



INSTITUTO TECNOLÓGICO VALE



**Programa de Pós-Graduação em Instrumentação, Controle e  
Automação de Processos de Mineração (PROFICAM)  
Escola de Minas, Universidade Federal de Ouro Preto (UFOP)  
Associação Instituto Tecnológico Vale (ITV)**

**Dissertação**

**DESENVOLVIMENTO DE UM *SOFT SENSOR* PARA INFERÊNCIA DE  
EFICIÊNCIA ENERGÉTICA DE MOINHO DE BOLAS EM CIRCUITO FECHADO A  
ÚMIDO**

**Diego Rafael Monteiro Diniz**

**Ouro Preto  
Minas Gerais, Brasil  
2020**

Diego Rafael Monteiro Diniz

DESENVOLVIMENTO DE UM SOFT SENSOR PARA INFERÊNCIA DE  
EFICIÊNCIA ENERGÉTICA DE MOINHO DE BOLAS EM CIRCUITO FECHADO A  
ÚMIDO

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. Agnaldo Jês da Rocha Reis, D.Sc.

Coorientador: Prof. Alan Kardek Rego Segundo, D.Sc.

Ouro Preto  
2020





A entrada para a mente do homem  
é o que ele aprende, a saída é o  
que ele realiza. Se sua mente não  
for alimentada por um  
fornecimento contínuo de novas  
ideias, que ele não pode trabalhar com  
um propósito, e se não houver uma  
saída por uma ação, sua mente  
torna-se estagnada. Tal mente é  
um perigo para o indivíduo que a  
possui e inútil para a comunidade  
(Jeremias W. Jenks)

# Agradecimentos

O presente trabalho não poderia ter chegado ao seu desfecho final sem o apoio e suporte de várias pessoas. Em primeiro lugar, gostaria de agradecer a Deus por me proporcionar essa grande oportunidade e a toda a minha família, em especial aos meus pais, que sempre me deram forças e incentivo incondicional para que fosse possível desenvolver dentro dessa etapa importante da minha vida.

Desejo igualmente agradecer os professores Agnaldo Rocha Reis e Alan Kardek Rego Segundo (orientador e coorientador, respectivamente) pelas ótimas orientações, motivação, empenho e o incansável apoio ao longo do desenvolvimento deste trabalho.

Desejo igualmente agradecer a VALE SA e, em especial, aos gestores Vicentino Rodrigues e a Juliene Oliveira por me concederem esta oportunidade e permitir que fosse possível conciliar a rotina de trabalho com a dedicação necessária para essa jornada.

Por último, agradeço muito a todos os meus colegas de trabalho e meus amigos próximos por sempre serem um combustível para a minha motivação e perseverança.

“Nascer sabendo é uma limitação porque obriga a apenas repetir e, nunca, a criar, inovar, refazer, modi car. Quanto mais se nasce pronto, mais refém do que se sabe e, portanto, do passado; aprender sempre o que mais impede que nos tornemos prisioneiros de situações que, por serem inéditas, não sabíamos enfrentar.”  
(Mário Sérgio Cortella)

## Resumo

Resumo da Dissertação apresentada ao Programa de Graduação em Instrumentação, Controle e Automação de Processos de Mineração como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

# DESENVOLVIMENTO DE UM SOFT SENSOR PARA INFERÊNCIA DE EFICIÊNCIA ENERGÉTICA DE MOINHO DE BOLAS EM CIRCUITO FECHADO ÚMIDO

Diego Rafael Monteiro Diniz

Setembro/2020

Orientadores: Agnaldo José da Rocha Reis  
Alan Kardek Rego Segundo

Em processos de moagem em plantas de beneficiamento mineral, os estudos relacionados ao seu consumo de energia são comumente relacionados aos custos do processo de cominuição. A medição do consumo de energia é capaz de fornecer tomadas de decisão para atendimentos específicos granulométricos desejadas com baixo consumo de energia. Porém, essa medição diretamente pode ser realizada de forma direta, sendo necessária adoção de equipamentos para medição do percentual de produto retido em malha passante, os quais possuem elevado custo e necessitam de obra especializada para a sua manutenção. Neste trabalho é apresentado o desenvolvimento de uma nova estratégia baseada em um soft sensor para inferência da eficiência energética em circuitos de moagem fechados úmidos, permitindo o aprimoramento da tomada de decisões das áreas operacionais responsáveis. Uma Rede Perceptron Multi-Camadas (PMC) treinada com o algoritmo de Levenberg-Marquadt foi empregada como motor do soft sensor. Dados reais de um circuito de moagem foram considerados para o desenvolvimento e validação do modelo proposto. Três cenários diferentes foram analisados. O melhor cenário apresentou um coeficiente de determinação  $R^2$  igual a 0,87, sendo um modelo com boa capacidade de generalização, atendendo a solução para a inferência desejada.

Palavras-chave: moinho de bolas, redes neurais artificiais, soft sensors

Macrotema: Usina; Linha de Pesquisa: Instrumentação no Processamento de Minérios; Tema: Eficiência Energética; Área Relacionada da Vale: Circuito de Moagem Úmido - Mina de Timbopeba.



## Abstract

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and Automation of Mining Process as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

### DEVELOPMENT OF A SOFT SENSOR FOR ENERGY EFFICIENCY INFERENCE OF WET CLOSED BALL MILLS

Diego Rafael Monteiro Diniz

September/2020

Advisors: Agnaldo José da Rocha Reis  
Alan Kardek Rego Segundo

In grinding processes in ore beneficiation plants, studies related to their energy consumption are commonly related to the costs of the comminution process. The measurement of energy consumption is capable of providing decision making for its effective control, meeting the desired granulometric specifications with low energy consumption. However, this measurement cannot be performed directly, and it is necessary to adopt equipment to measure the percentage of product retained in specific through-conveyors that have a high cost and the need for specialized labor to maintain them. In this work, the development of a novel strategy based on a Soft Sensor approach for the inference of the Energy Efficiency of a Wet Closed Ball Mills is presented. With the proposed tool, the decision making by the responsible operating areas could be improved. A Multi-Layered Perceptron trained with the Levenberg-Marquadt algorithm was employed as the Soft Sensor engine. Real data from a milling circuit was considered for developing and validating the proposed model. Three different scenarios have been analyzed. The best scenario presented a determination coefficient  $R$  equal to 0.87, being a model with satisfactory generalization capacity, attending the solution to the desired inference.

Keywords: artificial neural networks, ball mill, soft sensors.

Macrotheme: Mill; Research Line: Instrumentation in Mineral Processing; Theme: Energy Efficiency; Related Area of Vale: Wet Grinding Circuit - Timbopeba Mine.

# Lista de Figuras

Figura 2.1	Moinho Tubular. Fonte: Luz et al. (2010). . . . .	25
Figura 2.2	Ação de forças sobre um corpo moedor cônico. Fonte: Luz et al. (2010). . . . .	26
Figura 2.3	Consumo energético x carga moedora. Fonte: Rowland e Kjos (1969). . . . .	27
Figura 2.4	Consumo energético x velocidade. Fonte: Kelly e Spottiswood (1982). . . . .	27
Figura 2.5	Exemplo de representação de dados de ensaio de moagem primária - 12x12 polegadas. Fonte: Donda (2018). . . . .	31
Figura 2.6	Fluxograma de processo de moagem - Mina de Timbopeba/VALE SA . . . . .	33
Figura 2.7	Moinho de bolas - Mina de Timbopeba/VALE SA . . . . .	34
Figura 2.8	Fluxo de desenvolvimento de soft sensor Adaptado de: (KADLEC et al, 2009). . . . .	38
Figura 2.9	Representação do método bagging através de um fluxograma . . . . .	43
Figura 2.10	Representação de um neurônio artificial. Fonte: Demuth et al. (2009). . . . .	46
Figura 2.11	Exemplo de rede feedforward com múltiplas camadas. Fonte: Haykin (2009). . . . .	47
Figura 4.1	Evolução da seleção de variáveis durante a etapa de pré-processamento de dados. . . . .	59
Figura 4.2	Evolução da base de dados durante a etapa de pré-processamento de dados. . . . .	59
Figura 4.3	Simulação preliminar — Desempenho da rede em épocas de treinamento, com base no critério de desempenho MSE para os dados de validação do modelo. . . . .	60
Figura 4.4	Simulação preliminar — Critério de parada pelo número de validações. . . . .	61
Figura 4.5	Simulação preliminar — Análise de regressão dos dados de saída da rede e dos alvos. . . . .	62
Figura 4.6	Simulação preliminar — Comportamento do modelo comparado aos alvos na etapa de treinamento. . . . .	63
Figura 4.7	Simulação preliminar — Histograma do erro absoluto entre o modelo e os alvos. . . . .	64
Figura 4.8	Avaliação de desvio dos dados. . . . .	65
Figura 4.9	Análise de colinearidade das variáveis selecionadas. . . . .	66
Figura 4.10	Evolução da seleção de variáveis durante a etapa de pré-processamento de dados. . . . .	67
Figura 4.11	Evolução da base de dados durante a etapa de pré-processamento de dados. . . . .	67

Figura 4.12 Simulação preliminar aprimorada — Desempenho da rede em épocas de treinamento, com base no critério de desempenho MSE para os dados de validação do modelo. . . . .	68
Figura 4.13 Simulação preliminar aprimorada — Critério de parada pelo número de validações. . . . .	68
Figura 4.14 Simulação preliminar aprimorada — Análise de regressão dos dados de saída da rede e dos alvos. . . . .	69
Figura 4.15 Simulação preliminar aprimorada — Comportamento do modelo comparado aos alvos na etapa de treinamento. . . . .	70
Figura 4.16 Simulação preliminar aprimorada — Histograma do erro absoluto entre as saídas do modelo e os alvos. . . . .	71
Figura 4.17 Avaliação de outliers por diagrama de caixa - variável TO.FY4305.03. . . .	72
Figura 4.18 Simulação com projeto de experimentos - Evolução da base de dados durante a etapa de pré-processamento de dados. . . . .	72
Figura 4.19 Simulação com projeto de experimentos — Desempenho da rede em épocas de treinamento, com base no critério de desempenho MSE para os dados de validação do modelo. . . . .	74
Figura 4.20 Simulação com projeto de experimentos — Critério de parada pelo número de validações. . . . .	74
Figura 4.21 Simulação com projeto de experimentos — Análise de regressão dos dados de saída da rede e dos alvos. . . . .	75
Figura 4.22 Simulação com projeto de experimentos — Comportamento do modelo comparado aos alvos na etapa de treinamento. . . . .	76
Figura 4.23 Simulação preliminar aprimorada — Histograma do erro absoluto entre as saídas do modelo e os alvos. . . . .	77

# Lista de Tabelas

Tabela 2.1	Características e parâmetros do circuito de moagem da VALE / Mina de Timbopeba . . . . .	35
Tabela 3.1	Variáveis de processo candidatas como entradas para o modelo de sensor	52
Tabela 4.1	Planejamento de experimentos . . . . .	73
Tabela 4.2	Resultados das simulações realizadas . . . . .	77
Tabela 5.1	Variáveis de processo candidatas como entradas para o modelo de sensor	81

# Lista de Siglas e Abreviaturas

- ARMAX Modelo Auto-Regressivo de Médias Móveis com Variáveis Exógenas
- BHA Algoritmo black hole
- CFTV Circuito Fechado de Televisão
- CLP Controlador Lógico Programável
- CNN Rede Neural Convolutiva
- DAKELM Máquinas de Aprendizado Extremo do tipo Domain Adaptation Kernel
- DAMKELM Máquinas de Aprendizado Extremo do tipo Domain Adaptation Multi-Kernel
- DOE Projeto de Experimentos
- EF Engenharia Energética do Circuito de Moagem
- ELM Máquinas de Aprendizado Extremo
- FFT Transformada Rápida de Fourier
- GSHHO Algoritmo de seno de ouro de Harris Hawk
- IoE Internet da Energia
- IoT Internet das Coisas
- IQR Amplitude Inter-Quartis
- JITL Aprendizado Just-in-Time
- KPCA Análise de Componentes Principais para Núcleos
- KPLS Núcleos de Mínimos Quadrados Parciais
- LIMS Sistema de Gestão de Informações sobre Laboratórios

LSSVM Máquinas de Vetores de Suporte por Mínimos Quadrados  
 PMC Rede Perceptron Multi-Camadas  
 MSE Erro Médio Quadrático  
 NARMAX Modelo Auto-Regressivo Não-Linear de Médias Móveis com Variáveis Exógenas  
 PCA Análise de Componentes Principais  
 PIMS Sistema de Gestão de Informações sobre Processos  
 PLS Mínimos Quadrados Parciais  
 PSM Analisador de Tamanho de Partículas  
 RBF Rede de Base Radial  
 RELM Máquinas de Aprendizado Extremo Regularizadas  
 $R_f$  Percentual Retido em uma Malha na Alimentação do Processo  
 RNA Rede Neural Artificial  
 $R_p$  Percentual Retido no Produto do Processo na Mesma Malha de Retenção Alimentação  
 SLNPP Projeções de Preservação de Estruturas Locais em Locais Supervisionadas  
 SVM Máquinas de Vetores de Suporte  
 $W_1$  Índice de Trabalho  
 $W_{1o}$  Índice de Trabalho Operacional

# Lista de Símbolos

$dE$  Diferencial de energia necessária para se gerar um diferencial de tamanho  $dL$ , em kWh

$E$  Consumo específico, em kWh/t

$E(\%)$  Fator percentual de eficiência energética

$F_{80}$  Malha em que passam 80% da alimentação, em mm

$h_n$  Função alvo de saída

IQR Amplitude inter-quartis

$k$  Constante relativa ao material, em Wh

$K$  Constante empírica que depende do material a ser cominuído

LI Limite inferior do diagrama de caixa

$F(x(i);w)$  Função aproximada pela rede

$e_{av}(w)$  Função custo do método de Levenberg-Marquadt

$g$  Vetor de gradientes da rede

$H$  Matriz Hessiana

$I$  Matriz identidade com as mesmas dimensões de  $H$

$L$  Matriz de regularização que força a soma entre  $I$

$Dw$  Ajuste ótimo aplicado ao vetor de pesos aplicados  $w$

LS Limite superior do diagrama de caixa

$y$  Alvo observado

$\hat{y}$  Saída prevista pelo modelo

- $P_{80}$  Malha em que passam 80% da produção, em mm
- Q1 Quartil inferior que representa 25% dos dados
- Q3 Quartil superior que representa 75% dos dados
- a Sinal de saída
- b Limiar de ativação
- n Potencial de ativação
- p Vetor de R sinais de entrada
- W Vetor de R pesos sinápticos
- $R_{pm}$  Medição do percentual retido no produto do processo na mesma malha de alimentação
- RR Relação de redução ( $RR = F/P$ )
- W O trabalho necessário para reduzir 1 tonelada curta (do material  $F_{80}$  até  $P_{80}$ , em kWh
- $W_i$  Índice de trabalho - O trabalho necessário para reduzir 1 tonelada curta (do material de alimentação de tamanho in nito até  $P_{80}$  de 100mm, em kWh
- $W_o$  Índice de trabalho operacional, em kWh
- x Diâmetro da partícula, em mm
- $X_i$  Variável de predição de tamanho
- X Critério de rejeição de observações
- $Y_i$  Resposta (regressão) de tamanho
- z Número de desvios padrão pelo qual o  $i$ ésimo valor dista da média



# Sumário

1	Introdução	17
1.1	Contexto	17
1.2	Motivação	21
1.3	Objetivos	22
1.3.1	Objetivo Geral	22
1.3.2	Objetivos Específicos	22
1.4	Perguntas dessa Pesquisa	22
1.5	Organização do Texto	23
2	Referencial Teórico e Fundamentação Científica	24
2.1	Processo de Moagem	24
2.1.1	Introdução	24
2.1.2	Moinho de Carga Cadente	24
2.1.3	E ciência Energética de Moagem	27
2.1.4	Circuito de Moagem da VALE — Mina de Timbopeba	33
2.2	Soft Sensors	36
2.2.1	Introdução	36
2.2.2	Metodologia de desenvolvimento de soft sensors	37
2.2.3	Seleção do modelo	41
2.2.4	Treinamento e validação	42
2.2.5	Manutenção	44
2.3	Redes Neurais Artificiais	44
2.3.1	Conceitos	44
2.3.2	Neuônio artificial	45
2.3.3	Arquitetura de Redes Neurais Artificiais	47
2.3.4	Aprendizado e validação	48
3	Materiais e Métodos	51
3.1	Caracterização da área de estudo	51
3.2	Dados	51
3.3	Metodologia	51

3.4	Procedimento de pré-processamento dos dados . . . . .	52
3.5	Procedimento de simulação preliminar . . . . .	56
3.6	Procedimento de aprimoramento da simulação preliminar . . . . .	56
3.7	Procedimento de simulação com utilização de projeto de experimentos . . . . .	57
4	Resultados e Discussão . . . . .	59
4.1	Simulação preliminar . . . . .	59
4.1.1	Pé-processamento dos dados . . . . .	59
4.1.2	Simulação do modelo . . . . .	60
4.2	Simulação aprimorada . . . . .	64
4.2.1	Pé-processamento dos dados . . . . .	64
4.2.2	Simulação do modelo . . . . .	67
4.3	Simulação com utilização de projeto de experimentos . . . . .	71
4.3.1	Pé-processamento dos dados . . . . .	71
4.3.2	Simulação do modelo . . . . .	72
4.4	Resultados . . . . .	77
5	Conclusão . . . . .	80
	Referências Bibliográficas . . . . .	84
	Apêndices . . . . .	88

# 1. Introdução

## 1.1. Contexto

Em beneficiamento de minérios, a cominuição é necessária para se obter a granulometria adequada ao processo de concentração, assim como para a obtenção de uma liberação adequada dos minerais a serem separados. Existem diversos métodos disponíveis no mercado para realização dessa operação, sendo selecionados conforme a faixa de tamanhos de trabalho no processo.

