

3º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

CATEGORIA 3

DESENVOLVIMENTO DE SISTEMA AUTOMÁTICO DE IDENTIFICAÇÃO DE
MODOS DE FALHAS EM MÁQUINAS DE CHAVE UTILIZANDO INTELIGÊNCIA
ARTIFICIAL

INTRODUÇÃO

Uma ferrovia de alto tráfego precisa também de uma alta disponibilidade para operação. Para garantir isso, cada vez mais presente no dia a dia da manutenção, técnicas preditivas, monitoramento online e softwares de predição de falhas vem sendo utilizados. Um equipamento ferroviário que necessita de uma alta disponibilidade e que garante também uma grande produtividade para ferrovia é a máquina de chave.

Uma máquina de chave pode ser um conjunto mecânico, elétrico e ou hidráulico, e até mesmo pneumático que conectado ao aparelho de mudança de via, AMV, realiza as funções de destravamento, movimentação, travamento e indicação de posição Normal e Reversa das

agulhas do AMV. Em cada posição, Normal ou Reversa, a máquina de chave possui mecanismos de travamento e destravamento.

As máquinas de chave elétricas são as mais utilizadas em sistemas que possuem licenciamento automático de trens. Esse tipo de máquina realiza as funções de destravamento mecânico através do acionamento de um motor elétrico de corrente alternada (CA) ou corrente contínua (CC). O travamento mecânico é feito por engrenagens ao final do curso do movimento da chave.

As máquinas de chave elétricas oferecem recurso de travamento mecânico e elétrico num único equipamento, geralmente através de um conjunto de engrenagens. A indicação de posição Normal e Reversa é realizada por um dispositivo eletrônico que é acionado pelos tirantes conectados às agulhas do AMV.

As falhas em máquinas de chave, em sua maioria estão sempre associadas às condições de conservação, ajuste ou montagem do AMV. Uma quantidade pequena dessas falhas é associada diretamente a componentes da própria máquina como seus relés, dispositivos de acionamento e motor elétrico. Porém a análise da corrente do motor da máquina apresenta indícios de onde está a falha, mesmo não estando ela associada diretamente ao equipamento, mas ao AMV e seus componentes.

Em seu artigo, ASADA et al (2013) diz que geralmente são três os tipos de falhas que podem afetar o funcionamento de uma máquina de chave:

- Falhas abruptas – Aparecem de repente, sem qualquer indicação prévia;
- Falha intermitente – Falhas que acontecem esporadicamente;

- Falha incipiente – Defeito que se desenvolve gradualmente ao longo de um período de tempo.

Uma máquina de chave em perfeito funcionamento pode sofrer uma falha e parar de funcionar sem qualquer indicação de que esta poderia falhar, caracterizando uma falha abrupta. As falhas intermitentes são difíceis de identificar as causas, pois da mesma forma que aparecem podem sumir sem deixar nenhuma indicação do que possa ter acontecido. Já as falhas incipientes dão indícios ao longo do tempo que podem ser acompanhados de modo a prever a falha proporcionando a oportunidade de programação de restauração dos seus padrões normais de funcionamento.

NAKAMURA e TENTETSU (1992), em seu estudo categoriza esse tipo de falha incipiente em modos de falhas listados a seguir:

- Falhas causadas por componentes da máquina de chave;
- Falhas causadas por componentes externos;
- Falhas causadas por desalinhamento;
- Falhas causadas pelo ambiente;
- Falhas causadas por obstrução.

A condição do aparelho de mudança de via é um fator que influencia consideravelmente nos problemas em máquina de chave. Seus componentes podem ter problemas de ajustes, causando desalinhamento nas ferragens da máquina de chave, que são dispositivos que ligam as máquinas de chave às agulhas dos aparelhos de mudança de via.

Monitorar a máquina de chave e antever problemas significa diminuir o impacto de intervenções não programadas e trens parados por causa de falhas. Para propor um método eficiente de monitoramento utilizaremos ferramentas poderosas para análise e aquisição de dados.

Para tal, buscou-se uma linguagem de programação e um hardware de aquisição de dados que permitisse respostas rápidas às medições feitas e de fácil manipulação para testar as inúmeras hipóteses pertinentes ao tema. O software LabVIEW e o equipamento CompactRIO, ambos da National Instruments, mostraram-se o ambiente ideal para esses anseios.

DIAGNÓSTICO

Poucos são os sistemas de monitoramento de máquina de chave disponíveis no mercado mundial. Em sua maioria, obtêm da corrente de acionamento dos motores as informações necessárias para essa assistência. No entanto, essas informações não são tratadas de forma inteligente. Os alarmes são pré-definidos ou parametrizados fornecendo informações limitadas ao operador.

O custo de implantação de um sistema de monitoramento de mercado também é um complicador, dado o alto investimento em equipamentos e software.

Com o objetivo de reduzir os custos de implantação, dominar a tecnologia, poder contar com evolutivas no software/solução e obter um método de análise dos dados mais inteligente foi definida a arquitetura do presente trabalho.

Arquitetura do Sistema

A solução proposta e que já está em teste é modular e permite expansão, conforme apresentado na figura 1. Possibilita monitorar outros parâmetros com o mesmo hardware instalado, seja da máquina de chave ou qualquer outro equipamento ou parâmetro que faça sentido ser observado. Um exemplo simples é a temperatura do trilho.

O sistema consiste de um equipamento de medição de alta velocidade (250kS/s), transdutores de corrente e um servidor no datacenter. O meio de comunicação utilizado é o *backbone* óptico da própria ferrovia.

