

CATEGORIA (3)

ANÁLISE CLASSIFICATÓRIA DOS ALARMES DE WAYSIDE COM ABORDAGEM POR SISTEMA DE INFERÊNCIA NEURO-FUZZY ADAPTATIVA

INTRODUÇÃO

O trabalho constitui em um ensaio realizado para a aplicação ferroviária de um sistema híbrido entre Lógica Fuzzy Tipo-1 baseado no modelo Takagi-Sugeno e redes neurais artificiais (ANN). Dentre os tipos de modelos híbridos, foi escolhido o modelo ANFIS (Adaptative Neuro-Fuzzy Inference System) que tem como proposta classificar as condições dos alarmes dos sensores térmicos dos sistemas Hot Box Detector (HBD) e Hot Wheel Detector (HWD) que registram, respectivamente, a temperatura dos rolamentos e rodas dos vagões através da radiação infravermelha emitida pelos mesmos. Mediante o entendimento do processo de monitoramento dinâmico do material rodante, a fim de garantir maior assertividade na gestão dos processos de

manutenção, busca-se evitar riscos operacionais que estejam associados à interpretação de um operador responsável pela integridade do ativo pela perspectiva do Centro de Controle da Manutenção (CCM) e que possa ocasionar um descarrilamento, como as fraturas de rodas e degola de eixos. Baseada nessa prerrogativa, o trabalho aborda uma estratégia focada em lógica fuzzy devido ao fator semântico implicado nas análises de temperatura relativa e absoluta que muitas das vezes se torna dúvida mediante interpretação do analisador responsável, pelo fato de alguns desses alarmes apresentarem características de distinção complexas a primeira vista.

Atualmente, segundo informações da ANTF (Associação Nacional dos Transportadores Ferroviário), houve um aumento de 25,5% em toneladas úteis (TU) de cargas transportadas pelas ferrovias brasileiras na última década. Só em 2016 foram 503,8 milhões de TU transportadas, sendo esse o maior volume registrado na última década [1, 2]. Para uma logística nesses moldes, no atendimento do volume contratado se torna primordial que estratégias de otimização da manutenção sejam adotadas, promovendo maior disponibilidade e confiabilidade dos equipamentos e instalações, a fim de atender as expectativas, com custos adequados, segurança operacional e preservando o meio ambiente [3-5]. Segundo a NBR ISO 5462 da ABNT, manutenção é a combinação de todas as ações destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida. Nota-se, que qualquer esforço voltado para conservar ou reparar a condição de determinado ativo para desempenhar dada função é considerado uma manutenção, entretanto, a forma como é realizada a intervenção é que determina o tipo de manutenção empregada. A

manutenção corretiva, por exemplo, requer intervenção imediata para permitir que o equipamento comprometido por uma falha retome seu funcionamento, enquanto que a manutenção baseada na condição se trata de uma ação oportunista em agir preventivamente a uma falha ou defeito, a partir de determinadas condições operacionais e demais indicadores do ativo que possam indicar uma tendência de comprometimento parcial ou total de seus componentes [7-9]. A adoção da manutenção baseada na condição proporciona grandes vantagens, no entanto se faz necessária a estruturação de um plano de manutenção eficaz, tecnologias e equipamentos sofisticados, além de profissionais altamente preparados para fazer as análises e intervenções com qualidade nos menores tempos possíveis. Também se torna necessário que o componente possua alguma característica que viabilize o monitoramento sistêmico para análise e diagnóstico de uma possível anomalia ou redução do desempenho requerido. Um dos recursos utilizados para manutenção preditiva do setor ferroviário são os waysides, equipamentos de apoio operacional instalados ao longo da malha ferroviária para monitoramento dinâmico de determinados componentes dos trens, garantindo segurança operacional e melhorando a gestão dos ativos através da manutenção preditiva. Neste trabalho abordaremos superficialmente dois tipos de waysides: Hot Box Detector e Hot Wheel Detector Figura 1 e Figura 2, sendo que para o último foi conduzido um ensaio analítico da abordagem de inteligência computacional para auxílio na classificação do status do ativo [6, 10]. Os parâmetros segundo cada tipo de equipamento, suas condições de alarme e respectivo tipo de intervenção podem ser visualizados na Tabela 1 a seguir:




Figura 1 - Esquemático de instalação HBD. Fonte:[10].




Figura 2 - Esquemático de instalação HWD. Fonte: [10].

Tabela 1 - Equipamento, suas respectivas condições e os tipos de intervenção segundo análise especialista.

Equipamento	Condição	Tipo de intervenção	T[°C]
Hot Box	Alarme de Tendência	Programada	> 40
Alarme Diferencial (HBD)	Imediata	Intervenção conforme procedimento interno.	> 40 entre os lados / >55 absoluto
Alarme Absoluto	Imediata	Intervenção conforme procedimento interno	HBD > 70 / HWD > 200
Alarme Saturação	Interferência Externa	Programada	Máx. (fundo de escala) HBD > 140 / HWD > 520
Hot Wheel (Alarme Falso)	Diferença entre as médias (Trem Vazio)	Imediata	> 15
Hot Wheel (Alarme Falso)	Diferença entre as médias (Trem Carregado)	Imediata	> 20

DIAGNÓSTICO

A Teoria de Conjuntos Fuzzy foi concebida por L.A. Zadeh a com o objetivo de fornecer um ferramental matemático para o tratamento de informações de caráter impreciso ou vago. A lógica fuzzy, baseada nessa teoria, foi inicialmente construída a partir dos conceitos já estabelecidos de lógica clássica com a definição de alguns operadores semelhantes aos tradicionalmente utilizados, muitas vezes por necessidades de caráter eminentemente prático [11-13].

Os conceitos de lógica fuzzy permitem capturar em termos matemáticos as informações imprecisas, descrita por um conjunto de regras linguísticas e converter a semântica para um formato numérico. Se um operador humano for capaz de articular sua estratégia de ação como um conjunto de regras da forma conectiva “se... então...”, o resultado é um sistema de inferência baseado em regras, no qual a Teoria de Conjuntos Fuzzy e lógica fuzzy fornecem o ferramental matemático para se lidar com as mesmas, embora modificações tenham se tornado necessário para adaptá-los aos requisitos de aplicações diversas em engenharia [14-16].

