



**FUNDAÇÃO
UNIVERSIDADE
FEDERAL DE
MATO GROSSO DO SUL**

**FACULDADE DE ENGENHARIAS,
ARQUITETURA E URBANISMO E
GEOGRAFIA**

MESTRADO EM ENGENHARIA ELÉTRICA

Estimação de Séries Temporais via Rede NARX em Aplicações Industriais

Thainara de Araújo

Campo Grande MS
23 de fevereiro de 2022



FUNDAÇÃO
UNIVERSIDADE
FEDERAL DE
MATO GROSSO DO SUL

FACULDADE DE ENGENHARIAS,
ARQUITETURA E URBANISMO E
GEOGRAFIA

MESTRADO EM ENGENHARIA ELÉTRICA

Estimação de Séries Temporais via Rede NARX em Aplicações Industriais

Thainara de Araújo

Orientador: Prof. Dr. Marcio L. M. Kimpara

Coorientador: Prof. Dr. João O. P. Pinto

Dissertação apresentada à Universidade Federal de Mato Grosso do Sul na Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia, como requisito para a obtenção do grau de Mestre em Engenharia Elétrica.

Campo Grande MS
23 de fevereiro de 2022

Estimação de Séries Temporais via Rede NARX em Aplicações Industriais

Thainara de Araújo

Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Engenharia Elétrica, Área de Concentração em Energia Elétrica, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Mato Grosso do Sul.

Banca Examinadora:

Prof. Dr. Marcio L. Magri Kimpara
(Orientador)

Prof. Dr. João Onofre Pereira Pinto
(Co-orientador)

Prof. Dr. Raymundo Cordero Garcia

Prof. Dr. Walter Issamu Suemitsu

Campo Grande MS
23 de fevereiro de 2022

DECLARAÇÃO DE AUTORIA E RESPONSABILIDADE

Eu, **Thainara de Araújo**, residente e domiciliada na cidade de Campo Grande, Estado do Mato Grosso do Sul, portador do RG de nº 1.586.396 e CPF nº 49.893.441-11, declaro que a dissertação apresentada, com o título “Estimação de Séries Temporais via Rede NARX em Aplicações Industriais” é de minha autoria e assumo a total responsabilidade pelo seu conteúdo e pela originalidade do texto. Declaro que identifiquei e referenciei todas as fontes e informações gerais que foram utilizadas para construção do presente texto. Declaro também que este não foi publicado em outros meios de comunicação, tendo sido enviado com exclusividade para a Universidade Federal de Mato Grosso do Sul (UFMS).

Campo Grande, 23 de fevereiro de 2022.



Thainara de Araújo

Aos meus pais.

AGRADECIMENTOS

Em primeiro lugar gostaria de agradecer a Deus, que me sustentou durante minha caminhada e me deu sabedoria para chegar até aqui. Também agradeço por colocar em meu caminho as pessoas que me ajudaram, e que sem as quais a realização deste trabalho seria ainda mais difícil.

Sou grata aos meus orientadores, Marcio e João, não apenas por compartilhar seus conhecimentos, mas por serem compreensivos com minhas dificuldades.

A todos os professores que tive a oportunidade de conhecer durante o mestrado, agradeço, por serem parte fundamental do meu crescimento. Em especial ao professor Luigi, peça fundamental para elaboração desse trabalho.

Agradeço aos meus amigos e a minha família, por me incentivarem sempre, e se fazerem presente mesmo nesses tempos incomuns de pandemia.

RESUMO

A ampla utilização de automação na indústria tem levado os processos industriais a serem controlados a partir de informações provenientes de sensores, na forma de séries temporais. Por outro lado, o elevado custo dos sensores e a alta exigência de manutenção, devido a necessidade de calibração frequente, impulsionaram estudos no campo de previsão de séries temporais. Um método que vem ganhando destaque nesse campo de estudo é a previsão de séries temporais por meio da rede neural autorregressiva não linear com entradas exógenas. Essa rede integra o uso de atraso de tempo e de recorrência para captação de memória de curto prazo, o que a permite extrair informações sequenciais de suas preditoras. Neste trabalho essa rede é aplicada na previsão de séries temporais de interesse da indústria. O primeiro problema abordado corresponde a aplicação da rede neural para o monitoramento térmico em pontos críticos de um motor síncrono de ímã permanente, tendo em vista que as técnicas usuais se mostram custosas e/ou de difícil implementação. O segundo caso refere-se à validação de sensores de temperatura dos reatores de uma refinaria de petróleo. Os resultados são avaliados pelo cálculo do erro quadrático médio. Também foi avaliado o desempenho quanto a robustez, filtragem e espalhamento. A avaliação de desempenho ainda conta com uma comparação entre os métodos de previsão de série temporal obtidas por meio da inteligência artificial e da regressão kernel. Por fim foi constatado resultados satisfatórios, demonstrando o sucesso da aplicação da rede NARX nos problemas propostos.

Palavras-Chave: Previsão de Série Temporal, Rede Neural Autorregressiva Não Linear com Entradas Exógenas, Motor Síncrono de Ímã Permanente, Validação de Sensores, Robustez, Filtragem, Espalhamento, Regressão Kernel.

ABSTRACT

The widespread use of automation in industry has led industrial processes to be controlled from information coming from sensors, in the form of time series. On the other hand, the high cost of sensors and the high maintenance requirement, due to the need for frequent calibration, motivated studies in the field of forecasting time series. A method that has gained prominence in this field of study is the prediction of time series through the nonlinear autoregressive neural network with exogenous inputs. This neural network integrates the use of time delay and recurrence to capture short-term memory, which allows extraction of sequential information from its predictors. In this work, this network is applied in forecasting time series of interest to the industry. The first problem addressed corresponds to the application of the neural network for thermal monitoring at critical points of a permanent magnet synchronous motor, considering that the usual techniques are costly and/or difficult to implement. The second case refers to the validation of oil refinery reactors temperature sensors. The results are evaluated by calculating the mean square error. Performance regarding robustness, filtering and spillover was also evaluated. The performance evaluation also include a comparison between the time series prediction methods obtained through artificial intelligence and kernel regression. Finally, satisfactory results were found, demonstrating the success of the application of the NARX network in the proposed problems.

Keywords: Time Series Prediction, Nonlinear Autoregressive Neural Network with Exogenous Inputs, Permanent Magnet Synchronous Motor, Sensor Validation, Robustness, Filtering, Spillover, Kernel Regression.

LISTA DE FIGURAS

<i>Número</i>	<i>Página</i>
Figura 2.1 Classificação de Redes Neurais Artificiais (a) Rede alimentada adiante; (b) Rede recorrente.....	18
Figura 2.2 Rede <i>Perceptron</i>	19
Figura 2.3 Função Tangente Hiperbólica.	19
Figura 2.4 Rede <i>Perceptron</i> Multicamadas.....	20
Figura 2.5 Rede Autorregressiva Não Linear com Entradas Exógenas.	22
Figura 2.6 Configurações da Rede NARX (a) Série-Paralela; (b) Paralela.	24
Figura 3.1 Diagrama de treinamento da Rede nn.	38
Figura 3.2 Estrutura da Rede nn.....	39
Figura 3.3 Desempenho da Rede nn.....	39
Figura 3.4 Comparação entre os dados dos Sensores e os Estimados pela Rede nn...	40
Figura 3.5 Desempenho das Redes NARX.	42
Figura 3.6 Comparação entre dados dos Sensores e Estimados pelas Redes NARX...	42
Figura 3.7 Metodologia de estimação usando PCA	43
Figura 3.8 Estrutura da Rede nn_{PCA}	45
Figura 3.9 Desempenho da Rede nn_{PCA}	45
Figura 3.10 Comparação entre dados dos Sensores e Estimados pelas Redes nn e nn_{PCA}	46
Figura 3.11 Diagrama de ajuste da Regressão Kernel.....	47
Figura 3.12 Desempenho da Regressão Kernel.	47
Figura 4.1 Diagrama de agrupamento dos sensores. (a) função principal; (b) função de adição de sensores; (c) função de remoção de sensores.....	52
Figura 4.2 Matriz de correlação dos sensores.	53

Figura 4.3	Diagrama de treinamento das Redes.....	54
Figura 4.4	Desempenho das Redes NARX.	55
Figura 4.5	Comparação entre dados dos Sensores e Estimados pelas Redes NARX... 	56
Figura 4.6	Redes NARX aplicadas na detecção de falhas.....	57
Figura 4.7	Comparação de desempenho entre Regressão Kernel e NARX.	58
Figura 4.8	Comparação entre dados dos Sensores e Estimados por Regressão Kernel	59
Figura 4.9	Regressão Kernel aplicada na detecção de falhas.....	60

LISTA DE TABELAS

<i>Número</i>		<i>Página</i>
Tabela 3.1	Correlação entre as variáveis preditoras.....	36
Tabela 3.2	Correlação entre as variáveis de saída.....	37
Tabela 3.3	Sensibilidade ao Ruído.....	40
Tabela 3.4	Configuração das Redes NARX.....	41
Tabela 4.1	Configuração das Redes NARX.....	54

SUMÁRIO

1. Introdução	14
1.1. Justificativa.....	15
1.2. Objetivos	15
1.2.1. Objetivos Específicos.....	15
1.3. Organização do Trabalho	16
2. Fundamentação Teórica.....	17
2.1. Redes Neurais Artificiais.....	17
2.1.2. Perceptron.....	18
2.1.3. Perceptron Multicamadas.....	19
2.1.4. Redes Recorrentes	20
2.1.5. Rede NARX	21
2.1.6. Algoritmo de Aprendizagem.....	23
2.2. Regressão Kernel	27
2.3. Métricas de Desempenho	29
2.3.1. Erro Quadrático Médio	29
2.3.2. Coeficiente de Determinação	29
2.3.3. Sensibilidade.....	30
2.3.4. Filtragem.....	30
3. Estimação de Temperatura no PMSM.....	32
3.1. O Motor Síncrono de Imã Permanente.....	32
3.2. Base de Dados.....	34
3.3. Pré-processamento de dados abordado por correlação	35
3.4. Estimação Conjunta das saídas.....	37
3.4.1. Resultados.....	39
3.5. Estimação das saídas Separadamente	41
3.5.2. Resultados.....	41
3.6. Pré-processamento de Dados abordado por PCA	43
3.7. Estimação das Componentes Principais de Saída.....	44
3.7.2. Resultados.....	45
3.8. Comparação com a Regressão Kernel	46

3.9.	Conclusão	48
4.	Validação de Sensores	49
4.1.	O Problema	49
4.2.	Pré-processamento de Dados	50
4.3.	Configuração da Rede NARX	53
4.4.	Resultados	55
4.5.	Estimadores aplicados na Detecção de Falhas	56
4.6.	Comparação com a Regressão Kernel	58
4.7.	Conclusão	60
5.	Conclusão	61
	Referências	62

1. INTRODUÇÃO

Diante do presente cenário mundial, que exige tomadas de decisão cada vez mais rápidas, os seres humanos vêm buscando meios de antever informações que possam determinar a melhor estratégia para se controlar as mais variadas situações enfrentadas no seu dia-a-dia. Com o auxílio da inteligência artificial a previsão de determinadas informações se tornou possível e, hoje, previsões de dados já auxiliam na área de finanças [1], na indústria [2] e até mesmo na medicina [3].

Dentre as possibilidades de aplicação na indústria, as previsões de dados podem ser usadas tanto na substituição parcial de sensores (como sensores virtuais) [4] quanto para validação de sensores [5]. Os sensores são os equipamentos responsáveis por externalizar informações do processo para que seja possível tomar decisões de controle. Entretanto, muitas vezes os sensores são custosos, e a possibilidade de substituir parte deles por modelos matemáticos ou ao menos reduzir as paradas rotineiras para calibração gera economia à indústria.

Essa possibilidade fez com que a área de estudo em previsões de dados fosse impulsionada, gerando diversas técnicas de estimação, e tornando as previsões cada vez mais fidedignas à realidade. No caso da previsão de dados da indústria, a tarefa consiste em determinar um modelo matemático que represente a evolução temporal daqueles dados, ou seja, se trata de um problema de previsão de série temporal [6]. Dentre as técnicas de estimação destaca-se a aplicação de redes neurais artificiais (RNA) [7], em especial a rede autorregressiva não-linear com entradas exógenas (NARX - *Nonlinear AutoRegressive with eXogenous Inputs*) [8].

A rede NARX tem se mostrado bastante eficaz para modelar sistemas não lineares e especialmente séries temporais [8]. Exemplos são discutidos na seção 2.1.5, mostrando o desempenho superior da rede NARX em comparação a outras técnicas.

1.1. JUSTIFICATIVA

Dentre os problemas de previsão de série temporal enfrentados pela indústria, esse trabalho buscou solucionar dois casos. O primeiro é de especial interesse da indústria automobilística: previsão da temperatura em pontos críticos de um motor síncrono de imã permanente (geralmente utilizado em carros elétricos). O segundo se trata da validação dos sensores de temperatura de reatores de uma refinaria petrolífera.

A escolha desses problemas se deve à importante contribuição de sua solução para a indústria. No primeiro caso, é capaz de contornar os problemas de impraticabilidade de substituição dos sensores de temperatura no estator – mesmo estes apresentando defeito por tempo em atividade – e da impossibilidade de uso de sensor no rotor, devido rotação. Já no segundo caso a previsão bem sucedida minimiza a necessidade de manutenção frequente nos sensores da planta, muitas vezes de difícil acesso.

1.2. OBJETIVOS

Esse trabalho tem como objetivo a aplicação da rede NARX para previsão de dados temporais em duas situações de importância para indústria: dados de temperatura em um motor síncrono de imã permanente (*Permanent Magnet Synchronous Motor* – PMSM) e dados de temperatura de reatores em uma usina petrolífera. Explorando, dessa forma, a capacidade da rede NARX em solucionar dois problemas distintos, mas de grande valia ao setor industrial.

1.2.1. *Objetivos Específicos*

Além da realização das previsões temporais por meio da rede NARX, este trabalho ainda tem como propósito avaliar as estimativas obtidas por cada RNA considerando como métricas de desempenho: o erro quadrático médio, o coeficiente de determinação, a robustez, o espalhamento e a filtragem.

Adicionalmente, confrontar os resultados obtidos pela rede NARX com as previsões alcançadas por meio da regressão kernel, outro método que já se mostrou efetivo para resolução desses tipos de problema.

Por fim, a partir dos estimadores obtidos para o caso da refinaria, realizar a detecção de falhas nos sensores.

1.3. ORGANIZAÇÃO DO TRABALHO

O Capítulo 1 trouxe uma breve contextualização a respeito dos problemas de previsão de série temporal, apresentou os problemas abordados nesse trabalho, indicou o método de solução pretendido e por fim estabeleceu os métodos de avaliação de desempenho.

A fundamentação teórica encontra-se no Capítulo 2, onde é explicado em detalhes como funciona a rede NARX aplicada a problemas de previsão de série temporal. Também é descrito o método de regressão kernel e sua aplicação na estimação de temperaturas e na detecção de falhas de sensores. Além disso, é apresentado o detalhamento das métricas utilizada para avaliar o desempenho dos modelos.

No Capítulo 3, é apresentado detalhadamente o problema de temperatura no PMSM. Em seguida é descrita a base de dados do problema, a metodologia de solução (indicando como a RNA foi configurada e treinada) e os resultados.

O problema de validação de sensores é explicado detalhadamente no Capítulo 4. Então, é apresentada a base de dados, o modo de configuração da rede NARX para solução desse caso e os resultados alcançados. Da mesma forma são apresentados os resultados obtidos por regressão kernel e então as soluções são comparadas.

A conclusão, no Capítulo 5, contém uma breve análise a respeito das respostas obtidas e por fim são sugeridos trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. REDES NEURAIS ARTIFICIAIS

Uma rede neural pode ser descrita como um algoritmo projetado para executar uma tarefa de maneira similar ao cérebro humano. Para que a execução seja cumprida de maneira satisfatória as redes empregam uma metodologia própria, descrita em [9] como um processamento maciçamente paralelamente distribuído, realizado por meio de unidades de processamento simples, denominadas neurônios, com natural propensão a armazenar conhecimento experimental e disponibilizá-lo para uso.

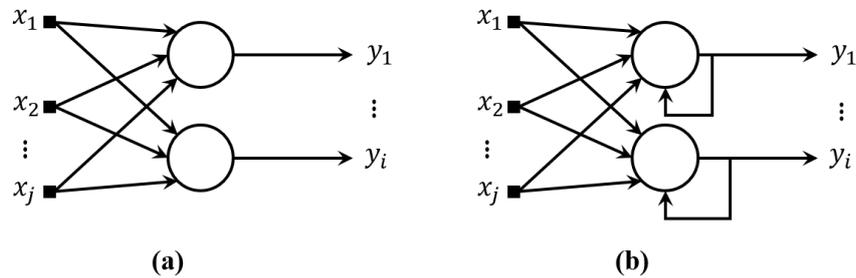
A maneira como essas unidades de processamento são interligadas denomina-se arquitetura da rede, e o procedimento capaz de transferir conhecimento útil à rede para execução da tarefa proposta chama-se algoritmo de aprendizagem. Juntos, a arquitetura da rede e o algoritmo de aprendizagem, são responsáveis pelo sucesso na conclusão da tarefa. Por isso devem ser cuidadosamente definidos observando os requisitos e limitações a serem enfrentadas de acordo com o problema estudado.

Quanto a arquitetura, as distinções de classe atentam-se ao modo como os neurônios são distribuídos, como eles são interligados e a forma que cada camada é composta [10]. Sendo assim, as arquiteturas de rede podem ser classificadas basicamente como: redes alimentadas adiante de camada única (*Perceptron*), redes alimentadas adiante de múltiplas camadas (*Perceptron* multicamadas) e redes recorrentes (que podem conter camadas múltiplas ou única).

