

Diagnóstico de falhas em motores de tração de locomotivas diesel-elétricas baseado em sistemas inteligentes

Fault diagnosis in diesel-electric locomotives traction motors based on intelligent systems

DOI:10.34117/bjdv7n6-671

Recebimento dos originais: 29/05/2021

Aceitação para publicação: 29/06/2021

Ricardo Gusmão Dias

Mestre em Modelagem Computacional e Sistemas -UNIMONTES

Instituição: Universidade Estadual de Montes Claros - UNIMONTES

Endereço: Campus Universitário Prof. Darcy Ribeiro, Av. Prof. Rui Braga, s/n – Vila Mauricéia, 39401-089, Montes Claros, MG, Brasil

E-mail: gusmaodias@yahoo.com.br

Maurílio José Inácio

Doutor em Engenharia Elétrica - UFMG

Instituição: Universidade Estadual de Montes Claros - UNIMONTES

Endereço: Campus Universitário Prof. Darcy Ribeiro, Av. Prof. Rui Braga, s/n – Vila Mauricéia, 39401-089, Montes Claros, MG, Brasil

E-mail: maurilio.inacio@unimontes.br

Renato Dourado Maia

Doutor em Engenharia Elétrica - UFMG

Instituição: Universidade Estadual de Montes Claros - UNIMONTES

Endereço: Campus Universitário Prof. Darcy Ribeiro, Av. Prof. Rui Braga, s/n – Vila Mauricéia, 39401-089, Montes Claros, MG, Brasil

E-mail: renato.dourado@unimontes.br

RESUMO

O modal ferroviário é um importante meio de transporte e o veículo empregado para movimentar trens de carga ou passageiro é a locomotiva. Um dos tipos de locomotiva mais utilizado é a locomotiva diesel-elétrica, caracterizada por possuir um motor diesel que aciona um gerador elétrico para alimentar os motores elétricos, denominados motores de tração. Falhas nos motores de tração causam impacto na operação das locomotivas e afetam a área de manutenção das empresas, uma vez que a sua manutenção representa um custo significativo. Neste contexto, o diagnóstico de falhas em motores de tração de locomotivas é relevante e várias abordagens têm sido propostas na literatura. Este trabalho propõe e avalia três modelos de sistemas inteligentes aplicados no diagnóstico de falhas em motores de tração: uma rede neural artificial tipo feedforward de múltiplas camadas, uma rede neurofuzzy e um classificador fuzzy evolutivo. Os resultados dos experimentos computacionais realizados demonstram que todos os modelos alcançam bom desempenho no diagnóstico de falhas, com melhores resultados apresentados pela rede neurofuzzy. Os resultados demonstram ainda que rede neural artificial permite a realização do diagnóstico com maior rapidez e que o classificador fuzzy evolutivo permite o aprendizado das falhas de modo on-line e em tempo real.

Palavras-Chave: Falhas, Motores Elétricos, Locomotivas Diesel-Elétricas, Inteligência Computacional.

ABSTRACT

Railway transport is an important mode of transport and the vehicle used to move freight or passenger trains is the locomotive. One of the most used types of locomotive is the diesel-electric locomotive, characterized by having a diesel engine that drives an electric generator to power the electric motors, called traction motors. Faults in the traction motors has an impact on the operation of the locomotives and affect the maintenance area of the companies, since their maintenance represents a significant cost. In this context, fault diagnosis in locomotive traction motors is relevant and several approaches have been proposed in the literature. This work proposes and evaluates three models of intelligent systems applied to the fault diagnosis in traction motors: a multilayer artificial neural network, a neurofuzzy network and an evolving fuzzy classifier. The results of the computational experiments performed demonstrate that all models achieve good performance in the fault diagnosis, with better results presented by the neurofuzzy network. The results also demonstrate that the artificial neural network allows the diagnosis to be carried out more quickly and that the evolving fuzzy classifier allows the faults to be learned online and in real time.

Keywords: Faults, Electric Motors, Diesel-Electric Locomotives, Computational Intelligence.

1 INTRODUÇÃO

O modal ferroviário é um meio de transporte caracterizado principalmente por sua capacidade de transportar grandes volumes de carga a médias e grandes distâncias e com elevada eficiência energética. Em relação ao modal rodoviário, apresenta diversas vantagens como menor número de acidentes, menor emissão de poluentes e menor índice de roubos. Em termos de carga transportada, o sistema ferroviário do Brasil é considerado o maior da América Latina, alcançando 714,7 milhões de TU (Toneladas Úteis) e sendo responsável por 20,7% da matriz de transporte de carga no país (ANTT, 2020; CNT, 2020).

O veículo ferroviário que fornece o esforço trator necessário para manter um trem de carga ou passageiro em movimento é a locomotiva. Dentre os diversos tipos de locomotivas existentes, uma das mais utilizadas no transporte de cargas pesadas é a locomotiva diesel-elétrica. Esse tipo de locomotiva possui um motor diesel, que é a fonte primária de energia, para acionar um gerador ou alternador. O gerador ou alternador converte a energia mecânica do motor diesel em energia elétrica. A energia elétrica é novamente convertida em energia mecânica por motores elétricos, chamados de motores

de tração, que são acoplados diretamente aos rotores por um conjunto de pinhão e engrenagens (BORBA, 2013).

