

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS UNIDADE ARAXÁ

OTÁVIO DOS SANTOS AMARAL

DESENVOLVIMENTO DE SENSOR VIRTUAL BASEADO EM REDES NEURAIS
ARTIFICIAIS APLICADO NA ESTIMAÇÃO DA CONCENTRAÇÃO DE APATITA
POR FLOTAÇÃO

ARAXÁ/MG

OTÁVIO DOS SANTOS AMARAL

DESENVOLVIMENTO DE SENSOR VIRTUAL BASEADO EM REDES NEURAIS
ARTIFICIAIS APLICADO NA ESTIMAÇÃO DA CONCENTRAÇÃO DE APATITA
POR FLOTAÇÃO

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Automação Industrial, do Centro Federal de Educação Tecnológica de Minas Gerais - CEFET/MG, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Automação Industrial.

Orientador: Prof. Leandro Resende Mattioli

Coorientador: Prof. Leandro Henrique Santos



MINISTÉRIO DA EDUCAÇÃO CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS DEPARTAMENTO DE ELETROMECÂNICA - AX



ATA N° 87 / 2023 - DELMAX (11.57.05)

Nº do Protocolo: 23062.060507/2023-98

Araxá-MG, 08 de dezembro de 2023.

Ata de Defesa do Trabalho de Conclusão de Curso de Engenharia de Automação Industrial do Aluno Otávio dos Santos Amaral

Às quatorze horas do dia sete de dezembro de dois mil e vinte e três, reuniu-se, no Centro Federal de Educação Tecnológica de Minas Gerais - CEFET-MG/ Campus Araxá, a Comissão Examinadora de Trabalho de Conclusão de Curso para julgar, em exame final, o trabalho intitulado DESENVOLVIMENTO DE SENSOR VIRTUAL BASEADO EM REDES NEURAIS ARTIFICIAIS APLICADO À CONCENTRAÇÃO DE MINÉRIOS FOSFÁTICOS POR FLOTAÇÃO, como requisito parcial para a obtenção do grau de Bacharel em Engenharia de Automação Industrial. Abrindo a sessão, o Presidente da Comissão, Prof. Dr. Leandro Resende Mattioli, após dar a conhecer aos presentes o teor das Normas Regulamentares do Trabalho Final, concedeu a palavra ao candidato, Otávio dos Santos Amaral, para a exposição de seu trabalho. Após a apresentação, seguiu-se a arguição pelos examinadores, com a respectiva defesa do candidato. Ultimada a arguição, a Comissão se reuniu, sem a presença do candidato e do público, para julgamento e expedição do resultado final. Após a reunião da Comissão Examinadora, o candidato foi considerado: APROVADO, obtendo nota final de: 97/100 (noventa e sete). O resultado final foi comunicado publicamente ao candidato pelo Presidente da Comissão. O aluno, abaixo assinado, declara que o trabalho ora identificado é da sua autoria material e intelectual, excetuando-se eventuais elementos, tais como passagens de texto, citações, figuras e datas, desde que devidamente identificada a fonte original. Declara ainda, neste âmbito, não violar direitos de terceiros. Nada mais havendo a tratar, o Presidente encerrou os trabalhos. O Prof. Leandro Resende Mattioli, responsável pela disciplina "Trabalho de Conclusão de Curso II", lavrou a presente ATA, que, após lida e aprovada, será assinada por todos os membros participantes da Comissão Examinadora e pelo candidato.

Araxá, 07 de dezembro de 2023.

Assinado eletronicamente por:

- Presidente e Orientador: Prof. Dr. Leandro Resende Mattioli
- Coorientador: Prof. Dr. Leandro Henrique Santos
- Membro Titular: Prof. Dr. Fábio de São José
- Membro Titular: Prof. Me. Willian Martins Leão
- Professor da Disciplina TCC 2: Prof. Dr. Leandro Resende Mattioli
- Aluno: Otávio dos Santos Amaral

(Assinado digitalmente em 11/12/2023 20:33)
LEANDRO RESENDE MATTIOLI
PROFESSOR ENS BASICO TECN TECNOLOGICO
DELMAX (11.57.05)
Matricula: 2973183

(Assinado digitalmente em 09/12/2023 23:29)
WILLIAN MARTINS LEAO
PROFESSOR ENS BASICO TECN TECNOLOGICO
DELMAX (11.57.05)
Matrícula: 1291584

(Assinado digitalmente em 11/12/2023 10:44)
OTÁVIO DOS SANTOS AMARAL
DISCENTE
Matrícula: 20193004118

Visualize o documento original em https://sig.cefetmg.br/public/documentos/index.jsp informando seu número: 87, ano: 2023, tipo: ATA, data de emissão: 08/12/2023 e o código de verificação: fe793f826b

À minha mãe, sua presença é a luz que ilumina cada passo do meu caminho. Seu amor incondicional e apoio constante são os alicerces sobre os quais construí este trabalho. Obrigado por ser meu porto seguro, minha fonte de inspiração e minha maior incentivadora. Ao meu pai (in memoriam), este trabalho é dedicado a você, cuja presença é eternamente sentida em cada conquista, mesmo que a saudade seja a sombra que acompanha meus passos. Seu apoio incansável e sabedoria permanecem como a bússola que me guia.

Agradecimentos

Primeiramente, quero expressar minha profunda gratidão a Deus, cuja orientação e força me sustentaram ao longo desta jornada. Sem sua graça, nada disso seria possível.

Meus pais, minha gratidão por todo o amor, apoio e sacrifício que vocês dedicaram a mim. Vocês sempre foram minha fonte de inspiração, e este sucesso é tão de vocês quanto é meu. Ao meu orientador e meu coorientador, minha gratidão é imensa. Suas orientações, conselhos e paciência foram cruciais para o desenvolvimento deste trabalho.

Aos meus amigos, expresso profunda gratidão por estarem ao meu lado, apoiando-me nos momentos difíceis e celebrando comigo nas horas de alegria. Especialmente, agradeço ao Alderico por elevar minha autoestima e fazer com que eu me sinta mais capaz quando estou ao seu lado. Sua sensatez acrescenta uma perspectiva valiosa à nossa relação. Gabriel, cuja notável habilidade em representar uma fachada amigável me ensinou a valorizar conexões autênticas. Lucas por compartilhar perspectivas distintas, sua abordagem singular enriquece notavelmente as conversas. Sua capacidade de me deixar mais alegre tornou cada desafio mais leve. Maria Paula por sempre expressar sua opinião de maneira direta, o que me faz refletir sobre a importância da comunicação sincera. Além disso, agradeço pela sua lealdade, que é um alicerce valioso em nossa amizade. Rafael por me lembrar da importância de valorizar a si mesmo. Sua amizade é um presente que enriquece minha vida, e suas palavras têm sido um lembrete constante de que o auto apreço é fundamental. Cássia pela sua incrível habilidade de me manter informado, demonstrando um cuidado singular em manter conexões. Além disso, sou grato por seu constante apoio e sua capacidade de me fazer sentir melhor em qualquer situação. E agradeço à Letícia por suas ações que me lembraram da importância da paciência e independência. Além de acrescentar uma trilha sonora especial à minha vida.

Agradeço aos professores Leandro Mattioli, Henrique e Willian por inspirarem meu crescimento acadêmico e pessoal.

Se você for tentar, tente de verdade. Caso contrário nem comece. Isso pode significar perder tudo. [...] Se você for tentar, tente de verdade. Não há outro sentimento melhor que isso.

Charles Bukowski

Resumo

As indústrias de mineração enfrentam desafios ao tentar medir algumas variáveis de maneira confiável, eficiente e econômica em seus processos. A flotação desempenha um papel crucial nesse setor e apresenta considerável complexidade ao determinar a concentração de minerais na polpa do minério, dado que requer análises laboratoriais que consomem tempo, que exigem a presença de profissionais qualificados, encarecendo significativamente o processo. Este estudo propõe o desenvolvimento de um sensor virtual por meio do uso de redes neurais, visando aprimorar a análise do processo de flotação. Foram exploradas redes Perceptron de múltiplas camadas e redes de função de base radial, empregando dados como concentração de coletor, pH, tempo, proporção de Palmitato e proporção de Oleato. O modelo resultante do sensor virtual foi validado com êxito, apresentando um erro máximo de 5,40%, erro médio quadrático de aproximadamente 0,05%, erro médio absoluto de 1,69% e um coeficiente de determinação de 0,99. Esses resultados confirmam a eficácia dos algoritmos de inteligência artificial na inferência da flotabilidade da apatita, indicando uma abertura promissora para estudos futuros. A introdução de um sensor virtual baseado em redes neurais oferece uma alternativa eficiente, rápida e economicamente viável para monitorar e otimizar os processos de flotação na indústria de mineração.

Palavras Chave: Sensores virtuais. Redes neurais artificiais. Inteligência artificial. Flotação. Apatita.

Abstract

Mining industries face challenges in reliably, efficiently, and economically measuring certain variables in their processes. Flotation plays a crucial role in this sector and poses considerable complexity when determining mineral concentration in ore pulp, as it requires time-consuming laboratory analyses that demand the presence of qualified professionals, significantly increasing the overall process cost. This study proposes the development of a virtual sensor through the use of neural networks to enhance the analysis of the flotation process. Multiple-layer perceptron networks and radial basis function networks were explored, utilizing data such as collector concentration, pH, time, Palmitate ratio, and Oleate ratio. The resulting virtual sensor model was successfully validated, presenting a maximum error of 5.40%, a mean squared error of approximately 0.05%, a mean absolute error of 1.69%, and a determination coefficient of 0.99. These results confirm the efficacy of artificial intelligence algorithms in inferring the floatability of apatite, indicating a promising avenue for future studies. The introduction of a neural network-based virtual sensor offers an efficient, fast, and economically viable alternative for monitoring and optimizing flotation processes in the mining industry.

Keywords: Virtual sensors. Artificial neural networks. Artificial intelligence. Flotation. Apatite.

Lista de Figuras

2.1	Princípio de funcionamento dos sensores	20
2.2	Exemplificação dos conceitos de exatidão e precisão	20
2.3	Estrutura e funcionamento de um sensor virtual	21
2.4	Exemplo de modelagem caixa preta	23
2.5	Neurônio artificial	23
2.6	Rede neural artificial	24
2.7	Função de ativação degrau	26
2.8	Função de ativação degrau bipolar	27
2.9	Função de ativação rampa simétrica	28
2.10	Função de ativação logística	28
2.11	Função de ativação tangente hiperbólica	29
2.12	Função de ativação gaussiana	29
2.13	Função de ativação linear	30
2.14	Exemplo de rede feedforward de camada única	31
2.15	Exemplo de rede feedforward de múltiplas camadas	31
2.16	Exemplo de rede recorrente	32
2.17	Rede PMC aplicada em aproximação funcional	33
2.18	Exemplos de regiões convexas para o problema de classificação de padrões . .	33
2.19	Amostras de treinamento da PMC referente a um problema de aproximação	
	funcional	34
2.20	Superposição de funções logística para um problema de aproximação funcional	34
2.21	Rede RBF aplicada em aproximação funcional	35
2.22	Função de base radial do tipo gaussiana	36
2.23	Fronteira de separabilidade do PMC e RBF	36
2.24	Amostras de treinamento da RBF referente a um problema de aproximação	
	funcional	36

2.25	Superposição de funções gaussianas para um problema de aproximação funcional	37
2.26	Estrutura de uma rede neural de Jordan	38
2.27	Comparativo entre os tipos de treinamento	39
2.28	Método de validação cruzada por amostragem aleatória	42
2.29	Método de validação cruzada usando k-partições	42
2.30	Apatita	43
2.31	Princípio da flotação de espuma	44
2.32	Representação da flotação direta	45
2.33	Representação da flotação reversa	45
2.34	Contato bolha de ar/superfície do mineral em um sistema com e sem coletor. .	47
2.35	Um tubo Hallimond típico usado para microflotação	48
4.1	Boxplot da flotabilidade com outliers	58
4.2	Boxplot da flotabilidade sem outliers	58
4.3	Histograma da flotabilidade	59
4.4	Desempenhos dos algoritmos de treinamento da PMC	60
4.5	Histograma da flotabilidade para cada subconjunto	63
4.6	Gráfico da dispersão da rede PMC	64
4.7	Gráfico da dispersão da rede RBF	64
4.8	Resposta do sensor virtual para diferentes amostras	65
4.9	Guia de inferência única da aplicação	66
4.10	Guia de inferência múltipla da aplicação	67
4.11	Guia de edição do modelo	68

Lista de Tabelas

4.1	Matriz de correlação cruzada	57
4.2	Resultados dos testes das RBFs	61
4.3	Resultados dos testes das PMCs	62
4.4	Desempenho do sensor virtual	65

Lista de Siglas e Abreviaturas

ADAM Estimativa de momento adaptativo

IA Inteligência Artificial

LBFGS Algoritmo de Broyden-Fletcher-Goldfarb-Shanno com memória limitada

MAE Erro absoluto médio

MAPE Erro percentual absoluto

MISO Múltiplas entradas e única saída

MSE Erro quadrático médio

PMC Perceptron multicamadas

R² Coeficiente de determinação

RBF Redes de funções de base radial

RMSE Raiz quadrada do erro quadrático médio

RNAs Redes Neurais Artificiais

SGD Método do gradiente estocástico

Sumário

1	Introdução			
	1.1	Objeti	vos	18
2	Rev	isão Bi	bliográfica	19
	2.1	Instrui	mentação	19
		2.1.1	Sensores virtuais	21
	2.2	Identif	ncação de sistemas	22
	2.3	Redes neurais artificiais		
		2.3.1	Potenciais áreas de aplicação	25
		2.3.2	Função de ativação	26
		2.3.3	Arquiteturas	30
		2.3.4	Rede Perceptron	32
		2.3.5	Redes de funções de base radial	35
		2.3.6	Redes de Jordan	37
		2.3.7	Processos de treinamento	38
	2.4	Benefi	ciamento de Minério Fosfático	42
		2.4.1	Flotação	44
		2.4.2	Microflotação	47
		2.4.3	Análise de processos químicos	48
		2.4.4	Sensores virtuais na mineração	50
3	Met	odolog	ia	5 2
	3.1	Aquisi	ção e tratamento dos dados	52
	3.2	Impler	nentação de diferentes topologias de redes neurais artificiais	53
	3.3	Execu	ção de algoritmos de treinamento supervisionado nas redes desenvolvidas	54
	3.4	Valida	ção dos treinamentos	54
	3.5	Avalia	ção das redes e definição da topologia mais adequada	54

	3.6	Implementação do sensor virtual para inferência em tempo real	55	
	3.7	Análise dos resultados	55	
4	Res	esultados		
	4.1	Tratamento dos dados	56	
	4.2	Implementação de diferentes topologias de redes neurais artificiais	59	
	4.3	Algoritmos de treinamento	60	
	4.4	Avaliação das redes e definição da topologia mais adequada	60	
	4.5	Implementação do sensor virtual	65	
_	C		60	
5	Considerações finais 69			

Capítulo 1

Introdução

No contexto industrial, as crescentes exigências de produtividade impõem um grande padrão de qualidade com o menor tempo de produção possível, exigindo medidas rápidas e precisas das grandezas dos processos, realizadas geralmente com técnicas e equipamentos de instrumentação.

