



Grupo de Estudo de Geração Hidráulica-GGH

MONITORAMENTO DE GRUPOS GERADORES DO TIPO KAPLAN UTILIZANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL

IGOR RENAN BRAGA DOS SANTOS(1); OSWALDO HONORATO DE SOUZA JÚNIOR(1); GERALDO LÚCIO TIAGO FILHO(1); JÚLIO CESAR SILVA DE SOUZA(1); TIAGO MARTINS DE AZEVEDO(1); OTÁVIO AUGUSTO SALGADO CARPINTEIRO(1); HAILTON SILVEIRA DOMINGUES BIANCARDINE JÚNIOR(1); UNIFEI(1);

RESUMO

É comum em centrais hidrelétricas novas e repotencializadas, a instalação de sensores para monitorar os níveis de vibração dos grupos geradores. Entretanto, ainda não são utilizadas técnicas de aprendizagem por redes neurais associadas a estes sinais de monitoramento do comportamento da máquina. Atualmente, as técnicas de emissão acústica (isto é, a utilização desses sinais) vem sendo amplamente desenvolvida exclusivamente para detecção e monitoramento do fenômeno da cavitação. E mesmo neste campo, a tecnologia não se encontra consolidada, sendo um enorme desafio devido à complexidade do fenômeno e aos fatores que tendem a influenciar a natureza da excitação e que são determinantes na trajetória da transmissão dos sinais, tais como sua contaminação por ruídos provenientes de outras fontes de excitação, sejam hidrodinâmicas, mecânicas ou eletromagnéticas. Este artigo aborda o desenvolvimento de um sistema de monitoramento das condições de operação das turbinas hidráulicas do tipo Kaplan, bem como de um módulo de auxílio à operação ótima das mesmas, por meio de técnicas de aprendizagem de máquina, mais especificamente redes neurais artificiais (RNAs). Uma das funcionalidades do produto é a capacidade de reconhecer e classificar padrões (estado vibratório cavitante, estado vibratório não-cavitante, etc.), permitindo o monitoramento dos fenômenos advindo das diversas perturbações nas turbinas hidráulicas, por meio da 'assinatura' da vibração provocada por esses fenômenos com a turbina operando sob diferentes condições, de forma a definir um protocolo de operação e manutenção preditiva capaz de minimizar os danos advindos dessas ocorrências e alertar o operador quanto à máquina operar fora dos limites definidos para cada parâmetro medido. Trata-se de um modelo estatístico cujos parâmetros são ajustados com o propósito de construir um classificador, o qual quando alimentado com os dados advindos dos sensores que inspecionam os vários pontos da máquina, é capaz de diferenciar o comportamento das perturbações no grupo gerador operando sob diferentes condições operacionais. Com efeito, tais informações, combinada com os dados e outras situações indesejadas, permite que o sistema integrado restrinja, ou não, este ponto do campo operacional da máquina. Basicamente, o sistema de monitoramento dessas perturbações no grupo gerador, sob diferentes condições operacionais, visa permitir que a turbina opere em melhores condições, tornando-se menos suscetíveis a danos físicos e a perda de rendimento, bem como reduzindo as paradas programadas para a manutenção da máquina. Como se pode observar, à princípio, trata-se de um sistema de aplicabilidade a qualquer unidade geradora, como de fato é, permitindo monitorar o comportamento da máquina, dando suporte à operação nas alterações de carga, visando mitigar os danos advindos da própria operação, que venham a refletir em manutenções corretivas e/ou paradas de máquina. No entanto, há alguns pontos relevantes a serem salientados, tais como: estabelecidos os limites e as faixas operacionais adequadas à operação e treinando o algoritmo inteligente por redes neurais, o mesmo a partir desses pontos, poderá sinalizar, indicar e alertar quanto a pontos indesejados de operação da unidade. O sistema servirá especificamente para esta máquina. Caso se deseje instalar o sistema em outra unidade, será necessário treinar novamente a rede neural para as novas condições operacionais da unidade geradora desejada. Dessa forma, deve-se ajustar novas condições de contorno operacional em relação ao campo de operação, no sentido de ampliar ou restringir pontos danosos, aplicando o sistema a diferentes unidades geradoras.

PALAVRAS-CHAVE

Monitoramento, Grupos Geradores, Rede Neural Artificial.

1.0 - INTRODUÇÃO

Um dos problemas que vem sendo enfrentado por diversas empresas, em especial aquelas relacionadas à geração hidrelétrica, está relacionado à operação das unidades geradoras em condições de baixas quedas e baixas vazões, devido aos longos períodos de estiagem, nos quais os reservatórios se encontram em níveis baixos de armazenamento, ou mesmo para reservatórios a fio de água, com baixas vazões, aquém das definidas e avaliadas pelos cálculos hidrológicos durante a sua implantação. Ou seja, as unidades têm operado em condições parciais com extremos limites em relação as oscilações de potência, pressão e vibrações em partes e componentes das turbinas, o que ao longo do tempo reduz a vida útil das unidades geradoras, em especial a turbina, além do aumento nas manutenções corretivas e por consequente aumento nos custos de operação e manutenção da central, e cuja Taxa de Indisponibilidade poderá repercutir em penalizações por não atendimento da Garantia Física.