O motor de tração faz parte do conjunto tríplice das locomotivas diesel-elétricas e este componente é afetado por diversos fatores inerentes ao seu funcionamento, e também por fatores externos do meio-ambiente. As falhas nesse componente causam uma diminuição no desempenho operacional dos trens reduzindo a potência desenvolvida pelas locomotivas e, em consequência disso, a composição ferroviária é retirada de circulação, gerando transtornos a toda uma cadeia logística (FARIA, 2012).

A ocorrência de falhas nos motores de tração das locomotivas diesel-elétricas afeta especialmente a área de manutenção, sendo que essa, assim como em qualquer outro segmento, é fundamental em um cenário de crescimento da demanda, pois está diretamente relacionada às questões de segurança, confiabilidade e disponibilidade. A manutenção de locomotivas representa em média 20% dos custos totais de transporte nas ferrovias de carga geral do Brasil. Ainda neste cenário, o setor de materiais e componentes representa aproximadamente 60% dos custos totais com a manutenção de locomotivas. Além disso, uma manutenção assertiva nos componentes das locomotivas diesel-elétrica está diretamente relacionada à eficiência energética das locomotivas (FARIA, 2012).

Neste contexto, o problema de diagnóstico de falhas nos motores de tração de locomotivas diesel-elétricas é de grande relevância para as empresas do segmento de transporte ferroviário. Por esse motivo, ao longo dos últimos anos, diversos trabalhos relacionados ao diagnóstico de falhas em locomotivas foram publicados na literatura. Esses trabalhos propõem diversas abordagens de detecção e isolamento de falha ou Fault Detection and Isolation (FDI), com base no conceito de manutenção baseada em condição ou Condition-base Maintenance (CBM) (VACHTSEVANOS et al., 2006). As abordagens propostas podem ser divididas basicamente em diagnóstico de falhas baseado em modelos e diagnóstico de falhas baseado em dados. Enquanto o diagnóstico baseado em modelos requer conhecimento físico do sistema, o diagnóstico baseado em dados necessita de grande quantidade de dados (GARRAMIOLA et al., 2018).

Dentre os métodos empregados no diagnóstico de falhas em motores de tração baseado em dados estão os que utilizam os sistemas inteligentes, tais como redes neurais artificiais, sistemas fuzzy e algoritmos evolucionários. Neste caso, o uso de sistemas inteligentes, além de não precisar do modelo matemático do motor, apresenta várias vantagens em relação a outros métodos, como maior precisão e maior confiabilidade. Mas, apesar dos avanços obtidos ao longo dos últimos anos, os resultados da aplicação

de sistemas inteligentes no diagnóstico de falhas em motores de tração de locomotivas na prática ainda estão distantes da teoria, o que justifica a necessidade de estudos mais aprofundados (CHEN et al., 2011).

Assim, este trabalho tem como objetivo propor a aplicação de sistemas inteligentes no diagnóstico de falhas em motores de tração de locomotivas diesel-elétricas empregando dados reais adquiridos de motores em estado normal e com falhas. São avaliados três modelos de sistemas inteligentes: rede neural artificial tipo feedforward de múltiplas camadas, rede neurofuzzy e sistema fuzzy evolutivo, e discutido as vantagens e desvantagens de cada modelo na aplicação em questão.

O restante deste trabalho está estruturado da seguinte forma: na seção 2 é apresentada a descrição da metodologia proposta neste trabalho; na seção 3 são apresentados os experimentos realizados e discutidos os resultados obtidos; e na seção 4 são apresentadas as conclusões.

2 MATERIAIS E MÉTODOS

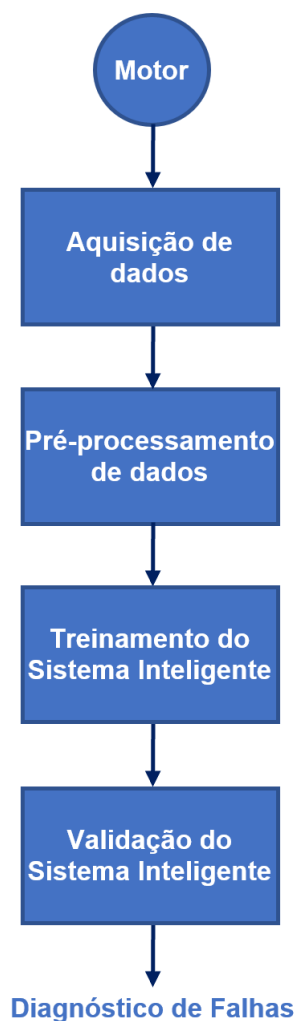
Nessa seção é apresentada a metodologia proposta neste trabalho para realização do diagnóstico de falhas em motores de tração de locomotivas diesel-elétrica. A metodologia é baseada no uso de dados reais adquiridos dos motores para treinamento e validação de um sistema inteligente e sua aplicação no diagnóstico de falhas, conforme ilustra a Figura 1.