Dentre os métodos disponíveis, tem-se o processo de moagem que, segundo Chaves e Peres (2012), compreende as operações de cominuição na faixa de tamanho abaixo de 3/4" e é efetuada por mecanismos de arredondamento das superfícies, quebra de pontas e alisamento. O objetivo deste processo é liberar o mineral de interesse para as etapas subsequentes de concentração, possibilitar o seu transporte por bombeamento de polpa, aumentar a área de superfície das partículas do mineral para atender as premissas de utilização de processos hidrometalúrgicos e atingir a granulometria adequada às especificações de mercado.

Processos de moagem, segundo Beraldo (1987), possuem elevado consumo energético e são frequentemente estudados, uma vez que o consumo energético representa uma parcela importante nos custos de cominuição em instalações de beneficiamento mineral. Segundo Wills e Napier-Munn (2006), o consumo energético do processo de moagem pode representar até 50% do consumo de toda a instalação e se trata de processo essencial para a separação dos minerais. Segundo Beraldo (1987), a maior parte da energia consumida nas perdas nos equipamentos, o que estreita a aplicabilidade dos modelos.

O cálculo para aproximação da eficiência energética de moagem pode ser feito caso a instalação possua um Analisador de Tamanho de Partículas (PSM) no fluxo de saída do moinho tubular. Segundo Wills e Napier-Munn (2006), a análise de tamanho de partículas é usada para determinar o tamanho ideal com o objetivo de alcançar a máxima eficiência e determinar a faixa de tamanho em que quaisquer perdas estejam ocorrendo no processo, tomando-se as medidas necessárias para correção. No entanto, esse equipamento possui custo elevado e necessita de mão de obra altamente qualificada para realização de sua parametrização e calibração periódica.

Considerando-se as limitações apresentadas quanto à eficiência energética, fomenta-se o desenvolvimento de um modelo de aprendizagem capaz de estimar a eficiência energética com base nas observações de variáveis de processo medidas e armazenadas em um banco de dados histórico. Isso pode possibilitar a decisão de quando e quanto repor a carga moedora, com o intuito de atingir a granulometria desejada do processo e otimizar o consumo de energia, o que é de grande interesse da indústria e é objeto de estudo da Internet da Energia (IoE) que, segundo Hannan et al. (2018, apud Bui et al., 2012), combina os conceitos de redes inteligentes e de Internet das Coisas (IoT) que se refere a uma arquitetura que facilita a troca de serviços, informações e dados entre nós de objetos inteligentes. Uma rede inte-

ligente é capaz de fornecer comunicação bidirecional entre uma rede e um sistema de gestão de monitoramento de energia. No contexto de processos industriais, existem sistemas de previsão baseados em sensores virtuais. Esse sistema de previsão se trata de um modelo que estima, em tempo real, a variável desejada a partir de dados medidos da planta” (LOTUFO e GARCIA, 2008).

Alguns estudos publicados remetem-se ao desenvolvimento, são aplicação de soft sensors em processos de beneficiamento mineral e, em especial, a previsão de carga de moinhos de bolas em circuitos úmido. Tang et al. (2010) desenvolveram um soft sensor para previsão da carga do moinho com base nos sinais de vibração de sua carcaça. A estimação de parâmetros é feita com a aplicação de uma Transformada Rápida de Fourier (FFT) para decomposição de frequências do sinal de vibração e a obtenção de informações para estimação de parâmetros com base na amplitude dos sinais decompostos. O modelo de sensor é baseado em um Núcleo de Mínimos Quadrados Parciais (KPLS) e as massas e picos de frequência são selecionados por um algoritmo genético. Em Zhao et al. (2010), a abordagem possui o mesmo objetivo e com abordagem similar ao caso apresentado por Tang (2010), porém o modelo de soft sensor desenvolvido é baseado em Máquinas de Vetores de Suporte (SVM). Shao et al. (2015) propõem um soft sensor baseado em aprendizagem em tempo real por uma combinação do modelo de Projeções de Preservação de Estruturas Locais e Locais Supervisionadas (SLNPP) com o modelo Aprendizagem on-line em Tempo Real (JITL) para resolver o problema de diminuição da imprecisão causada pela presença de não-linearidades e de desvio nos dados presentes no mesmo modelo apresentado por Tang (2010) e Zhao et al. (2010).

Bai et al. (2018) propõem a adoção de modelos de aprendizagem por Máquinas de Aprendizagem Extremo (ELM), que se baseiam em RNA do tipo unidirecional com uma camada oculta de neurônios em sua rede. Esses modelos são capazes de tratar a instabilidade existente do modelo proposto por Shao et al. (2015), devido a mudanças nas condições de processo das quais os moinhos de bolas em circuitos úmido são sujeitos. O desempenho desses modelos é comparado entre si em um experimento de previsão de carga de moinho de bolas úmido com variações em seu volume de enchimento e os melhores resultados apresentados pelos modelos Máquinas de Aprendizagem Extremo do tipo Domain Adaptation Kernel (DAKELM) e Máquinas de Aprendizagem Extremo do tipo Domain Adaptation Multi-Kernel (DAMKELM), que são capazes de transferir o conhecimento entre os núcleos de origem e do valor alvo, resolvendo problemas de aprendizagem. No caso do modelo DAMKELM, a adoção de núcleos se mostrou importante para resolver a instabilidade do modelo ELM ocasionada pela sua incerteza na inferência da previsão de carga do moinho com condições operacionais variáveis.

Para o trabalho de Wei et al. (2016), é proposta a adoção do modelo de aprendizagem por Rede Neural Convolutiva (CNN) combinado com o modelo ELM para tratar as fragilidades apresentadas pela utilização do método de Análise de Componentes Principais (PCA) por Tang et al. (2010) com o modelo de soft sensor baseado em SVM. A rede CNN baseada em aprendi-

deep learning tem se mostrado bastante eficaz em aplicações de reconhecimento de imagens e análise de fala. A combinação do modelo CNN, que é capaz de reduzir impactos externos na precisão da medição e de resolver o problema da dificuldade de estimar o volume de carga, com o modelo ELM, sendo esse capaz de aprender de forma rápida e com boa capacidade de generalização, se mostrou como uma abordagem superior a abordagens tradicionais propostas por Tang et al. (2010), Zhao et al. (2010) e Sha et al. (2015).

Outros estudos publicados remetem-se ao desenvolvimento, simulação e aplicação de soft sensors na previsão de tamanho de partículas ou de distribuição granulométrica do produto do circuito, que têm influência direta na determinação da eficiência energética. Nieto et al. (2009) propuseram o desenvolvimento de um estimador para inferir o tamanho de partícula no over flow de hidrociclones de um circuito de classificação baseado em um modelo empírico obtido por regressão, assumindo como variáveis de entrada: a pressão e vazão de polpa de minério na alimentação do hidrociclone, pressão interna do hidrociclone e vazão de água adicional do circuito. A saída do estimador foi comparada com um PSM existente no processo para fins de validação mostrando-se um estimador de alto desempenho. O modelo apresentado avalia o hidrociclone como uma operação isolada, sendo que outros fatores que podem influenciar nas características físicas da polpa de alimentação e no desempenho do corte do hidrociclone não são levados em consideração na inferência.

Casali et al. (1998) desenvolveram um soft sensor baseado em Modelo Auto-Regressivo de Médias Móveis com Variáveis Exógenas (ARMAX) obtido pelo método de regressão passo-a-passo para inferência de tamanho de partícula do produto do circuito de moagem fechado a úmido. O soft sensor foi concebido com base em conhecimento prévio dos fenômenos envolvidos como: equação da vazão volumétrica de entrada do hidrociclone, equação de corte do hidrociclone e equação de correção da eficiência do hidrociclone. Neste contexto, segundo Aguirre (2007), este procedimento é classificado como caixa cinza por usar informação auxiliar e que não se encontra no conjunto de dados utilizados durante a identificação de um sistema. Casali et al. (1998) apresentaram os resultados com uma correlação de 91,6% entre as saídas do modelo e as medições do PSM existente no processo. Sbarbaro et al. (2008) desenvolveram um modelo baseado em Modelo Auto-Regressivo-Linear de Médias Móveis com Variáveis Exógenas (NARMAX) considerando também um conhecimento prévio da dinâmica do processo. Os parâmetros do modelo são ajustados com base em um algoritmo de propagação do erro do modelo com uma função custo para minimização da soma dos erros quadráticos de predição. Para ambos os casos apresentados, o circuito de moagem possui um PSM instalado para fins de validação e comparação com as saídas apresentadas pelos modelos desenvolvidos. No entanto, o conhecimento prévio do processo foi necessário para o desenvolvimento dos modelos propostos.

Xie et al. (2020a) desenvolveram um soft sensor baseado em ELM para inferir o tamanho de partículas e composição de ferro do produto do processo de moagem com diferentes

funções de ativação em suas camadas. Método de Análise de Componentes Principais por Núcleos (KPCA) foi utilizado para redução da base de dados para cada modelo gerado. Devido a baixa capacidade de generalização e baixa precisão dos modelos gerados, o Algoritmo black hole (BHA) foi aplicado para otimizar os parâmetros dos modelos. Xie et al. (2020b) também desenvolveram um soft sensor híbrido baseado em Máquinas de Vetores de Suporte por Mínimos Quadrados (LSSVM) e Máquinas de Aprendizagem Extremo Regularizadas (RELM) com a mesma finalidade. Para aprimorar a precisão do modelo gerado, o Algoritmo de Seno de Ouro de Harris Hawk (GSHHO) foi aplicado para otimizar os parâmetros dos núcleos do modelo LSSVM. O desempenho dos modelos foram comparados com modelos desenvolvidos, aplicando-se a estratégia de janela móvel em ambos os modelos e o treinamento com o algoritmo de Kalman estendido. Ambos apresentaram uma boa correlação atendendo aos requisitos de controle em tempo real do processo de moagem com alta capacidade de generalização e boa precisão. No entanto, a medição em tempo real do tamanho de partículas foi necessária na composição da base de dados para o treinamento e simulação dos modelos gerados.

Ferrández et al. (1995) e Olivier et al. (2019) propõem a inferência da distribuição granulométrica em uma correia transportadora com base na análise de imagens de Circuito Fechado de Televisão (CFTV) com sistema de iluminação dedicada. Ferrández et al. (1995) implementaram uma RNA para classificar se um determinado ponto focal da retina do CFTV é ou não o centro de um grão de minério. Se identificado o grão, a borda do grão é aproximada por uma função polinomial. A distribuição granulométrica é inferida com base na contagem e distribuição de tamanho dos grãos identificados. Olivier et al. (2019) implementaram uma CNN para classificação das imagens geradas em 4 classes de tamanhos distintos: minério particulado, minério com alguns fragmentos de rochas, minério com algumas rochas grandes e discrepantes dos particulados e minério com volume predominante de rochas grandes comparado aos particulados presentes. Por se tratar de métodos de inferência com o minério seco, não é possível aplicar essas soluções para circuitos de moagem úmido cujo produto se encontra em formato de polpa de minério.

Não foram identificados estudos relacionados a aplicação de métodos de aprendizagem para a inferência de eficiência energética em circuitos de moagem, sendo essa grandeza de grande importância para se avaliar o rendimento operacional, buscando-se o ponto de operação para a obtenção do produto final de granulometria dentro das especificações desejadas e com consumo energético controlado. Trata-se de uma abordagem distinta comparada a previsão de enchimento de carga no cilindro de um moinho e a estimativa de tamanho de partículas em um processo isolado de hidrociclonagem por uma convergência dos objetivos a serem alcançados para ambos os casos: obter uma eficiência e cência do circuito de moagem para se atender a granulometria desejada do circuito desejada no processo. Este trabalho se insere neste contexto, sendo adotada a técnica de modelagem de soft sensor baseado em RNA para a obtenção da solução para o problema apresentado.

A aplicação do soft sensor foi realizada com base em dados coletados em um moinho

de bolas em circuito fechado da usina de beneficiamento de minério de ferro da Mina de Timbopeba, pertencente a VALE SA, localizada em Ouro Preto, Minas Gerais, Brasil. O desenvolvimento do algoritmo de soft sensor é realizado em um software de simulação de modelagem considerando uma base de dados iniciais. O circuito de moagem objeto deste estudo representa cerca de 13,7% do consumo de energia da mina e possui PSM instalado, sendo as informações quanto a eficiência energética determinadas com base nos resultados dos ensaios laboratoriais realizados, normalmente, de 3 em 3 horas. A validação do modelo é realizada utilizando uma base de dados apresentada durante a fase de treinamento do algoritmo.

## 1.2. Motivação

Na etapa de moagem da usina de beneficiamento de minério de ferro da Mina de Timbopeba, a reposição de corpos moedores é feita de forma manual, com base na opinião do moinho e com tomada de decisão da equipe operacional. Nesta tomada de decisão avaliadas as análises granulométricas obtidas em ensaios laboratoriais a partir de amostras do produto do circuito de moagem coletadas em campo. São realizadas normalmente 8 amostras por dia, espaçadas por um período de 3 horas. Por se tratar de uma reposição manual com base em tomada de decisão humana, erros de cálculo podem ocorrer de forma frequente, o que induz a reposição excessiva ou de ciente de corpos moedores, o que podem elevar o custo energético do processo e diminuir a eficiência de redução do minério, veri cada pelo aumento de massa no under ow da ciclonagem que realimenta o circuito de moagem, respectivamente.

O processo de moagem em questão possui um PSM para medição contínua de tamanho das partículas na sala do moinho, atendendo ao cenário descrito neste trabalho e que justifica o desenvolvimento de um modelo de previsão e eficiência energética do circuito de moagem com base na observação de variáveis de processo em banco de dados históricos. Com a implantação e validação do algoritmo proposto neste trabalho, os seguintes benefícios podem ser alcançados em um circuito fechado de moagem:

- Tomada de decisão mais coerente quanto a reposição de corpos moedores no moinho;
- Otimização de parcela do consumo energético de moagem afetada pelo volume de corpos moedores existentes no interior do moinho;
- Redução de desvios entre as granulometrias efetiva e especificada para o processo;
- Redução da exposição de operadores de campo para realização do processo de reposição manual;
- Possibilidade de implementação de lógica de programação em CLP para reposição automática de corpos moedores em batelada ou de forma contínua.

- Possibilidade de implementação de controlador que seja capaz de adequar a granulometria do produto final da etapa de moagem.

## 1.3. Objetivos

### 1.3.1. Objetivo Geral

O objetivo deste trabalho é desenvolver um soft sensor para inferência de eficiência energética de moinhos de bolas em circuito fechado utilizado em mineradoras com base em dados operacionais e laboratoriais observados em um processo.

### 1.3.2. Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Estudar a dinâmica do processo de moagem em um circuito fechado e investigar as variáveis existentes no processo, ensaios laboratoriais comumente realizados, características físicas do processo e as metodologias comumente adotadas para análise de corpos moedores;
- Coletar uma grande quantidade de dados de processo e de ensaios laboratoriais de um moinho de bolas em circuito fechado existente nas instalações de beneficiamento de minério da Mina de Timbopeba pertencente a VALE S.A. e registrar dados do processo como dimensões do circuito, especificações técnicas dos corpos moedores, dados de projeto e entre outras informações relevantes da investigação científica pretendida;
- Realizar o pré-processamento da base de dados obtida e investigar a sua melhor modelagem de soft sensor;
- Definir o algoritmo de treinamento do soft sensor e estruturar o método de testes para validação dos dados com base nas séries granulométricas disponibilizadas em ensaios laboratoriais.

## 1.4. Perguntas dessa Pesquisa

Para esta pesquisa são levantadas as seguintes perguntas para aprofundamento da investigação científica para este trabalho com base nos objetivos apresentados:

- Quais são as variáveis de processo e dados laboratoriais pertinentes para a inferência de eficiência energética em um circuito fechado de moagem?



- Quais são os critérios adequados para avaliação de pertinência das variáveis pertencentes a base de dados coletada para o projeto do sensor?
- Quais são os parâmetros e métricas a serem adotados para validação da inferência, uma vez que não é possível obter a medição direta da eficiência energética do circuito de moagem objeto desta investigação científica?
- Os benefícios esperados são capazes de serem satisfeitos com a eficiência da eficiência energética no circuito fechado de moagem a ser desenvolvido?

## 1.5. Organização do Texto

No capítulo 2 é apresentada uma fundamentação teórica aplicada para circuitos fechados de moagem úmido, cálculo de eficiência energética e um detalhamento do circuito de moagem estudado neste trabalho, suas características e importância no processo de beneficiamento de minério da Mina de Timbopeba com o objetivo de detalhar quais as variáveis identificadas, os parâmetros de projeto pertinentes e os ensaios laboratoriais disponíveis para composição da base de dados a ser utilizada para o desenvolvimento do sensor. Também é apresentada neste capítulo uma fundamentação teórica necessária para o entendimento de softwares de RNA, incluindo possíveis arquiteturas, métodos de aprendizagem, treinamento, testes e validação do modelo. No capítulo 3 é apresentado os materiais e métodos aplicados neste trabalho. No capítulo 4 são apresentados os resultados de cada simulação realizada com base nos procedimentos descritos no capítulo 3. Por fim, no capítulo 5 ocorre-se a conclusão do trabalho com base nos resultados apresentados no capítulo 4, discussão acerca do atendimento aos objetivos estabelecidos, contribuições e trabalhos futuros.

## 2. Referencial Teórico e Fundamentação Científica

### 2.1. Processo de Moagem

#### 2.1.1. Introdução

Nesta subseção são apresentados os conceitos básicos e características quanto ao processo de moagem, destacando-se o moinho de bolas em circuito fechado. Em seguida, são apresentadas as definições quanto a ciência energética de moagem e aos modelos matemáticos de cálculo para a obtenção desse indicador. Por fim, no item 2.1.4, tem-se um detalhamento do circuito de moagem da usina de beneficiamento de minério da Mina de Timbopeba pertencente a VALE SA, com a identificação dos equipamentos, fluxograma de processos, parâmetros de projeto e metodologia de reposição manual de corpos moedores.

