



EVENTO
ON-LINE



estga
universidade
de aveiro

ConBRepro

XIV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

I CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

04 a 06 de dezembro de 2024

Energias Limpas nas Engenharias

Análise de agrupamento para avaliação de matérias-primas na produção de ferroliga de manganês

Fernando Hiromitus

Universidade Estadual de São Paulo "Julio de Mesquita Filho"

Dr^a. Gislaíne Cristina Batistela

Departamento de Engenharia de - Universidade Estadual de São Paulo "Julio de Mesquita Filho"

Resumo: A indústria siderúrgica é fundamental para a economia global, com aplicações que vão desde a construção civil até a produção de bens de capital. Este setor enfrenta desafios crescentes para aprimorar a eficiência e produtividade, especialmente em processos de produção de ferroligas, como o ferro manganês. A pesquisa atual visa mapear variáveis do processo de produção e identificar as matérias-primas que impactam a produtividade e o rendimento em uma planta de produção de FeMnAC, analisando dados de consumo e produção específicos (junho/2023 - maio/2024). A metodologia incluiu análise de dados multivariada e aplicação de técnicas de clusterização, como o método *k-means*, para categorizar variáveis e identificar padrões de consumo e eficiência energética. Os resultados indicaram que diferentes clusters apresentam distintos perfis de produção e consumos específicos de manganês, energia e carbono. Essa segmentação pode orientar estratégias de otimização, possibilitando à indústria alinhar-se melhor às demandas de sustentabilidade e competitividade.

Palavras-chave: Ferroliga, Clusterização, Produtividade, Rendimento.

Clustering Analysis for Raw Material Assessment in Manganese Ferroalloy Production

Abstract: The steel industry is essential to the global economy, with applications ranging from civil construction to the production of capital goods. This sector faces increasing challenges to enhance efficiency and productivity, especially in the production processes of ferroalloys, such as ferromanganese. The current research aims to map production process variables and identify raw materials that impact productivity and yield in an FeMnAC production plant by analyzing specific consumption and production data (june 2023 - may 2024). The methodology included multivariate data analysis and clustering techniques, such as the *k-means* method, to categorize variables and identify consumption and energy efficiency patterns. The results indicated that different clusters exhibit distinct production profiles and specific consumptions of manganese, energy, and carbon. This segmentation can guide optimization strategies, enabling the industry to better align with sustainability and competitiveness demands.

Keywords: Ferroalloy, Clustering, Productivity, Yield.

1. Introdução

A indústria siderúrgica é vital na economia global e desempenha um papel crucial na sociedade sustentável moderna. Sua relevância abrange a indústria de transformação, contribuindo para o PIB e a criação de empregos. Além de ser fundamental como fornecedora de materiais para construção civil e na produção de bens de capital como automóveis e eletrodomésticos (VIANA, 2023).

O aço é um dos principais materiais empregados pelo homem, o seu uso foi intensificado após a revolução industrial, sendo sua produção atualmente um forte indicador de desenvolvimento econômico do país, uma vez que está ligada aos setores de construção civil, automobilístico, produção de máquinas e equipamentos e de bens de consumo (INSTITUTO AÇO BRASIL, 2019).

Uma das matérias primas para a produção do aço são as ligas de Manganês, que contribuem na redução de teores indesejados de enxofre e oxigênio nos aços, além de melhorar sua resistência e maleabilidade (GRUPO MARINGÁ, 2024).

O CRU é uma empresa reconhecida internacionalmente por prover análise, referência de preços e consultoria no mercado de mineração, metais e fertilizantes. Em seu relatório divulgado em abril de 2024 apresenta o desempenho de 31 empresas produtoras de Ferro Manganês Alto Carbono - FeMnAC e 46 empresas de Ferro Silício Manganês - FeSiMn (GRUPO MARINGÁ, 2024). Isto demonstra a limitação de informação referente a plantas industriais e conseqüentemente em estudos científicos relacionados ao produto e processo avaliado.

