



ESTRATÉGIA PARA DETECÇÃO DE FALHAS EM EQUIPAMENTOS
INDUSTRIAIS COM BAIXA REPETIBILIDADE DE EVENTOS USANDO
REDES NEURAIAS

Jean Americo Tomé

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Luiz Pereira Calôba

Rio de Janeiro

Abril de 2020

ESTRATÉGIA PARA DETECÇÃO DE FALHAS EM EQUIPAMENTOS
INDUSTRIAIS COM BAIXA REPETIBILIDADE DE EVENTOS USANDO REDES
NEURAIAS

Jean Americo Tomé

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM
CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Orientadores: Luiz Pereira Calôba

Aprovada por: Prof. Luiz Pereira Calôba

Prof. João Baptista de Oliveira e Souza Filho

Dr. Carlos Fernando Carlim Pinto

Dr. Marcelo Albano Moret Simões Gonçalves

RIO DE JANEIRO, RJ - BRASIL

ABRIL DE 2020

Tomé, Jean Americo

Estratégia para Detecção de Falhas em Equipamentos Industriais Com Baixa Repetibilidade de Eventos usando Redes Neurais/Jean Americo Tomé. – Rio de Janeiro: UFRJ/COPPE, 2020.

XIV, 57 p.: il.; 29, 7cm.

Orientador: Luiz Pereira Calôba

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2020.

Referências Bibliográficas: p. 54 – 55.

1. Detecção de falhas. 2. Redes Neurais. 3. Manutenção. 4. Preditiva. 5. Digital Twin. 6. Gêmeo Digital. 7. Industria. 8. Equipamentos. I. Calôba, Luiz Pereira. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

*A Deus, que transformou a
minha vida e guia a minha
história.*

Agradecimentos

Agradeço a Deus por despertar minha inteligência e por atrair meu coração à sabedoria.

À minha esposa, Adriana Santos, pela paciência e por perdoar minhas ausências, bem como por me apoiar e amar durante o período dedicado a esse trabalho.

À minha família por todo o sacrifício que fizeram por mim.

Ao meu professor e orientador Luiz Calôba, por todo o ensinamento e por me conduzir nessa jornada.

À equipe da Radix Engenharia e Software, por todo o apoio profissional e pelos desafios que resultaram nesse trabalho. Em especial, ao meu gerente João Zaiden, que me deu a oportunidade de trabalhar com o tópico aqui abordado.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

ESTRATÉGIA PARA DETECÇÃO DE FALHAS EM EQUIPAMENTOS
INDUSTRIAIS COM BAIXA REPETIBILIDADE DE EVENTOS USANDO
REDES NEURAIIS

Jean Americo Tomé

Abril/2020

Orientador: Luiz Pereira Calôba

Programa: Engenharia Elétrica

Muita das técnicas utilizadas na área de manutenção preditiva buscam ensinar aos modelos pelo menos duas situações de operação: uma correspondente a períodos normais, em que não há indícios de falha, e outra cobrindo períodos anteriores a um evento de falha. Porém, em diversos tipos de equipamentos, a realidade é que a repetibilidade de eventos de falha é baixa.

Nesse trabalho uma estratégia de modelagem que busca modelar o período normal de operação é apresentado. A utilização de dados de eventos de falha serve apenas para validação e ajuste de limiares de decisão. Essa estratégia constitui um *framework*, genérica o suficiente para ser aplicado a diferentes equipamentos, e foi utilizada em *softwares* de manutenção preditiva para diferentes famílias de equipamentos: válvula de controle, compressores alternativos e bombas.

A construção da abordagem é feita no topo de uma arquitetura de Redes Neurais Artificiais, que se encarrega do aprendizado do padrão normal de operação e, posteriormente, é utilizada como um *baseline* comparativo para diagnóstico do equipamento, efetivamente implementando um gêmeo digital de sua resposta. Um estudo de caso é realizado em dados reais, coletados no período de 2015-2018, de sensores relacionados a uma das válvulas de controle de uma grande indústria química brasileira. Toda a etapa de pré-processamento, limpeza, construção do modelo e tomada de decisão é apresentada e discutida.

A estratégia apresentada foi capaz de identificar tendências de degradação em 6 de 10 registros de falha que, em conjunto com a geração de alarmes baseado em limiares fixos, possibilitaria a geração de alarmes com até 20 dias de antecedência caso o modelo estivesse em operando em produção (online).