2.1 AQUISIÇÃO DE DADOS

A etapa de aquisição dos dados dos motores de tração foi realizada por meio de um equipamento de controle microprocessado Q-Tron, modelo QES-III (WABTEC, 2020), instalado em locomotivas diesel-elétricas modelo U20-C, de propriedade da empresa VLI Logística (VLI, 2020). Os motores de tração dessas locomotivas possuem as seguintes características (GMC, 1994):

- Modelo: 5GE761A9.
- Classificação: motor de corrente contínua de 4 pólos, com pólos de comutação e enrolamento em série.
- Velocidade máxima: 3100 RPM.
- Tensão máxima: 1200 Vcc.
- Corrente máxima: 655 A.

Figura 1- Metodologia proposta para o diagnóstico de falhas em motores de tração de Locomotias



Fonte: Elaborado pelos autores.

Foram selecionadas as seguintes variáveis fornecidas pelo equipamento de controle microprocessado:

- Tensão no motor (V);
- Corrente no motor (A);
- Temperatura no motor (°C);
- Velocidade da locomotiva (km/h).

Os motores de tração são acoplados às rodas da locomotiva por meio de um sistema mecânico de acoplagem, que determina a relação entre a velocidade angular do eixo do motor e a velocidade de deslocamento da locomotiva. Dessa forma, a velocidade angular do motor em RPM (Rotações por Minuto) pode ser calculada como (BORBA, 2013):

$$\eta_{\text{eixo}} = \frac{1000}{120 \cdot R} \cdot \frac{R}{r_{\text{roda}}} \cdot V_{\text{loco}} \quad (1)$$

onde:

η_{eixo} = velocidade angular do eixo do motor de tração;

R = relação de transmissão entre o pinhão do motor e a engrenagem do rodeiro da locomotiva;

r_{roda} = raio do rodeiro da locomotiva;

V_{loco} = velocidade de deslocamento da locomotiva.

Os dados adquiridos correspondem à condição de operação normal e condições de falhas dos motores de tração. Foram selecionadas, com auxílio de especialistas em manutenção de locomotivas da empresa VLI Logística, as falhas que mais ocorrem em um motor de tração e seus subsistemas (cabos de alimentação, engrenagens, circuitos de proteção e controle), que são as seguintes:

- Falha pinhão solto: ocorre quando o pinhão desliza pelo eixo do motor.
- Falha pinhão travado: ocorre quando o pinhão fica preso ao eixo do motor.
- Falha faíscamento: ocorre quando há um curto-circuito sobre a superfície do comutador com o porta escovas e outras peças do motor.
- Falha circuito aberto: ocorre quando há uma interrupção da passagem da corrente elétrica no campo ou na armadura do motor.
- Falha sobretemperatura: falha que ocorre quando há um superaquecimento do motor.

2.2 PRÉ-PROCESSAMENTO DE DADOS

Na etapa de pré-processamento dos dados, como o número de amostras adquiridas por falha era diferente, foram selecionadas do total de amostras uma mesma quantidade para cada tipo de falha. Em seguida as amostras foram normalizadas e rotuladas, constituindo assim o conjunto de dados a ser utilizada para treinamento e para validação dos sistemas inteligentes.

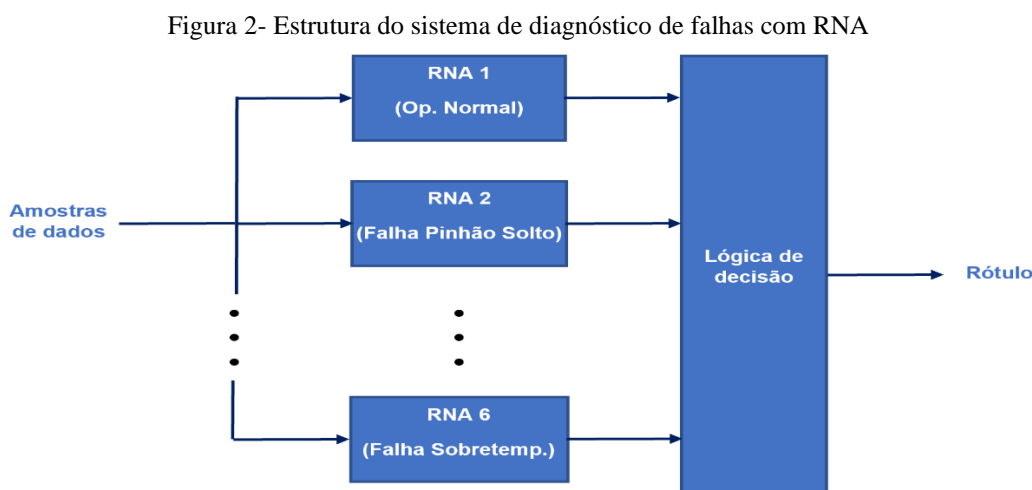
2.3 TREINAMENTO E VALIDAÇÃO COM REDE NEURAL ARTIFICIAL

Para realizar o diagnóstico de falhas em motores de tração empregando como sistema inteligente a rede neural artificial (RNA), neste trabalho foi escolhido o modelo de rede feedforward de múltiplas camadas.

