gov.br

Luciana Maria Guimaraes¹
luciana.guimaraes4@fatec.sp.gov.br

1 – Fatec Rubens Lara

Resumo:

A seleção adequada de equipamentos portuários é essencial para garantir a eficiência operacional e a competitividade dos terminais de contêineres. Este artigo propõe uma metodologia que integra a Matriz de Decisão com técnicas de Inteligência Artificial (IA) Generativa para aprimorar o processo de seleção de equipamentos, utilizando como estudo de caso o Reach Stacker. A abordagem visa comparar catálogos de diversos fabricantes, refinando descrições técnicas através de prompts de acesso, com o objetivo de obter respostas mais precisas e eficientes.

Palavras-chave: Seleção de equipamentos; Inteligência artificial generativa; Matriz de decisão; *Reach stacker*; Terminais de contêineres.

Abstract:

The proper selection of port equipment is essential to ensure operational efficiency and the competitiveness of container terminals. This article proposes a methodology that integrates the Decision Matrix with Generative Artificial Intelligence (AI) techniques to enhance the equipment selection process, using the Reach Stacker as a case study. The approach aims to compare catalogs from various manufacturers, refining technical descriptions through access prompts to obtain more precise and efficient responses.

Keywords: Equipment selection; Generative artificial intelligence; Decision matrix; *Reach stacker*; Container terminals.

Resumen:

La selección adecuada del equipo portuario es esencial para garantizar la eficiencia operativa y la competitividad de las terminales de contenedores. Este artículo

propone una metodología que integra la Matriz de Decisión con técnicas de Inteligencia Artificial Generativa (IA) para mejorar el proceso de selección de equipos, utilizando el Reach Stacker como estudio de caso. El enfoque busca comparar catálogos de diferentes fabricantes, refinando descripciones técnicas mediante prompts de acceso, con el objetivo de obtener respuestas más precisas y eficientes.

Palabras clave: Selección de equipo; Inteligencia artificial generativa; Matriz de decisión; Apilador de alcance; Terminales de contenedores.

1. INTRODUÇÃO

A operação eficiente de terminais portuários de contêineres depende diretamente da escolha criteriosa dos equipamentos utilizados, influenciando desde a produtividade até os custos operacionais. Com a ampliação do comércio global e o avanço das tecnologias de automação, a oferta de equipamentos tornou-se mais diversificada, trazendo desafios para a seleção da melhor alternativa. A necessidade de avaliar fatores como capacidade de carga, consumo energético, alcance operacional e custos de aquisição torna esse processo complexo, exigindo abordagens mais sofisticadas para assegurar a escolha mais vantajosa.

Nesse contexto, a Inteligência Artificial (IA) generativa emerge como uma ferramenta promissora, capaz de processar grandes volumes de dados, identificar padrões ocultos e fornecer comparações detalhadas entre diferentes modelos. Sua aplicação na análise de especificações técnicas permite reduzir vieses na tomada de decisão, proporcionando recomendações mais precisas e alinhadas às necessidades operacionais dos terminais. Além disso, a IA pode cruzar informações financeiras e operacionais, estabelecendo uma relação otimizada entre custo e desempenho, o que potencializa a eficiência dos equipamentos escolhidos.

O objetivo deste trabalho é demonstrar a utilização da IA Generativa como alternativa voltada à facilitação da exposição de dados para a escolha de equipamentos, a partir da Matriz de Decisão, amplamente conhecida nas áreas de projetos e de gestão. Também deseja-se mostrar que se pode obter diferentes resultados, condicionados por restrições nas características esperadas dos equipamentos.

Ao longo deste artigo, serão integradas IA Generativa com metodologias consolidadas, como a Matriz de Decisão, para demonstrar como os terminais portuários podem aprimorar significativamente seus processos de escolha de equipamentos. Essa abordagem não apenas facilita a comparação entre fornecedores, mas também permite que a IA processe grandes volumes de dados técnicos, identifique padrões ocultos e gere recomendações precisas. Dessa forma, será evidenciado como a tecnologia se torna uma aliada essencial na modernização da logística portuária, promovendo operações mais ágeis, sustentáveis e economicamente viáveis.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Equipamentos Portuários em Terminais de Contêineres

Nos terminais de contêineres, diversos equipamentos desempenham papéis cruciais na movimentação e armazenagem de cargas, garantindo a eficiência e a fluidez das operações logísticas. Entre os principais equipamentos, destaca-se o *Ship-To-Shore Crane* (STS), um guindaste robusto com ponte levadiça que se estende sobre o navio, utilizado para carregar e descarregar contêineres. Com capacidade de levantar cargas de até 65 toneladas e alcance de 70 metros, o STS permite o posicionamento de contêineres em até 25 fileiras dentro dos navios,

sendo essencial para operações de grande escala (Bichou; Gray, 2005; UNCTAD, 2021).

