

Desenvolvimento de sistema automático de identificação de modos de falhas em máquinas de chave utilizando inteligência artificial

Gustavo Moreira

Guilherme Miranda Kallemback

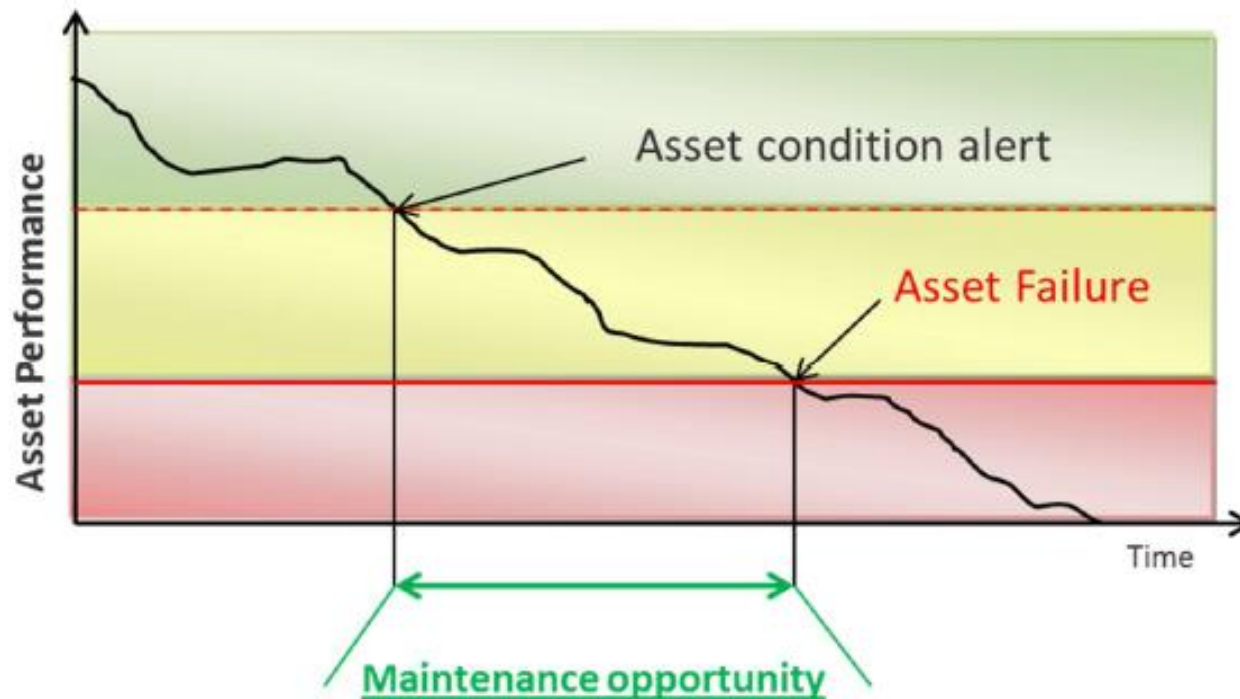
Wallison Barbosa

22ª Semana de Tecnologia Metroferroviária



Monitoramento de Condição

Princípio Básico



O monitoramento fornece tempo para prevenção de falhas e redução de gastos inesperados

Benefícios para o negócio

Redução de atrasos e paradas não programadas

- Manutenção preditiva – Redução no número de falhas
- Correção rápida de falhas – Aprovisionamento de material e mão de obra corretos
- Menor tempo na via – Viés de segurança e produção

Maior Disponibilidade


- Menos chamados de emergência
- Maior conhecimento sobre o comportamento e causa das falhas
- Menor número de falhas não identificadas

AMV - Aparelho de Mudança de Via



ANCAR

AMV - Aparelho de Mudança de Via



Detalhe de roletes e conjunto de frente

MCH - Máquina de chave




Máquina de chave Elétrica Kyosan

MCH - Máquina de chave




Máquinas de chave na EFVM

Principais modelos de MCH na linha tronco da EFVM



Principais causas de defeitos/falhas (2015 e 2016)



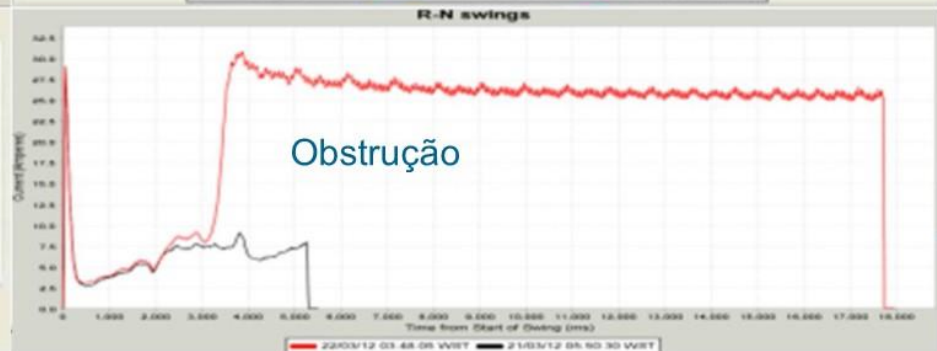
Máquinas de chave na EFVM

- MTTR de cerca de 6,14h
- Média de 2,9 falhas e defeitos por dia
- Trabalho se concentrará nas máquinas de chave modelo Kyosan (74%)
- Visará identificar as principais causas de defeitos/falhas (Desajustes, Obstruções, Dormentes desquadrados, etc) o que corresponde a 60% do total de ocorrências

Monitoramento da condição de MCH

No mercado, já temos algumas soluções disponíveis e várias ferrovias no mundo utilizam-se de produtos já prontos de monitoramento de máquina de chave.

- Monitoramento da potência elétrica demandada pelo motor
- Como o motor é de pequeno porte e o sistema elétrico do local é robusto, pode-se desconsiderar a variação de tensão



Monitoramento da condição de MCH

- Soluções do mercado são de alto custo
- Possuem arquitetura fechada
- Tecnologia proprietária dificulta a melhoria contínua e a integração com os sistemas legados das empresas

Dessa forma, a busca de uma solução da própria ferrovia se torna bastante viável

Identificação de falhas automática

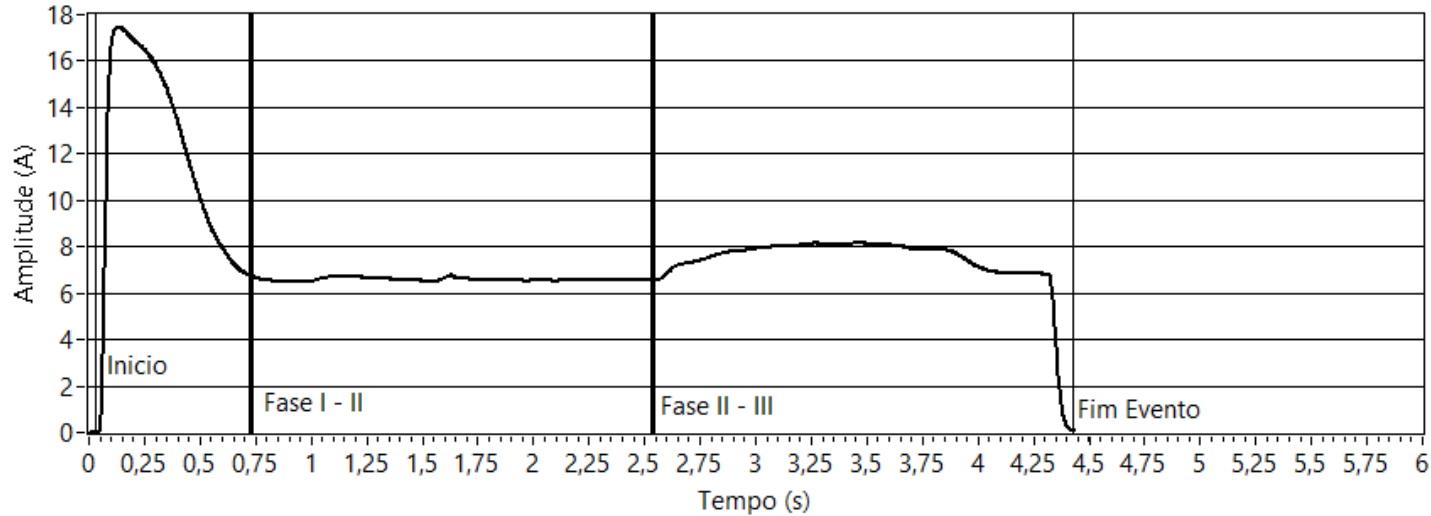
- A EFVM possui cerca de 950 máquinas de chave elétricas
- Média diária de 3.600 movimentações por dia
- Geração de grande quantidade de dados
- O sensoriamento somente não garante nenhuma vantagem competitiva, pois é necessária a análise das curvas para a classificação dos defeitos.
- Soluções mais simples já foram testadas e nenhuma apresentou resultados satisfatórios.
- A diferença nos tipos de componentes mecânicos dificulta a parametrização pura e simplesmente de limites de corrente

Identificação de falhas automática

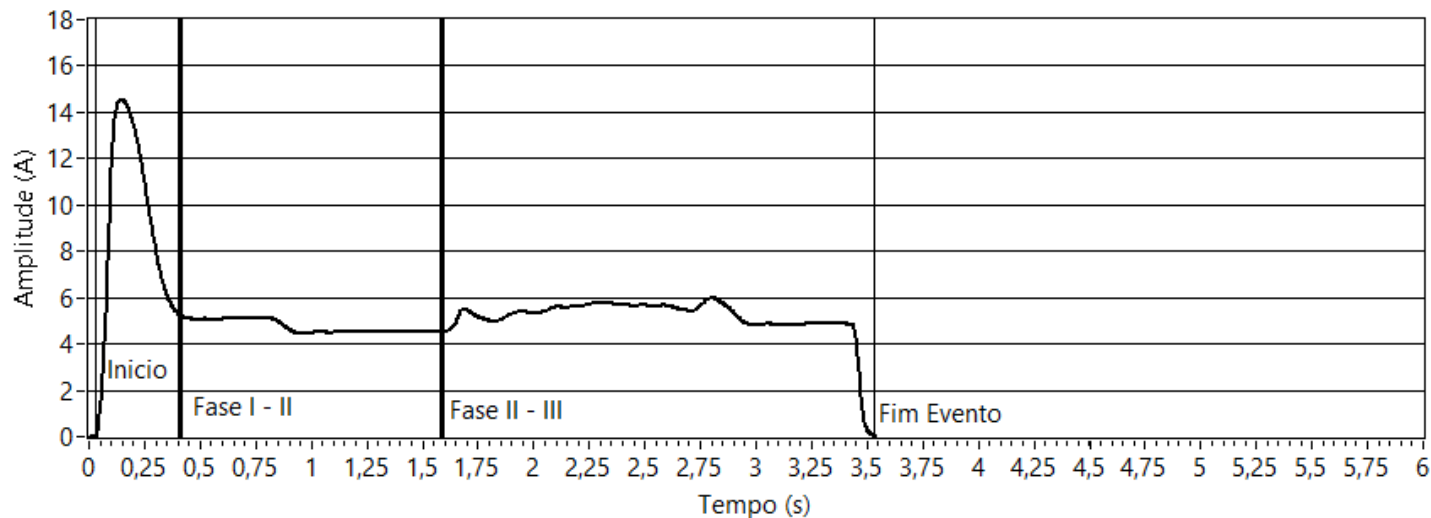
Exemplo de duas curvas classificadas como de operação normal.