#### 2.1.2. Moinho de Carga Cadente

A moagem constitui uma das operações unitárias necessárias para a adequação de produtos específicas granulométricas de processo. O projeto de instalação de um circuito de moagem compreende em uma combinação de equipamentos para se atingir tais especificações, cujos objetivos precisam ser explorados para o entendimento do processo de forma generalizada.

Segundo Garcia (2000), os moinhos de carga cadente são constituídos de um corpo tubular que gira em torno de seu eixo (Figura 2.1). A carcaça é feita de chapa calandrada e soldada com espessura recomendada entre 1/100 e 1/75 do diâmetro do moinho, fechada nas duas extremidades por tampas, cabeças ou espelhos. As tampas possuem dois pescoços para sustentação do moinho que gira dentro de mancais, incluindo a capacidade de seu enchimento por material úmido (no caso de operação do circuito úmido) e corpos moedores. Os moinhos possuem revestimento interno com material resistente a desgastes, podendo este revestimento ser metálico, de borracha ou cerâmico.

Figura 2.1: Moinho Tubular. Fonte: Luz et al. (2010).

O acionamento do moinho pode ser feito por coroa ou pinhão, havendo diversas maneiras de transmitir o movimento ao moinho, conforme a sua aplicação. Adota-se comumente o acionamento combinado com redutor e acoplamento elástico por permitir a partida do motor em plena carga e também por possuir proteção contra travamento do moinho.

A quebra do material passante no corpo tubular do moinho é realizada com a utilização de corpos moedores que podem ser em barras, bolas, ou fragmentos de rochas (seixos). Cylpebsse tratam de peças metálicas cilíndricas usadas em substituição a bolas e modi cadas para uma qualidade mecânica melhorada. Os seixos são fragmentos de rocha que são utilizados quando não é permitida a contaminação com o material proveniente dos demais tipos de corpos moedores. Dentre as cargas disponíveis para realização da fragmentação de material, as bolas e barras são mais utilizadas. As páculas são reduzidas pela combinação de impacto, compressão, abrasão e atrito, a um tamanho adequado à liberação do mineral de interesse, geralmente, a ser concentrado nos processos subsequentes (Luz, 2010).

Existem várias opções disponíveis para a operações de moagem, podendo ser realizada a úmido ou a seco, em circuito aberto ou fechado (FREITAS, 1997). Segundo Chaves e Peres (2012): "Em tratamento de minérios, o processamento úmido é a regra geral, pela razão básica de que a água é um excelente meio de transporte e dissipação de calor. Adicionalmente, ela, por si só, resolve o problema de abatimento das poeiras". A opção de moagem a seco é adotada quando há restrições ou impedimentos para operação úmida como escassez de água ou o material é solúvel em água. Para o circuito aberto não há realimentação da saída do moinho com base em um critério claro de classificação ou de correção da distribuição granulométrica do material de saída. Já os circuitos fechados contam com uma carga circulante para ajuste da distribuição granulométrica do material de saída do moinho tubular e redução de geração de finos (baixa granulometria).

Os circuitos fechados de moagem possuem duas configurações possíveis, sendo elas, segundo Nunes (2012): Com guarnição normal, onde a alimentação é conduzida ao moinho e com guarnição reversa a alimentação é conduzida pelo equipamento de classificação. A classificação

em processos de moagem úmido podem ser realizados por hidrociclones, classificadores espirais ou classificadores de rastelo. Os hidrociclones são os equipamentos mais empregados na operação de classificação para fechamento do circuito de moagem (BERALDO, 1987). O projeto deste equipamento é feito considerando um corte no material de modo a gerar uma fração de produto final do circuito de moagem com granulometria dentro da especificação de processo.

Segundo Chaves e Peres (2012), a dinâmica interna dos moinhos de carga fechada é afetada pela suas dimensões (diâmetro e comprimento), potência instalada e variáveis operacionais (quantidade de corpos moedores carregados no moinho, velocidade de rotação e porcentagem de sólidos na polpa alimentada). Segundo Luz et al. (2010), os corpos moedores são elevados pelo movimento da carga até um certo ponto de onde caem, seguindo uma trajetória parabólica, sobre os outros corpos moedores que estão na parte inferior do cilindro e sobre o material que ocupa os intervalos destes corpos. A carga interna (corpos moedores e material) acompanha o movimento do cilindro e é lançada por uma força centrífuga e percorre uma trajetória aproximadamente circular, conforme a Figura 2.2.

Figura 2.2: Ação de forças sobre um corpo moedor. Fonte: Luz et al. (2010).

Do ponto de vista prático, os moinhos são operados nas velocidades de 50 a 90% da sua velocidade crítica e a escolha desta é determinada pelas condições econômicas. Sabe-se, por outro lado, que aumentado a velocidade do moinho, aumenta a sua capacidade de processamento, mas compromete o seu desempenho (kWh/t) (Luz, 2010).

O efeito do volume interno ocupado no cilindro pela carga de corpos moedores e pela velocidade de operação do moinho afetam diretamente o consumo energético, conforme as Figuras 2.3 e 2.4.

Figura 2.3: Consumo energético x carga moedora. Fonte: Rowland e Kjos (1969).

Figura 2.4: Consumo energético x velocidade. Fonte: Kelly e Spottiswood (1982).

### 2.1.3. E ciência Energética de Moagem

#### Contextualização

Os diversos métodos de dimensionamento de moinhos desenvolvidos ao longo dos anos foram uma tentativa de se quantificar a energia requerida para a moagem das partículas com base no estudo dos mecanismos de quebra. Os processos de moagem envolvem uma grande quantidade de energia, pois cada partícula deve ser submetida a grandes esforços antes que ocorra qualquer fratura significativa (NUNES, 2012).

Segundo Beraldo (1987), a medição e ciência energética de moagem permite a comparação de resultados em diversas condições operacionais que são capazes de influenciar

na dinâmica do processo de quebra de carga, sendo elas:

- Velocidade do moinho;
- Distribuição de tamanho de corpos moedores;
- Quantidade de corpos moedores;
- Tamanho da alimentação;
- Tamanho do produto;
- Forma de revestimento e seu desgaste;
- Características do miúdo;
- Condições de operação do classificador.

A medição da eficiência energética se torna importante a fim de avaliar se o consumo de energia neste processo é superior ao necessário para a quebra de carga, o que indica um consumo de energia superior ao necessário em um processo que possui elevados custos de instalação e de operação. Por outro lado, um consumo de energia inferior ao necessário irá proporcionar uma quebra de carga ineficiente, sendo capaz de atender ao tamanho de partículas desejado e um aumento na carga circulante do processo devido ao corte especificado na etapa de classificação para determinação do produto final do circuito.

A seguir são de nidas algumas aproximações teóricas para consumo de energia em processos de moagem, destacando-se suas particularidades em suas aproximações.

Aproximações teóricas de modelos de cominuição

Segundo Chaves e Peres (2012), Rittinger estabeleceu uma teoria em 1867, na Alemanha, afirmando que a área da nova superfície gerada na cominuição é diretamente proporcional ao trabalho útil fornecido, conforme a Equação 2.1:

$$E = K \left( \frac{1}{x_2} - \frac{1}{x_1} \right) \quad (2.1)$$

Sendo:

E = Consumo específico, em kWh/t

K = Constante empírica que depende do miúdo a ser cominuído, em kWh

$x_1$  = Tamanho da alimentação, em mm;

$x_2$  = Tamanho do produto, em mm.

Segundo Nunes (2012), Kick demonstrou matematicamente que a energia necessária para realizar a fragmentação depende unicamente da razão de redução, sendo independente

da granulometria original. A equação de nida por Kické conhecida como a segunda lei da cominuição eé de nida conforme a seguir:

$$E = K \ln \frac{x_1}{x_2} \quad (2.2)$$

No entanto, segundo Chaves e Peres (2012), as duas teóricas não trouxeram nenhum benefício real ou contribuição metodológica objetiva, o que demonstrava que ambos os modelos eram colocados de lado por serem inadequados para a realidade industrial.

Neste contexto, Bond postulou em 1952 o que atualmente é conhecida como a terceira lei da cominuição. "A energia consumida para reduzir o tamanho de um material é inversamente proporcional a raiz quadrada do tamanho". Ele definiu como tamanho, a abertura da peneira pela qual passam 80% do material (Luz, 2010).

$$W = 10W_i \sqrt{\frac{1}{P_{80}} - \frac{1}{F_{80}}} \quad (2.3)$$

Sendo:

$F_{80}$  = Malha em que passam 80% da alimentação, em mm;

$P_{80}$  = Malha em que passam 80% da produção, em mm;

$W$  = O trabalho necessário para reduzir 1 tonelada curta (do material  $F_{80}$  até  $P_{80}$ ), em kWh;

$W_i$  = Índice de trabalho - O trabalho necessário para reduzir 1 tonelada curta (do material de alimentação de tamanho in nito até  $P_{80}$  de 100mm), em kWh

A energia gasta na moagem de  $F_{80}$  até  $P_{80}$  é, portanto, a diferença entre as energias necessárias para ir do in nito até  $F_{80}$  e do in nito até  $P_{80}$  (CHAVES e PERES, 2012). A determinação do Índice de Trabalho ( $W_i$ ) é realizada com base em ensaios de moagem em escala laboratorial padronizado pela norma brasileira NBR 11376 (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 1990).

É possível demonstrar em uma única equação a aplicação das teorias propostas por Rittinger, Kick e Bond. Conforme Chaves e Peres (2012), em 1957, Charles chegou na seguinte representação das três leis da cominuição:

$$dE = k \frac{dx}{x^n} \quad (2.4)$$

Sendo:

$dE$  = Diferencial de energia necessária para se gerar um diferencial de tamanho  $dx$ , em kWh;

$x$  = Diâmetro da partícula, em mm;

$n$  = Exponente indicativo da ordem do processo;

$k$  = Constante relativa ao material, em kWh

Se:

$n = 2$ , a representação é feita conforme a lei de Rittinger (2.1);

$n = 1$ , a representação é feita conforme a lei de Kick (2.2);

$n = 1,5$ , a representação é feita conforme a lei de Bond (2.3);

### Equação de Donda

É proposto por Donda (2018) um método distinto para cálculo da energia necessária para realizar uma fragmentação, adotando-se a utilização do Percentual Retido em uma Malha na Alimentação do Processo ( $R_f$ ) e Percentual Retido no Produto do Processo na Mesma Malha de Retenção da Alimentação ( $R_p$ ), já que o controle do produto de operação de uma moagem industrial é raramente feito pelo  $P_{80}$ . A dedução da formulação foi feita com base na seguinte afirmação dada por Donda (2018): “Em um processo de fragmentação de minerais e rochas, a taxa de variação da massa retida em uma dada malha com a variação do nível de energia específica é proporcional à massa retida inicial”.

A Equação (2.5) expressa a dedução de Donda (2018) em função dos percentuais retidos  $R_f$  e  $R_p$ :

$$E = \frac{1}{k} \ln \frac{R_f}{R_p} \quad (2.5)$$

Sendo:

$E$  = Consumo específico, em kWh/t

$k$  = Constante de Donda para a forma de aplicação de energia e da malha;

$R_f$  = Percentual retido em uma malha na alimentação do processo;

$R_p$  = Percentual retido no produto do processo na mesma malha de retenção da alimentação.

O valor de  $k$  poder ser determinado em ensaios laboratoriais com desvio aproximado de 10% em relação a moinhos industriais.

O método de Donda possui utilização mais prática, visto que a formulação trabalha com parâmetros usualmente utilizados para dimensionamento de moinhos industriais, tratando o material retido ou passante de uma malha com os tamanhos  $P_{80}$  e  $P_{80}$ .

A partir da Equação (2.5), isolando  $R_p$ , é possível estabelecer uma análise entre a energia específica em kWh/t com o percentual do produto retido na malha de interesse, conforme descrito na Equação (2.6):

$$R_p = R_f e^{-kE} \quad (2.6)$$

A Figura 2.5 é representado um ensaio de laboratório com a determinação da curva de  $R_p$  em função de  $E$ .



Figura 2.5: Exemplo de representação de dados de ensaio de moagem em 12x12 polegadas. Fonte: Donda (2018).

### Controle da eficiência energética de moagem

É proposto por Rowland e Kjos (1969) o controle da eficiência energética de moagem pela obtenção do Índice de Trabalho Operacional (W<sub>o</sub>). O Índice de trabalho operacional, em kWh pode ser calculado com base na medida energia aplicada ao pânho moinho e por análises laboratoriais nas amostras do material de alimentação produto do moinho. A Equação (2.7) apresenta o cálculo para obtenção do Índice de Trabalho Operacional.

$$W_o = \frac{W}{\frac{p_{10}}{P_{80}} - \frac{p_{10}}{F_{80}}} \quad (2.7)$$

Sendo:

W<sub>o</sub> = Índice de trabalho operacional, kWh

W = O trabalho necessário para reduzir 1 tonelada curta (do material F<sub>80</sub> até P<sub>80</sub>, em kWh

F<sub>80</sub> = Malha em que passam 80% da alimentação, em mm;

P<sub>80</sub> = Malha em que passam 80% da produção, em mm.

Segundo Beraldo (1987), é necessário corrigir a potência lida na linha de alimentação elétrica para que seja consideradas as perdas de linha do motor e eventualmente do redutor, caso o mesmo exista. O consumo específico é obtido pela razão entre a potência corrigida e a taxa horária de alimentação.

O parâmetro P<sub>80</sub> pode ser obtido com base em análises de amostras em laboratório ou de forma contínua com a utilização de Analisador de Tamanho de Partículas (PSM). No caso do parâmetro F<sub>80</sub>, a sua influência na variação do valor calculado para Índice de Trabalho Operacional é muito menor do que a influência causada pela variação do P<sub>80</sub>. O parâmetro F<sub>80</sub> também pode ser determinado com base em análises de amostras laboratoriais em materiais armazenados em pilhas de homogeneização caso existam na instalação. A eficiência do processo de moagem pode ser determinado conforme a Equação (2.8):

$$E(\%) = 100 \frac{W_l}{W_{loc}} \quad (2.8)$$

Sendo:

$W_{loc}$  = Índice de trabalho operacional corrigido, kWh/t

$E(\%)$  = Fator percentual de eficiência energética.

De forma análoga, é possível obter a eficiência do processo de moagem com base na Equação de Donda (2.5). A energia específica desejada é conhecida, considerando os parâmetros  $R_f$  e  $R_p$  de projeto. Calculando-se a energia específica com base nos resultados  $R_f$  e  $R_p$  durante a operação do circuito de moagem, a eficiência do processo de moagem pode ser determinada conforme a Equação (2.9)

$$E(\%) = 100 \frac{E_m}{E_p} \quad (2.9)$$

Sendo:

$E_m$  = Energia específica medida no processo, kWh/t

$E_p$  = Energia específica de projeto (desejada), kWh/t

A medida de eficiência energética é adotada para se registrar o desempenho do moinho, comparando-se resultados a altas rotações no processo e permitindo a avaliação de circuitos paralelos em uma mesma planta para realizar trabalhos de otimização.

Uma eficiência energética inferior a 100% significa que o processo de cominuição está eficiente o bastante para realizar a quebra de carga com o objetivo de atingir a granulometria desejada no produto do circuito. Por outro lado, uma eficiência energética acima de 100% denota um consumo específico superior ao desejado, aumentando-se o custo de operação de moagem.

Podem ser tomadas algumas decisões em virtude desta medida com o objetivo de otimizar a seu valor, sendo algumas delas:

- Alterar a velocidade de rotação do moinho, caso seja possível;
- Alterar a frequência ou o peso total de reposição de corpos moedores em processos de batelada;
- Adotar a reposição contínua de corpos moedores em quantidades menores;
- Alterar o tamanho ou composição dos corpos moedores utilizados na reposição;
- Reavaliar a metodologia de inspeção e verificação dos desgastes em revestimentos internos do cilindro, propondo a troca se necessário.

- Avaliar se houve alteração na composição média do material de alimentação ou da frente de lavra adotada para alimentação da planta para ajuste dos controles da moagem;
- Avaliar o comportamento do processo de classificação e eficiência no corte.

#### 2.1.4. Circuito de Moagem da VALE — Mina de Timbopeba

##### Fluxograma de processo

A Figura 2.6 ilustra o fluxograma de processo da moagem da usina de beneficiamento de minério de ferro da Mina de Timbopeba pertencente a VALE SA. Trata-se de um circuito fechado úmido com realimentação conforme underflow da bateria de ciclones.

Figura 2.6: Fluxograma de processo de moagem - Mina de Timbopeba/VALE SA

O circuito de moagem consiste em um moinho tubular de bolas, cuja alimentação é proveniente do underflow do hidrociclone alimentado pelo produto final da etapa de concentração magnética (Figura 2.7). O produto do moinho é direcionado a uma caixa de polpa com o intuito de amortecer o processo e evitar que ocorram vibrações bruscas na saída de polpa de minério até a alimentação do hidrociclone.

A bomba de polpa na saída da caixa é responsável por conduzir o material armazenado na caixa à alimentação da bateria de 8 ciclones que, por sua vez, realiza a separação do material conforme seu diâmetro de corte. As partículas com tamanho superior ao diâmetro de corte são direcionadas para o underflow da bateria de ciclones e realimentam o circuito de moagem. As partículas com tamanho inferior ao diâmetro de corte são direcionadas para o overflow desta mesma bateria de ciclones e alimentam o circuito de classificação, esse que recebe o produto final do circuito da moagem.