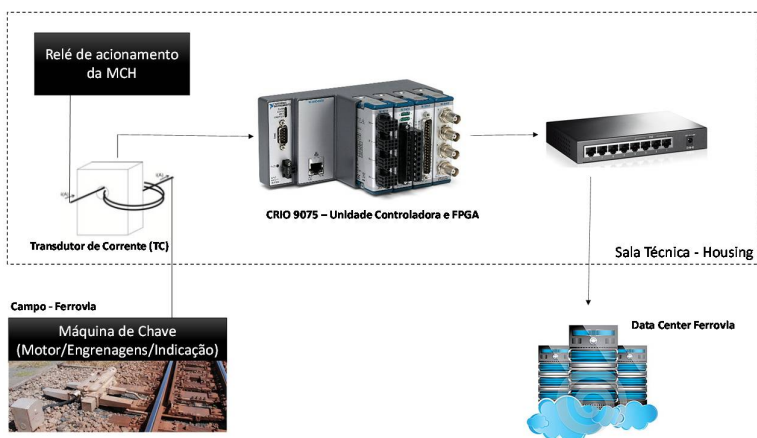


Figura 1 – Arquitetura do Sistema

O sistema foi instalado em duas das salas técnicas localizadas ao longo da Estrada de Ferro Vitória a Minas (EFVM), mais especificamente nas denominadas H06 e H07. Essas salas além do controle de outros equipamentos são responsáveis pelo comando de um travessão universal. Cada travessão universal na ferrovia é composto por dois travessões simples. Cada travessão simples é composto por dois conjuntos de AMVs e conseqüentemente duas máquinas de chave.

O acionamento dessas quatro chaves é realizado remotamente pelo Centro de Controle Operacional (CCO) da ferrovia através de um sistema supervisorio.

Os modelos de máquinas de chave em questão são os fabricados pela empresa Kyosan.

Sistema de Aquisição de dados

O sistema desenvolvido para a aquisição de dados das MCHs, se baseia em basicamente quatro tipos de softwares:

1. Firmware - Instruções de configuração do hardware FPGA
2. Software embarcado – programa para a coleta, tratamento e armazenamento temporário dos dados.
3. Software Servidor – responsável pela transferência dos dados do cRIO para o datacenter da ferrovia. Implementa toda a lógica de tratamento por inteligência artificial e comunica a condição do equipamento para o Supervisorio via um cliente OPC.
4. Sistema Supervisorio – responsável por apresentar aos usuários as informações críticas para operação dos equipamentos.

A operação do equipamento para a mudança de Normal para Reversa ou o contrário, é realizada tipicamente em um evento com duração menor que 8 segundos. Durante esse evento, a chave sofre diversos esforços mecânicos que são percebidos pelo motor como um aumento de carga, o que se reflete diretamente na corrente de trabalho.

O evento de operação de uma MCH pode ser dividido em três fases, conforme apresentado em ASADA et al, 2013:

Fase 1 – Acionamento do motor

Fase 2 – Movimentação da barra até o instante de conexão com a cesta

Fase 3 – Movimentação do conjunto de frente

Um ponto importante do sistema proposto foi o desenvolvimento de um algoritmo de detecção automática das fases do evento, como descrito em KALLEMBACK (2016) e MOREIRA (2016).

Esse algoritmo foi fundamental para a correta classificação das falhas ocorridas em cada instante de operação do equipamento. A Figura 2 mostra o gráfico de corrente de um evento típico de acionamento de MCH, mostrando as linhas de separação entre fases.




Figura 2 – Corrente de acionamento da máquina de chave

Métodos de Análise

O método de análise consiste na associação híbrida de dois módulos de inteligência artificial, sendo um módulo de inferência *fuzzy* e outro de redes neurais artificiais. O método deve ser confiável para identificar os sintomas das MCHs e flexível para que possa ser aplicado em larga escala, abrangendo chaves de diversos tipos. Ressalta-se que o método não identifica

os defeitos com base em uma "curva padrão", a identificação ocorre por aprendizado de máquina. No sistema proposto, foi utilizada a abordagem supervisionada de aprendizado, ou seja, os engenheiros de processo analisaram um banco de dados com milhares de eventos de movimentações e classificaram um a um tendo como base a vasta experiência com o equipamento. Em seguida, foi realizado o treinamento do sistema com base nesse banco de dados. Dessa forma, o sistema "aprende" como identificar defeitos no equipamento, além de possuir habilidade para extrapolar o conhecimento adquirido e padrões de defeitos para MCHs de outros tipos.

Definição dos padrões de eventos

Com base na experiência e padrões analisados para as diferentes assinaturas de correntes do motor da máquina de chave, adotou-se os seguintes critérios para determinação do tipo de evento (estado da máquina):

Normal – O Evento não apresenta nenhum defeito ou falha (Figura 3).

Defeito – São o tipo de falha incipiente já detalhado em capítulo anterior. A MCH ainda está em funcionamento, porém não está em sua condição ideal e pode vir a gerar uma falha.

Falha – A máquina de chave não consegue cumprir sua função, necessitando de uma intervenção imediata.

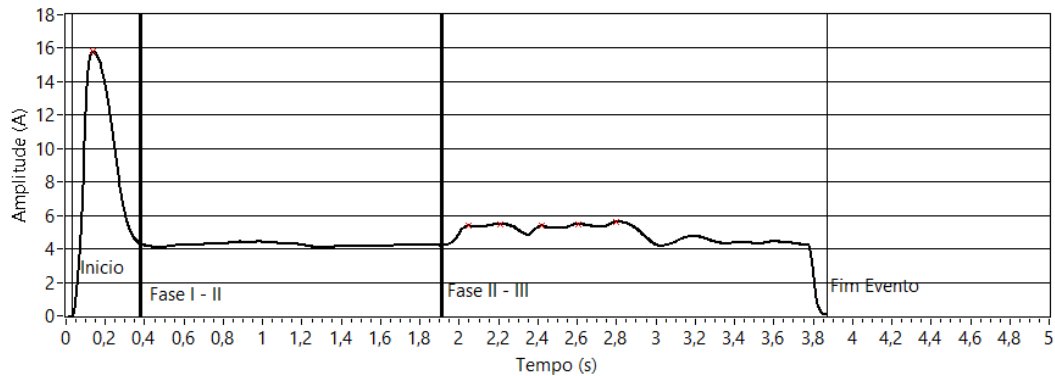


Figura 3 – Exemplo de movimento normal

Os padrões analisados como defeito foram separados em três problemas observados.

- Atrito durante a movimentação das agulhas
- Picos de corrente
- Problemas na alimentação elétrica

Um alto atrito durante a movimentação pode denotar diversos problemas, como roletes desajustados, excesso de brita ou sujeira entre as agulhas, falta de lubrificação ou até mesmo desajuste de componentes do AMV. Sendo assim, dividiu-se as curvas de atrito entre médio e alto atrito conforme pode se observar nas figuras 4 e 5.