Outro equipamento fundamental é o *Rubber-Tired Gantry Crane* (RTG), um guindaste montado sobre pneus de borracha, projetado para movimentar contêineres dentro do terminal. Modelos modernos podem empilhar até cinco ou seis contêineres, otimizando o espaço disponível e aumentando a capacidade de armazenamento. Além disso, existe também o Terminal Tractor, que é um veículo especializado na logística portuária, responsável pelo transporte de semirreboques e contêineres entre as pilhas de armazenamento e os guindastes, sendo amplamente adotado em terminais de alta rotatividade devido à sua agilidade e resistência operacional (Notteboom; Vernimmen, 2009).

Dentre as diversas opções disponíveis, destaca-se o *Reach Stacker*, cuja versatilidade e capacidade operacional o tornam essencial para as atividades portuárias. Seu braço telescópico possibilita a elevação de cargas de até 45 toneladas e o alcance da sexta fileira de contêineres empilhados, garantindo maior flexibilidade e eficiência às operações. Neste artigo, ele será o objeto central da análise, em razão de sua importância exclusiva para os terminais de contêineres e de seu impacto direto na eficiência logística (Dekker et al., 2013; Cullinane; Wang, 2007).

2.2 Matriz de decisão na seleção de equipamentos

A Matriz de Decisão é uma ferramenta amplamente empregada na análise multicritério, permitindo comparar alternativas com base em parâmetros objetivos e subjetivos. No contexto portuário, sua aplicação torna-se essencial para a escolha de equipamentos, considerando variáveis técnicas e econômicas que impactam diretamente a eficiência operacional e a viabilidade financeira das operações (Saaty, 2008; Macharis et al., 2012).

Entre os critérios analisados, destacam-se a capacidade de carga, que define o peso máximo suportado pelo equipamento; o alcance e altura de elevação, determinantes para a flexibilidade na movimentação de contêineres; e a velocidade operacional, fator crucial para otimizar o fluxo logístico e reduzir gargalos (Steenken et al., 2004).

Além desses aspectos, a matriz avalia o consumo energético, com foco na eficiência e sustentabilidade dos equipamentos, bem como o custo de aquisição e manutenção, abrangendo o investimento inicial e as despesas recorrentes ao longo da vida útil do ativo. Esses elementos garantem uma tomada de decisão mais embasada e estratégica, maximizando o desempenho operacional dos terminais (Bichou, 2011; Notteboom; Rodrigue, 2021).

A partir de informações extraídas de catálogos de equipamentos de fornecedores distintos, foram obtidas informações que servirão de base para aplicações futuras, a tabela 1 traz o exemplo mais utilizado de Matriz de Decisão.

Tabela 1 - Matriz de decisão

Equipamentos	Capacidade (t)	Centro de Carga (mm)	Pneus	Peso Operacional (t)	Altura de Elevação (mm)	Velocidade Carga/Sem (km/h)	Motor (Modelo)	Potência (kW)	Emissões
Terex TFC 45 h/hc	45	1.320	18.00-25	68,3	15.230	25 / 25	Cummins QSM11	239	Stage IIIA
Ferrari F500.RS1	46	830	18.00-25	68,0	16.100	Não especificado	Cummins QSM11	250	Stage IIIA
Kalmar DRG420-60S5	42	835	18.00-25 PR4/E4	65,5	15.100	22 / 28	Não especificado	Não especificado	Não especificado
Sany C45C2	45	Não especificado	18.00-25 40PR	72,0	15.100	21/25	Cummins QSM11	250	Stage III

Fonte: Adaptado de Catálogos Ferrari, Kalmar, Sany e Terex (2019 e 2014)

2.3 Aplicação da IA Generativa na Construção da Matriz de Decisão

A integração da IA Generativa no processo de construção da Matriz de Decisão envolve uma série de etapas interconectadas, que garantem a eficiência e a precisão na seleção de equipamentos. Inicialmente, a primeira etapa é a coleta de dados, na qual são reunidos catálogos e especificações técnicas de diversos fabricantes de *Reach Stackers*. Esses documentos contêm informações essenciais, como capacidade de carga, alcance, consumo energético e outros parâmetros relevantes, que servem como base para a análise posterior (Venkatasubramanian, 2019).