No entanto, apesar do grande número de sensores presentes no mercado, alguns processos requerem dados muito específicos ou estão sob circunstâncias que impedem a instalação de um dispositivo físico, como por exemplo locais com alta temperatura ou pressão. Para os casos em que os equipamentos convencionais não são viáveis ou que não é desejável interromper o processo, pode-se estimar as informações necessárias, a partir de outras grandezas conhecidas, por meio de métodos computacionais. Tais procedimentos são chamados de sensores virtuais (KE et al., 2017).

Dentre as técnicas conhecidas para o desenvolvimento de sensores virtuais, as Redes Neurais Artificiais (RNAs) se destacam por conseguir estabelecer associações entre os valores de entrada e saída, mesmo quando não se tem um modelo analítico da relação entre estas propriedades. Normalmente as empresas já possuem uma base de dados sólida, muitas vezes mal utilizada, mas com informações úteis, o que facilita o treinamento e o uso destes algoritmos.

Além disso, uma pesquisa de mercado encomendada pela IBM (2022) constatou que a adoção global da Inteligência Artificial (IA) está em constante crescimento. No Brasil, especificamente, 41% das empresas relataram implementar ativamente essa tecnologia. Esses resultados destacam que a IA está se tornando mais acessível e fácil de ser implementada.

Com o objetivo de implementar tecnologias capazes de superar essas barreiras que

desafiam o controle e a qualidade da produção, algumas áreas têm voltado seus olhares para os sensores virtuais. Nesse sentido, destacam-se as áreas de Engenharia Bioquímica (LIU; ZHU; ZHU, 2018), Usinas Sucroenergéticas (SANTOS LIMA; MAURICIO VILLANUEVA; CAVALCANTI CATUNDA, 2022), Tratamento de Água (HUANG; MENG; GUO, 2022; ZHANG; YANG; QIAO, 2021), Monitoramento de Gás (MARINKOVIĆ et al., 2016), entre outras. Todas estas pesquisas mostram que a indústria pode obter grandes benefícios utilizando estas técnicas de inferências.

Outro ramo que merece atenção é a Engenharia de Minas, pois possui grande destaque no Brasil, principalmente no estado de Minas Gerais. Assim como todos os setores fortemente ligados à indústria química, também apresentam dificuldades em obter medidas importantes para o processo, em tempo real e com precisão satisfatória. O tempo gasto com análises laboratoriais e/ou o uso de técnicas que não fornecem valores adequados, prejudicam a produção e consequentemente a economia e o desenvolvimento do setor no país. Nesse contexto, Montanares et al. (2021) conduziram uma pesquisa abordando o problema da estimativa de concentração de sílica na flotação por espuma de minério de ferro, fazendo uso de técnicas de aprendizado de máquina. Eles conseguiram obter resultados com desempenho satisfatório, com erros inferiores a 9%. Essas abordagens de dedução também podem ser aplicadas em processos de moagem, como demonstrado por Guo et al. (2019). Em seu estudo, eles concentraram seus esforços na medição da carga de moinho de bolas e apresentaram várias estratégias que resultaram em ótimos desempenhos.

Segundo dados da Associação Nacional para Difusão de Adubos, em 2022, a quantidade de fertilizantes entregues ao mercado totalizou 41.077.519 toneladas (ANDA, 2023). Estes produtos possuem grandes impactos nas competitividades do agronegócio brasileiro, o que influencia na balança comercial brasileira e no PIB, por serem muito sensíveis ao desempenho das *commodities* agrícolas.

Com o propósito de produzir fertilizantes à base de concentrado fosfático, faz-se necessário o beneficiamento dos minérios fosfáticos com ganga silicatada e carbonatada. Contudo, para alcançar o produto final, é essencial separar o mineral de seus contaminantes, como a calcita, magnetita, mica e outros, através do método de flotação. Porém, medir a concentração de apatita não é uma tarefa simples, já que os dispositivos disponíveis no mercado para essa finalidade exigem uma série de ensaios, o que torna o tratamento dos dados mais difícil.

Se as RNAs mostrarem ser um recurso viável, capaz de estimar a flotabilidade da apatita com base em dados de entrada, como a granulometria e o pH da polpa, então será possível reduzir o tempo e recursos gastos com análises laboratoriais sem que seja necessário grandes investimentos.

Sendo assim, a mineração pode usufruir das vantagens que um sensor virtual baseado em redes neurais artificiais pode oferecer, aprimorando o controle de qualidade e a eficiência desse processo e trazendo benefícios econômicos e ambientais para a indústria.

1.1 Objetivos

O objetivo primário do trabalho é auxiliar a análise no processo de flotação de minérios fosfáticos, fornecendo valores em tempo real da flotabilidade da apatita, através de um sensor virtual. Também são objetivos do projeto:

- Realizar o tratamento de dados em uma base histórica, relacionados a flotação de minérios fosfáticos;
- Investigar variáveis que se relacionam com a concentração da apatita;
- Conceber uma rede neural capaz de relacionar as variáveis de entrada para determinar a concentração de flotado.

Capítulo 2

Revisão Bibliográfica

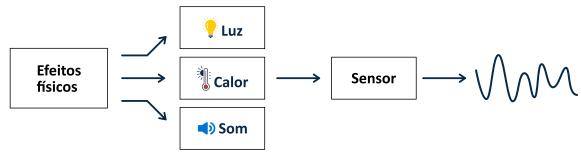
A revisão bibliográfica é importante para a compreensão das tecnologias envolvidas, bem como para o desenvolvimento de novas aplicações. Este capítulo apresenta uma análise crítica das pesquisas e estudos já realizados, buscando identificar as principais tendências, desafios e oportunidades de pesquisa nessa área.

2.1 Instrumentação

Para Singh (2010), o objetivo fundamental da instrumentação em um processo é obter as informações relevantes para o seu funcionamento. A instrumentação é justificada pela necessidade de se exercer controle sobre processos e operações industriais. Para que seja possível exercer controle sobre uma determinada condição, é imprescindível ser capaz de medi-la ou detectá-la.

Segundo Balbinot e Brusamarello (2010), a instrumentação é de suma importância, pois a medição é a base do processo experimental. Seja em um processo controlado ou na linha de produção de uma indústria, a medição de grandezas físicas é crucial em todas essas áreas. Os dispositivos responsáveis por efetuar estas ações são chamados de sensores, pois são sensíveis aos efeitos físicos do ambiente e capazes de gerar sinais de saída relacionados às informações desejadas (THOMAZINI; ALBUQUERQUE, 2009), como mostrado na Figura 2.1.

Figura 2.1: Princípio de funcionamento dos sensores



Fonte: Adaptado de Thomazini e Albuquerque (2009)

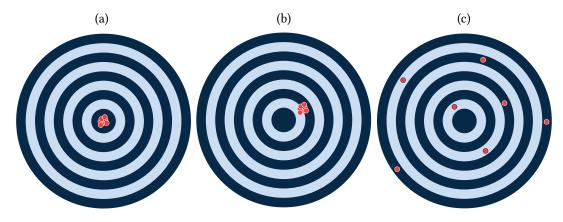
Para Balbinot e Brusamarello (2010) as medições realizadas não são perfeitas e os sensores possuem propriedades relacionadas aos erros e incertezas que apontam a confiabilidade nas medidas realizadas pelo instrumento. Algumas destas características são brevemente anunciadas a seguir.

Exatidão da medição: Segundo o Inmetro (2012) se refere ao nível de concordância entre um valor medido e o valor real do mensurando, e não é uma grandeza, mas sim um conceito qualitativo que não deve ser quantificado numericamente.

Precisão da medição: O Inmetro (2012) define como o grau de concordância entre os valores medidos, obtidos por meio de medições repetidas em objetos similares ou no mesmo objeto, sob condições específicas. A precisão da medição é comumente expressa numericamente por meio de medidas de dispersão, como desvio padrão, variância ou coeficiente de variação, sob condições de medição especificadas.

A Figura 2.2 ilustra os conceitos de precisão e exatidão.

Figura 2.2: Exemplificação dos conceitos de exatidão e precisão



Fonte: Adaptado de Balbinot e Brusamarello (2010)

As medições representadas na primeira figura são mais precisas em comparação com as medições na segunda figura, que, por sua vez, são mais precisas do que as da terceira figura. As duas primeiras imagens apresentam a mesma dispersão, enquanto a última imagem possui a maior dispersão. Portanto, as Figuras 2.2a e 2.2b têm a mesma precisão, que é maior do que a da 2.2c.

Fraden (2010) classifica os sensores em passivos ou ativos. Os sensores passivos não precisam de energia adicional e geram diretamente um sinal elétrico em resposta a um estímulo externo. Exemplos incluem termopares, fotodiodos e sensores piezoelétricos. Por outro lado, os sensores ativos requerem energia externa e modificam o sinal de excitação para produzir o sinal de saída. Eles são chamados de paramétricos porque suas propriedades mudam em resposta a um efeito externo. Um exemplo é o termistor, que mede a temperatura através de variações na resistência elétrica. Para medir a resistência de um sensor, é necessário aplicar corrente elétrica a partir de uma fonte de alimentação externa.

As características mencionadas são aplicáveis aos sensores físicos, no entanto, o presente trabalho propõe a utilização de um terceiro tipo de sensor: os sensores virtuais.

2.1.1 Sensores virtuais

Os sensores virtuais são softwares que têm o objetivo de fornecer medições indiretas de uma variável de processo com base em dados coletados por meio de sensores físicos ou outros sensores virtuais. A Figura 2.3 ilustra a estrutura e o funcionamento de um sensor virtual (MARTIN; KÜHL; SATZGER, 2021).

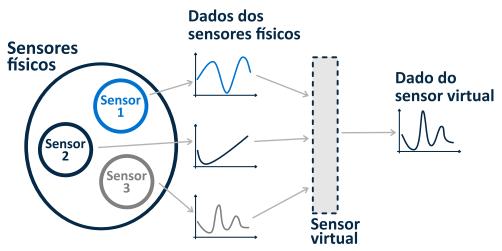


Figura 2.3: Estrutura e funcionamento de um sensor virtual

Fonte: Adaptado de Martin, Kühl e Satzger (2021)

Segundo Tegen et al. (2019), os sensores virtuais também podem ser utilizados em situações em que um sensor físico está com defeito. Esses sensores, que consistem apenas em software, têm a capacidade de identificar e eliminar leituras anômalas de outros sensores, o que torna a transmissão de dados mais eficiente e as medições mais confiáveis.

Martin, Kühl e Satzger (2021) destacam algumas desvantagens que os dispositivos físicos possuem em comparação com os sensores virtuais, como alto custo, aumento da imprecisão ao longo do tempo, maior suscetibilidade a ruídos no sinal, atraso e imprecisão nas medições quando instalados em locais inadequados, além da falta de sensores físicos disponíveis para certas medições.

2.2 Identificação de sistemas

A identificação do sistema permite construir modelos matemáticos que capturam o comportamento de um sistema, relacionando suas entradas com suas saídas. Isso pode ser útil para desenvolver um controle efetivo, tomar decisões e entre outras aplicações.

Para Aguirre (2015) os modelos desempenham um papel essencial na obtenção de conhecimento, na análise de dados e no controle de processos. O autor classifica as técnicas de modelagem em três categorias distintas, conhecidas como modelagem de caixa branca, caixa cinza e caixa preta. Na modelagem de caixa branca, é crucial ter um conhecimento profundo do sistema em análise, bem como das leis físicas que regem o sistema a ser modelado. Porém, por causa da complexidade e do tempo necessário para modelar um sistema a partir da equação dos fenômenos envolvidos, muitas vezes não é viável seguir esse procedimento.

Existem várias técnicas que são utilizadas como alternativas à modelagem de caixa branca. Assim, pouco ou nenhum conhecimento prévio do sistema é necessário. Tais métodos também são conhecidos como modelagem de caixa preta. O objetivo desses modelos é descrever as relações de causa e efeito entre as variáveis de entrada e saída. Por fim, as chamadas técnicas de identificação de caixa cinza utilizam informações auxiliares que não são incluídas no conjunto de dados utilizado durante o processo de identificação. A Figura 2.4 apresenta um exemplo de modelagem caixa preta de um sistema de múltiplas entradas e única saída (MISO), no qual a saída pode ser analisada de acordo com as variações nas entradas.

Figura 2.4: Exemplo de modelagem caixa preta

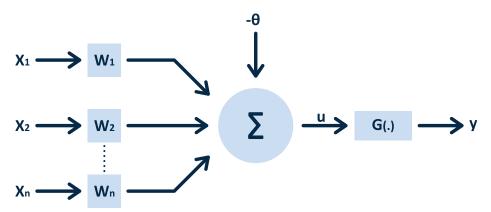


Fonte: Autoria própria

2.3 Redes neurais artificiais

Redes neurais artificiais são modelos computacionais que imitam a estrutura do sistema nervoso de seres vivos, capazes de aprender e armazenar informações. Elas são formadas por unidades de processamento, denominadas neurônios artificiais, que se interconectam por diversas conexões. A Figura 2.5 apresenta a estrutura de um neurônio artificial, responsável por coletar os sinais em suas entradas e produzir uma resposta em sua saída (SILVA; SPATI; FLAUZINO, 2016).

Figura 2.5: Neurônio artificial



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Os elementos presentes na Figura 2.5 são:

- $\{X_1, X_2, \cdots, X_n\} \rightarrow$ sinais de entrada vindos do meio externo;
- {W₁, W₂, · · · , W_n} → pesos sinápticos usados para ponderar cada uma das variáveis de entrada;
- $\Sigma \to {\rm combinador\ linear\ responsável\ por\ realizar\ o\ somatório\ dos\ sinais\ ponderados;}$

- $\theta \to \text{limiar}$ de ativação define o nível adequado para que o resultado gerado pelo combinador linear possa ativar a saída do neurônio;
- u → potencial de ativação (resultado da diferença entre o combinador linear e o limiar de ativação);
- $g \rightarrow$ função de ativação, que limita a saída dentro de um intervalo de valores e
- $y \rightarrow$ sinal de saída produzido pelo neurônio.

Segundo Goodfellow, Bengio e Courville (2016), a grande dificuldade em muitas aplicações de inteligência artificial é que muitos fatores influenciam os dados observados. Por exemplo, o sotaque do falante pode ser identificado apenas por uma análise em nível quase humano. As redes neurais artificiais permitem que o computador construa conceitos complexos a partir de conceitos mais simples e assim possa resolver este tipo de problema. A Figura 2.6 apresenta uma rede neural com duas entradas, dois neurônios em cada camada escondida e um neurônio de saída.

