

UNIVERSIDADE FEDERAL DE MINAS GERAIS
DEPARTAMENTO DE ENGENHARIA DE MINAS
Curso de Especialização em Engenharia de Recursos Minerais

Edwardes Antônio Dias Júnior

**ANÁLISE DE DADOS DE ROCHAS DE CROMITA VISANDO A MELHORIA DE
UM ALGORITMO DE CLASSIFICAÇÃO BASEADA EM SENSORES**

Belo Horizonte

2023

Edwardes Antônio Dias Júnior

**ANÁLISE DE DADOS DE ROCHAS DE CROMITA VISANDO A MELHORIA DE
UM ALGORITMO DE CLASSIFICAÇÃO BASEADA EM SENSORES**

Artigo apresentado ao Programa de Pós-Graduação em Engenharia de Minas da Universidade Federal de Minas Gerais (UFMG) como requisito para obtenção do título de Especialista em Engenharia de Recursos Minerais.

Orientador: Professor Hugo César Coelho Michel

Belo Horizonte

2023



UNIVERSIDADE FEDERAL DE MINAS GERAIS

CURSO DE ESPECIALIZAÇÃO EM ENGENHARIA DE RECURSOS MINERAIS

UFMG

ATA DA DEFESA DO ARTIGO DO ALUNO EDUARDES ANTÔNIO DIAS JÚNIOR

Realizou-se, no dia 24 de novembro de 2022, às 13:30 horas, na plataforma MS Teams, da Universidade Federal de Minas Gerais, a defesa de Artigo, intitulado "ANÁLISE DE DADOS DE ROCHAS DE CROMITA VISANDO A MELHORIA DE UM ALGORITMO DE CLASSIFICAÇÃO BASEADA EM SENSORES", apresentado por EDUARDES ANTÔNIO DIAS JÚNIOR, número de registro 2020720854, graduado no curso de ENGENHARIA MECÂNICA, como requisito parcial para a obtenção do certificado de Especialista em ENGENHARIA DE RECURSOS MINERAIS, à seguinte Comissão Examinadora: Professor Hugo César Coelho Michel (Universidade Federal de Minas Gerais) - Orientador, Professora Andréia Bicalho Henriques (Universidade Federal de Minas Gerais), Professor Pedro Henrique Alves Campos (Universidade Federal de Minas Gerais).

A comissão considerou a defesa do artigo:

(X) Aprovada

() Reprovada

Nota: **95**

Finalizando os trabalhos, lavrei a presente ata que, lida e aprovada, vai assinada por mim e pelos membros da Comissão.

Belo Horizonte, 24 de novembro de 2022.

Documento assinado digitalmente
gov.br HUGO CESAR COELHO MICHEL
Data: 30/11/2022 14:51:50-0300
Verifique em <https://verificador.iti.br>

Prof. Hugo César Coelho Michel (Mestre)


Risid Magriots Papini
Coordenadora do Curso de Especialização
em Engenharia de Recursos Minerais


Prof. Andréia Bicalho Henriques (Doutora)


Alireia Domingos
Secretária do Curso de Especialização
em Engenharia de Recursos Minerais


Prof. Pedro Henrique Alves Campos (Mestre)

AGRADECIMENTOS

Este trabalho foi elaborado com a contribuição de Priscila Maria Esteves e Pablo de Souza de Oliveira, a quem sou grato por todo apoio, parceria e contribuições!

Agradeço a Steinert Latinoamericana Ltda. e a Cia de Ferro Ligas da Bahia S.A. (“Ferbasa”) pelo suporte oferecido à elaboração deste trabalho.