RH07

W21b



W21a



Falhas de Máquina de Chave

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

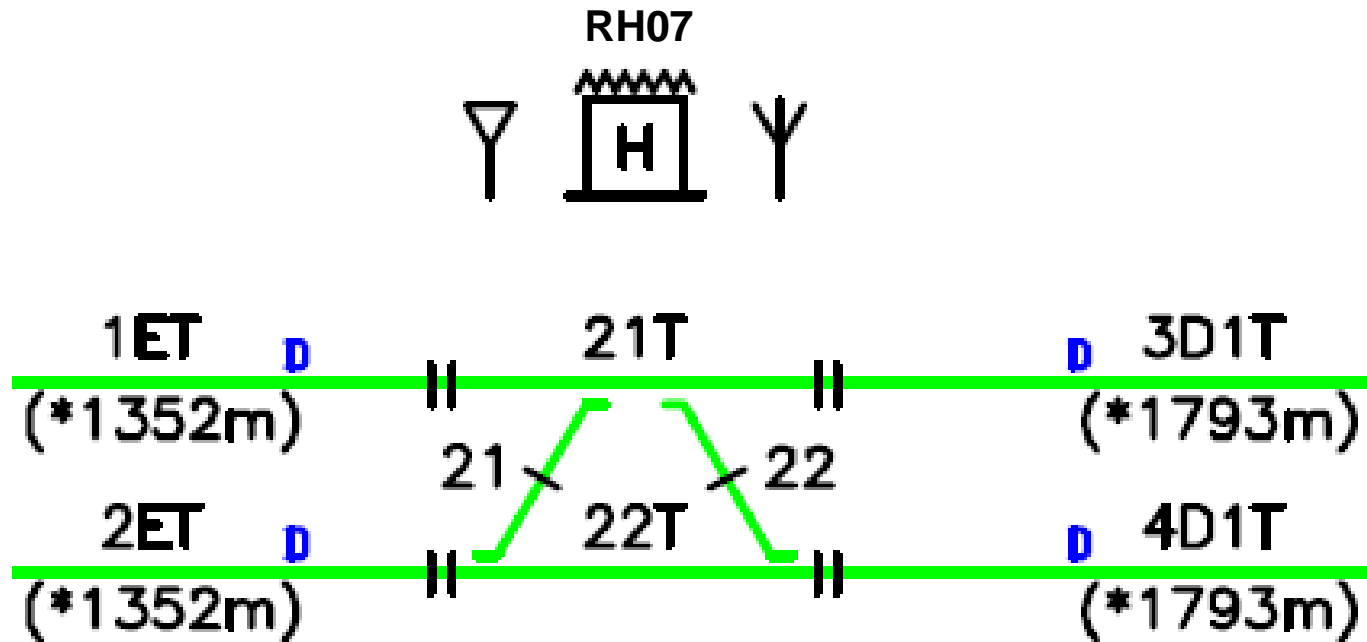
- **Falhas abruptas** – Aparecem de repente, sem qualquer indicação prévia;
- **Falha intermitente** – Falhas que acontecem esporadicamente;
- **Falha incipiente** – Defeito que se desenvolve gradualmente ao longo de um período de tempo.

Falhas de Máquina de Chave

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

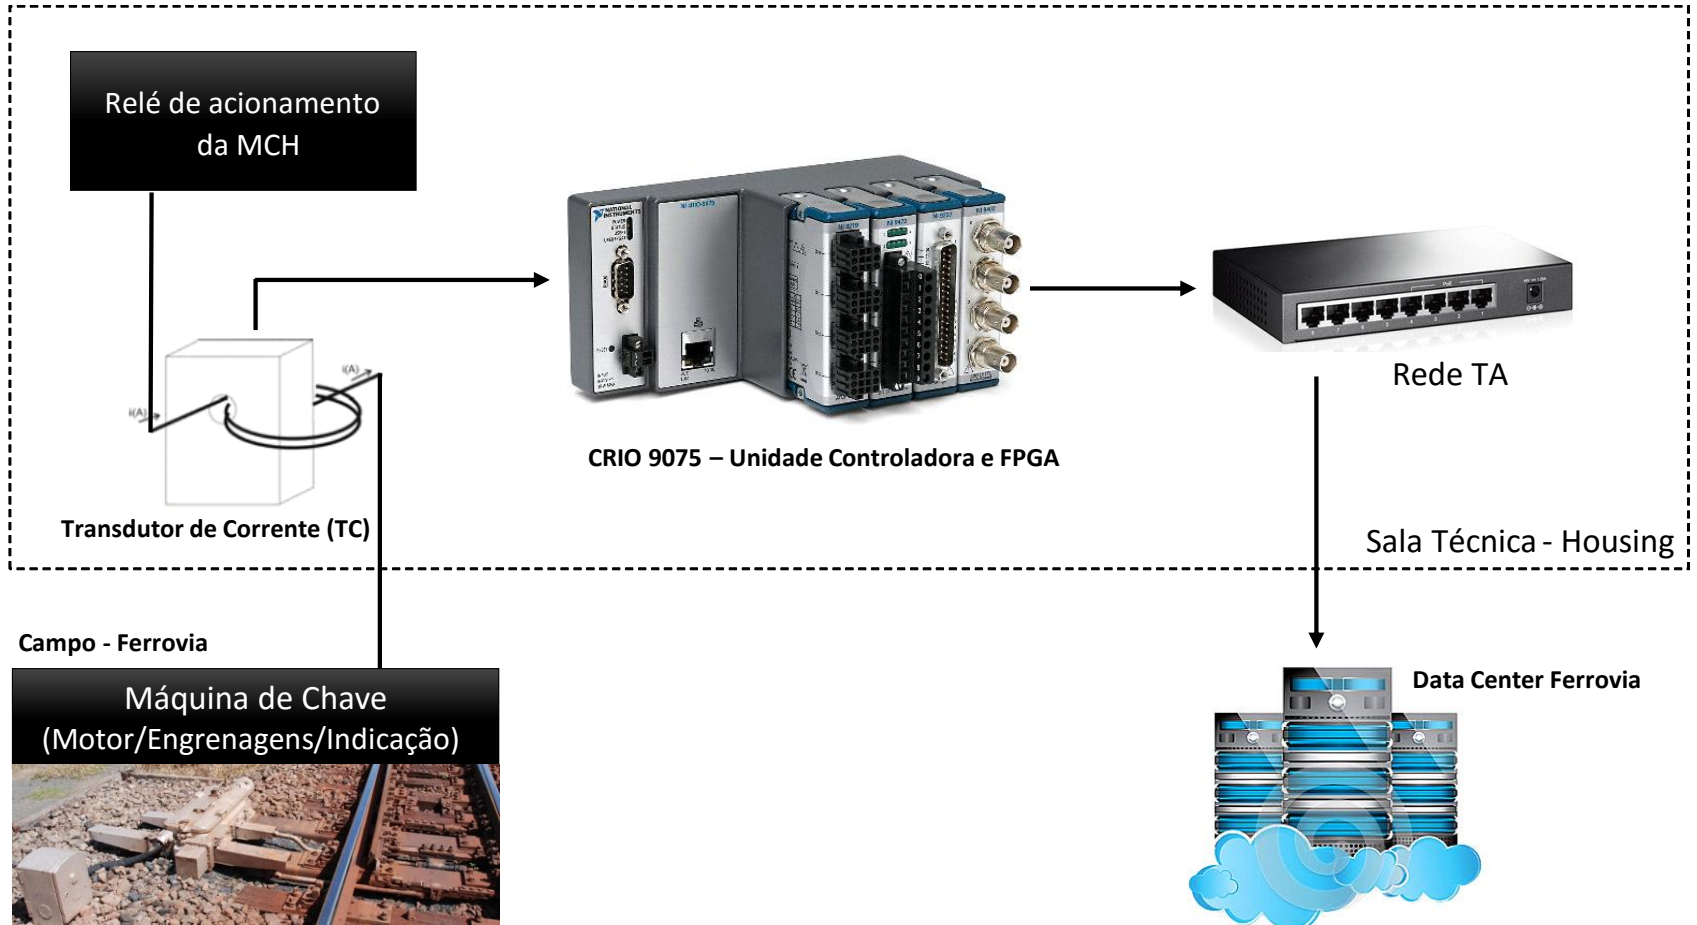
- Falhas causadas por componentes da máquina de chave;
- Falhas causadas por componentes externos;
- Falhas causadas por desalinhamento;
- Falhas causadas pelo ambiente;

Arquitetura do Sistema



Esquemático do plano de vias sinalizadas – Local de Instalação

Arquitetura do Sistema



Sistema de aquisição de dados

Firmware

- Instruções de configuração do hardware FPGA

Software embarcado

- programa para a interface com o firmware, coleta, trata e armazena temporariamente os dados.
- SO em tempo real - VxWorks

Software Servidor

- Responsável pela transferência dos dados do cRIO para o datacenter da ferrovia. Implementa toda a lógica de tratamento por inteligência artificial
- Comunica a condição do equipamento para o Supervisório

Sistema Supervisório

- responsável por apresentar aos usuários as informações críticas para operação dos equipamentos.

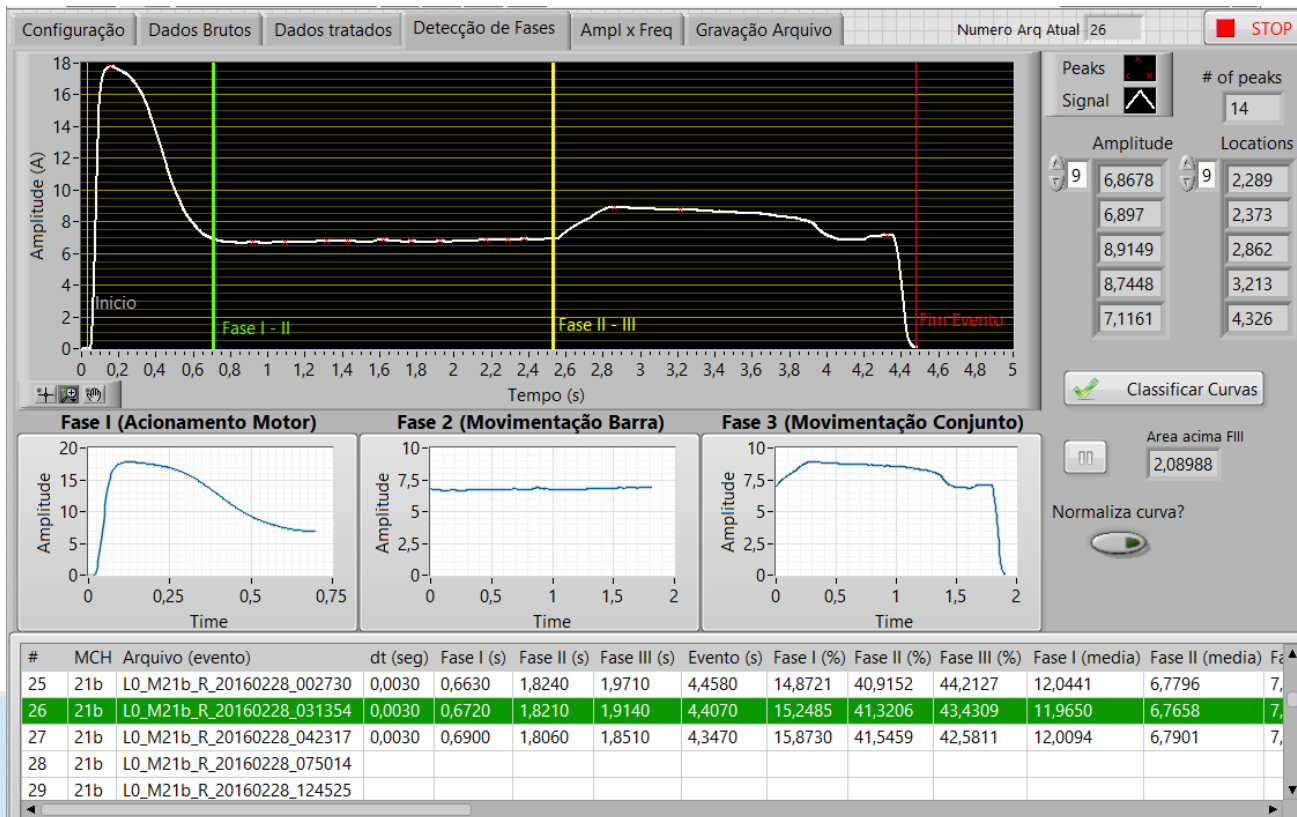
Sistema de aquisição de dados

O sistema desenvolvido possui as seguintes características:

- Tratamento dos sinais de forma determinística
- Armazenamento local e remoto
- Comunicação ethernet
- Alta taxa de amostragem por canal, 5kHz
- Alta resolução das entradas analógicas, 16 bits

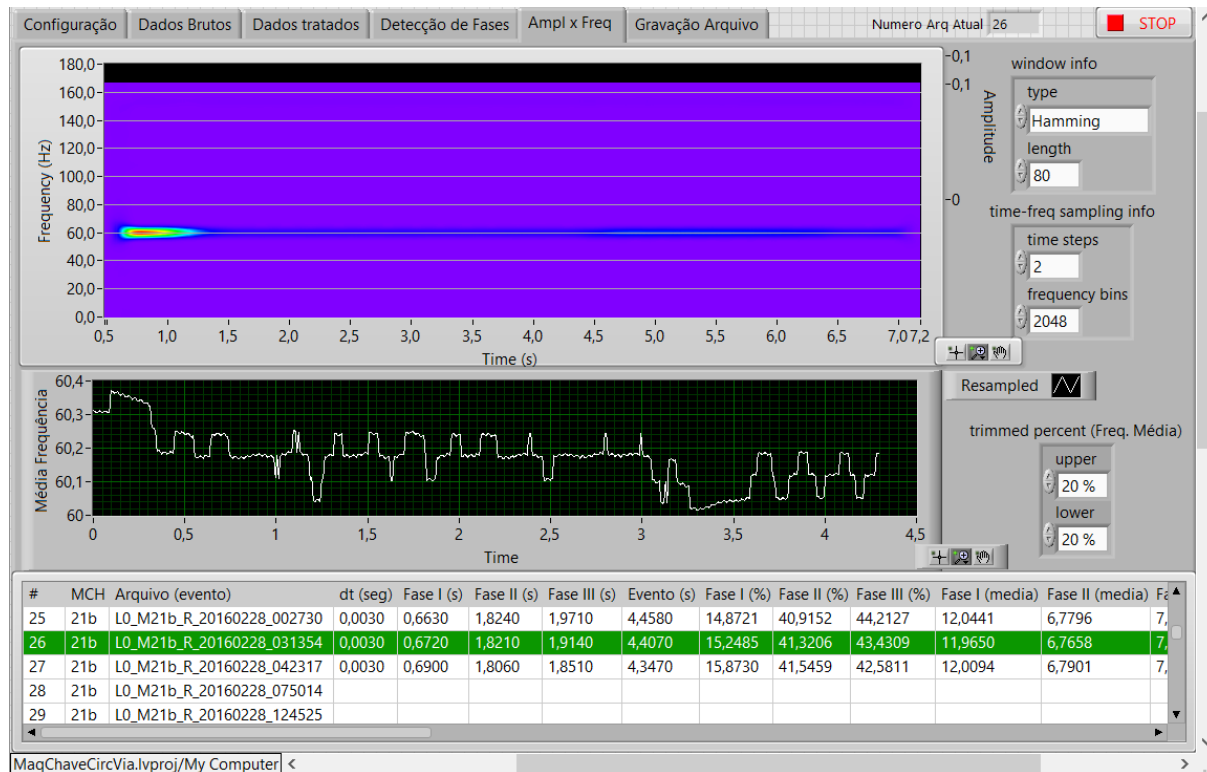
Software Supervisório

- Análise dos dados
- Examina as métricas do evento




Tela de análise de detecção de fases do evento

Software Supervisório



Tela de análise da espectral do sinal

Software Supervisório



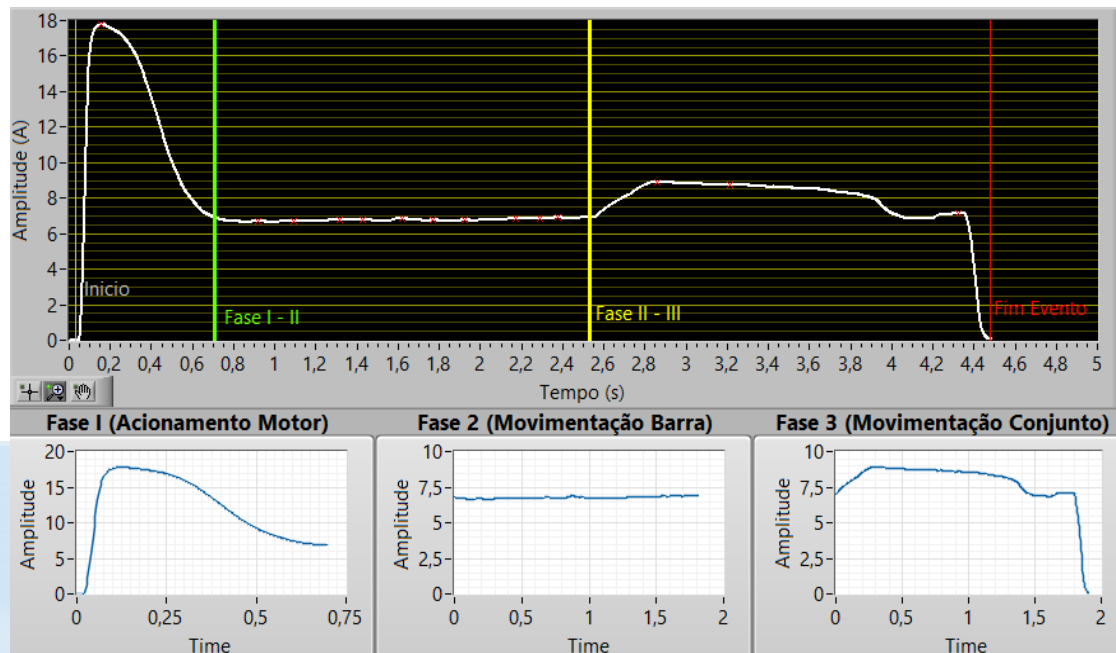
Tela de apresentação dos dados tratados e dos cálculos de derivada e integral

Algoritmo de Detecção de fases

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




Algoritmo de Detecção de fases

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



Definição de padrões de eventos

Normal – O Evento não apresenta nenhum defeito ou falha

Defeito – São o tipo de falha incipiente. A máquina chave ainda está em funcionamento, porém não está em sua condição ideal e pode vir a gerar uma falha

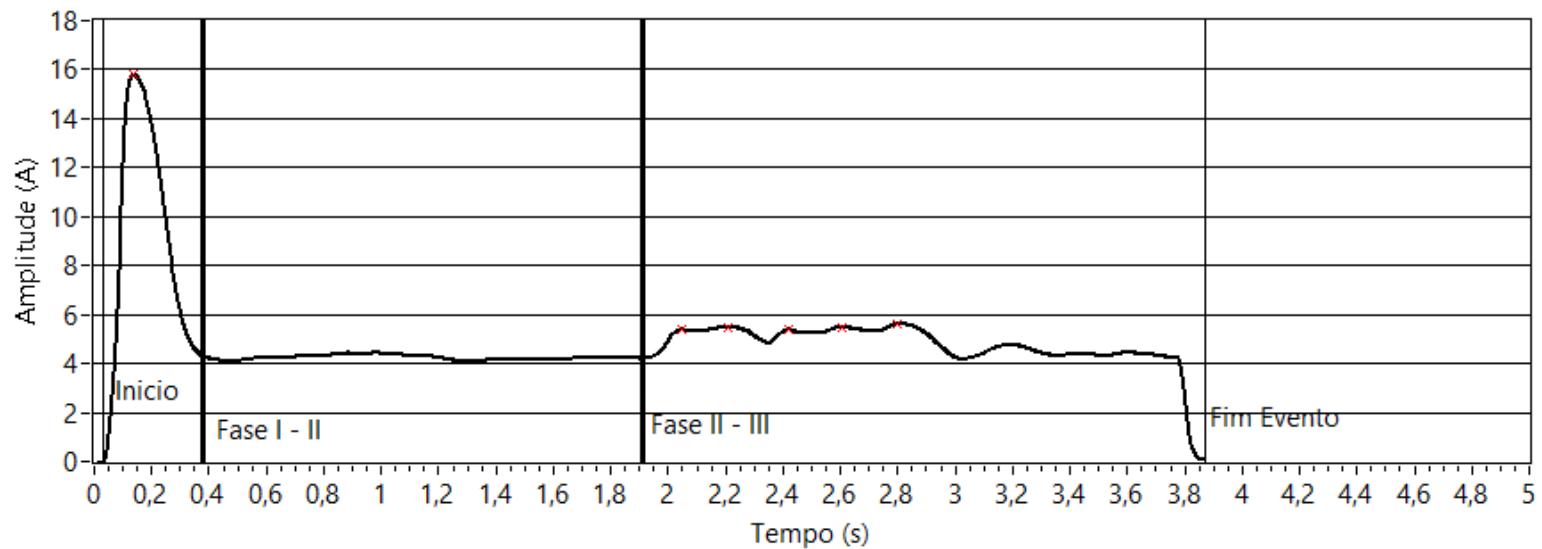
Falha – A máquina de chave não consegue cumprir sua função, necessitando de uma intervenção imediata.

Definição de padrões de eventos

Os padrões classificados como defeito foram separados em 3 problemas:

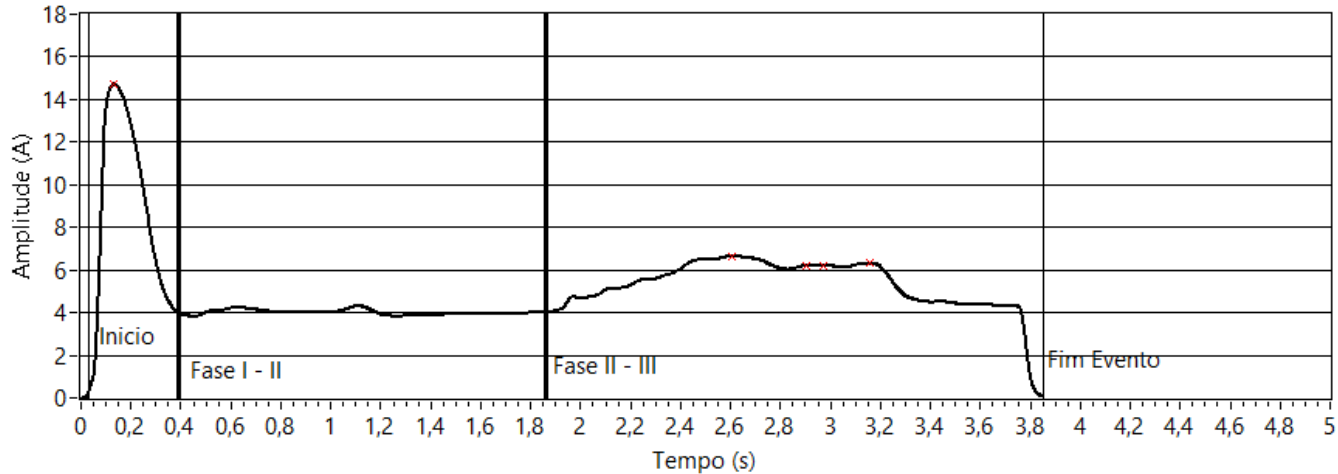
- Atrito durante a movimentação das agulhas
- Picos de corrente
- Problemas na alimentação elétrica