Pixels Partes do objeto Identificado

FLOR

Figura 2.6: Rede neural artificial

Fonte: Adaptado de Goodfellow, Bengio e Courville (2016)

Para Silva, Spati e Flauzino (2016), as redes neurais artificias possuem sete características relevantes, quais sejam:

- adaptação por experiência: seus parâmetros internos são ajustados por meio da apresentação sequencial de exemplos;
- 2. capacidade de aprendizado: por meio de métodos de treinamentos, a rede é capaz de identificar a relação existente entre diversas variáveis presentes na aplicação;

- 3. habilidade de generalização: após o treinamento da rede neural, esta pode generalizar o conhecimento adquirido e estimar soluções para problemas previamente desconhecidos;
- organização de dados: com base em características de um conjunto de informações, a rede neural pode organizar-se internamente para permitir o agrupamento de padrões que compartilham características em comum;
- 5. tolerância a falhas: devido ao grande número de conexões entre os neurônios artificiais, a rede neural torna-se um sistema capaz de tolerar falhas;
- 6. armazenamento distribuído: conhecimento sobre o comportamento de um processo dentro de uma arquitetura neural é distribuído entre as diversas sinapses dos neurônios artificiais, o que aumenta a robustez da arquitetura;
- 7. facilidade de prototipagem: a maioria das arquiteturas neurais pode ser prototipada facilmente em hardware ou software, pois, após o treinamento, os resultados são normalmente obtidos por meio de algumas operações matemáticas simples.

2.3.1 Potenciais áreas de aplicação

É possível utilizar Redes Neurais Artificiais em uma variedade de problemas nas áreas da engenharia. Segundo Silva, Spati e Flauzino (2016), podemos categorizar as potenciais áreas de aplicação da seguinte forma:

Aproximador universal de funções: Mapear o relacionamento funcional entre variáveis de um sistema usando um conjunto conhecido de valores representativos. Especialmente para mapear processos difíceis de modelar com técnicas convencionais.

Controle de processos: Encontrar medidas de controle para atingir requisitos de qualidade, eficiência e segurança do processo.

Reconhecimento/classificação de padrões: Associar um padrão de entrada a uma classe pré-definida.

Agrupamento de dados (clusterização): Identificar e detectar semelhanças e diferenças entre os diferentes padrões de entrada para permitir seu agrupamento.

Sistemas de previsão: Prever valores futuros de um processo com base em várias medidas prévias observadas em seu domínio.

Otimização de sistemas: Otimizar uma função de custo, levando em consideração possíveis restrições necessárias para mapear adequadamente o problema.

Memórias associativas: Recuperar padrões corretos, mesmo que os elementos que os compõem sejam apresentados de forma incerta ou imprecisa.

2.3.2 Função de ativação

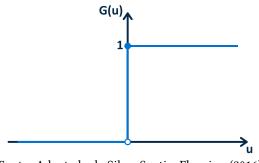
A função de ativação é utilizada para restringir a saída de um neurônio a um intervalo específico de valores, definido pela sua própria imagem. As funções de ativação podem ser parcialmente diferenciáveis e totalmente diferenciáveis (SILVA; SPATI; FLAUZINO, 2016).

Funções de ativação parcialmente diferenciáveis

Função degrau: O resultado obtido ao aplicar a função degrau será um valor unitário positivo quando o potencial de ativação do neurônio for maior ou igual a zero. Caso contrário, o resultado será zero. A Equação 2.1 é utilizada para representar a expressão matemática, enquanto a Figura 2.7 apresenta o comportamento da função.

$$g(u) = \begin{cases} 1, & u \ge 0 \\ 0, & u < 0 \end{cases}$$
 (2.1)

Figura 2.7: Função de ativação degrau



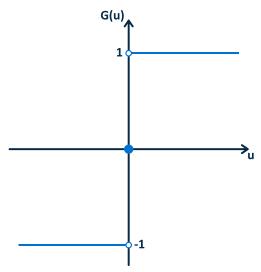
Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Função degrau bipolar: O resultado gerado pela aplicação dessa função assumirá valores unitários positivos quando o potencial de ativação do neurônio for maior que zero, terá valor

nulo quando o potencial for igual a zero e apresentará valores unitários negativos quando o potencial for menor que zero. A função é visualmente demonstrada na Figura 2.8, enquanto a expressão matemática correspondente pode ser encontrada na equação Equação 2.2.

$$g(u) = \begin{cases} 1, & u > 0 \\ 0, & u = 0 \\ -1, & u < 0 \end{cases}$$
 (2.2)

Figura 2.8: Função de ativação degrau bipolar



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Função rampa simétrica: Os valores retornados são iguais aos próprios valores dos potenciais de ativação quando estes estão dentro do intervalo [-a, a], limitando-se aos valores limite em caso contrário. Na Figura 2.9, é possível observar o comportamento da função, cuja representação matemática está indicada na Equação 2.3.

$$g(u) = \begin{cases} a, & u > a \\ u, & -a \le u \le 0 \\ -a, & u < -a \end{cases}$$
 (2.3)

-a a u

Figura 2.9: Função de ativação rampa simétrica

Fonte: Adaptado de Silva, Spati e Flauzino (2016)

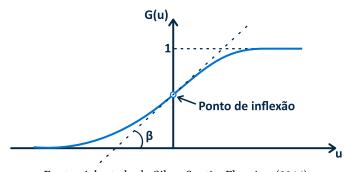
Funções de ativação totalmente diferenciáveis

Função logística (ou sigmoidal): O resultado de saída obtido ao aplicar a função logística sempre assumirá valores reais no intervalo de zero a um. O comportamento da função é ilustrado na Figura 2.10, enquanto sua expressão matemática correspondente é dada pela Equação 2.4:

$$g(u) = \frac{1}{1 + e^{-\beta u}} \,, \tag{2.4}$$

onde β é uma constante real associada ao grau de inclinação da função logística em relação ao seu ponto de inflexão.

Figura 2.10: Função de ativação logística



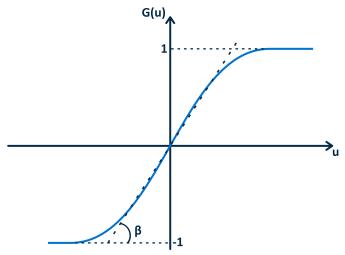
Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Função tangente hiperbólica: Ao contrário da função logística, o resultado de saída sempre estará no intervalo entre -1 e 1. A Figura 2.11 mostra o gráfico da função, enquanto a

Equação 2.5 representa a expressão matemática associada a ela.

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \tag{2.5}$$

Figura 2.11: Função de ativação tangente hiperbólica



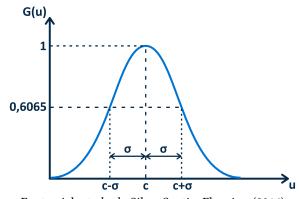
Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Função gaussiana: A saída do neurônio produzirá resultados idênticos para os valores de potencial de ativação u que estejam equidistantes do seu centro, pois a curva é simétrica em relação a ele. Na Equação 2.6, encontra-se a representação matemática da função, cujo comportamento é ilustrado na Figura 2.12:

$$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}},$$
 (2.6)

onde o parâmetro c define o centro da função gaussiana, enquanto σ representa o desvio padrão associado a ela, indicando o quão dispersa a curva está em relação ao seu centro.

Figura 2.12: Função de ativação gaussiana

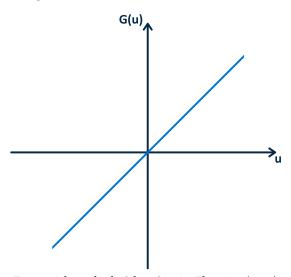


Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Função linear: A função de ativação linear gera resultados de saída idênticos aos valores do potencial de ativação *u*. A Figura 2.13 fornece uma representação visual do comportamento da função, enquanto a equação Equação 2.7 apresenta sua expressão matemática.

$$q(u) = u \tag{2.7}$$

Figura 2.13: Função de ativação linear



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

2.3.3 Arquiteturas

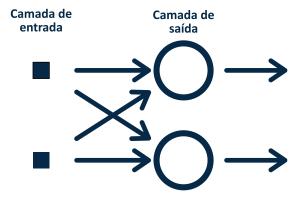
A arquitetura de uma rede neural se refere à sua estrutura, que engloba o número e a disposição das camadas, as conexões entre os neurônios e o fluxo de informações dentro da rede. Existem diversas arquiteturas amplamente utilizadas. As mais aderentes à proposta deste trabalho são descritas nas próximas seções.

Arquitetura feedforward de camada simples

As redes neurais feedforward são denominadas dessa forma porque a informação flui apenas em uma direção na rede, sem ciclos, passando primeiramente pelos nós de entrada e, em seguida, pelos nós de saída, como mostrado na Figura 2.14. A referência à camada única diz respeito à camada de saída dos neurônios. A camada de entrada dos nós de origem não é contabilizada, pois não realiza nenhum cálculo (SHARKAWY, 2020).

Essas redes são comumente utilizadas em tarefas que envolvem classificação de padrões e filtragem linear (SILVA; SPATI; FLAUZINO, 2016).

Figura 2.14: Exemplo de rede feedforward de camada única



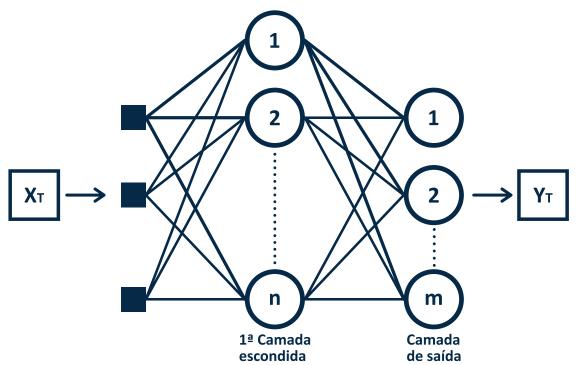
Fonte: Adaptado de Sharkawy (2020)

Arquitetura feedforward de camadas múltiplas

De acordo com Ozanich, Gerstoft e Niu (2020), os modelos de redes neurais feedforward de múltiplas camadas são descritos como uma sequência de transformações funcionais ponderadas. Essas redes consistem em camadas que recebem como entrada as saídas das camadas anteriores, conforme ilustrado na Figura 2.15.

São aplicadas para resolver uma ampla variedade de problemas, incluindo aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, controle de processos, entre outros (SILVA; SPATI; FLAUZINO, 2016).

Figura 2.15: Exemplo de rede feedforward de múltiplas camadas



Fonte: Adaptado de Ozanich, Gerstoft e Niu (2020)

Arquitetura recorrente

Segundo Wang et al. (2020), as redes neurais recorrentes são capazes de capturar informações dinâmicas em dados serializados, estabelecendo conexões periódicas entre os nós da camada oculta, como ilustrado na Figura 2.16. Enquanto nas redes neurais tradicionais todas as entradas (e saídas) são consideradas independentes, nas redes neurais recorrentes cada unidade está conectada a outras unidades na camada oculta em diferentes intervalos de tempo. Isso permite que as informações sejam transmitidas de uma camada para a próxima na rede.

Estas redes podem ser utilizadas em sistemas variantes em relação ao tempo, como previsão de séries temporais, otimização e identificação de sistemas, controle de processos etc.

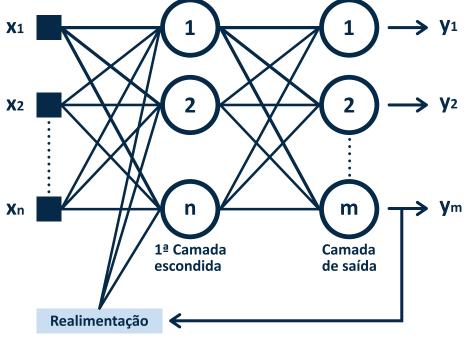


Figura 2.16: Exemplo de rede recorrente

Fonte: Adaptado de Silva, Spati e Flauzino (2016)

2.3.4 Rede Perceptron

A rede Perceptron multicamadas (PMC) é um tipo de rede neural feedforward que conecta várias camadas. Conforme afirmado por Wanchen (2020), a PMC é uma rede que apresenta uma correlação significativa entre seus elementos. Isso inclui o conteúdo, o dimensionamento e a divisão em lotes dos dados de entrada, bem como a inicialização dos parâmetros, o número de neurônios, a escolha das funções de ativação, o algoritmo de

treinamento e o número de camadas. A Figura 2.17 mostra um exemplo de rede PMC.

X1 A Logística

X2 B Logística

C Logística

Figura 2.17: Rede PMC aplicada em aproximação funcional

Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Segundo Silva, Spati e Flauzino (2016), uma rede PMC com uma camada escondida e uma camada de saída, tem a capacidade de mapear qualquer problema de classificação de padrões cujos elementos estejam contidos em uma região convexa. A Figura 2.18 apresenta dois exemplos de classificações, com dois (2.18a) e seis (2.18b) neurônios.

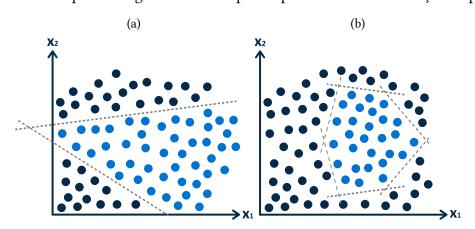


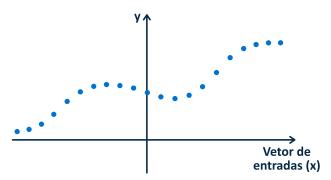
Figura 2.18: Exemplos de regiões convexas para o problema de classificação de padrões

Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Silva, Spati e Flauzino (2016) também argumentam que se as funções de ativação utilizadas nessa rede forem contínuas e limitadas em seu alcance, então uma topologia composta por apenas uma camada escondida é capaz de mapear qualquer função contínua no espaço das funções reais.

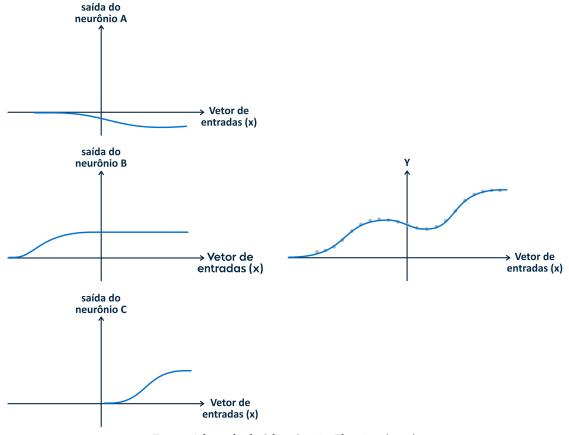
A Figura 2.20 mostra a aproximação da função formada pelas amostras da Figura 2.19. Neste exemplo, a rede utilizada (Figura 2.17) possui três neurônios na camada escondida com função de ativação logística, e um neurônio na camada de saída responsável por realizar uma combinação linear das respostas dos neurônios da camada anterior.

Figura 2.19: Amostras de treinamento da PMC referente a um problema de aproximação funcional



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

Figura 2.20: Superposição de funções logística para um problema de aproximação funcional



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

2.3.5 Redes de funções de base radial

De acordo com Bodyanskiy, Pirus e Deineko (2020), as redes de funções de base radial (RBFs) possuem capacidades de aproximação universal e de regularização. Evidentemente, quando uma RBF adequada é escolhida, a rede é capaz de aproximar com facilidade qualquer função contínua. A Figura 2.21 apresenta a configuração típica de rede RBF.

