

REDES NEURAIS ARTIFICIAIS APLICADAS NA PREDIÇÃO DO TEMPO REMANESCENTE PARA A MANUTENÇÃO DE UM VIRADOR DE VAGÕES

Laís Marino, laismbp@gmail.com¹

Jánes Landre Jr., janes@pucminas.br¹

Cádmio Augusto Rodrigues Dias, diascadm@gmail.com¹

Bernardo Rocha, bernardo.rocha@vale.com²

¹Pontifícia Universidade Católica de Minas Gerais, Av. Dom José Gaspar, 500 – Belo Horizonte/MG, Brasil – CEP 30535910

²Vale AS, Av. Dante Michelini, 5500 – Vitória/ES, Brasil – CEP 29090860

Resumo: A Indústria 4.0 aborda os desafios exigidos pelo mercado, atualmente, como aumento da segurança e planejamento de tarefas. Neste contexto, a Inteligência Artificial agrega valor à indústria ao possibilitar a realização de tarefas imprevistas que exigem adaptação e capacidade de resolução de problemas. A indústria da mineração mostra-se ideal para a transformação digital, por ser um desafio avaliar as condições dos ativos e possuir grandes ambientes e muitos ativos. Para aumentar a eficiência de processos em ambientes onde estão envolvidos ativos que se desgastam com o tempo, a manutenção preditiva revela-se importante, visto que possibilita melhorar a confiabilidade de ativos e o planejamento de reparos. O aprendizado de máquina é considerado uma solução inovativa para a sua implementação, mas a literatura sobre Redes Neurais Artificiais (RNAs) para predição de vida remanescente é limitada, principalmente para aplicações em cenários reais e que relatem o desempenho do modelo. Portanto, este estudo contribui com a aplicação de RNAs em cenário real da indústria de mineração. O objetivo é avaliar o desempenho de RNAs para o monitoramento de danos em ativos, a fim de auxiliar o planejamento da manutenção. Este trabalho limitou-se a prever o quanto próximo do momento de parada está o equipamento. Na metodologia, definiu-se o objeto de estudo, desenvolveram-se os modelos supervisionados para previsão, coletou-se o banco de dados, realizou-se um pré-processamento, e aplicou-se o modelo no banco de dados. As RNAs foram usadas na previsão do momento de parada para manutenção de um Virador de Vagões, a partir do banco de dados de motores do seu sistema Alimentador, o qual foi definido pelas necessidades da indústria. Comparou-se a capacidade de generalização e previsão para diversas topologias de RNAs com entradas variantes no tempo, diferentes tamanhos de janelamento dos dados e tipos de treinamento para a previsão de um passo. Por fim, foi calculado o intervalo de confiança das redes pela Máxima Verossimilhança. O resultado foi considerado satisfatório, com um erro relativo médio abaixo de 5,0% e o intervalo de confiança de teste (95%) inferior a 1,1%, mostrando que as RNAs apresentaram potencial para auxiliar no planejamento da manutenção. As redes convergiram e mostraram-se aptas para previsão temporal. O conhecimento das variáveis envolvidas para utilização nas RNAs revelou-se importante, visto que variáveis de entrada sem relação direta com a saída pretendida podem dificultar a convergência da rede e contribuir com o aumento do erro da resposta obtida.

Palavras-chave: Redes Neurais Artificiais, Equipamento de Mineração, Vida Útil Remanescente

1. INTRODUÇÃO

A quarta revolução industrial, conhecida como Indústria 4.0, surgiu na Alemanha como um “fenômeno inevitável para o futuro”, abordando os desafios exigidos pelo mercado atualmente, como flexibilidade, cadeia de suprimentos complexa, ambientes de produção flexíveis e eficientes, aumento da segurança de processos, planejamento de tarefas e qualidade da documentação (Kardec e Nascif, 2010; Drath e Horch, 2014; Takeda *et al.*, 2016). A rede de conexões entre humanos, máquinas e objetos tornou-se mais complexa no âmbito da Indústria 4.0. Seu processo de implantação permeia a necessidade de transformar dados e informações em conhecimento, a partir de interpretações contextualizadas, auxiliando a tomada de decisão (Tupa, Simota e Steiner, 2017).

Neste contexto a Inteligência Artificial (IA) agrega valor à indústria ao possibilitar a realização de tarefas imprevistas que exigem adaptação e capacidade de resolução de problemas, ao oferecer suporte à ação ágil e ao potencial de aumentar a eficiência e reduzir o uso de recursos e os custos de operação. (*Technology Scenario “Artificial Intelligence in Industrie 4.0”*, 2019). A IA aplicada à indústria utiliza como tecnologias facilitadoras *Big Data*, processamento de dados, aprendizado de máquina, tecnologias de plataforma capacitadoras para as demais operações, tecnologias de operação para criação de valor e apoio à tomada de decisão e tecnologia homem-máquina para garantir a autonomia e interação das partes interessadas.