Uma particularidade a ser levada em consideração neste circuito é a influência do processo de concentração magnética na realimentação do circuito de moagem. Existe um hidrocic-

Figura 2.7: Moinho de bolas - Mina de Timbopeba/VALE SA

clone que recebe o material proveniente do circuito de concentração magnética e as partículas com tamanho superior ao ângulo de corte são direcionadas para o underflow do hidrociclone e realimentam o circuito de moagem. As partículas com tamanho inferior ao ângulo de corte são direcionadas para o overflow do hidrociclone e alimentam a caixa de polpa existentes após o estágio de moagem do circuito. Logo, o overflow do estágio de classificação do material da concentração magnética é submetida a uma nova classificação adotando-se a bateria de ciclones do circuito de moagem.

Existe um circuito de reposição de corpos moedores dedicado. As bolas são armazenadas em silos e pesadas por balanças automáticas em correias transportadoras durante a sua condução até o tambor de alimentação do moinho. A reposição é feita em bateladas e de forma manual, podendo ser operada manualmente por um operador de campo ou remotamente em uma sala de controle operacional com apoio técnico de campo para acompanhamento da reposição.

As bombas de lubrificação dos mancaisixo e atuantes são responsáveis por realizar toda a lubrificação do equipamento, conforme as recomendações do fabricante. A lubrificação adequada permite o bom funcionamento do equipamento, o seu acoplamento e o giro do tambor com atrito mínimo em sua estrutura de sustentação.

A tabela (2.1) apresenta um resumo com as características do moinho de bolas em circuito fechado a úmido.

Tabela 2.1: Características e parâmetros do circuito de moagem da VALE / Mina de Timbopeba

Parâmetro / Característica	Valor ou Descrição
Tipo de circuito	fechado normal
Tipo de processo (a seco / úmido)	úmido
Material	minério de ferro
Fabricante do moinho	Metso Minerals
Diâmetro interno do cilindro (D) em	5,1816
Comprimento interno do cilindro (L) em	7,62
Tipo de revestimento	Mético dupla onda sinétrico
Espessura do revestimento interno em	80
Número de motores para acionamento do moinho	2 (principal e auxiliar)
Tipo de alimentador	drum feeder
Tipo de descarga	over ow
Tipo de corpos moedores adotados	bolas
Diâmetro dos corpos moedores	2,5"
Composição dos corpos moedores	Aço fundido
Consumo específico de corpos moedores (t)	280
Consumo específico de corpos moedores (kW)	65
Material	Hematita
Malha F <sub>95</sub> de alimentação em	10000
Malha P <sub>95</sub> de alimentação em	150
Relação de redução RR	66,67
R <sub>f</sub> +0.15mm (%)	49,92
R <sub>p</sub> +0.15mm (%)	15,0
Constante de Donda (k <sub>Donda</sub> )	0,331
Velocidade de operação (% da velocidade crítica)	71,9
Densidade de sólidos na alimentação (t/m <sup>3</sup> )	2,6
Potência instalada em (kW)	2850
Potência operacional em (kW)	2622
Consumo específico de energia (kWh/t)	3,6
Percentual teórico de enchimento	36%
Taxa de alimentação nominal do moinho (úmido) (t/h)	620
Umidade (%)	15
Taxa de alimentação nominal do moinho (seco) (t/h)	527
Diâmetro de corte da bateria de ciclones (mm)	150
Carga circulante (%)	200

Os dados operacionais dispostos na Tabela 2.1 foram disponibilizados pela VALE S.A. em 30/09/2017.

São coletadas amostras do produto do circuito da moagem para  $\rho$  em períodos espaçados em 3 horas (8 amostras por dia) com uma incerteza absoluta de 1.54%, conforme procedimento operacional adotado pelas análises laboratoriais na Mina de Timbopeba, infnseco aos equipamentos utilizados para a realização dos ensaios. Segundo a ISO GUM (2008), a incerteza é dividida nos tipos A e B, sendo a primeira a incerteza avaliada por métodos de análise estatística de séries de observações e a segunda por outros meios que não sejam por análises estatísticas. Para o caso apresentado, considera-se a incerteza de medição praticada nas análises laboratoriais como tipo B por ser uma incerteza padronizada em procedimento operacional local.

A frequência de coleta de amostras pode variar em função da disponibilidade da equipe responsável pelos ensaios laboratoriais para coleta e também pelo regime operacional do circuito de moagem. Os valores registrados pela equipe do laboratório químico no PIMS e historiados para análise dos resultados pela equipe responsável pela operação do circuito de moagem (tag 'P\_A4412.TO.FG.GLOBAL.+0.15MM').

Não são realizadas amostras para análise do  $R_f$ . Para este caso são considerados os valores de referência existentes conforme descrito na Tabela (2.1).

Todas as variáveis de processo são armazenadas no PIMS com o intuito de registrar os dados históricos e permitir avaliações operacionais e de engenharia quanto a produtividade e a eficiência do processo de moagem. São também armazenados os estados de equipamentos, parâmetros de processo, parâmetros estatísticos de malhas de controle e totalizadores. Todos os dados referente ao processo de moagem são armazenados e historiados no PIMS, em um total de 152 tags

## 2.2. Soft Sensors

### 2.2.1. Introdução

Os processos industriais contam com um elevado parque de instrumentos de medição instalados com o objetivo de mensurar variáveis para monitoramento e controle de processos. No entanto, segundo Li e Venczel (2017), as dificuldades de medição podem assumir diferentes formas, como tempo morto elevado, custo associado ao dispositivo de medição, técnica de medição, com habilidade da medição onde algumas variáveis só podem ser medidas com precisão limitada e nos piores casos ou a falta de dispositivos apropriados para medição.

Segundo Kadlec et al. (2009), no contexto de processos industriais, os modelos de previsão são chamados de soft sensors e podem ser distinguidos em duas classes: soft sensors baseados em modelos ou em dados. Soft sensors baseados em modelos focam na modelagem do processo, sendo capazes de descrever as suas características físicas e químicas (modelo caixa branca). No

caso de soft sensors baseados em dados, eles são capazes de descrever uma relação entre entradas e saídas com base em dados medidos do processo, o que os torna capazes de um comportamento real, sem a necessidade de se conhecer o modelo que rege o processo, isto possibilita sua predição (modelo caixa preta). O sucesso na implementação de soft sensors, conforme mencionado por Lipák e Venczel (2017), deve-se a sua capacidade de medir de forma a qualidade de produto por predição online, reduzir tempo e custo em processos produtivos, validar medições online de instrumentos por operação paralela e detectar falhas de hardware em instrumentos físicos.

Os soft sensors são comumente chamados de instrumentos virtuais, sensores inferenciais, sensores inteligentes ou sensores de software. Todos eles permeiam em um mesmo objetivo que é, segundo Lipák e Venczel (2017), fornecer estimativas em tempo real de variáveis difíceis de serem mensuradas, usando dados medidos e armazenados de variáveis no processo. Essas variáveis são adotadas criteriosamente como entradas do modelo de soft sensor e as variáveis de saída se tratam como respostas ou alvos da medição inferida.

Para este trabalho, foi dado um foco maior em soft sensors baseados em dados em processos contínuos, uma vez que deseja-se obter a estimativa de energia com base em diversas variáveis do processo pertinentes a esta área.

## 2.2.2. Metodologia de desenvolvimento de soft sensors

É proposto por Kadlec et al. (2009) uma metodologia usualmente adotada para desenvolvimento de soft sensors e que pode ser aplicada tanto em processos contínuos quanto em processos em batelada, conforme a Figura 2.8

### Inspeção inicial dos dados

A inspeção inicial dos dados é um passo preliminar para o desenvolvimento de soft sensor. A inspeção inicial se baseia na identificação das variáveis e dados históricos, com o intuito de avaliar comportamentos, padrões ou falhas visíveis sem qualquer aprofundamento ou suporte de especialistas responsáveis pelo processo.

A classificação e descrição das variáveis permite organizar os dados para que a etapa de seleção das variáveis elegíveis ao modelo de soft sensor seja facilitada. Processos possuem não somente dados históricos de instrumentos de medição, mas também possuem dados de estados de funcionamento de equipamentos, parâmetros de processo, totalizadores, parâmetros de malhas de controle (modo de operação, setpoint, referência de saída para o atuador, ganhos do controlador, etc.), dados de análises laboratoriais, alarmes, ciclos e entre outros dados.

Uma avaliação visual permite identificar possíveis congelamentos de variáveis ou variáveis cujos os instrumentos ou equipamentos estejam desativados em campo. Essas variáveis podem ser desconsideradas do projeto por não agregarem nenhuma informação ou variabilidade que possa interferir na variável a ser estimada.

Figura 2.8: Fluxo de desenvolvimento de soft sensor Adaptado de: (KADLEC et al., 2009).

Segundo Lipák e Venczel (2017), a inspeção dos dados é normalmente executada para que o desenvolvedor tenha uma visão geral da estrutura de dados e seja capaz de avaliar melhor o ponto de partida do processo de desenvolvimento.

Em alguns casos, segundo Kadlec et al. (2009), o desenvolvedor é capaz de tomar uma decisão razoável quanto ao modelo a ser adotado para o projeto, com base em sua experiência. No entanto, a decisão pode não ser a melhor é importante que sejam aplicados os critérios de desempenho adequados para se comparar o modelo adotado com modelos alternativos, a fim de avaliar o modelo que melhor se ajuste ao objetivo de sua implementação.

#### Seleção dos dados históricos

As variáveis listadas, organizadas e selecionadas sem conhecimento da dinâmica do processo, a priori, de todas no conjunto de avaliação para o desenvolvimento do modelo. Os dados históricos desse conjunto de variáveis são coletados, são de todas as partes estacionárias e ambas são considerados para a etapa de processamento dos dados.

Processos industriais normalmente contam com sistema de aquisição de dados para que o armazenamento de dados históricos do processo seja realizado e consultado, a fim de avaliar comportamentos do processo, parâmetros operacionais e avaliar o seu desempenho.



## Seleção de variáveis

A etapa de seleção de variáveis é um dos passos mais importantes no processo de desenvolvimento de um soft sensor. Segundo Lipák e Venczel (2017), a disponibilidade de todas as variáveis existentes do processo não significa que todas, sem exceção, são relevantes para o alvo a ser estimado. A inclusão de variáveis independentes que sejam irrelevantes ou, em alguns casos, menos relevantes na estimação do alvo podem ser capazes de deteriorar o desempenho geral do soft sensor.

As variáveis devem ser submetidas a uma análise crítica com base em estudos técnicos do processo e com o suporte de um especialista no processo, que possui conhecimento técnico quanto ao processo e é capaz de tratar particularidades envolvidas em sua operação que pode ser determinístico na seleção de variáveis elegíveis como entrada do modelo em projeto.

Após a seleção de variáveis por conhecimento técnico do processo, pode-se realizar um refinamento dessas escolhas com a aplicação de técnicas estatísticas ou de aprendizado de máquina, conforme mencionado por Lipák e Venczel (2017). Reis e Silva (2005) mencionam a necessidade de normalização dos dados e aplicação de um procedimento complementar baseado na padronização de variáveis antes da utilização efetiva da base de dados para o desenvolvimento de uma RNA's.

Como exemplo, existem técnicas estatísticas como a Análise de Componentes Principais (PCA) e Mínimos Quadrados Parciais (PLS) que são baseadas em métodos de variação aplicáveis em modelos lineares. Yuce e Rezgui (2015) sugerem a utilização de PCA para redução de número de entradas do modelo, sendo capaz de aumentar a precisão e sua generalização.

No entanto, essas técnicas se tornam pouco efetivas para processos industriais que são frequentemente regidos por dinâmicas não lineares. Técnicas baseadas em Rede Neural Artificial (RNA) também podem ser usadas em modelos não-lineares. Segundo Lipák e Venczel (2017), em métodos baseados em Rede Perceptron Multi-Camadas (PMC) as variáveis de menor correlação são excluídas iterativamente pela busca reversa da rede que um critério de parada seja atingido.

Processos industriais são dinâmicos e mudam constantemente. É importante considerar como essas mudanças afetam no conjunto de variáveis selecionadas, uma vez que determinadas variáveis podem se tornar irrelevantes na inferência do alvo como também variáveis excluídas da seleção podem se tornar relevantes para o novo cenário do processo.

## Atrasos e períodos de amostragem

Instrumentos de medição em processos possuem diferentes taxas de amostragem e atrasos de medição, conforme mencionado por Lipák e Venczel (2017). A disposição física de cada instrumento de medição no processo acarreta em um tempo de atraso no comportamento do processo entre ambas as medições, o que se torna pouco apropriado relacionar as medidas ao mesmo

tempo. Neste contexto, considerado os atrasos de medição como um problema adicional ao conjunto de dados coletados.

A identificação de atrasos associados a cada variável independente é tão importante quanto a seleção das variáveis independentes para o modelo. O autor sensor Lipták e Venczel (2017) alerta que esse passo é geralmente realizado iterativamente com o processo de seleção das variáveis, porém é negligenciado em alguns casos por questões de simplificação da etapa de pré-processamento de dados. O extenso conhecimento do processo é essencial para identificação dos atrasos.

A sincronização dos dados para se tratar as diferentes taxas de amostragem é geralmente tratada, segundo Kadlec et al. (2009), pelo PIMS que registra novas amostras de dados somente quando uma das variáveis mudam mais do que o limiar de valor de ruído.

## Dados faltantes

Dados faltantes (missing values) são de ruído como valores que não representam os valores reais mensurados pelos instrumentos de medição, podem estar associados a falhas em registros de valores, falhas nos instrumentos de medição, períodos de amostragem diferentes entre as variáveis, falhas de comunicação do sistema de armazenamento de dados, etc.

Os dados faltantes são capazes de reduzir ou inviabilizar o modelo desenvolvido conforme a avaliação do seu desempenho após sua implementação. É necessário tratar a base de dados de modo a remover os conjuntos de dados que possuem essas características.

## Outliers

Outliers são dados que, dentro de uma determinada amostra, desviam-se de forma incomum da distribuição normal dos dados da mesma amostra. Segundo Lipták e Venczel (2017), a falha na detecção de outliers ou o incorreto tratamento desses valores podem afetar a precisão do soft sensor contribuindo para a desconstrução do pacote de dados, perda de pontos informativos e preditivos e redução nas relações entre as variáveis.

Existem diversos métodos estatísticos e algoritmos com a finalidade de identificar os outliers presentes em um conjunto de dados. Conforme mencionado por Genat (2018), os testes estatísticos mais comuns que podem ser utilizados para se tratar a presença de outliers são o teste de Chauvenet, Dixon e Grubbs. Para este caso, pode-se utilizar também o método box plot.

No entanto, Lipták e Venczel (2017) recomenda uma avaliação cautelosa para se detectar falsos outliers e mascaramento (outliers não identificados). O suporte de especialistas no processo é fundamental para que se preservar informações fundamentais para o treinamento e validação do modelo.

## Desvios dos dados

Os desvios no processo ocorrem por mudanças próprias do processo ou pela presença de condições externas não previstas. Tais fatores não influenciam somente nos dados coletados mas também na dinâmica do processo, o que afeta diretamente no desempenho do modelo do soft sensor a ser desenvolvido.

Neste caso, Kadlec et al. (2009) recomenda que os desvios sejam reconhecidos, relatados e as devidas ações sejam tomadas para evitá-los. O suporte de especialistas, neste caso, também é recomendado para que as ações a serem tomadas sejam eficazes para se reduzir esses desvios.

## Colinearidade dos dados

A colinearidade se refere a relação linear entre duas ou mais variáveis independentes. A presença de colinearidades, segundo Kipr Venczel (2017) é capaz de causar instabilidade nos coeficientes de regressão dos mínimos quadrados. A dependência linear entre variáveis ocorre por duplicação de variáveis, por uma determinada variável ser uma compensação ou derivação de outra ou por uma determinada variável ser uma combinação linear de outras variáveis.

Inferências baseadas em modelos de regressão podem ser pouco confiáveis quando duas ou mais variáveis em análise são muito correlacionadas. Caso o coeficiente de correlação entre duas variáveis for maior que 0,9, tem-se um indicativo de forte relacionamento entre elas. Segundo Kadlec et al. (2009), as colinearidades podem ser tratadas transformando-se a variável de entrada em um novo espaço reduzido com base nos métodos PCA e PLS, a fim de reduzir os efeitos da colinearidade dos dados ou reavaliar ou selecionar um sub-conjunto de variáveis que seja menos colinear.

### 2.2.3. Seleção do modelo

Esta etapa se mostra como uma das mais críticas no desenvolvimento de um projeto de soft sensor. Conforme citado por Kadlec et al. (2009), o modelo é o motor do soft sensor e a sua seleção é crucial para o seu desempenho. Não há uma teoria que torne objetiva a sua escolha por critérios técnicos e são comumente selecionados os modelos por experiência do desenvolvedor. O objetivo do modelo é encontrar uma função que poderá ser utilizada para se encontrar uma saída conforme as entradas apresentadas, incluindo aquelas não vistas até o momento na fase de sua construção.

A primeira decisão a ser feita para escolha do modelo, segundo Kipr Venczel (2017), é se o modelo será estático ou dinâmico. Modelos dinâmicos são aqueles que explicam comportamentos que variam com o tempo e se assemelham com maior frequência com o comportamento de processos industriais. Segundo Azeiteiro et al. (2015), alguns autores sugerem inicialmente a adoção de um modelo linear e, caso o desempenho de forma satisfatória, conclui-se

que o processo possui um comportamento não-linear, o que ocorre na maioria dos processos industriais. Neste sentido, os desenvolvedores consideram o ponto um modelo não-linear como ponto de partida.

Segundo Lipák e Venczel (2017), RNAs são de longe as escolhas mais populares e eficazes de aproximações universais para modelação não-lineares. A adoção de técnicas baseadas em lógica fuzzy podem ser combinadas ao modelo baseado em RNA com sucesso para representação do conhecimento linguístico.