As primeiras aplicações bem sucedidas situaram-se nas áreas que envolvem Teoria de Controle, mas desde então, tem-se verificado uma utilização crescente de sistemas fuzzy em outros campos, como por exemplo, classificação, previsão de séries temporais, mineração de dados, planejamento e otimização de sistemas [15, 16]. O uso conjunto da lógica fuzzy e de outros sistemas computacionais têm propiciado a construção de sistemas híbridos, cuja capacidade de aprendizado tem se destacado na inteligência artificial aplicada [11-16].

Este trabalho utiliza dos fundamentos de redes neurais artificiais, conjuntos fuzzy e de lógica fuzzy, para suporte à tomada de decisão em processos de manutenção, assim como as definições operacionais que permitem abordar os mecanismos de inferência servindo de suporte para o raciocínio do nível de risco de ocorrência de anomalias.

A estrutura que compõe o sistema de lógica fuzzy e que será detalhado neste trabalho, pode ser dividido em 3 segmentos: Fuzzificação, Regras de Inferência e Defuzzificação.

A Figura 3 ilustra resumidamente essas regras a seguir:

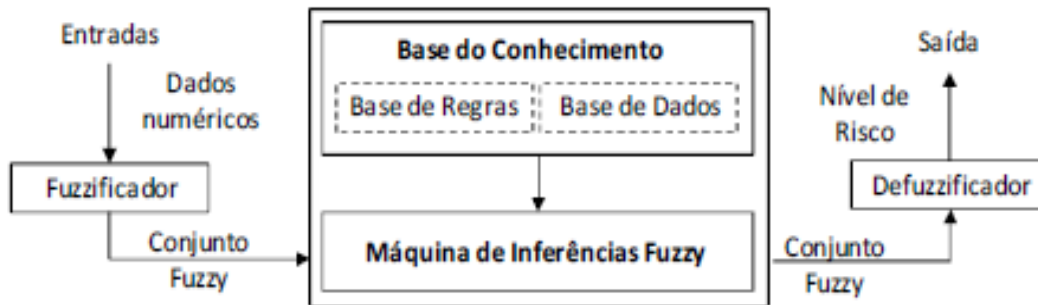


Figura 3 - Esquemático de instalação HWD. Adaptado da fonte em [13].

1. Conjuntos Fuzzy & Fuzzificação

Na teoria clássica dos conjuntos, o conceito de pertinência de um elemento a um conjunto fica definido de forma binomial, ou seja, dado um conjunto A em um universo X, os elementos deste universo simplesmente podem pertencer ou não pertencer àquele conjunto [11-16]. Esta característica pode ser expressa pela equação (1) a seguir:

$$f_A = \begin{cases} 1 & \text{se e somente se } X \in A \\ 0 & \text{se e somente se } X \notin A \end{cases} \quad (1)$$

Segundo a teoria de lógica fuzzy proposta por Zadeh fica definida uma caracterização mais ampla em que cada conjunto fuzzy está associado a uma variável linguística que nomeia as condições numéricas associadas, como a temperatura neste exemplo, generalizando a função característica de modo que ela pudesse assumir um número infinito de valores no intervalo {0; 1} que representem o grau de pertinência de um elemento a este ou a outros determinados conjuntos em específico e de forma

simultânea [11-16]. Um conjunto fuzzy A em um universo X definido pelas funções de pertinência é representado por um conjunto de pares ordenado segundo (2) e (3) a seguir, compondo assim um sistema de característica MISO (Multiple Input, Single Output):

$$\mu_A(x): X \rightarrow [0,1], \quad A = \{\mu_A(x)/x\} \quad x \in X \quad (2)$$

$$f_{A_i} = \begin{cases} X_i \in B, & \text{se } x_i \in A \\ 0, & \text{caso contrário} \end{cases} \quad (3)$$

Onde:

$\mu_A(x)$	Indicação do quanto x é compatível com o conjunto A;
x_i	Variável linguística do antecedente (entrada do sistema);
X_i	Variável do consequente (saída do sistema);

Assim como um determinado elemento pode pertencer a mais de um conjunto fuzzy, com diferentes graus de pertinência, as funções de pertinência podem ter diferentes formas associadas aos termos (Hedges) dependendo do conceito que se deseja representar e do contexto em que serão utilizadas [12-15]. No caso contínuo, a função de pertinência é uma função matemática, podendo ser representada pelas funções triangular, trapezoidal, gaussiana, sino generalizada, sigmoid, entre outras. A função de pertinência também é caracterizada pela relação de uma variável linguística, por exemplo, os conjuntos/listas de idades para jovem, adulto, idoso ou nível de pH de uma amostra. Neste trabalho foi escolhido como função de pertinência para representar os termos Hedges dos waysides grupos de gaussianas de pertinência, sendo as suas variáveis linguísticas associadas para as classificações de Rodeiro OK,

Rodeiro NOK, Sensor Defeituoso e Alarme de Tendência por opção de abordagem especialista como ilustrado na Figura 4 a seguir:




Figura 4 - Funções de Pertinência segundo valor de temperatura por rodeiro. Fonte: Python.

2. Composição de Relações, Conjunto de Regras Fuzzy & Sistema de Inferência

A composição de relações representa um papel muito importante em sistemas de inferência fuzzy. A base de regras do sistema foi composta pelas condições de contorno na Tabela 1 em conjunto com outras séries de condições operacionais estipuladas pelos especialistas ferroviários atualmente em prática na companhia. A operação realizada para se associar dois conjuntos pode ser representada pela t-norma segundo o produto algébrico ou pela s-norma segundo o somatório algébrico [13-16]. Dois desses tipos de composição podem ser representados por (4) e (5) a seguir:

Composição max-min:

(4)

$$f(x, z) = \{(x, z), \max [\min(f(x, y), f(y, z))]\}$$

Composição max-produto:

(5)

$$f(x, z) = \{(x, z), \max [(f(x, y) \cdot f(y, z))]\}$$

Apesar de (5) possuir ampla aplicação na literatura, para este trabalho o método escolhido para ser empregado no modelo se trata da composição do máximo-mínimo por razões de topologia da rede neuro-fuzzy. A metodologia da **Composição max-min** é composta da intersecção entre a área máxima construída a partir das constantes de corte do eixo das ordenadas com as gaussianas das funções de pertinência e desprezando as áreas formadas pelas constantes de corte mínimas, como poderá ser compreendido de forma mais detalhada na próxima seção na Figuras 9 e Figura 10.