Uma vez coletados os dados, a próxima etapa é o Processamento de Linguagem Natural (PLN), onde técnicas avançadas de IA são aplicadas para extrair e organizar as informações relevantes dos catálogos. Esse processo é crucial, pois transforma textos técnicos e muitas vezes desestruturados em dados estruturados e comparáveis, permitindo que a IA trabalhe com informações padronizadas e de alta qualidade (Jurafsky; Martin, 2023).

Com os dados devidamente processados, a etapa seguinte é a geração de prompts. Aqui, são desenvolvidas instruções específicas que orientam a IA a comparar e avaliar os equipamentos com base em critérios predefinidos, como eficiência energética, custo-benefício e desempenho operacional. Esses prompts são essenciais, pois direcionam a IA a focar nos aspectos mais relevantes para a tomada de decisão, garantindo que a análise seja alinhada com os objetivos do terminal portuário (Shrestha, Ben-Menahem; von Krogh, 2021).

Por fim, a IA realiza uma análise comparativa, processando os prompts e gerando uma avaliação detalhada entre os equipamentos. Nessa etapa, a IA não apenas compara os dados, mas também destaca as vantagens e desvantagens de cada opção, fornecendo uma compreensão mais clara e embasada. Essa análise final é o que permite aos gestores tomarem decisões informadas, pois combina dados técnicos com critérios estratégicos, garantindo que a escolha do equipamento seja a mais adequada para as necessidades operacionais e financeiras do terminal (IBM, 2022).

2.4 Desenvolvimento do Escalonamento Multicritério Aplicado

A seleção de equipamentos em ambientes portuários constitui um processo crítico que exige a análise simultânea de múltiplos critérios técnicos, operacionais e econômicos. Tradicionalmente, essas decisões eram tomadas de maneira qualitativa ou com base em poucos indicadores isolados. Contudo, a crescente complexidade dos equipamentos e a necessidade de maximizar a eficiência e a sustentabilidade impulsionaram a adoção de métodos quantitativos de análise multicritério (Khoshelham et al., 2024).

Neste contexto, desenvolveu-se uma ferramenta de apoio à decisão baseada em IA, estruturada em quatro níveis progressivos de sofisticação. O objetivo central foi criar um processo capaz de evoluir de operações básicas até uma análise complexa, apta a recomendar o modelo de *Reach Stacker* mais adequado a diferentes realidades portuárias, considerando critérios econômicos, operacionais e ambientais.

O processo completo foi escalonado em quatro níveis metodológicos, de complexidade crescente: (1) Estruturação dos dados, (2) Padronização dos parâmetros, (3) Normalização dos critérios e (4) Cálculo da decisão final ponderada. Dessa forma, a ferramenta viabiliza uma avaliação sistemática e robusta, alinhada às exigências de modernização e sustentabilidade dos terminais portuários (Zhang; Kumar, 2023).

Inicialmente, a IA extrai e organiza os dados fornecidos, estruturando-os em formatos adequados, como um *DataFrame* em *Python*. Essa etapa envolve a padronização dos parâmetros para assegurar a comparabilidade entre diferentes unidades de medida, aplicando técnicas como a normalização min-max (ajustando os valores a uma escala de 0 a 1) e a normalização z-score (distribuindo os dados com média zero e desvio padrão um) (Mubashir et al., 2024).