Uma forma eficaz de planejar os modelos a serem gerados a fim de investigar possíveis melhorias em seu desempenho na aplicação de planejamento fatorial experimental ou Projeto de Experimentos (DOE) que é uma abordagem sistemática e estatística para otimização de processos que tem sido amplamente utilizada por engenheiros de processos em uma variedade de indústrias (MURRAY et al., 2013). O DOE tem como objetivo explorar, mapear e modelar o comportamento da resposta (ou de respostas múltiplas) dentro de um determinado espaço de intervalos combinados de todos os fatores envolvidos simultaneamente, variando todas as variáveis de acordo com uma matriz experimental predefinida (BOWDEN, 2019).

Um experimento de triagem é realizado para determinar as variáveis experimentais e interações que influenciam significativamente no resultado, medidos em uma ou mais respostas (ATKINSON e DONEV, 2011). Eldin (2011) cita que se as experiências forem realizadas aleatoriamente, o resultado obtido também será aleatório. Neste contexto, destaca-se a necessidade de planejar os experimentos de maneira que as informações desejadas sejam obtidas.

A aplicação do método reduz a necessidade de simulações excessivas e a elevação do custo computacional para determinação da solução para o processo em análise.

#### 2.2.4. Treinamento e validação

As etapas de treinamento e validação do modelo de soft sensor selecionado requerem uma quantidade suficiente de amostras dos dados de entradas e dos respectivos alvos. No entanto, em alguns processos industriais, segundo Kádlec (2009), pode ser difícil obter uma quantidade suficiente de dados históricos para o desenvolvimento do modelo.

Análises estatísticas repetidas nos mesmos dados podem ser combinadas para formar um único resultado chamado conjunto ou estimador de consenso. Resultados individuais de algoritmos de aprendizagem são combinados para melhorar a precisão geral das decisões. Um conjunto de modelos de aprendizado de máquina pode ser conceituado como um consórcio de especialistas para tomar uma decisão (CHOWDHURY et al., 2017). Dentre os modelos existentes, tem-se o método bagging em que cada conjunto de treinamento é construído formando uma aplicação bootstrap do conjunto de treinamento original. Em outras palavras, dado um conjunto de treinamentos  $S$  de  $m$  exemplos, um novo conjunto de treinamento é construído desenhando  $m$  exemplos uniformemente (com substituição) de  $S$  (CARL et al., 2019). Bühlmann (2012) demonstra o método bagging conforme a seguir:

$$g(\cdot) = h_n((X_1, Y_1); \dots; (X_n, Y_n))(\cdot) : \mathbb{R}^d \rightarrow \mathbb{R}; \quad (2.10)$$

Sendo:

$X_i \in \mathbb{R}^d$  = Variável de predição de tamanho;

$Y_i \in \mathbb{R}^d$  = Resposta (regressão) de tamanho;

$h_n$  = Função alvo de nida;

O modelo é de nido por votação, podendo ser uma média entre os modelos gerados ou um método de combinação apropriado dentre os conjuntos de dados de treinamentos utilizados em modelos de regressão (Figura 2.9).

Figura 2.9: Representação do método bagging através de um fluxograma

Para a avaliação do desempenho do modelo treinado, são apresentados dados para validação que não foram apresentados em sua fase de treinamento. Segundo Souza (2016), o método Erro Médio Quadrático (MSE) é comumente utilizado para este caso, conforme descrito na Equação 2.11:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.11)$$

Sendo:

MSE = Erro Médio Quadrático;

$y$  = Alvo observado;

$\hat{y}$  = Sada prevista pelo modelo;  
n = Número de amostras.

O objetivo da etapa de validação do modelo é de validar a capacidade/habilidade do modelo treinado de desempenhar uma generalização para novas amostras de dados (SOUZA et al., 2016). É mencionado por Lipik e Venczel (2017) que a validação do modelo é frequentemente subestimada apesar de sua importância. Independente da aplicação para qual o modelo de soft sensors está sendo desenvolvido, o conhecimento de especialistas no processo é crítico para a validação do seu modelo. Os feedbacks dos especialistas são importantes para uma avaliação adicional quanto ao desempenho do modelo de soft sensor construído, apesar de ser uma avaliação subjetiva.

### 2.2.5. Manutenção

Segundo Souza et al. (2016), os dados históricos utilizados no desenvolvimento do modelo possuem informações limitadas a um período específico. Ao se lidar com novos eventos que não são considerados na base de dados utilizada, o desempenho do soft sensor tende a deteriorar com o tempo. Neste sentido, soft sensors precisam ser mantidos e ajustados regularmente.

## 2.3. Redes Neurais Artificiais

### 2.3.1. Conceitos

Redes neurais artificiais (RNAs) são sistemas paralelos distribuídos compostos por unidades de processamento simples (nós artificiais) que calculam determinadas funções matemáticas (normalmente não-lineares) (BRAGA et al., 2016). Esses sistemas são compostos por uma ou mais camadas conectadas e cada nó é associado a um peso sináptico responsável por armazenar o conhecimento adquirido e ponderar a entrada recebida. De forma resumida, o sistema representa uma função de transferência não-linear ajustável capaz de relacionar múltiplos valores de entradas e de saída.

A motivação para o desenvolvimento de RNAs é o sistema nervoso do ser humano. Segundo Silva et al. (2010), o cérebro humano contém em torno de  $10^{11}$  neurônios e cada um deles processa e se comunica com milhares de outros de forma paralela. A estrutura de cada neurônio, as suas conexões e a avaliação do comportamento entre eles forma a base de estudo de RNAs.

Segundo Silva et al. (2010), as características mais relevantes envolvidas em aplicações de RNAs são:

- Adaptação por experiência — Ajuste dos pesos sinápticos das conexões por apresentação sucessiva de exemplos relacionadas ao comportamento do processo;
- Capacidade de aprendizado — A rede consegue extrair relacionamentos existentes entre variáveis que compõem o modelo por intermédio de um método de treinamento adequado;
- Habilidade de generalização — A rede é capaz de generalizar o conhecimento adquirido após o seu treinamento, possibilitando estimar situações não desconhecidas;
- Organização de dados — A rede é capaz de se organizar internamente, agrupando dados que apresentem particularidades em comum;
- Tolerância a falhas — A rede se torna tolerante a falhas quando parte de sua estrutura interna é sensivelmente corrompida;
- Armazenamento distribuído — O conhecimento adquirido de uma rede é distribuído entre as diversas conexões existentes. Isto permite que possa elevar a robustez do sistema frente a eventuais neurônios que se tornaram inoperantes;
- Facilidade de prototipagem — A maioria dos modelos podem ser implementados e prototipados com facilidade em hardware ou software

### 2.3.2. Neurônio artificial

Um neurônio é uma unidade de processamento de informação fundamental para o desenvolvimento e operação de uma rede neural artificial (HAYKIN, 2009). O modelo de um neurônio artificial é representado por terminais de entrada ponderados por pesos sinápticos e um valor de limiar de ativação que produzem um terminal de saída por meio de uma função de ativação, conforme ilustrado na Figura 2.10 e representado pela Equat. 2.

Figura 2.10: Representação de um neurônio artificial. Fonte: Demuth et al. (2009).

$$a = f(n) = f(Wp + b) \quad (2.12)$$

Sendo:

$a$  = Sinal de saída;

$n$  = Potencial de ativação;

$W$  = Vetor de  $R$  pesos sinápticos;

$p$  = Vetor de  $R$  sinais de entrada;

$b$  = Limiar de ativação.

O limiar de ativação, segundo Silva et al. (2010), especifica qual será o patamar apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção a saída do neurônio. Já o potencial de ativação  $n$  se trata do resultado da diferença entre a combinação dos sinais de entrada ponderados por pesos sinápticos e o limiar de ativação. Caso o potencial de ativação seja igual ou superior ao limiar de ativação, o neurônio irá produzir um potencial excitatório. Caso contrário, o potencial será inibitório.

A função de ativação tem como objetivo limitar a saída de um neurônio dentro de um intervalo específico de valores a serem assumidos. Cada função possui uma maior aplicabilidade para determinados problemas e características peculiares que determinam a sua utilização ou não em uma RNA.



### 2.3.3. Arquitetura de Redes Neurais Artificiais

Segundo Haykin (2009), a maneira como os neurônios de uma RNA são estruturados está intimamente ligado ao algoritmo de treinamento da rede. Como é importante definir os fatores para a delimitação da arquitetura de uma RNA como a relação do conjunto de dados de entrada, a classificação da rede, quantas camadas (agrupamentos) são presentes, quantos neurônios cada camada contém, quais as funções de ativação de neurônios presentes em cada camada, como os neurônios de cada camada são conectados entre si, a relação do conjunto de saídas da rede e entre outros fatores.

Uma RNA pode ser classificada como uma rede sem realimentação (feedforward) ou como uma rede realimentada (feedback). Em uma rede do tipo feedforward os neurônios de uma camada são conectados em neurônios de camadas subsequentes. Os valores de saída de neurônios pertencentes a camada de saída não realimentam a rede como uma entrada. No caso da rede do tipo feedback as realimentações na rede podem ocorrer em uma ou mais saídas de neurônios pertencentes a camada de saída.

Na Figura 2.11 demonstra-se a arquitetura de uma feedforward de múltiplas camadas. Esta arquitetura é composta por uma ou mais camadas ocultas de neurônios que antecedem a camada de saída. Segundo Silveira et al. (2010), a Rede Perceptron Multi-Camadas (PMC) e a Rede de Base Radial (RBR) são as principais redes que podem adotar o modelo de rede feedforward de múltiplas camadas para se resolver problemas de aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, controle de processos e entre outros problemas.

Figura 2.11: Exemplo de rede feedforward com múltiplas camadas. Fonte: Haykin (2009).

Para este trabalho, foi dado um foco maior em modelos de sensores baseados em redes do tipo PMC que é aplicável para resolução de problemas relacionados a aproximação

funções.

### 2.3.4. Aprendizado e validação

O aprendizado ou treinamento de RNAs consiste na atualização de seus pesos de modo a se obter uma rede treinada e especializada para desempenhar uma certa função. Por analogia, um problema de aproximação de funções se baseia na determinação dos parâmetros do modelo estimado que o aproxime de uma função que represente a relação entre as entradas e saídas apresentadas com base na atualização dos pesos sinápticos e dos limiares de ativação com percentual de correção específico e desejavelmente alto.

O aprendizado pode ser o aprendizado supervisionado. A supervisão do aprendizado permite a comparação entre as saídas geradas pela rede e os alvos. A rede, em resposta a esta comparação, busca atualizar os pesos sinápticos com o objetivo de aproximar as saídas da rede aos alvos de forma iterativa. Segundo Braga et al. (2016), os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta e o algoritmo de retropropagação de erros (back-propagation) que se trata da generalização da regra delta para redes PMC.

O princípio do algoritmo back-propagation se baseia na utilização do gradiente descendente para se estimar os erros das camadas internas por meio de uma estimativa do efeito que estas causam no erro da camada de saída. Ou seja, o erro calculado para a rede PMC é retroalimentado para as camadas internas, possibilitando o ajuste de pesos de forma proporcional aos pesos sinápticos entre camadas.

O aprendizado pode ser realizado offline ou online. O aprendizado offline é realizado com base em um conjunto de dados de treinamento fixo e a sua solução é obtida diretamente por estes dados. Neste caso, novos treinamentos devem ser realizados caso sejam apresentados novos dados no conjunto em avaliação. Em contrapartida, o aprendizado online permite que a rede se mantenha em um regime constante de adaptação.

#### Método de Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt é um método gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não lineares, que pode ser incorporado ao algoritmo back-propagation a fim de potencializar a eficiência do processo de treinamento (SILVA et al., 2010). Esse algoritmo é capaz de convergir rapidamente próximo ao mínimo local ou global, porém não em todos os casos.

Segundo Haykin (2009), o ajuste ótimo aplicado ao vetor de pesos sinápticos no método de Levenberg-Marquardt é definido pela Equação 2.13.

$$Dw = [H + \lambda I]^{-1} g \quad (2.13)$$

Sendo:

$Dw$  = Ajuste ótimo aplicado ao vetor de pesos sinápticos  $w$ ;

H = Matriz Hessiana;

L = Matriz de regularização que força a soma entre I;

I = Matriz identidade com as mesmas dimensões de H;

g = Vetor de gradientes da rede.

A matriz Hessiana de uma função de variáveis se trata de uma matriz quadrada cujos elementos são derivadas parciais de segunda ordem dessa função.

A rede PM é treinada com o objetivo de minimizar a função custo conforme descrito pela Equação 2.14, considerando o conjunto de dados de treinamento  $\{(x(i), d(i))\}$  de dimensão N.

$$e_{av}(w) = \frac{1}{2N} \sum_{i=1}^N [d(i) - F(x(i); w)]^2 \quad (2.14)$$

Sendo:

$e_{av}(w)$  = Função custo do método de Levenberg-Marquardt;

$F(x(i); w)$  = Função aproximada pela rede.

O gradiente e a Hessiana da função de custo são descritas, respectivamente, pelas Equações 2.15 e 2.16:

$$g(x) = \frac{\nabla e_{av}(w)}{\nabla w} \quad (2.15)$$

$$H(x) = \frac{\nabla^2 e_{av}(w)}{\nabla w^2} \quad (2.16)$$

Substituindo as Equações 2.15 e 2.16 na Equação 2.13, o ajuste desejado para  $w$  é computado para cada época de treinamento do algoritmo de Levenberg-Marquardt. Em um ponto de vista prático, devido ao elevado custo computacional para a execução de muitas iterações deste algoritmo quando a dimensão do vetor de pesos é elevada, a matriz hessiana pode ser aproximada para uma função mais simplificada, conforme descrito na Equação 2.17

$$H(x) \approx \frac{1}{N} \sum_{i=1}^N \frac{\nabla F(x(i); w)}{\nabla w} \frac{\nabla F(x(i); w)}{\nabla w}^T \quad (2.17)$$

Segundo Haykin (2009), o uso dessa aproximação é justificado quando o algoritmo de Levenberg-Marquardt encontra-se em operação na vizinhança de um mínimo local ou global para a função custo.

## Validação e testes

A validação do processo de treinamento de redes neurais é realizado para cada época de treinamento com o objetivo de validar de forma antecipada o comportamento do processo em cada iteração.

O processo de validação é utilizado normalmente como critério de parada do processo de treinamento e avaliação da capacidade de reprodução dos resultados (generalização) da RNA durante o processo de treinamento. Caso o nível de desempenho da validação não apresente uma evolução em seu desempenho conforme o avanço das épocas de treinamento (checks de validação). A RNA é gerada com os pesos das conexões sinápticas da época de treinamento anterior à época de parada.

O coeficiente entre os dados alvo e as saídas da RNA na etapa de validação é utilizado como um indicador de sua capacidade de reprodução dos resultados (generalização).

A etapa de testes consiste na apresentação de dados de teste desconhecidos à RNA treinada. A avaliação pode ser feita de forma visual e pela análise de critérios de desempenho entre os dados de saída da rede e os respectivos alvos. O erro médio da rede em um instante  $t$ , descrito pela Equação 2.18, pode ser calculado e apresentado em formato de histograma de erros para se avaliar a frequência dos erros calculados e se a sua grande maioria é próxima de zero, comportamento este desejado para a rede treinada.

$$e(t) = y_t(t) - y(t) \quad (2.18)$$

A avaliação do desempenho da RNA pode ser realizada através de regressão entre as saídas da rede e os respectivos alvos. Essa regressão gera uma função linear entre os dados com um fator de correlação  $R$ . Uma correlação próxima de 1 significa que a rede se adaptou bem na resolução do problema de aproximação de uma função representativa ao processo. De forma análoga, uma correlação próxima de 0 significa que a rede não foi capaz de absorver nenhum aprendizado para representar o processo por uma aproximação de uma função.

Testes adicionais podem ser realizados, apresentando a rede um novo conjunto de dados para fins de reforço do processo de sua validação.

### 3. Materiais e Métodos

Neste capítulo é feita uma caracterização da área de estudo e a apresentação dos materiais e métodos aplicados para o desenvolvimento deste trabalho.

#### 3.1. Caracterização da área de estudo

A pesquisa em questão possui caráter experimental, com o intuito de avaliar características, propriedades ou relações existentes em dados de processos laboratoriais e dados técnicos inerentes a moinhos de bolas em circuito fechado, a fim de estimar a eficiência energética por meio de um soft sensor

#### 3.2. Dados

Foram utilizados dados do processo de moagem da usina de beneficiamento da Mina de Timbopeba, pertencente a VALE S.A. e localizada no município de Ouro Preto, estado de Minas Gerais, Brasil.

Os dados de processos e análises laboratoriais foram exportados do sistema Sistema de Gestão de Informações sobre Processos (PIMS) existente na unidade operacional. A base temporal dos dados de coletada em campo com avaliação conjunta com a área responsável pela engenharia de processos e os dados armazenados em um banco de dados local para posterior manipulação com a utilização de softwares adequados para o projeto e simulação de soft sensors

#### 3.3. Metodologia

O software MATLAB® foi utilizado para a etapa de pré-processamento dos dados e desenvolvimento do algoritmo de soft sensor responsável por realizar a inferência da eficiência energética do moinho de bolas em circuito fechado, conforme a base de dados inicial para realização de simulações. Nesta etapa, foi definida a topologia da RNA, incluindo as camadas existentes, funções de ativação, os pesos sinápticos e limites de ativação iniciais, o algoritmo para treinamento e a função de custo a ser adotada para avaliação do desempenho das etapas de treinamento, validação e testes do modelo projetado.

O software Minitab® foi utilizado para avaliação da eficiência de cada etapa de pré-processamento de dados durante o procedimento de simulação a utilização de Projeto de Experimentos (DOE), apresentado no subitem 3.7, e identificação de pontos de melhoria para a qualidade da base de dados.