Definição de padrões de eventos




Exemplo de movimento normal

Definição de padrões de eventos




Exemplo de movimento com médio atrito

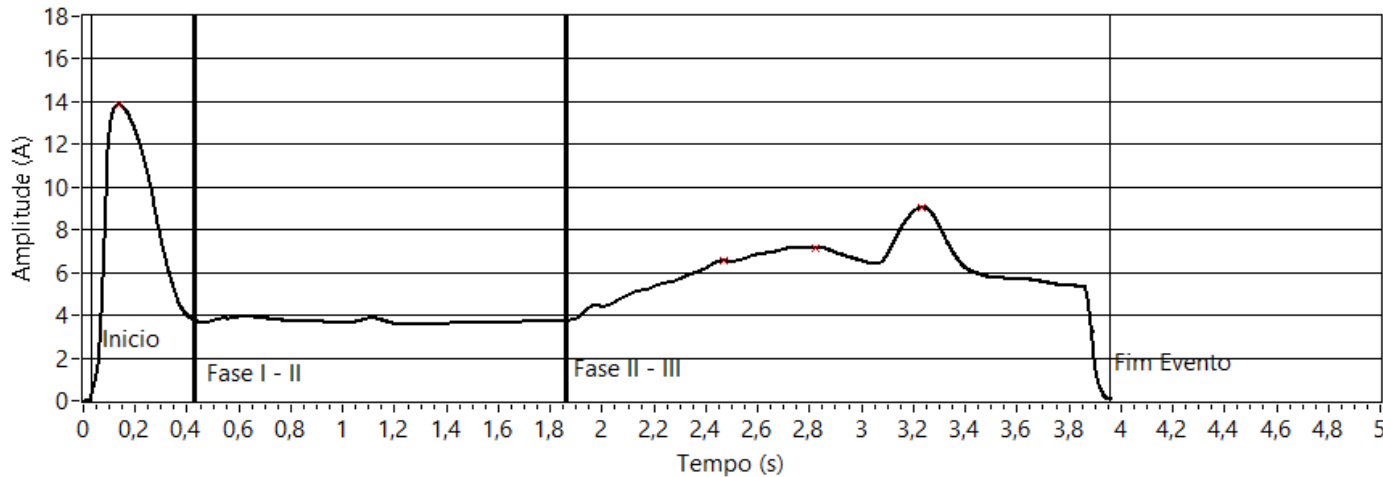


Exemplo de movimento com alto atrito

Definição de padrões de eventos




Exemplo de movimento com pico no destravamento




Exemplo de movimento com pico no travamento

Definição de padrões de eventos

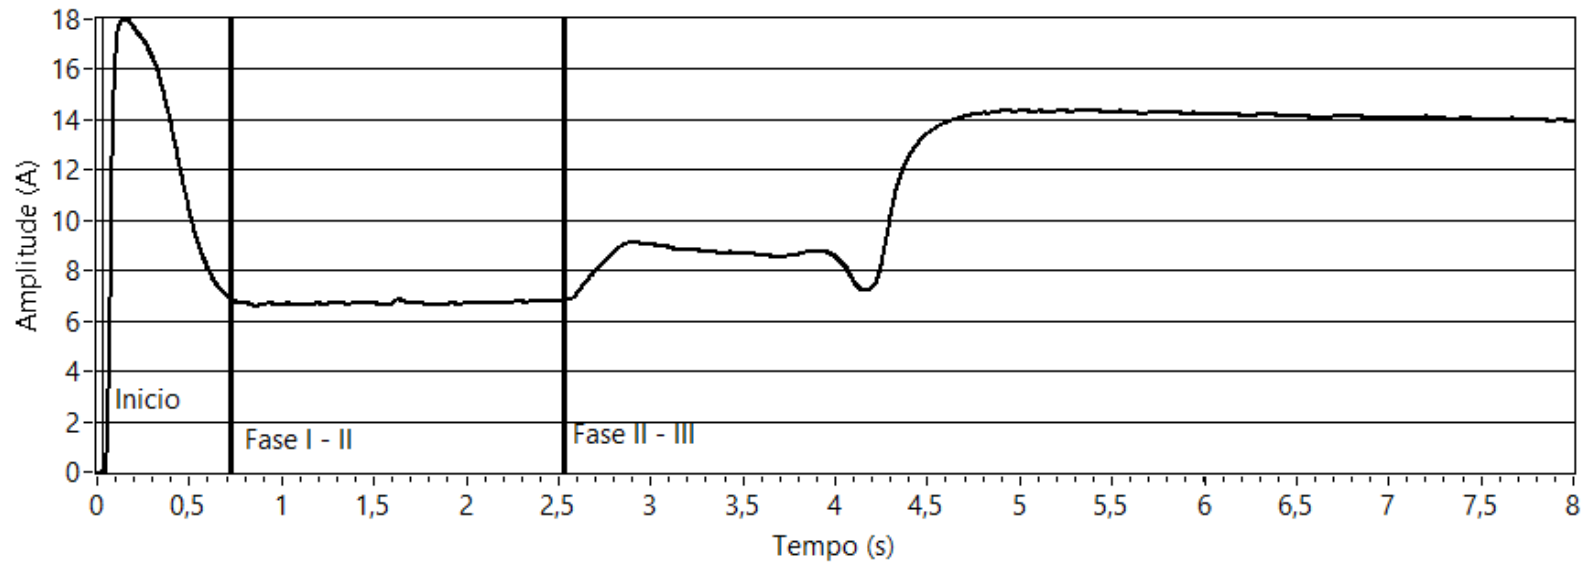


Exemplo de análise da frequência normal de alimentação



Exemplo de análise da frequência anormal de alimentação

Definição de padrões de eventos



Exemplo de falha por obstrução

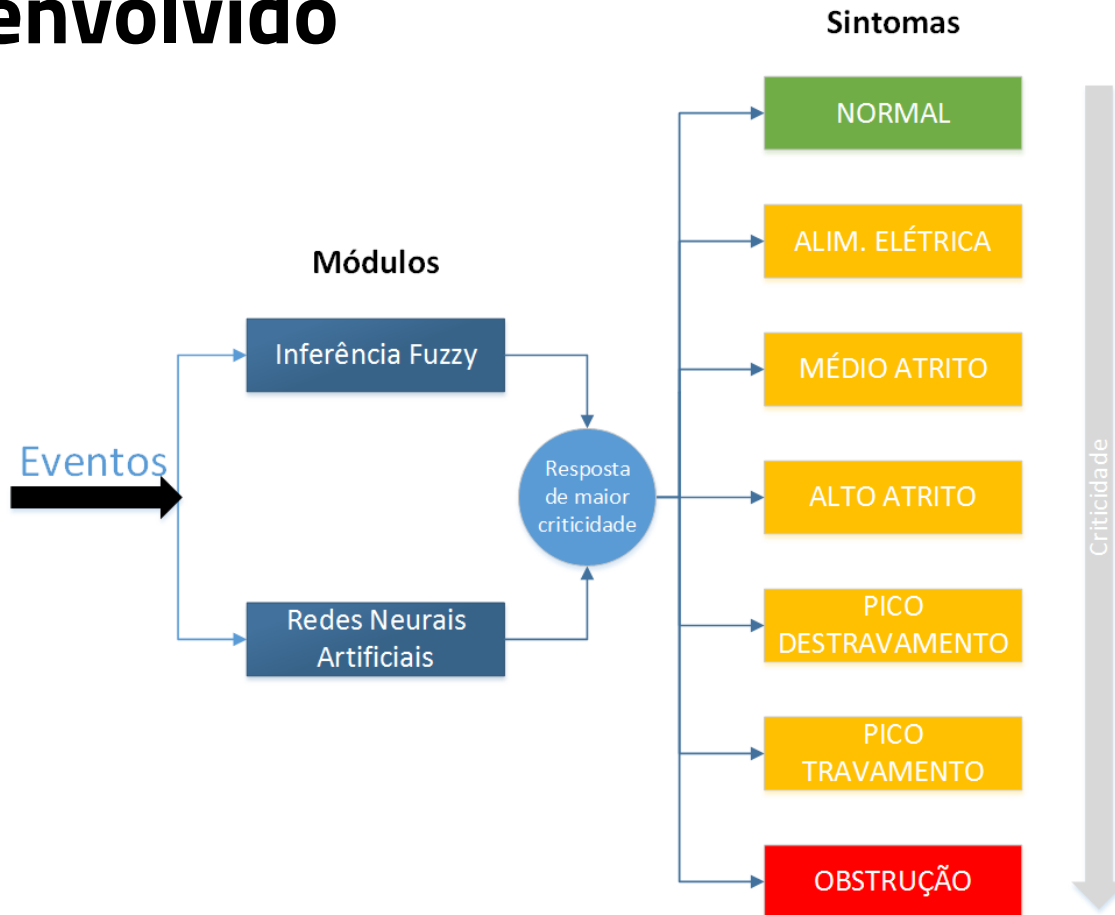
Métricas coletadas a partir dos eventos

- São coletadas cerca de 30 métricas calculadas a partir da curva de corrente
- Alguns exemplos:
 - Duração das três fases em segundos;
 - Percentual de tempo de cada fase em relação ao tempo total do evento;
 - Corrente média em cada fase;
 - Área compreendida por cada curva em cada fase;
 - Coeficiente de Variação do período de amostragem

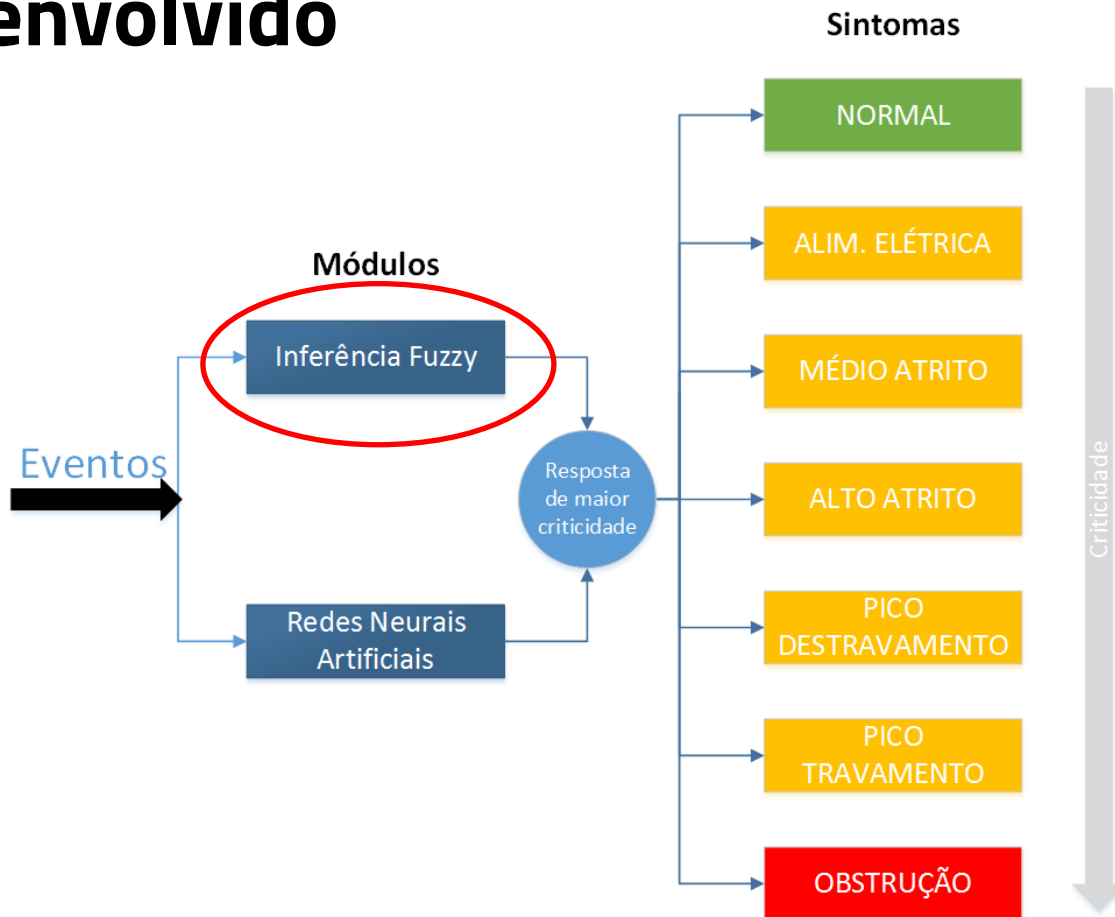
Sintomas e estados de máquina na operação da MCH

