

## **GRUPO DE ESTUDO DE GERAÇÃO HIDRÁULICA - GGH**

### **DIAGNÓSTICO DE DESALINHAMENTO E DESBALANCEAMENTO EM HIDROGERADORES UTILIZANDO APRENDIZADO PROFUNDO DE MÁQUINA (DEEP LEARNING)**

**YURI CROTTI (1); FABRIZIO LEAL FREITAS (1); EMERSON LIMA DO NASCIMENTO (1); MARCOS HISASHI NAPOLI NISHIOKA (1); ROBSON FAVERZANI (2); WESLEN SANTOS (2).  
AQTECH (1);  
SANTO ANTÔNIO ENERGIA(2);**

#### **RESUMO**

A ampla demanda no mercado de energia exige que a operação em hidrelétricas aconteça frequentemente em regimes extremos e, por consequência, é constante a preocupação com a detecção antecipada de falhas. Os modos de falha de desbalanceamento e desalinhamento do eixo em unidades hidrelétricas apresentam sintomas característicos. Para resolver esses problemas, neste trabalho é proposta uma abordagem de aprendizado de máquina profundo não supervisionado. Para o desenvolvimento da abordagem proposta foi utilizado um autoencoder profundo. Neste trabalho foi utilizado o banco de registros de vibração da Unidade Geradora 38 da UHE Santo Antônio localizada em Porto Velho. Este modelo foi capaz de detectar problemas relacionados ao desalinhamento e desbalanceamento.

**PALAVRAS-CHAVE:** Deep Learning, Deep Auto Encoder, Hidrogeradores, Desalinhamento, Desbalanceamento.

#### **1.0 INTRODUÇÃO**

A geração de energia hidrelétrica é uma fonte renovável altamente difundida em todo o mundo. Nos dias atuais a alta demanda no mercado de energia exige que a Operação e Manutenção (O&M) em hidrelétricas seja frequentemente em regimes extremos e por consequência é constante a preocupação com a detecção antecipada de falhas. Uma maneira de aumentar a produtividade de uma planta hidrelétrica é garantir que ela seja totalmente operável através de práticas otimizadas de manutenção preditiva.

A ocorrência de falhas podem implicar em tempo de máquina parada e trazer prejuízos financeiros para a empresa que opera a usina. Então encontrar uma maneira de evitar esses tipos de falhas para substituir manutenções corretivas e preventivas por manutenções preditivas é de interesse das empresas de energia.

De acordo com a ISO 13373-7 [1], os modos de falha de desbalanceamento e desalinhamento do eixo em unidades hidrelétricas apresentam sintomas típicos que se manifestam através da variação na magnitude de componentes harmônicos da rotação da máquina. Sendo assim, através do monitoramento de vibração da máquina é possível verificar se há anomalias no espectro de vibração correlacionadas com estes modos de falha. Com análise de vibração pode-se levantar informações de grande valia sobre as condições de saúde do ativo.

O aprendizado de máquina (Deep Learning) faz parte de uma ampla família de métodos de aprendizagem baseado em representação de dados, e tem tido bastante sucesso em avançar seu estado da arte em várias áreas [2]. Porém, no setor elétrico ainda é embrionário o seu uso prático para diagnóstico de falhas.

Estudos que envolvem métodos de aprendizado supervisionados requerem dados rotulados dos modos de falhas que se deseja monitorar, ou seja, que as amostras de dados sejam previamente identificadas como saudáveis ou falhas para que os modelos sejam treinados. Como a maioria das usinas hidrelétricas opera de forma contínua e ininterrupta, não é trivial coletar dados em todas as condições da máquina, ou seja, condições normais e de falha.

Para contribuir para a solução desse problema, neste trabalho é proposto uma abordagem de aprendizado de máquina não supervisionado, mais precisamente em aprendizado profundo (Deep Learning). O modelo de aprendizado profundo proposto é capaz de capturar automaticamente as informações úteis dos sinais e detectar as anomalias e por fim diagnosticar falhas de desalinhamento e desbalanceamento em hidrogeradores.

## 2.0 METODOLOGIA

Nesta seção será apresentada a metodologia deste trabalho. Conforme ilustrado no diagrama da Figura 1 o funcionamento da metodologia proposta é dividido em quatro etapas: aquisição e processamento de dados, extração de características (espectrogramas), treinamento do modelo por aprendizado profundo, detecção de anomalia e agrupamento de falhas.




Figura 1 - Diagrama da metodologia proposta. Fonte: do autor.