Os resultados de cada simulação foram avaliados e comparados com os valores desejados (alvos) também disponibilizados na base de dados inicial.

### 3.4. Procedimento de pré-processamento dos dados

Foram coletados dados dos 152 tags relacionados ao circuito de moagem da usina de beneficiamento de minério da Mina de Timbopeba, incluindo variáveis de medição, estados de funcionamento de equipamentos, ângulos de processo, totalizadores e ângulos de malhas de controle, dados de análises laboratoriais, alarmes, cálculos e entre outros dados.

Em seguida, foi realizada uma inspeção inicial dos dados, a fim de identificar tags congeladas ou cujas informações se remetem a equipamentos ou instrumentos desativados em campo. Dentre os 152 tags levantados, 19 destes tags foram desconsiderados da base de dados por apresentarem tais características. A confirmação quanto a desativação do equipamento ou instrumento em campo foi realizada junto com as áreas responsáveis pelo processo.

Foram levantados dados históricos dos 133 tags selecionados no período de 25/08/2018 a 31/01/2019 com período de amostragem de 30 segundos. A coleta e sincronização dos dados para que todos fossem representados no mesmo período de amostragem foi realizada pelo sistema PIMS existente na unidade operacional.

#### Seleção de variáveis

A seleção das variáveis candidatas dentre as 133 variáveis selecionadas não foi feita com base na revisão bibliográfica levantada neste trabalho e com a consulta de um especialista da área responsável pela operação do circuito de moagem. Dentre os 133 tags levantados, foram selecionadas 10 variáveis elegíveis como entradas do modelo soft sensor e a variável de saída EF (Eficiência Energética do Circuito de Moagem), conforme identificado na Tabela 3.1.

Tabela 3.1: Variáveis de processo candidatas como entradas para o modelo soft sensor

Tag	Descrição	Unidade
EF	Eficiência energética do circuito de moagem	%
TO_FY4305.03	Percentual calculado de carga circulante do circuito da moagem	%
TO_II4303.01	Corrente do motor principal do moinho	A
TO_JI4303.01	Potência do moinho	kW
TO_VI4303.01	Vibração do pédio da moagem	mg
TO_DI4305.01	Densidade de polpa bombeada para alimentação da bateria de ciclones	t/m <sup>3</sup>

Tabela 3.1 continuação da página anterior

Tag	Descrição	Unidade
TO_FI4305_01	Vazão de polpa bombeada para alimentação da bateria de ciclones	m <sup>3</sup> /h
TO_FY4305_01	Vazão de sólidos bombeada para alimentação da bateria de ciclones	t/h
TO_PI4307_01	Pressão na linha de alimentação da bateria de ciclones	bar
TO_SNMO430308_EST1	Estado de acoplamento do moinho em operação (0 = desacoplado / 1 = acoplado)	-
NUM_CICLONES	Número de ciclones abertos	-

A variável 'P\_A4412\_TO\_FG\_GLOBAL\_+0.15MM' é equivalente a  $R_{pm}$  gerado em ensaios laboratoriais e foi utilizada para cálculo da Eficiência Energética do Circuito de Moagem (EF), segundo a Equação 2.9 adaptada em função da Equação 2.5 devida por Donda (2018), usando-se o valor de  $R_f$  em 49,92%,  $R_p$  projetado em 15,0% e a constante para a forma de aplicação de energia e da malha em 0,331 (Equação 3.1).

$$E(\%) = 100 \frac{E_m}{E_p} = 100 \frac{\ln \frac{R_{fm}^2}{R_{pm}^3}}{\ln \frac{R_{fp}}{R_{pp}^5}} = \frac{3,9104 \ln(R_{pm})}{0,012024} \quad (3.1)$$

Sendo:

$R_{pm}$  = Medição do percentual retido no produto do processo na mesma malha de alimentação.

#### Tratamento de dados faltantes

Foi realizado um tratamento na base de dados a fim de retirar amostras de dados que continham:

- Valores inválidos gerados por falha de comunicação com o CLP do circuito de moagem;
- Intervalos de valores congelados em zero;
- Intervalos com valores de medição congelados no limite mínimo ou máximo do instrumento de medição.

#### Filtro dos dados por condição de processo

Dentre as variáveis selecionadas, duas delas foram utilizadas como filtros para aplicação de filtro na base de dados: o estado de acoplamento do moinho em operação 'TO\_

SNMO430308.EST1'), que permite a quebra de carga para redução mirério de alimentação do circuito e a quantidade de ramais abertos na bateria de ciclagem (NUM\_CICLONES').

O tag `TO\_SNMO430308.EST1' é do tipo binário, sendo `TOSNMO430308.EST1' = 0 quando o moinho encontra-se desacoplado ou 1 quando o mesmo encontra-se acoplado.

O tag `NUM\_CICLONES' é do tipo inteiro, podendo variar de 0 (todos os ramais fechados) até 8 (todos os ramais abertos). Em condições normais de operação, conforme avaliação junto a área operacional responsável pelo processo, a carga circulante do circuito de moagem da usina de beneficiamento da Mina de Timbopeba opera com 2, 3 ou 4 ramais abertos.

### Tratamento de outliers

A identificação e tratamento de outliers foi realizada utilizando o método estatístico  $Z$  com critério de rejeição de observações ( $X$ ). Segundo Andriotti (2005),  $Z$  ou  $Z$  padronizado se trata do número de desvios padrão pelo qual um valor qualquer dista da média, conforme descrito na equação 3.2.

$$z = \frac{(x_i - \bar{x})}{s} \quad (3.2)$$

Sendo:

$z$  = Número de desvios padrão pelo qual o  $i$ -ésimo valor dista da média;

$x_i$  =  $i$ -ésima observação da amostra;

$\bar{x}$  = Média de todas as observações pertencentes a uma amostra;

$s$  = Desvio padrão do conjunto de observações pertencentes a uma amostra.

Considerando o método  $Z$ , uma observação é considerada como um outlier quando:

$$x_i = \begin{cases} \text{outlier; } |x_i - \bar{x}| > Xs \\ \text{normal, caso contrário} \end{cases} \quad (3.3)$$

Sendo:

$X$  = Critério de rejeição de observações.

Com:

$X = 2$  (pouco conservador);

$X = 2,5$  (razoavelmente conservador);

$X = 3$  (muito conservador).

A fim de investigar a eficácia do tratamento de outliers, análises através de diagramas de caixa foram consideradas quando necessárias para tomadas de decisão quanto a base de dados considerada no pré-processamento dos dados. Segundo Dawson (2011), isto consiste em



uma caixa que se estende do primeiro ao terceiro quartis (Q1 e Q3, respectivamente) com uma marcação da mediana, com Amplitude Inter-Quartis (IQR), conforme descrito na Equação 3.4 e das cercas (limites) que extrapolam a caixa, conforme descrito pelas Equações 3.5 e 3.6. Os dados que se encontram fora dos limites de nidos para o diagrama de caixa são considerados outliers

$$IQR = Q3 - Q1 \quad (3.4)$$

Sendo:

Q3 = Quartil superior que representa 75% dos dados;

Q1 = Quartil inferior que representa 25% dos dados;

$$LI = Q1 - 1,5IQR \quad (3.5)$$

Sendo:

LI = Limite inferior do diagrama de caixa;

$$LS = Q3 + 1,5IQR \quad (3.6)$$

Sendo:

LS = Limite superior do diagrama de caixa;

#### Filtro dos dados por amostragem de produto

Como a amostra do produto do circuito da moagem para registro do percentual retido em uma malha na alimentação do processo ( $R_f$ ) é normalmente realizada de 3 em 3 horas, os dados se repetem no intervalo entre as amostras na base de dados do PIMS.

Os dados repetidos não se remetem a uma condição real de processo e sim a uma limitação quanto a disponibilização da medição em tempo real que o mesmo é disponibilizada somente após os resultados laboratoriais com registro de dados em um Sistema de Gestão de Informações sobre Laboratórios (LIMS).

Para este caso, foi aplicado um filtro para que a base de dados contivesse somente registros de dados nos instantes em que as amostras foram registradas no sistema.

#### Tratamento de desvios dos dados

Considerando a base reduzida após o filtro dos dados por amostragem do produto, uma análise do comportamento dos dados é realizada para identificação de desvios de processo ou comportamentos que possam influenciar na dinâmica do mesmo.

## Análise de colinearidades

Considerando a base tratada é a etapa de retirada dos desvios de dados realizada uma análise de colinearidade entre os dados com o objetivo de reduzir a quantidade de variáveis elegíveis como entradas do modelo, caso estas, aos pares, possuam fatores de correlação superiores a 90%.

### 3.5. Procedimento de simulação preliminar

A simulação preliminar foi realizada como ponto de partida para gerar o modelo, com o objetivo de investigar se o modelo gerado seria capaz de obter alguma aprendizagem com base nos dados apresentados, sua capacidade de generalização do pré-processamento dos dados. Não foram consideradas para essa simulação a aplicação do PCA para redução da dimensão dos dados de entrada e a redução conjunto de amostras por análise de desvio dos dados e por presença de colinearidades. Foi aplicada uma normalização dos dados para apresentação ao modelo com média nula e desvio padrão unitário. Para o tratamento de outliers, foi considerado o critério de rejeição de observações como muito conservador ( $\alpha = 3$ ).

O modelo gerado na simulação preliminar foi baseado em uma RNA do tipo Perceptron Multi-Camadas (PMC) sem realimentação (feedforward) com 11 neurônios na camada oculta e com funções de ativação do tipo tangente hiperbólica, utilizando 9 das 10 variáveis de entrada descritas conforme na Tabela 3.1 (a série 'TOSNMO430308.EST1' foi utilizada como Itro dos dados). A escolha da quantidade de neurônios na camada oculta para a simulação preliminar foi de modo de forma empírica.

Para esta simulação, o conjunto de dados foram subdivididos em conjuntos distintos de forma aleatória da seguinte proporção: 70% dos dados para treinamento da rede, 15% dos dados para validação da rede e os demais 15% para testes na rede treinada. O treinamento da rede foi realizado com base no algoritmo de Levenberg-Marquadt. Como critério de desempenho do modelo, adotou-se a utilização do critério MSE.

### 3.6. Procedimento de aprimoramento da simulação preliminar

A simulação aprimorada foi realizada com base nos resultados apresentados na simulação preliminar a fim de alcançar uma melhoria na correlação dos dados e aumentar capacidade de generalização do modelo.

Para o modelo de soft sensor dessa simulação, foi considerada a utilização do mesmo modelo proposto na simulação preliminar.

Houve uma redução na quantidade de variáveis de entrada do modelo com base em uma análise de colinearidades entre as variáveis e houve uma redução na quantidade de dados de

amostragem com a aplicação de um filtro pela quantidade ramais abertos da bateria de ciclones do circuito de moagem (tag 'NUMCICLONES'), considerando 3 ramais abertos como o caso mais típico no processo, e pela análise de desvios nos dados.

Foi aplicada uma normalização dos dados para apresentação do modelo com média nula e desvio padrão unitário. Após a normalização, aplicou-se o algoritmo PCA para redução da base de dados de entrada normalizada. O algoritmo aplicado aos dados de entrada de eliminar componentes principais que contribuem menos que um determinado percentual na variação total do conjunto de dados. Para este procedimento de simplificação considerado um percentual de 10%.

Nos procedimentos de subdivisão do conjunto de dados, o algoritmo de treinamento do modelo e seu critério de desempenho foram os mesmos adotados para a simplificação. O método bagging foi aplicado com a escolha do modelo que represente o melhor desempenho de todos os modelos gerados pelos diversos conjuntos de dados de treinamento que foram gerados aleatoriamente.

### 3.7. Procedimento de simulação com utilização de projeto de experimentos

Com base nos resultados apresentados no aprimoramento da simplificação, foram levantadas as seguintes necessidades, com o objetivo de melhorar de forma significativa a correlação das saídas do modelo com os alvos e a capacidade de generalização do modelo:

- Realizar novas simulações para o modelo baseado em RNAs do tipo PMC adotando a aplicação de DOE com o objetivo de planejar e avaliar os modelos testados, buscando os parâmetros que maximizem o desempenho do modelo do sensor
- Reavaliar o procedimento de processamento dos dados, verificando se as etapas sequenciadas possuem margem de melhoria no tratamento da base de dados;
- Coletar novos dados, caso possível, ou adotar técnicas distintas de re-sampling e expansão da base de dados com base em modelos estatísticos e computacionais para as etapas de treinamento, validação e testes do modelo do sensor com o objetivo de elevar a qualidade dos dados adotados para o desenvolvimento do modelo.

O planejamento do experimento considerou a avaliação dos seguintes fatores: a quantidade de neurônios na camada oculta do modelo (variando de 7 a 15) e as funções de ativação dos neurônios da camada oculta do modelo (funções de ativação tangente hiperbólica e logística). Os coeficientes de correlação das etapas de treinamento, validação e testes e o coeficiente de correlação global foram de nidos como respostas aos experimentos planejados e analisados.

As etapas de pré-processamento de dados foram revisitadas para aprimoramento da base de dados amostrados para utilização nas etapas de treinamento, validação e testes dos modelos. Por limitações do processo produtivo não foi possível coletar novos dados para expansão da base de dados para aplicação de um novo procedimento de pré-processamento dos dados. Não aplicou-se para a simulação métodos de reamostragem (ex. bagging).

As simulações planejadas com base na alteração dos fatores previstos foram realizadas, considerando a utilização do mesmo modelo proposto no aprimoramento da simulação preliminar.

Nos procedimentos de subdivisão do conjunto de dados, o algoritmo de treinamento do modelo e seu critério de desempenho se mantiveram os mesmos adotados para as demais simulações.

## 4. Resultados e Discussão

Neste capítulo, os resultados são apresentados conforme os materiais e métodos aplicados para desenvolvimento do soft sensor.

### 4.1. Simulação preliminar

#### 4.1.1. Pré-processamento dos dados

Os gráficos de evolução da seleção de variáveis e quantidade de amostras consideradas na base de dados são apresentadas, respectivamente, nas Figuras 4.10 e 4.11, considerando as etapas aplicadas de pré-processamento de dados que foram capazes de selecionar de forma progressiva as variáveis candidatas a entradas do modelo do soft sensor desenvolvido na simulação preliminar. A base gerada para a simulação do modelo é composta por 393 amostras.

Figura 4.1: Evolução da seleção de variáveis durante a etapa de pré-processamento de dados.

Figura 4.2: Evolução da base de dados durante a etapa de pré-processamento de dados.

#### 4.1.2. Simulação do modelo

Na Figura 4.3 é apresentada a evolução do desempenho do modelo por épocas de treinamento, com base na apresentação dos dados para a sua validação, alcançando-se um desempenho MSE de validação de 0,98445 com 6 épocas de treinamento.

Figura 4.3: Simulação preliminar — Desempenho da rede por épocas de treinamento, com base no critério de desempenho MSE para os dados de validação do modelo.

O critério de parada para este caso foi o número de validações que superou o limite estabelecido em épocas em que não ocorreram reduções no erro de generalização do modelo em observação ao critério de desempenho do conjunto de validação da rede PMC, conforme indicado na Figura 4.4

Figura 4.4: Simulação preliminar — Critério de parada pelo número de validações.

Na Figura 4.5 são indicadas as análises de regressão das séries da rede em relação aos alvos para as etapas de treinamento, validação e análise global dos dados. A RNA alcançou um coeficiente de correlação global de 45,613% entre as séries do sensor e os alvos, o que indica uma correlação fraca entre os dados. O coeficiente de correlação da etapa de validação da RNA de 46,06% indica uma baixa capacidade de generalização, sugere-se que a RNA tenha aprendido alguma informação com baixa exatidão para se inferir a ciência energética do circuito de moagem.

Figura 4.5: Simulação preliminar — Análise de regressão dos dados de saída da rede e dos alvos.

Na Figura 4.6 é possível avaliar por inspeção visual o comportamento da rede comparado aos alvos nas etapas de treinamento e de validação, respectivamente. O critério de desempenho global obtido para o modelo foi de 0,8159, considerando a aplicação do critério MSE.



Figura 4.6: Simulação preliminar — Comportamento do modelo comparado aos alvos na etapa de treinamento.

O histograma do erro absoluto dos dados apresentado na Figura 4.7 como uma aproximação de uma distribuição normal com média de 1,852 pp e desvio padrão de 24,21 pp. Com base na ISO GUM (2008), com o número de conjuntos de dados amostrados (graus de liberdade) superior a 100, considerou-se a incerteza expandida de 58,42 pp com fator  $k = 2$  pela distribuição de Student com nível de confiança de 95,45%. É indicado um erro médio com alta variabilidade em função da baixa capacidade de aprendizagem do modelo. Os extremos do histograma representam situações em que a saída da rede PMC indica uma eficiência energética elevada do circuito sendo que a eficiência real no processo é baixa e vice-versa.

Figura 4.7: Simulação preliminar — Histograma do erro absoluto entre o modelo e os alvos.

Os resultados apresentados na simulação preliminar do modelo de soft sensor apontaram a necessidade de reinicialização do fluxo de pré-processamento de dados e de gerar novas simulações do modelo preliminar, revendo o método utilizado e os parâmetros adotados, buscando um modelo capaz de aprender e inferir a energia elétrica do circuito de moagem com capacidade generalizada.

## 4.2. Simulação aprimorada

### 4.2.1. Pré-processamento dos dados

O procedimento de pré-processamento dos dados foi refeito, considerando a aplicação de um novo filtro pela quantidade de ramais abertos na bateria de ciclones, a eliminação de desvios e colinearidades dos dados.