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

Sistema híbrido de inteligência artificial desenvolvido

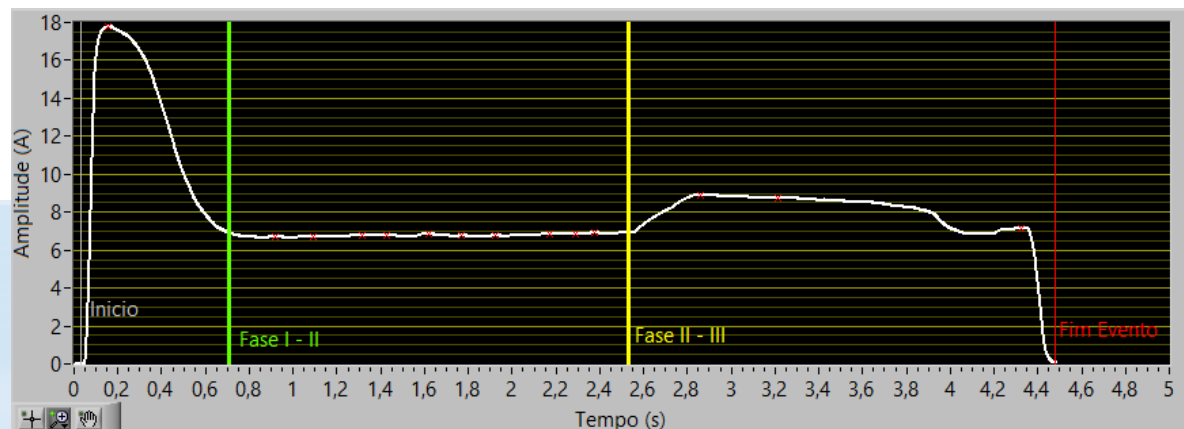


Sistema híbrido de inteligência artificial desenvolvido



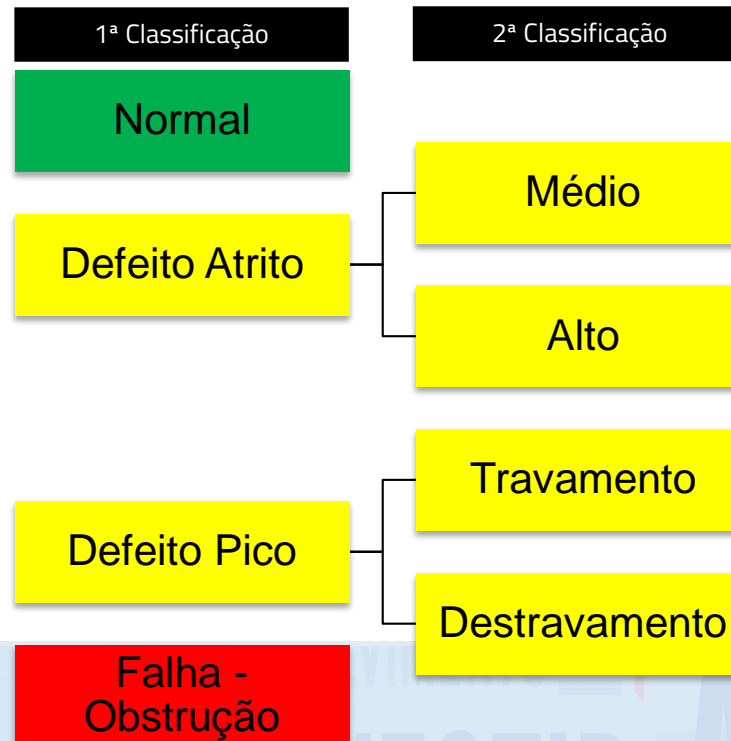
DEFINIÇÃO DO SISTEMA DE INFERÊNCIA FUZZY

- Utilizado o software Matlab, juntamente com o programa acessório ANFIS.
- Devido à complexidade do reconhecimento de padrões o tipo de sistema escolhido foi o Takagi-Sugeno.
- Seleccionadas 5 métricas para a criação do sistema:
 - 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



DEFINIÇÃO DO SISTEMA DE INFERÊNCIA FUZZY

Duas camadas de classificação



DEFINIÇÃO DO SISTEMA DE INFERÊNCIA FUZZY

Resultados Obtidos

- Foram coletados dados no período de 03/02/2016 a 11/03/2016. Nesse período ocorreram 1.581 eventos.
- Os dados de fevereiro/16, 1.332 eventos, foram separados para o fim de treinamento do sistema. Os dados de março/16, 249 eventos, foram usados para o check independente do sistema proposto
- A parametrização da primeira etapa de classificação foi:
 - Cinco entradas
 - Três conjuntos fuzzy com função de pertinência do tipo trapezoidal;
 - Função linear na saída

DEFINIÇÃO DO SISTEMA DE INFERÊNCIA FUZZY

Resultados Obtidos

- Para a parametrização das demais etapas do método, 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
- Para a camada da classificação dos defeitos de atritos, sistema gerou 9 conjuntos fuzzy com função de pertinência do tipo gaussiana.
- Para a camada da classificação dos defeitos de picos, sistema gerou 4 conjuntos fuzzy com função de pertinência do tipo gaussiana.

DEFINIÇÃO DO SISTEMA DE INFERÊNCIA FUZZY

Resultados Obtidos

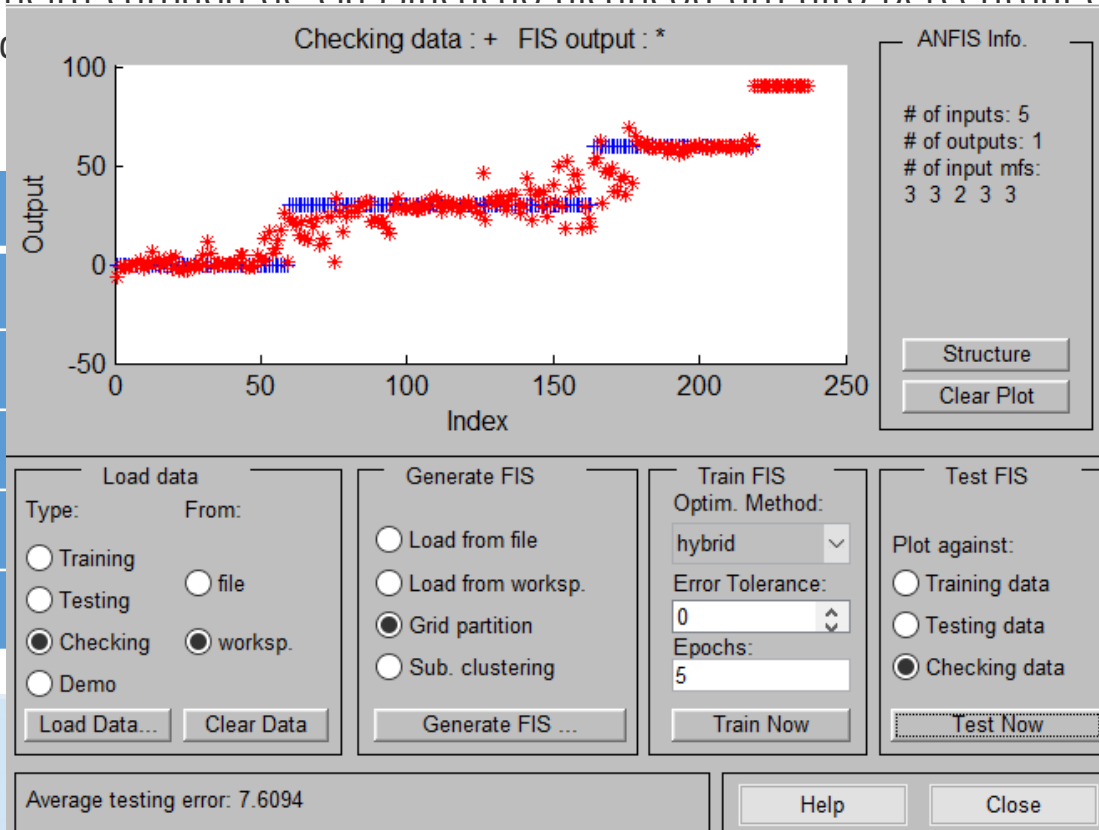
- Primeira camada de classificação alcançou um alto percentual de acertos em todos os modos de falhas estudados

Classes	Treinamento (%)	Teste (%)
Normal	91,69	93,33
Atritos	96,01	88,46
Picos	97,35	87,27
Obstrução	100	100
Total	94,81	90,42

DEFINIÇÃO DO SISTEMA DE INFERÊNCIA FUZZY

Resultados Obtidos

- Primeira camada de classificação alcançou um alto percentual de acertos em todos os modelos



Teste (%)

93,33

88,46

87,27

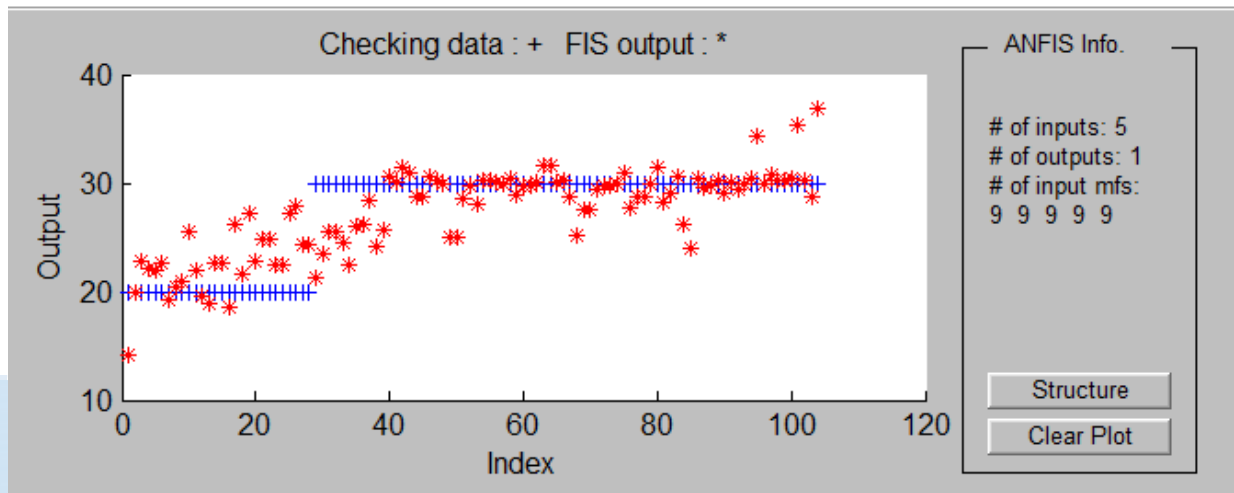
100

90,42

DEFINIÇÃO DO SISTEMA DE INFERÊNCIA FUZZY

Resultados Obtidos

- A segunda camada de classificação dos modos de atritos, pode-se ver que separação não é perfeita e possui um certo 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.