3. Defuzzificação

A defuzzificação é utilizada para fornecer um valor numérico de saída dos sistemas fuzzy, obtido a partir dos valores de pertinência ao conjunto fuzzy de saída. O processo de defuzzificação é amplamente utilizado em sistemas fuzzy de controle, aonde são obtidos os valores de ajuste correspondentes às entradas do sistema [13-15]. Na aplicação de um método de defuzzificação é necessário que a função de pertinência do conjunto de saída esteja matematicamente definida para modelos Mamdani ou a

função polinomial para modelos Sugeno, como no caso representado por este estudo [11-15].

Existem vários métodos de desfuzzificação e a seleção de um deles é dependente do domínio da aplicação em desenvolvimento, os métodos mais utilizados e que foram escolhidos para representar este estudo, se trata do Método do Centro de Massa (Centroid) e do Máximo dos Máximos (MoM) [11-15]. Por estes métodos, o valor numérico obtido representa o centro de gravidade da área que compreende uma ou o conjunto de mais de uma distribuição de probabilidade e da distribuição de probabilidade definida pelo ponto de máxima amplitude, respectivamente, na saída do sistema fuzzy.

O modelo de inteligência computacional explorado por lógica fuzzy para análises classificatórias se mostra uma metodologia madura, entretanto para que possa gerar valor ao Centro de Controle de Manutenção (CCM), este modelo constituído somente por lógica fuzzy carece de qualidade adaptativa mediante a geração e coleta de novos dados operacionais em diferentes regiões da ferrovia que apresentem de forma peculiar condições climáticas adversas entre si. Para tal, utiliza-se a hibridização com redes neurais artificiais (ANN) do tipo Perceptron de Multi Camadas (MLP) para garantir o aspecto adaptativo do sistema fuzzy. Essa metodologia híbrida empregada no processo de treinamento para futuras classificações de alarmes de waysides se trata do modelo ANFIS (Sistema de Inferência Neuro-Fuzzy Adaptativa), por se tratar de um sistema híbrido que alia o benefício das variáveis linguísticas dos sistemas nebulosos com o valor agregado de habilidades de aprendizado de redes neurais [17].

Neste caso em específico a estrutura dos neurônios (perceptrons) atua na adaptação direta dos parâmetros das funções de pertinência de modo que não haja uma grande dependência do conhecimento exclusivo do especialista na calibração dos conjuntos nebulosos [18-22]. A Figura 5 a seguir ilustra a topologia do modelo ANFIS abordado neste trabalho, sendo que para o processo de treinamento a função de ativação em N_i na rede neural é composta pelas funções de pertinência do sistema de inferência fuzzy:

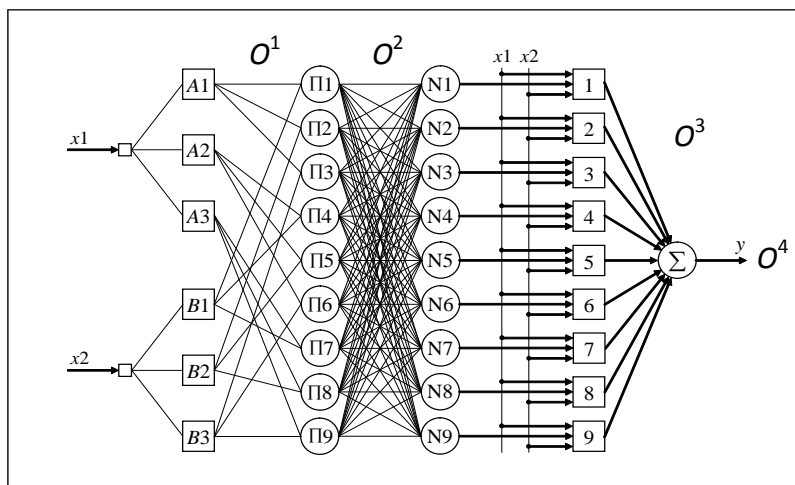


Figura 5 - Topologia rede ANFIS. Fonte: [22].

A rede em questão apresenta duas entradas (x_1 e x_2) representando os rodas/rolamentos direito e esquerdo com três funções de pertinência cada (A_1 , A_2 , A_3 , B_1 , B_2 e B_3) relativas as funções de pertinência para os níveis de temperatura baixo, médio e alto de cada lado do ativo, respectivamente. A entrada é propagada até a camada 4 onde os parâmetros do consequente são determinados através do método dos mínimos quadrados (treinamento linear) em O^4 e em seguida é realizada a retropropagação, a partir dos erros entre a saída (classificação y) e os dados de treinamento cuja classificação já é conhecida. Com a retropropagação, os parâmetros

dos antecedentes são ajustados pelo método do gradiente descendente de modo a atualizar as características das gaussianas de cada função de pertinência de acordo com os dados já classificados e validados por checagem técnica do equipamento real [22-25]. As equações que regem cada camada do modelo segundo o índice k em cada uma das entradas O^k do modelo podem ser compreendidas em (6)-(10) a seguir:

$$O_{A,i}^1 = \mu_{A,i}(x1), \quad i = 1, 2, 3 \quad (6)$$

$$O_{B,i}^1 = \mu_{B,i}(x2),$$

$$O_i^2 = w_i = \mu_{A,i}(x1) \cdot \mu_{B,i}(x2), \quad i = 1, 2, \dots, 9 \quad (7)$$

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_{n=1}^N w_n}, \quad i = 1, 2, \dots, 9 \quad \text{e} \quad N = 9 \quad (8)$$

$$O_i^4 = y = \bar{w}_i (p_i x1 + q_i x2 + r_i), \quad i = 1, 2, \dots, 9 \quad (9)$$

$$O_i^5 = y = \sum_{i=1}^N \bar{w}_i f_i, \quad i = 1, 2, \dots, 9 \quad \text{e} \quad N = 9 \quad (10)$$