As unidades dessas centrais já operam com baixa carga, e em muitos casos, com baixo fatores de capacidade, devido às condições hidrológicas e operacionais. Com isso, torna-se necessário, uma avaliação criteriosa bem como iniciativas, no sentido de otimizar a operação das unidades, com vistas a ampliar, dentro do possível, as faixas operacionais, minimizando os efeitos danosos deste tipo de operação e propiciando um aumento da vida útil dessas unidades, e, por consequência, uma redução de custos e das horas de indisponibilidade forçada.

Para solucionar estes problemas, tem-se como alternativa, o sistema proposto. Em função da unidade geradora, o sistema tem seu algoritmo desenvolvido e implantado, tanto em operação experimental, juntamente com os sensores instalados, quanto integrado aos ensaios de comportamento realizados no campo e em condições operacionais reais, respeitando os seus limites, ou até mesmo extrapolando-os, no sentido de determinar as reais condições operacionais dessas unidades. Dessa forma, com o devido treinamento da rede neural, o sistema auxiliará nas tomadas de decisões e até mesmo permitirá que se amplie os limites do campo operacional das unidades geradoras.

Nesse contexto, o desenvolvimento deste sistema inteligente, aliado ao sistema de aquisição e análise de sinais, monitorando todos os pontos relevantes da unidade turbina e gerador, em conjunto com as análises realizadas e de sua implantação, torna-se uma ferramenta fundamental na eficiência hidro-energética, principalmente no sentido de otimizar e ampliar a faixa operacional das turbinas e geradores da central, o que poderá até impactar no aumento da geração, ou até mesmo na recuperação ou o incremento da garantia física definida e ajustada com o poder concedente.

2.0 - DETECÇÃO E MONITORAMENTO DOS PRINCIPAIS FENÔMENOS UTILIZANDO REDES NEURAS

3.0 - 2.1 Contexto

A unidade geradora é o principal componente de uma usina hidrelétrica. O correto funcionamento desse elemento é essencial para segurança, estabilidade do sistema, produção de energia, confiabilidade da transmissão e custo operacional da central. A natureza variável da demanda por energia elétrica faz com que, cada vez mais, os grupos geradores, e principalmente, as turbinas hidráulicas trabalhem em condições parciais que divergem do ponto ótimo de operação. Em tais situações, tem-se a presença de fenômenos indesejados e nocivos ao funcionamento dos equipamentos, a saber: cavitação, flutuações de pressão, flutuações de potência e sobreaquecimento dos mancais. O diagnóstico dessas situações evita grande perdas econômicas e minimiza as chances de ocorrerem acidentes. Dessa forma, técnicas capazes de estender o campo operacional desses equipamentos precisam ser desenvolvidas.

Com exceção da cavitação, cuja detecção e monitoramento ocorrem indiretamente por meio da análise de vibração, todos os outros fenômenos supracitados são passíveis de mensuração direta, por meio de sensores. Dessa forma, grande parte do estado da arte deste tema tem seus trabalhos voltados para o monitoramento da vibração.

Aproximadamente 80% das falhas em unidades geradoras de turbinas hidráulicas são identificadas em sinais de vibração. (1). Assim, a qualidade e desempenho de uma máquina ou equipamento é determinada pela amplitude de vibração. O excesso de vibração pode causar desgaste, falhas e ruído intenso.

Contudo, essas vibrações são de complexa análise já que sofrem influências de fatores de ordem hidráulica, mecânica e elétrica/eletrônica que interagem entre si assumindo características não lineares, o que torna difícil estabelecer uma relação direta de causa e efeito. (2) (3).

As falhas podem ocorrer ao mesmo tempo e em diferentes componentes e partes da unidade geradora. Sendo assim, há uma grande demanda em se classificar de forma eficaz as relações complexas de causas e seus

sintomas resultantes (4). Nesse cenário, o monitoramento da condição de vibração é feito para avaliar as condições de desempenho em tempo real dos equipamentos, fornecendo indícios antecipados de falha eminente, de modo a evitar manutenções desnecessárias.

4.0 - 2.2 Principais fenômenos

2.2.1. Vibração

Existem basicamente três tipos de vibrações em grupos geradores de usinas hidrelétricas: vibração hidráulica, vibração mecânica e vibração elétrica/eletrônica.

A vibração hidráulica é resultado da interação entre o fluxo de água e a estrutura da unidade geradora. Vários podem ser os fatores que levam ao seu aparecimento, como variações de pressão, cavitação, obstáculos ao fluxo e vórtice de Von Karman. Contudo, a frequência de vibração é diferente para cada fonte de vibração.