A rede alimentada adiante e a recorrente diferem-se entre si pois, enquanto na primeira o fluxo de informação segue uma única direção, da entrada para a saída, na segunda há ao menos um laço de realimentação, essa diferença é ilustrada na Figura 2.1.

Figura 2.1 Classificação de Redes Neurais Artificiais

(a) Rede alimentada adiante; (b) Rede recorrente.



Fonte: Autoria Própria

2.1.2. Perceptron

A rede *Perceptron* é o tipo mais simples de rede neural e tem aplicação em problemas ditos linearmente separáveis. Ela consiste de um único neurônio com pesos sinápticos ajustáveis e bias. Cada neurônio tem uma função de excitação do tipo:

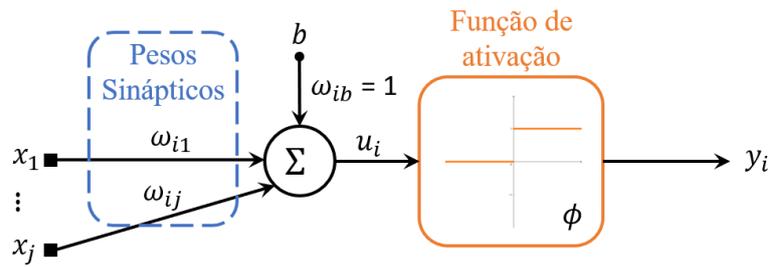
$$u_i = \sum_{j=1}^n \omega_{ij}x_j + b_i \quad (1)$$

onde o subscrito i identifica o neurônio, o j identifica a entrada, ω_{ij} é o peso sináptico que interliga a entrada x_j ao neurônio i , e u_i é a excitação interna do neurônio i . O elemento b_i se refere ao bias do neurônio i e a sinapse que liga o bias ao seu neurônio (ω_{ib}) usualmente possui módulo unitário. É justamente essa sinapse a responsável pela polarização do neurônio [11].

Uma vez que o neurônio sofre uma excitação u , então essa excitação experimenta a função de ativação (ϕ) do neurônio para então dar origem a saída (y_i), ou seja:

$$y_i = \phi(u_i) \quad (2)$$

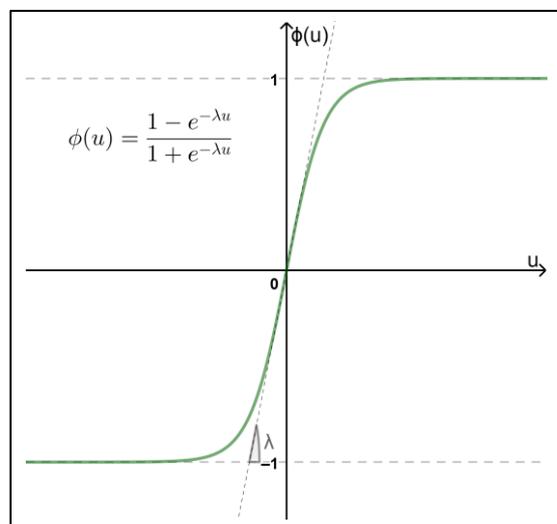
As Equações (1) e (2) são ilustradas na Figura 2.2.

Figura 2.2 Rede *Perceptron*.

Fonte: Autoria Própria

A função de ativação é responsável por normalizar u_i , o que é importante para assegurar a estabilidade no processo de treinamento. A utilizada na rede Perceptron é a do tipo limiar, mas nas demais redes as mais comuns são do tipo sigmóide. O uso majoritário da sigmóide se explica pela sua característica de balancear adequadamente o comportamento linear e não-linear [9]. Esse comportamento pode ser observado na Figura 2.3, que demonstra um tipo de função sigmóide, a tangente hiperbólica.

Figura 2.3 Função Tangente Hiperbólica.



Fonte: Autoria Própria

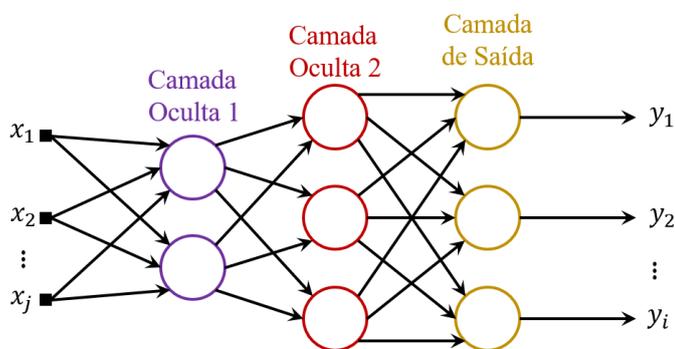
2.1.3. *Perceptron Multicamadas*

A fim de aumentar a gama de problemas solucionáveis pela rede *Perceptron* foi adicionada uma camada de neurônios, denominada camada intermediária ou escondida,

posicionada entre a entrada e a camada de saída, dando origem a rede *Perceptron* multicamadas (MLP – *Multi-Layer Perceptron*).

Essa rede pode ter uma ou mais camadas intermediárias, sendo uma forma genérica da rede *Perceptron*, e por isso sendo considerada uma das mais versáteis quanto a aplicabilidade [10]. Além disso, ela pode possuir vários neurônios na camada de saída, cada qual representando uma saída a ser mapeada. Sua arquitetura é exibida na Figura 2.4, onde os bias, os pesos sinápticos e as funções de ativação são considerados internos aos neurônios, representados por círculos.

Figura 2.4 Rede *Perceptron* Multicamadas.



Fonte: Autoria Própria

Embora poderosa, a MLP tem suas limitações quanto a problemas dinâmicos, então, para lidar com essa situação, a mesma precisa sofrer adaptações, assumindo configuração recorrente e/ou adicionando atrasos de tempo. Esses conceitos serão tratados adiante.

2.1.4. Redes Recorrentes

Conforme observado na Figura 2.1(b), nas redes recorrentes, as saídas são produzidas não apenas a partir dos valores atuais das entradas, mas também por valores anteriores das saídas. Isso ocorre devido aos laços de realimentação, que demandam o uso de elementos de atraso, resultando em uma dinâmica não-linear da rede, e, conseqüentemente, que essa contenha unidades não lineares [9]. Esses atrasos agregam memória a rede, o que permite o processamento de informações sequenciais. Por essa razão é classificada como uma rede neural dinâmica.

A presença de realimentação permite que a rede realize processamento dinâmico da informação, por essa razão é capaz de solucionar uma gama maior de problemas, incluindo aqueles problemas variantes no tempo, tais como: previsão de séries temporais [12], identificação e controle de sistemas [13], representação de sistemas dinâmicos não lineares arbitrários [14], entre outros.

Essencialmente, uma rede recorrente pode ser utilizada como memória associativa ou para mapeamento de entradas e saídas. No caso da memória associativa a rede é treinada com alguns padrões e, durante sua aplicação, a rede deve recordar e recuperar esses padrões, a partir de uma chave de entrada que pode estar em uma versão distorcida ou ruidosa [9]. Já no caso de mapeamento de entradas e saídas, a rede busca modelar um sistema, sendo capaz de prever suas saídas, ou seja, realiza uma estimação não paramétrica a partir da correspondência entre entradas e saídas desejadas.

Para ambas aplicações há diversos tipos de rede que podem ser utilizadas, dentre elas as redes: Elman, BRNN, LSTM, GRU [15] e NARX. Dar-se-á destaque a essa última, a qual mostrou-se tão eficiente computacionalmente quanto as máquinas de Turing [16].

2.1.5. Rede NARX

Essa rede tem a particularidade de unir duas estruturas dinâmicas, a realimentação e o atraso de tempo. A primeira estrutura permite que a rede utilize as saídas anteriores para calcular a atual, conforme explicado anteriormente. A segunda estrutura permite a apresentação não apenas do valor atual das entradas à rede, mas dos valores anteriores também, através da inclusão de uma linha de atraso entre as entradas e a rede.

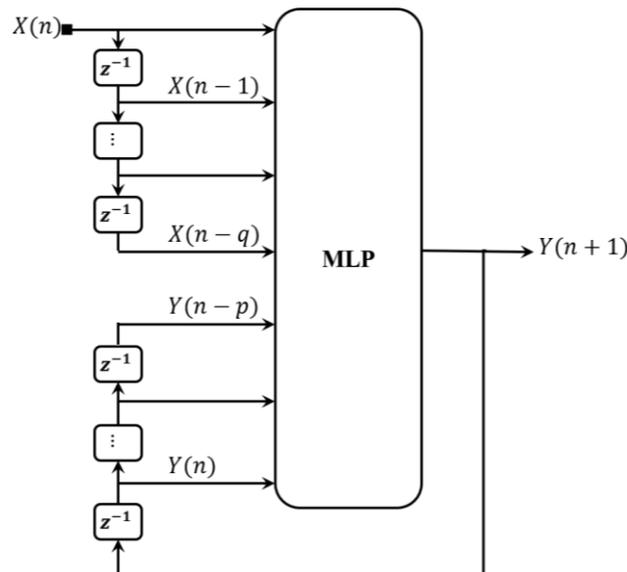
A estrutura de atraso temporal foi inicialmente aplicada a redes alimentadas adiante [17] e essa arquitetura recebeu o nome de redes neurais de atraso de tempo (TDNN – *Time-Delay Neural Network*), e só posteriormente foi empregada junto com a configuração recorrente, dando origem a rede NARX.

Por contar com essas duas estruturas a topologia NARX, exibida na Figura 2.5, é capaz de modelar uma função não-linear do tipo:

$$Y_{n+1} = f(Y_n, Y_{n-1}, \dots, Y_{n-p}, X_n, X_{n-1}, \dots, X_{n-q}) \quad (3)$$

onde Y é o conjunto de saídas da rede, $Y = \{y_1, y_2, \dots, y_i\}$, X é o conjunto de entradas da rede, $X = \{x_1, x_2, \dots, x_j\}$, o subscrito n refere-se ao momento atual e p e q , a quantidade de atrasos de tempo na saída e na entrada, respectivamente, sendo esses valores independentes. Destaca-se que a saída da função está adiantada em relação ao momento presente (Y_{n+1}).

Figura 2.5 Rede Autorregressiva Não Linear com Entradas Exógenas.



Fonte: Autoria Própria

Conforme observado na Figura 2.5, a rede NARX é basicamente uma MLP cuja entrada é composta por sua saída realimentada com atrasos (representados por z^{-1}) e por entradas exógenas que também podem conter atrasos.

Comparando a rede NARX com redes recorrentes convencionais percebe-se que a primeira, de modo geral, alcança resultados superiores, no que tange a descoberta de dependências de longo prazo, se comparada a segunda [18]. Por essa razão é largamente aplicada a problemas de série temporal, podendo-se citar como exemplo sua aplicação na: previsão de valores futuros do sinal de entrada [19]; modelagem de sistemas dinâmicos não lineares [20]; filtragem não linear [21], onde a saída alvo é uma versão não ruidosa do sinal de entrada; entre outros.

Em [19] é comparado o uso de dois métodos, a rede NARX e o modelo de média móvel integrada autorregressiva sazonal (SARIMA - *Seasonal Autoregressive Integrated Moving Average*), para previsão da radiação solar direta e média em uma superfície horizontal. Foram utilizados dados meteorológicos de curto prazo, com dados de 2007 a 2013 para

treinamento e dados de 2014 e 2015 para teste. Os dados correspondem ao valor da radiação solar e de hora, dia, mês e ano de cada amostra. As variáveis de tempo e radiação solar foram adotadas como entrada e a radiação solar futura como saída. A avaliação dos métodos foi realizada por meio do coeficiente de determinação e de diversas funções do erro. A partir dessas medidas de desempenho constatou-se que a rede NARX obteve melhores resultados na estimação dos dados de 2014 e 2015.

Também [22] se dedica ao estudo da rede NARX aplicada a previsão. Nesse trabalho a rede foi utilizada para prever o nível de lençóis freáticos na Alemanha. Foram definidas como entradas da rede as métricas de temperatura e precipitação, o que torna a abordagem facilmente replicável. O desempenho da rede foi avaliado a partir da raiz do erro quadrático médio, pelo coeficiente de determinação e pela eficiência de Nash-Sutcliffe. A rede obteve resultados satisfatórios para curto e médio prazo.

Em [23] buscou-se prever a vida útil remanescente de motores de turbina a gás utilizando a rede NARX. Para isso a rede foi projetada para prever o nível de desgaste do equipamento até a falha. Então, a vida útil foi calculada pela diferença entre o nível de desgaste atual e momento que atinge o nível de falha, ou seja, corresponde ao número de ciclos que o equipamento demanda para alcançar o estado de falha. O desempenho da rede fora mensurado pela diferença absoluta entre o valor da vida útil estimada e seu valor alvo. A rede foi testada para diferentes conjuntos de dados obtendo erros razoavelmente pequenos para a maioria dos casos, o que demonstra que a rede NARX foi capaz de estimar o nível de desgaste do motor de maneira suficientemente próxima ao real. Além disso, os resultados demonstraram a capacidade da rede em prever satisfatoriamente o nível de desgaste exponencial dos equipamentos.

2.1.6. Algoritmo de Aprendizagem

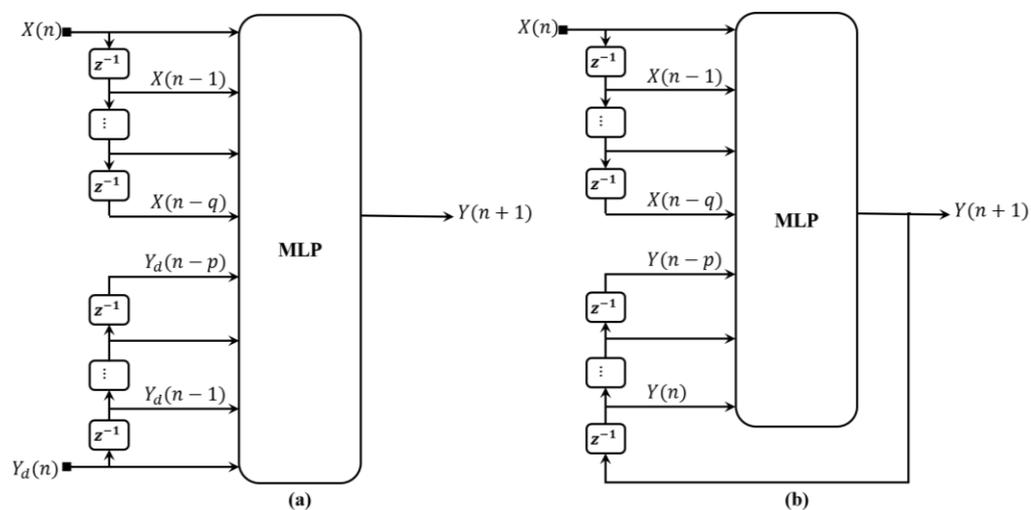
Para que a rede armazene conhecimento útil para execução da tarefa proposta é necessário um conhecimento prévio, obtido através de um algoritmo de aprendizagem (ou de treinamento), responsável por ajustar a força de conexão entre os neurônios (pesos sinápticos).

Observando a Figura 2.5 percebe-se que a rede NARX funciona de maneira não recursiva, isto é, não existe ligação entre a saída desejada e a entrada, pois são os próprios valores estimados que são realimentados na rede. No entanto, uma manobra muito utilizada

para o treinamento de redes NARX é uma modificação estrutural, dando origem a rede NARX em série-paralelo, mostrada na Figura 2.6(a). Nessa configuração, o conjunto de saídas desejadas (Y_d) é apresentada na entrada da rede em substituição a realimentação, obtendo como vantagens: a maior precisão na entrada e a arquitetura puramente alimentada adiante, o que permite o uso de retro propagação estática no treinamento [24]. Todavia, destaca-se que essa configuração geralmente é usada apenas para treinar a rede, logo, após configurado os pesos sinápticos, a rede pode voltar à configuração padrão, NARX em paralelo, apresentada na Figura 2.6(b).

Figura 2.6 Configurações da Rede NARX

(a) Série-Paralela; (b) Paralela.



Fonte: Autoria Própria

A retro propagação, aplicada na etapa de aprendizagem da rede NARX, é um algoritmo de treinamento baseado em tentativa e correção. A informação é primeiramente propagada da entrada para a saída, e então o valor obtido na saída é comparado ao valor desejado e é calculado o erro. Em seguida o erro segue o caminho inverso da informação, isto é, da saída para a entrada, por essa razão recebe o nome de retro propagação. É a partir do sinal de erro que os pesos sinápticos são atualizados, buscando a redução do erro na próxima iteração, ou seja, espera-se que as sinapses sejam ajustadas na direção em que os erros diminuam mais rapidamente. Então, são realizadas iterações sucessivas até que o valor estimado esteja suficientemente próximo ao desejado.

Entretanto, o algoritmo de retro propagação é muito lento para vários casos, visto que sua metodologia de ajuste dos pesos sinápticos não garante que a rede convergirá mais rápido. Por essa razão esse algoritmo foi sendo modificado dando origem a diversos algoritmos de treinamento [25], dentre eles uma classe chamada de “retro propagação baseada em gradiente conjugado”.

Diferente do algoritmo de retro propagação tradicional onde a taxa de aprendizagem é fixa, o algoritmo de retro propagação baseado em gradiente conjugado tem sua taxa de aprendizagem recalculada a cada iteração. Esse cálculo é realizado com base em uma pesquisa realizada ao longo da direção do conjugado da função [26]. Essa modificação garante maior velocidade de convergência em relação ao algoritmo tradicional [27].

O algoritmo de retro propagação baseado em gradiente conjugado começa a pesquisa de direção (p) de maneira similar ao algoritmo de retro propagação tradicional, ou seja, na direção negativa do gradiente (g):

$$p_0 = -g_0 \quad (4)$$

Em seguida é realizada uma pesquisa de linha para determinar a distância de movimento ideal (α) na direção de pesquisa atual. Então os pesos sinápticos são atualizados a cada iteração k :

$$\omega_{ij_{k+1}} = \omega_{ij_k} + \alpha_k p_k \quad (5)$$

Após atualizar os pesos, uma nova pesquisa de direção é realizada, de forma que essa nova pesquisa seja conjugada com as direções de pesquisa anteriores:

$$p_k = -g_k + \beta_k p_{k-1} \quad (6)$$

sendo a variável β a responsável por diferenciar um algoritmo de retro propagação baseado em gradiente conjugado do outro.