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

FAULT DETECTION IN INDUSTRIAL EQUIPMENT WITH LOW EVENT REPEATABILITY USING NEURAL NETWORKS

Jean Americo Tomé

April/2020

Advisor: Luiz Pereira Calôba

Department: Electrical Engineering

Many of the techniques used in the area of predictive maintenance seek to teach the models at least two operating situations: one corresponding to normal periods, in which there is no evidence of failure, and another covering periods prior to a failure event. However, in several types of equipment, the reality is that the repeatability of failure events is low.

In this work a modeling strategy that seeks to model the normal operating period is presented. The use of fault event data is only for validation and adjustment of decision thresholds. This strategy constitutes a framework, generic enough to be applied to different equipment, and has been used in predictive maintenance software for different equipment families: control valve, reciprocating compressors and pumps.

The approach is built on top of an Artificial Neural Network architecture, which takes care of learning the normal operating pattern, and is subsequently used as a comparative baseline for diagnosing the equipment, effectively implementing a digital twin of its response. A case study is performed on real data, collected in the period 2015-2018, from sensors related to one of the control valves of a large Brazilian chemical industry. The whole step of preprocessing, cleaning, model building and decision making is presented and discussed.

The strategy presented was able to identify degradation trends in 6 out of 10 fault records that, in conjunction with alarm generation based on fixed thresholds, would make it possible to generate alarms up to 20 days in advance if the model were operating in production (online).

Sumário

Lista de Figuras	x
Lista de Tabelas	xiv
1	1
1.1 Introdução	1
1.2 Metodologia	3
1.3 Contribuições	4
2 Estratégia para Predição de Falhas Proposta	5
2.1 Apresentação	5
2.1.1 Viés do Passado do Sistema no Modelo	6
2.2 Revisão da Literatura	7
3 Descrição do Estudo de Caso	11
3.1 Introdução	11
3.2 O Equipamento	11
3.3 Aspectos Operacionais	12
4	15
4.1 Pré-processamento	15
4.1.1 Normalização	15
4.1.2 A Base de Dados de Sensores	16
4.1.3 A Base de Eventos de Falha	20
4.1.4 A Base de Bateladas	22
4.1.5 Remoção de <i>outliers</i>	24
4.2 Visualização da Operação	25
4.2.1 Resina 1	25
4.2.2 Resina 3	27
4.3 Treinamento e Dimensionamento da Rede	29
4.4 Resultados	32
4.4.1 Operação do Modelo	32

4.4.2	Análise do Resíduo Médio	35
4.4.3	Operação do Modelo nos Períodos Pré-Falha	39
4.4.4	Falha de Tubing/Gaxeta em 10/07/2015	39
4.4.5	Falha de Oscilações em 28/09/2015	41
4.4.6	Falha sem Classificação em 13/01/2016	43
4.4.7	Falha de Posicionador em 19/12/2017	45
4.4.8	Lógica de Decisão baseada em Limiares Fixos	47
5		52
5.1	Conclusão	52
5.2	Trabalhos Futuros	53
	Referências Bibliográficas	54
	A Redes Neurais Artificiais (RNA)	56

Lista de Figuras

1.1	Representação das 4 revoluções industriais, salientando alguma das respectivas principais, retirado de Estadão (2019) e adaptado.	1
1.2	Representação da evolução das estratégias de manutenção, retirado de Limble CMMS (2019)	2
1.3	Representação da desproporção de dados entre períodos normais (sem indícios de falha) e em períodos anteriores um a evento de falha para o treinamento de modelos de aprendizado de máquina.	3
2.1	Desenho esquemático da arquitetura de operação da rede em paralelo com o sistema, fornecendo uma linha de referência para o funcionamento do sistema, portanto treinada apenas no período normal de operação. A partir do <i>resíduo</i> (diferença entre o predito e o real), definem-se as lógicas de decisão para a geração de alarmes.	6
2.2	Exemplo de alteração não recomendável: colocar o passado do sistema como entrada para a rede. A memória é a evolução do defeito de degradação/falha, exatamente o que não queremos que o modelo aprenda.	7
2.3	Estratégia baseada em equação de paridade, retirada de Venceslau (2013).	9
3.1	Representação do equipamento retirado do site do fabricante (Emerson, 2019).	11
3.2	Duração normalizada das etapas da batelada.	13
3.3	Figura esquemática mostrando a vazão da válvula de controle ao longo de uma batelada	13
4.1	Comparativo entre a normalização min-max e a normalização min-max, retirado de (Ben Alex Keen, 2019).	16
4.2	Distribuição original (valores propositalmente omitidos) e distribuição transformada através da normalização <i>min-max</i>	16
4.3	Distribuição do sinal de controle de abertura enviado à válvula (FC41010B.OUT) no período de 4 anos.	17