A vibração mecânica é geralmente devido a danos nos componentes da unidade geradora e eventuais erros de instalação que podem causar desequilíbrio rotacional, desalinhamento de eixo, problemas no rolamento, frouxidão mecânica, distorção de fundação e fricção entre componentes. A frequência de vibração é, portanto, um múltiplo da frequência de rotação.

A vibração elétrica é resultado de diversos fatores como curto-circuito, erros na ordem de polaridade, desequilíbrio de corrente, e espaçamentos de ar não uniforme entre o rotor e estator. Esses fatores podem causar desequilíbrios da atração magnética, não uniformidade da densidade do fluxo magnético e afrouxamento/deslocamento do núcleo do estator. Nestes casos, a frequência de vibração é a frequência de rotação do gerador.

Apresenta-se na Figura 1 um resumo dos principais motivos de vibração hidráulica, mecânica e elétrica em grupos geradores.

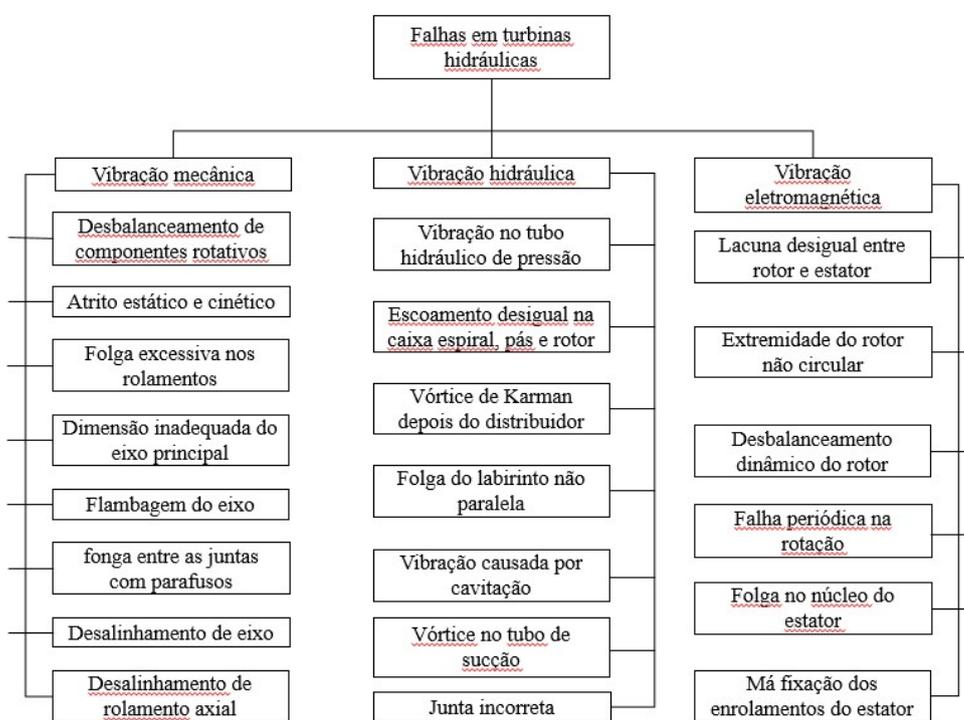


Figura 1 – Principais falhas em grupos geradores hidrelétricos devido à vibração. Fonte: (4) adaptado

Outra forma de se classificar os tipos de vibração é pelo local onde elas ocorrerem, no caso, motor, rotor, turbina, transformador, conduto forçado e gerador. Destacam-se, na sequência, as principais causas de vibração por componente. (3).

No motor, os problemas mecânicos são devido a desequilíbrios, desalinhamentos, danos devido a choques mecânicos, rolamento com defeito, frouxidão, falta de alinhamento com o solo. Já os problemas elétricos são devido a forças eletromagnéticas desequilibradas no rotor e no estator.

Na turbina a principal causa de vibração é a cavitação. A cavitação ocorre quando um líquido escoar numa região onde a pressão se reduz à pressão de vapor, ele ferve, formando bolhas de vapor numa massa líquida. As bolhas são arrastadas pelo líquido até regiões de pressão mais elevada onde entram em colapso quase instantaneamente. Se as bolhas de vapor estão próximas (ou em contato) a uma fronteira sólida quando entram em colapso, as forças exercidas pelo líquido, ao preencher os espaços anteriormente ocupados pelo vapor, criam pressões localizadas extremamente elevadas que causam erosão (destacamento de material) na superfície sólida. O fenômeno é acompanhado de ruído e vibrações. (5).