“As dificuldades fortalecem a mente, assim como o trabalho o faz com o corpo.” (Sêneca)

RESUMO

A tecnologia de classificação baseada em sensores (*Sensor-Based Sorting*, SBS) tem sido utilizada para separar *lump* (de cromita) de rochas de baixo teor há cerca de sete anos em uma mineradora no nordeste do Brasil. Esta tecnologia melhorou a qualidade e a produtividade, substituindo uma operação de seleção manual por uma classificação automática feita por um equipamento. Em uma tentativa de melhor compreender a correlação do teor de Cr₂O₃ com a leitura dos sensores, mil e oitocentas rochas foram individualmente digitalizadas em conjunto com a análise química, na premissa de metodologia “*Rock by Rock*”. Este estudo aborda uma análise de dados das leituras de sensores de raio-x e laser, em conjunto com as análises químicas, para melhor compreensão do comportamento e influência do teor de cromita nas respostas dos sensores. Esta análise demonstra que o teor de ferro pouco influência nos resultados de classificação e valida a importância da distribuição granulométrica da alimentação nesse tipo de tecnologia. Por fim, o atual algoritmo ainda é comparado com uma rede neural, indicando uma possível melhora na classificação ao se utilizar aprendizagem supervisionada.

Palavras-chave: classificação mineral, classificação baseada em sensores, cromita, redes neurais;

ABSTRACT

The sensor-based sorting technology has been used to separate chromite lump (chromite ore) from low grade rocks for about seven years in a mining company at the northeast of Brazil. This technology has improved the quality and the productivity, replacing a hand-picking operation for an automatic sorting equipment. In a tentative to better understand the correlation of the Cr₂O₃ grade and the sensors readings, one thousand and eight hundred rocks have been individually scanned and assayed, on a “Rock by Rock” methodology. This study approaches a data analysis of the x-ray and laser readings, together with the chemical assays, to better understand the behavior and influence of the chromite content on the sensor’s responses. The actual algorithm is compared also with a neural network, indicating a possible improvement on the classification using supervised learning.

Keywords: ore sorter, sensor-based sorting, chromite, neural networks;

LISTA DE FIGURAS

Figura 1 – Diagrama de processamento de dados do software KNIME.	14
Figura 2 – Relação de massa por faixa granulometria.....	16
Figura 3 – Análise do produto de cromita por faixa granulométrica.....	17
Figura 4 – Recuperação mássica (a) e metalúrgica (b) de cromita por faixa granulométrica. .	18

LISTA DE TABELAS

Tabela 1 – Quantidade de Rochas analisadas por tipo, origem e tamanho.	13
Tabela 2 – Resultados para o mineral cromita, com os classificadores DE-XRT e Rede Neural.	16
Tabela 3 – Resultados para o óxido de ferro, com os classificadores DE-XRT e Neural.	18

SUMÁRIO

1. INTRODUÇÃO	10
2. ESTUDO DE CASO: FERBASA – Cia de Ferro Ligas da Bahia.....	12
2.1 A FERBASA	12
2.2 A Tecnologia “ <i>Sensor Based Sorter</i> ”	12
3. METODOLOGIA PARA ANÁLISE DE DADOS.....	13
4. RESULTADOS E DISCUSSÕES.....	16
5. CONCLUSÃO.....	19
REFERÊNCIAS	20

1. INTRODUÇÃO

Há uma necessidade crescente na indústria mineral para a aplicação de equipamentos de alta tecnologia que permitam fornecer soluções sustentáveis para o processamento de minerais. Nesse contexto, a aplicação da tecnologia de classificação baseada em sensores, “*sensor-based-sorter*” (SBS) evoluiu significativamente nos últimos anos.

O sistema SBS consiste na aplicação de diversos sensores para a, *i.e.*, classificação, de partículas de minério com base em suas propriedades. A separação é realizada para partículas grosseiras, geralmente acima de 10 mm. Nesse sentido, a classificação pode ocorrer no início do processamento mineral, de forma a pré-concentrar o minério, reduzindo assim a quantidade de material no processo a jusante ou até mesmo já obter um produto comercial, com teor metalúrgico (Arvidson, 2014).