Esse tipo de rede é constituído por uma camada de neurônios de entrada, uma ou mais camadas de neurônios escondidas (ou intermediárias) e uma camada de neurônios

de saída. O fluxo de informações nesse tipo de rede é unidirecional, ou seja, segue sempre da camada de entrada em direção à camada de saída. Entre as principais redes feedforward de múltiplas camadas está o Perceptron Multicamadas (Multilayer Perceptron – MLP), que utiliza o processo de aprendizado supervisionado e o algoritmo de treinamento backpropagation. Essas redes podem ser empregadas na solução de diversos tipos de problemas, como aproximação de funções, classificação de padrões, identificação de sistemas, e outros (SILVA et al., 2010).

A estrutura do sistema de diagnóstico de falhas com RNA proposto neste trabalho é composta por seis redes e uma lógica de decisão, conforme apresentado na Figura 2. Nessa estrutura uma rede opera como classificador para operação normal e cinco redes operam como um classificador para cada tipo de falha. As saídas das redes são aplicadas na lógica de decisão, que fornece na saída o resultado do diagnóstico, ou seja, o rótulo da condição do motor de tração (normal ou falha), para cada amostra de dados de entrada adquirida. A Tabela 1 mostra a codificação utilizada na saída das RNA para classificação das amostras de dados. Para definição da topologia (número de camadas e neurônios) das RNA utilizadas foi empregado o método de validação cruzada k-partições (k-fold cross-validation). Nesse método, o conjunto total de amostras de dados é dividido em k partições, onde (k – 1) partições são usadas para treinamento das topologias candidatas e a partição restante é utilizada para teste. A topologia escolhida será aquela que apresentar melhor desempenho global quando aplicadas as k partições (SILVA et al., 2010).



Fonte: Elaborado pelos autores.

Tabela 1. Codificação utilizada na saída das RNA.

RNA1	RNA2	RNA3	RNA4	RNA5	RNA6	Rótulo	Condição
1	0	0	0	0	0	1	Operação normal
0	1	0	0	0	0	2	Falha pinhão solto

0	0	1	0	0	0	3	Falha pinhão travado
0	0	0	1	0	0	4	Falha faísca
0	0	0	0	1	0	5	Falha circuito aberto
0	0	0	0	0	1	6	Falha sobretemperatura

Fonte: Elaborado pelos autores.

2.4 TREINAMENTO E VALIDAÇÃO COM REDE NEUROFUZZY

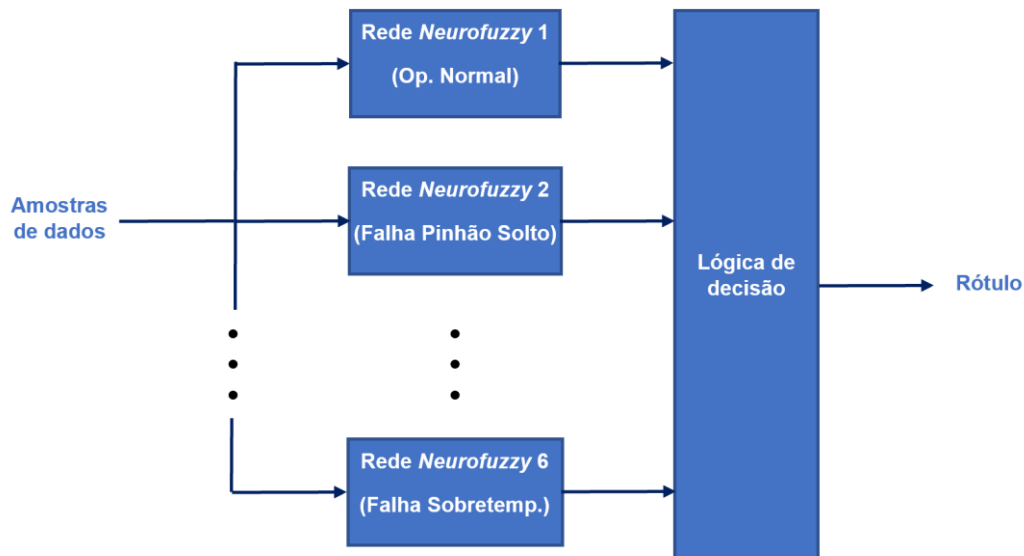
Outro modelo de sistema inteligente escolhido neste trabalho para realizar o diagnóstico de falhas em motores de tração foi o modelo de rede neurofuzzy (RNF) ANFIS (Adaptive Neuro Fuzzy Inference System) proposta por JANG et al. (1997).