Após a normalização dos dados, são atribuídos pesos relativos a cada critério, conforme as prioridades estabelecidas — por exemplo, eficiência energética, capacidade de elevação e custo operacional. Para o cálculo do escore final de cada modelo, adota-se o *Weighted Sum Model* (WSM), uma metodologia clássica da análise multicritério de decisão. No WSM, diferentes critérios são ponderados conforme sua importância relativa, e as alternativas são avaliadas pela soma ponderada de seus desempenhos normalizados, segundo a fórmula: $= (w_1 \times x_1) + (w_2 \times x_2) + (w_3 \times x_3) + \dots + (w_n \times x_n)$ em que w representa os pesos atribuídos e x os valores normalizados dos critérios (Triantaphyllou, 2000).

A etapa 1 consiste em traduzir a tabela original de características técnicas dos equipamentos para um modelo de dados digitalizado e manipulável. Para exemplificar, o seguinte script em Python representa esse primeiro nível de processamento (quadro 1).

Quadro 1 - Nível inicial de processamento

```
reach_stackers = [dict(zip(
    ["Modelo", "Capacidade (ton)", "Altura Max (m)", "Peso
Operacional (ton)", "Consumo Energético (kWh)",
"Preço (USD)"]
values
)) for values in [
("TEREX TFC45", 45, 15.2, 69, 12.5, 450000),
("TEREX TFC46", 46, 15.3, 70, 12.6, 455000),
("CVS F500.RS1", 45, 15.1, 68, 12.7, 440000),
("CVS F500.RS2", 45, 15.0, 67, 12.6, 442000),
("CVS F500.RS3", 45, 15.4, 69, 12.4, 448000),
("CVS F500.RS5", 45, 15.5, 70, 12.5, 450000),
("Kalmar DRG420-60S5", 42, 15.1, 72, 12.8, 470000),
("Kalmar DRG450-60S5", 45, 15.3, 74, 13.0, 475000),
("Kalmar DRG450-60S5M", 45, 15.3, 73, 13.1, 478000),
("Kalmar DRG450-60S5X", 45, 15.5, 74, 13.2, 480000),
("SANY SRSC45C2", 45, 15.2, 71, 12.7, 460000),
]]
```

Fonte: Elaborado pelos autores (2025)

Em seguida, no segundo nível de sofisticação, ocorre a padronização dos parâmetros para uniformizar as unidades de medida, facilitando sua comparação posterior. O quadro 2 traz o código que ilustra a organização dos valores.

Quadro 2 - Primeira interação

```
for rs in reach_stackers:
rs["Custo por Tonelada"] = rs["Preço (USD)"] /
rs["Capacidade (ton)"]
```

Fonte: Elaborado pelos autores (2025)

A terceira etapa implica a normalização dos critérios, necessária para eliminar discrepâncias entre escalas distintas, tais como kWh e toneladas. Utilizou-se aqui o método *Min-Max Scaling*, conforme a representação do quadro 3.

Quadro 3 - Segunda interação

```
def normalize(value, min_value, max_value):
    return (value - min_value) / (max_value - min_value)
for key in ["Capacidade (ton)", "Altura Max (m)", "Peso
Operacional (ton)", "Consumo Energético (kWh)",
"Custo por Tonelada"]:
```

Fonte: Elaborado pelos autores (2025)

Finalmente, no quarto e mais avançado nível de sofisticação, aplicou-se o modelo de soma ponderada para determinar o *score* final de cada equipamento, com pesos diferenciados conforme a prioridade dos critérios estabelecidos, mostrado no quadro 4:

Quadro 4 - Terceira interação

```
weights =
{ "Capacidade (ton)": 0.25,
"Altura Max (m)": 0.20,
"Peso Operacional (ton)": 0.15,
"Consumo Energético (kWh)": 0.20,
"Custo por Tonelada": 0.20
}
for rs in reach_stackings:
    rs["Final Score"] = sum(rs[f"Normalized {key}"] * weight
for key, weight in weights.items())
reach_stackings_sorted = sorted(reach_stackings,
key=lambda x: x["Final Score"], reverse=True)
```

Fonte: Elaborado pelos autores (2025)

De maneira geral, este processo automatiza a análise decisória, permitindo não somente a comparação objetiva dos modelos, mas também a adaptação da decisão a diferentes cenários de prioridade operacional.