Ao rejeitar precocemente mineral de baixo teor, ou até mesmo mineral estéril, em frações de tamanho mais grosseiro, a aplicação da tecnologia permite a redução dos custos de processamento, aumento da produtividade, bem como propicia a redução de impactos ambientais. Nesse sentido, a tecnologia tem provado a capacidade de gerar mudanças com ganhos significativos de custo e sustentabilidade (Robben, 2019)

No entanto, também é importante ressaltar que a aplicação de equipamentos do tipo SBS requer uma melhor preparação do material (*e.g.*, rochas) a ser introduzido para classificação, a fim de garantir sua adequação, *i.e.*, sua melhor apresentação, aos sensores disponíveis. Este é um fator importante que desempenha um papel fundamental no desenvolvimento dos algoritmos e da escolha de quais sensores serão utilizados para a classificação. Nesse sentido, é muito importante realizar uma avaliação adequada sobre os requisitos de britagem, peneiramento e da superfície das rochas, ao considerar um projeto SBS (Ketelhodt 2009).

Por se tratar de um equipamento de tecnologia avançada, tanto em hardware (*i.e.*, instrumentação por raio-X, triangulação via laser, sensores indutivos, câmeras, sistema de aquisição e sistema para processamento digitais de sinais), como em software (*i.e.*, interface de operação associada a diversos algoritmos para análise de dados), é necessária uma configuração prévia deste software, *i.e.*, o sistema responsável por determinar a classificação dos minérios, que pode ser ajustado a diversos cenários de classificação. Dessa forma, é importante que o engenheiro responsável pela tarefa de “sintonizar” o SBS tenha

conhecimentos sobre o minério de interesse, sua mineralogia e os principais teores das rochas coletadas, de maneira a compreender melhor os resultados apresentados pelos dados provenientes do equipamento, bem como suas correlações com o referido minério (Bassey Udoudo, 2010)

Por meio dessas correlações as propriedades físicas e químicas reais das rochas são evidenciadas e com isso permite-se um melhor ajuste do equipamento, mediante adequações na configuração do software, atendendo demandas produtivas ou mesmo variabilidades das frentes de lavra, viabilizando inclusive recursos que antes não se mostravam economicamente viáveis.

2. ESTUDO DE CASO: FERBASA – Cia de Ferro Ligas da Bahia

2.1 A FERBASA

A Companhia Brasileira de Ferro Ligas da Bahia S.A., FERBASA, é a única produtora nacional de ligas de ferro cromo (Andrade, BNDS, 1999). Sendo o cromo um importante mineral em todo o mundo, ele é utilizado em processos de fundição (areia de cromita), indústrias metalúrgicas (no aço inoxidável), químicas e de refratários (Sampaio, 2020). Com o objetivo de inovar e se manter competitiva no cenário global, a FERBASA implementou a utilização da tecnologia *sensor-based-sorter* (SBS) em 2013, no projeto denominado “*Hard Lump*” (Ferbasa, 2020).

2.2 A Tecnologia “*Sensor Based Sorter*”

A tecnologia *sensor-based-sorter* (SBS) pode combinar diferentes tipos de sensores para realizar a leitura de propriedades das partículas minerais, dentre propriedades ópticas como a cor (câmara espectro de luz visível), brilho e geometria (sensor de triangulação laser 3D), propriedades condutivas (sensor indutivo) e densidade atômica (sensor de raio-X por transmissão). A leitura dessas propriedades é realizada em tempo real, e conforme algoritmo previamente programado, o equipamento classifica as rochas de acordo com a necessidade do cliente, seja remoção de contaminantes e/ou aumento de teor (Steinert, 2020).