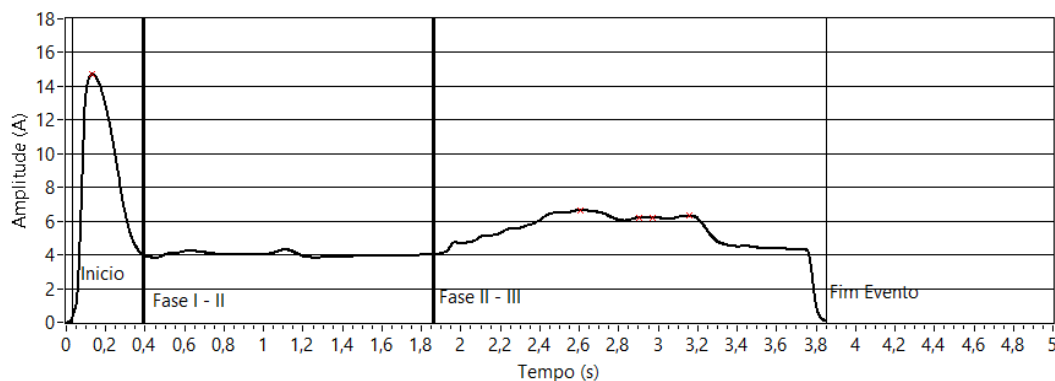


Figura 4 – Exemplo de movimento com médio atrito

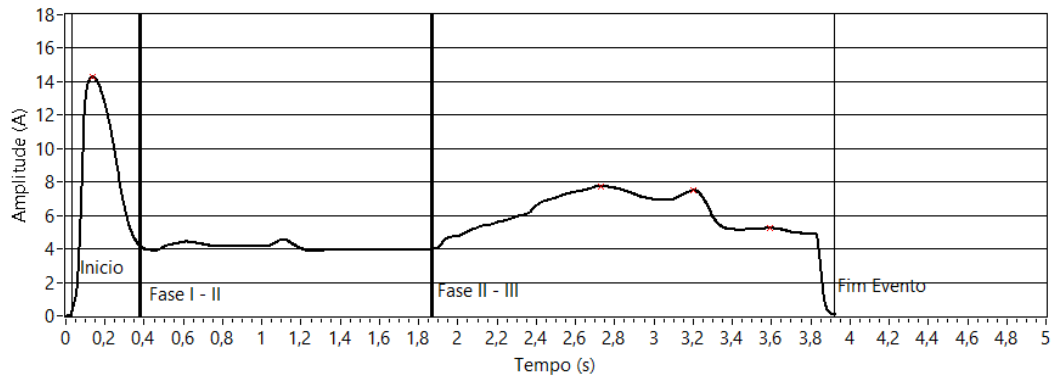


Figura 5 – Exemplo de movimento com alto atrito

Os picos de corrente foram identificados nos momentos do destravamento (início da movimentação, figura 6) e travamento (fim da movimentação, Figura 6 – **Exemplo de movimento com pico no destravamento**

) da chave. Eles podem demonstrar desajuste nas ferragens que ligam a chave a agulha por exemplo.

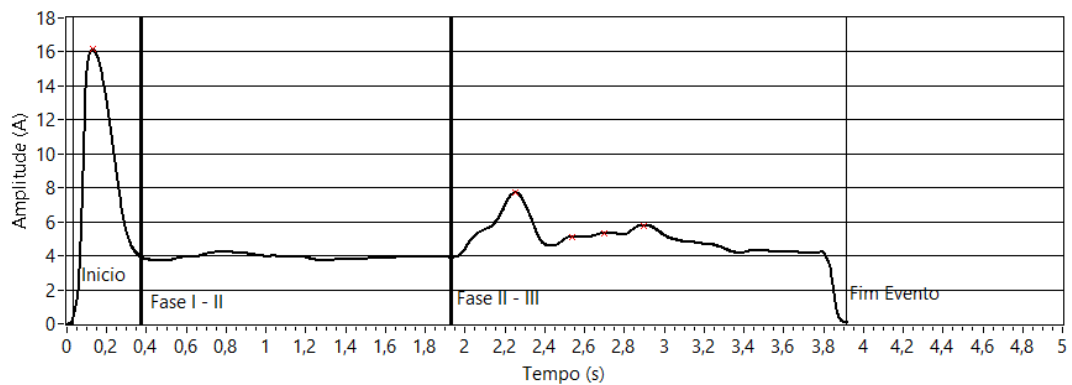


Figura 6 – Exemplo de movimento com pico no destravamento




Figura 7 – Exemplo de movimento com pico no travamento

Os problemas na alimentação elétrica se resumem na análise da frequência da corrente elétrica. No caso, a frequência de 60 Hz deve sofrer pouca variação no acionamento do motor e na movimentação da chave. Porém, quando há centelhamento ou interferências na medição, a frequência observada, através da análise FFT, sofre grandes variações. A figura 8 mostra a condição normal da frequência e a figura 9 mostra um evento onde o relé de acionamento estava com problemas.




Figura 8 – Exemplo de análise da frequência normal de alimentação




Figura 9 – Exemplo de análise da frequência anormal de alimentação

Classificou-se como falha um evento que não permite que o movimento da chave se complete, como mostra a figura 10. Um desajuste grave nas ferragens que as conectam às agulhas bem como obstruções causadas por excesso de brita na ponta da agulha ou algum outro tipo de obstáculo podem constituir essa falha do equipamento.