2.5 Aplicação Prática: Avaliação Multicritério dos Modelos e *Reach Stacker*

Após o desenvolvimento do método de escalonamento e da arquitetura de decisão inteligente, conforme apresentado no item 1, passou-se à aplicação

prática do sistema, utilizando catálogos oficiais dos modelos de *reach stacker*, a saber, os da Kalmar (2018), Sany (2015), Ferrari (2015) e Terex (2013). O objetivo é determinar, com base em critérios técnicos normalizados e ponderados, qual modelo de *Reach Stacker* oferece o melhor desempenho global para operações portuárias.

Inicialmente, os dados referentes aos onze modelos disponíveis foram organizados conforme seus principais parâmetros de desempenho: Capacidade (t), Altura Máxima (m), Alcance Máximo (m), Consumo de Combustível (kWh) e Peso Operacional (kg). Para garantir uma comparação justa entre diferentes unidades de medida e magnitudes, aplicou-se o processo de normalização, conforme detalhado no item 2.4, utilizando técnicas de min-max *scaling* e normalização invertida para parâmetros nos quais valores menores são desejáveis. Em seguida, definiram-se os pesos para cada critério com base em sua relevância operacional (tabela 2):

Tabela 2 - Pesos dos critérios

Critério	Peso (%)
Capacidade	30%
Altura Máxima	25%
Alcance Máximo	20%
Consumo de Combustível	15%
Peso Operacional	10%

Fonte: Elaborado pelos autores (2025)

Com todos os dados normalizados e ponderados, aplicou-se o método WSM para calcular o score final e cada modelo, conforme a fórmula: $(w_1 \times x_1) + (w_2 \times x_2) + (w_3 \times x_3) + \dots + (w_n \times x_n)$ em que *w* representa os pesos atribuídos e *x* os valores normalizados dos critérios. A matriz de decisão resultante da aplicação desse modelo é apresentada, a seguir, na tabela 3:

Tabela 3 – Ranking por critério

Posição	Score Final	Modelo
1º	0,7417	Kalmar DRG450-60S5
2º	0,7417	Kalmar DRG450-60S5M
3º	0,7417	Kalmar DRG450-60S5X
4º	0,7375	SANY SRSC45C2
5º	0,6750	Kalmar DRG420-60S5
6º	0,5292	CVS Ferrari F500.RS1
7º	0,5292	CVS Ferrari F500.RS5
8º	0,4458	CVS Ferrari F500.RS2
9º	0,4458	CVS Ferrari F500.RS3
10º	0,3250	TEREX TFC 46
11º	0,3083	TEREX TFC 45

Fonte: Elaborado pelos autores (2025)

A análise demonstrou que os modelos *Kalmar* DRG450-60S5, DRG450-60S5M e DRG450-60S5X apresentaram os melhores desempenhos, alcançando um score final de 0,7417. Esses modelos destacaram-se por sua excelente capacidade de carga, altura de elevação e alcance, aliados a um consumo de combustível e peso operacional competitivos em relação aos demais. O modelo SANY SRSC45C2

também apresentou desempenho notável, obtendo um score de 0,7375, o que o posiciona como uma alternativa sólida em termos de eficiência global.

Os modelos da linha CVS Ferrari demonstraram desempenho intermediário, com destaque para os modelos F500.RS1 e F500.RS5, cujas pontuações superaram as de seus similares F500.RS2 e F500.RS3. Por outro lado, os modelos TEREX TFC 45 e TEREX TFC 46 apresentaram os menores índices de desempenho, evidenciando limitações frente aos critérios técnicos priorizados neste estudo.

Esses resultados reforçam a eficácia da metodologia de decisão multicritério desenvolvida no item 2.4. A análise foi conduzida por meio de prompts escalonados até o Nível 4, que viabilizaram a normalização automatizada, a ponderação dos critérios, a aplicação do método WSM e a determinação do ranking final. Tal procedimento permite que decisões complexas, envolvendo múltiplos fatores simultaneamente, sejam tomadas de forma objetiva, transparente e tecnicamente fundamentada.

Adicionalmente, destaca-se que, conforme as necessidades estratégicas do terminal, diferentes cenários podem ser simulados. Por exemplo, em operações que priorizem a eficiência energética, é possível atribuir maior peso ao critério de consumo de combustível, o que resultaria na reordenação do ranking, favorecendo modelos com menor consumo específico. De modo análogo, em contextos em que a capacidade máxima de carga seja o fator decisivo, os modelos com desempenho superior nesse aspecto tendem a alcançar pontuações mais elevadas.