No caso do algoritmo de retro propagação baseado em gradiente conjugado com atualizações de Fletcher-Reeves a variável β é dada por:

$$\beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}} \quad (7)$$

O algoritmo de retro propagação baseado em gradiente conjugado com atualizações de Fletcher-Reeves é o que requer menor armazenamento dentre os algoritmos baseados em gradiente conjugado [26]. Isso porque os algoritmos de retro propagação baseados em gradiente conjugado demandam o cálculo da matriz Hessiana (matriz quadrada que contém as derivadas parciais de segunda ordem), a qual é bastante custosa computacionalmente. Já a versão de Fletcher-Reeves contorna esse obstáculo, pois não necessita da matriz Hessiana explicitamente [27].

Um outro método usado para evitar o cálculo da matriz Hessiana, mas que não é baseado em gradiente conjugado, é o algoritmo de retro propagação de Levenberg-Marquardt, no qual restringe-se a função de desempenho do algoritmo de retro propagação para funções do tipo soma de quadrados, então utiliza-se a aproximação:

$$H = J^T J \quad (8)$$

onde H é a matriz Hessiana e J a matriz Jacobiana (matriz quadrada que contém as derivadas parciais de primeira ordem).

Nesse método o gradiente de retro propagação é calculado a partir do produto entre J e o vetor de erros (e), ou seja:

$$g = J^T e \quad (9)$$

Dessa forma, o cálculo dos novos pesos sinápticos, mostrado na Equação (10), são computados por meio da atualização do tipo Newton utilizando a aproximação da matriz Hessiana, exibida na Equação (8).

$$\omega_{ij_{k+1}} = \omega_{ij_k} - [J^T J + \mu I]^{-1} J^T e \quad (10)$$

O parâmetro μ é adaptativo e, quando nulo, torna a Equação (10) no método de Newton usando matriz Hessiana aproximada, enquanto que para valores grandes torna a Equação (10) em um gradiente descendente com passo pequeno. O objetivo do algoritmo é reduzir o μ a fim de converter a Equação (10) em método de Newton o mais rápido possível, tendo em vista que este é mais rápido e preciso perto de um ponto de mínimo do erro. Portanto, μ é reduzido a cada etapa bem sucedida, isto é, quando a função de desempenho é reduzida, e

elevado quando a função de desempenho seria aumentada pela etapa provisória. Desse modo garante-se que a função de desempenho sempre irá decrescer [28].

Ambos os algoritmos de aprendizagem discutidos realizam a atualização dos pesos sinápticos apenas após todas as entradas e alvos terem sido apresentadas, o que constitui uma época. Essa abordagem é denominada treinamento em lote. O treinamento em lote é indicado para maioria dos problemas, exceto quando a superfície de erro não é bastante complexa e o conjunto de treinamento contém um grande número de informação redundante [29]. As principais características do treinamento em lote são: para conjuntos de dados de treino pequenos a velocidade de treinamento é maior, demanda um número de épocas menor, mas apresente uma convergência local; para um conjunto de treinamento grande a velocidade de treino é baixa, assim como sua capacidade de generalização, devido ao sobre ajuste [30].

2.2. REGRESSÃO KERNEL

A regressão kernel é um método de estimação bastante utilizado em virtude de sua fácil aplicação, já que se trata de uma regressão não-paramétrica. O método utiliza técnicas estatísticas, junto a um conjunto de dados de memória, para encontrar uma função que aproxime o comportamento dos dados. Ou seja, considerando um conjunto de dados de entradas e saídas:

$$(x_i, y_i) \text{ para } i = 1, \dots, n \quad (11)$$

sendo o subscrito i referente a i -ésima observação. O método busca encontrar uma equação f , suave e contínua, tal que:

$$y_i = f(x_i) + \varepsilon_i \quad (12)$$

onde ε_i são variáveis aleatórias, suficientemente pequenas, com média zero e variância comum σ^2 , não correlacionadas e independentes de y .

A estatística assegura que f pode ser aproximada pela equação:

$$\hat{f}(x_i) = \sum_{j=1}^m K(x_i, x_j, h) y_j \cdot \left(\sum_{j=1}^m K(x_i, x_j, h) \right)^{-1} \quad (13)$$

para uma constante de suavização (h) diminuta, tal que $h \rightarrow 0$.

O subscrito j presente na Equação (13) refere-se aos dados de memória do modelo e K é a função kernel, definida geralmente por uma função densidade de probabilidade simétrica, por exemplo a gaussiana (G):

$$K(x_i, x_j, h) = G(t, \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(t-\mu)^2}{2\sigma^2}} \quad (14)$$

onde x_i é a variável aleatória t , x_j é a média (μ) e h é o desvio padrão (σ).

Conforme mencionado anteriormente, a constante h controla o nível de suavidade da curva do estimador. Quando $h \rightarrow 0$ a curva adequa-se perfeitamente aos dados, inclusive aos ruídos, mas, quando $h \rightarrow \infty$, o nível de suavização causa perda de informação. Por essa razão a escolha de h deve equilibrar a relação de suavidade e informação a fim de obter o modelo mais fidedigno a realidade.

Esse método foi aplicado em [31] para previsão da temperatura na região de Selaparang Lombok, na Indonésia, obtendo estimações satisfatórias. O conceito de função kernel foi aplicado em [32], a fim de reduzir o viés nas estimações. Neste artigo foram utilizadas duas técnicas de regressão linear, uma usando gradiente descendente e a outra usando equações normais. Ambos os métodos foram avaliados com e sem o uso de recursos kernel. Aplicando os métodos sem o uso de métodos kernel percebeu-se que as estimações tiveram alto viés, enquanto que com o uso de recursos kernel esse viés pode ser controlado, adicionando suavidade a curva de estimação. Além disso, o uso da equação normal reduz os requisitos de processamento em comparação com o uso de gradiente descendente. Esse trabalho prova que, embora esse método seja facilmente aplicável, alcança resultados regulares. Todavia, os autores afirmam que melhores resultados podem ser obtidos a partir de RNAs.

Quando tanto os dados de entrada do estimador quanto os dados de saída referem-se a um mesmo parâmetro, a técnica adquire a capacidade de associar os dados entre si automaticamente. Nesse caso passa a se chamar Regressão Kernel Auto Associativa (AAKR – *Auto-Associative Kernel Regression*).

Em [33] aplica-se a AAKR para validação de sensores de corrente empregados a um motor de indução trifásico. Esse trabalho dedicou-se a detecção e compensação de falhas dos sensores. Com apenas três sensores eles conseguiram atingir resultados regulares, não apenas para detecção, mas também para compensação da falha, tendo sua performance melhorada com a adoção de seis sensores. No entanto, notou-se a necessidade de incluir mais sensores para aumentar a confiabilidade, ainda que sejam usados sensores de menor precisão a fim de minimizar os custos.

2.3. MÉTRICAS DE DESEMPENHO

2.3.1. Erro Quadrático Médio

A precisão de um modelo é baseada na diferença entre os valores reais e os estimados, ou seja, no erro. Uma medida de precisão comumente usada é o erro quadrático médio (MSE – *Mean Square Error*), definida por:

$$mse = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (15)$$

onde n é o número de observações, i corresponde à i -ésima observação, \hat{y} é a estimação do sinal e y é o sinal adquirido. O MSE varia de 0 a ∞ , de modo que quanto mais próximo a 0 ele for, mais preciso é o modelo.

Essa medida será utilizada como parâmetro de comparação entre os modelos de estimadores.

2.3.2. Coeficiente de Determinação

O coeficiente de determinação (R^2) informa quão ajustado aos dados um modelo está. Salienta-se que o valor de R^2 sozinho não é suficiente para declarar se um modelo é bom, mas aponta casos desfavoráveis.

Esse coeficiente é equivalente a porcentagem da variabilidade das saídas que fica explicada em função da variabilidade das entradas [34]. Matematicamente, o R^2 é dado por:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (16)$$

onde \bar{y}_i é a média dos dados de saída reais (y_i) e n é o número de observações estimadas.

R^2 varia de 0 a 1, sendo 1 o valor para um modelo perfeitamente adequado aos dados.

2.3.3. Sensibilidade

A sensibilidade mede o quão bem um modelo se comporta caso haja falta em algum dos sensores das variáveis preditoras. Para hipótese de uma falta, gerada artificialmente com *drift*, na i -ésima observação do sensor j , responsável por adquirir a entrada x_j , tem-se que o $x_j(i) = x_j^{drift}$. Essa entrada gera uma estimaco $\hat{y}_{k_i}^{drift}$ para a sada k . O *drift* pode ter comportamento aditivo ou multiplicativo alterando o sinal original. Assim, a sensibilidade é dada pela razo entre o *drift* na entrada e a propagao da falta, ou seja:

$$s_{jk} = \frac{\sum_{i=1}^n |\hat{y}_{k_i}^{drift} - \hat{y}_{k_i}|}{\sum_{i=1}^n |x_{j_i}^{drift} - x_{j_i}|} \quad (17)$$

Para o caso de validao de sensores, onde as sadas so estimaces das entradas, tem-se que s_{jk} é a **robustez** quando $j = k$ e, se $j \neq k$, ento s_{jk} é o **espalhamento**. Logo, a matriz s_{jk} denota o efeito da falta na entrada j sobre a sada k . Quanto mais prximo de 0 o valor de s_{jk} melhor o modelo se comporta na presena de faltas.

É importante frisar que a sensibilidade pode ter relao com a funo de *drift* aplicada a entrada, sendo grandes magnitudes mais facilmente atenuadas do que pequenas. Para contornar essa situao um sinal do tipo rampa pode ser usado como *drift*, permitindo avaliar o comportamento do modelo para diferentes magnitudes de falta.

2.3.4. Filtragem

A filtragem mensura a sensibilidade do estimador ao rudo. Ela pode ser obtida de modo anlogo ao estudo de sensibilidade ao *drift*, substituindo esse por um rudo branco (wn). Portanto a sensibilidade ao rudo é dada por:

$$s_{jk} = \sum_{i=1}^n |\hat{y}_{k_i}^{wn} - \hat{y}_{k_i}| \cdot \left(\sum_{i=1}^n |x_{j_i}^{wn} - x_{j_i}| \right)^{-1} \quad (18)$$

Neste trabalho o ruído adicionado segue a distribuição normal, isto é, média nula e variância unitária.

3. ESTIMAÇÃO DE TEMPERATURA NO PMSM

3.1. O MOTOR SÍNCRONO DE IMÃ PERMANENTE

O PMSM tem ampla aplicação na indústria, em especial no setor automobilístico, devido ao emprego em veículos elétricos e híbridos – atual tendência de mercado.

Essa categoria de motores refere-se a máquinas em corrente alternada cujo enrolamento do estator multifásico gera um campo magnético giratório proporcional à frequência da corrente de linha, ao passo que, no rotor, os ímãs permanentes geram um campo magnético constante. Quando o campo magnético gerado pelo enrolamento do estator gira, o rotor também gira, de maneira síncrona, de forma que a velocidade de rotação seja proporcional à frequência elétrica.

O funcionamento do rotor do PMSM é praticamente livre de perdas, entretanto, o ímã permanente tem seu comportamento influenciado pela variação de temperatura. A elevação da temperatura causa redução da densidade de fluxo residual, como no neodímio-ferro-boro [35]. Outra componente do PMSM sensível ao calor é o isolamento do enrolamento do estator, o qual tem seu envelhecimento acelerado termicamente, ameaçando gravemente a segurança de operação do motor. Por essas razões é indispensável que a temperatura seja mantida em uma faixa segura para o motor não ter seu desempenho comprometido [36].

É comum o uso de sensores para monitorar a variação de temperatura no estator do PMSM, entretanto essa alternativa enfrenta problemas como a difícil substituição, ainda que tenham seu funcionamento afetado. Já o uso de sensores no rotor é impossibilitado devido rotação. Uma possibilidade é utilizar sensores infravermelho ou *wireless*, contudo, ambas opções agregam substancial aumento de custo, impraticável a nível industrial. Sendo assim, uma alternativa adotada pela indústria é aplicar uma margem de segurança nos materiais embutidos, que evite danos térmicos, mas que em contrapartida gera aumento de custo [37].

Outra possibilidade para substituir os sensores é estimar, em tempo real, a temperatura nos pontos sensíveis ao calor. Essa estimativa pode contribuir tanto no projeto de motores com tamanho e quantidade de material otimizados quanto na aplicação de técnicas de controle que admitam o uso da capacidade máxima do PMSM.

A estimativa da temperatura é importante ainda para que sejam criados índices de falha e confiabilidade, usados como base para elaboração de um programa de manutenção para atingir a eficiência máxima do sistema, reduzindo interrupções na operação.

Alguns métodos de estimativa de temperatura em motores utilizam componentes elétricos que variam com a temperatura, contudo, a temperatura estimada nesses casos corresponde ao valor médio do enrolamento ou ímã e não a seus pontos críticos [36]. Já os modelos baseados em inteligência artificial buscam modelar o comportamento da temperatura através de amostras de dados, desvinculando-se de aproximações teóricas. A modelagem de temperatura de motores elétricos geralmente é bastante complexa, já que envolve múltiplas entradas e múltiplas saídas. Por essa razão as RNAs apresentam-se como uma opção adequada.

O uso de redes neurais para estimação de dados de temperatura é bastante comum na literatura. Em [38] é apresentado um modelo que usa redes neurais recorrentes com blocos de memória com o intuito de melhorar a precisão das previsões de temperaturas em um PMSM para além do estado da arte. Foram alcançados resultados promissores, pois, em comparação a abordagem por redes térmicas de parâmetros concentrados (*Lumped-Parameter Thermal Networks* – LPTNs), método amplamente aplicado para modelagens térmicas, a rede recorrente com blocos de memória demonstrou atuar com precisão de estimativa semelhante em relação à norma, porém com desempenho menor em relação ao desvio. Com base nesses resultados concluiu-se que novas alternativas baseadas em rede recorrente com blocos de memória devem ser investigadas, com o intuito de otimizar seus resultados e economizar tempo computacional.

Em [39] discorre sobre a estimativa de temperatura do enrolamento do estator por meio de uma rede neural profunda (*Deep Neural Network* – DNN). Foram utilizadas como preditores do modelo as variáveis: temperatura ambiente, temperatura do líquido de arrefecimento, tensão do eixo direto, tensão do eixo da quadratura, velocidade do motor, torque, corrente do eixo direto, corrente do eixo em quadratura, temperatura da superfície do ímã permanente, temperatura na culatra do estator e temperatura do dente do estator. O

resultado obtido provou-se adequado, no entanto demanda elevado custo computacional, já que a arquitetura da rede empregada utiliza duas ou mais camadas ocultas. Além disso, o modelo solicita entradas de difícil mensuração em um motor em operação, como é o caso da temperatura da superfície do ímã permanente, da temperatura na culatra do estator e da temperatura do dente do estator.

Em [37] investiga-se a aplicação de redes recorrentes e convolucionais profundas na estimação de temperaturas latentes de alta dinâmica de um PMSM. Nesse trabalho as quatro temperaturas alvo – do ímã permanente, da culatra do estator, do dente do estator e do enrolamento do estator – foram estimadas paralelamente por cada uma das redes. Então as diferentes arquiteturas foram comparadas com base na precisão e custo computacional de aplicação em tempo real. Ambas as arquiteturas obtiveram resultados satisfatórios, contudo, devido à alta complexidade das mesmas, sua aplicação pode ser comprometida. Isso se deve a dificuldade em embarcá-las para que sejam aplicáveis a um PMSM em operação.

O problema de estimação térmica em PMSM por meio da aplicação da rede NARX é abordado em [36]. As preditoras utilizadas foram: magnitudes de corrente, tensão, velocidade e temperatura do líquido de resfriamento. O desempenho da rede foi medido pela raiz do erro quadrático médio normalizada. A rede NARX buscou estimar o módulo da temperatura em pontos críticos do estator e no ímã permanente, entretanto a rede não conseguiu alcançar resultados satisfatórios. Sendo assim, foi proposta uma alteração no projeto da rede, a qual passou a estimar a diferença de temperatura entre o valor atual e o anterior. Após reajustada, a performance foi melhorada. Contudo, como a alternativa encontrada lida com uma diferença de temperaturas, essa medida deve ser mensurada em pequena magnitude, demandando o uso de sensores de precisão.

Percebe-se que os trabalhos supra citados são bastante recentes, demonstrando que a estimação da temperatura no interior de motores PMSM ainda é um desafio em aberto e estudos envolvendo a aplicação de RNAs podem trazer novas contribuições.

3.2. BASE DE DADOS

Os dados que deram suporte ao estudo desse problema foram disponibilizados por [40]. Essa base de dados versa a respeito de alguns ensaios de tração de um PMSM trifásico

de 52 kW. Os dados disponibilizados são amostras multivariadas capturadas a uma frequência de 2 Hz. As informações a respeito da aquisição dos dados são descritas em [41]. Os ensaios disponibilizados correspondem a 52 perfis de operação que refletem as condições de operação do motor nos testes, cada um deles possuindo diferentes quantidades de dados.

O banco de dados é composto por medidas de: temperatura ambiente (t_a) e do líquido refrigerante (t_c); corrente e tensão nos eixos direto e em quadratura do estator (i_d, i_q, u_d, u_q); velocidade do motor (s_m); torque (T); e as temperaturas no ímã permanente (t_{pm}) e no dente (t_{tooth}), enrolamento ($t_{winding}$) e culatra do estator (t_{yoke}).