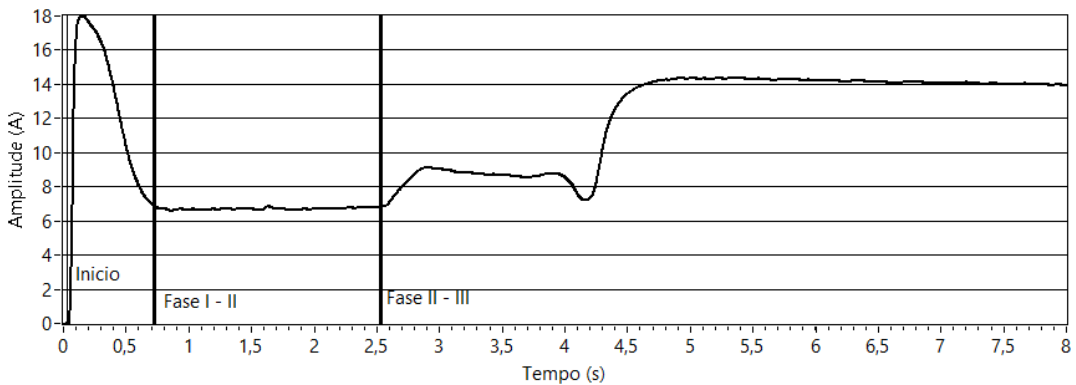


Figura 10 – Exemplo de falha por obstrução

É muito importante não somente identificar falhas, mas também padrões de comportamentos que venham impactar seu funcionamento adequado. Dessa forma as manutenções podem ser programadas para não gerar impactos na ferrovia.

Métricas coletadas nos eventos

Na fase de aquisição, diversas métricas foram selecionadas como parâmetros a serem monitorados. Essas métricas são os dados de entrada para o sistema inteligente proposto.

Abaixo são apresentados esses parâmetros:

- Duração das 3 fases em segundos (3 métricas);
- Tempo total do evento;
- Percentual de tempo de cada fase em relação ao tempo total do evento (3 métricas);
- Corrente média em cada fase (3 métricas);
- Área compreendida por cada curva em cada fase (3 métricas);
- Área total da curva
- Mediana da corrente de cada fase (3 métricas);
- Valor máximo da corrente;
- Média total da corrente;
- Valor máximo de corrente da terceira fase;
- Instante do valor máximo da terceira fase em %;
- Média de corrente da fase III em relação a fase II;
- Máximo de corrente da fase III em relação a fase II;
- Diferença entre o valor máximo da fase III e o início da fase;
- Área compreendida pela curva da fase III menos o último valor da fase II
- Valor % do maior valor da fase III em relação ao maior valor do evento
- Frequência média da corrente AC durante o evento
- Desvio Padrão da frequência da corrente AC

- *Range* da Frequência da corrente AC
- Coeficiente de Variação do período de amostragem

Com isso, cada evento de acionamento da MCH gera 30 métricas, essas monitoram não apenas a assinatura de corrente como também o período de amostragem do sistema embarcado e a frequência da corrente AC.

Definição do sistema de inferência Fuzzy

Para a configuração do módulo *Fuzzy*, foi escolhido o software Matlab, juntamente com os programas acessórios Simulink e ANFIS.

Devido à complexidade do reconhecimento de padrões analisando cada métrica uma a uma e ignorando a relação entre elas, a montagem de um sistema *Fuzzy* do tipo Mamdani nesse caso é impraticável manualmente. Usando a configuração clássica de três conjuntos *fuzzy* para cada entrada, e se fossem utilizadas as 30 métricas como entradas; o número de regras *fuzzy* seria de 3^{30} para ajuste manual.

Portanto, foram selecionadas apenas 5 métricas para a criação do sistema, além disso, o tipo de sistema escolhido foi o Takagi-Sugeno. O critério de escolha das métricas foi somente a experiência e ponto de vista dos engenheiros do processo. As métricas escolhidas foram:

- Corrente média na fase III
- Instante do valor máximo da terceira fase em %;
- Média de corrente da fase III em relação a fase II;
- Área compreendida pela curva da fase III menos o último valor da fase II
- Valor % do maior valor da fase III em relação ao maior valor do evento

O módulo *Fuzzy* assim como o módulo de Redes Neurais se propõem a identificar os seguintes sintomas e estados de máquina na operação da MCH:

- Normal
- Defeito – Médio atrito
- Defeito – Alto atrito
- Defeito – Pico Travamento
- Defeito – Pico Destravamento
- Defeito – Alimentação elétrica
- Falha – Obstrução

De forma empírica, percebeu-se que as métricas 1, 3 e 4 ajudam a estimar o quão alto é o valor da corrente, levando a conclusões sobre a amplitude dos defeitos (médio ou alto) e a separar claramente a obstrução. As métricas 2 e 5 ajudam a separar os defeitos de picos.

O sistema *Fuzzy* foi desenvolvido em camadas, ou seja, são realizadas diversas etapas de classificação para que a resposta final tenha o maior nível de segurança.

Definição da RNA – Rede Neural Artificial

Devido a necessidade de reconhecimento de padrões, foi utilizado o software Matlab com uma RNA de duas camadas, uma de neurônios ocultos com função de ativação sigmoide e outra de saída.

Essa RNA denominada Perceptron Multicamadas (PMC) é caracterizada pela presença de uma camada intermediária de neurônios situada entre a camada de entrada e a respectiva camada neural de saída.

A rede PMC se mostrou a mais adequada solução para esse caso devido a sua versatilidade de aplicação, já que é aplicável a diversos tipos de problemas em diversas áreas de conhecimento.

Foi utilizado o método de Kolmogorov como embasamento matemático para definição da quantidade ideal de neurônios para a RNA, método que indica que a quantidade de neurônios na camada escondida seja duas vezes a quantidade de entradas mais um. Ainda assim, foram realizados testes com quantidade maior de neurônios, os quais não foram satisfatórios quanto ao aumento da taxa de acertos da rede. Foi verificado também que com a diminuição da quantidade de neurônios, a taxa de acerto da rede reduzia proporcionalmente.

Como, no caso, os recursos de hardware (CPU e memória) para essa implementação são abundantes, os treinamentos e testes foram feitos utilizando todas as métricas coletadas nos eventos.

O módulo de RNA também foi desenvolvido em etapas, ou seja, são realizados diversos passos de classificação para que a resposta final tenha o maior nível de segurança.