A indústria da mineração ainda está incipiente no que diz respeito à transformação de dados em conhecimento e se mostra ideal para a transformação digital, por ser um desafio avaliar as condições dos ativos em relação aos cronogramas de manutenção e por possuir grandes ambientes e muitos ativos (Zhou *et al.*, 2017; Dehran, Agrawal e Midha, 2018). A manutenção preditiva é um método importante para melhorar a eficiência em ambientes onde estão envolvidos ativos que se desgastam com o tempo, por isso vem se tornando popular na indústria da mineração, visto que possibilita melhorar a eficácia da operação e a confiabilidade de ativos, o planejamento do reparo do ativo e prolongamento de sua vida remanescente. No contexto da Indústria 4.0, a manutenção preditiva inclui, principalmente, a determinação do tempo de vida remanescente, a detecção de falhas e anomalias, a eficiência, o custo, a confiabilidade e a otimização do agendamento de manutenções. Ainda há a necessidade da implementação de referenciais teóricos em ambientes industriais reais e muitas portas abertas na manutenção preditiva, sendo o aprendizado de máquina uma solução inovativa para a sua implementação (Kruczek *et al.*, 2019; Çınar *et al.*, 2020; Dalzochio *et al.*, 2020; Rastogi *et al.*, 2020).

Çınar *et al.* (2020) observaram um aumento significativo ao longo dos anos de pesquisas relacionadas à aplicação de técnicas de aprendizado de máquina da manutenção preditiva no contexto na Indústria 4.0, visto que consideram a manutenção preditiva inevitável para a manufatura inteligente e importante para melhorar a eficiência de ativos que deterioram com o tempo.

Na mineração Shahzad, Rehman, Ahmed (2017) atuaram no pré-processamento de banco de dados para a mineração de dados a partir da utilização de Algoritmos Genéticos para estimar valores faltantes em um banco de dados. Lee (2019) apresentou estudos de caso em diferentes minas utilizando aprendizado de máquina tanto para selecionar locais de exploração de recursos minerais e aumentar a eficiência do plano de desenvolvimento da mina, bem como para previsão de falhas e tempos de manutenção. Kahraman (2018) propôs um plano de manutenção de caminhões de mineração a partir de técnicas sequenciais de mineração de padrões, usadas para fazer previsões sobre o tempo de manutenção de caminhões de mineração. Patil *et al.* (2021) desenvolveram modelos de predição de vida remanescente para caminhões de minas subterrâneas, cuja saída incluiu um indicador de saúde do ativo em percentual, melhorando em 9% o indicador de eficiência geral do equipamento. Davite (2021) desenvolveu uma ferramenta para modelar cenários complexos de mineração a partir do aprendizado de máquina Bayesiano, permitindo a projeção de ações futuras e o auxílio à tomada de decisões.

As RNAs têm sido aplicadas em tarefas de previsão em uma ampla gama de atividades. Nascimento *et al.* (2020) propuseram um modelo de rede recorrente de Elman para identificar a zona de t horas até a falha de motores aeronáuticos. Kang *et al.* (2021) obtiveram o melhor desempenho para previsão do índice de saúde de motores aeronáuticos com um modelo de redes *Perceptron* de Múltiplas Camadas (PMC) em conjunto com a Análise de Componentes Principais. As RNAs também foram utilizadas para prognóstico da vida remanescente de baterias de lítio por Qu *et al.* (2019), que concluíram que os principais parâmetros da RNA influenciam significativamente a precisão do modelo. Na literatura é possível perceber a necessidade de buscar o melhor modelo de previsão para os dados de cada estudo, o que também foi observado por Xu e Saleh (2021), visando obter um modelo com melhor desempenho para o objetivo pretendido, visto que a acurácia pode variar de acordo com características dos dados, da arquitetura e de parâmetros do modelo.

Os benefícios das Redes Neurais Artificiais (RNAs) na indústria podem incluir auxiliar na manutenção preditiva, o que pode gerar economia de custos (Wang e Wang, 2018). No entanto, a literatura sobre RNAs e suas variações para previsão de vida restante é restrita e até mesmo escassa para aplicações em cenários de testes reais que relatam o desempenho do modelo (Elsheikh, Yacout e Ouali, 2019). É um desafio para aplicações industriais no que tange à manutenção preditiva obter uma precisão de previsão bem acima de 90%, considerando dificuldades inerentes ao cenário do setor de mineração, como a escassez de dados e dados desequilibrados. Além disto, a inteligibilidade e a compreensão dos métodos de IA precisam ser melhoradas. Portanto, faz-se necessária a pesquisa para resolver questões em aberto, como maneiras de lidar com a falta de dados, o desenvolvimento de métodos com erros muito baixos, desconhecimento de incertezas e métodos com pouca configuração e necessidades de engenharia, a fim de tornar as aplicações de IA intuitivas e compreensivas (*Technology Scenario "Artificial Intelligence in Industrie 4.0"*, 2019).

O aprendizado de máquina no contexto de IA tem se mostrado promissor em aplicações de previsão. A resposta dos algoritmos pode ser dada a partir de diferentes dados de entrada, como, por exemplo, dados históricos de um ativo. Suas vantagens incluem a capacidade de lidar com dados variados de alta dimensão e de extrair relações ocultas entre os dados de sistemas complexos e dinâmicos, permitindo a integração de informações e possibilitando a previsão de resultados futuros (Cardoso, 2020; Çınar *et al.*, 2020).

Este trabalho tem como objetivo avaliar a aplicabilidade de RNAs para monitoramento da evolução de danos em ativos, ao prever o tempo até a próxima parada, para auxiliar no planejamento de manutenção em dados reais do setor de mineração. As RNAs foram escolhidas por possuírem boa capacidade de autoaprendizagem, adaptação, robustez, memória e habilidade para lidar com não-linearidade, apesar de sua arquitetura e parâmetros serem incertos para obtenção do melhor desempenho (Hu *et al.*, 2019). Primeiramente é apresentada uma breve revisão de RNAs dependentes do tempo. Ao longo da metodologia são apresentados o banco de dados utilizado, as diferentes topologias de RNA englobadas no estudo, divisão dos dados para o processo de validação cruzada e o algoritmo para o cálculo do intervalo de confiança das RNAs. Por fim, são apresentados os resultados da comparação dos erros obtidos nas diferentes arquiteturas de RNA.