De maneira geral, as empresas estão procurando formas de aprimorar seu desempenho a fim de assegurar sua competitividade no mercado. A busca pela melhoria contínua pode servir como um instrumento diante das instabilidades e incertezas do ambiente externo. Para isso, é comum utilizar abordagens estruturadas, empregando ferramentas para análise, monitoramento e controle dos processos (OPRIME; LIZARELLI, 2010).

A pesquisa foi norteadada com a proposta de responder a seguinte questão: Quais as principais matérias primas que impactam na produção e nos consumos específicos de carbono, energia e manganês?

O objetivo geral deste estudo consiste em analisar o desempenho de um processo de produção de ferroliga, com foco na produtividade e rendimento

Para atingir esse propósito, propõe-se os seguintes objetivos específicos:

- Mapear as variáveis do processo;
- Identificar quais matérias primas possui maior impacto na produtividade e rendimento do processo.

2. Metodologia

O estudo exploratório buscou identificar a relação entre as variáveis de processo e os indicadores de produção e consumos específicos. O estudo foi realizado em uma planta de produção de FeMnAC no Forno 1, considerando dados do período de junho/2023 a maio/2024.

Os dados foram extraídos das planilhas de Boletim de Controle Operacional e Folha de Balança, que são registros diários contendo informações sobre a produção, o processo e o consumo de matérias-primas. Como o abastecimento dos fornos é contínuo e o escoamento do material ocorre em intervalos de duas a três horas, há um descompasso natural entre a entrada e a saída de material no forno. Para reduzir as variações observadas ao longo do dia, optou-se por agrupar os dados em intervalos diários.

As informações referentes à matéria-prima correspondem ao consumo específico que é calculado pela quantidade utilizada, em quilogramas, dividida pela produção líquida, com a umidade subtraída do peso. Cada matéria-prima tem características e custos distintos, sendo crucial identificar o mix que equilibre melhor produtividade e custo, o Quadro 1 apresenta a relação de matérias primas consideradas.

Quadro 1- Variáveis de matérias primas

Função	Variável	Unidade	Descrição
Redutora	Cons_Biorredutor	kg/t	Consumo de biorredutor produzido pela empresa e tem origem vegetal
	Cons_CoquePetroleo		Consumo de Coque produzido a partir do petróleo
Fundente	Cons_Dolomita		Consumo de Calcário Dolomítico
Fonte de Ferro	Cons_Briquete Ferro		Consumo de briquete de ferro, material produzido internamente na empresa que consiste em um material aglomerado a frio de carepa, um subproduto da produção do aço.
Fontes de Manganês	Cons_Min. A		Consumo de minério de manganês fornecido pelo fornecedor A
	Cons_Min. B		Consumo de minério de manganês fornecido pelo fornecedor B
	Cons_Min. C		Consumo de minério de manganês fornecido pelo fornecedor C
	Cons_Min. D		Consumo de minério de manganês fornecido pelo fornecedor D
	Cons_Min. E		Consumo de minério de manganês fornecido pelo fornecedor E
	Cons_Min. F		Consumo de minério de manganês fornecido pelo fornecedor F
	Cons_Min. G		Consumo de minério de manganês fornecido pelo fornecedor G
	Cons_Min. H		Consumo de minério de manganês fornecido pelo fornecedor H
	Cons_Min. I		Consumo de minério de manganês fornecido pelo fornecedor I
	Cons_Min. J		Consumo de minério de manganês fornecido pelo fornecedor J
	Cons_Refusão		Consumo de finos de liga excedente do consumo de lingotamento
	Cons_Briquete Mn		Consumo de briquete de manganês, material produzido internamente na empresa que consiste em um material aglomerado a frio de finos de minérios

Fonte: Elaborado pelo autor (2024)

A produtividade e rendimento do processo pode ser medido através dos indicadores apresentados no Quadro 2.