4.4	Distribuição do sinal de vazão da válvula (FC41010B.PV) no período de 4 anos.	18
4.5	Distribuição do sinal de <i>set-point</i> do controlador (FC41010B.SP) no período de 4 anos.	19
4.6	Distribuição das duas diferentes resinas em produção nas bateladas.	23
4.7	Período de operação da Resina 1 em 2015/10.	26
4.8	Sinal de vazão do equipamento para um período de produção da Resina 1 em 2015/10.	26
4.9	Sinal de <i>set-point</i> do equipamento para um período de produção da Resina 1 em 2015/10.	27
4.10	Sinal de controle enviado ao equipamento para um período de produção da Resina 1 em 2015/10.	27
4.11	Período de operação da Resina 3 em 2015/10.	28
4.12	Sinal de <i>set-point</i> do equipamento para um período de produção da Resina 3 em 2015/10.	29
4.13	Sinal de controle do equipamento para um período de produção da Resina 3 em 2015/10.	29
4.14	Representação de treinamento do modelo com as entradas e saídas utilizadas	31
4.15	Métrica R2 (Draper et al. (1998)) para diferentes números de neurônios na camada intermediária.	31
4.16	Métrica R2 para diferentes números de neurônios na camada intermediária.	32
4.17	Exemplo de operação do modelo no período instantâneo de treinamento para os sinais de vazão (normalizados).	33
4.18	Erro relativo de predição do modelo para o período de treinamento.	33
4.19	Exemplo de operação do modelo no período instantâneo de treinamento para o sinal de abertura enviado pelo controlador.	34
4.20	Exemplo de operação do modelo no período instantâneo de treinamento para o sinal de <i>set-point</i> (normalizado pelo seu valor máximo histórico).	34
4.21	Gráfico da média dos resíduos por batelada, normalizados pela vazão máxima do equipamento, para todo o período disponível, com os momentos de falha marcados em cinza.	35
4.22	Período de erro baixo, com um forte evento em 13/01/2016. A linha tracejada em vermelho apresenta um auxílio gráfico da tendência aproximada de crescimento.	36

4.23	Período de 02/2015-10/2015, onde acontece um crescimento gradual da tendência até a falha de oscilações em 28/09/2015. A linha tracejada em vermelho apresenta um auxílio gráfico da tendência aproximada de crescimento.	37
4.24	Tendência em anterior as falhas de Tubing e Gaxeta, em 10/07/2015 e 09/08/2015, demonstrando a característica agressiva dessas falhas, e anterior a falha de Gaxeta em 09/08/2015. A linha tracejada em vermelho apresenta um auxílio gráfico da tendência aproximada de crescimento.	38
4.25	Período de 04/2017 a 12/2017 apresentando uma tendência clara e forte em direção a falha de Posicionador. A linha tracejada em vermelho apresenta um auxílio gráfico da tendência aproximada de crescimento.	39
4.26	Comparação da vazão da válvula e a predita em dias anteriores a falha de 10/07/2015.	40
4.27	Sinal de <i>set-point</i> do controlador em dias anteriores a falha de 10/07/2015.	40
4.28	Sinal de abertura enviado pelo controle em dias anteriores a falha de 10/07/2015.	41
4.29	Comparação da vazão da válvula e a predita em dias anteriores a falha de 28/09/2015.	42
4.30	Sinal de <i>set-point</i> do controlador em dias anteriores a falha de 28/09/2015.	42
4.31	Sinal de abertura enviado pelo controle em dias anteriores a falha de 28/09/2015.	43
4.32	Comparação da vazão da válvula e a predita em dias anteriores a falha de 13/01/2016.	44
4.33	Sinal de <i>set-point</i> do controlador em dias anteriores a falha de 13/01/2016.	44
4.34	Sinal de abertura enviado pelo controle em dias anteriores a falha de 13/01/2016.	45
4.35	Comparação da vazão da válvula e a predita em dias anteriores a falha de 19/12/2017.	46
4.36	Sinal de <i>set-point</i> do controlador em dias anteriores a falha de 19/12/2017.	46
4.37	Sinal de abertura enviado pelo controle em dias anteriores a falha de 19/12/2017.	47
4.38	Resultado para todo o período com lógica de decisão baseada em limiares implementada.	49

4.39 Estatísticas de classificação para os dois limiares para todo o período de operação (3 anos).	50
A.1 Diagrama esquemático de um neurônio artificial	56
A.2 Representação de uma rede multi-camadas.	57