X1 A Gaussiana

X2 B Gaussiana

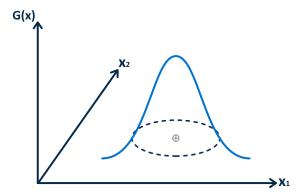
C Gaussiana

Figura 2.21: Rede RBF aplicada em aproximação funcional

Fonte: Adaptado de Silva, Spati e Flauzino (2016)

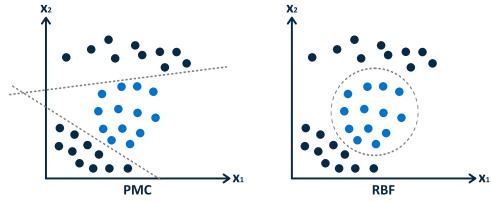
Quanto mais próxima uma determinada amostra estiver do centro da distribuição gaussiana (Figura 2.22), mais significativo será o valor gerado pelo campo receptivo radial da função de ativação. Por isso, nas RBFs com funções de ativação do tipo gaussiana, as fronteiras delimitadoras são estabelecidas por campos receptivos hiperesféricos. Como resultado, a classificação dos padrões é baseada na distância radial em relação ao centro das hiperesferas. No exemplo da Figura 2.23, a fronteira do PMC foi formada por dois segmentos de reta, indicando a presença de dois neurônios na camada intermediária. Já na RBF, um único campo radial foi capaz de agrupar todos os padrões de uma mesma classe, mostrando a presença de apenas um neurônio na camada escondida (SILVA; SPATI; FLAUZINO, 2016).

Figura 2.22: Função de base radial do tipo gaussiana



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

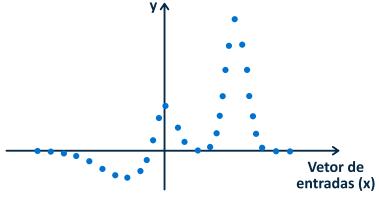
Figura 2.23: Fronteira de separabilidade do PMC e RBF



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

As redes de funções de base radial também têm a capacidade de aproximar universalmente funções. A Figura 2.25 ilustra como a rede mostrada na Figura 2.21 aproxima a função representada pelas amostras da Figura 2.24.

Figura 2.24: Amostras de treinamento da RBF referente a um problema de aproximação funcional.



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

saída do neurônio A

Vetor de entradas (x)

saída do neurônio B

Vetor de entradas (x)

saída do neurônio C

Vetor de entradas (x)

Figura 2.25: Superposição de funções gaussianas para um problema de aproximação funcional

Fonte: Adaptado de Silva, Spati e Flauzino (2016)

2.3.6 Redes de Jordan

A Figura 2.26 apresenta a estrutura da rede neural de Jordan, que inclui uma camada de entrada, uma camada oculta, uma camada de atraso e uma camada de saída. É importante ressaltar que os neurônios de atraso recebem alimentação diretamente da camada de saída (WU et al., 2019).

De acordo com Silva, Spati e Flauzino (2016), essas redes atuam de maneira similar ao PMC convencional para mapeamento de problemas de classificação, porém são utilizadas em situações que envolvem sistemas dinâmicos, nos quais o comportamento é considerado variante no tempo ou dependente dele.

 $\underbrace{\begin{array}{c} x(t) \\ \\ y(t-1) \end{array}} \underbrace{\begin{array}{c} Camadas \\ \\ Ocultas \end{array}} \underbrace{\begin{array}{c} h(t) \\ \\ \\ y(t) \end{array}} \underbrace{\begin{array}{c} Saidas \\ \\ \\ \end{array}} \underbrace{\begin{array}{c} y(t) \\ \\ \end{array}}$

Figura 2.26: Estrutura de uma rede neural de Jordan

Fonte: Adaptado de Wu et al. (2019)

2.3.7 Processos de treinamento

Treinamento é o procedimento mediante o qual os pesos sinápticos e limiares de ativação de uma rede neural são ajustados por meio de um processo contínuo de simulação realizado pelo ambiente em que a rede está integrada. A taxa de aprendizagem corresponde à velocidade com que a rede se adapta. O tipo de aprendizagem é determinado pela forma como a mudança de parâmetros ocorre (DONGARE; KHARDE; KACHARE et al., 2012).

Na documentação da (SCIKIT-LEARN), encontram-se três algoritmos para otimização dos pesos durante a fase de treinamento das redes PMC. São eles:

- Algoritmo de Broyden-Fletcher-Goldfarb-Shanno com memória limitada (LBFGS) : Este otimizador pertence à família de métodos quase-Newton.
- Método do gradiente estocástico (SGD): Refere-se à Descida Gradiente Estocástica.
- Estimativa de momento adaptativo (ADAM): Corresponde a um otimizador estocástico baseado em gradiente proposto por Kingma, Diederik e Jimmy Ba.

É importante observar que o solucionador padrão, 'adam', demonstra um desempenho significativo em conjuntos de dados relativamente grandes, que contêm milhares de amostras de treinamento ou mais, tanto em termos de tempo de treinamento quanto de pontuação de validação. No entanto, para conjuntos de dados menores, o otimizador 'lbfgs' pode convergir mais rapidamente e apresentar um desempenho superior.

Treinamento supervisionado

Durante o processo de treinamento, as redes neurais são ajustadas aos dados por meio de algoritmos de aprendizagem. Esses algoritmos de aprendizado envolvem a utilização de uma saída específica que é comparada com a saída prevista, resultando na adaptação de todos os parâmetros de acordo com essa comparação (GÜNTHER; FRITSCH, 2010).

Treinamento não supervisionado

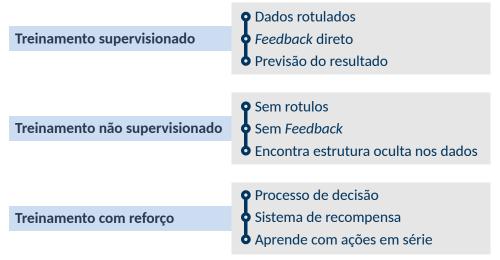
O treinamento não supervisionado lida com dados não rotulados ou dados cuja estrutura é desconhecida. Essas técnicas têm a capacidade de explorar a estrutura dos dados para extrair informações significativas sem depender de uma variável de resultado conhecida ou função de recompensa para orientação (RASCHKA; MIRJALILI, 2019).

Treinamento com reforço

É um tipo de aprendizado que pode ser considerado uma abordagem intermediária entre os dois tipos de aprendizado mencionados anteriormente. Nesse contexto, a máquina de aprendizado executa ações no ambiente e recebe feedback em resposta. O sistema de aprendizado avalia suas ações como benéficas (recompensadoras) ou desfavoráveis (puníveis) com base no feedback ambiental e ajusta seus parâmetros de acordo. Normalmente, o ajuste dos parâmetros continua até que um estado de equilíbrio seja alcançado, momento em que não ocorrem mais alterações nos parâmetros (DONGARE; KHARDE; KACHARE et al., 2012).

A Figura 2.27 faz um comparativo entre os três tipos de treinamento.

Figura 2.27: Comparativo entre os tipos de treinamento



Fonte: Adaptado de Raschka e Mirjalili (2019)

Problemas de overfitting e underfitting

De acordo com Zhang, Zhang e Jiang (2019), há uma extensa investigação dos fenômenos de sobreajuste (*overfitting*) e subajuste (*underfitting*) no campo de aprendizado de máquina.

O overfitting ocorre quando há um treinamento excessivo ou um aumento indiscriminado de neurônios, fazendo com que a rede memorize as respostas. Nesse caso, o erro quadrático durante a fase de aprendizado tende a ser muito baixo, mas durante a fase de execução, esse erro pode assumir valores muito altos. Por outro lado, uma rede com um número muito pequeno de neurônios pode ser insuficiente, resultando em uma situação de debilidade neural conhecida como *underfitting* Silva, Spati e Flauzino (2016).

Até o momento, acredita-se que o *underfitting* e o *overfitting* estão associados à complexidade das arquiteturas de redes neurais, à quantidade e ao tipo de dados amostrais utilizados nos conjuntos de treinamento, e ao número de épocas de treinamento, que serão abordados na próxima seção.

Métricas para avalição

Abiodun et al. (2019) destacam alguns indicadores estatísticos que são utilizados para avaliar o desempenho das RNAs. Esses indicadores abrangem o erro percentual absoluto (MAPE), o erro absoluto médio (MAE), erro quadrático médio (MSE), a raiz quadrada do erro quadrático médio (RMSE) e o coeficiente de determinação (R²).

Nas fórmulas a seguir, apresentadas por Chicco, Warrens e Jurman (2021), X_i representa o i-ésimo valor previsto, o elemento Y_i corresponde ao i-ésimo valor real e n é a quantidade de amostras.

• Erro percentual absoluto (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{Y_i - X_i}{Y_i} \right|$$
 (2.8)

• Erro absoluto médio (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |Y_i - X_i|$$
 (2.9)

• Erro quadrático médio (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^{n} (Y_i - X_i)^2$$
 (2.10)

• Raiz quadrada do erro quadrático médio (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (Y_i - X_i)^2}$$
 (2.11)

• Coeficiente de determinação (R2):

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (Y_{i} - X_{i})^{2}}{\sum_{i=1}^{n} (\overline{Y} - Y_{i})^{2}}$$
(2.12)

O coeficiente de determinação pode ser interpretado como a proporção da variância na variável dependente que é previsível a partir das variáveis independentes. O valor desejável que pode ser alcançado é 1, enquanto o valor mais indesejável é $-\infty$.

Seleção das melhores topologias

De acordo com Silva, Spati e Flauzino (2016), a escolha das topologias mais apropriadas frequentemente implica o uso da validação cruzada. Nesse procedimento, o conjunto total de dados disponíveis é particionado em duas partes, ou seja, um conjunto de treinamento e um conjunto de teste. O conjunto de treinamento é utilizado para o ajuste das topologias candidatas, enquanto o conjunto de teste é exclusivamente destinado à seleção daquela que demonstre os melhores resultados. Essa abordagem de divisão deve ser repetida várias vezes durante o processo de aprendizado, permitindo a inclusão de amostras distintas tanto no conjunto de treinamento quanto no de teste. O desempenho global de cada topologia é, então, compilado a partir da média dos desempenhos individuais em cada experimento.

Validação cruzada por amostragem aleatória

Na prática, a partir do conjunto total de dados, geralmente selecionamos aleatoriamente entre 60% e 90% para o conjunto de treinamento, enquanto o restante é alocado para o conjunto de teste. A Figura 2.28 apresenta uma representação visual do método de validação cruzada com amostragem aleatória.

Figura 2.28: Método de validação cruzada por amostragem aleatória



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

· Validação cruzada com k-partições

O conjunto total de dados é dividido em k partições, onde k-1 delas são combinadas para formar o conjunto de treinamento, enquanto a partição restante representa o conjunto de teste. Esse procedimento é repetido k vezes, garantindo que todas as partições tenham sido empregadas como conjuntos de teste. A Figura 2.29 ilustra essa estratégia.

Figura 2.29: Método de validação cruzada usando k-partições



Fonte: Adaptado de Silva, Spati e Flauzino (2016)

2.4 Beneficiamento de Minério Fosfático

Uma única rocha, como o carbonatito, pode conter uma variedade de minerais distintos, tais como calcita, apatita e biotita, o que a qualifica como um fertilizante, mesmo sob a forma de pó de rocha. No entanto, devido à sua baixa solubilidade, sua utilização em larga escala é dificultada, embora essa característica possa ajudar a reduzir o escoamento de nutrientes em

comparação com os fertilizantes químicos. É necessário um processo de desgaste para que os nutrientes presentes na rocha se tornem biodisponíveis (JONES; GUINEL; ANTUNES, 2020).

Na indústria de fertilizantes, é essencial que os minérios de fosfato apresentem um teor de P_2O_5 superior a 30%, uma relação CaO/P_2O_5 inferior a 1,6 e um teor de MgO inferior a 1%. Caso os minérios de fosfato não atendam a esses critérios, é necessário remover as impurezas por meio de um processo de beneficiamento. Esse processo tem como objetivo reduzir a presença de minerais de ganga, tais como quartzo, argilominerais, feldspato, mica, calcita e dolomita.

Desde os anos 1920, a flotação tem desempenhado um papel fundamental no processo de concentração dos minérios de fosfato. Através desse método, é possível recuperar as partículas finas de apatita, garantindo assim a qualidade necessária para a produção de fertilizantes (SIS; CHANDER, 2003).

Segundo O'Sullivan et al. (2020), a apatita (Figura 2.30) é um grupo mineral amplamente encontrado nas diversas litologias que constituem a crosta terrestre. Isso ocorre principalmente devido à limitação dos principais minerais formadores de rochas em acomodar quantidades significativas de fósforo em sua estrutura cristalina.



Figura 2.30: Apatita

Fonte: https://didatico.igc.usp.br/minerais/fosfatos/apatita/

2.4.1 Flotação

A flotação é um processo de separação realizado em uma suspensão mineral em meio aquoso, conhecida como polpa. As partículas presentes na polpa são obrigadas a percorrer um caminho e, em determinado momento, as partículas que se deseja flotar são induzidas a abandonar esse caminho, seguindo uma trajetória ascendente. A diferenciação entre as diferentes espécies minerais ocorre devido à capacidade das partículas se aderirem a bolhas de gás, geralmente ar. Quando uma partícula consegue se aderir à bolha, a densidade do conjunto partícula-bolha se torna menor do que a do fluido circundante, resultando no deslocamento vertical do conjunto em direção à superfície. Nessa região, o conjunto é retirado sob a forma de espuma, enquanto as partículas das outras espécies minerais continuam em sua trajetória original sem sofrer alterações (CHAVES; FILHO; BRAGA, 2010).

A Figura 2.31 exemplifica os fundamentos do processo de flotação em uma célula de flotação mecânica. O mecanismo agitador gera agitação intensa na fase de polpa, promovendo o encontro entre partículas e bolhas (colisão), a adesão seletiva das partículas hidrofóbicas/hidrofobizadas e seu transporte para a fase de espuma, onde ocorre a recuperação.

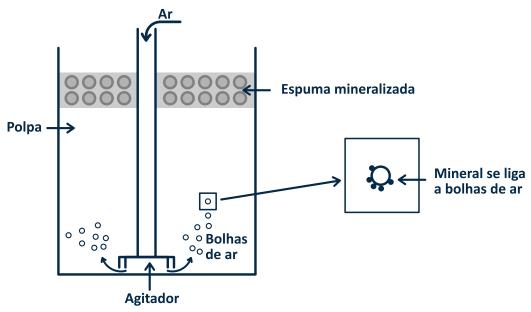


Figura 2.31: Princípio da flotação de espuma

Fonte: Adaptado de Galbadrakh (2006)

Durante o processo de concentração por flotação, ocorre frequentemente a transferência do mineral para a espuma, conhecida como fração flotada, enquanto a ganga permanece na polpa ou rejeito. Essa abordagem é denominada flotação direta (Figura 2.32). Por outro lado,

temos a flotação reversa (Figura 2.33), que é o oposto, onde a ganga é separada e direcionada para a fração flutuante (GALBADRAKH, 2006).