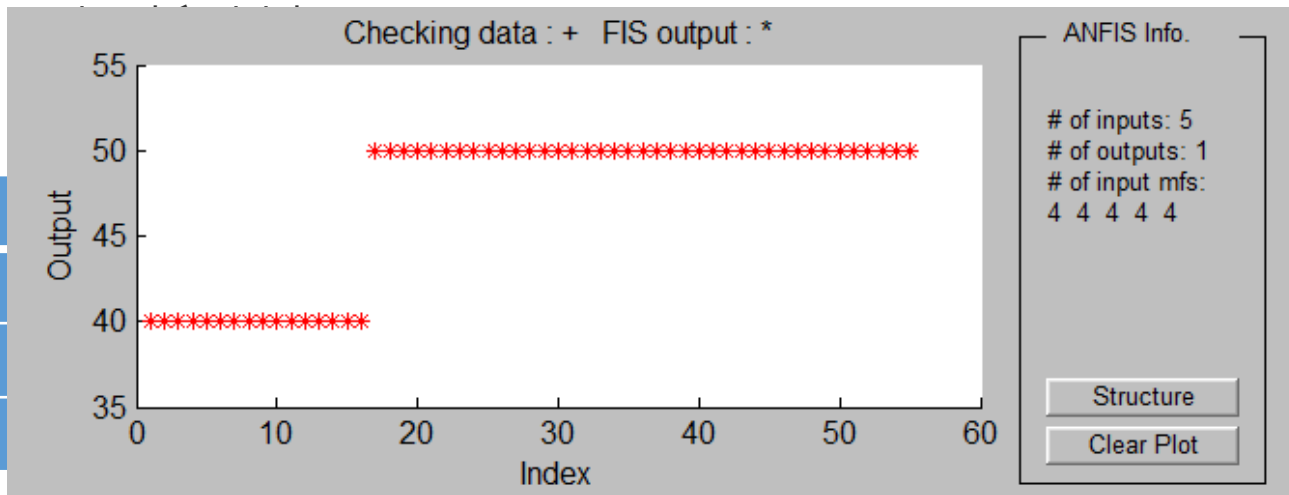


Teste (%)
78,57
89,47
85,71

DEFINIÇÃO DO SISTEMA DE INFERÊNCIA FUZZY

Resultados Obtidos

- A segunda camada de classificação dos modos de picos, pode-se ver que separação é perfeita e possui um grande nível de acerto.
- Isso está em linha com a experiência dos engenheiros do processo pois a separação



Teste (%)

100

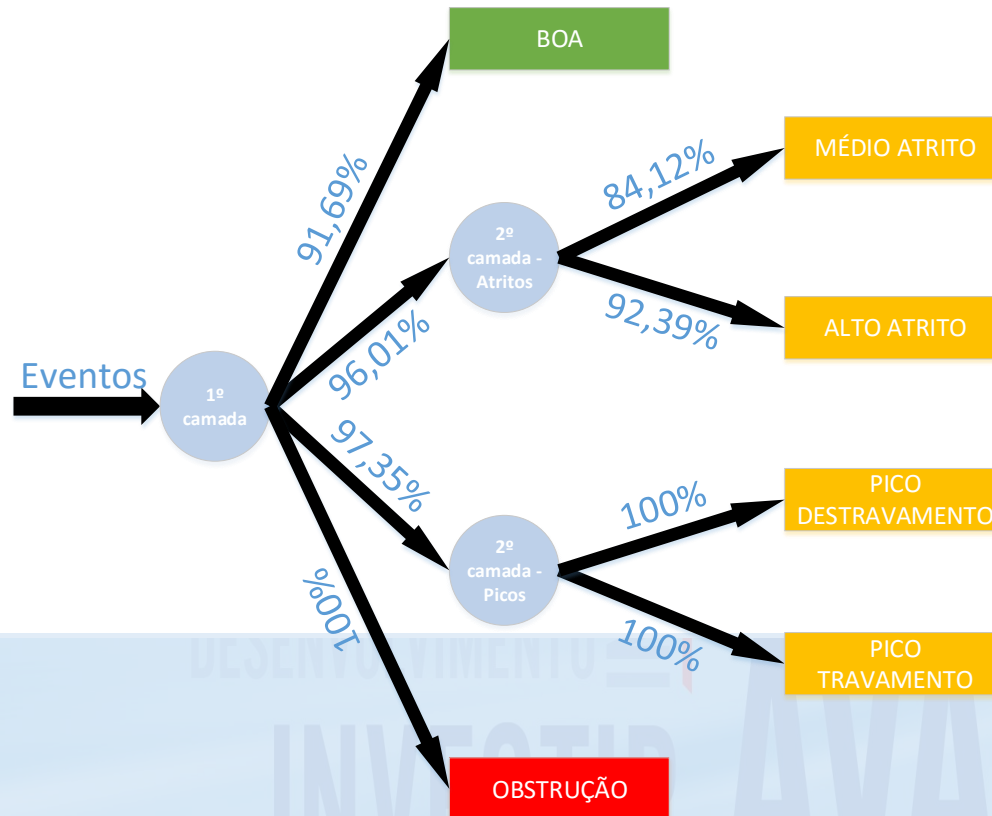
100

100

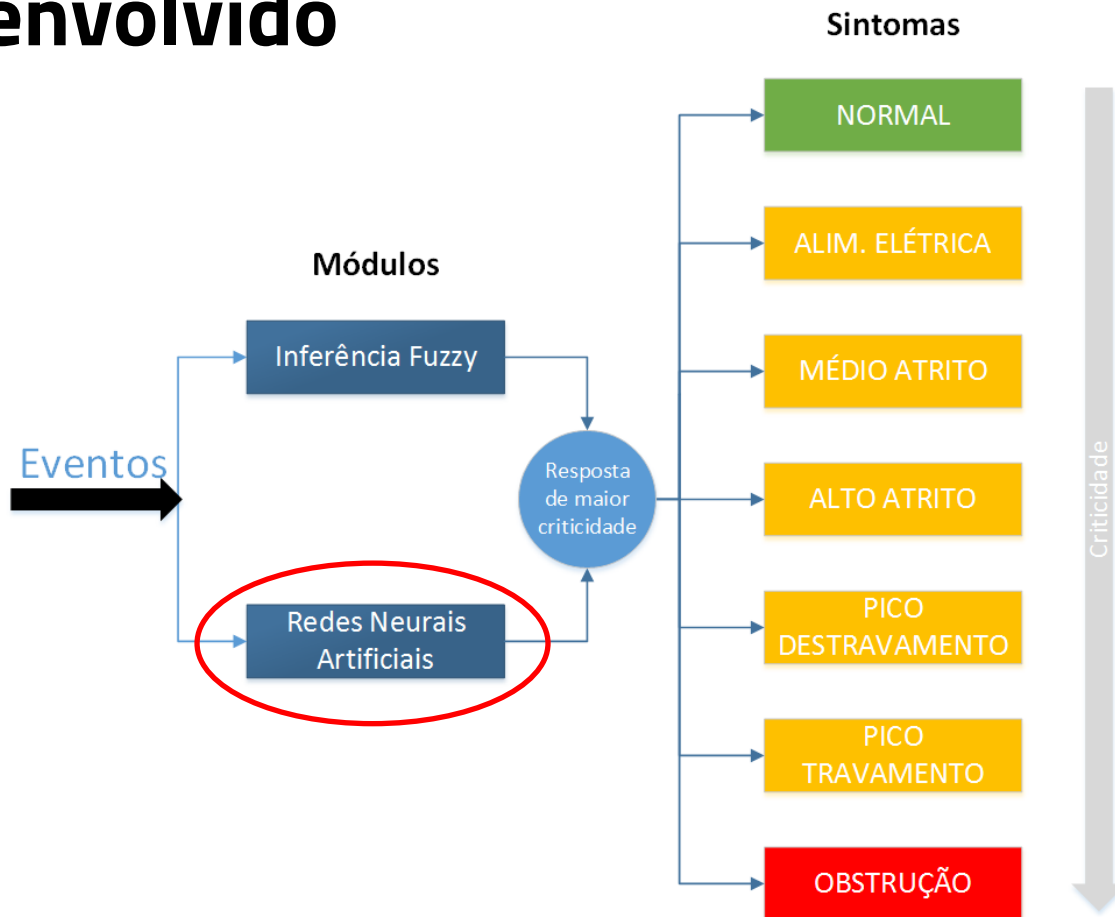
Resultados Obtidos – Módulo Fuzzy

Resumo

- Pode-se considerar que a probabilidade de acerto do modo de falha agregado é a multiplicação dos percentuais das camadas