O fenômeno de cavitação pode ser observado em diversos tipos de sistemas hidrodinâmicos e provoca a redução da eficiência da máquina. (6). A perda da eficiência da máquina está associada a três efeitos à cavitação: geração de ruído, vibração e a erosão. O processo violento de colapso da cavidade ocorre num curto espaço de tempo de cerca de vários nano segundos e resulta na emissão de frequência de ruído de grande amplitude. (7)

Além dos problemas citados anteriormente outros merecem ser destacados como: defeitos em rolamentos, falta de alinhamento com o solo, lubrificações inadequadas, desalinhamento do eixo, erosão abrasiva, operação fora das condições normais de projeto, desequilíbrio devido ao desgaste desigual de componentes, excentricidades, distorções, imperfeições, corrosão, acumulação de material e tolerância de folgas.

No transformador a força magneto-motriz causa vibrações no núcleo e nos enrolamentos causando um ruído que tem uma frequência duas vezes maior que a frequência de alimentação.

No conduto forçado a principal fonte de vibração ocorre com a mudança súbita no fluxo de água devido, por exemplo, ao fechamento brusco da comporta. A esse fenômeno dá-se o nome de golpe de aríete.

No gerador as fontes de vibração são devido a desequilíbrios nas forças magnéticas decorrentes geralmente de ar entre rotor e estator, falha de isolamento de qualquer polo, carga desigual no gerador, alta descarga parcial e enrolamentos soltos.

Em relação ao monitoramento da vibração, a técnica mais utilizada é a avaliação da severidade de vibração com base em alguma medida de nível global do sinal vibratório, tal como valor RMS, amplitude pico a pico ou zero a pico. Também são utilizadas medidas de ângulos de fase e diagramas de órbita. (8). Normas e recomendações foram e continuam sendo confeccionadas para quantificar a severidade de vibração. Todas são fontes de estudos de órgãos internacionais tais como a *International Organization for Standardization* (ISSO), *Deutscher Institut für Normung* (DIN), e no Brasil, a Associação Brasileira de Normas Técnicas (ABNT). Todas utilizam características do sinal no domínio do tempo para cálculo dos parâmetros e assim estimar a condição de funcionamento do equipamento por meio de tabelas e cartas de severidade. No domínio da frequência, o diagnóstico utilizando análise espectral ainda é a técnica mais comumente usada, pois, com uso do algoritmo da Transformação Rápida de Fourier (FFT) pode-se obter o espectro de frequências do sinal sendo, cada uma, relacionada a uma fonte de ruído proveniente do equipamento, considerando que o sinal vibratório captado pelo instrumento de detecção, no caso de acelerômetro, é o somatório das diversas fontes excitadoras do equipamento. As fontes excitadoras mais comuns são: frequência de giro dos eixos, frequência de engrenamento para equipamentos mecânicos que possuem pares engrenados, frequência de passagem das pás em ventiladores ou turbinas, frequência dos elementos rolantes, entre outras.

As normas internacionais publicam, a título de recomendação, cartas de severidade de vibração baseadas nos valores da amplitude máxima e pico-pico máxima, em que se identifica os níveis referentes a máquina em boas condições, aceitável, limite tolerável e não-permissível, para medições realizadas com as máquinas trabalhando nas suas condições nominais de operação e com temperaturas de óleo dos mancais estabilizadas (9).

É importante frisar que, como pode ser observado, a tecnologia ainda não se encontra consolidada, necessitando ainda de diversos avanços. Dessa forma, apresentam-se, a seguir, os principais estudos dispostos na literatura científica em relação a esta abordagem.

Estudos de diversos métodos e técnicas de diagnósticos de falhas foram levantados, e podem ser brevemente classificados nos seguintes itens: baseados em regras, baseados em conhecimento, baseado em modelos,

baseados em casos, rede neural, teoria de conjuntos aproximados, lógica *fuzzy* e método estatístico. (10). Muitos desses métodos são empregados para grupos geradores hidrelétricos.

Ainda em relação a detecção de falhas, há relatos sobre o uso de regras heurísticas em conjunto com redes neurais para a detecção em sistemas complexos. (11). Estuda-se também o uso de um conjunto de regras associada a colaborações de agentes visando três estágios de gerenciamento: detecção, diagnóstico e recuperação.(12).

Quanto ao uso de redes neurais, já foram utilizados uma rede neural *wavelet* e um algoritmo de otimização (colônia de formigas), para determinar os valores dos parâmetros da rede neural, no diagnóstico de falhas de vibração de uma unidade geradora hidrelétrica. (13). Tal estudo verificou que o algoritmo de otimização melhorou o desempenho da rede neural. Também há relatos sobre a utilização de um conjunto de redes neurais probabilísticas (RNPs) e um algoritmo de otimização (enxame de partículas), para selecionar as RNPs com melhor desempenho, no diagnóstico de falhas em máquinas rotativas. (14).

Ainda em relação ao diagnóstico de vibrações, verifica-se também a utilização de vibrações típicas de seis tipos de falhas de geradores hidrelétricos como dados de entrada de redes neurais *fuzzy*. (15).