Lista de Tabelas

3.1	Características do equipamento.	12
3.2	Tabela esquemática demonstrando a duração média das diferentes etapas de uma batelada.	12
4.1	Estatísticas da distribuição do sinal de controle de abertura enviado à válvula (FC41010B.OUT) no período de 4 anos.	18
4.2	Estatísticas da distribuição do sinal de vazão da válvula (FC41010B.PV) no período de 4 anos.	19
4.3	Estatísticas da distribuição do sinal de <i>set-point</i> do controlador (FC41010B.SP) no período de 4 anos.	20
4.4	Tabela com a informação dos eventos de falha e suas categorias.	21
4.5	Tabela final informativa dos eventos de falha, considerando a data de fim do evento e as categorias.	22
4.6	Demonstração da estrutura dos dados do registro das bateladas.	22
4.7	Estatísticas de duração das bateladas.	23
4.8	Proporção da produção de resinas 1 e 3 ao longo do tempo.	24
4.9	Exemplo de dados com atribuição <i>Bad</i> pelo historiador e demonstrando a etapa atual (<i>phase</i> da batelada	25
4.10	Sinal de vazão do equipamento para um período de produção da Resina 3 em 2015/10.	28
4.11	Sumário de resultados de antecipação das falhas através da geração dos alarmes pelo cruzamento dos limiares.	51

Capítulo 1

1.1 Introdução

A Indústria 4.0, conforme (Forbes: Why Everyone Must Get Ready For The 4th Industrial Revolution, 2016), conceito originário da chamada Quarta Revolução Industrial, é uma expressão que engloba o conjunto de transformações digitais para a indústria com o uso de tecnologia e sensores inteligentes. A Figura 1.1 representa as 4 revoluções industriais salientando alguma das suas principais contribuições.



Figura 1.1: Representação das 4 revoluções industriais, salientando alguma das respectivas principais, retirado de Estadão (2019) e adaptado.

A Quarta Revolução Industrial possui uma série de objetivos estratégicos, incluindo operação remota, simulação, otimização e suporte a operação. Dentro desse último aspecto, encontra-se a utilização de sistemas inteligentes e a aplicação de técnicas de aprendizado de máquina.

Esse tipo de abordagem tem sido amplamente utilizada na área de manutenção preditiva, considerada o estado da arte da área de manutenção de equipamentos, em que se realiza a manutenção baseada no acompanhamento periódico na análise de dados reais do equipamento, e não mais de forma tardia (corretiva) ou por an-

tecipação (preventiva) Gouriveau et al. (2016). A representação desta evolução é apresentada na Figura 1.2.

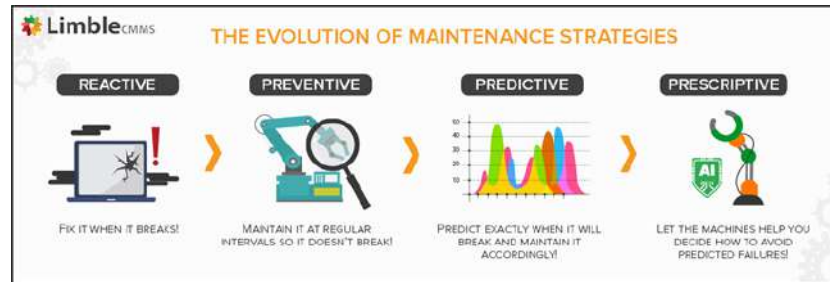


Figura 1.2: Representação da evolução das estratégias de manutenção, retirado de Limble CMMS (2019)

O objetivo final da manutenção preditiva, portanto, é definir o estado atual e futuro do equipamento, bem como o seu tempo restante de utilização, permitindo uma pausa para manutenção agendada, com poucos riscos e de forma a otimizar o planejamento de operação.

Com esses objetivos em mente, é natural e pode ser bem sucedida a aplicação de modelos de aprendizado de máquina, os quais possuem a capacidade de reconhecer padrões.

Todavia, para um correto funcionamento, muita das técnicas utilizadas nesta área passam por estratégias que buscam construir modelos baseado em dados, em pelo menos duas situações de operação: em períodos normais, em que não há indícios de falha, e em períodos anteriores a um evento de falha, de forma que os dados representem, ainda que parcialmente, um padrão ou característica que permita o modelo realizar a distinção entre momentos normais e de pré-falha.