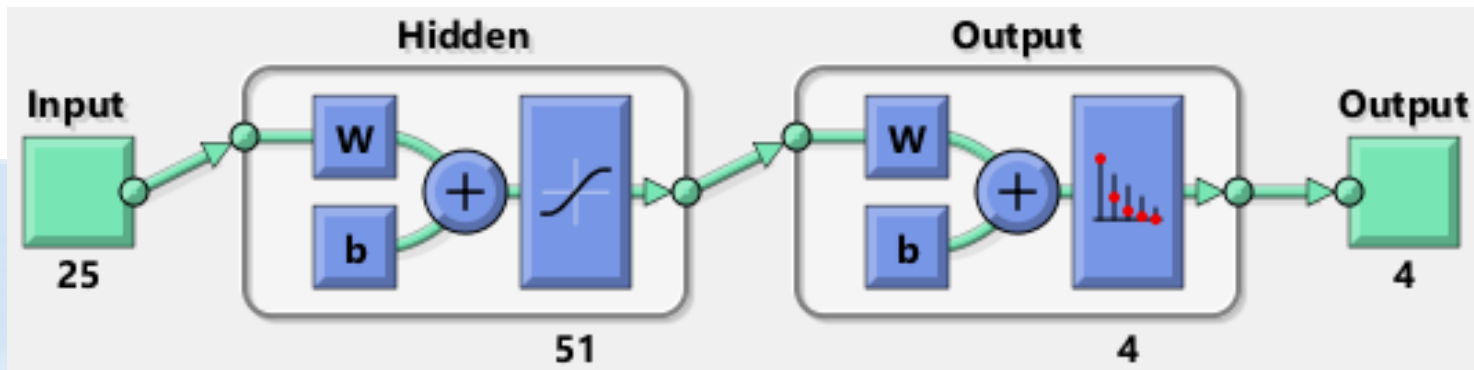


Sistema híbrido de inteligência artificial desenvolvido

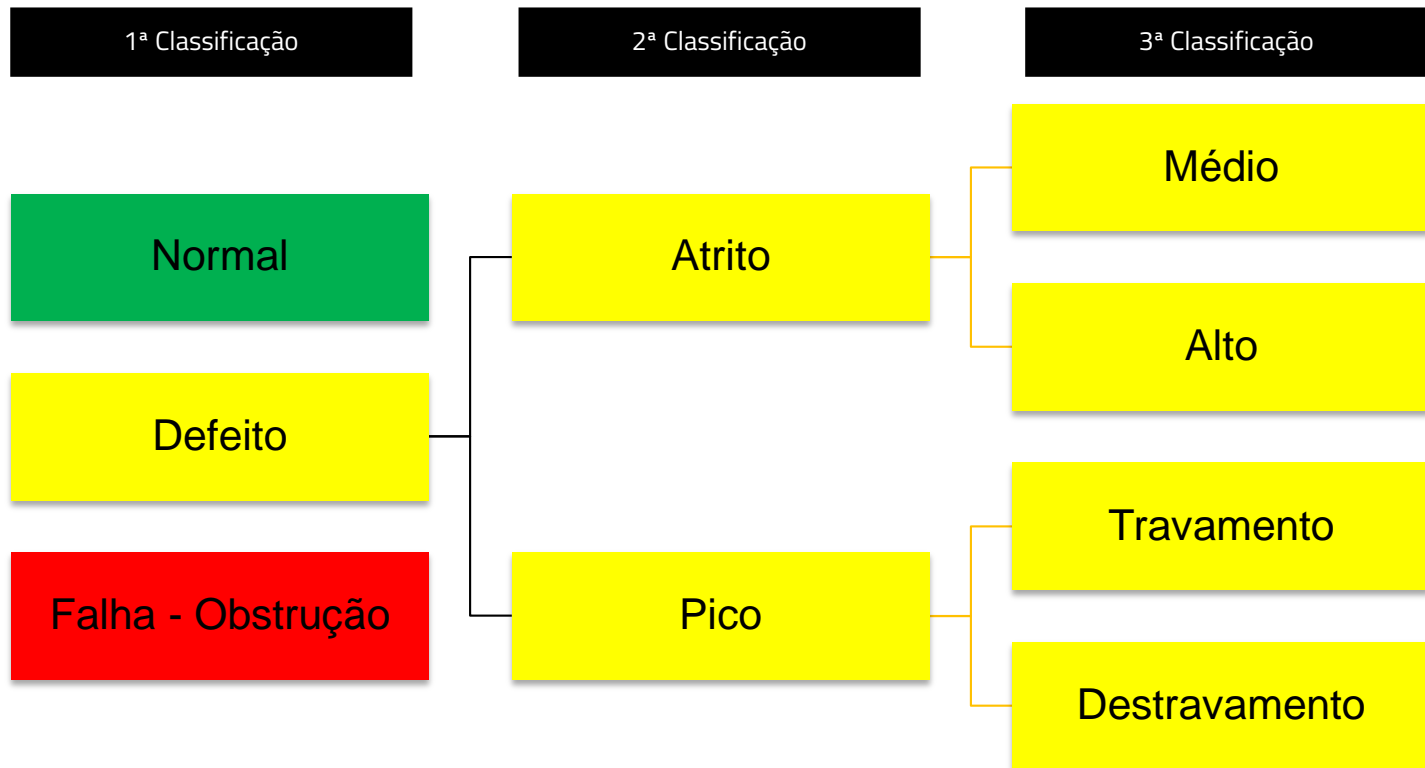


RNA – Rede Neural Artificial


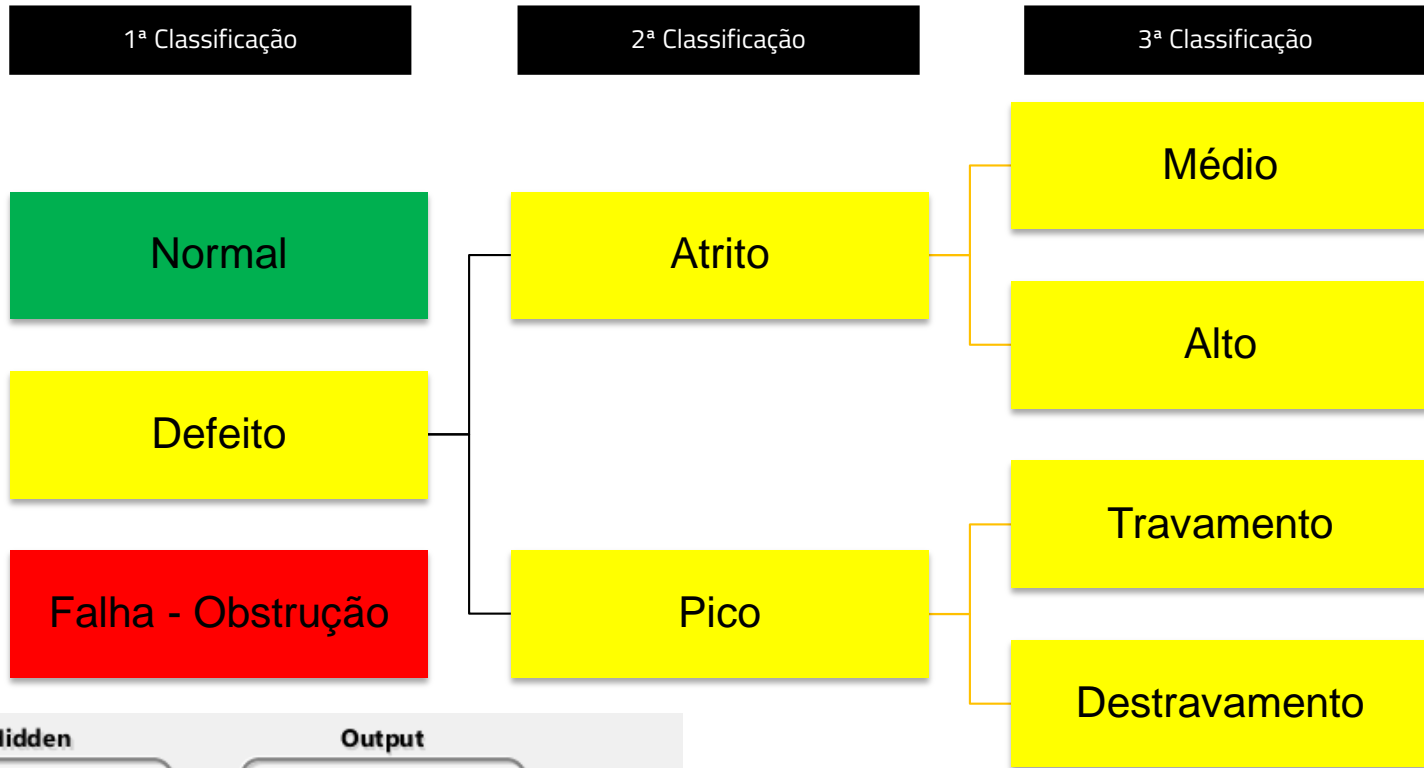
- Redes neurais possuem ampla capacidade de reconhecimento de padrões
- Podem trabalhar com grande volume de entradas e dados. No caso, as entradas são todas as métricas coletadas
- Principais características:
 - Feed-foward de duas camadas
 - Função de ativação do tipo Sigmóide
 - Definição do número de neurônios pelo método Kolmogorov




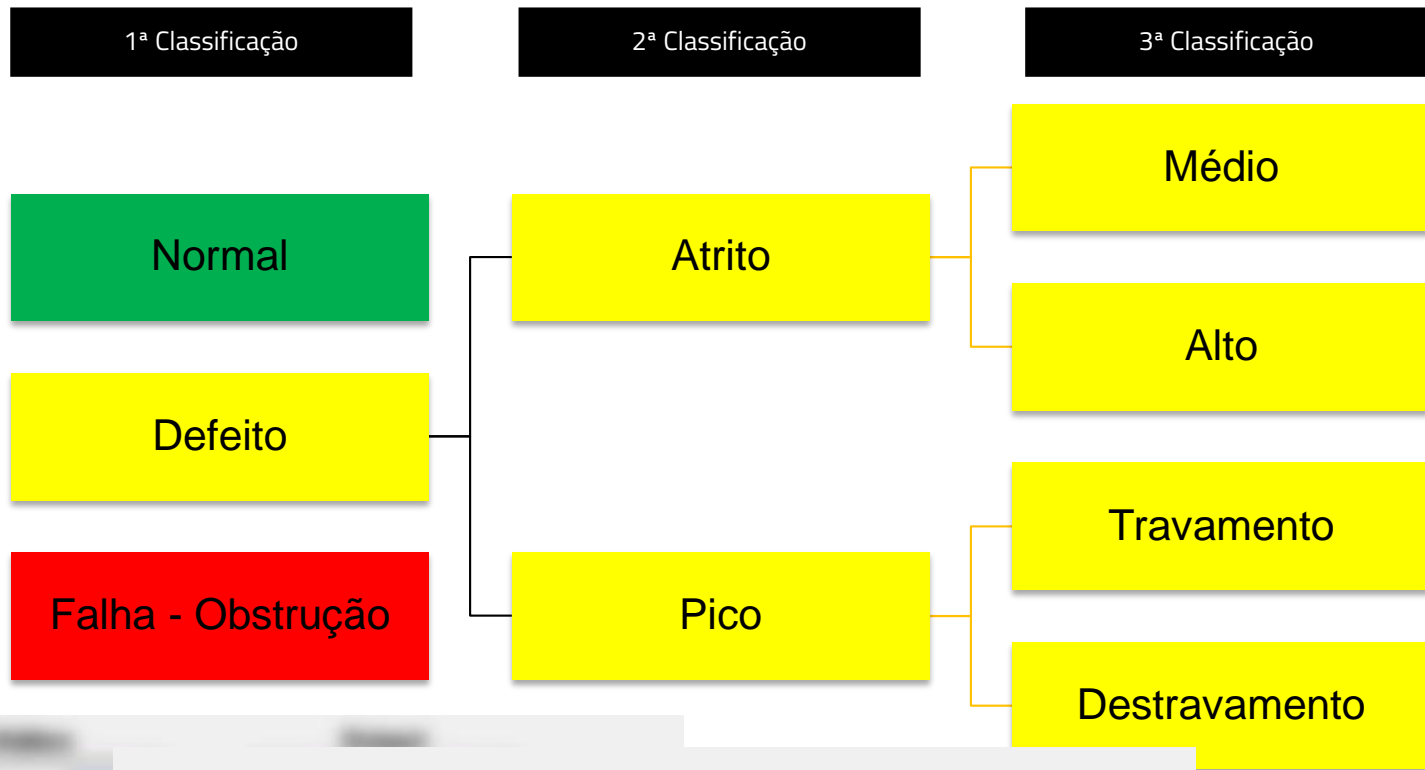
RNA – 3 Etapas de Classificação




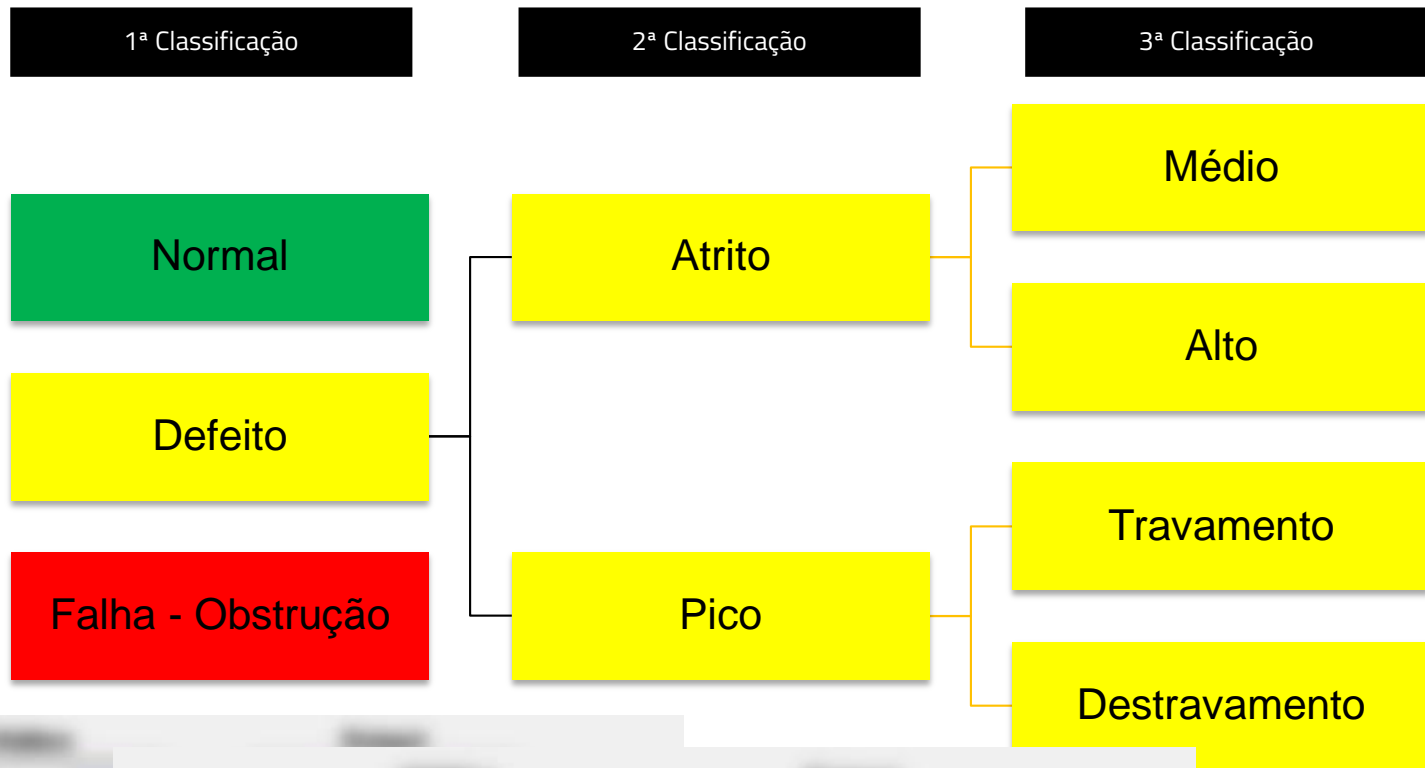
RNA – 3 Etapas de Classificação



RNA – 3 Etapas de Classificação



RNA – 3 Etapas de Classificação



RNA – 3 Etapas Classificação

Matriz de confusão – 1ª Etapa de Classificação

Training Confusion Matrix

Output Class \ Target Class	1	2	3	Accuracy
1	297 32.8%	20 2.2%	0 0.0%	93.7% 6.3%
2	24 2.7%	551 60.9%	0 0.0%	95.8% 4.2%
3	0 0.0%	0 0.0%	13 1.4%	100% 0.0%
Overall	92.5% 7.5%	96.5% 3.5%	100% 0.0%	95.1% 4.9%

Validation Confusion Matrix

Output Class \ Target Class	1	2	3	Accuracy
1	56 28.9%	7 3.6%	0 0.0%	88.9% 11.1%
2	4 2.1%	125 64.4%	0 0.0%	96.9% 3.1%
3	0 0.0%	0 0.0%	2 1.0%	100% 0.0%
Overall	93.3% 6.7%	94.7% 5.3%	100% 0.0%	94.3% 5.7%