Quadro 2- Indicadores de produtividade e desempenho

Indicador	Unidade	Descrição
CEE	kWh/t	O consumo específico de energia é o principal indicador de produtividade do processo. Ele é calculado dividindo a quantidade de energia consumida durante a corrida pela produção líquida.
CEC	kg/t	O consumo específico de carbono representa a quantidade de carbono consumido para produzir uma tonelada de liga.
CEMn	kg/t	O consumo específico de manganês representa a quantidade de manganês consumido para produzir uma tonelada de liga.
Prod_liquida	t/dia	Refere-se à quantidade de liga gerada na corrida.

Fonte: Elaborado pelo autor (2024)

2. Revisão bibliográfica

2.1 Produção de Ferroliga

As ferroligas de Manganês são combinações de elementos químicos, a Tabela 1 apresenta a especificação do produto e valor típico.

Tabela 1 - Especificação química do FeMnAC

Elemento	Limite Mínimo (%)	Limite Máximo (%)	Valor Típico (%)
Mn	74,0	78,0	-
Si	-	1,5	-
C	-	7,5	-
P	-	0,25	-
Al	-	-	0,040
Ti	-	-	0,040
B	-	-	<0,010


Fonte: Grupo Maringá (2024)

Os principais objetos da produção de ferro manganês são (OLSEN; TANGSTAD; LINDSTAD, 2007):

- Operar o forno de forma estável e em alta carga;
- Minimizar o consumo de carbono e energia;
- Produzir liga e escória com as composições requeridas;
- Assegurar o alto rendimento de manganês;
- Minimizar as emissões dos gases de efeito estufa e compostos nocivos.

Além disso é necessário que a empresa produza a custos competitivos. A Figura 1 apresenta a distribuição dos custos de produção. Minérios, redutores e eletricidade somados representam cerca de 87% do custo total.


Figura 1 - Composição do custo de produção



Fonte: Adaptado de GRUPO MARINGÁ (2024)

O consumo de energia é influenciado pelo efeito combinado das reações exotérmicas e endotérmicas no processo, bem como pela entalpia dos materiais que entram e saem do forno. As reações químicas mais significativas e os fluxos de massa estão representados na Figura 2, onde as reações exotérmicas (em vermelho) diminuem o consumo de energia elétrica, enquanto as reações endotérmicas (em azul) o aumentam (OLSEN; TANGSTAD; LINDSTAD, 2007).

Figura 2 - Principais reações no forno elétrico



Fonte: OLSEN; TANGSTAD; LINDSTAD (2007)

O consumo específico e a recuperação do manganês são influenciados por fatores como temperatura, basicidade da escória, razão CaO/MgO e teor de Al_2O_3 . O aumento da temperatura favorece a redução endotérmica e a recuperação de manganês é maior em escórias básicas. A adição de cal aumenta a atividade de MnO e diminui sua saturação. Contudo, escórias com basicidade acima de 1,1 têm menor impacto na recuperação. Altos níveis de CaO, MgO e Al_2O_3 aumentam a viscosidade da escória, dificultando a redução e retardando a reação (JIPNANG; MONHEIM; OTERDOOM, 2013).

A quantidade de carbono necessária para a produção de manganês por redução direta do minério pré-reduzido é fixa para uma composição metálica específica, além do consumo adicional devido à reação de Boudouard. Fatores como a reatividade do minério e do coque, mineralogia, porosidade, tamanho das partículas, presença de álcalis, geometria do forno e condições operacionais influenciam o grau de pré-redução (OLSEN; TANGSTAD; LINDSTAD, 2007).

2.3 Análise estatística do processo

Os métodos univariados analisam uma única variável, enquanto os multivariados lidam com várias variáveis simultaneamente. A natureza é multivariada, pois fenômenos como o clima dependem de diversos fatores, como vento, temperatura e pressão atmosférica. A análise de dados multivariados é útil para processar grandes conjuntos de dados, revelando estruturas ocultas que aprimoram a compreensão dos fenômenos estudados (BOHM et al., 2013).

Nos processos de fabricação, é comum que as variáveis estejam correlacionadas, o que está relacionado à qualidade do processo, que envolve diversas características (FREITAS et al., 2013).