3. METODOLOGIA PARA ANÁLISE DE DADOS

O estudo de análise de dados, foi realizado mediante 1.800 rochas de minério de cromo, de uma mesma mina da Ferbasa. As rochas foram obtidas de forma manual, mediante separação visual, por uma equipe de funcionários da mineradora e foram classificadas entre *lump*, disseminado e estéril. Estas rochas foram analisadas pelo equipamento SBS do fabricante Steinert, modelo KSS 200 L XRT, utilizando sensores de raio-X de transmissão (*Dual Energy X-Ray*, DE-XRT) e sensor de triangulação laser, sendo todas informações, digitalizadas e enviadas ao software de análise do equipamento.

Após, para validação das análises, um registro fotográfico e a análise química do teor de cromita (Cr_2O_3) foram realizadas para cada uma das 1.800 rochas. Os dados obtidos por meio das leituras dos sensores foram relacionados às análises de densidade e teor de Cr_2O_3 obtidos em laboratório para melhor compreensão e validação do uso de um SBS como um todo, bem como da conseqüente influência das propriedades físico-químicas na classificação dos minérios utilizando esta tecnologia.

Para uma melhor representatividade do material estudado, agrupou-se as rochas em 3 faixas de tamanhos distintos: $2'' < \text{tamanho} \leq 3''$, $3'' < \text{tamanho} \leq 4''$ e $4'' < \text{tamanho} \leq 5''$. Sendo oriundas ainda de 2 fontes distintas, da mina (ROM - *run out of mine*) e de uma pilha de baixo teor (*stockpile*). A Tabela 1 apresenta a relação dos dados e a forma como eles foram separados.

Tabela 1 – Quantidade de Rochas analisadas por tipo, origem e tamanho.

Granulometria	ROM			Stockpile		
	Lump	Disseminado	Rejeito	Lump	Disseminado	Rejeito
+2-3"	100	100	100	100	100	100
+3-4"	100	100	100	100	100	100
+4-5"	100	100	100	100	100	100
TOTAL	900			900		

Fonte: elaboração própria.

A análise é realizada referente aos dados das propriedades levantadas em laboratório e pelo equipamento SBS, sendo denominadas *atributos* neste trabalho. Logo, quatro atributos provêm de análise laboratorial: *peso*, *teor de óxido de cromo* (Cr_2O_3), *teor de óxido de ferro* (% FeO) e *densidade* (g/cm^3). Estes devem ser compreendidos como atributos de referência

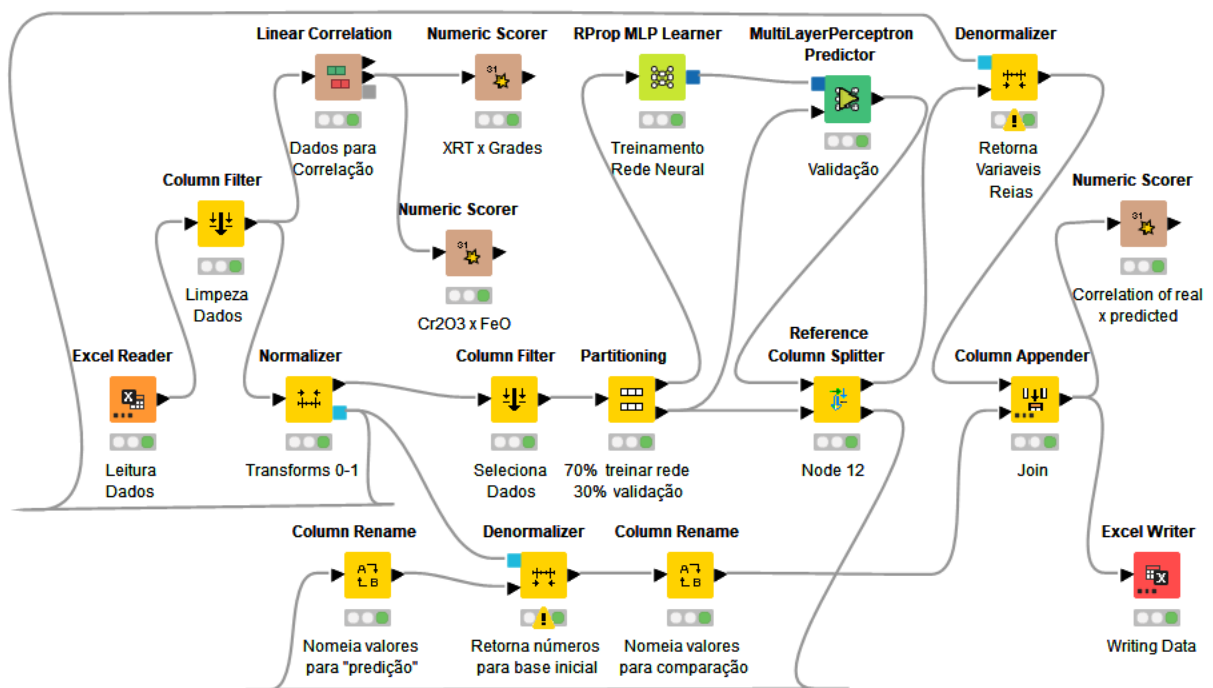
para validação do equipamento, de onde foram coletados outros trinta e cinco atributos, por meio do software proprietário do fabricante do SBS.