Naturalmente, a acurácia dos modelos em realizar a distinção e o reconhecimento dos padrões que antecedem uma falha é tanto maior quanto há mais eventos do mesmo tipo de falha, o que chamamos de repetibilidade do evento. Porém, em diversos tipos de equipamentos, a realidade é que esta repetibilidade é baixa: tanto as indústrias realizam procedimentos de manutenção e revisão periódicos para evitar a ocorrência de uma falha, quanto os fabricantes buscam uma robustez em seus projetos para que tais falhas não aconteçam - ou levem anos até ocorrer. Essa desproporção é representada na Figura 1.3.

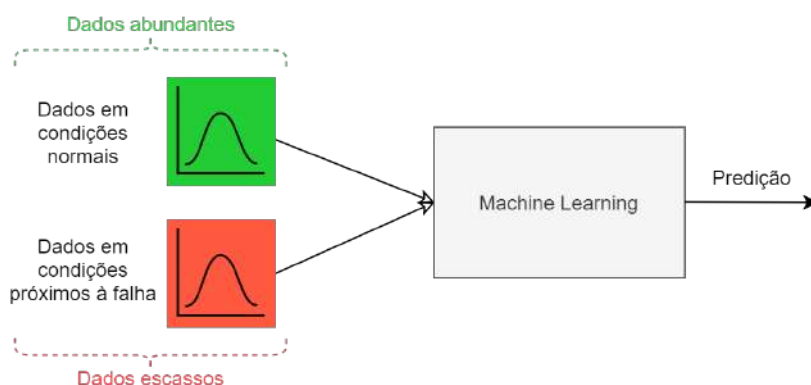


Figura 1.3: Representação da desproporção de dados entre períodos normais (sem indícios de falha) e em períodos anteriores um a evento de falha para o treinamento de modelos de aprendizado de máquina.

Um estudo de caso será realizado em dados reais, coletados no período de 2015-2018, de sensores relacionados a uma válvula de controle de uma grande indústria química brasileira. Toda a etapa de pré-processamento, limpeza, construção do modelo e tomada de decisão será apresentada e discutida.

1.2 Metodologia

Nesse trabalho uma estratégia de modelagem que busca absorver apenas o padrão dos dados durante o período normal será apresentada. A utilização de dados de eventos de falha serve apenas para validação e ajuste de limiares de decisão. Assim, essa estratégia é interessante para situações com baixa recorrência de eventos de falha.

É importante ressaltar essa estratégia constitui um *framework*, genérico o suficiente para ser aplicada para diferentes equipamentos, e que ela se encontra embarcada em projetos manutenção preditiva desenvolvidos para diferentes famílias de equipamentos: válvula de controle, compressores alternativos e bombas.

A construção da abordagem é feita no topo de uma arquitetura de Redes Neurais Artificiais (RNA), que se encarrega do aprendizado do padrão normal de operação e, posteriormente, é utilizada como um *baseline* comparativo para diagnóstico do equipamento, efetivamente implementando um gêmeo digital (*digital twin*) de sua resposta. O uso de outras técnicas de regressão também é possível, mas as RNA são preferíveis para esse tipo de abordagem devido a sua capacidade de generalização Haykin (2009).

1.3 Contribuições

A maior contribuição desse trabalho é a apresentação e análise de uma aplicação real de um *framework* para a detecção de falhas em equipamentos industriais com baixa repetibilidade de eventos, possibilitando a análise do equipamento de forma comparativa.

Um estudo de caso é realizado com dados reais de uma válvula de controle de uma grande indústria química brasileira, e todo o procedimento - preparação e limpeza dos dados, treinamento e dimensionamento do modelo e a definição dos patamares de decisão são apresentados, tornando esse trabalho original e o primeiro a lidar com esse tipo de problema em um equipamento do tipo válvula de controle.

Além disso, essa estratégia também foi testada e utilizada com equipamentos de outras famílias, tais como compressores alternativos e bombas, sendo bem sucedida, e hoje é uma das estratégias de um grande *software* industrial voltado para a detecção de falhas.

Por fim, um artigo desse trabalho será apresentado no congresso do evento *Rio Oil and Gas 2020*.

Capítulo 2

Estratégia para Predição de Falhas Proposta

2.1 Apresentação

Considere que um equipamento, ou suas partes, possam ser representadas como um sistema dinâmico, e suas variáveis possam ser identificadas como sinais de entrada do modelo no tempo, aqui representadas vetorialmente como $X(t)$, isto é, são estímulos - ou condições - a fim de levar seu sinal de saída, $y(t)$ para um determinado patamar.

Em equipamentos submetidos a uma malha de controle, como uma válvula digital, essa relação é clara: o sinal de entrada é a saída do controlador e o sinal de saída é o seu nível de abertura, implicando diretamente na vazão do fluido que passa por ela.