ANÁLISE DOS RESULTADOS

A partir da teoria abordada no tópico anterior, os testes foram conduzidos com dados operacionais de equipamentos em campo e não proveniente de uma giga de testes. Tais dados formam um universo com mais de 5000 amostras que compreendem situações ideais de operação, ou seja, quando não há alarmes de integridade; situações em que houve comprometimento do material rodante (tanto para rodeiros quanto para rolamentos); e situações de falso positivo, onde apesar de haver alarme

de integridade do material rodante, o mesmo se encontrava em boas condições, registrando assim irregularidade nos sensores responsáveis pelas respectivas coletas (interferência externa do sol, desalinhamento, pirômetro descalibrado, entre outros). A seguir, pode ser visualiza na Figura 6 o exemplos desse perfil de temperatura de rodeiros por eixo de acordo com o gráfico de dispersão de cada vagão em uma determinada composição, enquanto que na Figura 7 o raciocínio se estende de forma análoga, porém para rolamentos:

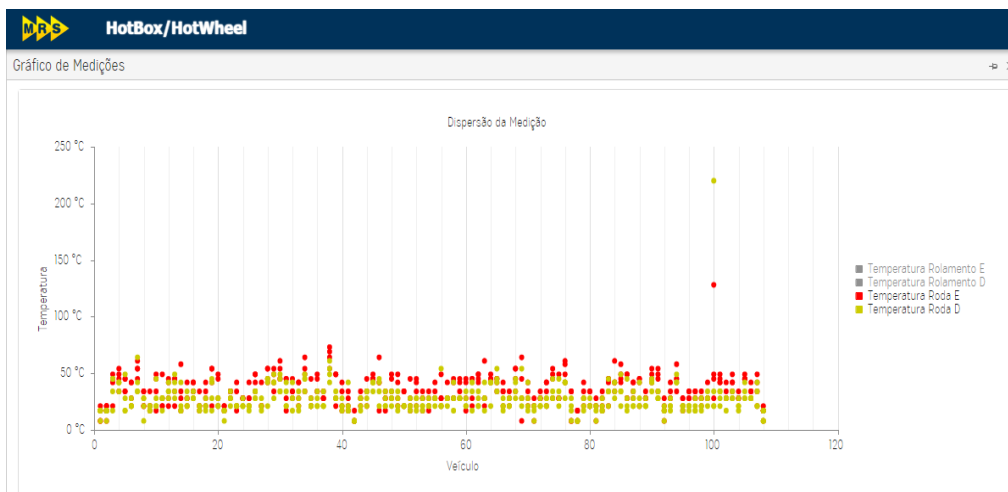


Figura 6 - Gráfico de dispersão do HWD para uma composição específica. Fonte: Sistema Automaweb.

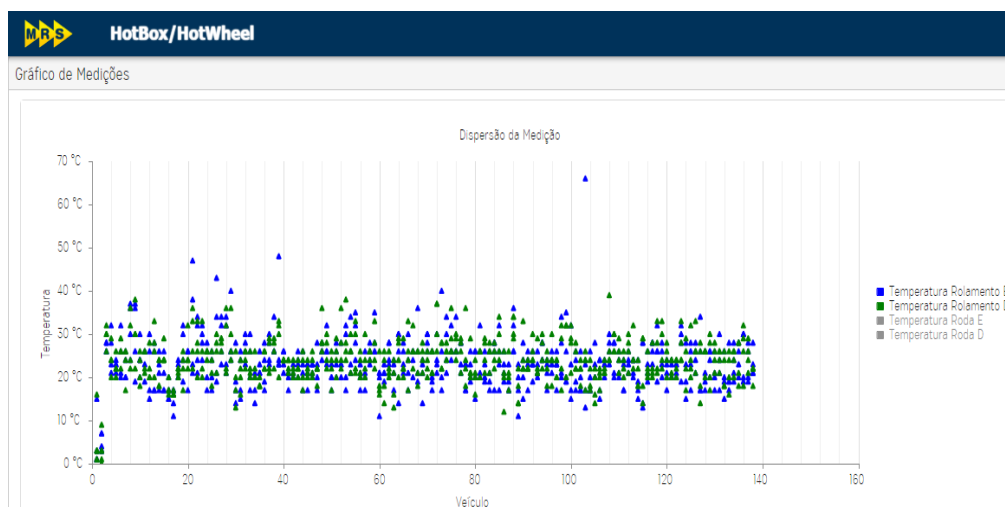


Figura 7 - Gráfico de dispersão do HBD para uma composição específica. Fonte: Sistema Automaweb.

O desenvolvimento do algoritmo de análise computacional em ANFIS foi construído da adaptação do modelo “Adaptative Neurofuzzy” de implementação permissiva em software livres pelo MIT (Massachusetts Institute of Technology) no ambiente Anaconda pela linguagem de programação em Python [27, 28]. A partir deste algoritmo as funções de pertinência das temperaturas para os lados direito e esquerdo do par de componente por eixo de vagão apresentados anteriormente na Figura 4, podem ser atualizadas em novas configurações compreendidas na Figura 8 a seguir:

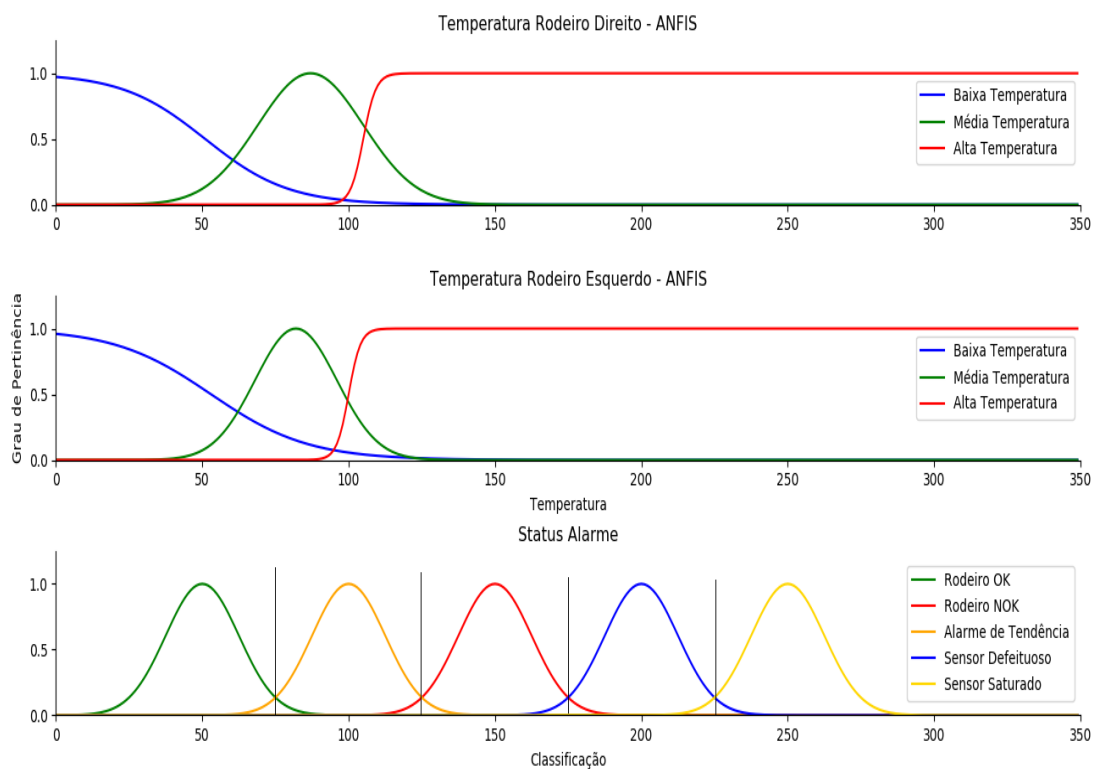


Figura 8 - Funções de Pertinência segundo valor de temperatura por rodeiro reajustados dos dados treinados pela rede ANFIS. Fonte: Python.

As medidas de temperatura do ativo no par de lados esquerdo e direito são estabelecidas como as entradas do sistema de inferência fuzzy segundo o eixo das abscissas e o ponto de intersecção com as gaussianas de cada função de pertinência

(baixa, média e alta temperatura) representará o valor da pertinência desta determinada temperatura de entrada no eixo das ordenadas de acordo com cada intervalo das gaussianas nos dois primeiros gráficos da Figura 8 ilustrada anteriormente. Em seguida, esses valores cruzados com o eixo das ordenadas são utilizados para parametrizar as constantes de corte para cada gaussiana de classificação no 3º gráfico da Figura 8. Uma vez estabelecidos esses cruzamentos com as constantes de corte, é computada a integral da área abaixo dos limites e depois se calcula a resposta do sistema de classificação a partir da composição max-min e defuzzificação por centro de massa e/ou amplitude máximo dos máximos como visto nas seções anteriores. Tal processo é representado pela Figura 9 e Figura 10 a seguir utilizando o valor de temperatura igual 106.5 °C para o rodeiro direito e 107.8 °C para o rodeiro esquerdo de forma meramente ilustrativa:

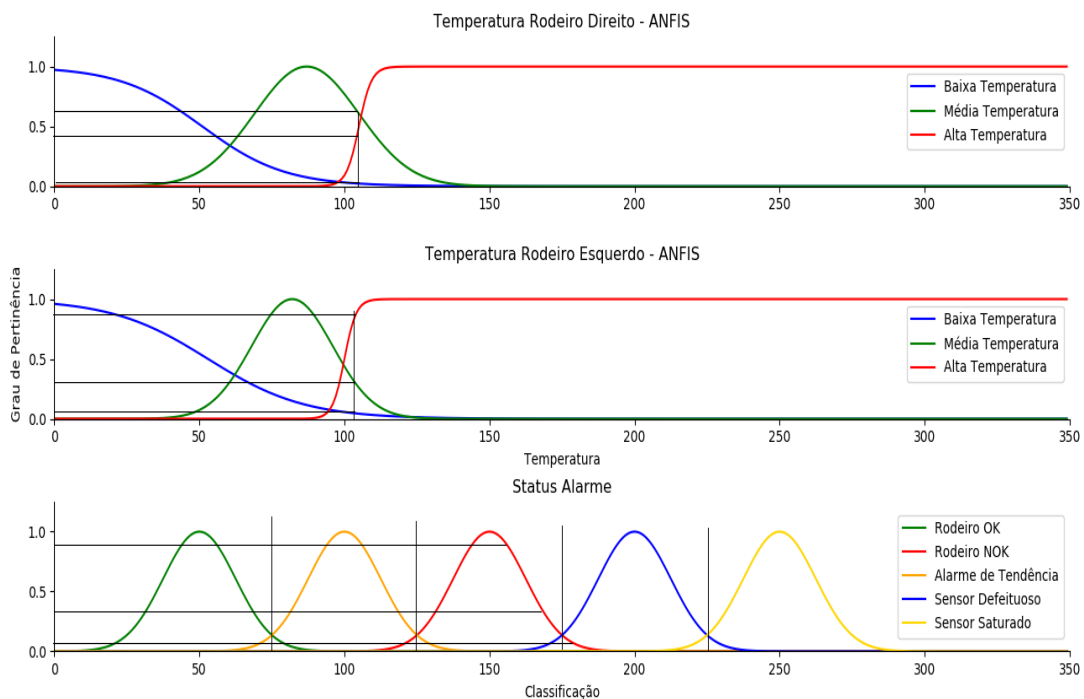


Figura 9 - Funções de Pertinência segundo valor de temperatura como constante de corte.




Figura 10 - Funções de Pertinência segundo valor de temperatura como constante de corte.

Para a realização do treinamento da rede baseado nesses parâmetros e nas informações iniciais, foi escolhido um limite de iteração por 1000 epochs ou tolerância igual 1^{-5} . A seguir a Figura 11 ilustra o erro associado à saída do sistema, enquanto que a Figura 12 demonstra a comparação entre os dados reais de temperatura da medição dos rodeiros de uma composição tida como exemplo e os dados sintéticos resultantes do treinamento da rede:




Figura 11 - Erro associado à saída do algoritmo de acordo com a respectiva epoch. Fonte: Python.




Figura 12 - Comparação entre os dados originais e os dados resultantes do treinamento da rede ANFIS.