Essa flexibilidade da ferramenta evidencia seu potencial não apenas para análises pontuais, mas também como suporte à tomada de decisão em distintos contextos operacionais, adaptando-se de forma dinâmica às prioridades estratégicas do gestor.

3. MÉTODO

Esta investigação adotou uma abordagem quantitativa, utilizando métodos de análise multicritério assistida por inteligência artificial para identificar o modelo de *reach stacker* mais adequado às exigências operacionais, ambientais e econômicas dos terminais portuários atuais. A aplicação de métodos de análise multicritério é amplamente reconhecida como uma abordagem eficaz para resolver problemas complexos e de múltiplos critérios, conforme descrito por Zeleny (1982), autor clássico na área de decisão multicritério.

Primeiramente, organizou-se uma base de dados com especificações técnicas, operacionais e ambientais de diversos modelos de *reach stackers*. As informações foram obtidas a partir de catálogos de fabricantes, fichas técnicas e documentos setoriais. As variáveis consideradas incluem, entre outras, a capacidade de carga, o alcance máximo, o tipo de motorização, o consumo de combustível, as emissões de gases de efeito estufa, o peso operacional e a altura máxima de elevação. Para a estruturação dessa base de dados, seguiu-se a metodologia descrita por Saaty (1980), que propõe um modelo de análise hierárquica para facilitar a decisão com múltiplos critérios.

Esses dados foram organizados em planilhas eletrônicas e, em seguida, tratados e normalizados para permitir comparações entre os modelos. A avaliação seguiu uma lógica de ponderação de critérios, adaptando os cenários simulados conforme as prioridades operacionais, como a maximização da eficiência energética, a redução do impacto ambiental, a otimização de custos operacionais e a melhoria da performance logística. A normalização linear, como abordada por Hwang e Yoon (1981), é uma técnica fundamental para garantir que as variáveis com unidades diferentes possam ser comparadas de forma adequada.

Nesse contexto, a inteligência artificial foi usada para classificar o desempenho dos modelos com base em algoritmos de avaliação multicritério. Técnicas de normalização linear, atribuição de pesos por cenário, cálculo de índices compostos e geração de rankings adaptativos possibilitaram simular diferentes contextos e identificar a melhor alternativa para cada cenário analisado. O uso de IA em problemas de otimização e avaliação multicritério tem sido descrito por Jain e Krishna (2001), que abordam como os algoritmos de inteligência artificial podem ser aplicados para lidar com a complexidade das avaliações.

A metodologia permitiu a identificação clara e objetiva dos modelos mais adequados às necessidades dos terminais portuários, considerando os aspectos de sustentabilidade, eficiência técnica e viabilidade econômica. Os resultados foram apresentados em quadros comparativos e visualizações, facilitando a interpretação estratégica das conclusões.

4. RESULTADOS E DISCUSSÃO

A aplicação prática realizada no item 2.5 confirma a eficácia da metodologia de decisão multicritério desenvolvida no item 1. A análise foi conduzida por meio dos prompts escalonados até o Nível 4, conseguindo realizar a normalização automatizada, ponderação dos critérios, aplicação do método WSM e a determinação do ranking final dos modelos de *Reach Stacker*. Tal procedimento permite que decisões complexas, envolvendo múltiplos fatores simultâneos, sejam tomadas de maneira objetiva, transparente e tecnicamente fundamentada.

Como mencionado anteriormente, uma das principais vantagens da ferramenta desenvolvida é sua flexibilidade para se adaptar a diferentes contextos operacionais. Por meio da modificação dos pesos atribuídos a cada critério, torna-se possível recalcular o ranking dos modelos de acordo com as prioridades estratégicas do terminal. Para ilustrar essa capacidade de adaptação, foi simulado um novo cenário:

Neste cenário, o terminal visa reduzir o consumo energético das operações. Assim, o peso do critério consumo de combustível é elevado para 40%, enquanto os demais são ajustados proporcionalmente (Tabela 4).

Tabela 4 – Segunda rodada de critérios

Critério	Peso (%)
Capacidade	20%
Altura Máxima	15%
Alcance Máximo	15%
Consumo de Combustível	40%
Peso Operacional	10%

Fonte: Elaborado pelos autores (2025)

A nova matriz obtida foi (Tabela 5).