O mesmo conceito pode ser aplicado a partes de equipamentos complexos. Os cilindros de um compressor industrial, por exemplo, podem ser pensados como um sistema que, dadas a pressão e temperatura de sucção, a densidade do gás e a potência do motor como entrada, entrega uma pressão (ou temperatura) de descarga como sinal de saída.

Esse mapeamento, $X(t) \rightarrow y(t)$, classificado como sistema *MISO*, também pode conter diversas formas de não-linearidades, tais como zona morta e atraso de transporte que, quando somado ao ruído dos sensores industriais, torna muito difícil a modelagem do ponto de vista fenomenológico.

Uma proposta para a detecção de falhas nesses sistemas é o uso de redes neurais para o aprendizado do mapeamento $X(t) \rightarrow y(t)$ em condições normais, fornecendo uma referência de como o sistema se comportava em períodos normais de operação para comparação. Assim, é possível a detecção de um mau funcionamento e de um cenário de princípio de falha através do distanciamento (em tendência) entre o comportamento observado no sistema versus a resposta fornecida pelo do modelo.

Do ponto de vista da Indústria 4.0, esse tipo de abordagem pode ser considerado uma forma de *Digital Twin*, uma vez que o modelo representa um gêmeo digital do comportamento normal e da dinâmica do equipamento.

Um desenho esquemático dessa arquitetura é apresentado na Figura 2.1.

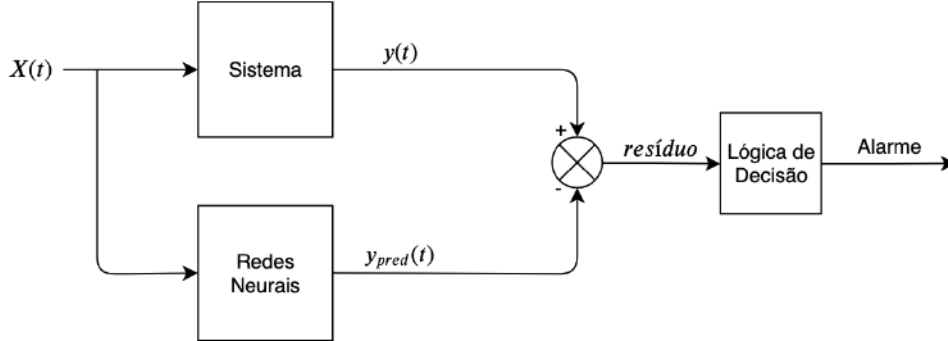


Figura 2.1: Desenho esquemático da arquitetura de operação da rede em paralelo com o sistema, fornecendo uma linha de referência para o funcionamento do sistema, portanto treinada apenas no período normal de operação. A partir do *resíduo* (diferença entre o predito e o real), definem-se as lógicas de decisão para a geração de alarmes.

O equipamento, ou uma de suas partes individuais, é retratada como um sistema, onde $X(t)$ representa suas entradas e $y(t)$ sua resposta. Um modelo baseado em redes neurais é operado em paralelo com o equipamento, logo recebendo $X(t)$ e entregando $y_{pred}(t)$. A quantidade $y(t) - y_{pred}(t)$ é computada e constitui o chamado *resíduo*, que define a entrada para um bloco de tomada de decisão. Por fim, a saída desse bloco corresponde a um alarme (ou diversos alarmes), definidos conforme a natureza do problema ou dos equipamentos.

2.1.1 Viés do Passado do Sistema no Modelo

Uma proposta natural - a partir do que foi apresentado - seria, para equipamentos mais complexos ou com características dinâmicas, utilizar como entrada do modelo o passado (através de um *buffer* e apresentado através de um atraso ΔT), alterando a arquitetura conforme Figura 2.2. Fazendo isso, estaríamos adicionando a memória do sistema no modelo. Todavia, a memória é justamente a evolução do defeito (degradação/falha), exatamente o que não queremos que o modelo aprenda. Pelo contrário, o modelo deve ser uma referência sem qualquer viés gerado pelo equipamento.