### 2.1 Aquisição dos dados

Neste estudo foi utilizado como referência de dados saudáveis o banco de registros de sinais do mancal guia do gerador e mancal guia da turbina da Unidade Geradora (UG) 38 da UHE Santo Antônio localizada em Porto Velho, RO. O mancal guia do gerador conta com 3 proximetros, oscilação radial a 45° e 315°, oscilação axial, amostrados à taxa de 20kHz. Já o mancal guia da turbina conta com 2 proximetros, oscilação radial a 45° e 315° também amostrados à taxa de 20kHz. O banco de dados conta com registros aquisitados entre 2019 e 2021. Na Figura 2 pode ser observado um exemplo de sinal de vibração.




Figura 2- Exemplo de um sinal de vibração. Fonte: do autor

Para contornar a falta de dados e garantir que falhas de desalinhamento e desbalanceamento estivessem presentes nos dados de vibração para ser avaliadas, foi utilizado um método de injeção de anomalias nos sinais digitalizados seguindo as heurísticas de detecção de frequências de interesse da ISO 13373-7 para gerar dados sintéticos no banco de dados.

As Tabelas 1 e 2 apresentam de forma resumida o comportamento característico de cada uma das falhas em cada sensor adotado no trabalho usando a norma ISO 13373-7 como referência.

Tabela 1- Configuração da inserção das falhas nos sensores do mancal do gerador.

Modo de falha	Mancal Gerador		
	Oscilação radial 45°	Oscilação radial 315°	Oscilação axial
Desbalanceamento estático	Excitar fundamental	Excitar fundamental	Permanece inalterado
Desalinhamento paralelo	Excitar a 2ª em 120% da fundamental e 3ª em 30% da 2ª	Excitar a 2ª em 120% da fundamental e 3ª em 30% da 2ª	Permanece inalterado

Tabela 2 - Configuração da inserção das falhas nos sensores do mancal da turbina.

Modo de falha	Mancal Turbina	
	Oscilação radial 45°	Oscilação radial 315°
Desbalanceamento estático	Excitar fundamental	Excitar fundamental
Desalinhamento paralelo	Excitar a 2ª em 120% da fundamental e 3ª em 30% da 2ª	Excitar a 2ª em 120% da fundamental e 3ª em 30% da 2ª

Para cada modo de falha, desalinhamento e desbalanceamento, foram injetados sinais de falhas em cada sensor de acordo com os níveis globais de vibrações pré-estabelecidos pela norma ISO 20815-5 [3]. Os níveis foram: A/B (considerado saudável), acima da transição B/C (considerado como nível de alarme) e acima da transição C/D (considerado crítico).

Para cada modo de falha foram geradas 114 amostras, divididas igualmente dentre os níveis de falha, ou seja, 38 amostras para cada nível. Para um comportamento adotado como normal da máquina foram separadas também 114 amostras.

## 2.2 Extração de Características - Espectrogramas

Um espectrograma pode ser muito útil para a análise de vibração, pois ele oferece uma visão melhor de como a vibração muda ao longo do tempo. Em um espectrograma, podem ser identificados indicadores de falhas como de desalinhamento e desbalanceamento em hidrogeradores.

Uma análise no domínio do tempo pode apontar um defeito, mas não especifica a localização ou a natureza deste defeito. Como uma coleção de análises de frequência de tempo, o espectrograma pode ser usado para identificar características de sinais não estacionários ou não lineares [4].

Segundo [4] um espectrograma é uma representação visual do espectro de frequências de um sinal que varia com o tempo. Em um gráfico de representação de espectrograma um eixo representa o tempo, o segundo eixo representa as frequências e as cores representam a magnitude (amplitude) da frequência observada em um determinado momento.

Para gerar um espectrograma é aplicada Transformada de Fourier de Tempo Curto (STFT), essa transformada é um tipo especial de transformada de Fourier usada quando o espectro de frequência de um sinal varia com o tempo. Consiste em executar as transformadas de Fourier iterativamente em um sinal amostrado, usando uma parte do sinal como entrada (uma pequena janela de tempo).

Segundo [5], sua representação matemática para sinais de tempo contínuos pode ser descrita pela equação 1, onde  $x(t)$  é o sinal de tempo,  $w(\tau)$  é a função janela e  $\tau$  é a variável de tempo.

$$STFT x(t)(t, w) = \int_{-\infty}^{\infty} x(t)w(t - \tau) \exp(-jw\tau) d\tau \quad (1)$$

Em termos de sinais discretos, pode ser descrito pela equação 2:

$$STFT x(n)(n, m) = \sum_{-\infty}^{+\infty} x(n)w(n - m) \exp(-jwn) \quad (2)$$

A Figura 3 apresenta um exemplo de espectrograma.