Inicialmente, um pré-processamento dos dados obtidos, referentes às 1.800 rochas que passaram pelo SBS, foi realizado utilizando o software Microsoft Excel, onde foi possível retirar 11 rochas da análise, apontadas como inutilizadas, seja devido um dado corrompido, ou amostra perdida, entre outros fatores.

Após a etapa de pré-processamento, a análise dos dados é realizada utilizando-se o *software* KNIME. O KNIME é um *software* que visa democratizar a análise de dados (*Data Analytics*) e, portanto, utiliza uma linguagem de alto nível e abstração da complexidade inerente de diversos algoritmos utilizados nesta área, auxiliando, e facilitando, a exploração dos dados, descobertas de informações “ocultas”, novas compreensões e previsões (KNIME, 2022a). O fluxo de trabalho é composto de tarefas individuais, chamadas de nós, representadas por blocos, que podem desempenhar as mais diversas tarefas, *i.e.*, ler e gravar arquivos, transformar dados, treinar modelos e visualizar dados, (KNIME, 2022b).

Portanto, o fluxo de trabalho (*workflow*) elaborado para a análise dos *atributos* mencionados é apresentado na Figura 1.

Figura 1 – Diagrama de processamento de dados do software KNIME.



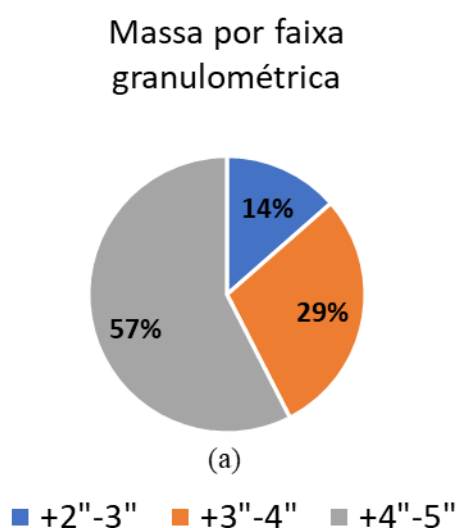
Fonte: elaboração própria.

