

REDES NEURAIS PARA MONITORAMENTO DO ACÚMULO DE DANOS EM EQUIPAMENTOS PORTUÁRIOS

Laís Marino, laismbp@gmail.com

Lucas Miranda Rodrigues, lucasrodrigues.miranda@hotmail.com

Ronei Avelar Soares, roneiavelar@gmail.com

Jánes Landre Júnior, janes@pucminas.br

Pontifícia Universidade Católica de Minas Gerais – Av. Dom José Gaspar, 500, Coração Eucarístico, Belo Horizonte, Minas Gerais, Brasil – 30535-610

Resumo: Esta pesquisa surgiu da necessidade de se entender os problemas estruturais de equipamentos portuários voltados para a mineração, dada a importância desta atividade, pois os minérios são elementos essenciais para a produção de inúmeros bens de consumo e a indústria da mineração é responsável por 4% do PIB no Brasil. Os equipamentos são extremamente robustos e de custo elevado para manutenção, portanto faz-se necessário o acompanhamento do desgaste dos ativos a partir do sensoriamento, inspeções e monitoramento de danos, tendo em vista o aumento da confiabilidade e previsões mais exatas e confiáveis, visto que atualmente há a tendência de grandes empresas utilizarem técnicas de inteligência artificial para diagnosticar e prever falhas. A metodologia deste estudo compreende a utilização dos principais sinais de sensoriamento relativos aos modos de falha mais relevantes para rolamentos em um ativo e, a partir disso, empregar o banco de dados real do histórico de falhas em rolamentos para alimentar o treinamento, o teste e a validação, quando aplicável, de um modelo de rede neural proposto, cuja saída é a classificação de um modo de falha. A modelagem da rede neural abarca a comparação de diversas topologias, segundo o método Cross-validation. A taxa de acertos de um modelo de rede neural pode estar relacionada à topologia, às características dos dados de entrada e saída e ao tipo de treinamento empregado. Foi encontrada uma topologia com 100% de taxa de acerto para os dados vibracionais utilizados, demonstrando que as redes neurais podem ser uma ferramenta poderosa para reconhecimento de padrões e classificação de falhas. Este trabalho contribui com a validação de uma metodologia para monitoramento de danos por um modelo de rede neural para rolamentos de um ativo, passível de replicação para os demais componentes e ativos, auxiliando o departamento de manutenção, confiabilidade e operação no planejamento das ações.

Palavras-chave: acúmulo de dano, inteligência artificial, manutenção, redes neurais, cross-validation.

1. INTRODUÇÃO

Esta pesquisa surgiu da necessidade de se entender os problemas estruturais de equipamentos portuários voltados para a mineração, dada a importância desta atividade, uma vez que os minérios são elementos essenciais para a produção de inúmeros bens de consumo e a indústria da mineração é responsável por 4% do PIB no Brasil (Brasil - DNPM, 2016, p.11). Os equipamentos são extremamente robustos e de custo elevado para manutenção, portanto faz-se necessário o acompanhamento do desgaste dos ativos a partir do sensoriamento, inspeções e monitoramento de danos, tendo em vista o aumento da confiabilidade e previsões mais exatas e confiáveis. Atualmente há a tendência de grandes empresas utilizarem técnicas de inteligência artificial para diagnosticar e prever falhas, a fim de aumentar a confiabilidade e diminuir os custos com as manutenções corretiva e preventiva.

Pereira *et al* (2016) propuseram o monitoramento de motores de indução a partir de identificação das falhas através de dados vibracionais, cujo processamento de sinais foi a técnica do envelope. Tian, Worg e Safaei (2010) implementaram um modelo de rede neural artificial para obter o percentual de vida de um ativo, tendo como entrada dados de monitoramento e tempo de vida. A avaliação da performance foi feita pelo cálculo do erro quadrático médio (MSE). Cheng, Qu e Qiao (2017) propuseram um modelo neuro-fuzzy para obter um prognóstico de vida remanescente de um equipamento com melhor custo benefício entre processamento e precisão da predição. Wang *et al* (2016) desenvolveram um modelo neuro-fuzzy para diagnóstico e previsão de falhas com o método de treinamento Momentum para a rede neural, obtendo resultados verossímeis e válidos para o proposto. Wu, Tian e Chen (2013) utilizaram uma rede neural artificial *feedforward* em conjunto com a teoria da probabilidade e distribuição de Weibull para estimar o tempo de falha de um equipamento até a próxima inspeção.