Figura 3 - Exemplo de espectrograma. Fonte: [4].

Como entrada do algoritmo da abordagem de aprendizado profundo foi utilizado espectrogramas dos sinais de vibração dos sensores do mancal guia do gerador e mancal guia da turbina da Unidade Geradora (UG) 38.

### 2.3 Detecção de anomalias – Deep Autoencoder

A detecção de anomalias é uma tarefa crucial na implantação de modelos de aprendizado de máquina. A detecção de anomalias refere-se à identificação de padrões que não estão de acordo com o comportamento normal esperado [6]. A detecção de anomalias em modelos não supervisionados tenta encontrar anomalias nos dados sem usar qualquer tipo de rótulo.

Para o desenvolvimento da abordagem proposta foi utilizado um autoencoder profundo (Deep Auto Encoder – DAE). Um autoencoder profundo é composto de duas redes neurais artificiais simétricas, onde uma representa codificação e a outra a decodificação. O codificador aceita os dados e os compacta na representação do espaço latente e então o decodificador reconstrói os dados do espaço latente [7]. As anomalias são detectadas analisando o erro de reconstrução dos sinais de vibração, ou seja, a diferença entre os sinais adquiridos e os reconstruídos pela rede neural.

O codificador pode ser representado pela equação 3 de codificação.

$$h = f(x) \quad (3)$$

Já o decodificador pode ser representado pela equação 4 de decodificação

$$r = g(h) \quad (4)$$

O autoencoder de forma geral pode ser descrito pela equação 5, onde você deseja  $r$  tão próximo quanto a entrada original  $x$ .

$$g(f(x)) = r \quad (5)$$

Uma abordagem de deep autoencoder pode utilizar diferentes tipos de camadas e arquiteturas para aprender a representação significativa dos dados. A combinação de estruturas autoencoders com Redes Neurais Convolucionais (CNNs) é uma abordagem padrão do aprendizado profundo não supervisionado em várias tarefas de processamento de sinais. Unindo o codificador e decodificador, camadas convolucionais e deconvolucionais são empregadas para extrair informações essenciais dentro da representação latente [8].

As redes neurais convolucionais são principalmente utilizadas para em abordagens de imagem [9]. Normalmente, uma rede neural convolucional, consiste em uma arquitetura de várias camadas que incluem convolução, pooling, camadas densas, além das camadas de entrada e saída. Quando agregada a uma abordagem de autoencoder, a rede neural convolucional é um método promissor e inovador para tarefas de detecção de anomalias. Arquitetura do deep autoencoder convolucional proposta nesse trabalho pode ser observada na Figura 4.




Figura 4 - Arquitetura deep autoencoder convolucional. Fonte: do autor.

#### 2.4 Agrupamento de Anomalias - Clustering Hierárquico

Além da detecção das anomalias, foi utilizado um método de agrupamento para uma possível classificação dos dados anômalos. Agrupamento de dados é uma técnica que agrupa pontos de dados semelhantes de forma que os pontos no mesmo grupo sejam mais semelhantes entre si do que os pontos nos outros grupos.

O método utilizado para o agrupamento foi o clustering hierárquico aglomerativo. O agrupamento hierárquico aglomerativo é uma abordagem dominante para a construção de agrupamento de objetos com base em sua similaridade e distância [10]. O agrupamento hierárquico aglomerativo é uma abordagem que inicia uma análise *Bottom up*. Ela começa o agrupamento com muitos grupos pequenos e os mescla para criar grupos maiores.

### 3.0 RESULTADOS

O primeiro objetivo da abordagem proposta foi de detecção de dados normais e dados anômalos. Essa detecção se deu pelo erro de reconstrução dos sinais de vibração fornecido pelo deep autoencoder convolucional. Para uma melhor visualização destes sinais de vibração foram extraídas as informações espaço latente do deep autoencoder convolucional. A Figura 5 apresenta o espaço latente extraído e as anomalias detectadas.




Figura 5- Espaço latente DAE e detecção de anomalias. Fonte: do autor.

Nesse conceito de classificação, temos algumas métricas que indicam os erros e acertos de um modelo, comparando com o resultado esperado.

- Verdadeiros Positivos (VP): classificação correta da classe positivo;
- Falsos Negativos (FN): erro em que o modelo previu a classe negativo quando o valor real era classe positivo;
- Falsos Positivos (FP): erro em que o modelo previu a classe positivo quando o valor real era classe negativo;
- Verdadeiros Negativos (VN): classificação correta da classe negativo.