Essa rede é definida como uma rede adaptativa que é funcionalmente equivalente a um sistema inferência fuzzy dos tipos Takagi-Sugeno ou Tsukamoto. A estrutura da rede ANFIS é constituída por cinco camadas, uma camada de entrada, três camadas intermediárias e uma camada de saída. Para o aprendizado, a rede ANFIS utiliza um algoritmo treinamento de duas etapas, que combina os métodos do gradiente descendente e estimador de mínimos quadrados. As RNF são caracterizadas principalmente por sua capacidade de tratamento da informação incompleta e imprecisa (como normalmente são os dados adquiridos de sensores instalados em ambientes hostis) e também pela facilidade de interpretação do conhecimento adquirido (representado na forma de regras fuzzy).

A estrutura do sistema de diagnóstico de falhas com RNF proposta neste trabalho é semelhante àquela com RNA, composta por seis redes e uma lógica de decisão, conforme apresentado na Figura 3. Neste caso também é utilizada uma rede para classificação da operação normal e cinco redes para classificação de cada tipo de falha. E o resultado (rótulo que indica a condição do motor como normal ou falha) também é fornecido para lógica de decisão a partir de cada amostra de dados de entrada adquirida. A Tabela 2 mostra a codificação utilizada na saída das RNF para classificação das amostras de dados.

As RNF normalmente não exigem definição de topologia como as RNA, uma vez que possui uma estrutura diferente. Porém, um parâmetro desse tipo de rede precisa ser escolhido, que é o número de regras fuzzy. Neste trabalho, para escolha das RNF também foi empregado o método de validação cruzada k-partições. Neste caso, as RNF com diferentes números de regras fuzzy são avaliadas e a RNF escolhida será aquela que apresentar melhor desempenho global quando aplicadas as k partições.

Figura 3- Estrutura do sistema de diagnóstico de falhas com redes neurofuzzy



Fonte: Elaborado pelos autores.

Tabela 2. Codificação utilizada na saída das RNF.

RNF1	RNF2	RNF3	RNF4	RNF5	RNF6	Rótul	Condição
1	0	0	0	0	0	1	Operação normal
0	1	0	0	0	0	2	Falha pinhão solto
0	0	1	0	0	0	3	Falha pinhão travado
0	0	0	1	0	0	4	Falha faíscamento
0	0	0	0	1	0	5	Falha circuito aberto
0	0	0	0	0	1	6	Falha sobretemperatura

Fonte: Elaborado pelos autores.

2.5 TREINAMENTO E VALIDAÇÃO COM SISTEMA FUZZY EVOLUTIVO

O diagnóstico de falhas em motores de tração também foi realizado neste trabalho empregando como modelo de sistema inteligente um Sistema Fuzzy Evolutivo (SFE).

Esse modelo advém de uma linha de pesquisa recente denominada de Sistemas Inteligentes Evolutivos (SIE), onde busca-se o desenvolvimento de sistemas inteligentes capazes de adaptar ao ambiente, por meio de um aprendizado contínuo realizado de modo on-line e, se necessário, em tempo real. Em um SIE, tanto a estrutura do sistema quanto seus parâmetros não são fixos e não precisam ser definidos à priori, eles são definidos e ajustados de forma gradual durante o processo evolutivo. Devidos às suas características, os SIE são indicados para solução de problemas onde o ambiente é dinâmico e não estacionário, como normalmente são as aplicações do mundo real (ANGELOV e KASABOV, 2006; ANGELOV et al., 2010).

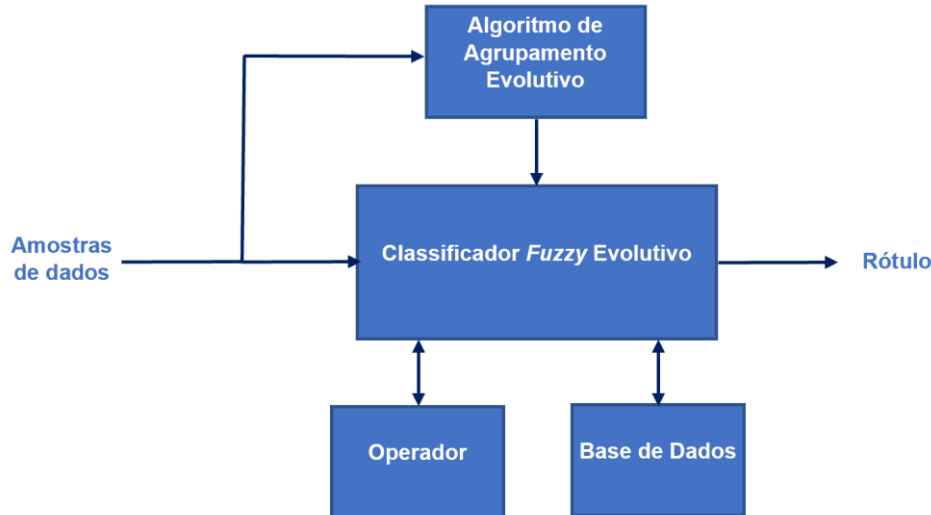
Um SFE pode ser definido como um sistema de inferência fuzzy dos tipos Mamdani ou Takagi-Sugeno onde o número de regras fuzzy e seus parâmetros são definidos e ajustados pelo mecanismo de aprendizagem. O processo de aprendizagem se resume basicamente a duas etapas: a primeira consiste na atualização dos antecedentes das regras (conjuntos fuzzy) e a segunda consiste na atualização dos consequentes das regras (conjuntos fuzzy no modelo de Mamdani ou funções lineares no modelo de Takagi-Sugeno). Para a primeira etapa da aprendizagem geralmente é empregado algum algoritmo de agrupamento evolutivo, que identifica a organização espacial das variáveis de entrada e/ou saída e a utiliza para ajuste dos parâmetros dos antecedentes das regras. E para a segunda etapa geralmente é empregado algum algoritmo de estimação de parâmetros, que avalia a qualidade do modelo com base no erro de modelagem e ajusta os parâmetros dos consequentes das regras (BARUAH e ANGELOV, 2011).