O objetivo deste estudo é monitorar o acúmulo de danos no ativo a partir da definição de modos de falha, processamento dos sinais dos dados coletados, e classificação da falha do ativo. Neste contexto, as técnicas de inteligência artificial apresentam-se apropriadas para cumprir com estas finalidades, particularmente as redes neurais, pois é uma ótima ferramenta para classificação de padrões, generalizações e capacidade de aprendizado segundo Jang, Sun e Mizutani (1997) e Silva, Spatti e Flauzino (2010, p.94-120), adequadas para tarefas de diagnóstico.

2. PROCEDIMENTO COMPUTACIONAL

A metodologia deste estudo segue as etapas descritas no fluxograma da Fig. 1. Três modos de falha mais relevantes dos rolamentos do ativo foram identificados, e, então, definidos os sinais indicativos dessas falhas, medidos pelo sensoriamento existente. O banco de dados com as informações das variáveis obtidas pelo sensoriamento do ativo, correspondentes ao histórico de falhas, foi utilizado para alimentar o modelo da rede neural proposta.

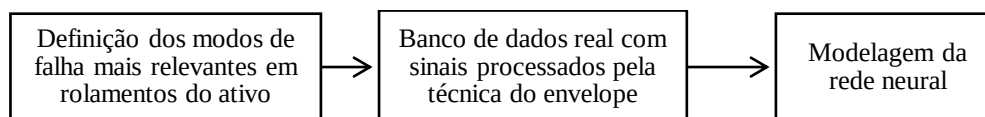


Figura 1. Fluxo de trabalho.

Com os modos de falha devidamente identificados, foi utilizado o banco de dados existente para discernir quais as variáveis coletadas pelo sensoriamento no ativo necessárias para indicar as respectivas falhas. Ou seja, foram utilizados apenas os dados referentes às variáveis indicativas dos modos de falha considerados neste estudo: sinais referentes à pista interna, à pista externa e ao elemento rolante.

Os dados utilizados para entrada na rede neural são dados vibracionais de rolamentos, cujos componente possuem cada um uma respectiva frequência característica, tornando possível a detecção de falhas por sinais de vibração. A técnica de processamento de sinais utilizada no banco de dados foi a análise de envelope, que consiste na mudança do sinal vibracional para o domínio da frequência, seleção de uma faixa em torno da frequência central e demodulação do sinal. Em seguida obtêm-se os módulos de amplitude do sinal e extraem-se, do domínio da frequência, as frequências características correspondentes ao módulo do sinal (ALMEIDA, 2016).




Figura 2. Fluxograma para modelagem da rede neural classificadora.

Na modelagem da rede neural classificadora (Fig. 2), após definidos e normalizados os dados históricos conhecidos para entrada e saída da rede, foram feitos treinamentos e testes com diferentes topologias de redes e métodos de treinamento, a fim de escolher a topologia com melhor taxa de acerto para ser utilizada no estudo.

Os dados do sensoriamento já processados foram selecionados aleatoriamente, de forma que um percentual fosse destinado ao treinamento e o restante ao teste e validação, quando necessário. Para encontrar a melhor topologia de rede neural foi utilizado o método *Cross-validation*, que consiste na escolha e no treinamento de diversas topologias, com diferentes características, como as variações abordadas neste estudo: número de camadas, número de neurônios em cada camada, método de treinamento empregado e variação da taxa de aprendizagem e momentum, quando aplicável. Os dados de validação foram usados como um dos critérios de parada do treinamento. Por fim, os dados para teste foram usados no

cálculo do erro da rede neural com a melhor topologia. Para um resultado satisfatório, o treinamento é encerrado e os parâmetros do modelo da rede neural selecionada são guardados. Caso contrário, testam-se novas topologias.