Para uma avaliação da qualidade da abordagem proposta na detecção de anomalias foram utilizadas as métricas de avaliação como acurácia, precisão, f1-score e recall. A equação 6 apresenta como a métrica de acurácia é calculada, essa métrica indica uma performance geral do modelo. Dentre todas as classificações, quantas o modelo classificou corretamente.

$$acurácia = \frac{VP + VN}{VP + FN + FP + VN} \quad (6)$$

A equação 7 apresenta a métrica de precisão, essa métrica indica dentre todas as classificações da classe positiva que o modelo fez, quantas estão corretas.

$$precisão = \frac{VP}{VP + FP} \quad (7)$$

Já a equação 8 apresenta como a métrica de recall é calculada, essa métrica apresenta dentre todas as situações da classe positivo como valor esperado, quantas estão corretas.

$$recall = \frac{VP}{VP + FN} \quad (8)$$

Por fim, equação 9 apresenta a métrica f1-score, essa métrica apresenta uma média harmônica entre precisão e recall.

$$F1 - score = 2 * \frac{precisão * recall}{precisão + recall} \quad (9)$$

A Tabela 3 apresenta os valores das métricas de qualidade no presente estudo, ou seja, o desempenho do modelo de Machine Learning para classificação com base nos dados de monitoramento da máquina.

Tabela 3- Métricas de qualidade na detecção da anomalia.

	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)
Normal	92.0	74.0	95.0	84.0
Anomalia	92.0	99.0	92.0	95.0

Analisando os grupos formados pelo espaço latente do deep autoencoder convolucional apresentados na Figura 5 e a detecção das anomalias com base erro de reconstrução dos sinais, as métricas apresentadas na Tabela 3 mostram que a abordagem apresentou bons resultados para classificação de um dado normal e um dado anômalo, ou seja, desbalanceamento ou desalinhamento.

Em uma segunda etapa, a abordagem proposta analisou somente os dados considerados anômalos e buscou-se agrupar os dados em distintos modos de falhas. Para encontrar o número ótimo de grupos de modos de falha para serem identificados utilizou-se o Método Cotovelo [11], esse método é realizado o agrupamento para várias quantidades diferentes de grupos e como resposta o método apresenta o número ótimo de grupos para esses dados. Como era de se esperar, o número ideal encontrado foi de 2 grupos de modos de falhas.

A Figura 6 apresenta o agrupamento do espaço latente, tendo como objetivo classificar os dados anômalos dos modos de falhas.




Figura 6 - Espaço latente DAE e detecção de anomalias. Fonte: do autor.

Para uma avaliação da qualidade da abordagem proposta na classificação dos dados anômalos, foram utilizadas novamente as métricas para avaliação como acurácia, precisão f1-score e recall. A Tabela 4 apresenta um resumo dos valores das métricas de qualidade da abordagem na classificação dos dados anômalos.

Tabela 4- Métricas de qualidade na classificação dos dados anômalos.

	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)
Desbalanceamento	100.0	100.0	99.0	100.0
Desalinhamento	100.0	99.0	100.0	100.0

Analisando a Figura 6 em conjunto com a métricas apresentadas na Tabela 4, pode-se observar que o espaço latente do deep autoencoder convolucional foi capaz de gerar grupos para os modos de falhas de desbalanceamento e desalinhamento e que foi possível classificar os modos de falhas com valores excelentes pelo ponto de vista das métricas de aprendizado de máquina.

#### 4.0 CONCLUSÕES

Os resultados confirmam que a abordagem proposta baseada em aprendizado profundo é eficaz e robusta na detecção de anomalias com base no erro de reconstrução do deep autoencoder convolucional nos dados de vibração não rotulados.



A abordagem também foi capaz de agrupar e detectar problemas relacionados ao desalinhamento e desbalanceamento em unidades hidrelétricas utilizando dados não rotulados, o que aponta que a abordagem baseada em aprendizado profundo utilizando autoencoder é promissora em auxiliar no diagnóstico de outras falhas em unidades hidrelétricas, contribuindo para a manutenção preditiva no setor elétrico brasileiro.

## 5.0 AGRADECIMENTOS

Este trabalho é parte integrante do projeto de P&D ANEEL PD-06683-0220/2020 intitulado “Sistema de Aprendizado de Máquina (Machine Learning) para análise e diagnóstico de falhas em hidroelétricas com base em dados de processo, vibração e acústica”. Agradecemos a contribuição da equipe da Santo Antônio Energia em viabilizar este projeto de pesquisa.