Tabela 5 – Novo *ranking* com novos critérios

Posição	Score Final (eficiência energética)	Modelo2
1º	0,7708	SANY SRSC45C2
2º	0,7458	Kalmar DRG450-60S5M
3º	0,7458	Kalmar DRG450-60S5X
4º	0,7458	Kalmar DRG450-60S5
5º	0,7125	Kalmar DRG420-60S5
6º	0,5542	CVS Ferrari F500.RS1
7º	0,5542	CVS Ferrari F500.RS5
8º	0,4583	CVS Ferrari F500.RS2
9º	0,4583	CVS Ferrari F500.RS3
10º	0,3458	TEREX TFC 45
11º	0,3417	TEREX TFC 46

Fonte: Elaborado pelos autores (2025)

Observa-se que o modelo SANY SRSC45C2 passa a ocupar a primeira posição no ranking. Isso se deve ao seu desempenho superior no critério de consumo de combustível em comparação aos demais modelos, evidenciando que, em contextos em que a eficiência energética é fundamental, a escolha ótima pode ser diferente daquela apontada na análise global.

As simulações demonstram de forma concreta a capacidade da ferramenta de se adaptar a diferentes contextos operacionais, permitindo uma análise multicritério dinâmica e precisa. Com simples ajustes nas porcentagens, a inteligência artificial desenvolvida recalcula automaticamente os scores e reorganiza o ranking, oferecendo suporte decisório ágil e fundamentado.

5. CONSIDERAÇÕES FINAIS

Este estudo teve como objetivo demonstrar como a integração da IA Generativa juntamente com Matriz de Decisão pode otimizar a escolha de equipamentos portuários com critérios e interações com IA claramente definidos e imparcialidade nas escolhas, ponderando somente informações técnicas fornecidas. A aplicação prática revelou que, ao automatizar etapas de coleta, processamento e avaliação de dados, a metodologia entrega rankings de modelos de *Reach Stacker* com elevado grau de confiabilidade e agilidade.

Embora o estudo tenha se centrado nos *Reach Stackers*, a mesma lógica pode ser estendida a outros equipamentos e cenários, a exemplo dos RTG, STS e veículos

portuários ou até mesmo a eficiência energética, climas ou a objetivos a ser conquistado, a exemplo de níveis de emissões de gases ou localizações mais frias e quentes. Ressalta-se que a base de dados utilizada foi limitada a catálogos disponíveis publicamente, fichas técnicas e documentos setoriais, testes em cenários operacionais reais poderão ajustar parâmetros e validar ainda mais a acurácia do modelo. Trabalhos futuros podem explorar a incorporação de dados de sensores em tempo real, assim como métricas de emissões de CO₂, para enriquecer a tomada de decisão com indicadores ambientais dinâmicos.

REFERÊNCIAS

BICHOU, K. A critical review of conventional terminology for classifying seaport operations. **Transportation Research Part E: Logistics and Transportation Review**, v. 41, n. 6, p. 469–487, 2005. Disponível em: <https://doi.org/10.1016/j.tre.2004.06.001>. Acesso em: 12 abr. 2025.

BICHOU, K. Port operations, planning and logistics. In: TALLEY, W. K. (Ed.). **Port Economics**. London: Routledge, 2011. p. 123–145.

CULLINANE, K.; WANG, T. The efficiency of European container ports: A cross-sectional data envelopment analysis. **International Journal of Logistics: Research and Applications**, v. 10, n. 3, p. 237–252, 2007. Disponível em: <https://doi.org/10.1080/13675560701467120>. Acesso em: 17 abr. 2025.

DEKKER, R.; BLOEMHOF, J.; MALLIDIS, I. Operations Research for green logistics – An overview of aspects, issues, contributions and challenges. **European Journal of Operational Research**, v. 219, n. 3, p. 671–679, 2012. Disponível em: <https://doi.org/10.1016/j.ejor.2011.11.010>. Acesso em: 26 abr. 2025.

HWANG, C. L.; YOON, K. **Multiple Attribute Decision Making: Methods and Applications**. New York: Springer-Verlag, 1981.

IBM. **Artificial Intelligence for Decision Making**. International Business Machines Corporation, 2022. Disponível em: <https://www.ibm.com/artificial-intelligence>. Acesso em: 19 abr. 2025.