Esses resultados foram utilizados na construção nas partições classificatórias (clustering) das condições dos ativos através da análise por agrupamento FCM (Fuzzy C-Means) de uma parte dos dados utilizados no treinamento do sistema de

classificação dos rodeiros. Comparando o desempenho do algoritmo com a classificação que havia sido executada pelos operadores, pôde ficar evidente através dos gráficos na Figura 13 e na Figura 14 o agrupamento para uma composição escolhida para o exemplo onde foram identificadas as situações de sensores defeituosos nas amostras de cor azul; nas amostras de cor verde as situações associadas aos dados que retratam as condições normais de operação e que a princípio foram identificados pelos operadores como falhas nos rodeiros (falsos positivos); nas amostras de cor amarela as condições de ativos que não romperam os limitantes de falha, mas que apresentavam evolução ao longo dos waysides adjacentes, configurando uma tendência de falha; e as situações descritas pelas amostras de cor vermelha que ilustram os casos em que de fato houve risco de integridade no material rodante considerado como uma falha no ativo [26, 27, 30]:

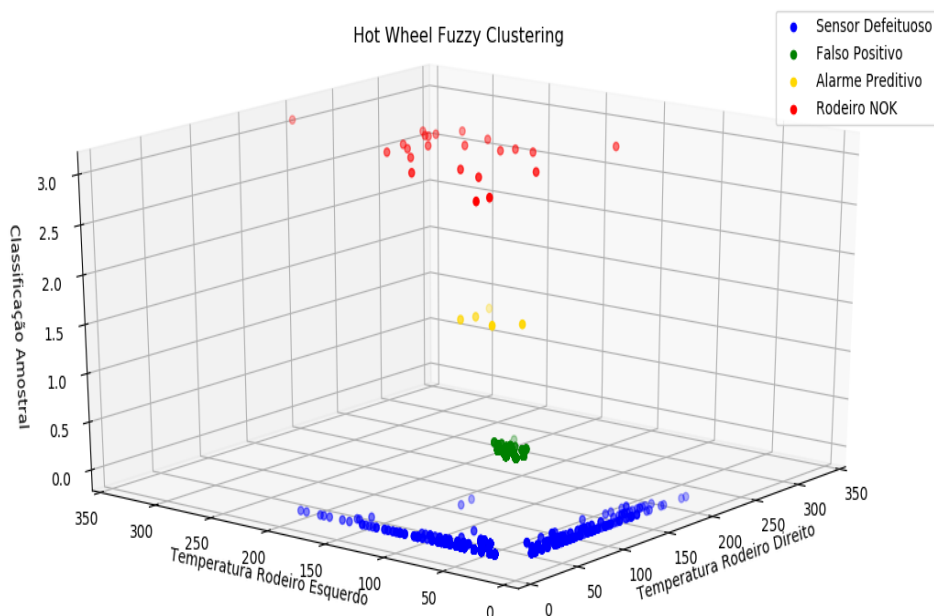


Figura 13 - Partição FCM para classificação de status de rodeiros.