## REFERÊNCIAS

- (1) INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. ISO 13373-2- Condition monitoring and diagnostics of machines — Vibration condition monitoring. P. 8,2016.
- (2) ZHOU, Chong; PAFFENROTH, Randy C. Anomaly detection with robust deep autoencoders. In: Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining. 2017. p. 665-674., pp. 665–674.
- (3) INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. ISO 20816-5. Mechanical vibration - Measurement and evaluation of machine vibration — Part 5: Machine sets in hydraulic power generating and pump-storage plants. P. 3,2018.
- (4) BOASHASH, Boualem. Time-frequency signal analysis and processing: a comprehensive reference. Academic press, 2015.
- (5) AHMED, Hosameldin; NANDI, Asoke K. Condition monitoring with vibration signals: Compressive sampling and learning algorithms for rotating machines. John Wiley & Sons, 2020.
- (6) CHANDOLA, Varun; BANERJEE, Arindam; KUMAR, Vipin. Anomaly detection: A survey. ACM computing surveys (CSUR), v. 41, n. 3, p. 1-58, 2009.
- (7) GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep learning. MIT press, 2016.
- (8) CHADHA, Gavneet Singh et al. Deep Convolutional Clustering-Based Time Series Anomaly Detection. Sensors, v. 21, n. 16, p. 5488, 2021.
- (9) LECUN, Yann et al. Convolutional networks for images, speech, and time series. The handbook of brain theory and neural networks, v. 3361, n. 10, p. 1995, 1995.
- (10) MURTAGH, Fionn; CONTRERAS, Pedro. Algorithms for hierarchical clustering: an overview. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, v. 2, n. 1, p. 86-97, 2012.
- (11) BHOLOWALIA, Purnima; KUMAR, Arvind. EBK-means: A clustering technique based on elbow method and k-means in WSN. International Journal of Computer Applications, v. 105, n. 9, 2014.

## DADOS BIOGRÁFICOS



Yuri Crotti nasceu em Lauro Muller/SC em 1994. É mestre em Tecnologia da Informação e Comunicação (2020) e graduado em Engenharia da Computação (2018), ambos pela Universidade Federal de Santa Catarina. Desde 2012 trabalha em projetos envolvendo inteligência artificial, visão computacional (computer vision), aprendizado de máquina (machine learning) e ferramentas para monitoramento e controle de ambientes nos setores energético e industrial. Atualmente é Cientista de Dados e Desenvolvedor de Machine Learning na AQTech Power Prognostics de Florianópolis

## (2) FABRIZIO LEAL FREITAS



Fabrizio Leal Freitas nasceu em São Paulo/SP em 1977. É doutorando em Ciência da Computação, mestre em Engenharia de Produção (2010), graduado em Engenharia de Produção Elétrica (2005) pela UFSC. Desde 2003 trabalha com desenvolvimento de produtos inovadores, em especial sistemas de monitoramento e diagnóstico para plantas de geração de energia. Atua como pesquisador e coordenador em projetos de PD no programa ANEEL em cooperação com concessionárias do setor elétrico. Atualmente é consultor de PD/Data Science na AQTech de Florianópolis e pesquisador em Machine Learning no Laboratório de Integração de Software e Hardware (LISHA/UFSC).

(3) EMERSON LIMA DO NASCIMENTO

Graduado em engenharia eletrônica pela Universidade Federal de Pernambuco (UFPE). Atualmente é analista de software na AQTech Power Prognostics, participando de projetos de pesquisa, desenvolvimento e inovação na área de manutenção preditiva de hidro e aerogeradores, com ênfase em processamento digital de sinais, inteligência artificial e computacional.

(4) MARCOS HISASHI NAPOLI NISHIOKA

Graduado em engenharia mecânica pela Universidade Federal de Santa Catarina (UFSC, 2018). Bolsista pelo Laboratório de Engenharia Biomecânica (LEBm/HU-UFSC) de 05/2015 a 05/2017 em análise de materiais e ensaios mecânicos. Consultor de projetos para i9 Consultoria, Empresa Junior de 07/2016 a 12/2017. Estagiário de engenharia pela empresa Wier, Tecnologia em Plasma e Ozônio de 06/2017 a 11/2017. Engenheiro Mecânico e Analista de vibrações pela AQTech de 07/2018 até o presente momento. Possui foco no desenvolvimento de soluções para diagnóstico de máquinas rotativas a partir de análise de vibrações. Pós-graduando em nível Mestrado na UFSC, área de Vibrações e Acústica.

(5) ROBSON FAVERZANI

Resumo sobre o co-autor

(6) WESLENS SANTOS

Resumo sobre o co-autor