Definição do sistema híbrido Neuro-Fuzzy

Após a parametrização dos módulos *Fuzzy* e *Neural* de forma independente, foi desenvolvido uma técnica inovadora para aumentar ainda mais a confiabilidade da análise de defeitos por um sistema autônomo. Embora as taxas de acerto de cada módulo tenham se mostrado favoráveis para a identificação de problemas, utilizou-se a abordagem de pior caso. Dessa

forma, foi implementado a lógica de realizar as análises de modo segmentado e avaliar qual a saída mais restritiva. Sendo assim, a resposta do sistema sempre tenderá para a condição mais segura de operação. As tabelas 1 e 2 mostram as sequências de criticidade dos sintomas de problemas. Os problemas de alimentação elétrica não necessitam de sistema inteligente para sua identificação. Para isso foi usado como referência o padrão brasileiro da ANEEL chamado PRODIST (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) que recomenda que a frequência da rede no caso da ferrovia se situe entre 59,5Hz e 60,5Hz. Dessa forma, todas as vezes que o sistema identificar variações de frequência maiores que esse limite, o sistema apresentará o erro de alimentação elétrica.

Tabela 1

Criticidade (maior mais crítico)	Sintoma
1	Normal
2	Alimentação Elétrica
3	Pico destravamento
4	Médio Atrito
5	Alto atrito
6	Pico travamento
7	Obstrução

Tabela 2

Criticidade	Estado da máquina
1	Normal
2	Defeito
3	Falha

A figura 11 mostra como os módulos operam em paralelo para produzirem melhor resultado.

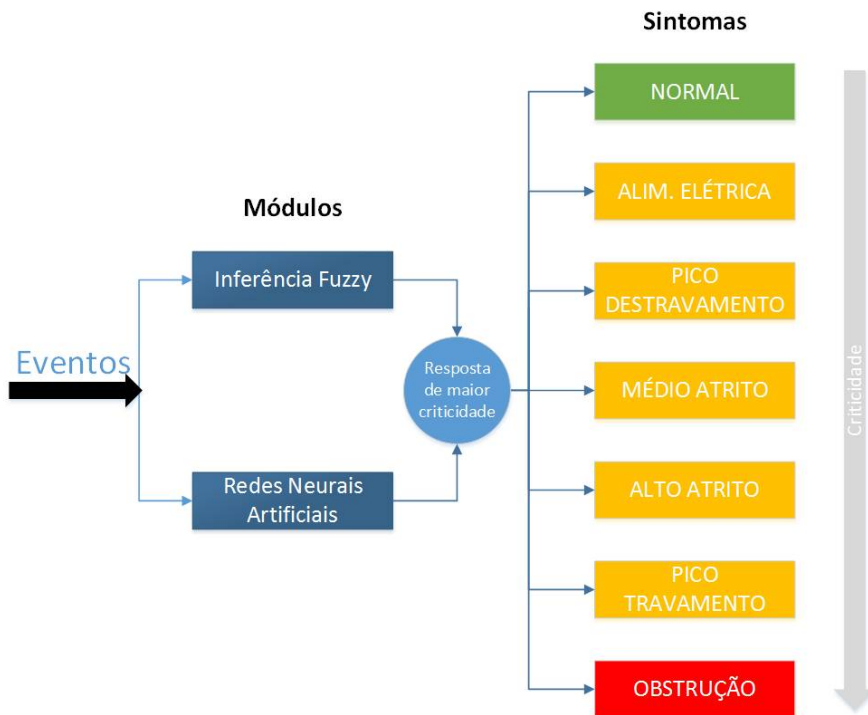


Figura 11 – Diagrama dos módulos de inteligência artificial

ANÁLISE DOS RESULTADOS

Para a realização do treinamento dos módulos *Fuzzy* e *Neural* foi criado um banco de dados de movimentações das quatro MCH monitoradas na H07. Os dados foram coletados no período de 03/02/2016 a 11/03/2016. Nesse período foram coletados 1.581 eventos.

Cada evento foi classificado conforme a sua classe de funcionamento. Os dados de fevereiro/16, 1.332 eventos, foram separados para o fim de treinamento do sistema inteligente. Os dados de março/16, 249 eventos, foram usados para o check independente do sistema proposto.

Módulo de Sistema Fuzzy

O sistema foi parametrizado para criar duas camadas de classificação, conforme apresentado na figura 15. Essa configuração tem por objetivo aumentar o nível de especialização do sistema de inferência para modos de falhas mais difíceis de serem separados. Nesse caso específico, foram criados três sistemas de inferência.

Primeira camada de classificação

Na parametrização da primeira camada foram utilizadas as métricas (descritas na seção Definição do sistema de inferência *Fuzzy*) como entradas, utilizando três conjuntos *fuzzy* com função de pertinência do tipo trapezoidal; com exceção da métrica (Instante do valor máximo da terceira fase em %, a qual usou apenas dois conjuntos *fuzzy*). Para a saída foi escolhida uma função linear. A figura 12 e a tabela 3 mostram os resultados obtidos pelo sistema de inferência. Para que seja possível plotar um gráfico, os eventos classificados como Normal correspondem ao valor igual a 0, as de defeito de atrito com valor igual a 30, defeitos de picos com valor de 60 e obstrução de 90.

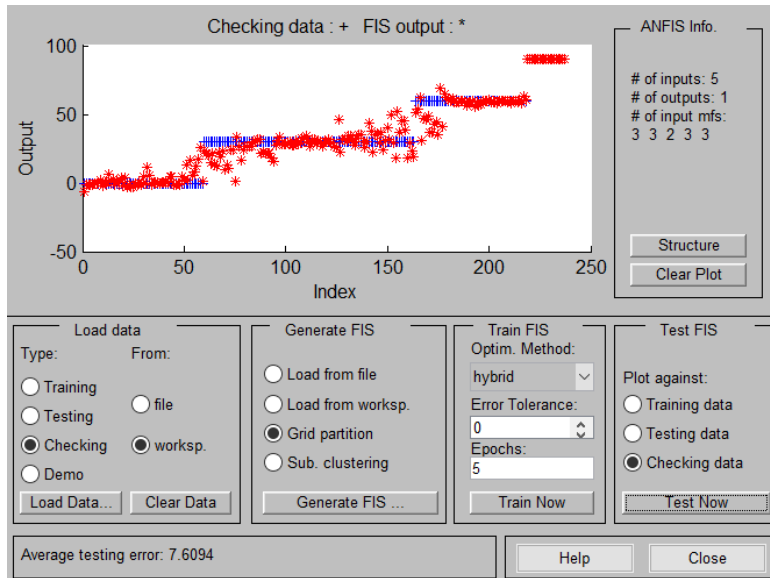


Figura 12 – Check Primeira camada

Tabela 3

Classes	Acertos Total (%)
Normal	91,69
Atrito	96,01
Pico	97,35
Obstrução	100
Total	94,81