A partir de um SFE é possível implementar um Classificador Fuzzy Evolutivo (CFE) onde, neste caso, os consequentes das regras fuzzy são valores crisp (número inteiro) correspondentes ao rótulo da classe pertencente a um conjunto de classes. A saída do classificador para cada nova amostra de dados de entrada é definida pela regra com maior grau de ativação. O CFE empregado neste trabalho para realizar o diagnóstico de falhas em motores de tração para foi proposto por Inácio et al. (2012), que emprega uma versão aprimorada do algoritmo de agrupamento evolutivo Evolving Clustering Method (ECM), proposto por Kasabov e Song (2002). O CFE tem como principal característica a capacidade de criar uma base de regras fuzzy em modo on-line e em tempo real, permitindo que o sistema aprenda a diagnosticar as falhas, com auxílio do operador, na medida em que elas ocorram. Com essa característica, o sistema de diagnóstico de falhas é capaz de se adaptar ao sistema dinâmico, tornando possível o diagnóstico de falhas não conhecidas previamente.

A estrutura do sistema de diagnóstico de falhas com CFE proposto neste trabalho se diferencia daquelas empregando RNA e RNF por utilizar um único classificador, conforme apresentado na Figura 4. Com essa estrutura, o algoritmo de agrupamento evolutivo realiza o agrupamento de forma gradual ao recebimento das amostras de dados pelo sistema. A cada novo grupo encontrado é feita a associação a uma nova classe pelo CFE com a criação de uma nova regra fuzzy, definindo a operação como normal ou falha, sendo que essa condição é informada pelo operador do sistema. Caso a amostra de dados pertença a um grupo já existente, o CFE atualiza a regra fuzzy correspondente e fornece o rótulo que classifica a amostra como operação normal ou falha, a partir dos rótulos já

armazenados na base de dados. A Tabela 3 mostra a codificação utilizada na saída do CFE para classificação das amostras de dados.

Figura 4. Estrutura do sistema de diagnóstico de falhas com classificador fuzzy evolutivo



Fonte: Elaborado pelos autores.

Tabela 3. Codificação utilizada na saída do CFE.

Rótulo	Condição
1	Operação normal
2	Falha pinhão solto
3	Falha pinhão travado
4	Falha faíscamento
5	Falha circuito aberto
6	Falha sobretemperatura

Fonte: Elaborado pelos autores.

O CFE, diferentemente das RNA e das RNF, não exige quaisquer definições relacionadas à estrutura ou parâmetros. Isso significa que, nesse classificador, o número de regras fuzzy e seus parâmetros são determinados automaticamente, não sendo necessário empregar nenhum método para projeto do modelo como a validação cruzada.

3 RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os experimentos computacionais realizados, seus resultados, bem como uma análise dos mesmos.

Nos experimentos foram empregados dados reais de motores de tração de locomotivas, cedidos pela empresa VLI Logística, onde foram coletados dados de 10 motores em condição normal e com falhas, sendo 6.000 amostras por motor, compondo um conjunto de dados de 60.000 amostras. Para realização dos processos de treinamento e validação dos sistemas inteligentes conforme o método de validação cruzada k-

partições, o conjunto de dados foi dividido em 10 subconjuntos, neste caso, 9 conjuntos foram utilizados para treinamento e um para validação. A implementação dos sistemas de diagnóstico de falhas com cada modelo de sistema inteligente foi realizada utilizando o software Matlab (MATLAB, 2020),'' executado em um computador PC com processador Intel Core i5, clock de 1,7 GHz, memória RAM de 8 GB e HD de 1 TB.

Para avaliação de desempenho dos sistemas inteligentes no diagnóstico de falhas dos motores de tração foi utilizada a matriz de confusão, a qual permite calcular as seguintes métricas:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (2)$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3)$$

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (4)$$

$$\text{F1 - score} = 2 \times \frac{\text{Precisão} \times \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} \quad (5)$$

Onde:

VP = verdadeiros positivos;

VN = verdadeiros negativos;

FP = falsos positivos;

FN = falsos negativos.

Os sistemas inteligentes foram avaliados também em relação aos tempos de treinamento e validação.