3.3. PRÉ-PROCESSAMENTO DE DADOS ABORDADO POR CORRELAÇÃO

A base de dados foi dividida em dois conjuntos: treino e teste, a fim de realizar a validação cruzada para verificar a generalização do modelo. O primeiro conjunto recebeu cerca de 70% dos perfis de operação, que corresponde a 37 perfis de uso do motor, e foi usado durante o estágio de aprendizagem. O segundo conjunto ficou com os demais dados, 15 perfis, e foi usado para avaliar a performance do modelo. Na divisão desses dados optou-se por adicionar os perfis de operação de menor duração no conjunto de treino, e conseqüentemente os dados de maior duração no conjunto de teste. Essa opção visa reduzir o tempo de treinamento do modelo. Desse modo a divisão dos dados atingiu a proporção de 50% para cada conjunto.

Em seguida os dados foram normalizados, utilizando a técnica Z-score, tendo como base a média e variância dos dados de treinamento. Essa estratégia visa mitigar problemas de saturação na modelagem.

Então, passou-se para etapa de selecionar as variáveis de entrada e saída do modelo. O problema de monitoramento da temperatura no PMSM se fundamenta na dificuldade em mensurar de maneira confiável e econômica as temperaturas no ímã permanente e no estator ($t_{pm}, t_{yoke}, t_{tooth}$ e $t_{winding}$) durante a atividade, especialmente na aplicação automotiva. Sendo assim, a proposta é obter um modelo capaz de estimar essas temperaturas.

Para modelagem do estimador tem-se disponível as demais variáveis disponibilizadas pela base de dados, as quais já são comumente mensuradas nos veículos elétricos para fins de controle, tornando o modelo de fácil aplicação.

Uma vez separadas as variáveis alvo de temperatura, as demais variáveis da base de dados foram investigadas quanto a correlação, conforme visto na Tabela 3.1. Esse procedimento permite conhecer aquelas variáveis que possuem alta correlação com as demais, podendo ser descartadas. Essa estratégia visa a redução do custo computacional.

Tabela 3.1 Correlação entre as variáveis preditoras.

	t_a	t_c	u_d	u_q	s_m	T	i_d	i_q
t_a	1,000	0,480	0,249	0,048	0,000	-0,263	0,089	-0,253
t_c	0,480	1,000	0,178	-0,031	-0,095	-0,164	0,156	-0,156
u_d	0,249	0,178	1,000	0,012	-0,178	-0,824	0,332	-0,800
u_q	0,048	-0,031	0,012	1,000	0,715	-0,053	-0,144	-0,040
s_m	0,000	-0,095	-0,178	0,715	1,000	0,011	-0,695	-0,005
T	-0,263	-0,164	-0,824	-0,053	0,011	1,000	-0,252	0,997
i_d	0,089	0,156	0,332	-0,144	-0,695	-0,252	1,000	-0,217
i_q	-0,253	-0,156	-0,800	-0,040	-0,005	0,997	-0,217	1,000

Fonte: Autoria Própria

Analisando a Tabela 3.1 é possível perceber a alta correlação entre as variáveis u_d , T e i_q , permitindo eliminar duas delas. Opta-se por eliminar a variável T , pois sua aquisição é difícil e imprecisa no motor em operação. Dentre as opções restantes foi mantido i_q , pois possuía maior correlação com as eliminadas. Além disso, considerando o aspecto físico do PMSM sabe-se que T é proporcional a i_q :

$$T = \frac{3}{2}N[\lambda_{pm} + (L_d - L_q)i_d]i_q \quad (19)$$

onde L_d e L_q correspondem as indutâncias nos eixos direto e em quadratura do estator, N ao número de par de polos do motor e λ_{pm} é o fluxo magnético concatenado do imã permanente.

Uma vez definidos os alvos e as preditoras do modelo os dados encontram-se preparados para serem aplicados no ajuste do modelo.

3.4. ESTIMAÇÃO CONJUNTA DAS SAÍDAS

Conforme mencionado anteriormente, o método escolhido para modelagem do estimador de temperaturas foi a rede NARX, devido a sua capacidade para prever séries temporais. Uma vez que a rede NARX tem capacidade de estimar os 4 parâmetros pretendidos simultaneamente e as temperaturas buscadas apresentam correlação de média a alta entre si, conforme exibido na Tabela 3.2, então, numa primeira análise, decidiu-se por utilizar uma única rede (nn).

Tabela 3.2 Correlação entre as variáveis de saída.

	t_{pm}	t_{yoke}	t_{tooth}	$t_{winding}$
t_{pm}	1,000	0,667	0,729	0,669
t_{yoke}	0,667	1,000	0,945	0,826
t_{tooth}	0,729	0,945	1,000	0,959
$t_{winding}$	0,669	0,826	0,959	1,000

Fonte: Autoria Própria

A rede NARX é caracterizada pelo uso de recorrência e atrasos temporais tanto na entrada quanto na realimentação. A quantidade de atrasos precisa ser configurada pelo projetista, assim como os demais parâmetros comumente configurados nas redes alimentadas adiante, dentre eles: número de neurônios de cada camada, função de ativação de cada neurônio e algoritmo de aprendizagem.

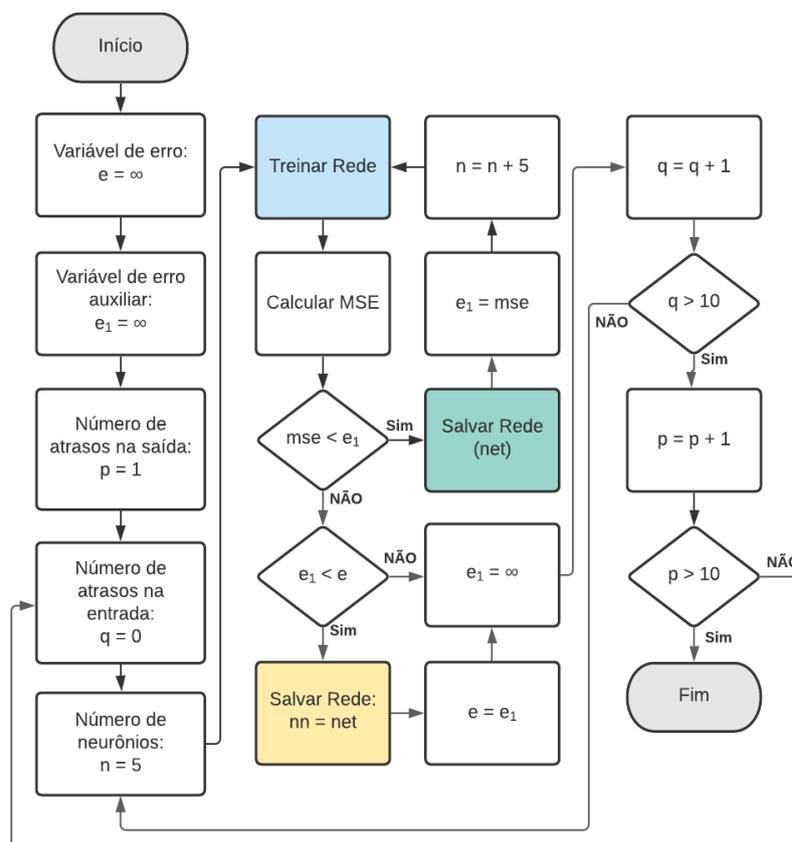
A função de ativação utilizada nos neurônios da camada oculta foi a tangente hiperbólica, a qual, além de ser derivável em toda a sua extensão, traz a vantagem de poder assumir tanto valores positivos quanto negativos. Na camada de saída, a função de ativação empregada foi a linear.

O algoritmo de aprendizagem aplicado foi o de Levenberg-Marquardt, empregando-se a função “*trainlm*” do Matlab[®]. Foram mantidos os parâmetros de aprendizagem pré definidos pelo software, com exceção do método de divisão dos dados de treinamento. O método selecionado para divisão de dados, “*divideblock*”, consiste em dividi-los em três subconjuntos formados por blocos contíguos, mantendo a informação temporal do problema.

Essa divisão é utilizada pela *toolbox* para avaliar a generalização da RNA. Utilizou-se a arquitetura NARX série-paralela durante o treinamento.

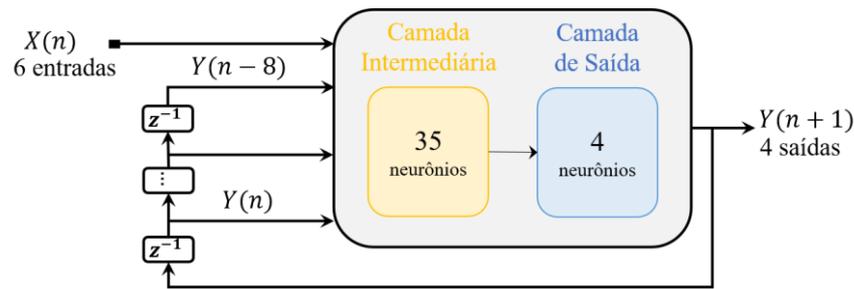
O número de neurônios e atrasos da rede foi definido por meio de tentativas, escolhendo-se a configuração na qual o aumento desses parâmetros não agregava melhora significativa de precisão ao modelo (considerando os dados de treino), portanto, não havendo razão para o incremento de custo computacional. As tentativas foram realizadas conforme ilustrado na Figura 3.1. Assim, obteve-se a melhor configuração da rede nn a partir de diversas iterações nas quais são incrementados neurônios, n , na camada oculta e atrasos, p e q , na realimentação e na entrada, respectivamente.

Figura 3.1 Diagrama de treinamento da Rede nn .



Fonte: Autoria Própria

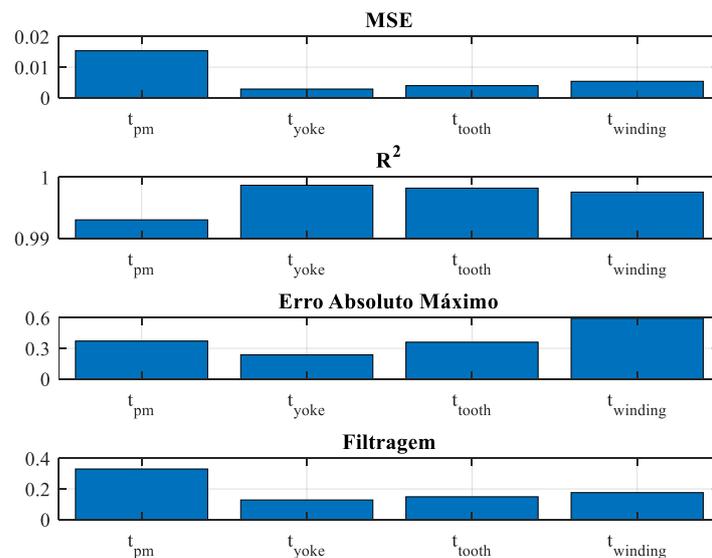
A configuração final para a rede nn é ilustrada na Figura 3.2, apresentando nenhum atraso na entrada, 9 atrasos na realimentação e 35 neurônios na camada oculta. Destaca-se que, como a saída é estimada em um momento futuro, os 9 blocos de atraso permitem a realimentação das amostras correspondentes ao momento atual e dos últimos 8 instantes.

Figura 3.2 Estrutura da Rede nn .

Fonte: Autoria Própria

3.4.1. Resultados

Após o ajuste dos pesos sinápticos da rede, realizado via *toolbox* do Matlab[®] e obtido em 61 épocas, esta foi modificada para a arquitetura paralela e os dados de teste foram apresentados a ela. O desempenho da rede nessa avaliação é exibido na Figura 3.3.

Figura 3.3 Desempenho da Rede nn .

Fonte: Autoria Própria

Note que nesse problema não é mensurada a robustez, pois não faz sentido segundo a sua definição apresentada na seção 2.3.3, visto que a rede não estima suas entradas exógenas. Da mesma forma, o espalhamento não é computado, pois não traz informações relevantes para esse tipo de problema. Em contrapartida é apresentado o erro absoluto máximo na estimação dos dados de treino.

Os valores de MSE demonstram uma estimação bastante precisa, com erros inferiores a 0,02. O coeficiente de desempenho demonstra alta adequação entre os dados estimados e seus alvos. O erro absoluto máximo apresenta que, mesmo nos pontos em que a rede tem maior dificuldade de estimar, a diferença entre dados reais e estimados é diminuta.

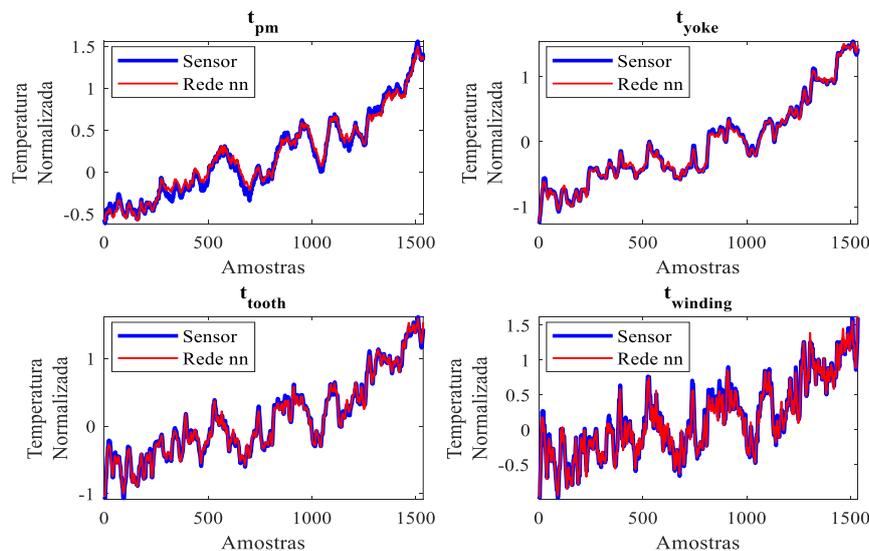
A filtragem denota baixa sensibilidade do modelo a um ruído. A análise detalhada do efeito do ruído é mostrada na Tabela 3.3. Observa-se que as saídas têm boa tolerância a ruídos nos dados de entrada, sendo t_{pm} a saída mais afetada e t_c a entrada que mais afeta as saídas.

Tabela 3.3 Sensibilidade ao Ruído.

	t_{pm}	t_{yoke}	t_{tooth}	$t_{winding}$
t_a	0,219	0,091	0,103	0,116
t_c	0,781	0,232	0,212	0,182
u_q	0,220	0,093	0,112	0,135
s_m	0,267	0,107	0,138	0,185
i_d	0,232	0,111	0,146	0,200
i_q	0,265	0,132	0,182	0,237

Fonte: Autoria Própria

A comparação entre os dados reais e estimados pela rede para o perfil que obteve melhor desempenho, considerando o MSE, pode ser vista na Figura 3.4.

Figura 3.4 Comparação entre os dados dos Sensores e os Estimados pela Rede nn .

Fonte: Autoria Própria

3.5. ESTIMAÇÃO DAS SAÍDAS SEPARADAMENTE

Percebe-se na Figura 3.3 e na Figura 3.4 que a rede nn tem mais dificuldade em estimar t_{pm} , que é justamente a saída de menor correlação entre as demais. Portanto, para verificar se essa saída não estava sendo prejudicada ao ser estimada junto com as demais, foram desenvolvidas quatro novas redes, uma para estimar cada saída. As redes NARX foram nomeadas: nn_{pm} , nn_{yoke} , nn_{tooth} e $nn_{winding}$, referindo-se os estimadores das temperaturas t_{pm} , t_{yoke} , t_{tooth} e $t_{winding}$, respectivamente.

A metodologia para configuração e treinamento das novas redes foi similar a aplicada a rede nn , mostrada na Figura 3.1. A partir desse método, foram encontradas as redes NARX cujas configurações são descritas na Tabela 3.4. Percebe-se que estimando os sensores separadamente foram encontradas redes mais simples, entretanto, que demandaram mais memória e precisaram de mais épocas para serem ajustadas.

Tabela 3.4 Configuração das Redes NARX.

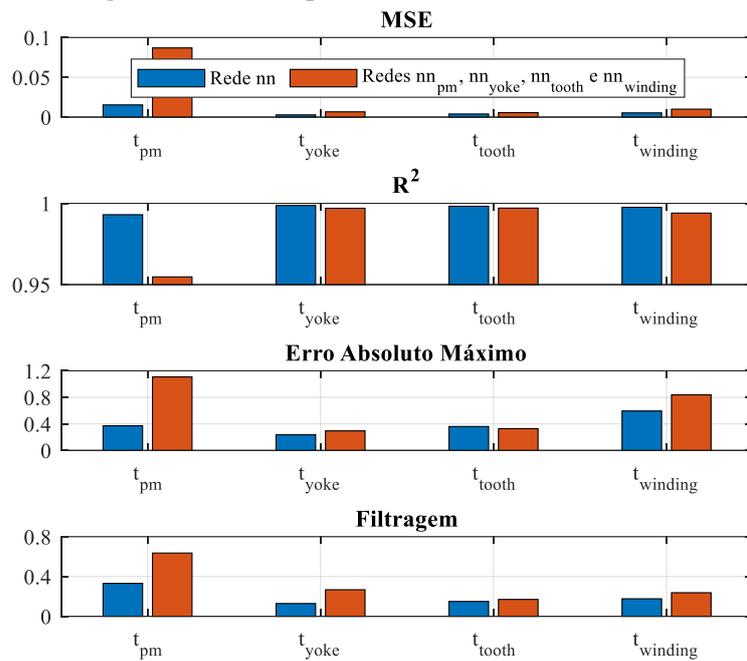
	nn_{pm}	nn_{yoke}	nn_{tooth}	$nn_{winding}$
Atrasos na entrada	3	6	5	5
Atrasos na realimentação	10	10	7	3
Neurônios na camada Intermediária	20	5	10	5
Épocas	239	142	197	181

Fonte: Autoria Própria

3.5.2. Resultados

Como na abordagem anterior, os dados de teste foram apresentados às redes e foram avaliadas as métricas de desempenho. Em seguida as métricas foram comparadas a solução anterior, conforme Figura 3.5. Percebe-se que as estimativas de nn obtiveram resultados melhores ou praticamente equivalentes aos das novas redes. Isso prova a vantagem de realimentar as saídas bem correlacionadas e demonstra a ineficácia de separar a saída t_{pm} .