A análise multivariada abrange um conjunto de métodos estatísticos onde a maioria das variáveis em um conjunto de dados fornece informações essenciais para a tomada de decisões (BOHM et al., 2013; FREITAS et al., 2013).

A seleção da técnica multivariada depende principalmente do tipo de variável, se for classificada como dependentes utiliza-se uma técnica de dependência, onde as variáveis independentes explicam a dependente como por exemplo a regressão múltipla. Caso contrário, utiliza-se uma técnica de interdependência, onde todas as variáveis são analisadas simultaneamente, sem distinção como por exemplo na análise fatorial (HAIR et al., 2009).

A análise de agrupamentos, ou análise de clusters, é um conjunto de técnicas exploratórias utilizadas para identificar comportamentos semelhantes entre observações (como indivíduos ou empresas) com base em determinadas variáveis. O objetivo principal é criar grupos que sejam homogêneos internamente e heterogêneos entre si, de modo que as observações dentro de um grupo sejam semelhantes, mas diferentes das observações de outros grupos (FÁVERO; BELFIORE, 2017).

A técnica é descritiva e exploratória, sem base para inferências estatísticas, e a formação dos grupos depende dos elementos do procedimento, podendo não refletir uma estrutura real dos dados. Para que os grupos sejam significativos, é essencial uma fundamentação conceitual e validação. A análise não é generalizável e depende da seleção cuidadosa e fundamentada das variáveis, pois escolhas inadequadas podem comprometer os resultados (HAIR, 2009).

Essa técnica não supervisionada agrupa alternativas semelhantes em clusters e possui dois principais tipos de algoritmos: o hierárquico, que cria uma hierarquia de clusters (aglomerativo ou divisivo), e o não hierárquico, onde as alternativas são alocadas em clusters após a definição do número de grupos pelo tomador de decisão (ISHIZAKA; LOKMAN; TASIOU, 2021).

Permite classificar a distância entre variáveis utilizando os índices de proximidade de Pearson, que representam as proporções de dependência não linear entre elas (FORTES et al., 2022).

A clusterização se distingue da classificação pela ausência de variáveis-alvo, pois não busca classificar ou prever valores, mas sim dividir os dados em grupos homogêneos. Essa técnica é amplamente aplicada em diversas áreas, como na medicina, onde pode ser utilizada para agrupar tipos de doenças com base nas características e sintomas dos pacientes (ALDINO et al., 2021).

FORTES et al. (2022) conduziu um estudo sobre a corrosão do aço carbono, por meio da análise de cluster, foi possível determinar uma relação significativa entre os parâmetros físico-químicos da água e a perda de peso das placas de aço carbono.

BERTON et al. (2020) aplicou o cluster não hierárquico para agrupar fazendas voltadas a produção de pecuária leiteira, diferenciando de acordo com o seu sistema produtivo. Com isso avaliou o efeito na pegada ambiental, eficiência produtiva e competição entre ração para animais e alimentos para humanos.

ALDINO et al. (2021) utilizou em seu estudo o agrupamento não hierárquico através da abordagem K-Means para agrupar áreas potenciais de produção de milho com base na área de colheita, produção e ano da colheita e conseguiu identificar as melhores áreas para produção.

A primeira etapa é criar uma medida de similaridade entre os objetos a serem agrupados, indicando o grau de correspondência entre eles com base nas características analisadas (HAIR, 2009).

As medidas de distância são utilizadas para definir a proximidade entre observações em uma análise de agrupamentos. Existem várias formas de calcular essas distâncias, cada uma com características específicas. Neste trabalho foi adotado a Distância Euclidiana que

é a mais comum sendo generalizada para múltiplas variáveis. A distância euclidiana calcula a linha reta entre dois pontos. A distância d entre duas observações p e q é dada por:

$$d_{pq} = \sqrt{\sum_{j=1}^k (X_{jp} - X_{jq})^2} \quad (1)$$

Como os dados não possuíam as mesmas unidades de medida, houve a padronização por meio do procedimento de escores Z (Z -scores). Nesse método, para cada observação i , o valor da nova variável padronizada Z_i é obtido subtraindo-se a média da variável original X e, em seguida, dividindo-se pelo seu desvio padrão conforme equação (2). Dessa forma, todas as variáveis padronizadas terão média 0 e desvio padrão 1, eliminando a influência das unidades de medida nas distâncias entre as observações. Além disso, o procedimento Z -scores mantém a distribuição original das variáveis.

$$ZX_{ji} = \frac{X_{ji} - \bar{X}_j}{s_j} \quad (2)$$

Para definição do agrupamento final, optou-se pelo uso de um procedimento de agrupamento não hierárquico.