Test Confusion Matrix

Output Class \ Target Class	1	2	3	Accuracy
1	65 33.5%	7 3.6%	0 0.0%	90.3% 9.7%
2	5 2.6%	113 58.2%	0 0.0%	95.8% 4.2%
3	0 0.0%	0 0.0%	4 2.1%	100% 0.0%
Overall	92.9% 7.1%	94.2% 5.8%	100% 0.0%	93.8% 6.2%

All Confusion Matrix

Output Class \ Target Class	1	2	3	Accuracy
1	418 32.3%	34 2.6%	0 0.0%	92.5% 7.5%
2	33 2.6%	789 61.0%	0 0.0%	96.0% 4.0%
3	0 0.0%	0 0.0%	19 1.5%	100% 0.0%
Overall	92.7% 7.3%	95.9% 4.1%	100% 0.0%	94.8% 5.2%

RNA – 3 Etapas Classificação

Matriz de confusão – 2ª Etapa de Classificação (Defeitos – Atrito ou Pico de corrente)

Training Confusion Matrix

Output Class	1	439 76.1%	4 0.7%	99.1% 0.9%
	2	0 0.0%	134 23.2%	100% 0.0%
		100% 0.0%	97.1% 2.9%	99.3% 0.7%
		1	2	
		Target Class		

Validation Confusion Matrix

Output Class	1	91 74.0%	2 1.6%	97.8% 2.2%
	2	0 0.0%	30 24.4%	100% 0.0%
		100% 0.0%	93.8% 6.3%	98.4% 1.6%
		1	2	
		Target Class		

Test Confusion Matrix


Output Class	1	86 69.9%	3 2.4%	96.6% 3.4%
	2	0 0.0%	34 27.6%	100% 0.0%
		100% 0.0%	91.9% 8.1%	97.6% 2.4%
		1	2	
		Target Class		

All Confusion Matrix

Output Class	1	616 74.8%	9 1.1%	98.6% 1.4%
	2	0 0.0%	198 24.1%	100% 0.0%
		100% 0.0%	95.7% 4.3%	98.9% 1.1%
		1	2	
		Target Class		

RNA – 3 Etapas Classificação

Matriz de confusão – 3ª
Etapa de Classificação
(Atrito)



RNA – 3 Etapas Classificação

Matriz de confusão – 3ª
Etapa de Classificação
(Picos de corrente)

Training Confusion Matrix

Output Class	1	30 19.0%	0 0.0%	100% 0.0%
	2	0 0.0%	128 81.0%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%
		1	2	
		Target Class		

Validation Confusion Matrix

Output Class	1	6 17.6%	0 0.0%	100% 0.0%
	2	0 0.0%	28 82.4%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%
		1	2	
		Target Class		

Test Confusion Matrix

Output Class	1	8 23.5%	0 0.0%	100% 0.0%
	2	0 0.0%	26 76.5%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%
		1	2	
		Target Class		

All Confusion Matrix

Output Class	1	44 19.5%	0 0.0%	100% 0.0%
	2	0 0.0%	182 80.5%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%
		1	2	
		Target Class		

RNA – 3 Etapas Classificação

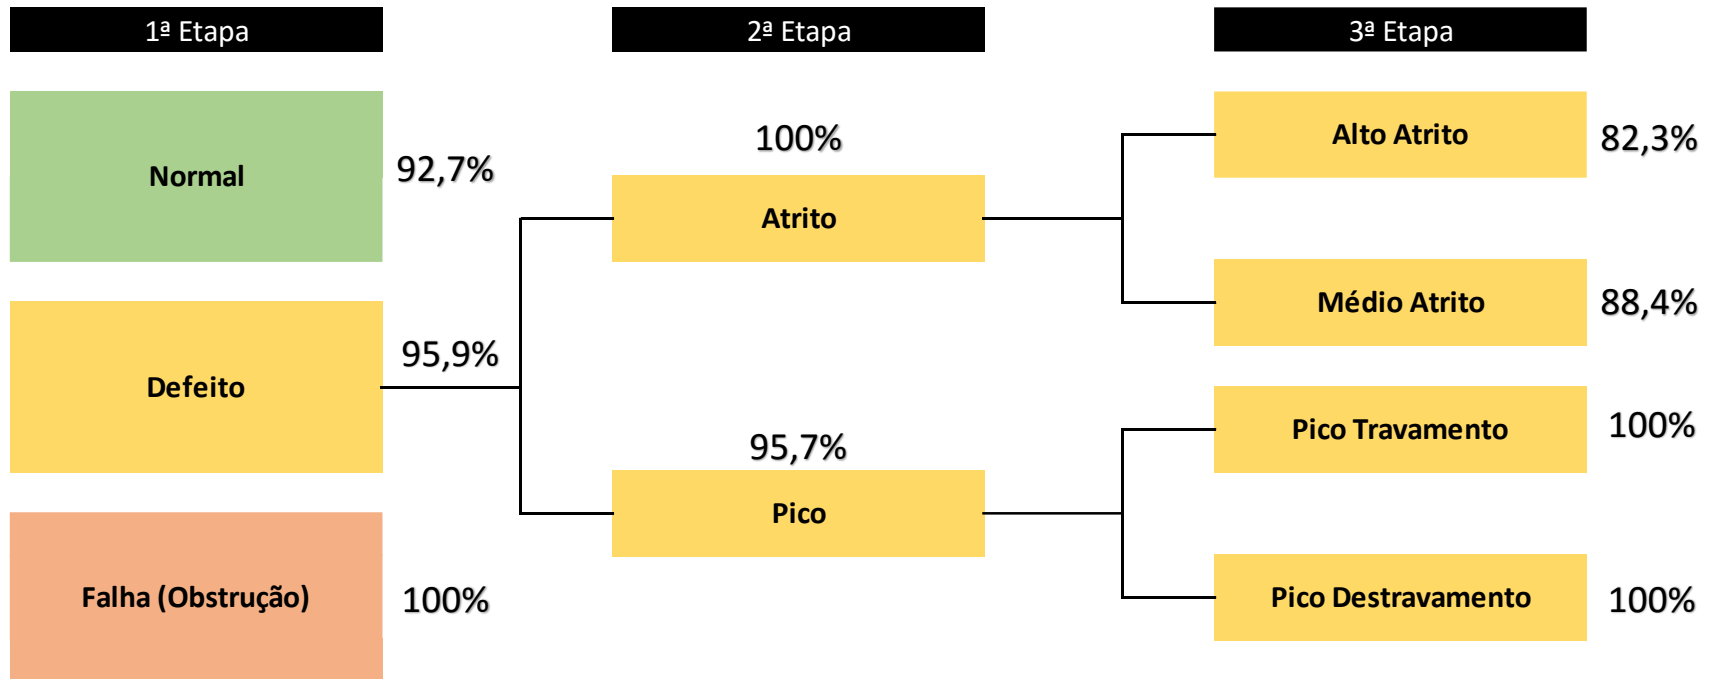
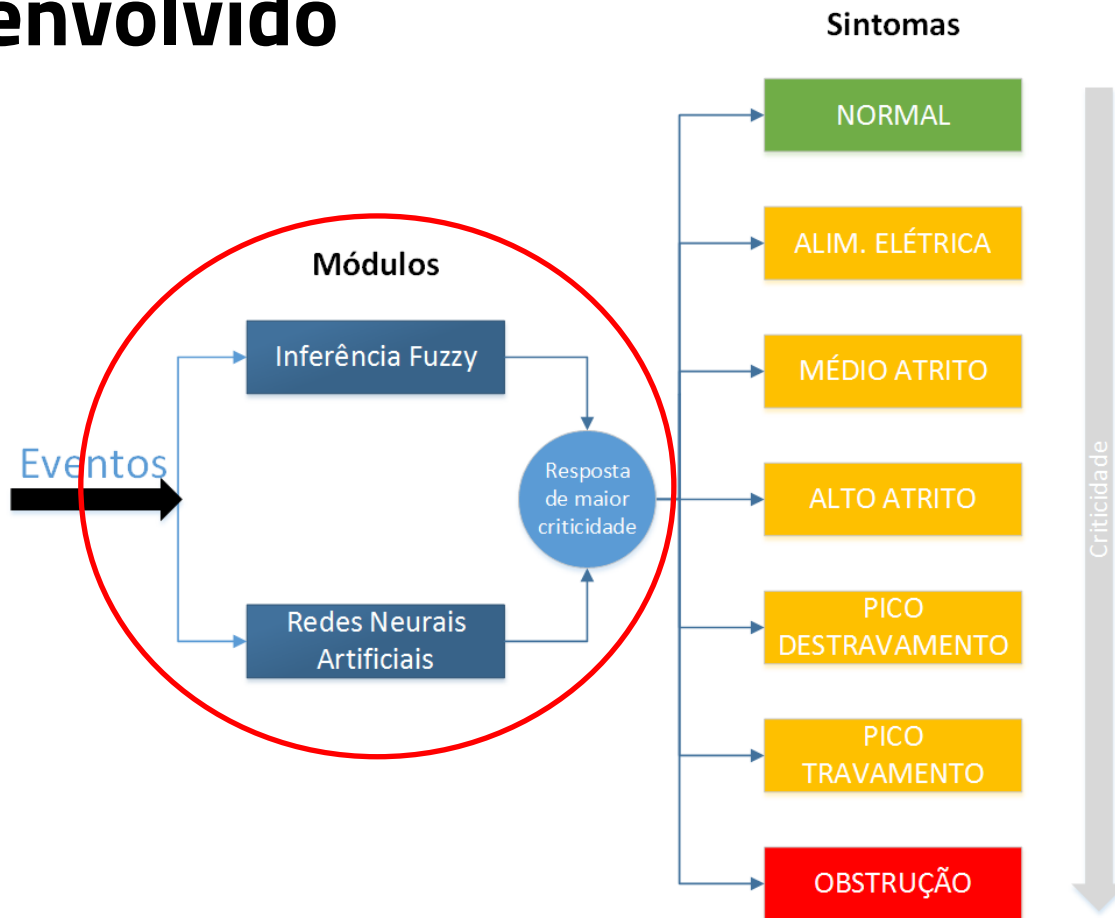


Diagrama resumo treinamento 3 etapas

Sistema híbrido de inteligência artificial desenvolvido



Resultados sistema híbrido

Nível de resposta - Estado da máquina

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

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

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 possível, é necessário dividir a curva de corrente da máquina de chave em fases.
- 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.
- Proporcionará às equipes de manutenção mais informações nos atendimentos as ocorrências com o nível de acerto superior a 90%.
- É importante observar que o método conseguiu separar com 100% de certeza a falha da MCH, o que trará um grande ganho à manutenção e operação desse equipamento.

Trabalhos Futuros

- Um próximo passo importante a ampliação do conhecimento dos modos de falha, é a instalação do sistema em outros pontos da ferrovia.
- Aplicar o sistema desenvolvido para os demais modelos de máquinas de chave
- O desenvolvimento de uma arquitetura com custo ainda mais acessível

Referências

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.

MÁRQUEZ, Fausto P. G.; SCHMID, Felix; COLLADO, Javier C. [Wear assessment employing remote condition monitoring: a case study](#). **Wear**, v. 255, n. 7–12, , p.1209-1220, August–September 2003.

MÁRQUEZ, Fausto P. G.; SCHMID, Felix; TERCERO, DIEGO J. P.; [Unobserved Component models applied to the assessment of wear in railway points: A case study](#). **European Journal of Operational Research**, v.176, n.3, p.1703-1712, 1 February 2007.

NAKAMURA, K., 1992. [Tentetsu Souchi \[The point machine\]](#). **Japan Railway Electrical Engineering Association**.

Desenvolvimento de sistema automático de identificação de modos de falhas em máquinas de chave utilizando inteligência artificial

Gustavo Moreira - gustavo.moreira@vale.com

Guilherme Miranda Kallembach – guilherme.kallembach@vale.com

Wallison Barbosa – wallison.barbosa@vale.com

22ª Semana de Tecnologia Metroferroviária