Figura 2.32: Representação da flotação direta.

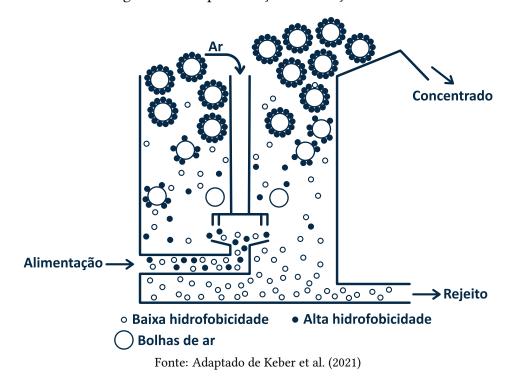
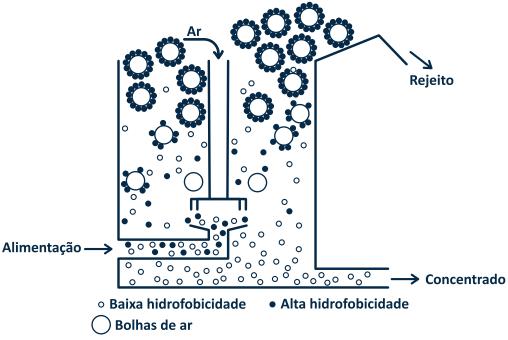


Figura 2.33: Representação da flotação reversa.



Fonte: Adaptado de Keber et al. (2021)

A flotação é amplamente utilizada em escala crescente na concentração de minérios metálicos não ferrosos, como Cu, Pb, Zn, Co, Ni, Mo, Sb, etc., sejam eles sulfetos, óxidos ou

carbonatos, como uma etapa inicial na produção de metais. Além disso, ela é empregada na concentração de minerais "não metálicos" que são utilizados como matérias-primas na indústria química, como por exemplo, CaF₂, BaSO₄, NaCl, KCl, S, alumina, sílica, entre outros (LEJA, 2004).

A flotação de fosfato foi inicialmente realizada com sabão, depois evoluiu ao longo dos anos com o desenvolvimento de reagentes e a melhoria dos parâmetros do processo. O desempenho de um sistema de flotação é vulnerável a uma série de variáveis, como densidade da polpa, temperatura, coletores, espumantes, ativadores, depressores, reguladores de pH, agitação, fluxo de ar, etc. (DERHY et al., 2020).

Reagentes de flotação

Para Bulatovic (2007), a seleção dos reagentes é crucial para o processo de flotação, sendo uma etapa fundamental em seu desenvolvimento. No estágio inicial desse processo, os avanços mais significativos têm sido alcançados graças aos reagentes de flotação aprimorados. Durante a criação de um processo de tratamento, são investidos consideráveis recursos, como tempo, energia e atenção, na escolha dos reagentes mais adequados, visando obter os resultados mais eficazes em termos de separação e concentração. Nas plantas comerciais, o controle preciso das adições de reagentes é a estratégia mais importante para alcançar o sucesso na flotação.

Os reagentes são divididos em coletores, espumantes, reguladores e depressores:

Coletores: Os coletores têm a função principal de hidrofobizar as partículas a serem flotadas. São compostos surfactantes que possuem uma estrutura típica, composta por uma parte molecular (não iônica) e uma parte polar (iônica). Devido às características elétricas das ligações covalentes, a parte molecular do coletor possui uma maior afinidade com a fase gasosa do que com a fase líquida. Quando há uma interface sólido-gás no sistema, como é o caso das bolhas de ar sopradas para dentro da célula de flotação, a molécula do coletor tende a posicionar-se nessa interface, de forma a orientar sua parte não polar em contato com o gás e sua porção iônica em contato com a água (CHAVES; FILHO; BRAGA, 2010).

A Figura 2.34 mostra a interação entre a bolha de ar e a superfície do mineral em dois sistemas: um sem coletor (2.34a) e outro com coletor (2.34b). Sem o coletor, as bolhas de ar têm um ângulo de contato pequeno com a superfície mineral, o que resulta em uma adsorção insignificante. No entanto, quando há a presença do coletor, forma-se um ângulo de contato

significativo, favorecendo a ocorrência da flotação do mineral.

Figura 2.34: Contato bolha de ar/superfície do mineral em um sistema com e sem coletor.



Fonte: Adaptado de Chaves, Filho e Braga (2010)

Espumantes: São substâncias heteropolares compostas por tensoativos, que têm a propriedade de reduzir a tensão superficial da água e podem se adsorver na interface entre a bolha de ar e a água. Sua presença na fase líquida contribui para aumentar a resistência do filme das bolhas de ar, promovendo uma melhor aderência das partículas hidrofóbicas às bolhas (BULATOVIC, 2007).

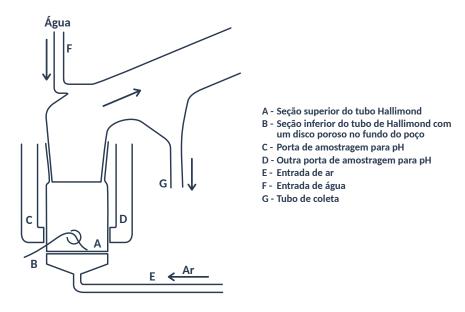
Reguladores: O principal objetivo desses reagentes consiste em alterar a ação do coletor em relação às superfícies minerais, resultando na capacidade de controlar a seletividade do processo de flotação. Quando os reguladores estão presentes, o coletor adsorve exclusivamente as partículas que devem ser recuperadas (BULATOVIC, 2007).

Depressores: São compostos capazes de reforçar a hidrofilicidade da superfície das partículas que deseja-se encaminhar para o afundado, com o objetivo de tornar a coleta seletiva (CHAVES; FILHO; BRAGA, 2010).

2.4.2 Microflotação

Conforme apontado por (SHARMA, 2009), os ensaios de microflotação têm sido empregados por muitos anos para a avaliação da eficácia de coletores em relação à flotação de minerais puros. Esses testes envolvem a utilização de uma pequena quantidade de mineral puro, geralmente entre 0,5 a 5g, e são notáveis por sua alta reprodutibilidade, devido ao rigoroso controle das variáveis. Embora tenham sido desenvolvidas diversas células de flotação para serem usadas em testes de microflotação, o tubo Hallimond modificado tem se destacado como uma opção pioneira nesse contexto. O diagrama esquemático de um tubo Hallimond modificado é mostrado na Figura 2.35.

Figura 2.35: Um tubo Hallimond típico usado para microflotação



Fonte: Adaptado de Sharma (2009)

O tubo Hallimond consiste em uma seção inferior com poros de no mínimo 40 micrômetros, uma seção superior de vidro dobrado, e a água é adicionada por cima. O ar é usado para criar uma superfície hidrofóbica para que os minerais se liguem. Pode-se usar gás nitrogênio para evitar a oxidação dos minerais. Um agitador magnético mantém as partículas em suspensão. O condicionamento dos minerais pode ocorrer dentro ou fora do tubo, dependendo do tamanho. Minerais flutuantes são coletados em um tubo de saída, e as portas de amostragem monitoram o pH durante o processo.

2.4.3 Análise de processos químicos

Krug e Rocha (2019) explicam que a análise é uma investigação complexa que pode ser resumida por meio de uma série de tarefas (etapas). Nem sempre todas essas tarefas são obrigatórias. As medidas não devem ser realizadas apenas como uma etapa isolada, pois estão intrinsecamente ligadas a um processo iterativo que abarca:

- Especificação das necessidades;
- Revisão das informações;
- Criação;
- Plano de estudos;

- Amostragem;
- Preparo das amostras;
- Análise preliminar;
- Identificação/confirmação da composição química;
- · Análise quantitativa;
- Coleta e revisão de dados;
- Interpretação dos dados/solução do problema;
- Relatório dos resultados/aconselhamento.

Segundo Júnior e Cruz (2011), ao analisar processos químicos, busca-se entender as características e quantidades dos produtos em relação às características e quantidades dos insumos, e vice-versa, em todas as etapas e no conjunto do processo. Essa análise é fundamentada na Lei da Conservação das Massas, proposta por Antoine Laurent Lavoisier (1743-1794), que expressa a ideia de que "na natureza nada se perde, nada se cria, tudo se transforma". Assim, fica evidente que a natureza impõe certas limitações às mudanças físicas e químicas da matéria, as quais devem ser consideradas ao projetar ou analisar um processo existente.

No exemplo da flotação, supondo que 100 gramas de minério sejam introduzidos no processo. Ao verificar a quantidade de massa presente no material que flutua e no material que afunda, percebe-se que ela permanece igual à introduzida inicialmente, ou seja, 100 gramas. Portanto, para calcular a flotabilidade de um minério, basta seguir a Equação 2.13.

$$f(\%) = \frac{m_f}{m_t} \times 100, (2.13)$$

onde f representa a flotabilidade, m_f é a massa que flutua e m_t é a massa total.

Não há um período definido para a conclusão da análise, devido a diversas variáveis durante o processo que são difíceis de controlar, como o fator humano, disponibilidade de laboratório e complexidade da análise. Após a coleta da amostra, a realização da análise de balanço de massas é relativamente simples e pode ser concluída em poucos minutos, contanto que haja disponibilidade de laboratório e profissionais qualificados naquele momento. Em

situações em que os testes visam analisar a flotabilidade em condições específicas, é necessário um período mais extenso, que pode variar de horas a dias, além dos custos associados ao material utilizado.

2.4.4 Sensores virtuais na mineração

Conforme mencionado na Capítulo 1, a Engenharia de Minas pode tirar proveito da aplicação de sensores virtuais. Esta seção tem como objetivo apresentar outros estudos relevantes neste campo, além dos já referidos anteriormente.

Jian, Lihui e Yongfang (2020) empregaram uma rede neural convolucional para realizar uma detecção em tempo real do grau de espuma e possíveis anomalias no processo de flotação de antimônio. Os resultados obtidos em seus experimentos revelaram que a taxa de precisão na detecção do estado da espuma atingiu incríveis 99,17%, superando a precisão da classificação realizada por seres humanos.

Ai et al. (2021) também desenvolveram um modelo de aprendizado profundo para extrair as características visuais e dinâmicas da espuma, a fim de estabelecer uma relação preditiva entre as características da imagem e o conteúdo do concentrado. Comparando experimentos com dados históricos da indústria, ficou evidente a eficácia do método de monitoramento proposto. Além disso, testes industriais conduzidos em uma planta real de flotação de zinco na China demonstraram que o coeficiente de determinação alcançado por esse método é de 0,9256, representando uma melhoria significativa de 7,9% em relação a um sistema especialista já em uso naquela planta.

Na sua 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, Sobreira (2021) propõe a utilização de técnicas de aprendizado de máquina, incluindo o M5P, Random Forest e REPTree, com o objetivo de desenvolver sensores virtuais para estimar a vazão mássica de minério em um equipamento desprovido de uma balança integradora. Estes sensores foram criados com base em informações de corrente, torque e velocidade do motor de uma correia transportadora, bem como medições de vazão de minério de ferro obtidas de uma balança integradora instalada em outro transportador. Os sensores virtuais propostos foram implementados em um controlador lógico programável de um transportador de correia localizado no complexo S11D da Vale, no estado do Pará. Como resultado, os sensores virtuais propostos demonstraram a capacidade de medir a vazão de

minério com uma taxa de erro aceitável em comparação com uma balança integradora.

No mesmo programa de pós-graduação, Guedes (2020) conduziu em sua dissertação a implementação de um sensor virtual com base em redes neurais artificiais e *random forests* para previsão em tempo real do teor de ferro no concentrado de minério de ferro, fazendo uso de diversas variáveis de entrada, tais como a vazão de ar e o nível de espuma, entre outras. Entre as redes neurais escolhidas, o erro absoluto médio (MAE) variou de 1,8 a 2,4. De maneira similar, entre as *random florests* selecionadas, o MAE variou de 0,9 a 1,2.

Guicheng et al. (2022) demonstraram que a utilização de sensores virtuais também se revela eficaz na vigilância em tempo real da carga do moinho semiautógenos (SAG), visando assegurar a operação contínua do processo de moagem e prevenir situações de moagem insuficiente ou excessiva. O modelo baseado em máquinas de vetores de suporte apresentou taxas de erro predominantemente situadas na faixa de 5 a 10%.

Liu, Wang et al. (2019) empregaram o método dos mínimos quadrados parciais na criação de um sensor virtual capaz de identificar diferentes tipos de alterações nos estados do processo de lixiviação de cianeto de ouro. Esses estados compreendem quatro circunstâncias distintas: estado estacionário, condições de operação, variações temporais lentas e valores discrepantes. Seu trabalho resultou em um erro quadrático médio inferior a 10% e um coeficiente de determinação superior a 0.9.

Capítulo 3

Metodologia

Seguindo a base fornecida na revisão bibliográfica, neste capítulo, os passos necessários para alcançar os objetivos apresentados no Capítulo 1 são enumerados e detalhados. O trabalho se desenvolve em sete grandes etapas: (i) aquisição e tratamento dos dados; (ii) implementação de diferentes topologias de redes neurais artificiais; (iii) execução de algoritmos de treinamento supervisionado nas redes desenvolvidas; (iv) validação dos treinamentos; (v) avaliação das redes e definição da topologia mais adequada; (vi) implementação do sensor virtual para inferência em tempo real e (vii) análise dos resultados.

As próximas seções detalham cada uma dessas etapas do projeto.

3.1 Aquisição e tratamento dos dados

O primeiro passo é adquirir e pré-processar dados das variáveis que possam estar relacionadas à concentração de apatita. Para tanto, o projeto utiliza um *dataset* que reúne informações provenientes de experimentos realizados por Santos (2022) em sua pesquisa. Nesse estudo, foram avaliados os efeitos do uso de óleos de Andiroba (Carapas guianensis) e Patauá (Oenocarpus bataua), bem como da gordura de Bacuri (Platonia insignis), no contexto da microflotação de apatita e carbonatos presentes no minério fosfático.

A obtenção de dados é crucial para obter uma amostra apropriada do problema. Em uma situação ideal, os dados empregados no treinamento de uma rede neural devem ser diversos e abranger uma ampla gama de cenários distintos. Isso assegura que a rede neural seja capaz de generalizar de forma eficaz e produzir resultados suficientemente precisos. No entanto, este estudo pretende utilizar o mesmo cenário empregado por Santos (2022), o que implica que os

dados estão restritos a determinados valores.

O tratamento dos dados refere-se à aplicação de técnicas para preparar os dados antes de serem alimentados à rede neural. Isso pode incluir etapas como:

Limpeza dos dados: A limpeza dos dados, envolve a modificação e remoção de campos com informações incorretas ou incompletas. Além disso, é importante identificar e eliminar informações duplicadas ou dados não relacionados, bem como corrigir problemas de formatação, valores ausentes ou erros de ortografia.

Normalização: A normalização tem como objetivo ajustar os valores para uma escala comum, preservando as proporções entre eles e evitando perda de informações.