Os resultados do procedimento não hierárquico são menos influenciados por observações atípicas, pela medida de distância utilizada e pela inclusão de variáveis irrelevantes ou inadequadas. Métodos não hierárquicos são adequados para grandes conjuntos de dados, pois não exigem o cálculo de matrizes de similaridade entre todas as observações, mas apenas entre cada observação e os centróides dos agrupamentos. Além disso, algoritmos de otimização que permitem a realocação de observações podem ser aplicados em conjuntos de dados de qualquer tamanho.

A técnica de agrupamento k -means tem como objetivo dividir os n indivíduos de um conjunto de dados multivariados em k grupos ou clusters ($G_1, G_2, \dots, G_k$), onde G_i representa o conjunto de n_i indivíduos no i -ésimo grupo. A implementação mais comum do k -means é aquela que busca encontrar a partição dos n indivíduos em k grupos, minimizando a soma dos quadrados dentro dos grupos (WGSS) para todas as variáveis, este critério é explicitamente definido como:

$$WGSS = \sum_{j=1}^q \sum_{l=1}^k \sum_{i \in G_l} (x_{ij} - \bar{x}_j^{(l)})^2 \quad (3)$$

Onde: $\bar{x}_j^{(l)} = \frac{1}{n_l} \sum_{i \in G_l} x_{ij}$ é a média dos indivíduos do G_l na variável j .

O valor de k foi obtido através da análise do gráfico gerado através do comando `fviz_nbclust()` do pacote `facto extra` do programa R, identificando o momento da suavização da curva plotada.

Baseando-se no agrupamento obtido foi categorizado a base de dados e obtido a média dos valores da base de dados indicadores com a finalidade de encontrar os melhores resultados.


Para conclusão do procedimento foi verificado se os valores de cada uma das três variáveis incluídas na análise são estatisticamente diferentes entre os três clusters. Para isso,

utilizou-se o teste F da análise de variância de um fator (*one-way ANOVA*) com um nível de significância de 5%.

4. Resultados

A análise começou pela determinação do número de agrupamentos. A Figura 3 mostra a curva da soma dos quadrados dentro dos clusters, na qual foi identificado que o número ideal de clusters para o conjunto de dados de Matéria Prima é igual a oito.

Figura 3 - Número ótimo de cluster



Fonte: Elaborado pelo autor

A Tabela 2 apresenta o número de elementos e a média dos valores das variáveis da clusterização do conjunto de dados Matéria Prima. Avaliando os dados é possível visualizar a distinção entre os cluster impactados principalmente pelos consumos de fontes de Mn que é o Brique de Mn, Refusão e os Minérios de A a J.

Tabela 2 - Média dos dados de cada agrupamento

Cluster	Qtde	Cons_Biorredutor	Cons_Brique de Ferro	Cons_Brique de Mn	Cons_Coque Petroleo	Cons_Dolomita	Cons_Refusão	Cons_Min A	Cons_Min B	Cons_Min C	Cons_Min D	Cons_Min E	Cons_Min F	Cons_Min G	Cons_Min H	Cons_Min I	Cons_Min J
1	21	264	183	0	197	296	51	1150	115	909	0	0	0	0	244	0	0
2	18	293	200	368	235	337	0	0	638	1109	351	236	0	0	0	0	0
3	42	285	126	0	204	332	70	1169	80	873	55	217	1	130	0	0	0
4	61	269	214	441	238	325	0	0	6	1132	1029	20	0	0	0	0	0
5	39	280	156	515	229	296	0	379	0	1316	158	241	0	0	0	0	0
6	63	259	80	0	202	141	93	761	24	93	468	253	0	289	0	6	633
7	25	300	164	0	201	235	75	932	160	630	2	1	0	148	0	311	236
8	53	324	177	0	201	343	31	1428	0	503	0	0	589	0	0	0	0