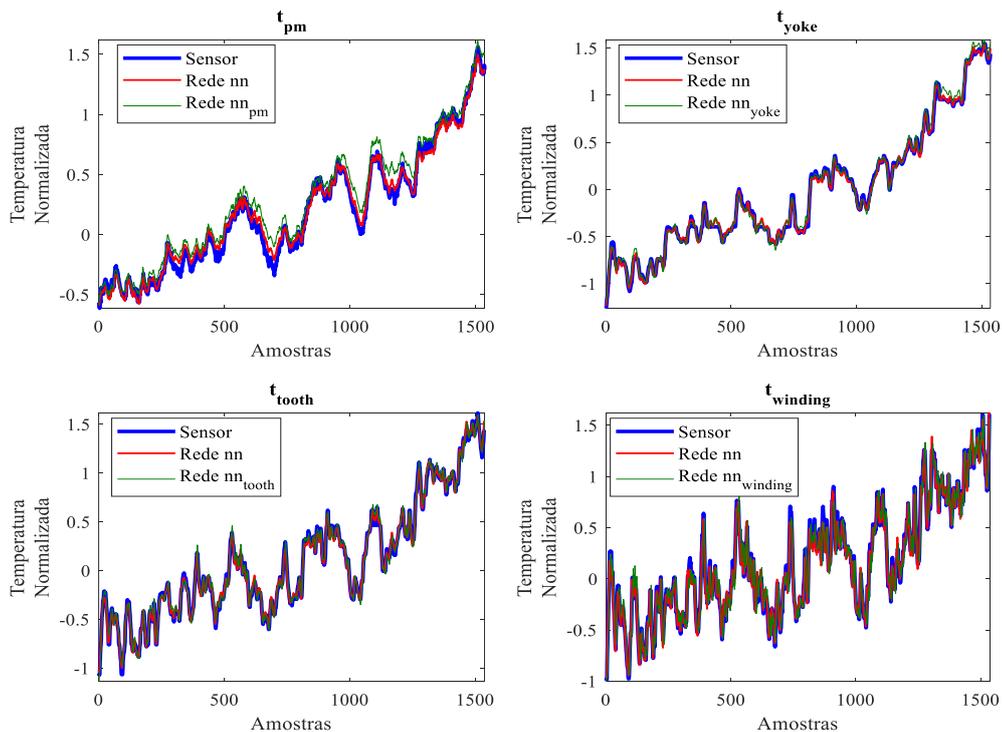
Figura 3.5 Desempenho das Redes NARX.



Fonte: Autoria Própria

Confirmando as conclusões obtidas pela avaliação das métricas de desempenho, a Figura 3.6 ilustra como a estimação a partir de uma única rede, *nn*, aproximou-se mais dos dados capturados pelos sensores do que a estimação realizada por redes diferentes.

Figura 3.6 Comparação entre dados dos Sensores e Estimados pelas Redes NARX.



Fonte: Autoria Própria

3.6. PRÉ-PROCESSAMENTO DE DADOS ABORDADO POR PCA

Buscando reduzir ainda mais o custo computacional, uma terceira abordagem foi examinada. Os mesmos dados, já normalizados e separados em conjunto de treino e teste, foram avaliados pelo método de análise das componentes principais (*Principal Component Analysis* – PCA) a fim de reduzir o número de parâmetros de entrada e/ou saída da rede. Desse modo, buscou-se estimar os dados de temperatura utilizando a transformação dos dados reais para um sistema de coordenadas baseado nas componentes principais (X_{PC}) e, após a estimação, retornando as estimações obtidas no sistema de coordenadas das componentes principais (Y_{PC}) para o sistema de coordenadas real, conforme ilustrado na Figura 3.7.



Da mesma maneira que na abordagem por correlação, os dados de entrada e saída do modelo foram analisados separadamente. A análise foi realizada usando os autovetores da matriz de covariância, também denominados raízes latentes (lat_{in}), que indicam a quantidade de variância explicada por cada componente principal. Em seguida, a fim de simplificar essa informação, esses valores foram transformados para a forma de porcentagem. Assim,

$$lat_{in}[\%] = [40,35 \quad 23,93 \quad 16,12 \quad 9,62 \quad 6,25 \quad 3,06 \quad 0,64 \quad 0,03] \quad (20)$$

Esses valores demonstram que as três últimas componentes principais detêm menos de 4% de informação acerca da variância dos dados de entrada. Por essa razão, é possível remover essas duas componentes do modelo sem prejuízos significativos de informação. Assim, a abordagem por PCA obtém a redução de três variáveis de entrada da rede, uma variável a menos que a abordagem por análise de correlação.

Posteriormente foram analisados os dados de saída, da mesma maneira descrita previamente, obtendo-se como raízes latentes em porcentagem:

$$lat_{out}[\%] = [85,30 \quad 10,24 \quad 4,40 \quad 0,06] \quad (21)$$

Essa avaliação demonstra que é possível desconsiderar as duas últimas componentes principais com um custo de perda de informação acerca da variância dos dados de saída

inferior a 5%. Logo, a PCA contribuiu com a redução da quantidade de dados a ser apresentada à rede para modelagem do estimador.

A transformação dos dados reais para componentes principais e vice-versa é realizada por meio da matriz de vetores singulares a direita (V), obtida pela decomposição de valores singulares dos dados de treino. Assim,

$$X_{PC} = X * V_{in} \quad (22)$$

$$Y = Y_{PC} * V'_{out} \quad (23)$$

onde V_{in} é a matriz de vetores singulares a direita dos dados de entrada e V_{out} é a matriz de vetores singulares a direita dos dados de saída.

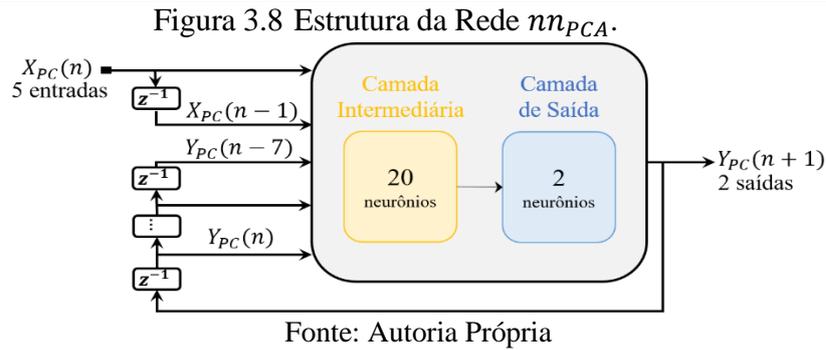
$$V_{in} = \begin{bmatrix} 0,237 & -0,076 & -0,682 & 0,088 & -0,682 & -6.10^{-5} & 0,001 & 0,005 \\ 0,188 & 0,051 & -0,662 & 0,013 & 0,723 & 0,012 & 0,011 & -2.10^{-4} \\ 0,500 & -0,042 & 0,150 & -0,003 & 0,028 & -0,830 & -0,185 & 0,045 \\ -0,025 & -0,539 & -0,046 & 0,692 & 0,009 & -0,097 & 0,467 & 0,004 \\ -0,126 & -0,659 & -0,030 & 0,0137 & 0,060 & 0,118 & -0,729 & 0,015 \\ -0,542 & 0,165 & -0,185 & -0,107 & -0,031 & -0,310 & -0,087 & 0,727 \\ 0,253 & 0,455 & 0,016 & -0,692 & -0,069 & 0,232 & -0,436 & 0,032 \\ -0,533 & 0,175 & -0,191 & -0,150 & -0,038 & -0,3715 & -0,138 & -0,684 \end{bmatrix} \quad (24)$$

$$V_{out} = \begin{bmatrix} -0,439 & -0,897 & 0,006 & 0,050 \\ -0,514 & 0,277 & 0,723 & 0,370 \\ -0,533 & 0,215 & -0,043 & -0,817 \\ -0,509 & 0,269 & -0,689 & 0,439 \end{bmatrix} \quad (25)$$

3.7. ESTIMAÇÃO DAS COMPONENTES PRINCIPAIS DE SAÍDA

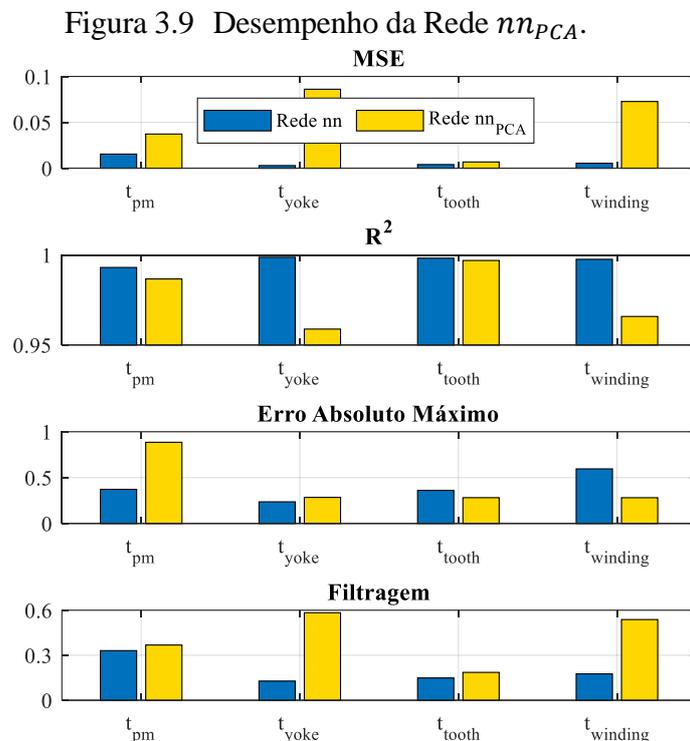
Diferente das redes anteriores, nessa abordagem a rede NARX não foi utilizada para estimar as temperaturas nos pontos críticos do PMSM diretamente, mas para calcular suas projeções no sistema de coordenadas das PCs. A essa rede foi dada o nome de nn_{PCA} .

A metodologia para configuração e treinamento da rede nn_{PCA} foi idêntica a aplicada a rede nn , exibida na Figura 3.1. A configuração final para nn_{PCA} , obtida em 168 épocas, é apresentada na Figura 3.8.



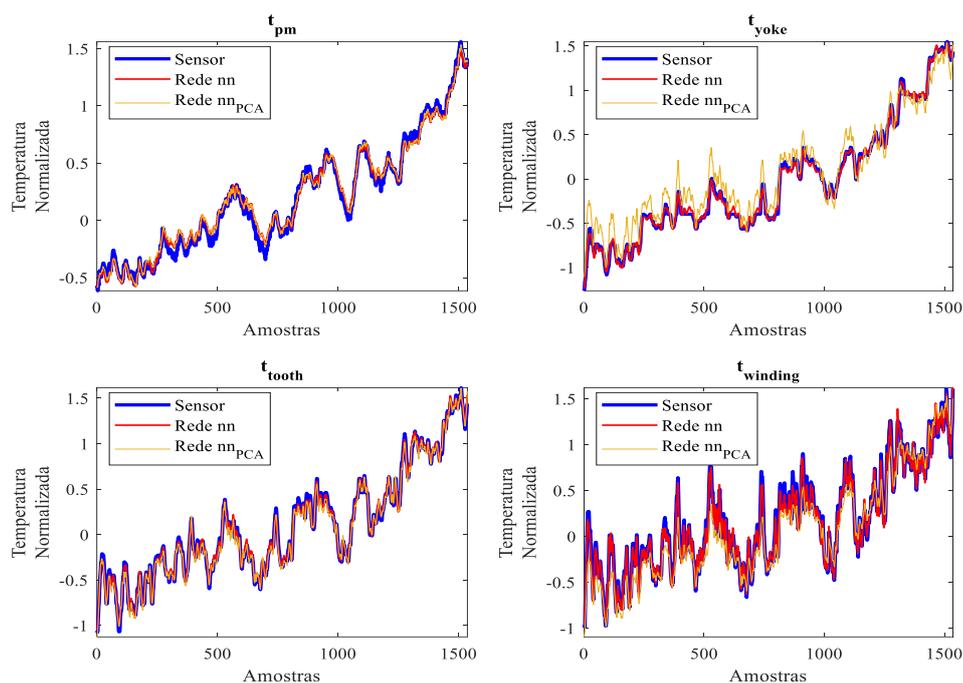
3.7.2. Resultados

Como nas abordagens anteriores, os dados de teste foram apresentados à rede. Entretanto, foi exigida mais uma etapa para estimação das temperaturas, conforme foi descrito na Figura 3.7, que consiste na transformação das saídas da rede para o sistema de coordenadas real. Somente após essa transformação as métricas foram avaliadas e comparadas com a solução obtida por nn . Essa comparação é exibida na Figura 3.9, onde se observa que a nn_{PCA} teve desempenho inferior considerando a maioria das métrica analisadas.



Fonte: Autoria Própria

A comparação entre as estimativas das redes nn e nn_{PCA} e os dados adquiridos pelos sensores para um dos perfis de teste pode ser observada na Figura 3.10.

Figura 3.10 Comparação entre dados dos Sensores e Estimados pelas Redes nn e nn_{PCA} .

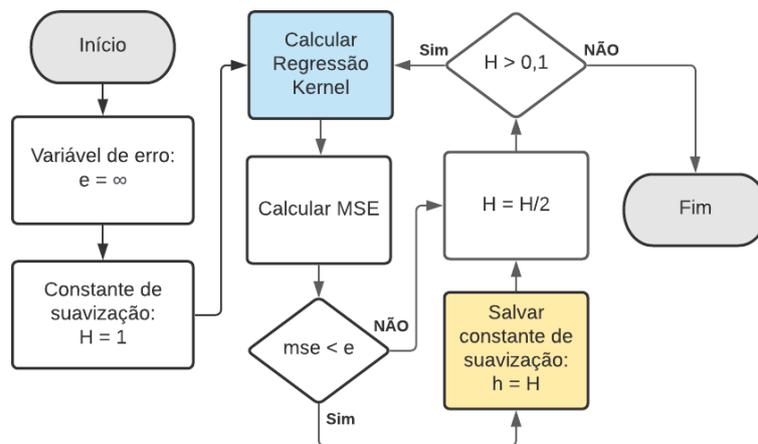
Fonte: Autoria Própria

Embora tenha sido usado diferentes abordagens, todas foram bem sucedidas, comprovando que a rede NARX é eficiente para a estimação das temperaturas nos pontos críticos do PMSM. Sendo assim, é possível aplicá-la para garantir um monitoramento confiável, e conseqüentemente auxiliar na durabilidade e desempenho desse motor.

3.8. COMPARAÇÃO COM A REGRESSÃO KERNEL

Os dados pré-processados pela abordagem por correlação foram usados para modelar um estimador por regressão kernel. Foram usados diferentes constantes de suavização para buscar o melhor ajuste do estimador, conforme Figura 3.11. A função kernel utilizada foi a Gaussiana.

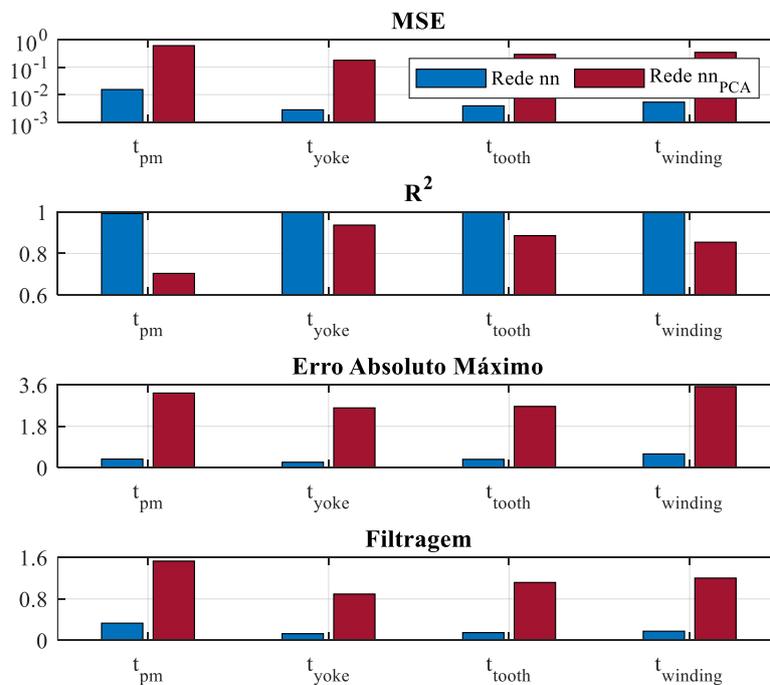
Figura 3.11 Diagrama de ajuste da Regressão Kernel.



Fonte: Autoria Própria

O valor que obteve melhor precisão foi para $h = 0,5$. Contudo, ainda assim os erros de estimação foram cerca de dez vezes maiores que os encontrados para as estimações usando NARX. Além disso, o modelo demonstrou-se bastante sensível a erros na entrada do tipo ruído, conforme mostrado na Figura 3.12.

Figura 3.12 Desempenho da Regressão Kernel.



Fonte: Autoria Própria

Sendo assim, constatou-se que essa técnica não obteve êxito na estimação das temperaturas do PMSM. Desse modo, para melhorar sua atuação na predição, o ideal seria associar essa técnica a alguma outra, como foi realizado em [42]. A associação de métodos kernel com outras técnicas é bastante comum, e também pode ser visto em [43] e [44].

3.9. CONCLUSÃO

O problema investigado nesse capítulo trata da estimação de temperatura nos pontos críticos do PMSM, locais onde a implantação de sensores é complexa e/ou a manutenção dos mesmos também é dificultosa. O monitoramento da temperatura nesses pontos é imprescindível para garantir que o motor não terá seu desempenho comprometido pelo desgaste térmico de seus componentes sensíveis ao calor.