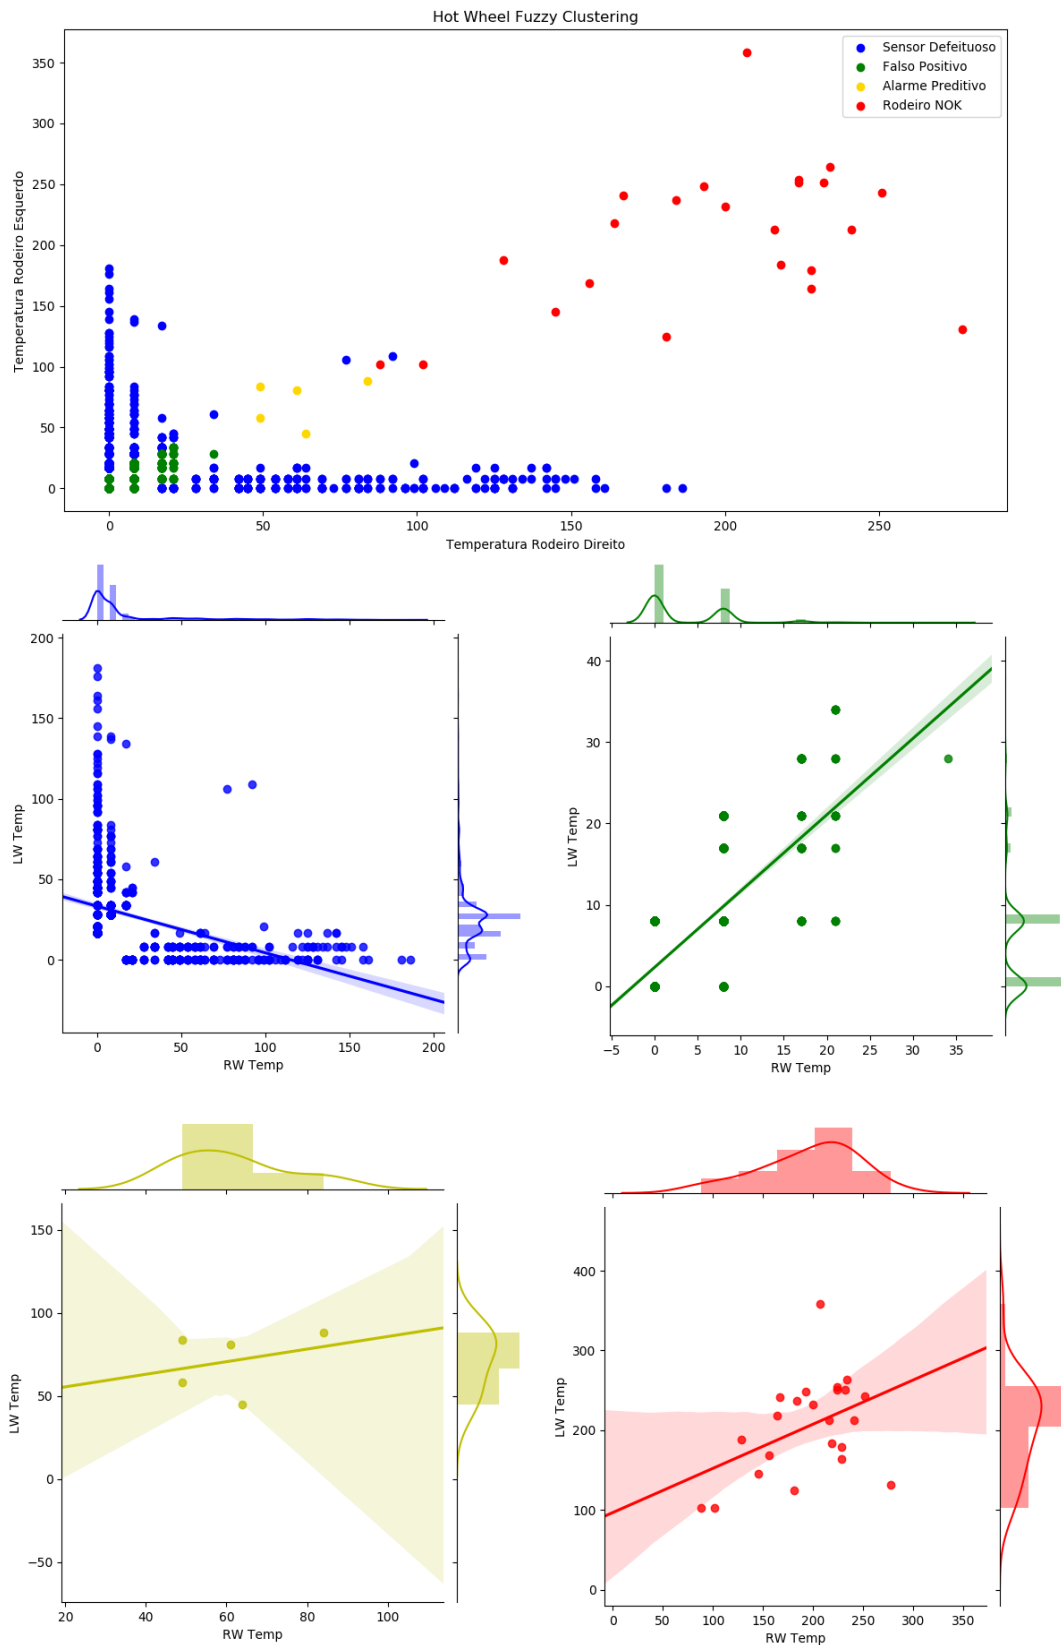


Figura 14 - Partição FCM para classificação e regressão de status de alarme por rodeiro.

CONCLUSÕES

Para garantir a disponibilidade e confiabilidade do material rodante, além dos benefícios citados, pode-se destacar ainda, que o tratamento dos dados fazendo uso da inteligência artificial, é capaz de conferir maior agilidade ao processo decisório, entretanto alguns importantes aspectos ainda devem ser levados em consideração. É importante garantir que o tratamento dos resultados obtidos seja realizado por profissionais que detenham conhecimento suficiente e estejam capacitados a avaliar qualitativamente os padrões e regras encontrados na saída do sistema proposto a fim de validá-lo e contestar possíveis irregularidades do mesmo, prezando pelas etapas de aprendizado de máquina supervisionado, semi-supervisionado até que se alcance o patamar de aprendizado não supervisionado.

Também pôde ser analisado o potencial do algoritmo como garantia da qualidade do sistema de forma a se tornar o mais independente possível da avaliação e expertise de um operador. Segundo o estudo para a base de dados selecionada, fica evidente a maior concentração de defeitos no equipamento de medição de temperatura (em azul) decorrentes de diversos sintomas, tais como defeito de configuração, vandalismos e fatores externos climáticos que chama atenção como principal fragilidade para este conjunto de amostras em específico, sobretudo no rodeiro direito. Além disso, temos resultados que apresentam um padrão bem definido para situações de falso positivo (em verde) e defeitos nos rodeiros (em vermelho), sendo este com valores de variância consideravelmente mais baixa. Outro fato que merece

destaque é a alta incerteza para o comportamento definido pelos pontos de tendência de falha no material rodante (em amarelo) e que pode ser justificado pelo número baixo de ocorrências no espaço amostral considerado neste ensaio. Em uma visão macroscópica, o estudo prospectivo desempenhado neste trabalho também apresenta uma proposta de divisão do novo fluxo de processo que passaria a compor cinco fases:

- **Seleção dos dados:** nesta fase compilam-se todas as informações relevantes no que diz respeito à limpeza dos dados do comportamento dinâmico do material rodante em questão a partir do sensoriamento em campo no sistema de IoT próprio da companhia.
- **Pré-processamento:** nesta etapa faz-se uma filtragem prévia dos dados (data cleaning), conforme critérios bem definidos pelo usuário, como por exemplo, desconsiderar equipamentos que estejam com baixo grau de confiabilidade como outliers do sistema.
- **Transformação:** os dados são agrupados conforme formato adequado para o processamento segundo localização, tipo de carga (composição vazia ou carregada) e horário. A partir do sistema de armazenamento a análise dos dados, aplica-se o algoritmo de otimização dos padrões e relacionamentos classificatórios.
- **Avaliação:** Nesta última fase, são realizadas as interpretações dos resultados obtidos, com auxílio de especialistas do ramo e a partir dessa análise, traça-se a tendência evolutiva do processo.

Conforme descrito acima, as saídas do programa escolhido podem definir novas regras, traçar os futuros prováveis e as tendências evolutivas das anomalias além de

termos tecnológicos para mitigar tais fragilidades no setor desejado. É através do uso do sistema de otimização que se torna possível analisar o volume de dados disponível, assim como em um próximo passo do estudo a estruturação das relações entre os sensores em locais adjacentes, formando uma rede para análise mais complexa em uma visão holística do sistema. Como dito anteriormente, a abordagem do método de inteligência computacional pode proporcionar a incorporação de informações que não seriam agregadas anteriormente em tempo hábil de resposta rápida apenas na mão do homem.