Nos experimentos de diagnóstico de falhas em motores de tração empregando como sistema inteligente a RNA, foram empregadas 10 topologias diferentes e realizados 10 testes com cada uma (validação cruzada com $k = 10$ partições). A rede que apresentou maior média global de desempenho nos testes foi uma rede com topologia constituída por uma camada de entrada com 4 neurônios, 3 camadas intermediárias com 9 neurônios cada e uma camada de saída com um neurônio. A Tabela 4 apresenta os resultados obtidos nos testes com a RNA.

Tabela 4. Resultados do diagnóstico de falhas com RNA.

Métrica	Média	Desvio padrão
Acurácia	0,9908	0,0025
Precisão	0,9729	0,0072
Sensibilidade	0,9730	0,0071
F1-score	0,9726	0,0073
Tempo de treinamento		12,58s
Tempo de validação		0,08s

Fonte: Elaborado pelos autores.

Nos experimentos de diagnóstico de falhas em motores de tração empregando como sistema inteligente a RNF, foram empregadas 10 redes com número de regras fuzzy diferentes e realizados 10 testes com cada uma (validação cruzada com $k = 10$ partições). A rede que apresentou maior média global de desempenho nos testes foi uma rede com 12 regras fuzzy. A Tabela 5 apresenta os resultados obtidos nos testes com a RNF.

Tabela 5. Resultados do diagnóstico de falhas com RNF.

Métrica	Média	Desvio padrão
Acurácia	0,9924	0,0017
Precisão	0,9771	0,0053
Sensibilidade	0,9775	0,0049
F1-score	0,9770	0,0052
Tempo de treinamento		506,51s
Tempo de validação		0,20s

Fonte: Elaborado pelos autores.

Nos experimentos de diagnóstico de falhas em motores de tração empregando como sistema inteligente a CFE, como não é necessário empregar um método para projeto do modelo, foram realizados 10 testes com os mesmos subconjuntos de dados empregados nos testes com a RNA e com a RNF, e obtida a média global de desempenho nos testes. A Tabela 6 apresenta os resultados obtidos nos testes com o CFE.

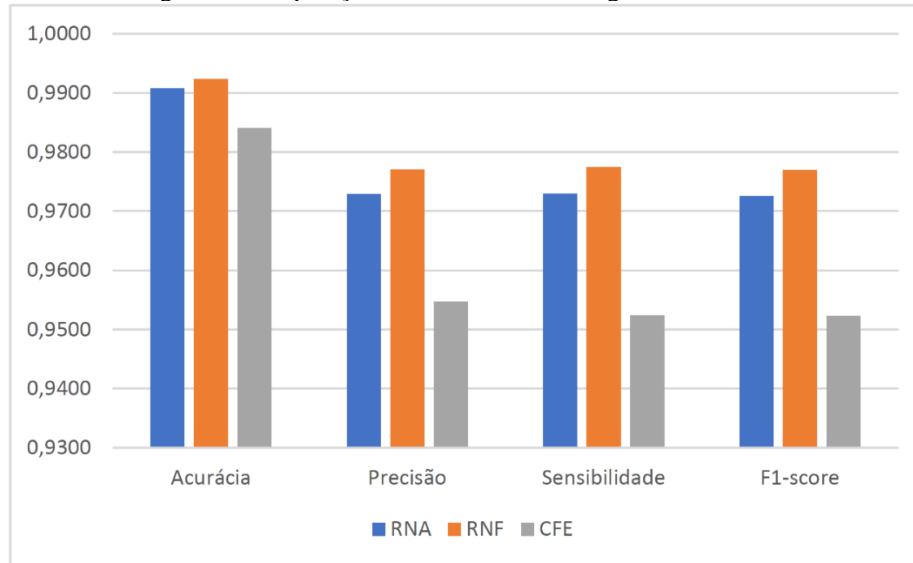
Tabela 6. Resultados do diagnóstico de falhas com CFE.

Métrica	Média	Desvio padrão
Acurácia	0,9841	0,0058
Precisão	0,9547	0,0151
Sensibilidade	0,9524	0,0161
F1-score	0,9523	0,0166
Tempo de treinamento		118,97s
Tempo de validação		13,68s

Fonte: Elaborado pelos autores.

Para permitir uma comparação entre os modelos de sistemas inteligentes empregados no diagnóstico de falhas em motores de tração de locomotivas diesel-elétricas, a Figura 5 apresenta um gráfico com os resultados obtidos com cada modelo.

Figura 5: Comparação dos resultados do diagnóstico de falhas



Fonte: Elaborado pelos autores.

Analisando os valores apresentados nas Tabelas 4, 5, 6 e o gráfico apresentado na Figura 5, pode-se observar que os três modelos de sistemas inteligentes alcançaram resultados próximos no diagnóstico de falhas em motores de tração de locomotivas diesel-elétricas. As métricas de desempenho calculadas mostram que os modelos empregados no diagnóstico de falhas alcançaram um bom desempenho, com valores acima de 0,95 para todas as métricas. De forma geral, os resultados indicam que todos os modelos foram capazes de diagnosticar corretamente tanto as ocorrências correspondentes às falhas do motor de tração, quanto aquelas correspondentes à operação normal.