Verificou também que, quando se trata do diagnóstico de falhas do gerador hidráulico, o método tradicional de análise no domínio de tempo-frequência é incapaz de processar a característica não linear do hidrogerador. Assim, eles propuseram um novo método baseado em funções não-lineares de resposta de frequência. Os resultados obtidos indicam que o método proposto é eficaz e conciso tanto no diagnóstico de faltas quanto na análise não linear de hidrogeradores. (16).

2.2.2. Flutuações de pressão e oscilações de potência

As flutuações de pressão e as oscilações de potência estão vinculadas, de forma que estas derivam sua existência daquelas. (17). Tipicamente, quando a produção de energia elétrica é maximizada e se aproxima de seu ponto máximo, oscilações de pressão autoexcitadas no próprio sistema hidráulico podem surgir e isso se traduz em flutuações na geração de potência elétrica, que são nocivas à integridade dos equipamentos. (18).

A flutuação de pressão é um dos parâmetros de maior importância para a caracterização da estabilidade de uma turbina hidráulica do tipo Kaplan. (18). É um fenômeno resultante do fluxo hidráulico instável, fonte de uma série de fenômenos nocivos e indesejados, tais como: vibrações, danos às pás da turbina hidráulica e ressonância com toda a instalação. (18). Em certos modelos de turbina hidráulica, a flutuação de pressão, bem como a consequente oscilação de potência, pode ocorrer não apenas em condições parciais, mas, até mesmo, em pontos próximos do ponto ótimo de operação. Assim, devido a sua importância, torna-se necessário investir na monitoração desse fenômeno.

2.2.3. Cavitação

O problema de engenharia de maior importância, associado à cavitação, seja, talvez, o dano causado às máquinas hidráulicas, que ocorre quando as bolhas colapsam nas vizinhanças da estrutura sólida. (19). Essa grande quantidade de implosões introduz grandes perturbações no padrão vibratório das turbinas, visto que cada implosão produz ondas de choque de grande amplitude e altamente localizadas. Nesse contexto, a técnica de análise por vibração é um método prático para a detecção da cavitação e, de fato, observa-se que, para o monitoramento das condições de uso de máquinas rotativas, a análise de vibração tem sido a técnica mais empregada. (18).

Já foi estabelecida a viabilidade técnica de se aplicar MLPs no monitoramento da cavitação em turbinas hidráulicas do tipo Francis, visto que já foi atestado que tanto as Redes Neurais Artificiais (RNAs) quanto às árvores de decisão são capazes de diferenciar o padrão vibratório cavitante do não-cavitante em turbinas hidráulicas. (20) (21) (22) (23) (24) (25). Bons resultados foram alcançados aplicando redes neurais artificiais na detecção da cavitação, destacando-se que, por meio da rede neural construída, foi possível observar a influência da temperatura na indução do comportamento cavitante. (26). Atesta-se, portanto, que as RNAs se constituem em ferramentas poderosas no gerenciamento e operação inteligente de turbinas hidráulicas. (27). Também foram obtidos resultados promissores quanto ao monitoramento, por meio de RNAs, das condições de uso de eixos rotativos. (28). Além disso, mostra-se que as MLPs, treinadas por meio do algoritmo da retropropagação do erro, superam os métodos estatísticos tradicionais. Por meio da rede neural RBF, pode-se também prever o impacto que a geometria das pás terá sobre o desempenho, em regime de cavitação, de bombas centrífugas. (29).

5.0 - 2.3 Conceituação básica sobre redes neurais MLP

As Redes Neurais Artificiais (RNAs) têm sido amplamente utilizadas nas mais diversas áreas do conhecimento, tais como, previsões de séries temporais, controle e análise de sinais. O *multilayer perceptron* (MLP) será o modelo de RNA utilizado nesse projeto. Quando utilizado em problemas de classificação de padrões, ele constrói, por meio de treinamento supervisionado, uma função não-linear que separa os padrões segundo classes pré-definidas.

O modelo neural *multilayer perceptron* (MLP) mostrado na Figura 2 é um modelo matemático de interpolação composto por três camadas de neurônios artificiais.

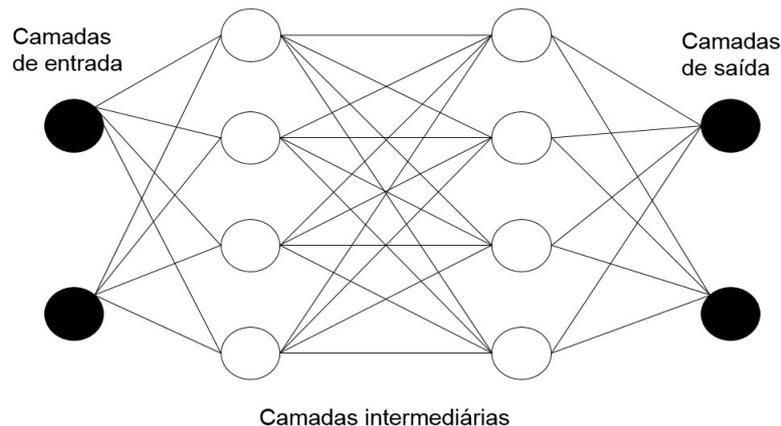


Figura 2 – Arquitetura do modelo MLP.