Remoção de *outliers*: Outliers são observações atípicas em relação a um conjunto de dados. Esses pontos discrepantes podem introduzir distorções nas análises.

Seleção de características relevantes: Existem alguns dados no conjunto que são irrelevantes para a análise, portanto, o ideal é não utilizá-los. Quanto mais características forem usadas, mais processamento será necessário, sem trazer nenhum benefício significativo.

O objetivo dessas etapas é melhorar a qualidade e a utilidade dos dados, eliminando informações desnecessárias ou prejudiciais e destacando os padrões relevantes para o problema em questão. O tratamento adequado dos dados também ajuda a lidar com desafios comuns encontrados no treinamento de redes neurais, como o sobreajuste.

3.2 Implementação de diferentes topologias de redes neurais artificiais

Algumas topologias são implementadas com o intuito de encontrar aquela que melhor se adequa ao propósito determinado. Ao analisar os dados, constata-se que as arquiteturas recorrentes não são apropriadas, uma vez que são projetadas para dados sequenciais, enquanto o conjunto de dados adquirido não apresenta essa propriedade. Implementam-se redes Perceptron multicamadas, com diferentes funções de ativação e quantidades de neurônios. Além disso, também são implementadas redes de função de base radial, as quais

apresentam diferentes quantidades de neurônios. É importante destacar que, nas RBFs, não é comum ter mais de uma camada escondida, como apontado por Silva, Spati e Flauzino (2016), e as funções de ativação dos neurônios são gaussianas.

3.3 Execução de algoritmos de treinamento supervisionado nas redes desenvolvidas

Após obter a base de dados e implementar a estrutura e a dinâmica de propagação de dados das redes neurais, é essencial aplicar os algoritmos de treinamento a diversas topologias de redes a fim de determinar qual delas oferece o desempenho mais satisfatório. A biblioteca Scikit-learn disponibiliza três otimizadores distintos: o método do gradiente estocástico (SGD), a estimativa de momento adaptativo (ADAM) e o algoritmo de Broyden-Fletcher-Goldfarb-Shanno com memória limitada (LBFGS). Cada um desses otimizadores é avaliado ao longo de até 500 épocas de treinamento para determinar qual se adapta melhor a esta situação. A rede neural de função de base radial utiliza um algoritmo de treinamento particular, no qual as saídas dos neurônios da camada oculta são determinadas por meio da função gaussiana, enquanto os pesos do neurônio de saída são obtidos por meio de regressão linear.

3.4 Validação dos treinamentos

Nesta fase, testes são conduzidos nas redes neurais, seguindo o método de validação cruzada com cinco partições. Nesse processo, são fornecidos valores de entrada, e as respostas geradas são analisadas e comparadas com as respostas esperadas, que provêm de um subconjunto do conjunto de dados chamado conjunto de teste.

A validação evidencia se a rede de fato foi capaz de generalizar ou identificar os padrões nas entradas, em vez de simplesmente memorizar os exemplos do conjunto de treinamento.

3.5 Avaliação das redes e definição da topologia mais adequada

Conforme abordado no Capítulo 2, existem várias métricas que podem ser usadas para avaliar a qualidade de um modelo de rede neural, como erro percentual absoluto, erro

quadrático médio e o coeficiente de determinação. Além disso, aspectos de carga computacional durante o treinamento ou na fase de execução também podem ser considerados. Notavelmente, o número de épocas necessário para alcançar o critério de parada do algoritmo de treinamento e o uso de recursos de memória e processamento durante a propagação de sinais constituem importantes parâmetros de qualidade.

Diante disso, nesta etapa, as métricas de desempenho das redes neurais são comparadas e usadas na definição da arquitetura mais adequada para o problema.

3.6 Implementação do sensor virtual para inferência em tempo real

Nesta fase, desenvolve-se uma aplicação capaz de estimar os valores de concentração de apatita a partir de outros parâmetros fornecidos pelo usuário. Nesse sentido, a rede neural escolhida nas etapas anteriores, já treinada, é usada com seu modelo de propagação de sinais nas entradas para a obtenção dos valores da saída.

3.7 Análise dos resultados

Ao final, é realizada uma análise dos resultados para avaliar as ideias discutidas ao longo do trabalho, apresentando as principais descobertas e contribuições obtidas. Também é fundamental destacar como as evidências coletadas validam ou invalidam os objetivos propostos.

Capítulo 4

Resultados

Neste capítulo, são explorados os resultados obtidos ao longo do estudo. Os números, gráficos e interpretações fornecem uma visão aprofundada do que foi descoberto sobre o assunto em questão.

4.1 Tratamento dos dados

Seleção de variáveis

Após adquirir o *dataset*, foi fundamental escolher as variáveis a serem usadas como entrada e saída do modelo, uma vez que nem todas as variáveis disponíveis em um processo são igualmente relevantes para o desenvolvimento de um modelo baseado em Redes Neurais Artificiais (RNAs).

É importante ressaltar que algumas medições podem não estar prontamente disponíveis. Por exemplo, para obter a massa do material flotado, é necessário realizar uma análise laboratorial. Portanto, incorporar essa variável no modelo iria de encontro ao propósito de criar um sensor virtual.

O Quadro 4.1 exibe as variáveis selecionadas após a análise do processo, destinadas a serem empregadas no desenvolvimento do sensor virtual.

Assume-se a existência de correlação entre as variáveis de entrada e de saída que justificam o modelo. A fim de avaliar a relevância das variáveis escolhidas como entradas do sistema, foi realizado o cálculo da matriz de correlação, a qual é exibida na Tabela 4.1.

Quadro 4.1: Lista de variáveis selecionadas

Variável	Unidade	Relação	Tipo
Concentração de coletor	mg/L	Direta	Entrada
pН		Inversa	Entrada
Tempo	min	Inversa	Entrada
Proporção de Palmitato	%	Inversa	Entrada
Proporção de Oleato	%	Direta	Entrada
Flotabilidade	%		Saída

Tabela 4.1: Matriz de correlação cruzada

	[]	pН	Tempo	Palmitato	Oleato	Flotabilidade
[]	1,000	0,049	-0,286	0,508	-0,459	0,399
pН	0,049	1,000	0,157	0,032	-0,023	-0,346
Tempo	-0,285	0,157	1,000	-0,092	0,084	-0,264
Palmitato	0,508	0,032	-0,092	1,000	-0,965	-0,155
Oleato	-0,459	-0,023	0,084	-0,965	1,000	0,170
Flotabilidade	0,399	-0,346	-0,265	-0,155	0,170	1,000

Ao examinar a matriz de correlação cruzada entre as variáveis, torna-se evidente que existem relações entre as variáveis de entrada e a variável de saída. Mesmo que não sejam altamente correlacionadas, essas variáveis ainda podem contribuir de forma significativa para o modelo.

Remoção de outliers

A base de dados, que consistia das variáveis selecionadas, continha informações imprecisas, incompletas e duplicadas. Como resultado, as entradas correspondentes foram eliminadas a fim de depurar os dados. A etapa subsequente envolveu a detecção de *outliers*, utilizando o método do intervalo interquartil, o qual apontou os valores -44,74 e 79,04 como limites inferiores e superiores, respectivamente. A Figura 4.1 exibe o *boxplot* da flotabilidade, onde é possível observar a presença de alguns pontos atípicos nos dados.

Figura 4.1: Boxplot da flotabilidade com outliers

Para evitar remover estes dados, optou-se por remover alguns registros com baixa flotabilidade, pois estes existem em maior quantidade no *dataset*, a fim de aumentar a média dos valores e, consequentemente, o limite superior. Após aplicar esta estratégia, o limite inferior e superior apresentaram os valores de -52.39 e 93,84, respectivamente. A Figura 4.2 apresenta o *boxplot* sem os *outliers*.

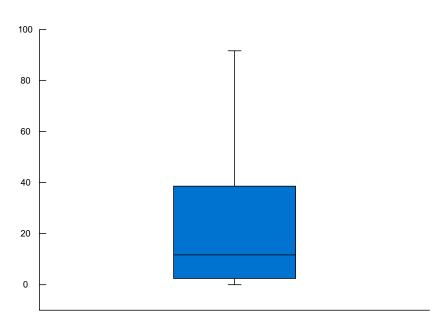


Figura 4.2: Boxplot da flotabilidade sem outliers

Fonte: Autoria Própria

Outra conclusão que pode ser obtida a partir da Figura 4.2 é que o terceiro quartil situase em torno de 40, indicando que 75% dos dados estão concentrados no intervalo de 0 a 40. A Figura 4.3 exibe o histograma da flotabilidade, onde é evidente que os dados com flotabilidade até 10% são mais frequentes na base de dados, sugerindo que o sensor pode ter um melhor desempenho quando operando dentro de certas faixas.

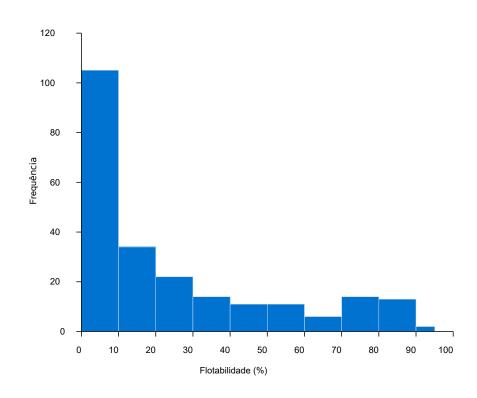


Figura 4.3: Histograma da flotabilidade

Fonte: Autoria Própria

Normalização:

Por último, o *dataset* passou por um processo de normalização, garantindo que todos os valores estivessem dentro do intervalo de 0 a 1. Esse procedimento foi adotado para evitar qualquer vantagem indevida de uma variável sobre as outras.

4.2 Implementação de diferentes topologias de redes neurais artificiais

Este trabalho utiliza a biblioteca de aprendizado de máquina, Scikit-learn para as redes PMCs, enquanto o código das RBFs é de autoria própria. Os códigos-fonte utilizados como

base para as PMCs e RBFs podem ser acessados nos seguintes links, respectivamente: github.com/Otavio414/tcc-pmc.git e github.com/Otavio414/tcc-rbf.git.

4.3 Algoritmos de treinamento

Foram experimentados três algoritmos diferentes no treinamento das redes PMCs. A Figura 4.4 ilustra o desempenho de cada um desses algoritmos, destacando que o LBFGS demonstrou os menores erros nesta situação, o que levou à sua escolha para o treinamento das redes PMCs.

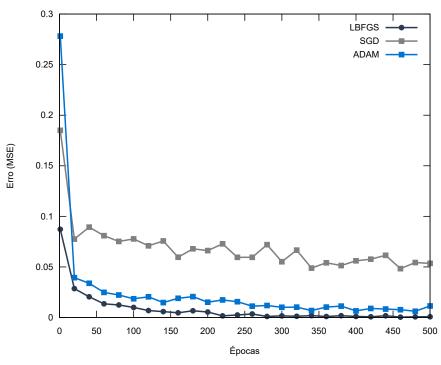


Figura 4.4: Desempenhos dos algoritmos de treinamento da PMC

Fonte: Autoria Própria

4.4 Avaliação das redes e definição da topologia mais adequada

Utilizando as redes treinadas de acordo com método de relação cruzada usando cinco partições, foram registrados os resultados para diferentes combinações. Os desempenhos das redes RBFs estão disponíveis na Tabela 4.2, enquanto os resultados das redes PMCs podem ser encontrados na Tabela 4.3.

Tabela 4.2: Resultados dos testes das RBFs.

Nº Neurônios	MSE (%)	RMSE (%)	MAE (%)	R ²
10	4,771	2,168	16,630	0,456
20	4,089	2,014	15,157	0,535
30	3,533	1,873	13,737	0,592
40	3,631	1,889	13,014	0,584
50	3,244	1,794	12,418	0,621
60	2,748	1,646	11,870	0,687
70	3,356	1,788	12,197	0,610
80	2,763	1,612	10,547	0,674
90	3,482	1,714	10,674	0,577
100	2,672	1,621	10,119	0,691
110	1,921	1,281	8,649	0,796
120	4,268	1,886	9,992	0,485
130	9,427	2,402	9,996	-0,169
140	13,297	2,665	9,787	-0,676
150	11,049	2,920	11,223	-0,336

Tabela 4.3: Resultados dos testes das PMCs.