Segunda camada de classificação - Atritos

A parametrização da segunda camada para a classificação dos atritos, não obteve bons resultados para a configuração semelhante ao da primeira camada. Dessa forma, foi usado o recurso *Subtractive Clustering*, o qual analisa os dados por um algoritmo *K-means* e identifica clusters de dados. A partir desses clusters, o sistema gera automaticamente a quantidade de conjuntos *fuzzy* e o tipo da função de pertinência. Nesse caso, o sistema gerou 9 conjuntos

fuzzy com função de pertinência do tipo gaussiana. A figura 13 apresenta os resultados dessa parte do sistema.

A figura 13 mostra os dados obtidos durante a fase de treinamento e check do sistema. Pode-se ver que separação não é perfeita e possui um grande nível de confusão. Isso está em linha com a experiência dos engenheiros do processo pois a separação visual é passível de erros, visto que em muitos casos a classificação entre médio e alto atrito é tênue. A tabela 4 apresenta os percentuais de acerto dessa camada.




Figura 13 - Check segunda camada - atritos

Tabela 4

Classes	Acertos Total (%)
Médio Atrito	84,12
Alto Atrito	92,39
Total	89,04

Segunda camada de classificação - Picos

A parametrização da segunda camada para a classificação dos picos, obteve os melhores resultados para a configuração semelhante ao da segunda camada - atritos. Nesse caso, o sistema gerou 4 conjuntos *fuzzy* com função de pertinência do tipo gaussiana.

A figura 14 mostra os dados obtidos durante a fase de treinamento do sistema. Pode-se ver que separação é perfeita e possui um grande nível de assertividade. Isso está em linha com a experiência dos engenheiros do processo pois a separação visual é trivial. A tabela 5 apresenta os percentuais de acerto dessa camada.

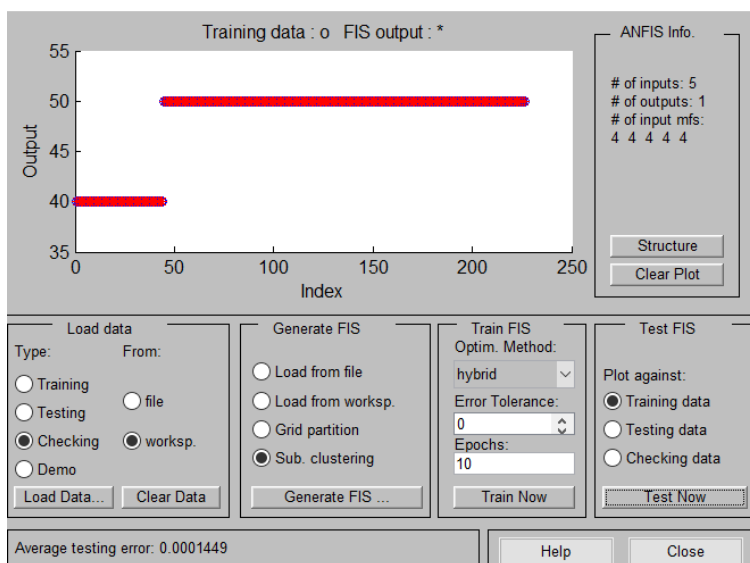


Figura 14 – Treinamento Segunda Camada - picos

Tabela 5

Classes	Acertos Total (%)
Pico destravamento	100,00
Pico travamento	100,00
Total	100,00

O diagrama da figura 15 resume os índices de acerto do método *fuzzy* em camadas.

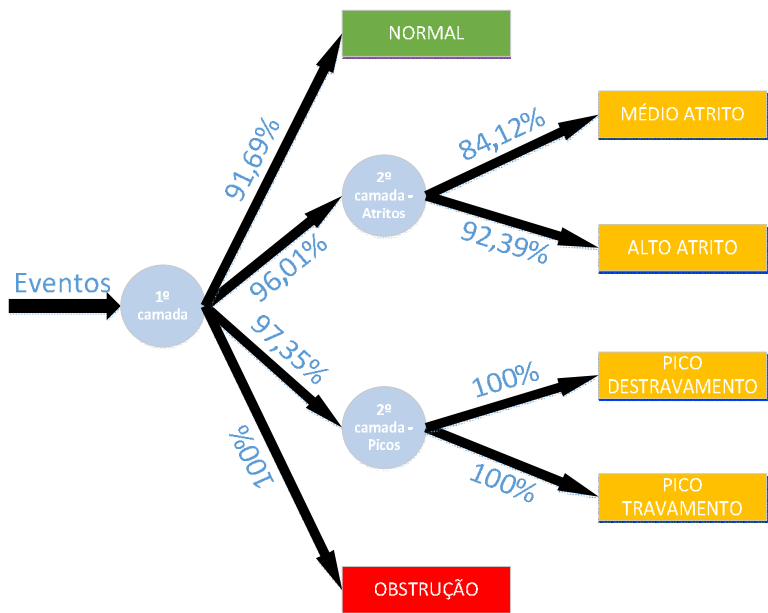


Figura 15 – Percentuais de acertos do sistema fuzzy em camadas

Pode-se considerar que a probabilidade de acerto do modo de falha é a multiplicação dos percentuais das camadas, dessa forma, a tabela 6 resume os percentuais agregados.

Tabela 6

Classes	Acertos Totais (%)
Normal	91,69
Médio atrito	80,76
Alto atrito	88,70
Pico travamento	97,35
Pico destravamento	97,35
Obstrução	100,00
Média Total	84,01

Módulo de Redes Neurais Artificiais

O sistema foi parametrizado com três camadas de classificação, conforme apresentado na figura 18. Essa configuração tem por objetivo aumentar o nível de especialização da rede neural para sintomas mais difíceis de serem separados. Nesse caso específico, foram criadas quatro redes neurais PMC. Na configuração em camadas, cada RNA recebe as informações de todas as trinta métricas mais a saída da RNA anterior como dados de entrada.