2.1. Tipos de treinamento

Os tipos de treinamento abordados foram *Backpropagation*, *Momentum* e *Levenberg-Marquardt*. O *Backpropagation* é um algoritmo que se dá em duas fases: propagação adiante, quando há o processamento das entradas e pesos até a saída, e propagação reversa, quando ocorre a comparação entre a saída atual e a desejada, e este erro é utilizado para o ajuste dos pesos desde a camada de saída até a camada de entrada. O *Momentum* é um termo δ inserido na equação de atualização dos pesos, visando acelerar o treinamento da rede, como mostra a Eq.1, onde W representa o peso das conexões sinápticas, η é a taxa de treinamento, $\frac{dE}{dW}$ é a variação do erro em relação à variação do peso sináptico (Silva, Spatti e Flauzino, 2010):

$$W_{novo} = W_{atual} + \eta \frac{dE}{dW} + \delta(W_{atual} - W_{antigo}) \quad (1)$$

Ainda de acordo com Silva, Spatti e Flauzino (2010), o treinamento por *Levenberg-Marquardt* é uma função gradiente de segunda ordem baseado no método mínimo para modelos não lineares. A partir da utilização do jacobiano transposto dos pesos no treinamento da rede, a convergência do algoritmo ocorre de 10 a 100 vezes mais rápida que no *Backpropagation*.

A implementação do *Backpropagation* e do *Momentum* foi feita em linha de programação no Matlab, permitindo maior flexibilidade para alteração das características da rede, e o método *Levenberg-Marquardt* foi empregado através ferramenta nftool do Matlab, cuja rede pode possuir apenas uma camada intermediária, possibilitando variação apenas do número de neurônios nesta camada.

3. RESULTADOS

Foram utilizadas 80 amostras de sinais no contexto de falha de algum dos três componentes do rolamento: pista interna, pista externa e elemento rolante. Desta forma, são três as entradas para a rede neural – amplitudes dos dados de pista interna, pista externa e elemento rolante - e três as saídas correspondentes – sendo 0 uma situação sem falha no respectivo componente e 1 uma situação de falha.

Foram testadas topologias de redes neurais classificatórias com as seguintes características: uma ou duas camadas intermediárias com as possíveis combinações para 4 ou 8 neurônios por camada; três tipos de treinamento, sendo eles *Backpropagation*, *Momentum* e *Levenberg-Marquardt*; variação da taxa de aprendizado de 0,05 até 0,75 para os dois primeiros tipos e variação da taxa de *Momentum* para o segundo tipo de treinamento. Para cada topologia foi feita a média do resultado de cinco treinamentos com valores de época, ou seja, quantas iterações foram necessárias até a convergência, erro quadrático médio (MSE) de teste e o valor R de regressão de 0 a 1, que representa a correlação entre valores de saída obtidos e desejados da rede, significando 1 a melhor correlação. O critério de parada do treinamento está relacionado ao erro quadrático médio durante o treinamento, teste e validação, quando aplicável, e à quantidade de épocas, ou seja, iterações já realizadas. A taxa de acerto foi calculada com base na validação dos resultados com o banco de dados utilizado. Foram direcionadas aleatoriamente 85% das amostras para treinamento e 15% para teste para o *Backpropagation* e o *Momentum*, e 70% para treinamento, 15% para teste e 15% para validação para o *Levenberg-Marquardt*, visto que este método necessita utilizar dados de validação. A Tabela 1 apresenta os valores da média de 5 treinamentos feitos com cada topologia que apresentou R superior a 0,9 e MSE inferior a 0,1.

Tabela 1. Resultados das topologias de redes neurais com maior taxa de acerto.