No *workflow* da Figura 1, é possível observar que, da esquerda para a direita, o fluxo inicia com a leitura dos dados de um arquivo Excel (bloco *Excel Reader*), seguido por um pré-tratamento dos dados (bloco *Column Filter*) e análise de correlação (blocos sequenciais *Linear Correlation* e *Numeric Scorer*) para os teores de cromita e óxido de ferro, ambos aferidos em laboratório, e para o classificador DE-XRT com os teores de cromita. Foi utilizado ainda uma rede neural do tipo Perceptron Multicamada (*Multi Layer Perceptron - MLP*), como método classificatório das leituras dos sensores. Método este que requer uma série de etapas de preparação (blocos *Normalizer*, *Column Filter* e *Partitioning*) para iniciar o treinamento da rede neural MLP (bloco *RProp MLP Learner*) e sua consequente classificação, predição (através do bloco *MultiLayer Perceptron Predictor*). Para o correto fluxo de trabalho, várias etapas auxiliares são necessárias (blocos *Column Rename*, *Denormalizer*, *Reference Column Splitter* e *Column Appender*) para finalmente se realizar uma análise estatística dos valores reais com os valores da predição da rede neural e a gravação de todos os dados obtidos neste processamento de dados (nos blocos *Numeric Scorer* e *Excel Writer*, respectivamente).

4. RESULTADOS E DISCUSSÕES

Para análise de dados, foram utilizados 30% das rochas, uma vez que 70% delas foram utilizadas para treinar a rede neural. Dessa população, o teor médio de cromita calculado é de 22% sendo o de oxido de ferro 14%. A correlação de Pearson encontrada, entre os 2 teores, é de 0,2386. O peso da população é 886 kg sendo 57,5% da granulometria grosseira (+4"-5"), 28,9% média (+3"-4") e 13,6% finos (+2"-3"), conforme Figura 2.

Figura 2 – Relação de massa por faixa granulometria



Fonte: elaboração própria.

Para se considerar uma massa de rochas como produto, determinou-se como teor de corte, a amostra de população em que o teor obtido seja 38% de Cr₂O₃. Otimizando a classificação para se obter a maior a massa possível, por meio do classificador DE-XRT, bem como pela rede neural, identificada apenas como “Neural”, os percentuais de massa recuperada e de recuperação metalúrgica, são indicados na Tabela 2.

Tabela 2 – Resultados para o mineral cromita, com os classificadores DE-XRT e Rede Neural.

Cr ₂ O ₃	Produto			Rejeito			Co-Produto		
	Massa	Teor	Rec. Met	Massa	Teor	Rec. Met	Massa	Teor	Rec. Met
DE-XRT	24,8%	38,0%	42,5%	18,6%	2,2%	1,9%	56,5%	21,8%	55,6%
Neural	38,3%	38,0%	65,6%	24,5%	2,2%	2,5%	37,3%	19,0%	32,0%

Fonte: elaboração própria.

Para avaliação da eficiência da classificação, além do produto, considerou-se ainda uma quantidade de massa como estéril, maior possível, em que o teor de Cr₂O₃ não ultrapasse 2,2% e a massa restante foi considerada como co-produto, Tabela 2, a ser concentrada na planta do cliente como areia de cromita, pós cominuição, mediante separação magnética (processo com menor recuperação metalúrgica e mais oneroso).

Conforme Tabela 2, a rede neural, apresentou 54,4% mais massa no produto (38,3% contra 24,8%) e 31,7% mais rejeição de massa como estéril (24,5% contra 18,6%). O classificador utilizado atualmente, DE-XRT, apresentou uma menor eficiência, categorizando uma massa maior como co-produto, cerca de 51,5% a mais (56,5% contra 37,3%) se comparada com a massa de produto intermediário gerada pela rede neural. Este resultado é corroborado pelo maior coeficiente de correlação de Pearson da rede neural, de 0,9554, contra 0,8440 calculado para a o classificador DE-XRT.

Ao se analisar o resultado por faixas granulométricas, Figura 3, ambos classificadores possuem resultados similares para a granulometria grosseira (+4-5”) com maior discrepância, menos massa recuperada, a medida em que se reduz a granulometria, conforme Figura 4(a). No caso da granulometria média (+3-4”), o classificador de rede neural chega a recuperar x3,13 mais massa em comparação com o classificador DE-XRT, enquanto para a granulometria fina (+2-3”), esse multiplicador chega a x12,67.