Reavaliação do filtro dos dados pela quantidade de ramais abertos

A filtragem dos dados pela quantidade de ramais abertos na bateria de ciclones (‘NUM.CICLONES’) foi reavaliada, considerando o caso mais comum identificado (3 ramais abertos). Esta variável deixou de ser uma entrada elétrica para o modelo por possuir variabilidade nula.

## Análise de desvios nos dados

Considerando a base reduzida de dados por amostragem do produto, foi realizada uma análise do comportamento dos dados para identificação de desvios de processo ou comportamentos que possam influenciar na produção do mesmo.

Observando os dados de medições das variáveis 'TOPI4307.01' e 'TO\_FI4305.01', observou-se um degrau nas medições em um mesmo instante, o que sugere uma mudança no processo, conforme indicado na Figura 4.8.

Figura 4.8: Avaliação de desvio dos dados.

Todos os dados que antecedem o degrau identificado foram desconsiderados da base de dados para utilização nas simulações desta etapa.

## Análise de colinearidades

Foi realizada uma análise de colinearidade entre os dados. A matriz de correlação obtida para a base de dados tratada atualmente é apresentada na Figura 4.9. As correlações são destacadas caso estejam com valores próximos ou acima de 0,9.

Figura 4.9: Análise de colinearidade das variáveis selecionadas.

Foi verificado que a variável 'TO.FY4305.01' possui forte correlação com as variáveis 'TO.FI4305' e 'TO.DI4305'. Isto se deve pelo fato desta variável ser calculada em função das variáveis que são medidas em campo por instrumentos de medição.

As variáveis 'TO.FI4305.01' e 'TO.PI4307.01' também possuem forte correlação entre si, já que o aumento de pressão na linha de alimentação da bateria de ciclones implica em um aumento na vazão de polpa dessa mesma linha.

Logo, com base na análise de colinearidade realizada, as variáveis 'TO.FY4305.01' e 'TO.PI4307.01' foram desconsideradas como entradas para o modelo de soft sensor proposto. Com isso, a listagem de variáveis elegíveis para aplicação no modelo de soft sensor foi reduzida para 7 variáveis (6 variáveis de entrada e 1 variável de saída).

#### Evolução do processo de pré-processamento

Os gráficos de evolução da seleção de variáveis e quantidade de amostras consideradas na base de dados são mostradas, respectivamente, nas Figuras 4.10 e 4.11, considerando as etapas aplicáveis de pré-processamento de dados que foram capazes de selecionar de forma progressiva as variáveis candidatas a entradas e saídas do modelo de soft sensor desenvolvido na simulação preliminar. A base gerada para a simulação do modelo é composta de 393 amostras.

Figura 4.10: Evolução da seleção de variáveis durante a etapa de processamento de dados.

Figura 4.11: Evolução da base de dados durante a etapa de processamento de dados.

#### 4.2.2. Simulação do modelo

Foram gerados 1000 conjuntos de amostras de dados aleatoriamente com a aplicação do método bagging, para cada conjunto gerado, gerou-se uma RNA respectiva. Considerando o conjunto de modelos gerados, o que mais se aproximou do desempenho de todo o conjunto foi escolhido como o modelo de sensor para esta simulação.

Na Figura 4.12 é apresentada a evolução do desempenho do modelo escolhido por épocas de treinamento, com base na apresentação dos dados para a sua validação, alcançando-se um desempenho MSE de 0,60568 com 10 épocas de treinamento.

O critério de parada para este caso foi o número de validações que superou o limite estabelecido em épocas em que não ocorreram reduções no erro de generalização do modelo, em observação ao critério de desempenho do conjunto de validação da rede PMC, conforme indicado na Figura 4.13

Figura 4.12: Simulação preliminar aprimorada — Desempenho da rede em épocas de treinamento, com base no critério de desempenho MSE para os dados de validação do modelo.

Figura 4.13: Simulação preliminar aprimorada — Critério de parada pelo número de validações.

Na Figura 4.14 são indicadas as análises de regressão das séries da rede em relação aos alvos para as etapas de treinamento, validação e análise global dos dados. A RNA alcançou um coeficiente de correlação global de 61,715% entre as séries do soft sensor e os alvos, o que indica uma melhoria na correlação entre os dados comparada a simulação preliminar. O coeficiente de correlação na etapa de validação da RNA de 75,717% indica uma capacidade moderada de generalização, capaz de inferir a eficiência energética do circuito de moagem porém com baixa exatidão e com margem para melhoria na aprendizagem e na capacidade de generalização do modelo.

Figura 4.14: Simulação preliminar aprimorada — Análise de regressão dos dados de série da rede e dos alvos.

Na Figura 4.15 é possível avaliar por inspeção visual o comportamento da rede comparado aos alvos nas etapas de treinamento e de validação, respectivamente. O critério de desempenho global obtido para o modelo foi de 0,7282, considerando a aplicação MSE.

Os resultados apresentados na simulação preliminar do modelo de soft sensor apontaram a necessidade de reinicialização do fluxo de pré-processamento de dados e de gerar novas simulações do modelo preliminar, revendo o método utilizado e os parâmetros adotados, buscando um modelo capaz de aprender e inferir a eficiência energética do circuito de moagem

com capacidade generalizãç

Figura 4.15: Simulação preliminar aprimorada — Comportamento do modelo comparado aos alvos na etapa de treinamento.

O histograma do erro absoluto dos dados apresentado na Figura 4.16 como uma aproximação de uma distribuição normal com média de  $-0,01245$  pp e desvio padrão de  $23,87$  pp. É indicada uma alta variabilidade em função da baixa capacidade de aprendizagem do modelo. Da mesma forma que a simulação preliminar, considerou-se a incerteza expandida de  $k_s = 47,74$  pp com fator  $k = 2$  pela distribuição de Student com nível de confiança de  $95,45\%$ . Os extremos do histograma também representam situações em que a saída da rede PMC indica uma inferência de eficiência energética elevada do circuito sendo que a eficiência real no processo é baixa e vice-versa.



Figura 4.16: Simulação preliminar aprimorada — Histograma do erro absoluto entre o modelo e os alvos.

Houve uma melhoria na correlação dos dados de saída da rede e os alvos por inspeção visual do gráfico apresentando na Figura 4.14, comparado aos resultados da simulação preliminar. A melhoria ainda não foi suficiente para estimar a eficiência energética do circuito de moagem com precisão e boa capacidade de generalização, necessitando de novos estudos quanto ao modelo de soft sensor proposto.

### 4.3. Simulação com utilização de projeto de experimentos

#### 4.3.1. Pré-processamento dos dados

O procedimento de pré-processamento dos dados foi feito, considerando uma nova avaliação no tratamento de outliers. Foi verificada a presença de outliers de forma isolada na variável de entrada 'TOFY4305.01' pela análise de diagrama de caixa, conforme indicado na Figura 4.17. A análise foi considerada para esta variável por se tratar de um tag calculado com base nos dados de carga circulante do circuito, visto que valores discrepantes em virtude do comportamento das demais variáveis dependentes para a sua obtenção. A base de dados para utilização no treinamento, testes e validação do modelo obteve uma nova redução conforme indicado na Figura 4.18, retirando os dados relativos aos outliers identificados na variável de entrada 'TOFY4305.01'.

Figura 4.17: Avaliação de outliers por diagrama de caixa - variável TO.FY4305.03.

Figura 4.18: Simulação com projeto de experimentos - Evolução da base de dados durante a etapa de pré-processamento de dados.

Os demais etapas realizadas no procedimento de pré-processamento dos dados foram mantidas, incluindo a análise de desvios e colinearidades dos dados tratada no aprimoramento da simulação preliminar.

#### 4.3.2. Simulação do modelo

Na Tabela 4.1 são mostrados os testes planejados para simular variando a quantidade de neurônios na camada oculta e as respectivas taxas de ativação. Gerou-se um modelo para cada teste planejado e os coeficientes de correlação das etapas de treinamento, validação

e testes e o coeficiente de correlação global foram registrados para cada teste realizado. Cada teste planejado foi realizado sem repetições.

Tabela 4.1: Planejamento de experimentos

Teste	Quantidade de neurônios na camada oculta	Função de Ativação	Coeficiente de Correlação			
			Treinamento	Testes	Validação	Global
1	7	tang. hiperbólica	0,8799	0,4296	0,3968	0,6835
2	7	logística	0,9008	0,6678	0,6432	0,8163
3	8	tang. hiperbólica	0,3918	0,2471	0,5304	0,3907
4	8	logística	0,6976	0,0757	0,0900	0,5657
5	9	tang. hiperbólica	0,4521	0,2829	0,1721	0,3639
6	9	logística	0,4840	0,4343	0,1665	0,4211
7	10	tang. hiperbólica	0,6558	0,0913	0,2724	0,4970
8	10	logística	0,6076	0,5442	0,4568	0,5836
9	11	tang. hiperbólica	0,8714	0,8163	-0,2279	0,5300
10	11	logística	0,7007	0,4065	0,4180	0,6085
11	12	tang. hiperbólica	0,9521	0,7509	0,7014	0,8690
12	12	logística	0,9664	0,6258	0,6284	0,8630
13	13	tang. hiperbólica	0,4136	0,3792	0,5386	0,4288
14	13	logística	0,9149	0,9291	0,3940	0,7857
15	14	tang. hiperbólica	0,7888	0,7114	0,3948	0,7173
16	14	logística	0,8788	0,4435	0,2699	0,7201
17	15	tang. hiperbólica	0,7129	-0,0072	0,3785	0,5753
18	15	logística	0,6212	0,1155	0,1485	0,4385

O modelo escolhido corresponde ao 11º teste planejado que obteve o maior coeficiente de correlação global (86,90 %) comparado aos demais modelos testados. Na Figura 4.19 apresentada a evolução do desempenho do modelo escolhido em épocas de treinamento, com base na apresentação dos dados para a sua validação, alcançando-se um desempenho MSE de 0,31054 com 6 épocas de treinamento.

O critério de parada para este caso foi o número de validações que superou o limite estabelecido em 6 épocas em que não ocorreram melhorias do desempenho da rede PMC, conforme indicado na Figura 4.20

Figura 4.19: Simulação com projeto de experimentos — Desempenho da rede por épocas de treinamento, com base no critério de desempenho MSE para os dados de validação do modelo.

Figura 4.20: Simulação com projeto de experimentos — Critério de parada pelo número de validações.

A Figura 4.21 indica as análises de regressão das saídas da rede em relação aos alvos para as etapas de treinamento, validação, testes e análise global dos dados. O modelo alcançou uma correlação de 86,898% entre as saídas do soft sensor e os alvos, o que indica uma correlação forte entre os dados.

Figura 4.21: Simulação com projeto de experimentos — análise de regressão dos dados de saída da rede e dos alvos.

Os gráficos ilustrados na Figura 4.22 indicam o comportamento entre as saídas do soft sensor e os alvos, o que confirma um avanço considerável no desempenho da rede comparada a simulação aprimorada do teste preliminar. O critério de desempenho global obtido para o modelo foi de 0,2246, considerando a aplicação do critério MSE.

Figura 4.22: Simulação com projeto de experimentos — Comportamento do modelo comparado aos alvos na etapa de treinamento.

O histograma do erro absoluto dos dados apresentado na Figura 4.22 como uma aproximação de uma distribuição normal com média de  $-0,02923$  pp e desvio padrão de  $12,27$  pp. Da mesma forma que a simulação preliminar, considerou-se a incerteza expandida de  $k_s = 24,54$  pp com fator  $k = 2$  pela distribuição de Student com nível de confiança de  $95,45\%$ . A concentração de erros relativos próximos de zero aumentou significativamente, houve uma redução da faixa de dispersão comparado aos resultados apresentados na simulação preliminar aprimorada e uma redução na frequência de casos particulares entre desvios extremos entre a eficiência real no processo e a eficiência energética estimada pelo modelo.

Figura 4.23: Simulação preliminar aprimorada — Histograma do erro absoluto entre o modelo e os alvos.

Houve uma melhoria na correlação dos dados de saída da rede e os alvos por inspeção visual do gás ao apresentando na Figura 4.21, comparado aos resultados da simulação preliminar aprimorada. A forte correlação denota uma capacidade de inferência e ciência energética com probabilidade de acerto de 86,898%. O coeficiente de correlação para a etapa de validação de 75,089% indica que o modelo possui uma capacidade de generalização com margem de melhorias no processo de aprendizagem.

#### 4.4. Resultados

A tabela 4.2 relaciona as características das etapas de processamento de dados e desenvolvimento do modelo para cada simulação planejada de forma comparativa.

Tabela 4.2: Resultados das simulações realizadas

	Característica / Propriedade do Modelo	Resultados		
		Simulação Preliminar	Simulação Aprimorada	Simulação com DOE
Tratamento de variáveis	Eliminação por inspeção	Sim	Sim	Sim
	Eliminação por seleção	Sim	Sim	Sim
	Aplicação de filtro nos dados	Sim	Sim	Sim
	Eliminação por colinearidade	Não	Sim	Sim

Tabela 4.2 continuação da página anterior

	Característica / Propriedade do Modelo	Resultados		
		Simulação Preliminar	Simulação Aprimorada	Simulação com DOE
Tratamento dos dados amostrados	Dados faltantes	Sim	Sim	Sim
	Filtragem - Acoplamento	Sim	Sim	Sim
	Filtragem - Ramais abertos	Não	Sim	Sim
	Outliers	Sim	Sim	Sim
	Filtragem - Amostragem	Sim	Sim	Sim
	Desvio nos dados	Não	Sim	Sim
Arquitetura do Modelo	Modelo	PMC	PMC	PMC
	Entradas	9	6	6
	Camadas ocultas	1	1	1
	Neuônios - Camada oculta	11	11	12
	Func. Ativação - Camada oculta	Tan. Hiperb.	Tan. Hiperb.	Tan. Hiperb.
	Func. Ativação - Sada	Linear	Linear	Linear
Dados de entrada do modelo	Normalização dos dados	Sim	Sim	Sim
	Aplicação de PCA	Não	Sim	Não
	Aplicação método bagging	Não	Sim	Não
	Aplicação de DOE	Não	Não	Sim
Treinamento, validação e testes	Algoritmo de treinamento	Levenberg-Marquadt	Levenberg-Marquadt	Levenberg-Marquadt
	Épocas de treinamento	6	4	6
	Critério de parada	Número de validações	Número de validações	Número de validações
	MSE validação	0,98445	0,60568	0,31054
	Gradiente	0,55583	0,068613	0,024974
	Mu	0,001	0,001	0,001
Resultados	Coef. correlação - Treinamento	0,57677	0,6155	0,95209
	Coef. correlação - Validação	0,4606	0,75717	0,70141
	Coef. correlação - Testes	0,1387	0,443	0,75089
	Coef. correlação - Global	0,45613	0,61715	0,86898
	MSE modelo	0,8159	0,7282	0,2246
Avaliação dos Erros	Erro relativo médio	1,852 pp	-0,01 pp	-0,03 pp
	Desvio padrão do erro relativo	24,21 pp	23,87 pp	12,27 pp
	Incerteza expandida do modelo	48,42 pp	47,74 pp	24,54 pp
	Dispersão mínima	-77,91 pp	-66,09 pp	-61,30 pp
	Dispersão máxima	112,61 pp	91,12 pp	39,54 pp



Dentre as simulações realizadas, o modelo gerado com análise de DOE se mostrou como uma solução adequada para o problema proposto, comparado aos demais modelos gerados, com capacidade de inflexibilidade e eficiência energética do circuito de moagem úmido da usina de beneficiamento de minério da Mina de Timbopeba com capacidade de produção de 86,898%, comparadas às análises laboratoriais de granulometria do produto e para a condição de carga circulante com 3 ramais abertos na bateria de ciclones com o moinho acoplado à operação (quebra de carga).

O modelo em questão possui uma incerteza expandida de 24,54 pp com nível de confiança de 95,45%, superior a incerteza absoluta de médias das análises laboratoriais de 1,54% realizadas na Mina de Timbopeba. Por a precisão da medição das análises laboratoriais é atribuída a informação de qualidade (distribuição granulométrica) para a venda do produto para o cliente. No caso da incerteza expandida do modelo de estudo comparado ao problema tratado neste trabalho, o erro é atribuído para a tomada de decisões quanto a possíveis ajustes operacionais no circuito da moagem em tempo real, sendo possível obter ganhos de eficiência no processo produtivo (o que ocorreria mínimo a cada 3 horas, considerando o cenário sem a implementação do softsensor).

## 5. Conclusão

Neste trabalho foi apresentado o desenvolvimento de um soft sensor para inferência de energia elétrica de moinhos de bolas em circuito fechado utilizado em moinhadoras com base em dados operacionais e laboratoriais coletados do processo de moagem existente nas instalações de beneficiamento de minério da Mina de Timbopeba - VALE SA. Foram abordados os principais conceitos de processos de moagem, desenvolvimento de soft sensor e RNAs, adotando-se uma rede PMC sem realimentação (feedforward) como motor do soft sensor

Para a realização das simulações, foi-se necessário realizar o pré-processamento dos dados antes de realizar as simulações para eliminação das variáveis de entrada candidatas bem como evitar a utilização de dados inválidos, faltantes, outliers e desvios dos dados, sejam eles relacionados ao processo ou aos instrumentos de medição

Partiu-se de uma simulação preliminar a fim de investigar a capacidade de obter alguma aprendizagem com base nos dados tratados e a capacidade de generalização do modelo inicial. Novas simulações foram realizadas com a incorporação de aprimoramentos no modelo proposto para se elevar a capacidade de aprendizagem e generalização de tal modo que fosse possível considerá-lo como um potencial solução para o problema tratado neste trabalho.

Com a realização de 2 novas simulações sequenciadas com base na simulação preliminar, foi possível obter um modelo como solução adequada para o problema proposto com capacidade de inferência da energia elétrica do circuito de moagem úmido da usina de beneficiamento de minério da Mina de Timbopeba com capacidade de produção de 86,898%, considerando 3 ramais abertos na bateria de ciclones do circuito. A aplicação de DOE na 3ª simulação se mostrou eficiente por planejar de forma sistemática um teste fatorial completo para a geração dos modelos candidatos pela variação de parâmetros de projeto (quantidade de neurônios e a função de ativação dos neurônios da camada oculta).