Foram utilizados dados de reais de um componente de um ativo de mineração, limitados a um período de 13 meses de coletas. Os modelos foram programados em Matlab, abrangendo diferentes arquiteturas de RNAs PMC com janelamento de dados, dada a característica temporal do banco de dados de degradação. As limitações do estudo compreenderam: a falta de um especialista para auxiliar o desenvolvimento do modelo, principalmente na etapa de seleção de variáveis

relevantes; a utilização dos dados, conforme foram disponibilizados, assumindo que estes dados estão completos e íntegros, de acordo com unidade de medida fornecida para cada variável.

2. METODOLOGIA

A metodologia deste estudo seguiu as seguintes etapas: definição do objeto de estudo; desenvolvimento do modelo supervisionado para previsão; pré-processamento do banco de dados do objeto de estudo; aplicação do modelo no banco de dados do objeto de estudo.

2.1. Redes neurais artificiais

As Redes Neurais Artificiais são apropriadas principalmente para o uso em sistemas complexos, de grande escala, cujas informações são pouco claras, podendo ser aplicadas a sistemas que possuem o comportamento dependente do tempo, em que as entradas e saídas da rede, em um determinado instante, estejam vinculadas aos seus valores em momentos anteriores. Os modelos de RNAs apresentam vantagens sobre outros modelos de aprendizado de máquina no que diz respeito ao tratamento de dados aleatórios, incertezas e dados não lineares (AGUIRRE, 2000; LJUNG, 1998 apud Silva, Spatti e Flauzino, 2010, p. 138; Yan *et al.*, 2017).

O neurônio é a célula elementar da rede neural e têm como função a condução de impulsos. O modelo não linear de um neurônio artificial pode ser representado de forma genérica pela Figura 1a. Os sinais de entrada x_1 a x_n são adquiridos externamente e normalizados em um intervalo entre 0 e 1 ou -1 e 1 para melhor eficiência computacional, passando para a mesma escala sinais de grandezas diferentes, como mostrado na Eq. (1). As sinapses são a conexão entre uma entrada x_j ao neurônio k e possuem uma força de ligação, que pode ser positiva ou negativa, chamada peso sináptico w_{kj} – sendo o primeiro índice (k) referente ao neurônio e o segundo (j) à entrada. O combinador linear (Σ) faz a soma ponderada dos sinais de entrada com o respectivo peso sináptico, resultando em um potencial de ativação. No entanto, para haver ativação da saída do neurônio, é preciso que este resultado esteja em um patamar apropriado, o qual é definido pelo limiar de ativação ou bias. A diferença entre o combinador linear e bias é denominado potencial de ativação, ou seja, se essa diferença for positiva, o potencial é excitatório, se for negativa, será inibitório. Por fim, a função de ativação limita a amplitude do sinal de saída do neurônio (y_k), que normalmente é um intervalo unitário fechado, entre 0 e 1, ou alternado, entre -1 e 1 (Haykin, 2001; Silva, Spatti e Flauzino, 2010).

$$X_{normalizado} = \frac{X - X_{mínimo}}{X_{máximo} - X_{mínimo}} \quad (1)$$

O processo de treinamento de uma RNA consiste na atualização dos pesos sinápticos até que um critério de parada estabelecido seja alcançado. Cada iteração deste processo, em que todo o conjunto de treinamento é usado para alterar os pesos sinápticos, é denominada época. Existem diversas técnicas para o treinamento de redes neurais, divididas em treinamento supervisionado ou não supervisionado, que consistem respectivamente em ter o conhecimento das entradas e saídas desejadas ou utilizar apenas os dados de entrada para o treinamento. Neste trabalho são conhecidas as entradas e saídas desejadas da rede neural, portanto *Backpropagation* e Momentum, que são métodos supervisionados, serão abordados. No algoritmo *Backpropagation* a rede propaga os sinais de entrada adiante, gerando uma saída, cujo erro em relação à saída desejada é calculado e utilizado para atualizar os pesos desde a saída até a entrada da rede (propagação reversa). A taxa Momentum é o termo δ inserido na equação de atualização dos pesos do *Backpropagation* multiplicando por $(W_{atual} - W_{antigo})$ para acelerar a convergência da rede, conforme Eq. (4), em que W são os pesos, η é a taxa de aprendizagem e E é o erro.

$$W_{novo} = W_{atual} + \eta \frac{dE}{dW} + \delta (W_{atual} - W_{antigo}) \quad (2)$$




Figura 1. a) Modelo não linear de um neurônio e b) Arquitetura de uma rede PMC *feedforward*

A arquitetura das RNAs pode variar segundo o tipo de conexão dos neurônios. Nas redes *feedforward* (Figura 1b), todos os neurônios possuem conexões da esquerda para a direita, cujo fluxo segue unidirecionalmente da entrada até a saída (Jang, Sun e Mizutani, 1997, p. 200–202; Silva, Spatti e Flauzino, 2010).