Fonte: Elaborado pelo autor

A Tabela 3 apresenta a média dos indicadores, é possível destacar: o conjunto 6 apresentou os melhores resultados de consumo, o conjunto 7 apresentou uma maior produção decorrente da maior produtividade e o conjunto 1 que apesar de um valor médio de CEE apresentou bons resultados de consumo específico de carbono e manganês, além de uma produção líquida elevada. E de forma negativa destacam-se os conjuntos 2 e 3 que apresenta elevados consumos específicos e menor produção.


Tabela 3: Média dos indicadores

Cluster	CEE	CEC	CEMn	Produção Líquida
1	2.825	387	1.041	65,6
2	2.947	452	1.139	62,9
3	2.833	416	1.114	60,3
4	2.894	429	1.045	64,6
5	2.891	434	1.052	62,7
6	2.621	382	1.053	65,8
7	2.684	416	1.085	67,9
8	2.834	446	1.097	64,8

Fonte: Elaborado pelo autor

A Figura 4 apresenta o intervalo de confiança da média dos indicadores referente a clusterização do conjunto de dados Matéria Prima. Para o consumo específico de energia os melhores resultados foram do cluster 6 e 7. Para o consumo específico de carbono os melhores resultados foram do cluster 1 e 6. Para o consumo específico de manganês os melhores resultados foram do cluster 1, 4, 5 e 6. E para produção os melhores resultados foram do cluster 1, 6, 7 e 8.

Figura 4: Intervalo de confiança da média dos indicadores em relação ao agrupamento



Fonte: Elaborado pelo autor

O resultado do teste F da análise de variância de um fator (*one-way ANOVA*) é apresentado na Tabela 4. O *p-value* para a análise do CEE e o CEC apresentaram valores inferiores a 0,05, rejeitando a hipótese nula (H_0) desta forma aceita-se a hipótese alternativa de que nem todas as médias são iguais, enquanto para a análise de CEMn e Prod. Liq. apresentou

valor superior a 0,05, aceitando a hipótese nula (H_0) desta forma aceita-se que todas as médias são iguais e não há diferenciação entre os clusters.

Tabela 4: Teste F da análise de variância de um fator

	CEE	CEC	CEMn	Prod. Liq.
Valor Estat. F	6,85	6,42	1,60	1,54
p.value	0,000	0,000	0,134	0,152
Avaliação	rejeita H_0	rejeita H_0	Não rejeita H_0	Não rejeita H_0

Fonte: Elaborado pelo autor

O conjunto que apresentou melhor desempenho foi o conjunto 6, caracterizado pelo menor consumo específico de manganês e carbono. Esse conjunto também corresponde ao maior número de dias analisados, o que indica uma representatividade sólida dos dados. No que se refere às matérias-primas, destacam-se o maior consumo de Refusão e de Minério J. A Refusão, composta por finos do próprio material que recircula no processo, permite uma melhor utilização dos recursos disponíveis. O Minério J, por sua vez, apresenta um grau de oxidação inferior ao dos demais minérios, o que pode facilitar reações mais eficientes e reduzir o consumo de carbono.

Além disso, o menor uso de Dolomita nesse conjunto pode reduzir a necessidade de calcinação do CaO e MgO, o que implica um menor consumo energético. Essa característica também tende a resultar em um volume menor de escória, promovendo um processo mais eficiente.

5. Conclusões

Este artigo explorou a aplicação da análise de agrupamento (clusterização) para formar conjuntos de dados com características semelhantes, avaliando o desempenho de um processo com base na produção e nos consumos específicos de manganês, carbono e energia.