A rede NARX foi capaz de estimar essas temperaturas com bastante precisão nas três abordagens investigadas. A primeira abordagem utilizou a análise de correlação para selecionar as variáveis preditoras e uma única rede para estimar todas as saídas. A segunda utilizou as mesmas preditoras da primeira, mas foram estimadas as saídas separadamente, usando uma rede para cada. Essa abordagem foi investigada pois desejava-se melhorar a estimação da variável t_{pm} , que, por não apresentar uma correlação tão alta com as demais variáveis de saída, poderia ter sido afetada negativamente ao estimá-la junto as demais temperaturas alvo. Contudo, percebeu-se que não houve melhora em estimar cada temperatura separadamente, pelo contrário, os resultados foram inferiores.

A terceira abordagem utilizou a PCA para selecionar as preditoras do modelo, e conseguiu reduzir o número de entradas e saídas, reduzindo o custo computacional do modelo, entretanto essa redução causou piora de desempenho na estimação das variáveis alvo.

O sucesso da rede NARX para estimação das temperaturas nos pontos críticos do PMSM revela uma maneira interessante em solucionar o problema de monitorá-las, garantindo que os componentes do motor sensíveis ao calor não serão desgastados. A abordagem que obteve melhores resultados utiliza como preditoras variáveis que já são adquiridas em veículos elétricos para fins de controle, logo pode ser facilmente aplicada.

4. VALIDAÇÃO DE SENSORES

4.1. O PROBLEMA

A detecção de faltas em sensores é uma tarefa difícil, uma vez que são esses os responsáveis por observar o processo e entregar as informações a respeito do seu funcionamento, inclusive a ocorrência de falhas nos demais dispositivos. Por essa razão, a validação de sensores é um assunto de extrema importância para processos cujo controle é baseado em medições de sensores. Na indústria de petróleo e gás, por exemplo, a aquisição confiável de dados do processo é fundamental para garantir não apenas bom desempenho, mas também a segurança do sistema [45].

Uma técnica bastante utilizada para validar a informação adquirida pelo sensor é a utilização de um ou mais sensores em redundância. No entanto, essa técnica, nomeada redundância física, traz algumas desvantagens. São elas: o alto custo envolvido, tanto para aquisição e instalação, quanto para manutenção dos sensores adicionais; e, em alguns casos, a impossibilidade de aplicação devido ao espaço físico disponível para instalação [46].

Uma alternativa ao método anterior é a chamada redundância analítica, na qual um modelo matemático é criado, a partir de outros sensores com os quais o estimado é bem correlacionado, permitindo detectar falhas na medição [47]. Além disso, essa alternativa permite que o processo funcione mesmo que o sensor apresente um certo grau de imprecisão, já que é capaz de realizar a compensação. Isso reduz a necessidade de paradas para calibração, sendo assim, essas estimativas também podem ser usadas como base para elaboração de um plano de manutenção/calibração dos sensores.

Por essas razões, a redundância analítica aplicada a validação de sensores é alvo recorrente de estudos. Busca-se encontrar novos métodos, cada vez mais confiáveis, e que permitam sua aplicação em tempo real. Em [33] tem-se um exemplo do uso de redundância analítica para validação de sensores. A abordagem empregada nesse artigo, baseada na AAKR, já foi relatada na seção 2.2.

Três métodos diferentes são empregados para esse mesmo fim em [48]. São eles: AAKR, similaridade Fuzzy e rede Elman. O problema abordado refere-se à detecção de falhas em sensores de temperatura de uma máquina rotativa. O desempenho de cada método é avaliado por meio das medidas de acurácia, robustez, espalhamento e velocidade de detecção de anomalias. A rede Elman mostrou-se mais precisa, além de ser resistente ao espalhamento, entretanto apresentou baixa robustez. A similaridade Fuzzy revelou-se pouco sensível ao ruído, mas teve baixa precisão. Já a AAKR apresentou alta velocidade de detecção de falha, no entanto demonstrou baixa resistência ao espalhamento. Por essa razão, a alternativa encontrada foi utilizar as técnicas associadas. Essa proposta superou as limitações das técnicas usadas individualmente, mas ainda carece de técnicas de otimização que potencialize o desempenho.

O método de AAKR também é aplicado na validação de sensores de uma planta de gás natural sintético em [49], mostrando-se robusto e capaz de detectar irregularidades. Novamente, em [5], o método AAKR é aplicado para validação de sensores, dessa vez aplicado a sensores da indústria de petróleo e gás natural. Nesse segundo artigo os modelos foram avaliados quanto a precisão e sensibilidade, obtendo bons resultados para ambas métricas de desempenho.

Embora o método AAKR apresente bons resultados de maneira geral, ele demanda alto custo computacional. Ainda assim, é uma boa base de comparação para avaliar novas estratégias propostas para validação de sensores.

Uma abordagem para validação de sensores baseada em rede NARX, será apresentada a seguir e em seguida será comparada ao método AAKR. Os dados que deram suporte ao estudo são provenientes de uma refinaria de petróleo e correspondem as medições de 115 sensores de temperatura empregados em seus reatores. A base de dados contém informações acerca de um ano de funcionamento amostradas em intervalos de 1 hora.

4.2. PRÉ-PROCESSAMENTO DE DADOS

A primeira etapa do pré-processamento de dados consistiu em verificar a presença de sensores cuja amostragem esteja com mais de 1% dos dados comprometidos e aqueles cujos

dados sejam constantes para mais de 10% das amostras. Apenas um sensor apresentou problema, sendo invalidado.

Em seguida os dados foram separados em 3 conjuntos – treino, teste e validação – a fim de avaliar a capacidade de generalização do modelo por meio da validação cruzada. Essa separação consistiu em selecionar os últimos 20% de amostras de cada sensor para o conjunto de validação, e, dos dados restantes, 70% foi adicionado ao conjunto de treino e os outros 30% para o conjunto de teste. A separação entre dados de treino e teste foi realizado por meio do método da veneziana, que consiste em dividir os dados por blocos temporais.

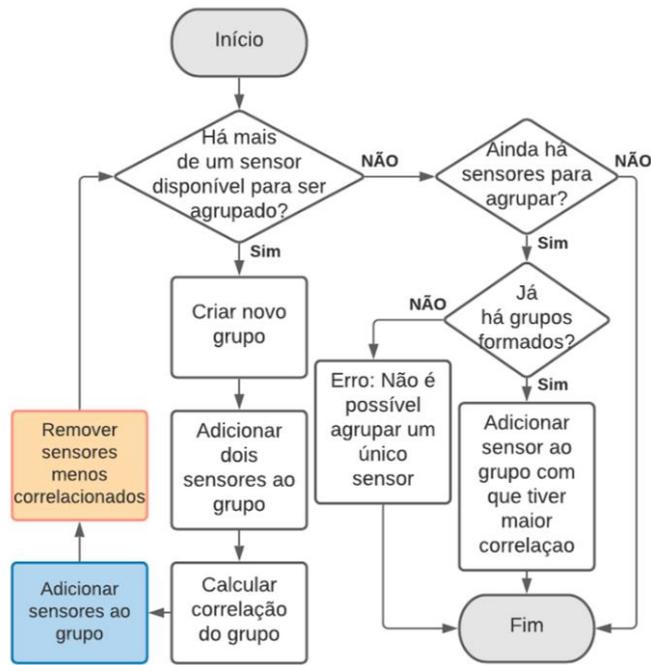
Depois, os sensores foram agrupados com base na correlação entre eles, conforme mostrado na Figura 4.1. O procedimento de agrupamento está resumido em (a), e seus blocos de adição e remoção de sensores dos grupos são exibidos em (b) e (c), respectivamente. A estratégia de agrupamento permite reduzir o problema global em subproblemas. Além disso, garante que toda informação entregue ao modelo será útil para estimação.

O processo de agrupamento resultou em quatro grupos, sendo eles constituídos por 3, 9, 12 e 90 sensores cada. Então, como um dos grupos ficou com um número muito grande de sensores, ele foi subdividido em grupos de 15 sensores cada. Dessa forma, evita-se o problema de saturar a rede devido a grande quantidade de entradas.

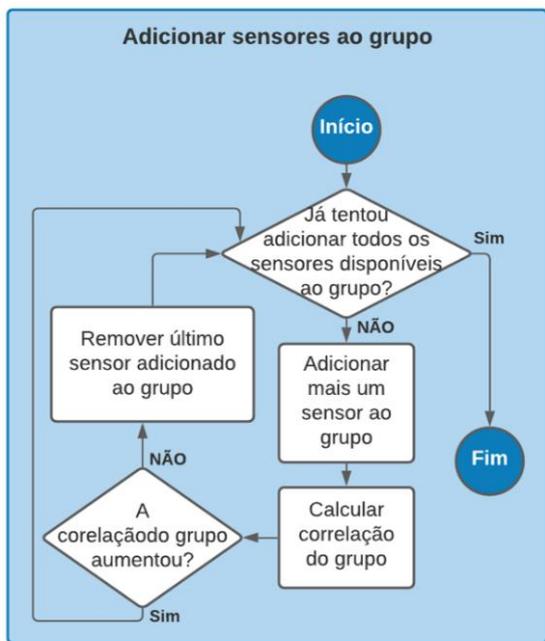
Avaliando os agrupamentos verificou-se que um dos sensores do grupo que possui apenas 3 sensores possuía correlação muito baixa com os demais, por isso foi excluído. Os grupos resultantes podem ser vistos na Figura 4.2, onde é expressa a matriz de correlação que deu base a esse agrupamento, por meio de um mapa de calor.

Posteriormente foram tirados os *outliers* dos dados de treino, a fim de evitar que os estimadores se ajustem a dados errôneos. Assim, os dados encontravam-se prontos para serem aplicados no ajuste dos modelos.

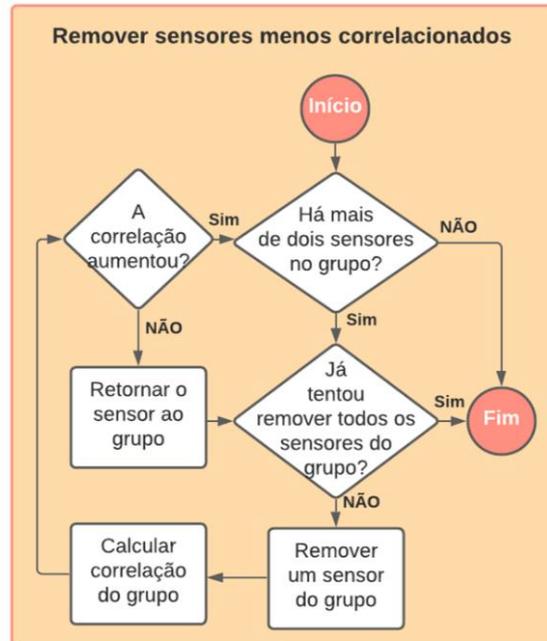
Figura 4.1 Diagrama de agrupamento dos sensores. (a) função principal;
 (b) função de adição de sensores; (c) função de remoção de sensores



(a)

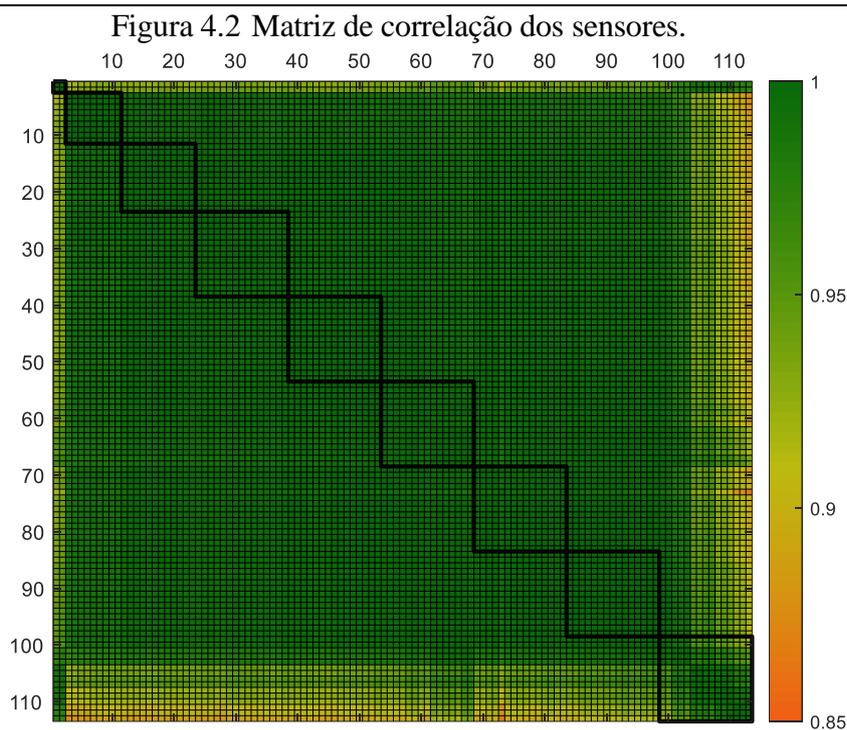


(b)



(c)

Fonte: Autoria Própria



4.3. CONFIGURAÇÃO DA REDE NARX

Uma vez que os sensores foram separados em grupos, cada grupo foi usado para ajustar uma RNA diferente, capaz de estimar os sensores daquele grupo. As redes NARX foram nomeadas: nn_1 , nn_2 , nn_3 , referindo-se aos grupos compostos por 2, 9 e 12 sensores, respectivamente, e nn_4 , nn_5 , nn_6 , nn_7 , nn_8 e nn_9 , para os de 15 sensores.

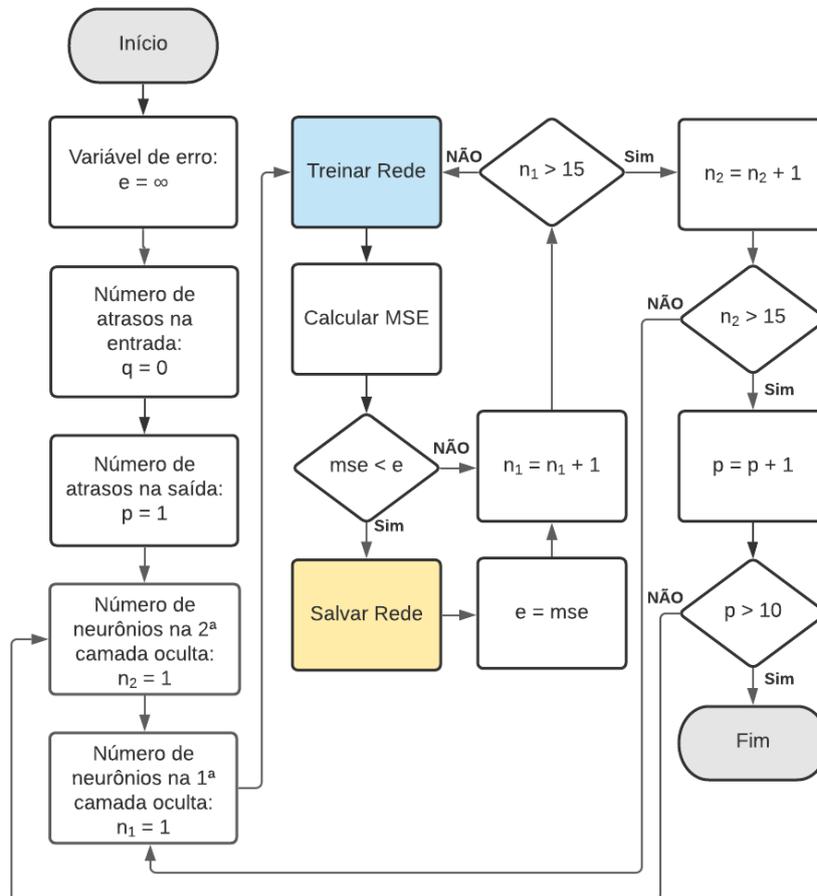
Cada rede foi configurada individualmente com número de atrasos e de neurônios independentes uma das outras. O que se manteve padrão entre as redes foi o uso da configuração série-paralela durante a etapa de treinamento, a função de ativação dos neurônios da camada de saída do tipo linear, a função de ativação dos neurônios da camada intermediária do tipo tangente hiperbólica, a função de treinamento do tipo retro propagação baseada em gradiente conjugado com atualizações de Fletcher-Reeves e a quantidade de atrasos na entrada de valor nulo.

Essa última padronização visa a redução da quantidade de memória demandada e se embasa no fato que, como as entradas exógenas e as realimentadas referem-se a uma mesma variável do sistema, e, em condições ótimas, devem possuir o mesmo valor, então não há necessidade da entrada de informações duplicadas na rede NARX.

Novamente as quantidades de neurônios e atrasos são definidas por experimentação.

Os experimentos seguem o procedimento descrito na Figura 4.3.

Figura 4.3 Diagrama de treinamento das Redes.



Fonte: Autoria Própria

Com o uso desse procedimento foram encontradas as redes apresentadas na Tabela 4.1. As redes alcançaram melhores resultados para configurações com poucos atrasos.

Tabela 4.1 Configuração das Redes NARX.