A determinação da uma topologia, ou seja, a quantidade de neurônios e número de camadas escondidas ou intermediárias de uma rede neural é geralmente feita empiricamente, visto que dependem do problema abordado, do algoritmo de aprendizado, da disponibilidade dos pesos iniciais e da distribuição das amostras no espaço. As redes Perceptron de Múltiplas Camadas (PMC) possuem no mínimo uma camada intermediária de neurônios com arquitetura *feedforward* (**Erro! Fonte de referência não encontrada.**) e podem ser empregadas para aproximação de funções, classificação de padrões, dentre outras. A topologia da rede pode ser variada, permitindo alteração do número de neurônios ou de camadas intermediárias, das funções de ativação dos neurônios e dos métodos de treinamento supervisionado. A operação da rede PMC consiste em, a partir de uma amostra, assumindo os pesos sinápticos ajustados em treinamento, obter as respostas da(s) camada(s) intermediária(s) e, por fim, disponibilizar as saídas da rede (Haykin, 2001; Silva, Spatti e Flauzino, 2010).

2.2. Banco de dados

O objeto de estudo foi definido de acordo com as necessidades da indústria no que diz respeito a custo, paradas para manutenção e histórico de falhas. Dentre os equipamentos portuários de mineração, o Virador de Vagões, mais especificamente o sistema de alimentadores, foi escolhido por especialistas. A metodologia deste estudo compreendeu a programação de RNAs com entradas variantes no tempo, utilizada com o banco de dados referente aos motores de do sistema Alimentador Norte (AL1) e Sul (AL2) de um Virador de Vagões entre Julho de 2017 e Agosto de 2018.

Os dados de vibração foram coletados manualmente em média a cada 4 dias, totalizando 108 amostras para o AL1 e 101 para o AL2. Em caso de intervalo irregular entre amostras, a última coleta realizada até o momento foi utilizada. Os dados de operação são referentes a medições realizadas a cada 5 segundos no ativo, foram retirados do sistema de aquisição de dados PIMS e separados conforme *Timestamp* a fim de obter-se os valores em intervalos regulares. Dos dados de manutenção foram extraídas as datas de troca no sistema alimentador para o cálculo do tempo até a parada do ativo. O horímetro contém informação sobre horas do ativo em operação, a partir do qual, em conjunto com o tempo médio de operação, foi calculado o percentual até a parada. As variáveis disponíveis no banco de dados são apresentadas na Tab. 1, que mostra o local da medição, o tipo de variável (dados vibracionais, de operação ou de manutenção) e se a variável foi utilizada com valor original (O) ou normalizado (N). O banco de dados foi aplicado de três maneiras: B1, com 8 preditores originais; B2, com 5 preditores originais, após retirada dos preditores constantes e correlacionados; B3, com 5 preditores normalizados.

Tabela 1. Preditores do banco de dados dos Alimentadores.

LOCAL DA MEDIÇÃO	TIPO DE VARIÁVEL	VARIÁVEL	B1	B2	B3
Lado acoplado do motor do alimentador	Vibração	Envelope	O	O	N
		Velocidade	O	O	N
		Aceleração	O	O	N
Motor do alimentador	Operação	Rotação	O		
		Corrente	O		
		Velocidade de referência	O		
		Horímetro	O	O	N
	Manutenção	Percentual de tempo médio até parada	O	O	N

A saída desejada deste processo foi o percentual de tempo até a próxima parada. O percentual de tempo até parada foi calculado com base nas ordens de manutenção, como na Eq. (1), sendo Dia_{up} o dia da última parada, como marco zero, Dia_{atual} o número de dias até a coleta do dado, Dia_{pp} o dia até a próxima parada:

$$\%Tempo = \frac{Dia_{atual} - Dia_{up}}{Dia_{pp} - Dia_{up}} * 100\% \quad (3)$$

2.3. Modelo proposto

Na etapa de pré-processamento dos dados foi avaliado inicialmente o coeficiente de correlação de dados e a relevância das variáveis para a obtenção da previsão de parada da máquina, com o intuito de simplificar o modelo e evitar o sobreajuste (Soofastaei, 2020). Nesta etapa foram removidas variáveis correlacionadas ou com variância nula (Velocidade de referência, Rotação e Corrente), sobrando apenas as variáveis utilizadas em B2 e B3. Em B3 estas foram normalizadas para o intervalo [0, 1], para que variáveis com diferentes grandezas fiquem em uma escala comum a todas, prevenindo saturação na operação do neurônio ou perda de informação, conforme James *et al.* (2013); Silva, Spatti, e Flauzino (2010).

A RNA PMC com entradas variantes no tempo possui arquitetura *feedforward* sem realimentação. Devido aos atrasos temporais encontrarem-se na camada de entrada, a topologia é denominada Rede Neural com Atraso de Tempo, do inglês *Time Delay Neural Network* (Haykin, 2001). A predição de valores após o instante atual t é dada em função dos n

anteriores, como na Eq. (2). O resultado da predição $x(t)$ é comparado com a saída $y(t)$, obtendo a Eq. (3) de minimização do erro $E(t)$, em que N é a quantidade total de amostras sequencialmente coletadas.

$$x(t) = f(x(t-1), x(t-2), \dots, x(t-n_p)) \quad (4)$$

$$E(t) = x(t) - y(t), \text{ onde } (n_p + 1) \leq t \leq N \quad (5)$$

A programação da RNA com entradas variantes no tempo, em que é obtida, como resposta, uma previsão de um momento posterior a partir de entradas de momentos anteriores foi feita no Matlab®. O estudo abarcou a rede neural PMC com dois tipos de treinamento, variação do número de camadas, quantidade de neurônios por camada e parâmetros de treinamento, com as características a seguir:

- Normalização das entradas no intervalo entre 0 e 1, utilizando a Eq. (1);
- Duas técnicas de treinamento: *Backpropagation* ou *Momentum*;
- Quantidade de camadas intermediárias: uma ou duas;
- Variação do número de neurônios em cada camada intermediária, segundo método de Fletcher-Gloss para redes de uma camada: $2 \cdot \sqrt{n} + n_2 \leq n_1 \leq 2 \cdot n + 1$, onde n é o número de entradas da rede, n_1 é número de neurônios na camada intermediária e n_2 é o número de neurônios na camada de saída;
- Variação com passo de 0,05 das taxas de aprendizado (η) de 0 a 0,9 e, quando aplicável, variação da taxa de Momentum (δ) de 0,05 até 0,75 (Silva, Spatti e Flauzino, 2010; James et al., 2013);
- *Cross-Validation*: 5 partições com 80% dos dados para treinamento e 20% teste (Silva, Spatti e Flauzino, 2010).

2.4. Intervalo de confiança

Para o cálculo do intervalo de confiança para redes neurais foi usado o método da máxima verossimilhança, que leva em conta duas fontes de incertezas para um modelo preditivo: a variância do ruído (σ_v^2 , variância dos erros do conjunto de validação cruzada no treinamento da rede), e a variância da incerteza (σ_w^2 , variância da incerteza do modelo) (Menezes e Valença, 2016). No processo de validação calcula-se o erro σ_v pela Eq. (5).

$$\sigma_v = \frac{1}{n-1} \sum_{i=1}^n (Erro_i - \widehat{Erro})^2 \quad (6)$$

Em que n é a quantidade de valores, $Erro_i$ é o erro referente a entrada i , $\widehat{Erro}$ é a média dos erros, e σ_w^2 é calculado a partir dos erros para todas as entradas do treinamento da rede. Com os valores de σ_v^2 e σ_w^2 é possível calcular o σ_{total}^2 , que foi usado para encontrar o intervalo de confiança a partir da Eq. (6).

$$f(x) - t * \sigma_{total}^2 < f(x) < f(x) + t * \sigma_{total}^2 \quad (7)$$

Em que $f(x)$ é o valor calculado pela rede e t é o valor extraído da tabela t-Student para o maior grau de liberdade possível e um intervalo definido que geralmente é 90%, 95% ou 99% de chance de conter o valor real.

O cálculo do intervalo de confiança utilizando a máxima verossimilhança, conforme apresentado por Menezes e Valença (2016), foi implementado de acordo com o seguinte algoritmo:

1. Dividir a base de dados em treinamento e teste
2. Normalizar dados
3. Treinar a rede
4. Calcular a variância do erro σ_v^2 pela Eq.(5)
5. Desnormalizar dados
6. Calcular os erros $Erro_i = (Calculado_i - Desejado_i)$
7. Normalizar dados
8. Treinar nova rede com mesmas entradas e as saídas sendo os erros
9. Calcular a variância do erro da segunda rede σ_w^2 pela Eq.(5)
10. Desnormalizar dados
11. Calcular a variância total $\sigma_{total}^2 = \sigma_v^2 + \sigma_w^2$
12. Selecionar o grau de confiança e seu valor apropriado na tabela t-Student
13. Calcular o intervalo para os valores obtidos com os dados de teste, conforme Eq.(6)

2.5. Avaliação do desempenho das RNAs

As RNAs foram comparadas quanto ao tempo de treinamento, número de épocas e métricas de erro. O Erro Relativo Médio indica a margem de erro em relação ao valor desejado e é dado pela Eq.(7). O Erro Quadrático médio (MSE, *Mean*

Squared Error) representa a diferença média da variação entre o valor obtido e o valor desejado, conforme Eq.(8), sendo Y o valor desejado e $\hat{Y}$ o obtido.

$$\text{Erro Relativo Médio (\%)} = \frac{1}{n} \sum_{i=1}^n \left(\frac{|Y - \hat{Y}|}{Y} \cdot 100 \right) \quad (8)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (9)$$

A rede que apresentou a melhor topologia, ou seja, melhor média de cinco treinamentos iniciais, foi treinada mais cinco vezes para escolha do modelo com menor erro para o cálculo do intervalo de confiança da rede para treinamento e para teste, seguindo os passos do algoritmo da máxima verossimilhança. Para isto, foram considerados intervalos de confiança a 95%.

3. RESULTADOS

A Tab. 2 mostra a comparação entre os resultados com os diferentes bancos de dados B1, B2, quando aplicável, e B3 mantendo a janela deslizante de tamanho 3. O erro relativo médio caiu mais de 50% para o AL1 e 80% para o AL2 devido ao tratamento do banco de dados, excluindo as variáveis correlacionadas e normalizando os valores.