A partir dos dados coletados ao longo de 322 dias, foram formados 8 conjuntos. Observou-se que o conjunto 6, composto por um mix de matérias-primas com maior consumo de Refusão e Minério J e menor consumo de Dolomita, apresentou menor consumo de energia e carbono e, além disso, está entre os menores consumos de manganês, com uma produção superior.

A técnica mostrou-se promissora para agrupar dados automaticamente, convertendo uma série contínua de variáveis de matérias-primas em um número limitado de conjuntos. Isso facilitou a análise dos dados e ajudou a identificar o melhor mix de matérias-primas.

A pesquisa se limita aos tipos de matérias-primas utilizadas, e embora incluam 10 tipos diferentes de minérios de manganês, o estudo pode não ser aplicável a novos materiais, o que poderia gerar novos clusters.

Futuras pesquisas poderiam focar na automação do processo de classificação ou na aplicação da análise de agrupamento para outras variáveis de produção.

Referências

ALDINO, A. A. *et al.* Implementation of K-Means Algorithm for Clustering Corn Planting Feasibility Area in South Lampung Regency. *Journal of Physics: Conference Series*. **Anais...**IOP Publishing Ltd, 27 jan. 2021.

BERTON, M. *et al.* Environmental impact and efficiency of use of resources of different mountain dairy farming systems. **Agricultural Systems**, v. 181, 1 maio 2020.

BOHM, K.; SMIDT, E.; TINTNER, J. Application of Multivariate Data Analyses in Waste Management. Em: **Multivariate Analysis in Management, Engineering and the Sciences**. InTech, 2013.

EGBUERI, J. C. Groundwater quality assessment using pollution index of groundwater (PIG), ecological risk index (ERI) and hierarchical cluster analysis (HCA): A case study. **Groundwater for Sustainable Development**, v. 10, 1 abr. 2020.

FÁVERO, L. P.; BELFIORE, P. **Manual de Análise de Dados**. 1. ed. Rio de Janeiro: Elsevier, 2017.

FORTES, J. C. *et al.* Corrosion of Carbon Steel in Extreme Environments by Acid Mine Water: Experimental Study of the Process Using a Factorial Analysis Tool. **Minerals**, v. 12, n. 8, 1 ago. 2022.

GRUPO MARINGÁ. **Nossos produtos - Siderurgia**. Disponível em: <<https://www.grupomaringa.com.br/siderurgia>>. Acesso em: 19 out. 2024.

GRUPO MARINGÁ. **Produção de Ferro-Liga**. Itapeva: 2024.

HAIR, J. F. *et al.* **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman, 2009.

ISHIZAKA, A.; LOKMAN, B.; TASIOU, M. A Stochastic Multi-criteria divisive hierarchical clustering algorithm. **Omega (United Kingdom)**, v. 103, 1 set. 2021.

JIPNANG, E.; MONHEIM, P.; OTERDOOM, H. **Modeling and simulation process optimisation model for FeMn and SiMn production**. in: The Thirteenth International Ferroalloys Congress, Efficient Technologies in Ferroalloy Industry, Almaty, Kazakhstan, pp. 811–820.

OLSEN, S. E.; TANGSTAD, M.; LINDSTAD, T. **Production of Manganese Ferroalloys**. Trondheim: SINTEF and Tapir Academic Press, 2007.

OPRIME, P. C.; LIZARELLI, F. L. Felação entre estrutura para a melhoria contínua e desempenho e estrutura organizacional relationship between organizational structure for continuous improvement and performance. **Revista Produção Online**, v. 10, n. 2, p. 250–273, jun. 2010.

VIANA, F. L. E. **Indústria Siderúrgica**. Fortaleza: Banco do Nordeste do Brasil, ano 6, n.176, julho. 2021.

YUAN, G. L. *et al.* Environmental geochemical mapping and multivariate geostatistical analysis of heavy metals in topsoils of a closed steel smelter: Capital Iron & Steel Factory, Beijing, China. **Journal of Geochemical Exploration**, v. 130, p. 15–21, jul. 2013.