Na busca constante de evolução na forma de gerir esses ativos, a operadora ferroviária que detém esses ativos, a fim de reduzir os impactos na circulação dos trens provenientes à necessidade de manutenções corretivas, deve continuar adotando modelos de intervenções preventivas e preditivas baseadas na condição, que através de alarmes indicam o mau funcionamento de determinado componente de seus ativos, possibilitando o planejamento de uma intervenção por oportunidade ou uma intervenção imediata, caso seja necessário. Dessa forma, a fragilidade relacionada à estratégia de monitoramento dinâmico tem sua imprecisão na identificação do alarme para casos de waysides reduzida, pois o controle dos ativos ocorre de maneira automatizada, havendo redundâncias que garantam uma maior eficácia da informação.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ANTF - ASSOCIAÇÃO NACIONAL DOS TRANSPORTADORES FERROVIÁRIOS. Informações Gerais. Disponível em: <<http://www.antf.org.br/informacoes-gerais/>>. Acesso em: 03 dez 2017.
- [2] CONFEDERAÇÃO NACIONAL DO TRANSPORTE - CNT. Anuário CNT do Transporte 2017. Disponível em: <http://cms.cnt.org.br/Imagens%20CNT/PDFs%20CNT/Anu%C3%A1rio/anuario%20ferroviario.pdf>>. Acesso em: 03 dez 2017.
- [3] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. Confiabilidade e manutenibilidade: NBR ISO 5462. Rio de Janeiro, 1994. [4] DIAS, M. A. Logística, transporte e infraestrutura. 1 ed. São Paulo: Editora Atlas, 2012. 340p.
- [4] GOULART, Fernando S.; FIDALGO, Robson do N.. Data Mining. Pernambuco: UFPE, 1998. 42 slides
- [5] KARDEC, A.; NASCIF, J. Manutenção - Função Estratégica. 2 ed. Rio de Janeiro: QualityMark, 2001. 361p.
- [6] MRS LOGÍSTICA. MRS. Disponível em: <<https://www.mrs.com.br/>>. Acesso em: 03 dez 2017.
- [7] TEÓFILO, L. C. Um Modelo de Avaliação da Manutenção de um Veículo Ferroviário. 1989. 146 p. Dissertação (Mestrado em Engenharia de Transportes) – Instituto Militar de Engenharia – IME, Rio de Janeiro.

- [8] XENOS, H. G. Gerenciando a Manutenção Produtiva. 1 ed. Belo Horizonte: Editora de Desenvolvimento Gerencial, 2004. 302p.
- [9] MENDONÇA, Luciana. Inovação tecnológica no Brasil. O setor elétrico, São Paulo, ed. 73, fev. 2012.
- [10]. Hot Wheel Detector Sub-System and Software Manual – Progress Rail Services, a Caterpillar Company, 2012.
- [11] MENDEL, J. M., Fuzzy Logic Systems for Engineering: a Tutorial, Proc. IEEE, V. 83, No. 3, pp. 345-377, 1995.
- [12] KLIR, George J. & YUAN, B., Fuzzy Sets and Fuzzy Logic – Theory and Applications, Prentice Hall PTR, 1995.
- [13] ROSS, T.J., Fuzzy Logic with Engineering Applications, 2oEdition, John Wiley & Sons, 2004.
- [14] ZIMMERMANN, H. J., Fuzzy Set Theory and Its Applications, 2nd Edition, Kluwer Academic Publishers, 1994.
- [15] ZADEH, L.A., Fuzzy Sets as a Basis for a Theory of Possibility. Fuzzy Sets and Systems, Vol.1:3-28
- [16] ZADEH, L.A., A Fuzzy Algorithmic Approach to the Definition of Complex or Imprecise Concepts. Int. Journal of Man-Machine Studies, Vol.8: 249-291.
- [17] MORETO, M. & CIESLAK, D. A. G., Fuzzy Inference System to Automatic Fault Classification in Power Plants. IEEE Latin America Transactions, Vol. 14 Nº 2, Feb. 2016.

- [18] MAHANTY, R. N. & GUPTA, P. B. D., A Fuzzy Logic Based Fault Classification Approach using Current Samples Only. Electric Power Systems Research 77.
- [19] GOMIDE, F., LEMOS, A., CAMINHAS, Multivariable Gaussian Evolving Fuzzy Modeling System. IEEE Transaction on Fuzzy Systems, Vol. 19, Nº 1, Feb. 2011.
- [20] GOMIDE, F., LEMOS, A., CAMINHAS, W., SILVA, A. M., A Fast Learning Algorithm for Evolving Neo-Fuzzy Neuron. Applied Soft computing 14.
- [21] MUTHUVIJAYALAKSHMI, M., KUMAR, E., VENKATESAN, P., Classification of TB Disease Diagnosis Using ANFIS. International Journal of Current Research, Vol. 6, Nº 9 Sep. 2014.
- [22] JANG, S. R., “ANFIS: adaptive-network-based fuzzy inference system,” IEEE Transactions on Systems, Man and Cybernetics, vol. 23, no. 3, pp. 665–685, 1993.
- [23] GÜLER, I., ÜBEYLI, E. D., Adaptative Neuro-Fuzzy Inference System for Classification of EEG Signals Using Wavelet Coefficients. Journal of Neuroscience Methods 148.
- [24] CHEN, C., JOHN, R., TWYXCROSS, J., GARIBALDI, J. M., An Extended ANFIS Architecture and its Learning Properties for Type-1 and Interval Type-2 Models.
- [25] KAMEL, T. S., HASSAN, M. A. M., ANFIS for Fault Classification in the Transmission Lines. The Online Journal on Electronics and Electrical Engineering, Vol.2.
- [26] RUSPINI, E.H., Numerical methods for fuzzy clustering, Information Science, 2, 319-350,1970.

[27] The Scikit-Image Team, The Scikit-Fuzzy Documentation, Release 0.2, Jun. 2016.

Python Libraries.

[28] MIT License Anfis for Python. Acesso em Nov. 2018:
<https://github.com/twmeggs/anfis>.

[29] SILVA, H. P., Análise do Processo de Manutenção – Estudo de Caso MRS Logística.
Universidade Salgado de Oliveira, 2017.

[30] ABDULSHAHED, A. M., LONGSTAFF, A. P., FLETCHER, S., MYERS, A., Thermal Error
Modelling of Machine Tools Based on ANFIS with Fuzzy C-Means Clustering using a
Thermal Image Camera – Applied Mathematical Modelling, School of Computing and
Engineering, University of Huddersfield, Queensgate, 2015.