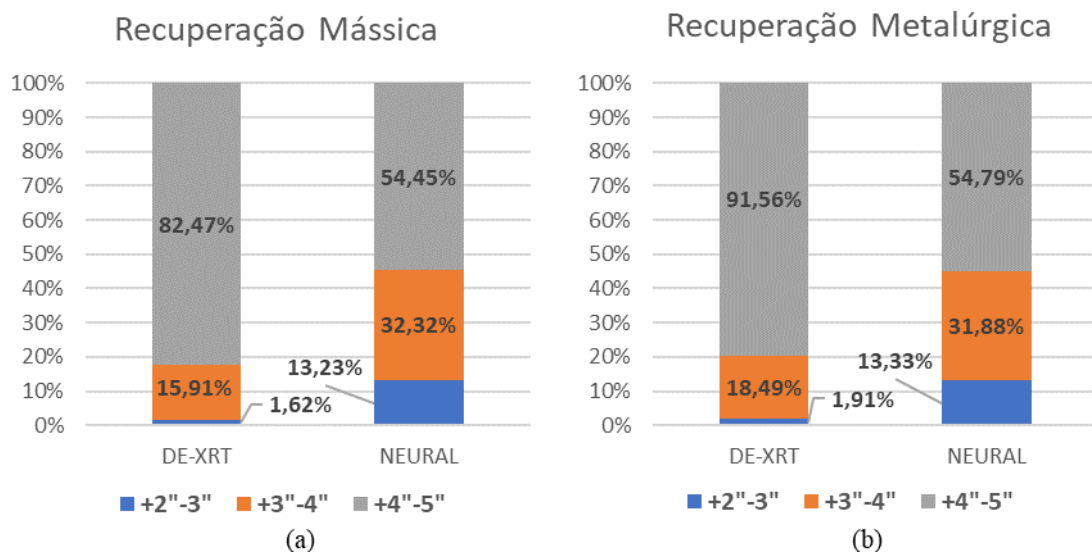
Figura 3 – Análise do produto de cromita por faixa granulométrica.

Classificador	DE-XRT			Neural		
	Massa	Teor	Rec. Met	Massa	Teor	Rec. Met
+2”-3”	0,40%	40,02%	0,73%	5,07%	38,27%	8,74%
+3”-4”	3,95%	39,45%	7,03%	12,38%	37,47%	20,90%
+4”-5”	20,49%	37,68%	34,79%	20,85%	38,24%	35,93%
Total/Média	24,85%	38,00%	42,55%	38,30%	37,99%	65,57%

Fonte: elaboração própria.

Analisando a recuperação metalúrgica, a maior parte do mineral recuperado, aproximadamente 92%, se encontra na fração grossa para o classificador DE-XRT, enquanto para o classificador de rede neural, essa proporção já cai para quase metade, cerca de 55%, conforme Figura 4(b).

Figura 4 – Recuperação mássica (a) e metalúrgica (b) de cromita por faixa granulométrica.



Fonte: elaboração própria.

Quanto ao óxido de ferro, que apresentou o menor coeficiente de correlação de Pearson com a cromita, avaliando-se o teor das 3 classificações obtidas (produto, rejeito e co-produto) têm-se:

Tabela 3 – Resultados para o óxido de ferro, com os classificadores DE-XRT e Neural.

FeO	Produto			Rejeito			Co-Produto		
	Peso	Teor	Rec. Met.	Peso	Teor	Rec. Met.	Peso	Teor	Rec. Met.
DE-XRT	24,8%	14,9%	27,1%	18,6%	14,3%	19,6%	56,5%	12,8%	53,3%
Neural	38,3%	14,9%	41,9%	24,5%	14,1%	25,3%	37,3%	12,0%	32,7%

Fonte: elaboração própria.