Tabela 2 - Comparação entre os Resultados 1 a 5 das RNAs com entradas variantes no tempo com $np=3$

Resultado	1 (AL1)	2 (AL1)	3 (AL1)	4 (AL2)	5 (AL2)
Banco de dados	B1	B2	B3	B1	B3
Tempo de treinamento (s)	16,37	7,48	12,27	7,21	25,85
Número de épocas	332	238	258	172	609
Erro relativo médio (%)	59,46	32,69	4,35	90,50	9,99
MSE	2,87E-2	8,83E-2	4,51E-4	4,00E-2	1,43E-3
Intervalo de confiança do treinamento (95%)	±16,06%	±56,73%	±3,11	±11,47%	±0,20
Intervalo de confiança do teste (95%)	±17,56%	±42,75%	±0,11	±13,32%	±0,38

Os resultados revelaram a importância de fazer o tratamento e a normalização dos dados, pois, para os dados de ambos os alimentadores, foi obtida a queda significativa do erro relativo médio e intervalo de confiança da rede. As redes que apresentaram os melhores resultados para todas as previsões foram treinadas com o termo Momentum.

Os melhores resultados ocorreram para o banco de dados B3, com 5 entradas, cujos valores foram normalizados. Portanto, este banco de dados foi escolhido para fazer uma comparação de resultados entre redes com janelas deslizantes de tamanhos distintos para ambos os Alimentadores AL1 e AL2, como mostra a Tab. 3.

O Resultado A apresenta $np = 2$, em que a melhor topologia de rede possui um erro relativo médio de apenas 4,35%. Enquanto para o Resultado C, com $np = 3$ este valor subiu para 10,02%. Houve pequena variação do MSE entre eles, mas ainda assim se manteve baixo para todas as melhores topologias destas tabelas, na ordem de 10^{-4} .

Tabela 3 - Melhores Resultados das RNAs com entradas variantes no tempo para 5 entradas normalizadas (B3) e diferentes tamanhos de janela

Resultado	A (AL1)	B (AL1)	C (AL1)	D (AL2)	E (AL2)	F (AL2)
Janela deslizante (np)	2	3	4	2	3	4
Tempo de treinamento (s)	12,27	19,00	33,98	25,85	23,75	17,82
Número de épocas	258	341	704	609	466	598
Erro relativo médio (%)	4,35	10,02	7,78	9,99	8,72	13,69
MSE	4,51E-4	3,52E-4	1,08E-3	1,43E-3	1,46E-3	4,35E-3
Intervalo de confiança do treinamento a 95% (%)	±3,11	±2,98	±0,07	±0,20	±0,17	±0,07
Intervalo de confiança do teste a 95% (%)	±0,11	±0,07	±0,25	±0,38	±0,35	±1,09

O tempo de treinamento não se mostrou necessariamente relacionado com o tamanho da janela deslizante. Por possuir mais entradas – 5 para cada instante, neste caso – ao aumentar o tamanho da janela, houve uma tendência na melhora da precisão da rede, conforme notado por Silva, Spatti, e Flauzino (2010). Isto ocorreu para o intervalo de confiança de treinamento de ambos os alimentadores, entretanto não foi observado para o conjunto de teste. O intervalo de confiança foi calculado com base na variância da resposta obtida, não sendo diretamente proporcional ao erro relativo médio e ao MSE. No entanto, estes parâmetros são relevantes para a seleção das topologias que podem apresentar melhor desempenho.

As Figuras 1 e 2 mostram respectivamente a comparação da evolução do erro relativo médio e do MSE de teste para treinamentos com diferentes tamanhos de janela deslizante para o Alimentador 1 (a) e para o Alimentador 2 (b). Os treinamentos relativos ao AL1 apresentaram bom desempenho, porém, para o AL2 pode ser observado o ajuste excessivo para $np = 2$ e $np = 3$.

Os resultados obtidos para a previsão do tempo até a próxima parada para manutenção dos alimentadores utilizando 5 dados de entrada normalizados apresentaram MSE inferior a 0,005 e erro relativo médio inferior a 14%, o que foi considerado um resultado satisfatório para este estudo. O intervalo de confiança de teste a 95% das redes variou entre $\pm 0,07\%$ e $\pm 1,09\%$, mostrando que as RNAs apresentaram potencial para obter resultados de previsão para auxiliar no planejamento da manutenção.




Figura 2. Evolução do erro relativo médio de teste para diferentes tamanhos de janela deslizante para (a) AL1 e (b) AL2




Figura 3. Evolução do MSE de teste para diferentes tamanhos de janela deslizante para (a) AL1 e (b) AL2

4. CONCLUSÃO

Como a técnica de RNA possui a desvantagem de necessitar de um banco de dado extenso com muitos dados de falhas para que seja possível também classificar a provável falha do equipamento, a aplicação neste trabalho limitou-se a prever o quão próximo do momento de parada está o equipamento.

Para a aplicação de previsão, foco deste artigo, foi possível obter um resultado satisfatório para o auxílio da manutenção utilizando as RNAs PMC com entradas variantes no tempo a partir de um banco de dados de um motor do sistema Alimentador de um Virador de Vagões. Neste contexto, foram treinadas redes com banco de dados original e normalizado, além da comparação entre diferentes tamanhos de janela dos dados, como foi mostrado nos resultados.

Para ambos os Alimentadores, houve diminuição significativa do erro relativo médio – de mais de 50% para menos de 10% – e do MSE – com redução de ao menos 10 vezes – ao considerar apenas entradas que apresentavam tendência de aumento dos valores ao longo das coletas e ao normalizar os valores das entradas. As redes convergiram e se mostraram aptas quando utilizadas para previsão temporal. Possuir o conhecimento sobre as variáveis que se deseja abordar para a entrada e saída das RNAs revelou-se importante, uma vez que variáveis de entrada que não possuem relação direta com a saída pretendida podem dificultar a convergência da rede e contribuir com o aumento do erro da resposta obtida.