Tipo de Treinamento	Nº de camadas	Neurônios por camada	Taxa de aprendizado	<i>Momentum</i>	Épocas	MSE Teste	R
<i>Momentum</i>	2	4/4	0,05	0,9	1128	0,061	0,950
<i>Momentum</i>	2	4/4	0,4	0,6	1283	0,054	0,933
<i>Momentum</i>	1	4	0,05	0,9	2439	0,059	0,933
<i>Momentum</i>	2	8/4	0,05	0,6	2526	0,052	0,933
<i>Backpropagation</i>	1	4	0,75	-	2645	0,047	0,933
<i>Momentum</i>	2	8/4	0,05	0,3	4170	0,053	0,933
<i>Backpropagation</i>	2	8/8	0,05	-	5445	0,055	0,933
<i>Momentum</i>	1	8	0,4	0,9	483	0,087	0,917
<i>Momentum</i>	2	4/8	0,75	0,6	896	0,071	0,917
<i>Momentum</i>	2	8/8	0,05	0,6	4461	0,067	0,917
<i>Levenberg-Marquardt</i>	1	8	-	-	23	0,038	0,916

O resultado mostrou um maior acerto para as redes que utilizaram maior número de amostras no treinamento, o que indica que o resultado pode ser ainda mais consistente para um treinamento com maior quantidade de amostras, desde que não seja um conjunto de dados grande demais e com muitas iterações no treinamento, para evitar o *overfitting*, o que levaria a rede a perder sua capacidade de generalização.

Quanto mais camadas possui uma rede, maior é o grau da função de regressão. Portanto, para redes com duas ou mais camadas, a função de regressão possui grau 2 ou superior, permitindo a classificação de padrões não lineares. Dessa forma, a função de regressão com mais camadas pode atender melhor a classificação dos modos de falha e com taxa de acerto mais elevada do que a rede com apenas uma camada, como ocorreu com algumas topologias deste estudo.

O desempenho do tipo de rede tem ligação não apenas com suas próprias características, mas também com os tipos de dados de entrada e saída utilizados. Assim sendo, pode ocorrer, para outros tipos de dados, que uma rede com características distintas das apresentadas como melhores neste estudo obtenha o melhor desempenho, reforçando a importância da aplicação do método *Cross-validation* para o alcance de resultados os mais próximos dos exatos quanto possível.

A rede neural classificadora que foi capaz de classificar corretamente as falhas com a maior taxa de acerto, de 95%, possui 2 camadas intermediárias com 4 neurônios em cada, com taxa de aprendizado de 0,05, *Momentum* de 0,9 utilizando o método de treinamento *Momentum*, como mostra a Tab.1. Então esta mesma rede foi treinada novamente e escolhido o melhor de três resultados para apresentar a evolução do MSE (Fig.3a) e da taxa de acerto no decorrer das épocas (Fig.3b).




Figura 3. Evolução (a) do MSE e (b) da taxa de acerto durante treinamento e teste da rede neural.

Neste treinamento a rede alcançou 100% de acerto durante o treinamento, com MSE de treinamento de 0,086 e MSE de teste de 0,027, atendendo ao valor desejado de MSE abaixo de 0,1. Foi possível então a obtenção de uma rede neural com capacidade de generalização de todas as amostras utilizadas para treinamento e teste, comprovando-se uma ferramenta poderosa para reconhecimento de padrões e classificação de falhas.

4. CONCLUSÃO

Este trabalho contribui com uma metodologia para monitoramento de danos por um modelo de rede neural para um ativo, permitindo a replicação da metodologia para demais equipamentos portuários da atividade de mineração, de forma a auxiliar o departamento de manutenção, confiabilidade e operação no planejamento das ações.

As redes neurais se mostraram aptas para generalização de padrões e classificação de falhas com uma taxa de acertos elevada quando encontrada a melhor topologia de rede dadas as características dos dados de entrada e saída. Este estudo permite aplicar técnicas de inteligência artificial em equipamentos robustos, contribuindo para o estado da arte na área de integridade estrutural de equipamentos com aplicação na atividade de mineração para suprir uma demanda real.