Este resultado corrobora a baixa relação entre os 2 minerais na leitura dos sensores, conforme, Figura 2, uma vez que os teores são muito similares entre as 3 classificações obtidas (teores próximos de 12% e 14%) e o próprio teor de alimentação (14%), além de não haver grandes diferenças desses teores entre ambos os classificadores, conforme Tabela 3.

5. CONCLUSÃO

A análise de dados auxilia na compreensão dos fatores que impactam na classificação baseada sem sensores, na aplicação do minério de cromita, na operação da FERBASA. Tanto o classificador comumente utilizado, DE-XRT, como a rede neural analisada, apresentaram diferenças significativas na recuperação conforme faixa granulométrica. Esse efeito é explicado pela limitação da tecnologia de raio-x de transmissão que naturalmente possui maior absorção atômica para materiais mais espessos. Isso justifica a implementação da tecnologia *multi-sensor sorting* (MSS), em que mais sensores são utilizados para compensar esse efeito. A própria FERBASA já utiliza esta tecnologia, de maneira que o estudo aqui apresentado não representa a condição operacional, nem resultados, atuais. Porém, além de reforçar a importância da granulometria das rochas na classificação, os resultados demonstram o potencial da utilização da aprendizagem supervisionada, em que a rede neural apresentou melhores resultados de classificação do que a metodologia DE-XRT. Os resultados respondem também ao questionamento da influência do óxido de ferro na classificação, em que em ambos os classificadores aqui analisados, o impacto no resultado pode ser considerado desprezível.

A análise em separado por granulometrias, para geração de produtos em faixas distintas, pode gerar otimizações na produção, assim como a comparação da rede neural, com a metodologia atualmente utilizada na FERBASA, pode gerar melhores resultados. Ambos os casos, demonstram o potencial da análise de dados aplicados à mineração e os estudos devem ser continuados de maneira a se otimizar tanto o processo, quanto o algoritmo para se obter uma maior eficiência na classificação com a tecnologia de separação baseada em sensores.

REFERÊNCIAS

Andrade, M. L. A., Cunha, L. M. da S., & Gandra, G. T. (1999). Panorama da Indústria Mundial de ferroligas. BNDES Setorial- Biblioteca Digital, 57–114.

Arvidson, B. R., & Wotruba, H. (2014). Ore sorting. *Mineral Processing and Extractive Metallurgy: 100 Years of Innovation*, 209–221. <https://doi.org/10.1016/b978-075064450-1/50016-3>

Bassey Udoudo, O. (2010). Modelling the efficiency of an automated sensor-based sorter. *University of Exeter*, 215. <http://hdl.handle.net/10036/118786>

FERBASA. (2020). *Reunião Pública 3T20/9M20*.

Ketelhodt, L. (2009). Viability of optical sorting of gold waste rock dumps. *World Gold Conference 2009*, 271–278.

KNIME. (2022a). Getting Started Guide. Disponível em: <https://www.knime.com/getting-started-guide>. Acessado: 10 de novembro de 2022.

KNIME. (2022b). Workbench Guide. Disponível em: https://docs.knime.com/latest/analytics_platform_workbench_guide/index.html. Acessado: 10 de novembro de 2022.

Robben, C., & Wotruba, H. (2019). Sensor-based ore sorting technology in mining—past, present and future. *Minerals*, 9(9), 1–25. <https://doi.org/10.3390/min9090523>

Sampaio, J.A; Andrade M.C; Sobrinho, J. (2004). *Aproveitamento de rejeitos de cromita por processos gravíticos. 1*, 283–290.

Steinert. (2020). *Magnetic Separation & Sensor-Based Sorting from a Single Source*. Cologne, Germany: Internal Communication.

Varela, J. J., Wotruba, H., & Petter, C. O. (2006). Optical sorting applied for Brazilian carbonate rock. *IMPC 2006 - Proceedings of 23rd International Mineral Processing Congress*, 325–330.