Função de ativação: Linear						
N Neurônios		MSE (%)	RMSE (%)	MAE (%)	R ²	Número
1ª Camada	2ª Camada	WISE (%)	MVISE (70)	MAL (%)	K	de iterações
50	0	4,794	2,185	17,928	0,452	17
100	0	4,794	2,185	17,927	0,452	17
150	0	4,794	2,185	17,928	0,452	15
50	25	4,794	2,185	17,928	0,452	17
100	50	4,794	2,185	17,928	0,452	20
150	75	4,794	2,185	17,928	0,452	16
50	50	4,794	2,185	17,928	0,452	19
100	100	4,794	2,185	17,928	0,452	16
150	150	4,794	2,185	17,928	0,452	16
	Função	de ativação	o: Unidade L	inear Retific	cada	
N Neu	rônios	MSE (%)	RMSE (%)	MAE (%)	\mathbb{R}^2	Número
1ª Camada	2ª Camada	WISE (%)	MVISE (70)	MAL (%)	K	de iterações
50	0	2,752	1,589	8,101	0,683	1503
100	0	1,825	1,291	6,501	0,785	1655
150	0	1,886	1,269	6,101	0,780	1622
50	25	2,639	1,494	7,003	0,689	1528
100	50	2,099	1,341	5,737	0,753	1147
150	75	2,650	1,444	6,110	0,694	986
50	50	1,715	1,254	6,040	0,794	1612
100	100	1,520	1,139	4,759	0,821	1046
150	150	1,695	1,171	5,080	0,803	845
		Função de	ativação: Lo	ogística		
N Neu	rônios				\mathbf{D}^2	Número
N Neu	rônios 2ª Camada	Função de MSE (%)	ativação: Lo RMSE (%)	ogística MAE (%)	R ²	Número de iterações
					R ²	
1ª Camada	2ª Camada	MSE (%)	RMSE (%)	MAE (%)		de iterações
1ª Camada 50	2ª Camada 0	MSE (%)	RMSE (%) 1,287	MAE (%) 6,347	0,807	de iterações 9922
1ª Camada 50 100	2ª Camada 0 0	MSE (%) 1,670 2,621	RMSE (%) 1,287 1,593	MAE (%) 6,347 7,242	0,807 0,702	de iterações 9922 10401
1ª Camada 50 100 150	2ª Camada 0 0 0	MSE (%) 1,670 2,621 1,918	RMSE (%) 1,287 1,593 1,252	MAE (%) 6,347 7,242 8,218	0,807 0,702 0,789	de iterações 9922 10401 8271
1ª Camada 50 100 150 50	2ª Camada 0 0 0 0 25	1,670 2,621 1,918 5,353	RMSE (%) 1,287 1,593 1,252 1,887	MAE (%) 6,347 7,242 8,218 7,201	0,807 0,702 0,789 0,326	de iterações 9922 10401 8271 6951
1ª Camada 50 100 150 50 100	2ª Camada 0 0 0 25 50	MSE (%) 1,670 2,621 1,918 5,353 5,322	RMSE (%) 1,287 1,593 1,252 1,887 2,060	MAE (%) 6,347 7,242 8,218 7,201 7,464	0,807 0,702 0,789 0,326 0,437	de iterações 9922 10401 8271 6951 7599
1ª Camada 50 100 150 50 100 150	2ª Camada 0 0 0 25 50 75	1,670 2,621 1,918 5,353 5,322 1,687	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552	0,807 0,702 0,789 0,326 0,437 0,804	de iterações 9922 10401 8271 6951 7599 8143
1ª Camada 50 100 150 50 100 150 50	2ª Camada 0 0 25 50 75	1,670 2,621 1,918 5,353 5,322 1,687 1,427	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776	0,807 0,702 0,789 0,326 0,437 0,804 0,841	de iterações 9922 10401 8271 6951 7599 8143 7128
1ª Camada 50 100 150 50 100 150 50 100	2ª Camada 0 0 0 25 50 75 50 100 150	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631	de iterações 9922 10401 8271 6951 7599 8143 7128 7722
1ª Camada 50 100 150 50 100 150 50 100 150 50 100 150	2ª Camada 0 0 0 25 50 75 50 100 150	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ão de ativaç	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 The Hiperbólio	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631 0,657	de iterações 9922 10401 8271 6951 7599 8143 7128 7722
1ª Camada 50 100 150 50 100 150 50 100 150 50 100 150	2ª Camada 0 0 0 25 50 75 50 100 150 Funça	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223
1a Camada 50 100 150 50 100 150 50 100 150 50 N Neu	2ª Camada 0 0 0 25 50 75 50 100 150 Funça	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ão de ativaç	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 The Hiperbólio	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631 0,657	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223
1a Camada 50 100 150 50 100 150 50 100 150 50 100 150 100 150	2ª Camada 0 0 0 25 50 75 50 100 150 Funça	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ão de ativaç MSE (%)	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent RMSE (%)	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 The Hiperbólio MAE (%)	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631 0,657	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223 Número de iterações
1a Camada 50 100 150 50 100 150 50 100 150 50 100 150 N Neu 1a Camada 50	2ª Camada 0 0 0 25 50 75 50 100 150 Funça rônios 2ª Camada 0	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ão de ativaç MSE (%) 4,041	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent RMSE (%) 1,862	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 e Hiperbólio MAE (%) 8,449	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631 0,657 ca R ²	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223 Número de iterações 10141
1a Camada 50 100 150 50 100 150 50 100 150 50 100 150 N Neu 1a Camada 50 100	2ª Camada 0 0 0 25 50 75 50 100 150 Funça arônios 2ª Camada 0 0	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ão de ativaç MSE (%) 4,041 5,577	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent RMSE (%) 1,862 2,080	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 te Hiperbólio MAE (%) 8,449 8,999	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631 0,657 ca R ² 0,547 0,363	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223 Número de iterações 10141 7994
1a Camada 50 100 150 50 100 150 50 100 150 N Neu 1a Camada 50 100 150	2ª Camada 0 0 0 25 50 75 50 100 150 Funça arônios 2ª Camada 0 0	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ão de ativaç MSE (%) 4,041 5,577 12,905	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent RMSE (%) 1,862 2,080 2,805	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 The Hiperbólio MAE (%) 8,449 8,999 10,564	0,807 0,702 0,789 0,326 0,437 0,804 0,631 0,657 ca R ² 0,547 0,363 -0,590	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223 Número de iterações 10141 7994 7883
1a Camada 50 100 150 50 100 150 50 100 150 N Neu 1a Camada 50 100 150 50	2ª Camada 0 0 0 25 50 75 50 100 150 Funça rônios 2ª Camada 0 0 0 25	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ão de ativaç MSE (%) 4,041 5,577 12,905 2,763	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent RMSE (%) 1,862 2,080 2,805 1,610	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 te Hiperbólio MAE (%) 8,449 8,999 10,564 6,475	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631 0,657 ca R ² 0,547 0,363 -0,590 0,685	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223 Número de iterações 10141 7994 7883 3084
1a Camada 50 100 150 50 100 150 50 100 150 50 100 150 N Neu 1a Camada 50 100 150 50 100	2ª Camada 0 0 0 25 50 75 50 100 150 Funça arônios 2ª Camada 0 0 0 25 50	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ño de ativaç MSE (%) 4,041 5,577 12,905 2,763 4,419	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent RMSE (%) 1,862 2,080 2,805 1,610 1,975	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 e Hiperbólio MAE (%) 8,449 8,999 10,564 6,475 7,224	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631 0,657 ca R ² 0,547 0,363 -0,590 0,685 0,463	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223 Número de iterações 10141 7994 7883 3084 3028
1a Camada 50 100 150 50 100 150 50 100 150 N Neu 1a Camada 50 100 150 50 100 150	2ª Camada 0 0 0 25 50 75 50 100 150 Funça arônios 2ª Camada 0 0 25 50 75	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 ão de ativaç MSE (%) 4,041 5,577 12,905 2,763 4,419 2,439	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 ção: Tangent RMSE (%) 1,862 2,080 2,805 1,610 1,975 1,471	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 The Hiperbólio MAE (%) 8,449 8,999 10,564 6,475 7,224 6,315	0,807 0,702 0,789 0,326 0,437 0,804 0,631 0,657 ca R ² 0,547 0,363 -0,590 0,685 0,463 0,732	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223 Número de iterações 10141 7994 7883 3084 3028 3012
1a Camada 50 100 150 50 100 150 50 100 150 N Neu 1a Camada 50 100 150 50 100 150 50	2ª Camada 0 0 0 25 50 75 50 100 150 Funça rônios 2ª Camada 0 0 25 50 75 50	MSE (%) 1,670 2,621 1,918 5,353 5,322 1,687 1,427 3,179 2,879 6 de ativaç MSE (%) 4,041 5,577 12,905 2,763 4,419 2,439 3,541	RMSE (%) 1,287 1,593 1,252 1,887 2,060 1,283 1,109 1,569 1,608 2ão: Tangent RMSE (%) 1,862 2,080 2,805 1,610 1,975 1,471 1,706	MAE (%) 6,347 7,242 8,218 7,201 7,464 5,552 4,776 6,962 6,332 e Hiperbólio MAE (%) 8,449 8,999 10,564 6,475 7,224 6,315 6,981	0,807 0,702 0,789 0,326 0,437 0,804 0,841 0,631 0,657 ca R ² 0,547 0,363 -0,590 0,685 0,463 0,732 0,577	de iterações 9922 10401 8271 6951 7599 8143 7128 7722 8223 Número de iterações 10141 7994 7883 3084 3028 3012 3628

Após a análise dos resultados, a decisão foi tomar a topologia com o melhor desempenho de cada arquitetura. Optou-se pela configuração de 150 neurônios distribuídos em duas camadas ocultas, utilizando a função de ativação tangente hiperbólica para a Perceptron Multicamadas (PMC) e 110 neurônios para a Rede de Função de Base Radial (RBF), devido aos resultados mais favoráveis com menores erros e um coeficiente de determinação superior. Para treinar e testar essas topologias selecionadas, o conjunto de dados foi dividido em dois subconjuntos, com o objetivo de manter uma distribuição equilibrada de dados entre eles, conforme ilustrado no histograma da Figura 4.5.

Frequência O Flotabilidade (%) Fonte: Autoria Própria

Figura 4.5: Histograma da flotabilidade para cada subconjunto

As respostas de cada uma podem ser observadas nas Figuras 4.6 e 4.7. A Figura 4.6 representa a arquitetura PMC. A Figura 4.7 corresponde à arquitetura RBF. Embora os valores nas tabelas indiquem um desempenho superior da rede PMC, a análise dos gráficos de dispersão revela o comportamento das redes neurais em diferentes valores de flotabilidade. Ao examinar os gráficos, fica evidente que os pontos na representação da rede Perceptron multicamadas estão mais próximos da linha de tendência do que os pontos na representação da rede de função de base radial. Em outras palavras, as previsões da PMC estão próximas do comportamento encapsulado nos registros do *dataset*, tornando-a a escolha mais adequada para compor o sensor virtual proposto.

Figura 4.6: Gráfico da dispersão da rede PMC

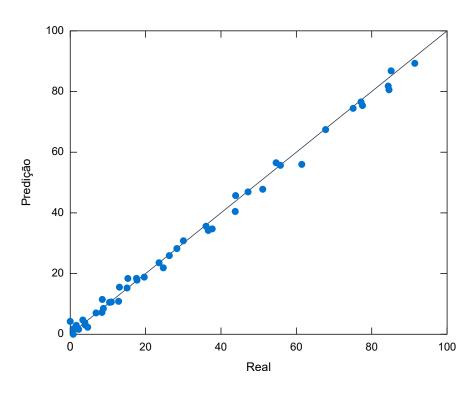
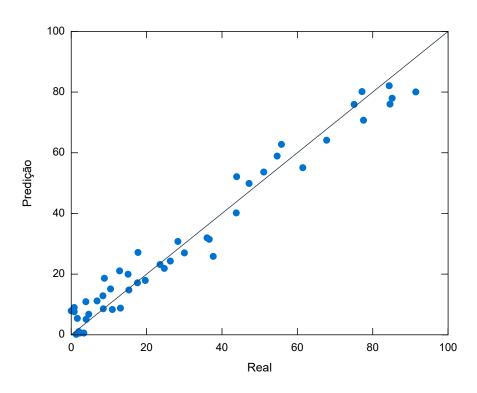


Figura 4.7: Gráfico da dispersão da rede RBF



Fonte: Autoria Própria

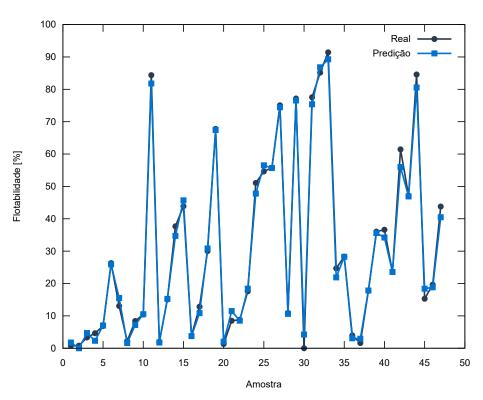
4.5 Implementação do sensor virtual

Conforme demonstrado na Tabela 4.4, os testes conduzidos revelaram um erro máximo de aproximadamente 5% e um coeficiente de determinação próximo a 1. Esses resultados indicam que as predições estão em excelente concordância com os valores obtidos por meio da análise laboratorial. Essa concordância entre os valores pode ser observada na Figura 4.8.

Tabela 4.4: Desempenho do sensor virtual

MSE (%)	0,049
MAE (%)	1,691
Erro Máximo (%)	5,404
R^2	0,995

Figura 4.8: Resposta do sensor virtual para diferentes amostras



Fonte: Autoria Própria

A interface gráfica desenvolvida para interação com o usuário é ilustrada nas Figuras 4.9, 4.10, 4.11. Na Figura 4.9, é possível visualizar a guia destinada à inferência única. Nesta guia, o usuário fornece os valores de concentração de Oleato e Palmitato, concentração do coletor, pH e tempo, após o que a aplicação retorna o valor da flotabilidade correspondente.

Sensor Virtual Aplicado à Concentração de Apatita por Flotação Inferência única Inferência múltipla Editar modelo Concentração 48.2 de Oleato (%) 55.48% Concentração 27.1 de Palmitato (%) Concentração 20 do coletor (mg/L) рΗ Tempo (min) Inferir

Figura 4.9: Guia de inferência única da aplicação

A funcionalidade de inferência múltipla permite que o utilizador importe um arquivo CSV contendo os dados de entrada e a aplicação retorna o valor de flotabilidade para cada linha na tabela. Após a realização das inferências, o usuário tem a opção de salvar uma tabela CSV contendo os dados completos. A captura de tela relacionada com esta funcionalidade pode ser vista na Figura 4.10.

Sensor Virtual Aplicado à Concentração de Apatita por Flotação CEFET-MG Inferência única Inferência múltipla Editar modelo **.** Exportar Q Inferir 👤 Importar Oleato (%) Palmitato (%) Flotabilidade (%) Concentração do coletor (mg/L) pΗ Tempo (min) 100.0 0.0 6.0 4.06 100.0 0.0 10.0 12.0 7.0 7.19 100.0 10.0 7.0 11.30 0.0 9.0 100.0 0.0 20.0 12.0 7.0 11.88 100.0 0.0 20.0 10.5 7.0 18.28 7.0 56.25 100.0 0.0 20.0 9.0 20.0 7.0 74.33 100.0 0.0 6.0 7.5 100.0 0.0 20.0 3.0 76.38 100.0 0.0 20.0 7.5 5.0 87.11 75.0 0.0 7.5 7.0 0.00 75.0 11.5 1.0 7.5 7.0 1.05 75.0 11.5 5.0 9.0 7.0 7.86 75.0 11.5 5.0 6.0 3.0 25.96 75.0 11.5 10.0 12.0 7.0 12.61 34.41 75.0 75.0 11.5 15.0 6.0 7.0 67.19 20.0 10.5 7.0 75.0 11.5 7.96 75.0 11.5 30.0 9.0 3.0 34.22 48.2 27.1 10.0 10.5 7.0 1.93 27.1 7.5 7.0 11.19 48.2 7.0 27.1 15.0 9.0 5.64 48.2 27.1 15.0 6.0 7.0 30.41 48.2 27.1 20.0 9.0 7.0 46.64

Figura 4.10: Guia de inferência múltipla da aplicação

Com o objetivo de permitir a reconfiguração da rede neural utilizada no sensor virtual para se adaptar a situações diferentes das utilizadas em seu treinamento original, foi adicionada uma seção dedicada à modificação do modelo. Nessa seção, o usuário deve disponibilizar dois arquivos CSV: um para treinamento e outro para teste. Após o término do treinamento, o usuário tem a capacidade de avaliar o desempenho do sensor reajustado, bem como comparar suas respostas com os dados de teste. A imagem relacionada a essa funcionalidade, está ilustrada na Figura 4.11.

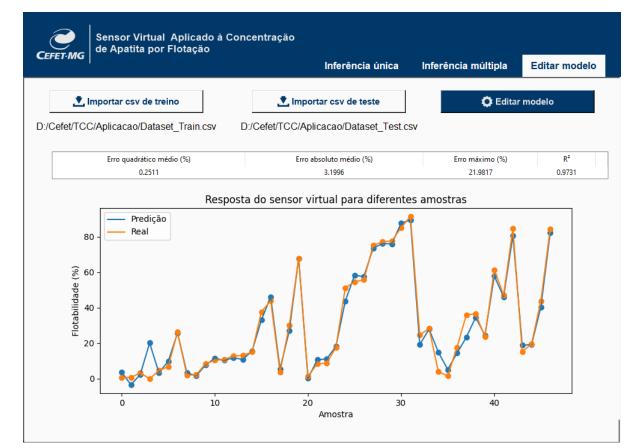


Figura 4.11: Guia de edição do modelo

Os resultados da validação do sensor virtual demonstram um desempenho satisfatório, apresentando um erro máximo de 5,40%, um erro médio quadrático de aproximadamente 0,05%, um erro médio absoluto de 1,69% e um coeficiente de determinação de 0,99. Além disso, o tempo médio necessário para cada inferência é de 1ms. Na fase de treinamento, o tempo médio é de 10s, e são realizadas aproximadamente 1900 épocas de treinamento. Esses indicadores evidenciam a exatidão e a confiabilidade do modelo proposto, ressaltando sua habilidade em inferir a flotabilidade da apatita.