A camada de entrada recebe um padrão de entrada e a camada de saída produz um padrão de saída correspondente ao padrão de entrada. A ativação do padrão de entrada é propagada para os neurônios da camada (ou das camadas) intermediária e, por fim, para a camada de saída. Os neurônios da camada intermediária e, às vezes, os da camada de saída possuem uma função de ativação não-linear, o que torna o MLP um modelo não-linear.

As funções de ativação do MLP são funções não-lineares e diferenciáveis, como, por exemplo, a função dada pela Equação (1).

$$f(\text{net}) = \frac{1}{(1 + e^{-k\text{net}})} \quad (1)$$

A função de erro, isto é, a função a ser minimizada, é dada pela Equação (2).

$$E_p = \frac{1}{2} \sum_j (o_j - t_j)^2 \quad (2)$$

em que o_j é a saída obtida do neurônio j e t_j é a saída esperada do neurônio j .

2.3.1. Algoritmo de Treinamento da Rede Neural MLP

De maneira geral, o algoritmo de treinamento da rede MLP consiste basicamente no ajuste dos pesos da rede, de forma a minimizar a função de erro (Equação (2)). Para isto, para cada peso w_{ij} , é calculado um termo de correção do erro δ_{pj} . O cálculo do termo de correção inclui, naturalmente, o cálculo das derivadas parciais da função de erro em relação aos pesos.

O algoritmo de treinamento da rede MLP compreende duas etapas:

1. Propagação positiva do sinal funcional: durante esta etapa, todos os pesos da rede são mantidos fixos;

2. Retropropagação (*back-propagation*) do erro: durante esta etapa, o sinal de erro é propagado em sentido oposto ao de propagação do sinal funcional e os pesos da rede são ajustados tendo, por base, uma medida de erro.

Especificamente, o algoritmo de treinamento compreende, de forma simplificada, os seguintes passos (30):

1. Inicializar os pesos w_{ij} do MLP;
2. Apresentar o padrão de entrada $X_p = (x_0, x_1, x_2, \dots, x_{n-1})$ e o padrão de saída desejado $T_p = (t_0, t_1, t_2, \dots, t_{m-1})$, onde n é o número de neurônios da camada de entrada e m é o número de neurônios da camada de saída.
3. Cada neurônio i de uma camada passa uma ativação o_{pi} , calculada de acordo com a Equação (3), para cada neurônio j da camada seguinte.

$$o_{pj} = f(\text{net}_{pj}) \quad (3)$$

em que net_{pj} é calculado de acordo com a Equação (4).

$$\text{net}_{pj} = \sum_i \omega_{ij} x_i \quad (4)$$

em que w_{ij} é o peso da conexão do neurônio i , de uma camada, ao neurônio j da camada seguinte.

4. Adaptar todos os pesos, iniciando-se na camada de saída e terminando-se na camada de entrada, de acordo com a Equação (5).

$$\omega_{ij}(t+1) = \omega_{ij}(t) + \eta \delta_{pj} o_{pi} \quad (5)$$

em que t representa a iteração de atualização do peso w_{ij} , η é a taxa de aprendizagem e δ_{pj} é um termo de correção do erro do peso w_{ij} , dado pelo padrão p .

Se j é um neurônio da camada de saída, δ_{pj} é calculado pela Equação (6).

$$\delta_{pj} = f'(\text{net}_{pj}) \cdot (t_{pj} - o_{pj}) \quad (6)$$

em que f' é a derivada da função f (Equação (1)). Se j é um neurônio da camada oculta, δ_{pj} é calculado pela Equação (7).

$$\delta_{pj} = f'(\text{net}_{pj}) \sum_k \delta_{pk} \omega_{jk} \quad (7)$$

em que a soma é realizada sobre os k neurônios da camada anterior à do neurônio j .

6.0 - CONCLUSÃO

O trabalho elabora uma revisão bibliográfica sobre o tema, com a finalidade de discutir os meios possíveis e viáveis de detecção dos fenômenos nocivos à operação de turbinas do tipo Kaplan. A proposta é fundamentada nas medições de vibração, estabelecendo um padrão para o monitoramento por meio de redes neurais, fundamentado na associação entre esses fenômenos vinculados a processos de manutenção preditiva e que represente um diferencial de análise, permitindo que a partir de um campo básico inicial operacional, se possa contornar e avaliar esses fenômenos *on-line*, de maneira à ampliar este campo por meio de um sistema inteligente que avalie os limites operacionais em quaisquer pontos de operação.