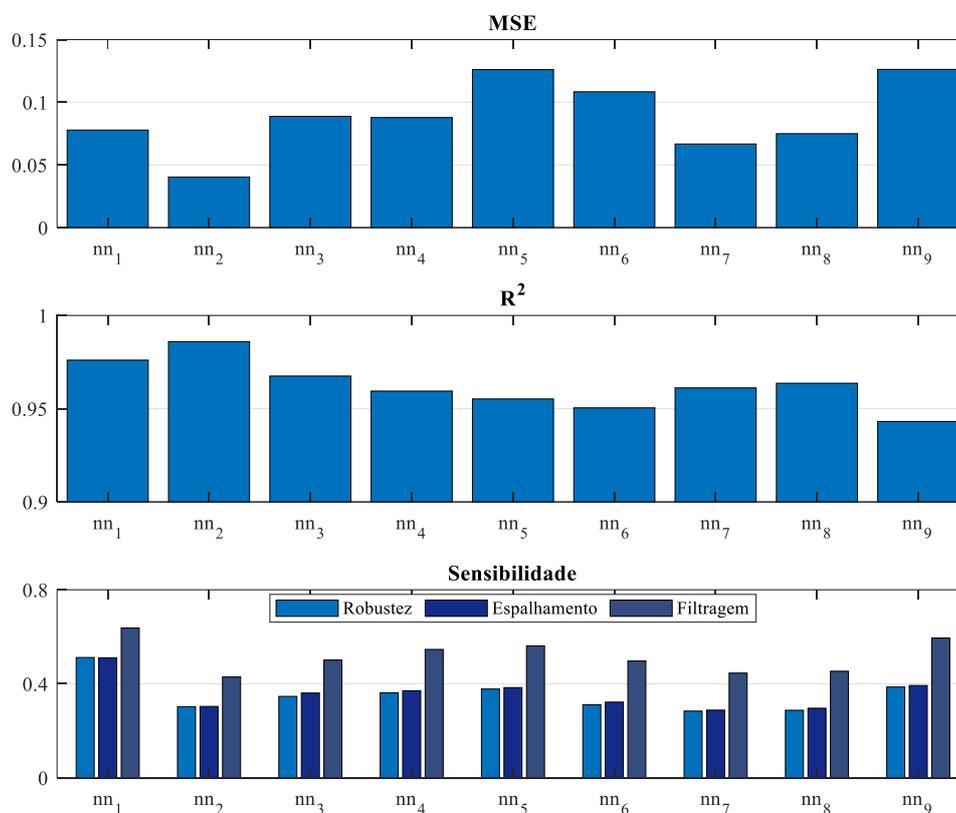
	nn_1	nn_2	nn_3	nn_4	nn_5	nn_6	nn_7	nn_8	nn_9
Atrasos na realimentação	3	1	2	1	1	1	1	1	1
Neurônios na 1ª camada Intermediária	2	6	8	6	13	4	9	12	13
Neurônios na 2ª camada Intermediária	5	1	8	7	6	4	6	1	6
Épocas	22	34	72	50	31	23	31	33	30

Fonte: Autoria Própria

4.4. RESULTADOS

Após a etapa de treinamento as redes foram modificadas para arquitetura paralela e seus respectivos dados de teste e validação foram apresentados a cada uma delas. A comparação do desempenho de cada grupo pode ser vista na Figura 4.4. Esses valores correspondem a média aritmética entre os desempenhos das estimações para cada sensor.

Figura 4.4 Desempenho das Redes NARX.

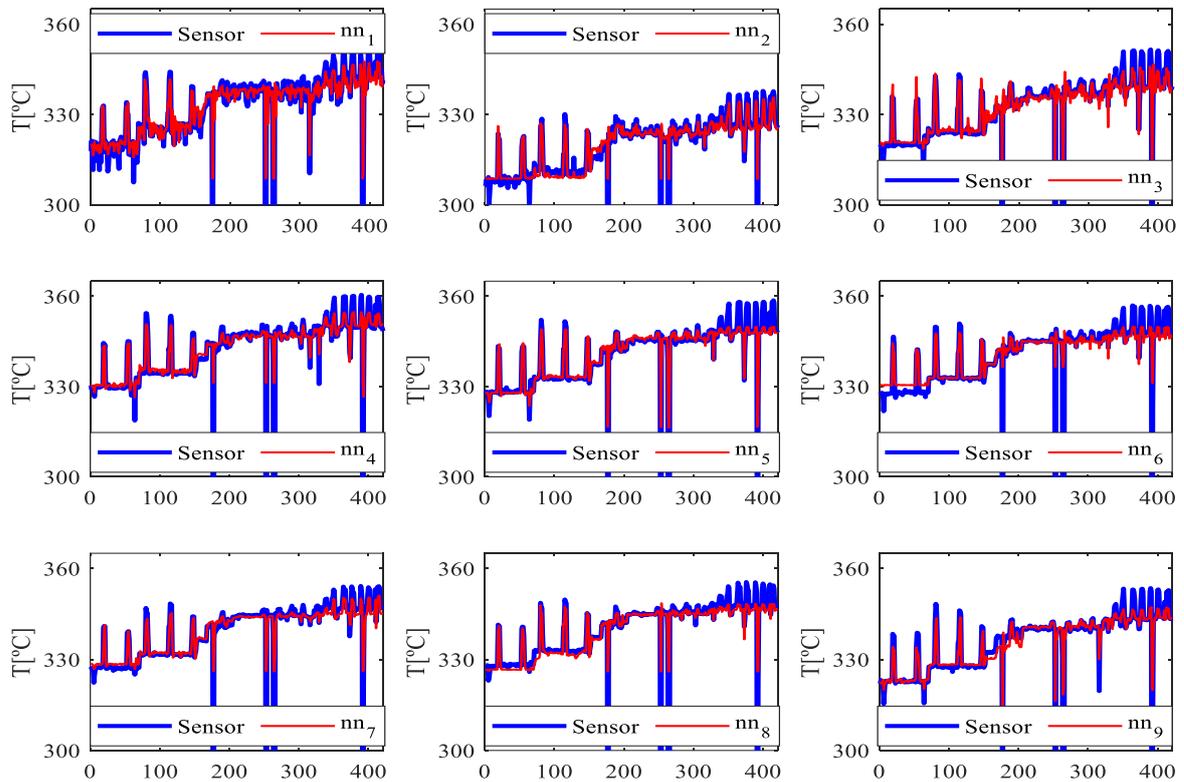


Fonte: Autoria Própria

Todos os grupos alcançaram estimações precisas, com MSE inferiores a 0,15. O valor do coeficiente de determinação sugere boa adequação dos dados estimados aos dados reais. A avaliação de sensibilidade trouxe informações importantes a respeito dos modelos, já que, de modo geral, são moderadamente sensíveis tanto ao *drift* quanto ao ruído, alcançando pior desempenho para esse segundo caso.

O comparativo entre as estimativas geradas pelos modelos e os dados reais para um sensor de cada grupo pode ser visto na Figura 4.5. Esse comparativo contém tanto os dados de teste quanto os dados de validação.

Figura 4.5 Comparação entre dados dos Sensores e Estimados pelas Redes NARX.



Fonte: Autoria Própria

4.5. ESTIMADORES APLICADOS NA DETECÇÃO DE FALHAS

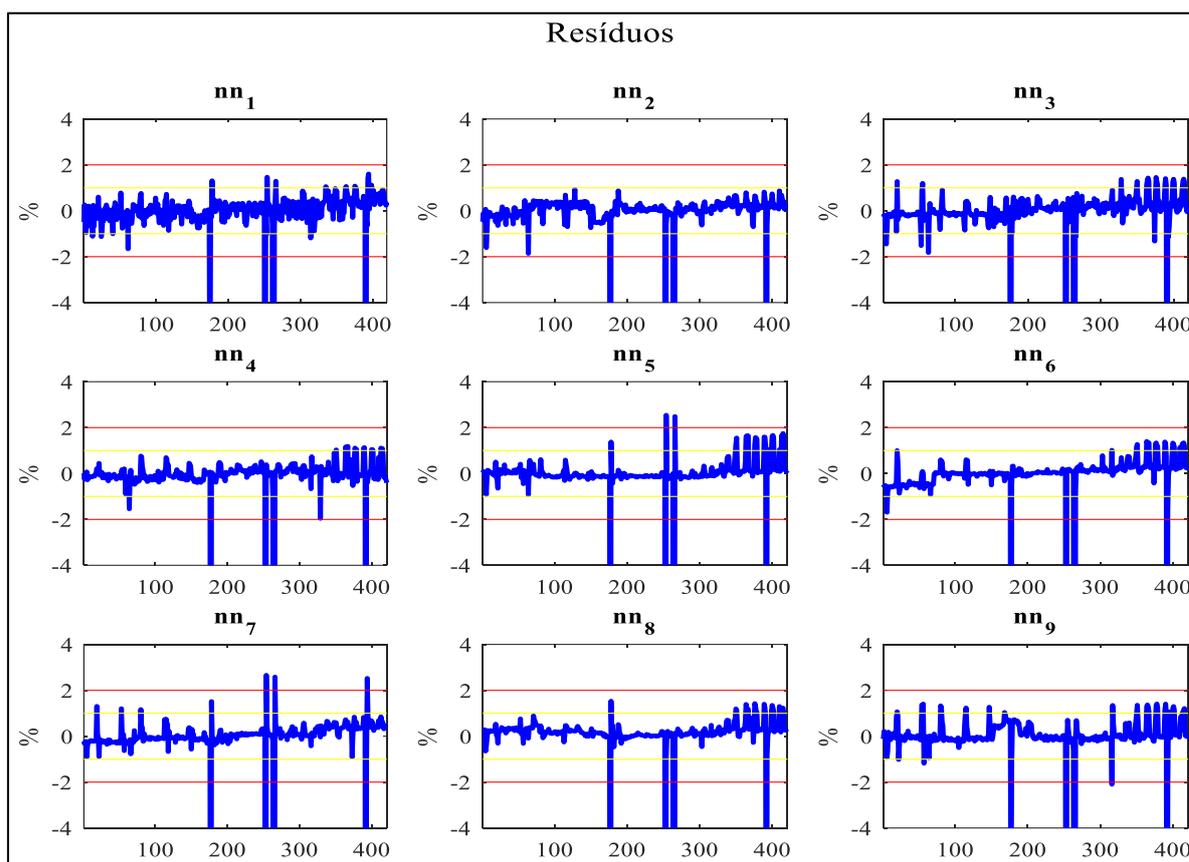
Para detecção de falhas foi calculado o resíduo, isto é, o erro instantâneo entre a aquisição real dos sensores e sua estimativa. Em seguida o resíduo foi convertido em porcentagem do intervalo de medição do sensor, conforme a Equação (26).

$$\text{Resíduo [\%]} = \frac{\text{Valor medido} - \text{Valor estimado}}{\text{URV} - \text{LRV}} * 100 \quad (26)$$

onde URV corresponde ao valor máximo do intervalo de medição do sensor e LRV ao valor mínimo desse intervalo.

Então, foi definido arbitrariamente um limiar fixo para o resíduo, de 2%, para a detecção de falhas. Sendo assim, sempre que o resíduo ultrapassar esse limiar considera-se um alerta de falha. Na Figura 4.6 são apresentados os resíduos das estimações mostradas anteriormente.

Figura 4.6 Redes NARX aplicadas na detecção de falhas.



Fonte: Autoria Própria

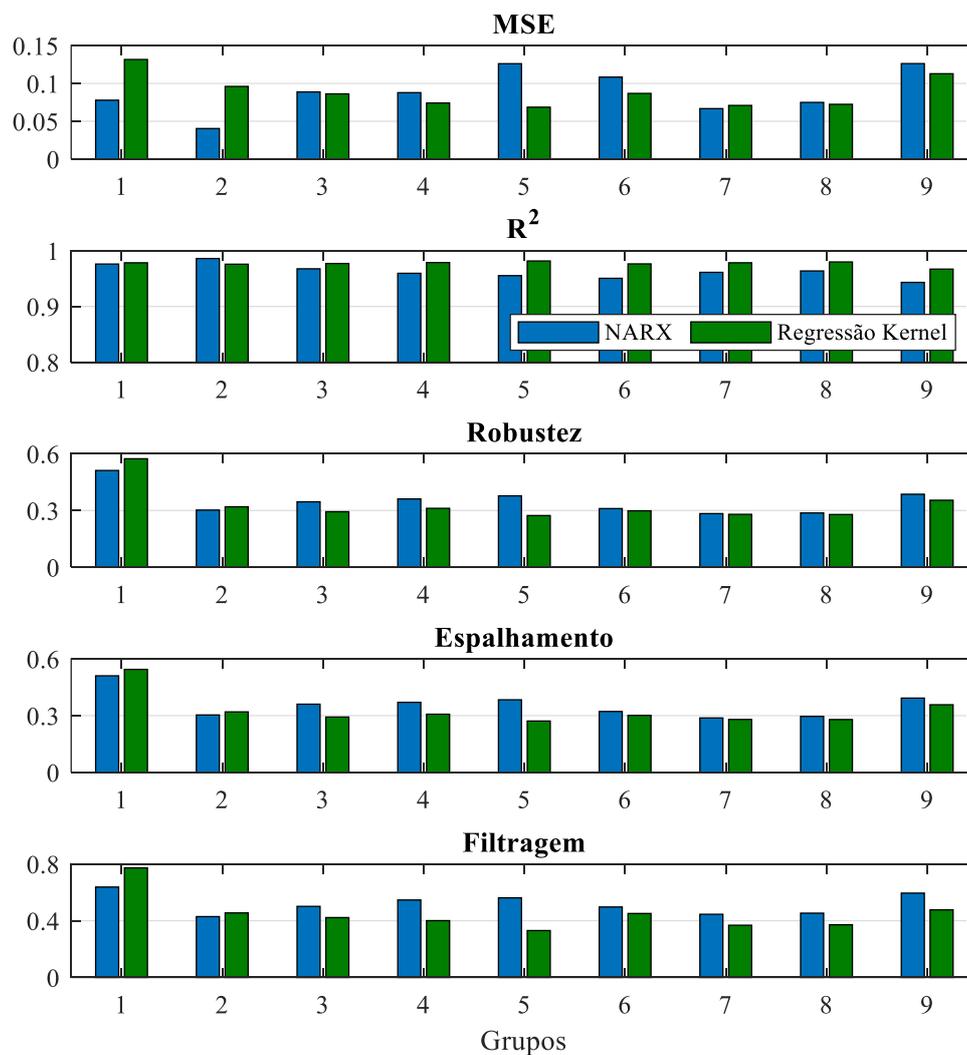
Percebe-se que o resíduo se mantém por quase todo período dentro da margem de segurança de 1%, em amarelo. Além disso, o resíduo só ultrapassa o limiar de 2%, em vermelho, definido para detecção de falhas, quando ocorre *outlier* na medição do sensor, que realmente configura uma falha. Portanto, os modelos obtidos a partir da rede NARX mostraram-se capazes de realizar a tarefa de detecção de falhas.

4.6. COMPARAÇÃO COM A REGRESSÃO KERNEL

Os dados pré-processados e agrupados por correlação foram usados para modelar estimadores por regressão kernel, chamados: $k_1, k_2, k_3, k_4, k_5, k_6, k_7, k_8$ e k_9 referentes aos mesmos grupos utilizados na abordagem anterior. Foram avaliadas diferentes constantes de suavização para buscar o melhor ajuste para cada estimador, conforme a Figura 3.11. Novamente a função kernel utilizada foi a Gaussiana.

O valor que obteve melhor precisão, para todos os modelos, foi $h = 0,5$. O desempenho desses estimadores pode ser visto na Figura 4.7.

Figura 4.7 Comparação de desempenho entre Regressão Kernel e NARX.

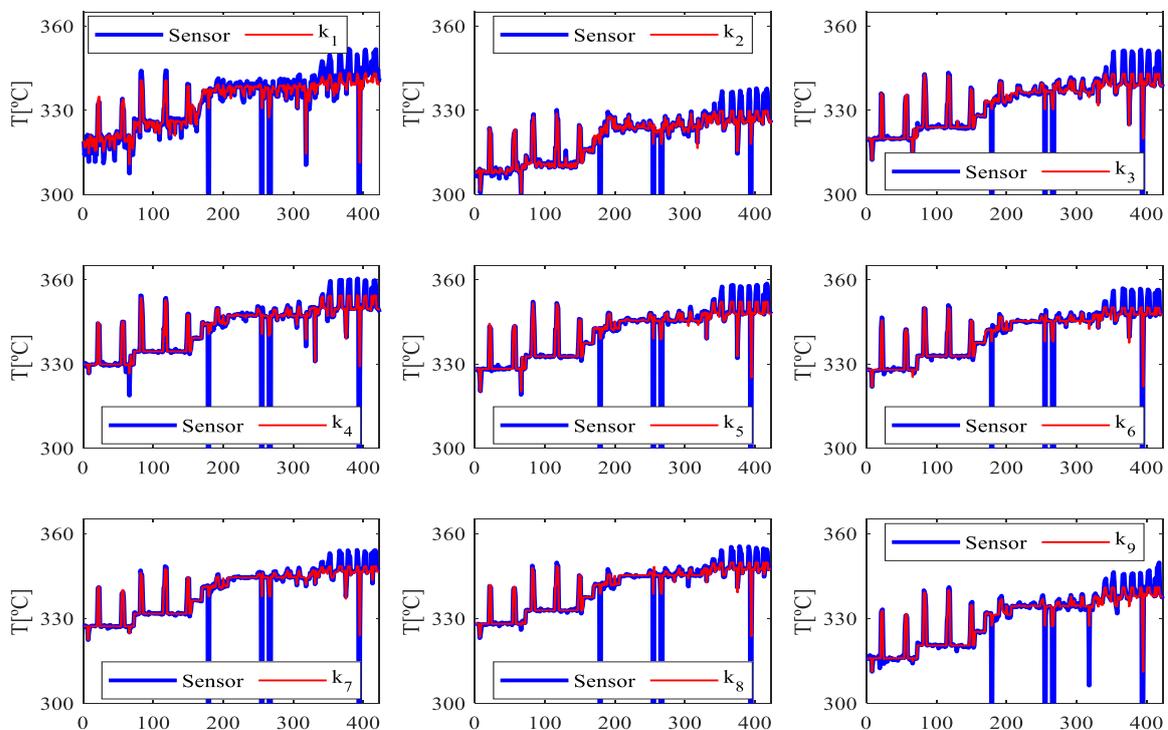


Fonte: Autoria Própria

O desempenho de ambos métodos, regressão kernel e NARX, foram próximos para grande parte dos grupos e métricas avaliadas. Os piores desempenhos da regressão kernel ocorreram nos grupos 1 e 2, que possuem menos sensores. Para os demais grupos a regressão kernel mostrou-se menos sensível, tanto ao *drift* quanto ao ruído. Entretanto, de modo geral, percebe-se um desempenho semelhante de ambas as abordagens.