Para trabalhos futuros é sugerida a implementação de outros tipos de treinamento, bem como da lógica Fuzzy, para incorporar incertezas no modelo. Também podem ser empregados métodos híbridos para avaliação da previsão de múltiplos passos do acúmulo de anos em ativos. Além de dados vibracionais, podem ser utilizados ainda dados de simulações de fadiga e propagação de danos no ativo para que se possa fazer não só a previsão, mas também a comparação da saúde do ativo entre o momento da intervenção e as previsões obtidas pelas simulações.

5. AGRADECIMENTOS

Os autores agradecem à Pontifícia Universidade Católica de Minas Gerais (PUC Minas) e à VALE S.A. pelo apoio financeiro. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

6. REFERÊNCIAS

- Cardoso, D.E.R., 2020. *Aplicação de conceitos de manutenção preditiva com aplicação de ferramentas de Inteligência Artificial*. Universidade do Porto, Porto. doi:https://hdl.handle.net/10216/128181.
- Çınar, Z.M. et al., 2020. “Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0”, *Sustainability*, Vol.12, No.19, p. 8211. doi:10.3390/su12198211.
- Dalzochio, J. et al., 2020. “Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges”, *Computers in Industry*, Vol. 123, p. 103298. doi:10.1016/j.compind.2020.103298.
- Davite, S.G., 2021. *Data analysis and decision making in the mining sector*. Universida de Vigo, Vigo. Disponível em: <http://hdl.handle.net/11093/2443>.
- Dehran, S., Agrawal, P. e Midha, P., 2018. “Digital Applications in Metals and Mining Industry”, *American Journal of Operations Management and Information Systems*, Vol. 3, No. 1, pp. 33–37. doi:10.11648/j.ajomis.20180301.15.
- Drath, R. e Horch, A., 2014. “Industrie 4.0-hit or hype”, *IEEE Industrial Electronics Magazine*, Vol. 8, No. 2, pp. 56–58. doi:10.1109/MIE.2014.2312079.
- Elsheikh, A., Yacout, S. e Ouali, M.-S., 2019. “Bidirectional handshaking LSTM for remaining useful life prediction”, *Neurocomputing*, Vol. 323, pp. 148–156. doi:10.1016/J.NEUCOM.2018.09.076.
- Haykin, S., 2001. *Redes Neurais: Princípios e Prática*. 2ª ed. Ed. Bookman, Porto Alegre, Brasil, 898 p.
- Hu, Y. et al., 2019. “Remaining Useful Life Model and Assessment of Mechanical Products: A Brief Review and a Note on the State Space Model Method”, *Chinese Journal of Mechanical Engineering* 2019 32:1, Vol. 32, No. 1, pp. 1–20. doi:10.1186/S10033-019-0317-Y.
- James, G. et al., 2013. *An introduction to Statistical Learning: with Applications in R*. Ed. Springer, New York. doi:10.1007/978-1-4614-7138-7.
- Jang, J.-S.R., Sun, C.-T. e Mizutani, E., 1997. *Neuro-fuzzy and softing computing: a computational approach to learning and machine intelligence*. Ed. Prentice Hall, Upper Saddle River, New Jersey.
- Kahraman, A., 2018. *Maintainability analysis of mining trucks with data analytics.*, *Electronic Theses and Dissertations*. University of Louisville, Louisville. doi:10.18297/etd/2932.
- Kang, Z., Catal, C. e Tekinerdogan, B., 2021. “Remaining Useful Life (RUL) Prediction of Equipment in Production Lines Using Artificial Neural Networks”, *Sensors (Basel, Switzerland)*, Vol. 21, No. 3, pp. 1–20. doi:10.3390/S21030932.
- Kardec, A. e Nascif, J., 2010. *Manutenção: função estratégica*. 3ª ed. Ed. Qualitymark, Rio de Janeiro, Brasil.
- Kruczek, P. et al., 2019. “Predictive Maintenance of Mining Machines Using Advanced Data Analysis System Based on the Cloud Technology”, *Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection - MPES 2018*. Springer International Publishing, pp. 459–470. doi:10.1007/978-3-319-99220-4_38.
- Lee, C.S.-M.Y., 2019. “Case Analysis for Introduction of Machine Learning Technology to the Mining Industry”, *Tunnel and Underground Space*, Vol. 29, No. 1, pp. 1–11. doi:10.7474/TUS.2019.29.1.001.
- Menezes, B. e Valença, M., 2016. “Construindo Intervalos de Confiança na Previsão Da Potência do Vento Utilizando Reservoir Computing”, in *Anais do 11. Congresso Brasileiro de Inteligência Computacional*. SBIC, pp. 1–6. doi:10.21528/CBIC2013-238.
- Nascimento, N.M.M. et al., 2020. “Temporal Classification of Turbofan Engine Health using Elman Recurrent Network”, in *Congresso Brasileiro de Inteligência Computacional*. doi:10.21528/CBIC2019-68.
- Patil, S.D. et al., 2021. “Predictive asset availability optimization for underground trucks and loaders in the mining industry”, *OPSEARCH* 2021 58:3, Vol. 58, No. 3, pp. 751–772. doi:10.1007/S12597-020-00502-4.
- Qu, J. et al., 2019. “A Neural-Network-Based Method for RUL Prediction and SOH Monitoring of Lithium-Ion Battery”, *IEEE Access*, Vol. 7, pp. 87178–87191. doi:10.1109/ACCESS.2019.2925468.
- Rastogi, V. et al., 2020. “Predictive Maintenance for SME in Industry 4.0”, *Proceedings - 2020 Global Smart Industry Conference, GloSIC 2020*, pp. 382–390. doi:10.1109/GLOSIC50886.2020.9267844.
- Shahzad, W., Rehman, Q. e Ahmed, E., 2017. “Missing Data Imputation using Genetic Algorithm for Supervised Learnin”, *International Journal of Advanced Computer Science and Applications*, Vol.8, No.3. doi:10.14569/IJACSA.2017.080360.