Torna-se, dessa forma, extremamente relevante, principalmente em função dos benefícios do sistema de monitoramento das condições operacionais dos grupos geradores, uma vez que consolidado implicará em uma operação otimizada com ganhos de energia média gerada, aumento da vida útil dos equipamentos e redução dos custos operacionais. A melhoria e o desenvolvimento de um sistema inteligente de gerenciamento operacional

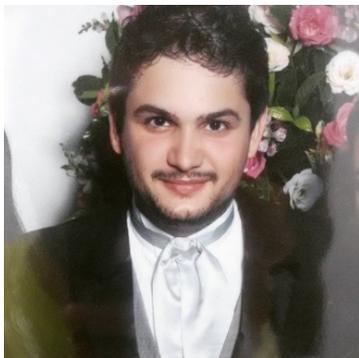
têm como objetivo a ampliação da faixa operacional, procurando impactar de maneira positiva no planejamento de manutenção de boa parte das centrais hidrelétricas, o qual, atualmente, se baseia em sistemas de monitoramento dos parâmetros operacionais e diagnóstico de possíveis problemas surgidos ao longo do tempo. No entanto, a maioria desses sistemas disponíveis se encontra fundamentada em inspeções periódicas intrusivas, gerando custos com indisponibilidade das unidades geradoras, mão de obra e eventualmente com consumo desnecessário de material devido à imprevisão do momento adequado para o reparo.

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) ZHAO, D; MA, W; LIANG, W.-K; LUO, X.-Q. Data fusion fault diagnosis and simulation of hydroelectric units vibration. Proceedings of the Chinese Society of Electrical Engineering, vol. 25, no. 20, pp. 137–142, 2005.
- (2) SHEN, D.; CHU, F.; CHEN, S. Diagnosis and identification of vibration accident for hydro-generator unit. Journal of Hydrodynamics, vol. 15, no. 1, pp. 129–133, 2000.
- (3) MOHANTA, R.; CHELLIAH, T.; ALLAMSETTY, S.; AKULA, A.; CHOSH, R. Sources of vibration and their treatment in hydro power stations-A review. Engineering Science and Technology, an International Journal, 20, 637–648, 2017.
- (4) ZHANG, X.; ZHOU, J.; GUO, J.; ZOU, Q.; HUANG, Z. Vibrant fault diagnosis for hydroelectric generator units with a new combination of rough sets and support vector machine. Expert Systems with Applications, 39, 2621–2628, 2012.
- (5) STREETER, V. L.; WYLIE, E. B.; BEDFORD, K. W. Fluid Mechanics 9th. 1997.
- (6) KOIVULA, T. On Cavitation in Fluid Power. Proc. Of 1^a PFNI-PhD Symp, Hamburg 2000, pp. 371-382.
- (7) ESCALER, X.; EGUSQUIZA, E.; FARHAT, M.; AVELLAN, F.; COUSSIRAT, M. Detection of cavitation in Hydraulic Turbines. Mechanical Systems and Signal Processing 20, 2006, pp. 983-1007.
- (8) PUSEY, H. C. & ROEMER, M. J. “An assessment of Turbomachinery condition monitoring and failure prognosis technology”, The Shock and Vibration Digest, p. 365-371, vol. 31, 1999.
- (9) ARATO, A. J., “Manutenção preditiva usando análise de vibrações”, Barueri, Editora Manole Ltda, 2004.
- (10) SONG, G.; HE, Y.; CHU, F.; GU, Y.; HYDES: A Web-based hydro turbine fault diagnosis system. Expert Systems with Applications, vol. 34, 764–772. 2008.
- (11) JAMSA JOUNELA, S.-L.; VERMASVUORI, M.; ENDE’N, P; HAAVISTO, S. A process monitoring system based on the Kohonen self-organizing maps. Control Engineering Practice, 11(1), 83–92, 2003.
- (12) CHO, KWANG-JONG; AHN, SEONG-JIN; CHUNG, JIN-WOOK. A study on the classified model and the agent collaboration model for network configuration fault management. Knowledge-Based Systems Volume, 16(4), 177–190, 2003.
- (13) XIAO, Z.; HE, X.; FU, X.; MALIK, O. P. ACO-Initialized Wavelet Neural Network for Vibration Fault Diagnosis of Hydroturbine Generating Unit. Mathematical Problems in Engineering, 2015.
- (14) WANG, Z.; LU, C.; ZHOU, B. Fault diagnosis for rotary machinery with selective ensemble neural networks. Mechanical Systems and Signal Processing, 113, 112-130, 2018.
- (15) YU, W.; WANG, Y.; GUI, W.; YANG, C. A vibration fault diagnosis system of hgs based on fnn. School of Information Science and Engineering - Central South University, China, 2006.
- (16) XIA, X.; ZHOU, J.; LI, C.; ZHU, W. A novel method for fault diagnosis of hydro generator based on NOFRFs. Electrical Power and Energy Systems, 71, 60–67, 2015.
- (17) MULLER, A; FAVREL, A; LANDRY, C; AVELLAN, F. Fluid–structure interaction mechanisms leading to dangerous power swings in francis turbines at full load 69 (2017) 56–71.