Em relação às métricas de desempenho, o modelo com melhor resultado foi a RNF, superando a RNA e o CFE, que obteve o pior resultado dentre esses. Esses resultados indicam que, na aplicação de diagnóstico de falhas em motores de tração, o modelo RNF permite a realização de um diagnóstico mais preciso e confiável.

Entretanto, em relação aos tempos de treinamento e validação, a RNA obteve melhor resultado, com valores significativamente menores dos obtidos pela RNF e CFE. Neste caso, os resultados indicam que o modelo RNA permite maior rapidez na realização do diagnóstico falhas em motores de tração.

O modelo CFE, apesar de apresentar os menores valores de métricas de desempenho entre os três modelos e apresentar tempos de treinamento validação relativamente altos, possui uma vantagem que é a capacidade de aprendizado de modo on-line e em tempo real. Isso significa que esse modelo permite, na realização do diagnóstico de motores de tração, que falhas não conhecidas previamente possam ser

aprendidas e posteriormente diagnosticadas corretamente.

4 CONSIDERAÇÕES FINAIS

Este trabalho apresentou uma abordagem de diagnóstico de falhas em motores de tração de locomotivas diesel-elétricas baseada no uso de dados reais adquiridos do motor e sistemas inteligentes para realização do diagnóstico. Foram avaliados três modelos: uma rede neural artificial tipo feedforward de múltiplas camadas, uma rede neurofuzzy e um classificador fuzzy evolutivo.

Os resultados dos experimentos computacionais realizados permitem concluir que o diagnóstico de falhas em motores de tração de locomotivas diesel-elétrica baseado em sistemas inteligentes apresenta bom desempenho, sendo a rede neurofuzzy superior aos outros modelos, apesar desse modelo apresentar maior tempo de operação que a rede neural artificial e não possuir a capacidade de aprendizado on-line em tempo real do classificador fuzzy evolutivo.

Em trabalhos futuros pretende-se implementar um sistema de diagnóstico de falhas para motores de tração empregando um sistema embarcado e instalar esse sistema em uma locomotiva diese-elétrica para avaliar seu desempenho em situações de operação reais.

REFERÊNCIAS

ANGELOV, P. KASABOV, N. Evolving Intelligent Systems - eIS. IEEE SMC eNewsLetter, n. 15, 2006, p. 1-13.

ANGELOV, P. et al. Evolving Intelligent Systems: Methodology and Applications. New York, USA: John Wiley & Sons, 2010.

ANTT. Transporte de Cargas Ferroviário. Disponível em: <http://www.antt.gov.br/cargas/arquivos_old/Ferrovuario.html>. Acesso em: 10 ago. 2020.

BARUAH, D. B. and ANGELOV, P. Evolving fuzzy systems for data streams: a survey. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, v. 1., 2011, p. 461-476.

BORBA, J. L. Apostila de Engenharia de Manutenção. Programa de pós-graduação em Engenharia Ferroviária. Pontifícia Universidade Católica, Belo Horizonte, MG, 2013.

CHEN, Z. P., et al. Analysis and Comparison of Locomotive Traction Motor Intelligent Fault Diagnosis Methods. Applied Mechanics and Materials, v. 97-98. 2011. p. 994-1002.

CNT. Anuário CNT do Transporte. Disponível em: <<https://anuariodotransporte.cnt.org.br/2019/Ferrovuario/2-6-/Transporte-de-cargas#>>. Acesso em: 10 ago. 2020.

FARIA, C. Apostila de Custos de Ferroviários. Programa de pós-graduação em Engenharia Ferroviária. Pontifícia Universidade Católica, Belo Horizonte, MG, 2012.

GARRAMIOLA, F. et al. A Review in Fault Diagnosis and Health Assessment for Railway Traction Drives. Applied Sciences, n. 8, 2018, p. 2475.

GMC - General Motors Corporation. Motores de tração, procedimentos recomendados. Tradução da obra: Electro-Motive Division General Motors Corporation, Traction Motors Recommended Practices, 1994.

INÁCIO, et al. Diagnóstico de Falhas On-Line Baseado em Sistema Inteligente Evolutivo. Anais: XIX Congresso Brasileiro de Automática - CBA. Campo Grande, 2012.

JANG, et al. Neuro fuzzy and soft computing. Upper Saddle River, NJ, USA: Prentice Hall, 1997.

KASABOV, N. SONG, Q. DENFIS: Dynamic Evolving Neural-Fuzzy Inference System and Its Application for Time Series Prediction. IEEE Transactions on Fuzzy Systems, v. 10, n. 2, 2002, p. 144-154.

MATLAB. Mathworks. Disponível em: <<https://www.mathworks.com/products/matlab.html>>. Acesso em: 04 set. 2020.

SILVA et al. *Redes neurais artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010.

VACHTSEVANOS, G. et al. *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. Hoboken, N. J., USA: Wiley, 2006.

VLI. VLI Logística. Disponível em: <<http://www.vli-logistica.com.br/>>. Acesso em: 15 jul. 2020.

WABTEC. QES-III Control System. Disponível em: <<https://www.wabtec.com/products/5115/qes-iii>>. Acesso em: 15 jul. 2020.