Para a configuração da rede, foi executado o algoritmo de treinamento utilizando os eventos de movimentações das chaves do banco de dados criado para o trabalho.

A primeira camada da RNA segrega os estados da máquina (Normal, Defeito ou Falha). Na matriz de confusão da figura 16, pode-se observar o resultado do treinamento e teste com os três estados de máquina.



Figura 16 – Matriz de confusão da primeira etapa de classificação

Sendo as curvas normais representadas pela classe 1, as em defeito pela classe 2 e as em falha pela classe 3. Os eventos classificados como 2 - Defeitos seguem para a próxima etapa de classificação. Pode-se notar que, em média, essa primeira etapa possui taxa de acertos de 94,8%.

Os resultados da 2ª etapa de classificação são apresentados na figura 17. Essa etapa separa os eventos entre Atrito (classe 1) e Pico (classe 2).




Figura 17 – Matriz de confusão da segunda etapa de classificação

É possível perceber que todos os defeitos de atrito são identificados. Existe certa confusão, porém quando se trata dos alvos de picos, que ora são classificados como atrito, mas ainda tendo um índice de acerto 93,8% na validação. Porém, a taxa média de acerto dessa classificação ficou em 98,9%.

Ao introduzir a 3ª etapa na classificação com duas RNAs, os dados de pico de travamento e destravamento são totalmente segregados e os de alto e médio atrito mostram menor percentual de acertos, porém ainda aceitáveis com acertos acima de 80%.

A matriz de confusão na figura 18 mostra o alto atrito na classe 1 e o médio atrito na classe 2. A redução na relação de acerto dos alvos é aceitável devido à natureza do problema. Um problema de atrito sempre demonstrará a dificuldade de movimento sendo que essa

graduação entre médio pode ser utilizada para definição de criticidade do defeito por exemplo.

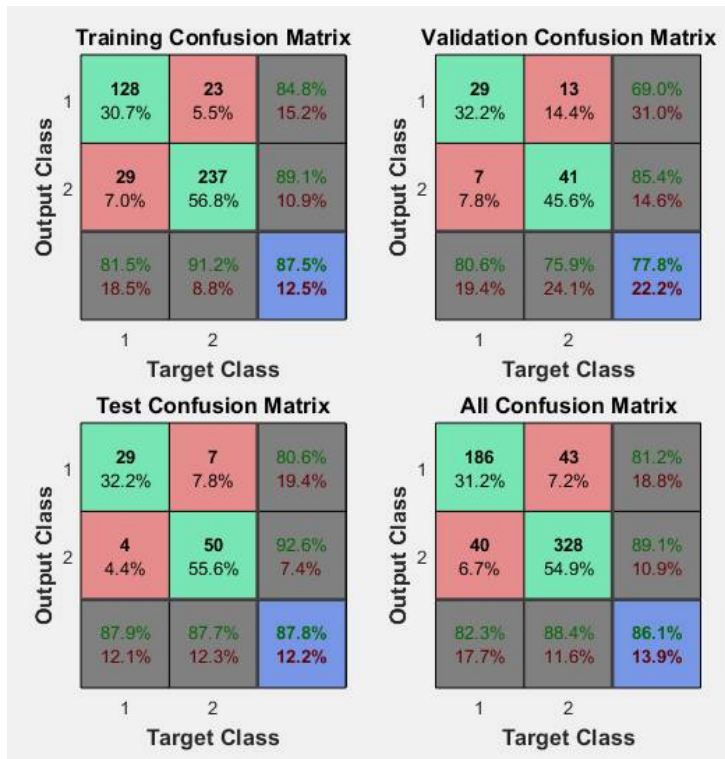


Figura 18 – Matriz de confusão da RNA Atrito na terceira etapa de classificação

Problemas em picos de travamento segregados 100% conforme mostrado na figura 19 podem demonstrar problemas diferentes como um problema em um tirante em um pico de destravamento e sujeira na ponta da agulha no pico de travamento por exemplo. Por isso importante diferenciá-los.

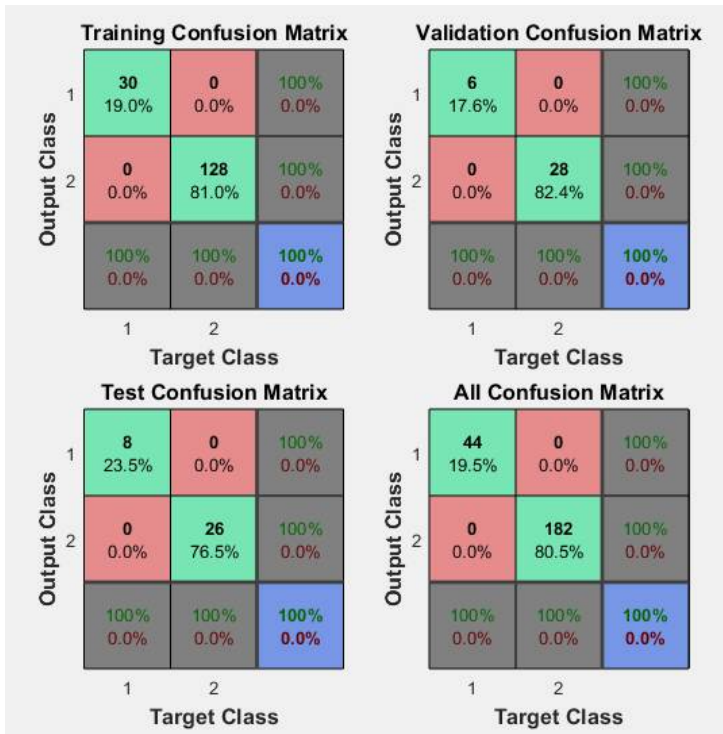


Figura 19 – Matriz de confusão da RNA Pico na terceira etapa de classificação

O diagrama da figura 20, resume o teste com todas as etapas de classificação.