5. AGRADECIMENTOS

Os autores agradecem generosamente à Pontifícia Universidade Católica de Minas Gerais (PUC Minas), à VALE S.A., à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

6. REFERÊNCIAS

ALMEIDA, I. B. Análise de falhas em rolamentos por análise de vibração aplicado a aerogeradores. Natal, RN, 2016. Dissertação de Mestrado – Universidade Federal do Rio Grande do Norte.

- Brasil - DNPM (Departamento Nacional de Produção Mineral). Sumário Mineral 2015, v.35, 146p. DNPM, Brasília, 2016. ISSN 0101-2053. Disponível em: < <http://www.dnpm.gov.br/dnpm/sumarios/sumario-mineral-2015>>. Acessado em: 12 dez. 2017.
- CHENG, F.; QU, L.; QIAO, W. Fault Prognosis and Remaining Useful Life Prediction of Wind Turbine Gearboxes Using Current Signal Analysis. IEEE Transactions on Sustainable Energy, p. 1–1, 2017.
- HAYKIN, S. Redes neurais: princípios e prática. 2. ed. Porto Alegre: Prentice Hall, 1999.
- JANG, J.-S. R.; SUN, C.-T.; MIZUTANI, E. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. Upper Saddle River, New Jersey: Prentice Hall, 1997.
- PEREIRA, R. R. et al. On-line monitoring induction motors by fuzzy logic: A study for predictive maintenance operators. 2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD). Anais...IEEE, ago. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7603373/>>. Acesso em: 17 jul. 2017
- SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. São Paulo: Artliber, 2010.
- TIAN, Z.; WORG, L.; SAFAEI, N. A neural network approach for remaining useful life prediction utilizing both failure and suspension histories. Mechanical Systems and Signal Processing, v. 24, n. 5, p. 1542–1555, 1 jul. 2010.
- WANG, X. et al. Intelligent fault diagnosis and prediction technologies for condition based maintenance of track circuit. 2016 IEEE International Conference on Intelligent Rail Transportation (ICIRT). Anais...IEEE, ago. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7588745/>>. Acesso em: 17 jul. 2017.
- WU, B.; TIAN, Z.; CHEN, M. Condition-based Maintenance Optimization Using Neural Network-based Health Condition Prediction. Quality and Reliability Engineering International, v. 29, n. 8, p. 1151–1163, dez. 2013.

7. RESPONSABILIDADE AUTORAL

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

NEURAL NETWORKS FOR MONITORING PORT FACILITIES DAMAGE ACCUMULATION

Laís Marino, laismbp@gmail.com

Lucas Miranda Rodrigues, lucasrodrigues.miranda@hotmail.com

Ronei Avelar Soares, roneiavelar@gmail.com

Jánes Landre Júnior, janes@pucminas.br

Pontifícia Universidade Católica de Minas Gerais – Av. Dom José Gaspar, 500, Coração Eucarístico, Belo Horizonte, Minas Gerais, Brasil – 30535-610

Abstract. *This study arose from the need to understand the structural problems of mining port equipment, given the importance of this activity, since ores are essential elements for the production of many consumer goods and the mining industry is responsible for 4% of GDP in Brazil. The assets are extremely robust and present high costs for maintenance, therefore it is necessary the monitoring of the assets wear from the sensing, inspections, and monitoring of damages, given that currently there is the tendency of large companies to use artificial intelligence techniques to diagnose and predict failures. The methodology of this study includes the use of the main sensing signals concerning the most relevant failure modes for bearings in a facility and, from that, use the actual failure record database in bearings to feed the training, testing and validation, where applicable, of a proposed neural network model, whose output is the failure mode classification. Neural network modeling includes the comparison of several topologies, according to the Cross-validation method. The hit rate of a neural network model can be related to the topology, the characteristics of the input and output data and the type of training. A topology with 100% hit rate for the vibrational data used was found, demonstrating that neural networks can be a powerful tool for pattern recognition and classification. This work contributes to the validation of a methodology for the monitoring of damage by a neural network model for asset bearings, subject to other replication components and assets, assisting the department of maintenance, reliability, and operation in the action planning.*

Keywords: *accumulation of damage, artificial intelligence, neural networks, maintenance, cross-validation.*