A etapa de eliminação de variáveis por presença de colinearidades a partir do aprimoramento da simulação preliminar foi capaz de reduzir a quantidade de entradas pela eliminação de variáveis correlacionadas que podem acometer em instabilidades no modelo de regressão

O tratamento de desvios de dados que representa uma variação dinâmica do processo foi importante para a evolução do rendimento do modelo entre as duas primeiras simulações. A presença de desvios capazes de afetar diretamente a dinâmica do modelo do soft sensor devido a variação na dinâmica do processo, seja por condições anormais identificadas ou por influências externas.

O método bagging se mostrou aplicável no processo de aprimoramento da simulação preliminar pela geração de diversos modelos conforme os conjuntos de dados de amostras gerados para o seu desenvolvimento. No entanto, todo o método gerou modelos com desempenho diversos, sendo o critério de votação adotado o modelo que mais se aproxima da média da população de modelos gerados com coeficiente de correlação global moderado, porém com

resultados melhores comparados aos resultados do modelo proposto não são eliminados.

A simulação de diversos modelos de forma sequenciada no aprimoramento da solução preliminar apresenta um elevado custo computacional nos processos de treinamento, validação e testes. No caso da simulação com DOE, a quantidade excessiva de modelos gerados não foi necessária, sendo gerado apenas 18 modelos planejados com base em experimentos pela variação de parâmetros conhecidos.

Por fim, durante o desenvolvimento deste trabalho, foram formuladas perguntas que auxiliaram no atendimento aos objetivos estabelecidos. As mesmas são respondidas a seguir.

1. Quais são as variáveis de processo e dados laboratoriais pertinentes para a eficiência da e ciência energética em um circuito fechado de moagem moído?

Resposta: As variáveis de entrada pertinentes para a eficiência da e ciência energética são representadas na Tabela 5.1.

Tabela 5.1: Variáveis de processo candidatas como entradas para o modelo do sensor

Tag	Descrição	Unidade
TO_FY4305.03	Percentual calculado de carga circulante do circuito da moagem	%
TO_II4303.01	Corrente do motor principal do moinho	A
TO_JI4303.01	Potência do moinho	kW
TO_VI4303.01	Vibração do pédio da moagem	mg
TO_DI4305.01	Densidade de polpa bombeada para alimentação da bateria de ciclones	t/m <sup>3</sup>
TO_FI4305.01	Vazão de polpa bombeada para alimentação da bateria de ciclones	m <sup>3</sup> /h

A utilização das variáveis de estado de acoplamento do moinho em operação (TO-SNMO430308.EST1'), a quantidade ramais abertos na bateria de ciclones (NUM-CICLONES') e o alvo do modelo (Eficiência energética - EF) foram pertinentes para o fito dos dados na etapa de processamento dos dados.

2. Quais são os critérios adequados para avaliação de pertinência das variáveis pertencentes a base de dados coletada para o projeto do sensor?

Resposta: A base levantada na revisão bibliográfica como embasamento teórico, a inspeção dos dados para identificação de tags congelados ou que se remetem a equipamentos ou instrumentos desativados em campo, a consulta do especialista responsável pela operação do circuito de moagem são os principais critérios adequados para a seleção

variáveis como potenciais candidatas ao modelo gerado. Além disso, podemos citar a eliminação de variáveis que foram utilizadas como Itros da base de dados e pela presença de colinearidades entre os dados.

3. Quais são os parâmetros e métricas a serem adotados para validação inferencial, uma vez que não é possível obter a medição direta da eficiência energética do circuito de moagem objeto desta investigação científica?

Resposta: Com base na revisão bibliográfica, não existem métricas estabelecidas como regras gerais para que se determine se um modelo é capaz de aprender ou não um determinado problema de regressão ou de classificação. As métricas são estabelecidas com base na acuracidade necessária para o problema em análise. Todavia, os parâmetros a seguir foram levados em consideração na validação da inferência dos modelos gerados nas simulações realizadas neste trabalho:

- O coeficiente de regressão global do modelo com base nos alvos de medição utilizados nas fases de treinamento, validação e testes dos modelos gerados (eficiência energética medida com base nas análises granulométricas em ensaios laboratoriais realizadas normalmente de 3 em 3 horas) para avaliar a capacidade de aprendizagem do modelo.
- O coeficiente de regressão da etapa de validação para avaliação da capacidade de generalização do modelo no processo de aprendizagem;
- A incerteza expandida com base no histograma do erro absoluto entre as saídas do modelo e os respectivos alvos;

Os parâmetros medidos com base no modelo gerado e proposto como solução para o problema deverão ser avaliados e cancelados pelo especialista responsável pela operação do circuito de moagem. Para este trabalho, o modelo gerado como solução estimativa da inferência da eficiência energética com capacidade de predição de 86,898%, capacidade de generalização de 75,089% e incerteza expandida de 24,54 ppé capaz de promover ganhos no processo da moagem por permitir tomadas de decisão a possíveis ajustes operacionais no circuito da moagem em tempo real, comparado ao cenário atual do processo onde as tomadas de decisão são feitas com um tempo de espera de aproximadamente 3 horas devido a periodicidade dos registros dos ensaios laboratoriais de análise granulométrica do circuito da moagem.

4. Os benefícios esperados são capazes de serem satisfeitos com a inferência da eficiência energética no circuito fechado de moagem simulado?

Resposta: Os benefícios a seguir poderão ser satisfeitos com base na capacidade de predição de 86,898% do modelo gerado e de modo como solução para o problema tratado neste trabalho:

- Tomada de decisão mais coerente quanto a reposição de corpos moedores no moinho;
- Redução de desvios entre as granulometrias efetiva e especificada para o processo;
- Redução da exposição de operadores de campo para realização do processo de reposição manual;
- Possibilidade de implementação de lógica de programação em CLP para reposição automática de corpos moedores em batelada ou de forma contínua;
- Possibilidade de implementação de controlador que seja capaz de adequar a granulometria do produto final da etapa de moagem;
- Potencial de redução do consumo total de energia da Mina de Timbopeba de 0,38%, acarretando em uma redução de custo anual de R\$ 70.492,17;
- Potencial de redução de emissão de dióxido de carbono (CO<sub>2</sub>) anual de 53,41 tCO<sub>2</sub>;
- Custo evitado de R\$ 839.698,90 (custo estimado de aquisição de um PSM).

Este trabalho deixa como contribuição para o meio acadêmico e industrial uma solução potencial para ineficiência energética em moinho de bolas em circuito fechado úmido sem a necessidade de um PSM instalado no circuito, podendo ser desenvolvido e replicado para o ambiente industrial, tratando-se das particularidades do processo, a fim de aprimorar a granulometria adequada às especificações de mercado.

Por se tratar de uma inovação comparada às soluções identificadas e apresentadas no contexto deste trabalho, pode-se destacar como contribuição deste trabalho o pedido de depósito de patente BR 10 2020 014057 em nome da VALE SA e a Universidade Federal de Ouro Preto (UFOP) realizado em 09/07/2020 para requerimento de direitos de propriedade intelectual quanto a invenção em questão.

Como sugestões para trabalhos futuros, novas simulações podem ser realizadas, considerando a variação na quantidade de ramais abertos na bateria de ciclones e a abordagem de novas estratégias com o intuito de aprimorar os resultados, visando a implementação de um ambiente de produção para verificação e validação das contribuições previstas.

## Referências Bibliográficas

- AGUIRRE, L. A. Introdução a identificação de sistemas - técnicas lineares e não-lineares aplicadas a sistemas reais. N. 3. Belo Horizonte, UFMG, 2007.
- ALCALÁ, S. G. S. Ensemble Learning Methodologies for Soft Sensor Development in Industrial Processes Coimbra, PhD Thesis, 2015. Disponível em: < <http://hdl.handle.net/10316/28313> > .
- ANDRIOTTI, J. L. S. Técnicas estatísticas aplicáveis a tratamento de informações oriundas de procedimentos laboratoriais Porto Alegre, CPRM, 2005. Disponível em: < <http://rigeo.cprm.gov.br/jspui/handle/doc/451> > .
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR11736 - Moinho de bolas - Determinação do índice de trabalho Rio de Janeiro, 1990.
- ATKINSON, A. C., DONEV, A. N. Optimum Experimental Designs Berlin, Heidelberg, Springer, 2011. p. 148.
- BAI, G., YAN, F., HE, M., et al.. Soft Sensor of Wet Ball Mill Load Based on DAM-KELM Model N. 30. Shenyang, China, IEEE, 2018. Disponível em: < <https://ieeexplore.ieee.org/document/8407291> > . p. 1087–1092.
- BERALDO, J. L. Moagem de Miários em Moinhos Tubulares N. 1. São Paulo, Editora Edgard Bücher Ltda, 1987. 143 p.
- BOWDEN, G. D., PICHLER, B. J., MAURER, A. A Design of Experiments (DoE) Approach Accelerates the Optimization of Copper-Mediated 2019.
- BRAGA, A. D. P., CARVALHO, A. P. D. L. F. D., LUDERMIR, T. B. Redes Neurais Artificiais. Teorias e Aplicações N. 2. Rio de Janeiro, LTC, 2016. 226 p.
- BUI, N., CASTELLANI, A. P., CASARI, P., et al.. The Internet of energy: A Web-enabled smart grid system, v. 26. IEEE Netw., 2012. p. 39–45.
- BÜHLMANN, P. Bagging, Boosting and Ensemble Methods 2012. p. 2-3.

- CARLI, F. D., MEJIA, R. I. G., ARAÚJO, G. A. T. D. *Advanced analytics applied to problem solving technique on a pulp mill*. N. 49. Latin American Applied Research, 2019. p. 175-180.
- CASALI, A., GONZALEZ, G., TORRES, F., et al.. *Particle size distribution soft-sensor for a grinding circuit*, v. 99. Powder Technology, 1998. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0032591098000849>>. p. 15-21.
- CHAVES, A. P., PERES, A. E. C. *Teoria e prática do Tratamento de Minérios: Britagem, Peneiramento e Moagem*. N. 5. São Paulo, Oficina de Textos, 2012. p. 198–322.
- CHOWDHURY, A. K., TJONDRONEGORO, D., CHANDRAN, V., et al.. *Ensemble methods for classification of physical activities from wrist accelerometry*, v. 49(9). Medicine & Science in Sports & Exercise, 2017. p. 1965-1973.
- DAWSON, R. *How Significant is a Boxplot Outlier?*, v. 19. Journal of Statistics Education, 2011. doi: 10.1080/10691898.2011.11889610.
- DEMUTH, H. B., BEALE, B. H., HAGAN, M. T. *Neural Network Toolbox, User's Guide*. N. 6. The MathWorks Inc., 2009.
- DONDA, J. D. *Teoria geral da cominuição*. N. 1. Belo Horizonte, CVRD, 2018.
- ELDIN, A. B. *General Introduction to Design of Experiments (DOE)*. N. 2. IntechOpen, 2011. p. 21.
- FERNÁNDEZ, R., VIENNET, E., GOLES, E., et al.. *Online coarse ore granulometric analyzer using neural networks*. Paris, França, Proceedings ICANN'95, 1995. Disponível em: <<https://www.researchgate.net/publication/2592211>>.
- FREITAS, G. G., KELIN, M. D. S., RUSCHID, J. J. *Process for iron ore pellets production*. Titular: Companhia Vale do Rio Doce, Minas Gerais, Brazil n. US5908166. Depósito: 15 out. 1997. Concessão: 1 jun. 1999, United States Patent, 1997.
- GARCIA, A. D. *Reforma e adequação de um moinho de 4.000 HP para nova aplicação*. São Paulo, Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo, 2000.
- GRANATO, D., OLIVEIRA, C. C. D., KIST, A. *Análise estatística descritiva aplicada à ciência e tecnologia de alimentos usando programas estatísticos*. N. 1. São Paulo, IAL, 2018.

- HANNAN, M. A., FAISAL, M., KER, P. J., et al.. *A Review of Internet of Energy Based Building Energy Management Systems: Issues and Recommendations*, v. 6. IEEE, 2018. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8403212>>. p. 38997-39014.
- HAYKIN, S. *Neural Networks and Learning Machines*. N. 3. New Jersey, Prentice Hall, 2009. 906 p.
- ISO GUM. *Avaliação de dados de medição — Guia para a expressão de incerteza de medição*. N. 1ª edição brasileira. 2008.
- KADLEC, P., GABRYS, B., STRANDT, S. *Data-driven Soft Sensors in the process industry*. N. 33. *Computers and Chemical Engineering*, 2009. Disponível em: <[www.elsevier.com/locate/compchemeng](http://www.elsevier.com/locate/compchemeng)>. p. 795–814.
- KELLY, E. G., SPOTTISWOOD, D. J. *Introduction to mineral processing*. New York, John Wiley Sons, 1982. cap. 8 e 10.
- LIPTÁK, B. G., VENCZEL, K. *Measurement and Safety*, v. I. New York, CRC Press, 2017.
- LOTUFO, F. A., GARCIA, C. *Sensores Virtuais ou Soft Sensors: Uma Introdução*. FCT - Unesp - Presidente Prudente, SP, Brazil, 7ª Brazilian Conference on Dynamics, Control and Applications, 2008. Disponível em: <<https://www.researchgate.net/publication/228413086>>.
- LUZ, A. B., SAMPAIO, J. A., FRANÇA, S. C. A. *Tratamento de Minérios*. N. 5. Rio de Janeiro, CETEM/MCT, 2010. Capítulo 4. p. 143–210.
- MURRAY, P. M., TYLER, S. N. G., MOSELEY, J. D. *Beyond the numbers: Charting chemical reaction space*. N. 17. 2013. p. 40–46.
- NIETO, L., OLIVARES, J., GATICA, J., et al.. *A virtual sensor for estimating particle size of hydrocyclones overflow*. Viña del Mar, Chile, IFACMMM, 2009. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1474667016325885>>. p. 14-16.
- NUNES, A. D. L. *Modelagem e simulação do circuito de moagem da Votorantim Metais Zinco Morro Agudo*. São Paulo, Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo, 2012.
- OLIVIER, L. E., MARITZ, M. G., CRAIG, I. K. *Deep convolutional neural network for mill feed size characterization*. Belfast, Northern Ireland, International Federation of Automatic Control, 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896319308043>>.



- REIS, A. J. R., SILVA, A. P. A. *Feature Extraction via Multiresolution Analysis for Short-Term Load Forecasting*, v. 20. IEEE Transactions on Power Systems, 2005. p. 189-198.
- ROWLAND, C. A., KJOS, D. M. *Rod and ball mills. Mineral processing plant design*. New York, SME, 1969. cap. 12. p. 239-278.
- SBARBARO, D., ASCENCIO, P., ESPINOZA, P., et al.. *Adaptive soft-sensors for on-line particle size estimation in wet grinding circuits*, v. 16. Control Engineering Practice, 2008. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0967066107000299>>. p. 171-178.
- SHAO, W. M., TIAN, X. M., WANG, P. *Supervised local and non-local structure preserving projections with application to just-in-time learning for adaptive soft sensor*. N. 23. China, *Chinese Journal of Chemical Engineering*, 2015. p. 1925–1934.
- SILVA, I. N., SPATTI, D. H., FLAUZINO, R. A. *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: Curso Prático*. N. 1. São Paulo, São Paulo, 2010. 399 p.
- SOUZA, F. A. A., ARAÚJO, R., MENDESA, J. *Review of Soft Sensors Methods for Regression Applications*, v. 152. Chemometrics and Intelligent Laboratory Systems, 2016. doi: 10.1016/j.chemolab.2015.12.011. p. 69-79.
- TANG, J., YU, W., ZHAO, L., et al.. *Modeling of Operating Parameters for Wet Ball Mill by Modified GA-KPLS*. Suzhou, Jiangsu, China, IEEE, 2010. Disponível em: <<https://ieeexplore.ieee.org/document/5585151>>. p. 282–287.
- WEI, J., GUO, L., XU, X., et al.. *Soft Sensor Modeling of Mill Level Based on Convolutional Neural Network*. Qingdao, China, IEEE, 2016. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/7162762>>. p. 4738–4742.
- WILLS, B. A., NAPIER-MUNN, T. J. *Will's Mineral Processing Technology - An Introduction to the Practical Aspects of Ore Treatment and Mineral Recovery*. N. 7. Elsevier Science Technology Books, 2006.
- XIE, W., WANG, J. S., XING, C., et al.. *Extreme Learning Machine Soft-Sensor Model With Different Activation Functions on Grinding Process Optimized by Improved Black Hole Algorithm*, v. 8. IEEE Netw., 2020a. doi: 10.1109/ACCESS.2020.2970429. p. 25084-25110.
- XIE, W., WANG, J. S., XING, C., et al.. *Adaptive Hybrid Soft-Sensor Model of Grinding Process Based on Regularized Extreme Learning Machine and Least Squares Support Vector Machine Optimized by Golden Sine Harris Hawk Optimization Algorithm*. Complexity, 2020b. doi: 10.1155/2020/6457517.

- YUCE, B., REZGUI, Y. *An ANN-GA Semantic Rule-Based System to Reduce the Gap Between Predicted and Actual Energy Consumption in Buildings*, v. 14. IEEE Transactions on Automation Science and Engineering, 2015. p. 1351-1363.
- ZHAO, L., YANG, J., YU, W., et al.. *Modelling of Mill Load for Wet Ball Mill via GA and SVM Based on Spectral Feature*. Changsha, China, 2010 IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA), 2010. Disponível em: <<https://ieeexplore.ieee.org/document/5645241>>. p. 874–879.