- (18) WU, Y; LI, S; LIU, S; DOU, H –S; QIAN, Z. Prediction of Pressure Fluctuation by Turbulent Flow Analysis, Springer Netherlands, Dordrecht, 2013, pp. 237–275.
- (19) BRENNEN, C. E. Cavitation and Bubble Dynamics, Cambridge University Press, 2013.
- (20) HOCEVAR, M.; SIROK, B.; BLAGOJEVIC, B. Prediction of cavitation vortex dynamics in the draft tube of a francis turbine using radial basis neural networks 14 (2005) 229–234.
- (21) YONG, W.; LIN, L. H.; QI, Y. S.; GAO, T. M.; Kai, W. Prediction research on cavitation performance for centrifugal pumps, in: 2009 IEEE International Conference on Intelligent Computing and Intelligent Systems, vol. 1, 137–140, 2009.
- (22) GRUBER, P.; ODERMATT, P.; ETTERLIN, M.; LERCH, T.; FREI, M.; FARHAT, M. The detection of cavitation in hydraulic machines by use of ultrasonic signal analysis, IOP Conference Series: Earth and Environmental Science 22 (2014) 052005.
- (23) SOUZA, J. C. S.; MEIRA JUNIOR, R.; BIANCARDINE JUNIOR, H. S. D.; SOUZA JR, O. H.; TIAGO FILHO, G. L; GALHARDO, C. R. Use of multi-layered perceptron neural networks (mlp) for prediction of cavitation in hydraulic turbines, in: III Latin American on Hydro Power & Systems Meeting IAHR, Quito, Ecuador, 2017.
- (24) HAJNAYEB, A.; AZIZI, R.; GHANBARZADEH, A.; CHANGIZIAN, M. Vibration-based cavitation detection in centrifugal pumps, Diagnostyka 18 (3) (2017) 77–83, 6414.
- (25) SHORA, M. M.; GHASSEMI, H.; NOWRUZI, H. Using computational fluid dynamic and artificial neural networks to predict the performance and cavitation volume of a propeller under different geometrical and physical 16 (2017) 1–26.
- (26) DE GIORGI, M.; BELLO, D.; FICARELLA, A. An artificial neural network approach to investigate cavitating flow regime at different temperatures, Measurement 47 (Complete) (2014) 971–981.
- (27) AGUINAGA, A.; LUO, X.; HIDALGO, V.; CANDO, E.; LLULLUNA, F. A Feed-Forward Backpropagation Neural Network Method for Remaining Useful Life Prediction of Francis Turbines. Proceedings of the 3 rd World Congress on Mechanical, Chemical, and Material Engineering (MCM'17) Rome, Italy – June 8 – 10, 2017.
- (28) CHAUBEY, A.; CHELLADURAI, H.; LAMBA, S. S. Condition monitoring of rotating shaft using virtual instrumentation, in: 5th International and 26th All India Manufacturing Technology, Design and Research Conference, 2014, pp. 557–(1–6).
- (29) ZHANG, S.; RENHUI, Z.; ZHANG, S.; YANG, J. Effect of impeller inlet geometry on cavitation performance of centrifugal pumps based on radial s function 2016 (2016) 1–9.
- (30) HAYKIN, S. Neural Networks and Learning Machines. 3 ed. Prentice-Hall, Inc., 2009.

8.0 - DADOS BIOGRÁFICOS



Igor Renan Braga dos Santos, graduado em Engenharia Hídrica pela Universidade Federal de Itajubá (UNIFEI) no ano de 2015, mestre em Engenharia de Energia pela mesma instituição, no ano de 2018, doutorando em Engenharia Elétrica também pela mesma instituição, e recém-pós-graduado em Engenharia de Segurança do Trabalho pela Centro Universitário de Maringá (UNICESUMAR). Atualmente, integrante da equipe de projetos do Centro Nacional em Referência de Pequenas Centrais Hidrelétricas (CERPCH) e membro ativo do Grupo de Estudo em Energias Renováveis (GEER). da UNIFEI. Possui experiência na elaboração, execução e acompanhamento de projetos de Pesquisa e Desenvolvimento (P&D - ANEEL). Presta serviços de consultoria no setor energético, destacando trabalhos como: Estudo da revisão e metodologia de cálculo de garantia física de usinas não despachadas centralizadamente, para o Ministério de Minas e Energia, e algumas revisões de série de vazões afluentes para PCHs e CGHs.