- Silva, I.N. da, Spatti, D.H. e Flauzino, R.A., 2010. *Redes neurais artificiais para engenharia e ciências aplicadas*. Ed. Artliber, São Paulo, Brasil.
- Soofastaei, A., 2020. *Data Analytics Applied to the Mining Industry*, Ed: CRC Press, Boca Raton, 272 p. doi:10.1201/9780429433368.
- Takeda, N. et al., 2016. *Using Operation Information in Reliability Design and Maintenance: Analytics for the IoT Era : Hitachi Review*. Disponível em: <https://www.hitachi.com/rev/archive/2016/r2016_09/114/index.html>. Acesso em: 22, Março, 2020.
- Technology Scenario “Artificial Intelligence in Industrie 4.0”, 2019. Berlin: Federal Ministry Economic Affairs Energy (BMWi). Disponível em: www.bmwi.de. Acesso em: 15, Abril, 2020.
- Tupa, J., Simota, J. e Steiner, F., 2017. “Aspects of Risk Management Implementation for Industry 4.0”, *Procedia Manufacturing*, Vol. 11, pp. 1223–1230. doi:10.1016/J.PROMFG.2017.07.248.
- Wang, K. e Wang, Y., 2018. “How AI Affects the Future Predictive Maintenance: A Primer of Deep Learning”, in *Lecture Notes in Electrical Engineering*. Springer Verlag, pp. 1–9. doi:10.1007/978-981-10-5768-7_1.
- Xu, Z. e Saleh, J.H., 2021. “Machine learning for reliability engineering and safety applications: Review of current status and future opportunities”, *Reliability Engineering & System Safety*, Vol. 211, p. 107530. doi:10.1016/J.RESS.2021.107530.
- Yan, J. et al., 2017. “Industrial Big Data in an Industry 4.0 Environment: Challenges, Schemes, and Applications for Predictive Maintenance”, *IEEE Access*, Vol. 5, pp. 23484–23491. doi:10.1109/ACCESS.2017.2765544.
- Zhou, C. et al., 2017. “Industrial Internet of Things (IIoT) applications in underground coal mines”, in *SME Annual Conference and Expo 2017: Creating Value in a Cyclical Environment*. Society for Mining, Metallurgy and Exploration (SME), pp. 368–374. doi:10.19150/me.7919.

7. RESPONSABILIDADE AUTORAL

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

ARTIFICIAL NEURAL NETWORKS APPLIED IN THE PREDICTION OF THE REMAINING TIME FOR THE MAINTENANCE OF A ROTARY CAR DUMPER

Laís Marino, laismbp@gmail.com¹

Jánes Landre Jr., janes@pucminas.br¹

Cádmio Augusto Rodrigues Dias, cadmordias@gmail.com¹

Bernardo Rocha, bernardo.rocha@vale.com²

¹Pontifícia Universidade Católica de Minas Gerais, 500 Dom José Gaspar Av. – Belo Horizonte/MG, Brasil – Zip Code 30535910

²Vale AS, 5500 Dante Michelini Av. – Vitória/ES, Brasil – Zip Code 29090860

Abstract. Industry 4.0 addresses the challenges demanded by the market today, such as increased security and task planning. In this context, Artificial Intelligence adds value to the industry by making it possible to carry out unforeseen tasks that require adaptation and problem-solving skills. The mining industry is ideal for digital transformation, as it is a challenge to assess the condition of assets and has large environments and many assets. To increase the efficiency of processes in environments where assets, that wear out over time, are involved, predictive maintenance proves to be important, as it makes it possible to improve assets reliability and repair planning. Machine learning is considered an innovative solution for its implementation. However, the literature on Artificial Neural Networks (ANNs) for remaining life prediction is limited, mainly for applications in real scenarios and reporting the model's performance. Therefore, this study contributes to the application of ANNs in a real scenario of the mining industry. The objective is to evaluate the performance of ANNs for monitoring asset damage, to assist in maintenance planning. This work was limited to predicting how close the equipment is to the moment of stopping. In the methodology, the object of study was defined, supervised models for forecasting were developed, the database was collected, data was pre-processed, and the model was applied to the database. The ANNs were used to predict the downtime for maintenance of a Rotary Car Dumper, applying the engine database of its Feeder system, which was defined as of the needs of the industry. The generalization and prediction capability were compared for different topologies of ANNs with time-varying inputs, different data window sizes, and training types for one-step prediction. Finally, the confidence interval of the networks was calculated by the Maximum Likelihood. The result was considered satisfactory, with a mean relative error below 5.0% and the test confidence interval (95%) below 1.1%, showing that the ANNs had the potential to assist in maintenance planning. The networks converged and proved to be suitable for temporal forecasting. Knowledge of the variables involved for use in ANNs proved to be important since input variables not directly related to the intended output can hamper network convergence and contribute to increasing the error of the response obtained.

Keywords: Artificial Neural Networks, Mining Equipment, Remaining Useful Life