Capítulo 5

Considerações finais

Em conclusão, a efetiva implementação de um sensor virtual baseado em redes neurais tem o potencial de contribuir significativamente para a indústria de mineração, especialmente no contexto dos desafios enfrentados ao medir variáveis como a concentração de minerais na polpa do minério durante o processo de flotação. Este estudo evidencia que os algoritmos de inteligência artificial, em particular as redes neurais artificiais, apresentam uma abordagem confiável, eficiente e economicamente viável para analisar esses processos complexos.

A introdução deste sensor virtual oferece uma alternativa promissora e economicamente viável às análises laboratoriais tradicionais, contribuindo assim para a otimização e monitoramento eficaz dos processos de flotação na indústria de mineração.

Com base nos resultados positivos evidenciados no capítulo anterior, fica evidente que a aplicação de algoritmos de inteligência artificial na indústria de mineração não apenas supera os desafios anteriores na medição de variáveis, mas também abre portas para futuros estudos.

Com o propósito de aprimorar esta pesquisa, sugerem-se como futuras linhas de trabalho:

- Adquirir uma base de dados que contemple cenários distintos daqueles explorados neste estudo, incluindo diferentes valores de concentração do coletor, pH, tempo, proporções de Palmitato e Oleato;
- Expandir as saídas para os minerais de ganga (dolamita, calcita...);
- Desenvolver sensores virtuais destinados a outros processos de mineração, como moagem, cominuição e lixiviação, ampliando assim a aplicabilidade da pesquisa para além do escopo inicial.

Referências

ABIODUN, Oludare Isaac et al. Comprehensive review of artificial neural network applications to pattern recognition. **IEEE Access**, IEEE, v. 7, p. 158820–158846, 2019.

AGUIRRE, Luis Antonio. **Introdução à identificação de sistemas**. 4. ed.: Editora UFMG, 2015.

AI, Mingxi et al. Two-Stream Deep Feature-Based Froth Flotation Monitoring Using Visual Attention Clues. **IEEE Transactions on Instrumentation and Measurement**, v. 70, p. 1–14, 2021. DOI: 10.1109/TIM.2020.3026456.

ANDA. Mai. 2023. Disponível em: https://anda.org.br/pesquisa_setorial/.

BALBINOT, Alexandre; BRUSAMARELLO, Valner João. **Instrumentação e Fundamentos de Medidas**. Edição: Editora LTC. 2. ed.: Editora LTC, 2010. v. 1.

BODYANSKIY, Yevgeniy; PIRUS, Anastasiia; DEINEKO, Anastasiia. Multilayer Radial-basis Function Network and its Learning. In: 2020 IEEE 15th International Conference on Computer Sciences and Information Technologies (CSIT). Set. 2020. v. 1, p. 92–95. DOI: 10.1109/CSIT49958.2020.9322001.

BULATOVIC, Srdjan. Handbook of Flotation Reagents Chemistry, Theory and Practice: Flotation of Sulfide Ores. **Handbook of Flotation Reagents: Chemistry, Theory and Practice Flotation of Sulfide Ores**, v. 3, jan. 2007. DOI:

10.1016/B978-0-444-53029-5.X5009-6.

CHAVES, Arthur Pinto; FILHO, Laurindo de Salles L.; BRAGA, Paulo Fernando A. **TRATAMENTO DE MINÉRIOS**. Edição: Adão B. (Ed.) Luz, J.A. (Ed.) Sampaio e S.C.A. (E.d.). França. 5. ed.: Centro de Tecnologia Mineral, 2010.

CHICCO, Davide; WARRENS, Matthijs J; JURMAN, Giuseppe. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. **PeerJ Computer Science**, PeerJ Inc., v. 7, e623, 2021.

DERHY, Manar et al. Review of the Main Factors Affecting the Flotation of Phosphate Ores. **Minerals**, v. 10, n. 12, 2020. ISSN 2075-163X. DOI: 10.3390/min10121109. Disponível em: https://www.mdpi.com/2075-163X/10/12/1109.

DONGARE, AD; KHARDE, RR; KACHARE, Amit D et al. Introduction to artificial neural network. **International Journal of Engineering and Innovative Technology (IJEIT)**, Citeseer, v. 2, n. 1, p. 189–194, 2012.

FRADEN, Jacob. **Handbook of Modern Sensors: Physics, Designs, and Applications**. Edição: LLC 2010 Springer ScienceþBusiness Media. 4. ed.: Springer ScienceþBusiness Media, LLC 2010, 2010.

GALBADRAKH, Byambasuren. Mineral Processing Technology. Out. 2006.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Edição: MIT Press. MIT Press, 2016.

GUEDES, Érick Victor De Oliveira. Aplicação de soft sensor baseado em redes neurais artificiais e random forest para predição em tempo real do teor de ferro no concentrado da flotação de minério de ferro. **Universidade Federal de Ouro Preto**, 2020.

GUICHENG, Wang et al. Soft-sensing Prediction of Mining SAG Mill Load. In: 2022 34th Chinese Control and Decision Conference (CCDC). 2022. P. 4048–4052. DOI: 10.1109/CCDC55256.2022.10034384.

GÜNTHER, Frauke; FRITSCH, Stefan. Neuralnet: training of neural networks. **R J.**, v. 2, n. 1, p. 30, 2010.

GUO, Xuqi et al. Soft sensor for ball mill load based on multi-view domain adaptation learning. In: 2019 Chinese Control And Decision Conference (CCDC). Jun. 2019. P. 6082–6087. DOI: 10.1109/CCDC.2019.8832908.

HUANG, Qilan; MENG, Hao; GUO, Lijin. Research on Soft Sensor of Effluent Ammonia Nitrogen Based on GNPSO-LSTM. In: 2022 34th Chinese Control and Decision Conference (CCDC). Ago. 2022. P. 4536–4541. DOI: 10.1109/CCDC55256.2022.10034179.

IBM. 2022. Disponível em: https://www.ibm.com/blogs/ibm-comunica/estudo-ibm-41-das-empresas-no-brasil-ja-implementaram-ativamente-inteligencia-artificial-em-seus-negocios/.

INMETRO. **Vocabulário Internacional de Metrologia**. Edição: Inmetro. 1. ed.: Inmetro, 2012. Disponível em:

<http://www.inmetro.gov.br/inovacao/publicacoes/vim_2012.pdf>.

JIAN, Hu; LIHUI, Cen; YONGFANG, Xie. Design of Soft Sensor for Industrial Antimony Flotation Based on Deep CNN. In: 2020 Chinese Control And Decision Conference (CCDC). 2020. P. 2492–2496. DOI: 10.1109/CCDC49329.2020.9164722.

JONES, J.M.C.; GUINEL, F.C.; ANTUNES, P.M. Carbonatites as rock fertilizers: A review. **Rhizosphere**, v. 13, p. 100188, 2020. ISSN 2452-2198. DOI:

https://doi.org/10.1016/j.rhisph.2020.100188. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S2452219819301909>.

JÚNIOR, Alberto Colli Badino; CRUZ, Antonio José Gonçalves Da. **Balanços de massa eenergia na análise deprocessos químicos**. Edição: UAB-UFSCar. São Carlos, SP, Brasil, 2011.

KE, Wensi et al. Soft sensor development and applications based on LSTM in deep neural networks. In: 2017 IEEE Symposium Series on Computational Intelligence (SSCI). Nov. 2017. P. 1–6. DOI: 10.1109/SSCI.2017.8280954.

KEBER, Sebastian et al. Reverse flotation of synthetic anglesite from a zinc leaching residue. Jun. 2021. DOI: 10.13140/RG.2.2.18784.20484.

KRUG, Francisco José; ROCHA, Fábio Rodrigo Piovezani. Métodos de Preparode Amostras para Análise Elementar, 2019.

LEJA, Jan. **Surface Chemistryof Froth Flotation**. 2. ed.: Springer Science+Business Media, LLC, 2004. v. 1.

LIU, Qing; WANG, Zhengsong et al. Soft Sensor Modeling and Adaptive Model Correction Strategy for Gold Cyanide Leaching Process. In: 2019 Chinese Control And Decision Conference (CCDC). 2019. P. 6065–6070. DOI: 10.1109/CCDC.2019.8832585.

LIU, Yuanqing; ZHU, Ziyan; ZHU, Xianglin. Soft sensor modeling for key parameters of marine alkaline protease MP fermentation process. In: 2018 Chinese Control And Decision Conference (CCDC). Jun. 2018. P. 6149–6154. DOI: 10.1109/CCDC.2018.8408209.

MARINKOVIĆ, Zlatica et al. A neural network approach for safety monitoring applications. In: 2016 IEEE Sensors Applications Symposium (SAS). Abr. 2016. P. 1–5. DOI: 10.1109/SAS.2016.7479862.

MARTIN, Dominik; KÜHL, Niklas; SATZGER, Gerhard. Virtual Sensors. **Business & Information Systems Engineering**, v. 63, n. 3, p. 315–323, jun. 2021. ISSN 1867-0202. DOI: 10.1007/s12599-021-00689-w. Disponível em: https://doi.org/10.1007/s12599-021-00689-w.

MONTANARES, Mauricio et al. Assessing machine learning based approaches for silica concentration estimation in iron froth flotation. In: 2021 IEEE International Conference on Automation/XXIV Congress of the Chilean Association of Automatic Control (ICA-ACCA). Mar. 2021. DOI: 10.1109/ICAACCA51523.2021.9465297.

O'SULLIVAN, Gary et al. The trace element composition of apatite and its application to detrital provenance studies. **Earth-Science Reviews**, Elsevier, v. 201, p. 103044, 2020.

OZANICH, Emma; GERSTOFT, Peter; NIU, Haiqiang. A feedforward neural network for direction-of-arrival estimation. **The journal of the acoustical society of America**, Acoustical Society of America, v. 147, n. 3, p. 2035–2048, 2020.

RASCHKA, Sebastian; MIRJALILI, Vahid. **Python machine learning**. 3. ed.: Packt Publishing Ltd, 2019.

SANTOS, Leandro Henrique. Minérios Fosfáticos Ígneos com Ganga Carbonática: Estudos Fundamentais. **UNIVERSIDADE FEDERAL DE MINAS GERAIS**, 2022.

SANTOS LIMA, Jayne dos; MAURICIO VILLANUEVA, Juan Moises;
CAVALCANTI CATUNDA, Sebastian Yuri. Modeling a Virtual Flow Sensor in a
Sugar-Energy Plant using Artificial Neural Network. In: 2022 IEEE International
Instrumentation and Measurement Technology Conference (I2MTC). Mai. 2022. P. 1–6. DOI:

10.1109/I2MTC48687.2022.9806538.

SCIKIT-LEARN. Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPRegressor.html.

SHARKAWY, Abdel-Nasser. Principle of neural network and its main types. **Journal of Advances in Applied & Computational Mathematics**, v. 7, p. 8–19, 2020.

SHARMA, Jatin. Adsorpion and microflotation studies with pure minerals and an arylhydroxamic acid collector. Edição:

Thunder Bay Faculty of Engineering Lakehead University. 2009.

SILVA, Ivan Nunes da; SPATI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes** neurais artificiais: para engenharia e ciências aplicadas. second: Artliber, 2016.

SINGH, S K. **Industrial Instrumentation and Control**. Edição: Tata McGraw. 3. ed.: Tata McGraw, 2010.

SIS, H.; CHANDER, S. Reagents used in the flotation of phosphate ores: a critical review. **Minerals Engineering**, v. 16, n. 7, p. 577–585, 2003. ISSN 0892-6875. DOI:

https://doi.org/10.1016/S0892-6875(03)00131-6. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0892687503001316>.

SOBREIRA, Sandro Geraldo Alves. Aplicação de sensores virtuais baseados em aprendizado de máquina para estimativa de vazão mássica de minério de ferro em correias transportadoras. **Universidade Federal de Ouro Preto**, 2021.

TEGEN, Agnes et al. Collaborative Sensing with Interactive Learning using Dynamic Intelligent Virtual Sensors. **Sensors**, v. 19, n. 3, 2019. ISSN 1424-8220. DOI:

THOMAZINI, Daniel; ALBUQUERQUE, Pedro Urbano Braga de. **Sensores Industriais:** Fundamentos e Aplicações. Edição: Érica. 4. ed.: Érica, 2009.

10.3390/s19030477. Disponível em: https://www.mdpi.com/1424-8220/19/3/477.

WANCHEN, Li. Analysis on the Weight initialization Problem in Fully-connected Multi-layer Perceptron Neural Network. In: 2020 International Conference on Artificial Intelligence and Computer Engineering (ICAICE). Out. 2020. P. 150–153. DOI:

10.1109/ICAICE51518.2020.00035.

WANG, Yi et al. Comparative study of landslide susceptibility mapping with different recurrent neural networks. **Computers & Geosciences**, Elsevier, v. 138, p. 104445, 2020.

WU, Wei et al. Time series analysis of human brucellosis in mainland China by using Elman and Jordan recurrent neural networks. **BMC infectious diseases**, BioMed Central, v. 19, n. 1, p. 1–11, 2019.

ZHANG, Haotian; ZHANG, Lin; JIANG, Yuan. Overfitting and Underfitting Analysis for Deep Learning Based End-to-end Communication Systems. In: 2019 11th International Conference on Wireless Communications and Signal Processing (WCSP). Out. 2019. P. 1–6. DOI: 10.1109/WCSP.2019.8927876.

ZHANG, Hongye; YANG, Cuili; QIAO, Junfei. Soft-Sensing Method of Effluent Ammonia Nitrogen Based on Emotional Neural Network. In: 2021 China Automation Congress (CAC). Out. 2021. P. 85–90. DOI: 10.1109/CAC53003.2021.9728113.

FOLHA DE ASSINATURAS

Emitido em 18/12/2023

CÓPIA DO TRABALHO Nº 232/2023 - DELMAX (11.57.05)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 18/12/2023 20:43) LEANDRO RESENDE MATTIOLI

PROFESSOR ENS BASICO TECN TECNOLOGICO
DELMAX (11.57.05)
Matrícula: ###731#3

(Assinado digitalmente em 18/12/2023 19:19) OTÁVIO DOS SANTOS AMARAL

DISCENTE
Matrícula: 2019#####8

Visualize o documento original em https://sig.cefetmg.br/documentos/ informando seu número: 232, ano: 2023, tipo: CÓPIA DO TRABALHO, data de emissão: 18/12/2023 e o código de verificação: ca0e30c042