A Figura 4.8 mostra o comparativo entre as estimações obtidas por regressão kernel e os dados reais para um sensor de cada grupo, contendo tanto os dados de teste quanto os dados de validação.

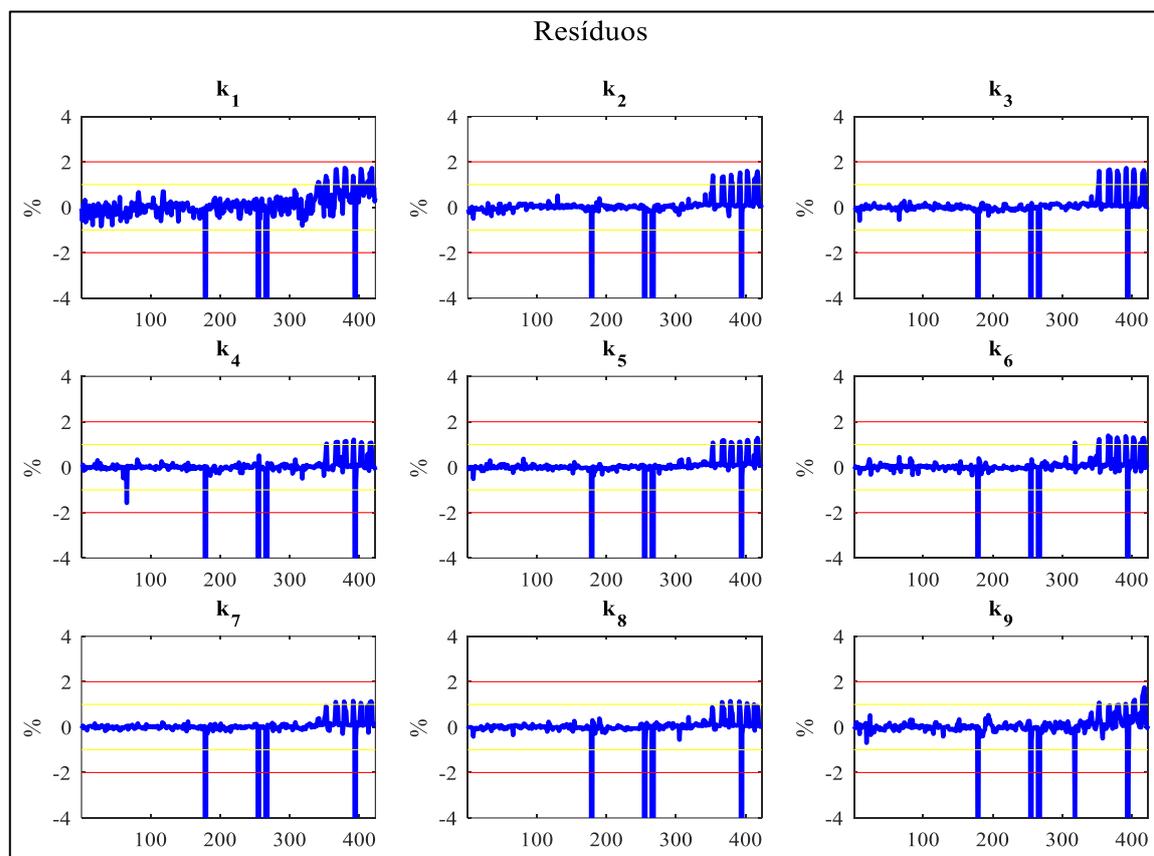
Figura 4.8 Comparação entre dados dos Sensores e Estimados por Regressão Kernel.



Fonte: Autoria Própria

Aplicando os modelos obtidos a partir de regressão kernel na detecção de falhas, obtemos as respostas apresentadas na Figura 4.9. Da mesma forma que a rede NARX, a regressão kernel foi capaz de manter o resíduo dentro da margem de segurança por quase todo período, e ultrapassando o limite de detecção de falhas apenas na ocorrência dos *outliers*.

Figura 4.9 Regressão Kernel aplicada na detecção de falhas.



Fonte: Autoria Própria

4.7. CONCLUSÃO

No estudo do problema de validação de sensores investigou-se a capacidade da rede NARX de realizar a auto associação, ou seja, usar os dados aqisitados pelos sensores para estimar os mesmos, a fim de diluir qualquer erro de medição que possa vir a ocorrer, gerando dados mais confiáveis. Essas estimativas, por sua vez, puderam ser usadas para detectar falhas nos sensores, através da comparação entre os valores aqisitados e estimados. E, por fim, a resolução através da rede NARX foi comparada a solução obtida por AAKR.

Percebeu-se que ambos métodos de estimação são capazes de executar a tarefa de detecção de falhas. Mas a rede NARX tem a vantagem de demandar menos memória e menor custo computacional, tendo em vista que a regressão kernel exige uma quantidade maior de dados de memória. Em contrapartida a rede NARX exige maior experiência do projetista, pois conta com alguns parâmetros que devem ser previamente definidos.

5. CONCLUSÃO

Esse trabalho averiguou o desempenho da rede NARX para resolução de problemas de interesse industrial. O primeiro problema trata da estimação de temperatura nos pontos críticos do PMSM, locais sensíveis ao calor, que demandam monitoramento da temperatura, mas onde a aplicação de sensores encontra dificuldades, seja na implantação e/ou na manutenção. O segundo problema discorre a respeito da validação e detecção de falhas em sensores de temperaturas empregados em diferentes pontos dos reatores de uma refinaria de petróleo.

O êxito da rede NARX na solução do primeiro caso estudado traz como benefícios sua fácil aplicação, tendo em vista que as preditoras do modelo geralmente já são aquisitadas para fins de controle, e o modelo poder ser embarcado sem grandes dificuldades, por não se tratar de uma arquitetura complexa, bem como por não demandar muita memória.

No segundo caso a rede NARX alcançou resultados similares à AAKR, superando-a nos casos em que haviam poucos sensores agrupados. Constatando-se, portanto, a possibilidade de uso da rede NARX para validação de sensores. Além disso, devido à simplicidade do método, é possível utilizá-lo em tempo real.

Nesse trabalho a configuração das redes NARX foram definidas a partir de tentativas, que é uma opção pouco eficiente, por essa razão, uma sugestão de trabalhos futuros é a elaboração de um método mais eficiente para definição dos parâmetros de configuração da rede. Além disso, ainda podem ser explorados: a comparação do desempenho da rede NARX com outras redes recorrentes e a implementação embarcada dessas redes. Ademais, a técnica utilizada na estimação de temperaturas do PMSM pode ser explorada para aplicação em outros tipos de motores, a fim de avaliar a generalização de sua capacidade.

REFERÊNCIAS

- [1] O. B. Sezer, M. U. Gudelek e A. M. Ozbayoglu, “Financial time series forecasting with deep learning: A systematic literature review: 2005–2019,” *Applied Soft Computing*, vol. 90, 2020.
- [2] M. Quarto, G. D’urso, C. Giardini, G. Maccarini e M. Carminati, “A Comparison between Finite Element Model (FEM) Simulation and an Integrated Artificial Neural Network (ANN)-Particle Swarm Optimization (PSO) Approach to Forecast Performances of Micro Electro Discharge Machining (Micro-EDM) Drilling,” *Micromachines*, vol. 12, nº 6, p. 667, 2021.
- [3] S. Chambon, M. N. Galtier, P. J. Arnal, G. Wainrib e A. Gramfort, “A deep learning architecture for temporal sleep stage classification using multivariate and multimodal time series,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, nº 4, pp. 758-769, 2018.
- [4] G. Gruosso, G. Storti Gajani, F. Ruiz, J. D. Valladolid e D. Patino, “A virtual sensor for electric vehicles’ state of charge estimation,” *Electronics*, vol. 9, nº 2, p. 278, 2020.
- [5] L. Galotto, A. D. M. Brun, R. B. Godoy, F. R. R. Maciel e J. O. P. Pinto, “Data based tools for sensors continuous monitoring in industry applications,” *IEEE 24th International Symposium on Industrial Electronics (ISIE)*, pp. 600-605, 2015.
- [6] P. J. Brockwell e R. A. Davis, *Time series: theory and methods*, New York: Springer, 2009.
- [7] A. Tealab, “Previsão de séries temporais usando metodologias de redes neurais artificiais: uma revisão sistemática.,” *Future Computing and Informatics Journal*, vol. 3, nº 2, pp. 334-340, 2018.
- [8] E. Diaconescu, “The use of NARX neural networks to predict chaotic time series,” *Wseas Transactions on computer research*, vol. 3, nº 3, pp. 182-191, 2008.
- [9] S. Haykin, *Redes neurais: princípios e prática*, Porto Alegre: Bookman Editora, 2007.

-
- [10] I. N. Da Silva, D. H. Spatti e R. A. Flauzino, *Redes neurais artificiais para engenharia e ciências aplicadas-curso prático*, São Paulo: Artliber, 2010.
- [11] L. A. Aguirre, *Enciclopédia de automática: controle e automação*, vol. 3, São Paulo: Editora Blucher, 2007.
- [12] J. Connor, L. E. Atlas e D. R. Martin, "Recurrent networks and NARMA modeling," *NIPS*, pp. 301-308, 1991.
- [13] K. S. Narendra e P. K., "Identification and control of dynamical systems using neural networks," *IEEE Transactions on Neural Networks*, vol. 1, n° 1, pp. 4-27., 1990.
- [14] D. R. Seidl e R. D. Lorenz, "A structure by which a recurrent neural network can approximate a nonlinear dynamic system," *IJCNN-91-Seattle International Joint Conference on Neural Networks. IEEE*, pp. 709-714, 1991.
- [15] H. Bohan e B. Yun, "Traffic flow prediction based on BRNN," *IEEE 9th International Conference on Electronics Information and Emergency Communication (ICEIEC)*, pp. 320-323, 2019.
- [16] H. T. Siegelmann, B. G. Horne e C. L. Giles, "Computational capabilities of recurrent NARX neural networks," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 27, n° 2, pp. 208-215, 1997.
- [17] A. Waibel, T. Hanazawa, G. Hinton, K. Shikano e K. J. Lang, "Phoneme recognition using time-delay neural networks," *IEEE transactions on acoustics, speech, and signal processing*, vol. 37, n° 3, pp. 328-339, 1989.
- [18] L. R. Medsker e L. C. Jain, *Recurrent neural networks: Design and Applications*, Washington: CRC press, 1999.
- [19] N. A.-N. H. AL-Rousan, "A Comparative Assessment of Time Series Forecasting Using NARX and SARIMA to Predict Hourly, Daily, and Monthly Global Solar Radiation Based on Short-Term Dataset," *Arabian Journal for Science and Engineering*, vol. 46, n° 9, pp. 8827-8848, 2021.
- [20] Y. Ma, H. Liu, Y. Zhu, F. Wang e Z. Luo, "The NARX model-based system identification on nonlinear, rotor-bearing systems," *Applied Sciences*, vol. 7, n° 9, p. 911, 2017.

-
- [21] G. Li, X. Lu, M. Liang e Z. Feng, “Low-frequency noise suppressing of desert seismic data by improved nonlinear autoregressive with external input neural network,” *Exploration Geophysics*, pp. 1-11, 2021.
- [22] A. Wunsch, T. Liesch e S. Broda, “Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (NARX),” *Journal of Hydrology*, vol. 567, pp. 743-758, 2018.
- [23] O. Bektas e J. A. Jones, “NARX time series model for remaining useful life estimation of gas turbine engines,” *PHM Society European Conference*, vol. 3, n° 1, 2016.
- [24] “Design Time Series NARX Feedback Neural Networks,” MathWorks, 2021. [Online]. Available: <https://www.mathworks.com/help/deeplearning/ug/design-time-series-narx-feedback-neural-networks.html>. [Acesso em 30 Novembro 2021].
- [25] A. Sidani e T. Sidani, “A comprehensive study of the backpropagation algorithm and modifications,” *Conference Record Southcon. IEEE*, pp. 80-84, 1994.
- [26] G. S. D. S. Gomes, “Novas funções de ativação em redes neurais artificiais multilayer perceptron,” *Tese (Doutorado em Ciências da Computação) – Centro de Informática, Universidade Federal de Pernambuco, Recife*, p. 137, 2010.
- [27] A. Chatterjee, “A fletcher–reeves conjugate gradient neural-network-based localization algorithm for wireless sensor networks,” *IEEE transactions on vehicular technology*, vol. 59, n° 2, pp. 823-830, 2009.
- [28] H. Demuth e M. Beale, “Neural network toolbox user’s guide,” The MathWorks, Natick, MA, 2004.
- [29] M. F. Møller, “A scaled conjugate gradient algorithm for fast supervised learning,” *Neural networks*, vol. 6, n° 4, pp. 525-533, 1993.
- [30] “Deep Learning Book,” Data Science Academy, 2021. [Online]. Available: <https://www.deeplearningbook.com.br/o-efeito-do-batch-size-no-treinamento-de-redes-neurais-artificiais/>. [Acesso em 31 Janeiro 2022].
- [31] M. Hadijati, D. Komalasari e N. Fitriyani, “Statistical Downscaling Model Using Nonparametric Regression to Predict Temperature in Selaparang Lombok,” *Scientific Committe*, p. 129, 2016.

-
- [32] P. Thosar, J. Patil, M. Singh, S. Thamke e S. Gonge, “Prediction of Motor Temperature using Linear Regression,” *International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE)*. *IEEE*, pp. 7-12, 2020.
- [33] L. Galotto, J. O. P. Pinto, B. Ozpineci, L. C. Leite e L. E. S. Borges, “Sensor compensation in motor drives using kernel regression,” *IEEE International Electric Machines & Drives Conference*, vol. 1, pp. 229-234, 2007.
- [34] M. E. G. Martins, “Coeficiente de correlação amostral,” *Rev. Ciência Elementar*, vol. 2, n° 2, p. 69, 2014.
- [35] S. D. Umans, Fitzgerald & Kingsley's Electric Machinery, 7^a ed., New York: McGraw-Hill, 2014.
- [36] H. J. Lee J., “Temperature Estimation of PMSM Using a Difference-Estimating Feedforward Neural Network,” *IEEE Access*, vol. 8, pp. 130855-130865, 2020.
- [37] W. Kirchgässner, O. Wallscheid e J. Böcker, “Estimating Electric Motor Temperatures with Deep Residual Machine Learning,” *IEEE Transactions on Power Electronics*, vol. 36, n° 7, pp. 7480-7488, 2020.
- [38] O. Wallscheid, W. Kirchgässner e J. Böcker, “Investigation of long short-term memory networks to temperature prediction for permanent magnet synchronous motors,” *International joint conference on neural networks (IJCNN)*. *IEEE*, pp. 1940-1947, 2017.
- [39] H. Guo, Q. Ding, Y. Song, H. Tang, L. Wang e J. Zhao, “Predicting temperature of permanent magnet synchronous motor based on deep neural network,” *Energies*, vol. 13, n° 18, p. 4782, 2020.
- [40] W. Kirchgässner, “Electric Motor Temperature: 140 hours recordings from a permanent magnet synchronous motor (PMSM),” LEA department at Paderborn University, [Online]. Available: <https://www.kaggle.com/wkirgsn/electric-motor-temperature>. [Acesso em 12 Fevereiro 2021].
- [41] W. Kirchgässner, O. Wallscheid e J. Böcker, “Deep residual convolutional and recurrent neural networks for temperature estimation in permanent magnet synchronous motors,” *IEEE International Electric Machines & Drives Conference (IEMDC)*, pp. 1439-1446, 2019.
- [42] A. Okada, A. S. Koshikawa, K. Yonaga, K. Sasaki, T. Kato e M. Ohzeki, “Performance Improvement of Magnet Temperature Estimation using Kernel Method based Non-

-
- Linear Parameter Estimator for Variable leakage flux IPMSMs,” *IEEJ Journal of Industry Applications*, vol. 10, nº 6, pp. 618-623, 2021.
- [43] N. Chen, J. Dai, X. Yuan, W. Gui, W. Ren e H. N. Koivo, “Temperature prediction model for roller kiln by ALD-based double locally weighted kernel principal component regression,” *IEEE Transactions on Instrumentation and Measurement*, vol. 67, nº 8, pp. 2001-2010, 2018.
- [44] D. N. Nguyen, T. L. Pham, V. C. Nguyen, A. T. Nguyen, H. Kino, T. Miyake e H. C. Dam, “A regression-based model evaluation of the Curie temperature of transition-metal rare-earth compounds,” *Journal of Physics: Conference Series*, vol. 1290, nº 1, p. 012009, 2019.
- [45] M. Catelani, L. Ciani e M. Venzi, “Failure modes, mechanisms and effect analysis on temperature redundant sensor stage,” *Reliability Engineering & System Safety*, vol. 180, pp. 425-433, 2018.
- [46] C. G. Mattera, J. Quevedo, T. Escobet, H. R. Shaker e M. Jradi, “A method for fault detection and diagnostics in ventilation units using virtual sensors,” *Sensors*, vol. 18, nº 11, p. 3931, 2018.
- [47] R. Swischuk e D. Allaire, “A machine learning approach to aircraft sensor error detection and correction,” *Journal of Computing and Information Science in Engineering*, vol. 19, nº 4, 2019.
- [48] P. Baraldi, F. Di Maio, D. Genini e E. Zio, “Comparison of data-driven reconstruction methods for fault detection,” *IEEE Transactions on Reliability*, vol. 64, nº 3, pp. 852-860, 2015.
- [49] J. cha, T. Lee, J. Y. Kim, J. Shin, J. Kim e C. Yeom, “Sensor drift detection in sng plant using auto-associative kernel regression,” *IEEE International Systems Engineering Symposium (ISSE)*, pp. 1-4, 2017.