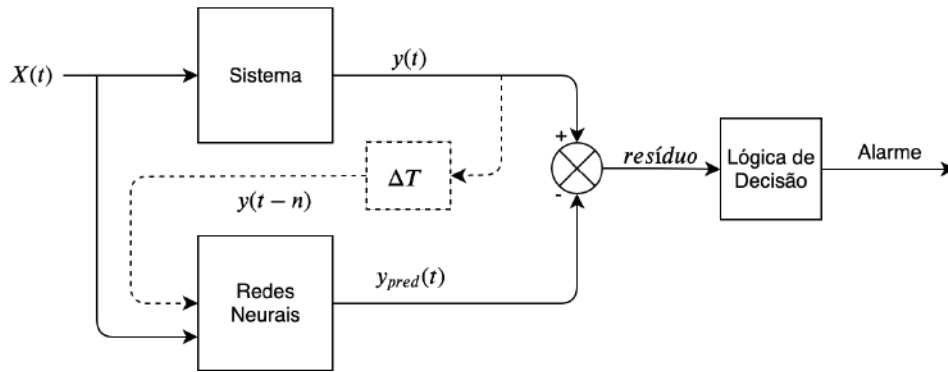


Figura 2.2: Exemplo de alteração não recomendável: colocar o passado do sistema como entrada para a rede. A memória é a evolução do defeito de degradação/falha, exatamente o que não queremos que o modelo aprenda.

No desenvolvimento da abordagem desse trabalho essa proposta foi avaliada, porém o resultado tornou o modelo altamente dependente da resposta atrasada do equipamento, uma vez que sua autocorrelação é altíssima. Assim, o modelo não se afastava do equipamento em momentos anteriores a falha, mas continuava seguindo seus padrões.

Uma outra possibilidade seria adicionar o vetor de entradas passadas $X(t-n)$ na rede neural. Nos equipamentos contemplados com essa abordagem essa possibilidade não gerou um ganho significativo para o modelo, uma vez que a taxa de amostragem dos dados era muito maior do que a dinâmica do equipamento, implicando que a mudança de estado se completava dentro de um intervalo de aquisição. Todavia, se há dados disponíveis em alta frequência essa abordagem deve ser avaliada, uma vez que possibilita a captura de mais informações sobre a dinâmica do sistema.

2.2 Revisão da Literatura

A presente revisão será focada em estratégias de detecção de falha em equipamentos do tipo válvula de controle, que é o abordado no estudo de caso e que será apresentado adiante neste trabalho. Dessa forma, pode-se fornecer uma visão geral do estado da arte para essa família de equipamentos. Uma visão geral de outras estratégias considerando diferentes famílias de equipamentos é reservada para trabalhos futuros.

Em estratégias similares, destaca-se o trabalho desenvolvido em Karpenko and Sepehri (2001), onde o autor propõe uma estrutura de redes neurais para simular a dinâmica do equipamento pós-atuação. Em síntese, baseado-se na parametrização da resposta do equipamento a um degrau, portanto considerando medidas tais como o tempo morto, o tempo de pico, o percentual de overshoot, o erro de *steady-state*, é realizada a predição dos sinais que causaram essa resposta, tais como a pressão de

alimentação e a posição de válvulas de agulha relacionadas ao bloqueio da abertura de ar para o atuador e diafragma. O autor realiza diversos testes experimentais para cada condição de falha (pressão de alimentação, bloqueio de abertura de ar no atuador e vazamento pelo diafragma), buscando a resposta do equipamento nessas condições para a criação de uma base de dados. Após a realização do treinamento e do dimensionamento da rede, os resultados são bastante promissores para a identificação de cada falha. Todavia, sua grande dificuldade de expansão para outras válvulas é a necessidade de se realizar ensaios, visto se tratar uma abordagem intrusiva.

O mesmo tipo de abordagem é utilizado pelo autor Karpenko et al. (2003), mas agora focando na identificação de falhas em um posicionador de uma válvula de controle pneumática. Naturalmente, para essa aplicação, as variáveis de entrada são diferentes, relacionadas a performance do atuador na curva pressão x posição do equipamento. A metodologia também se mostra bem sucedida, tornando possível a modelagem da resposta do equipamento através de RNA, apesar de permanecer com seus aspectos negativos, necessitando de ensaios no equipamento.

Em Prabakaran et al. (2013), o autor utiliza o pacote *Actuator Diagnosis in Industrial Control Systems* (DAMADICS) para simular os efeitos de falha no equipamento e utiliza de uma arquitetura de redes neurais para aprender a resposta do equipamento e posteriormente utilizar a estratégia de comparação (resíduo), salientando que, no fundo, o modelo está fazendo, internamente, uma aproximação de 5 parâmetros naturalmente difíceis de serem estimados devido a sua natureza dinâmica, frente aos diversos pontos de operação do equipamento, para conseguir prever sua saída. O autor mostra que o treinamento do modelo (2 camadas intermediárias) foi bem sucedido, porém encerra o artigo sem apresentar o resultado da operação do modelo, a quantidade e quais foram as falhas detectadas a partir de alguma tomada de decisão, que também não foi apresentada.