JAIN, L. C.; KRISHNA, C. K. **Artificial Intelligence: Techniques and Applications**. Berlin: Springer, 2001.

JURAFSKY, D.; MARTIN, J. H. **Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition**. 3. ed. Draft. 2024. Disponível em: <https://stanford.edu/~jurafsky/slp3/>. Acesso em: 10 abr. 2025.

KHOSHELHAM, K.; WANG, Z.; ZHANG, J. Multi-criteria decision-making for equipment selection: A review. **ResearchGate**, 2024. Disponível em: <https://www.researchgate.net/publication/387021549>. Acesso em: 06 mai. 2025.

MACHARIS, C.; DE WITTE, A.; TURCKAERT, M. Multi-criteria analysis as a tool to include stakeholders in project evaluation: The MAMCA method. **Transportation Research Part**

A: Policy and Practice, v. 46, n. 1, p. 1–12, 2012. Disponível em:
<https://doi.org/10.1016/j.tra.2011.09.012>. Acesso em: 22 abr. 2025.

MUBASHIR, M. et al. A survey on data normalization techniques in machine learning. **Applied Sciences**, v. 14, n. 14, 2024. Disponível em: <https://www.mdpi.com/2076-3417/14/14/6174>. Acesso em: 28 abr. 2025.

NOTTEBOOM, T.; RODRIGUE, J.-P. **Port Economics, Management and Policy**. London: Routledge, 2021. Disponível em: <https://www.routledge.com/Port-Economics-Management-and-Policy/Notteboom-Pallis-Rodrigue/p/book/9780367331584>. Acesso em: 04 mai. 2025.

NOTTEBOOM, T.; VERNIMMEN, B. The effect of high fuel costs on liner service configuration in container shipping. **Journal of Transport Geography**, v. 17, n. 5, p. 325–337, 2009. Disponível em: <https://doi.org/10.1016/j.jtrangeo.2008.05.003>. Acesso em: 16 abr. 2025.

SAATY, T. L. **The Analytic Hierarchy Process**: Planning, Priority Setting, Resource Allocation. New York: McGraw-Hill, 1980.

SAATY, T. L. Decision making with the analytic hierarchy process. **International Journal of Services Sciences**, v. 1, n. 1, p. 83–98, 2008. Disponível em: <https://doi.org/10.1504/IJSSci.2008.01759>. Acesso em: 13 abr. 2025.

SHRESTHA, Y. R.; BEN-MENAHM, S.; VON KROGH, G. **Leveraging AI for Decision Support Systems**: Theory and Practice. Cham: Springer, 2021.

STEENKEN, D.; VOß, S.; STAHNBERG, R. Container terminal operation and operations research – A classification and literature review. **OR Spectrum**, v. 26, n. 1, p. 3–49, 2004. Disponível em: <https://doi.org/10.1007/s00291-003-0157-z>. Acesso em: 30 abr. 2025.

TRIANAPHYLLOU, E. **Multi-Criteria Decision Making Methods**: A Comparative Study. Dordrecht: Springer, 2000.

UNCTAD. **Review of Maritime Transport 2021**. United Nations Conference on Trade and Development, 2021. Disponível em: <https://unctad.org/webflyer/review-maritime-transport-2021>. Acesso em: 25 abr. 2025.

VENKATASUBRAMANIAN, V. **Data Science for Engineering Decision Making**. Hoboken: Wiley, 2019.

ZELENY, M. **Multiple Criteria Decision Making**. New York: McGraw-Hill, 1982.

ZHANG, X.; KUMAR, S. Decision-making models for port equipment selection integrating sustainability indicators. **Journal of Marine Science and Engineering**, v. 11, n. 3, 2023. Disponível em: <https://www.mdpi.com/2077-1312/11/3/607>. Acesso em: 08 mai. 2025.

"Os conteúdos expressos no trabalho, bem como sua revisão ortográfica e das normas ABNT são de inteira responsabilidade do(s) autor(es)."

“Declara-se pelos autores que durante a preparação deste trabalho foi(foram) utilizado(s) ChatGPT e DeepSeek para interações com prompts para análise de dados e cálculos. Após utilizar esta ferramenta/serviço, os autores editaram e revisaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo da publicação.”