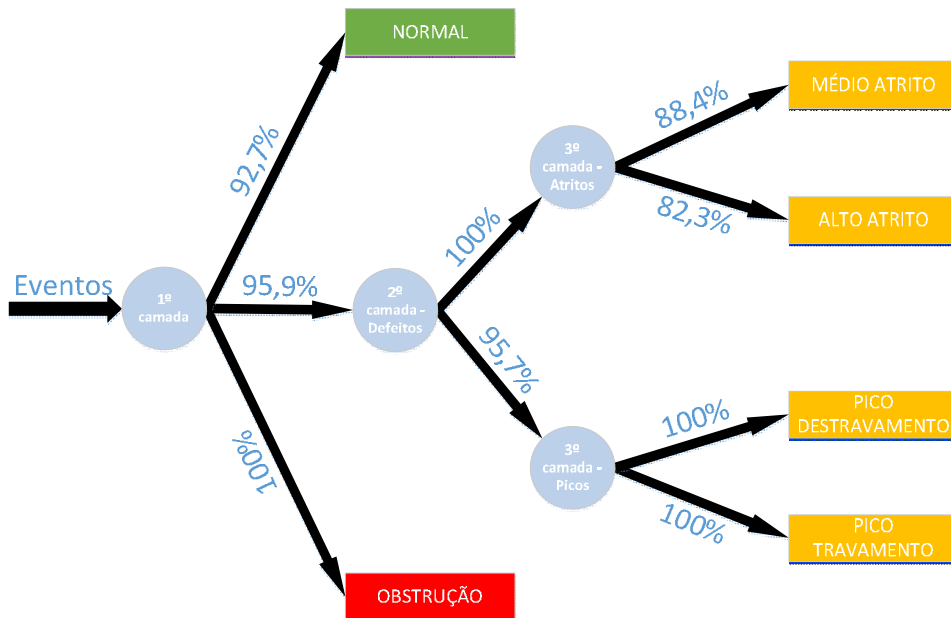


Figura 20 – Diagrama resumo do treinamento em três etapas

Sistema híbrido Neuro-Fuzzy

Com a conclusão do treinamento individual dos módulos de RNA e *Fuzzy*, a implementação do sistema híbrido é facilitada, pois devido aos critérios de criticidade o sistema deverá escolher a resposta de maior valor entre os módulos. Dessa forma, o sistema fornece dois níveis de respostas, a primeira é com relação ao estado da máquina (Normal, Defeito ou Falha), a segunda, e mais detalhada, são os sintomas (Alim. Elétrica, Médio Atrito, Alto Atrito, Pico Travamento e Destravamento). As tabelas 7 e 8 mostram o resultado para o sistema final.

Tabela 7 - Nível de resposta - Estado da máquina

Estado da máquina	Acertos Totais (%)
Normal	92,20
Defeito	96,29
Falha	100,00
Média Total	95,52

Tabela 8 - Nível de resposta - Sintomas

Sintoma	Acertos Totais (%)
Normal	92,20
Alimentação Elétrica	100,00
Pico destravamento	94,57
Médio Atrito	82,77
Alto atrito	83,82

Pico travamento	94,57
Obstrução	100,00
Média Total	91,16

As informações mais relevantes ao CCO (Centro de controle operacional) da ferrovia são somente os estados das máquinas, que apenas precisa saber se a chave está com operação normal, anormal ou se o equipamento falhou completamente. Nesse quesito do CCO, pode-se verificar que o sistema fornecesse taxas de acerto acima de 95% em média. Já para o CCM (Centro de controle de manutenção) e para as equipes de manutenção, as informações sobre os sintomas são muito valiosas para determinar se o equipamento precisa sofrer uma intervenção imediata ou não. Portanto, o ciclo de manutenção do equipamento pode ser otimizado de modo a substituir a manutenção preventiva pela manutenção preditiva. Outro fato importante é a identificação do defeito remotamente com taxa de acerto acima de 90%. Esse fato proporcionará a equipe de campo informações privilegiadas sobre o equipamento, o que poderá reduzir o tempo de reparação (MTTR - *Mean Time to Repair*).

CONCLUSÕES

A assinatura de corrente de uma máquina de chave demonstra uma série de sintomas de defeitos que analisados da forma correta, podem gerar uma vantagem para a manutenção em relação a possíveis impactos na ferrovia.

Para que essa análise seja a mais assertiva possível, é necessário dividir a curva de corrente da máquina de chave em fases, que compreendem seu acionamento, movimentação e

travamento. O conhecimento profundo de cada característica dessas fases é determinante para o sucesso da predição de defeitos.

Mais importante que saber se a máquina está em falha ou não, é saber o provável motivo da falha. Isso pode ser alcançado com o sistema proposto. Ter essa informação disponível para o CCM vai proporcionar às equipes de manutenção mais informações nos atendimentos as ocorrências com o nível de acerto superior a 95%. Com essas informações consolidadas e totalmente confiáveis poderemos mudar o patamar de manutenção preventiva para um modo por condição desde de que tenhamos um sistema de monitoramento eficaz.

No que tange a arquitetura do sistema, algumas ações podem ser tomadas de modo a garantir maior compatibilidade do sistema no ambiente a ser instalado. O desenvolvimento de uma arquitetura com custo mais acessível e por exemplo sensores de efeito hall menos intrusivos que os utilizados devem ser pensados.

REFERÊNCIAS BIBLIOGRÁFICAS

ASADA, T.; ROBERTS, C.; KOSEKI, T. An algorithm for improved performance of railway condition monitoring equipment: Alternating-current point machine case study. *Transportation Research Part C: Emerging Technologies*, v.30, p.81-92, May 2013.

KALLEMBACK, Guilherme M. Identificação de modos de falha a partir da assinatura de corrente de máquinas de chave utilizando um sistema de inferência *fuzzy*, Abril 2016.

MOREIRA, Gustavo C. Identificação de modos de falha a partir da assinatura de corrente do motor de máquina de chave utilizando redes neurais artificiais, Abril 2016.

NAKAMURA, K., 1992. TENTETSU, S. The point machine. Japan Railway Electrical Engineering Association.

NATIONAL Instruments. 2016. ilustrações. Disponível em: <http://www.ni.com>. Acesso em: 10 mar. 2016.