No mesmo ano, o trabalho desenvolvido em Hafaifa et al. (2013) apresenta a mesma estratégia aplicada a um estudo de caso de uma válvula de controle de vazão em uma linha de bombeamento. O autor utiliza duas redes neurais para a geração de dois sinais de saída do equipamento, porém não entra em detalhes do que eles representam no mundo real. Entre as entradas do modelo estão as pressões e temperaturas no equipamento. Este trabalho autor demonstra uma reação clara do resíduo para algumas situações de falha e salienta que estes carregam uma informação valiosa, que pode ser utilizada para a tomada de decisão. Para a geração de alertas, o autor sugere uma segunda rede neural atuando a partir da magnitude do resíduo; bem como uma terceira, buscando distinção entre os modos de falhas. Todavia, o autor encerra o artigo sem demonstrar a metodologia ou como realizaria o treinamento dessas duas redes adicionais.

Em termos de estratégias alternativas, em MOUTINHO (2016) há uma proposta interessante de detecção de falha baseada em clusterização (por distância de Mahalanobis) e redução de dimensionalidade (PCA). A estratégia é memorizar os padrões dos períodos normais (pré-definidos) de operação de forma a buscar um distanciamento desses clusters nos períodos de falha. Novamente, há a utilização do *framework* DAMADICS e os testes realizados foram considerando dados de simulação. A metodologia apresenta resultados consistentes.

Venceslau (2013), que aborda falhas de agarramento de válvulas de controle, o autor faz um resumo interessante de diferentes estratégias de classificação e predição de falhas. Entre as estratégias apresentadas, faz referência a metodologia via equações de paridade, conforme Figura 2.3, salientando seu grande potencial em identificar anomalias.

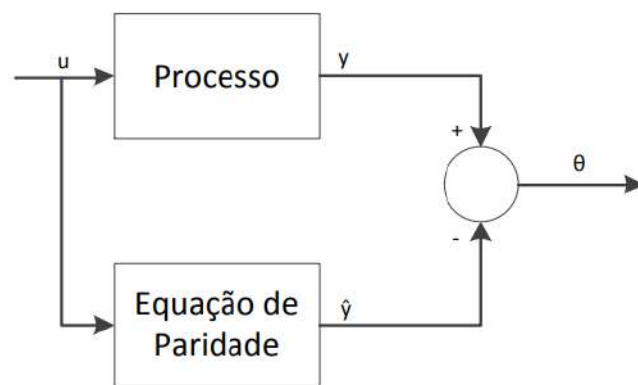


Figura 2.3: Estratégia baseada em equação de paridade, retirada de Venceslau (2013).

Note que esse tipo de abordagem é similar a utilizada nesse trabalho, porém o equacionamento é substituído por um modelo de aprendizado de máquina que faz uso de dados reais históricos. A metodologia apresentada pelo autor é relacionada a detecção de agarramento, com duas estratégias, pelas quais são estimadas duas variáveis latentes utilizadas para a detecção do grau de agarramento. A primeira considera a distância média dos pontos ao centroide a curva de *process value* x *operation value* *PV-OP* do equipamento como entrada da rede; enquanto a segunda estratégia utiliza o domínio frequencial, realizando a transformação do sinal de *process value* e usando a caracterização das frequências mais atuantes como entrada da rede. No geral é um trabalho interessante, mas que carece de testes em dados reais de equipamentos, uma vez que todo o dataset foi gerado através de modelos teóricos

de agarramento.

Capítulo 3

Descrição do Estudo de Caso

3.1 Introdução

A estratégia de detecção de falha apresentada será avaliada em um equipamento real do tipo Válvula de Controle que atua no fornecimento de água de resfriamento da camisa de um reator para uma grande indústria química brasileira. Mais detalhes do equipamento e do sensoramento disponível será apresentado na seção 3.2, bem como seu funcionamento descrito na seção 3.3.

3.2 O Equipamento

A válvula de controle é do modelo *Fischer* 8580, do fabricante EMERSON, similar ao mostrado na Figura 3.1. Este dispositivo possui um posicionador eletropneumático sendo caracterizada como Falha Aberta (Ar para Fechar), isto é, em caso de falha no sistema pressão, esta permanece totalmente aberta, permitindo a vazão de água.



Figura 3.1: Representação do equipamento retirado do site do fabricante (Emerson, 2019).

O equipamento possui um sistema de posicionamento inteligente, que reduz efeitos de fricção e de histerese, através de uma malha de realimentação interna. Infelizmente, porém, os dados dos sensores do posicionador **não** são historiados (armazenados em um sistema historiador) e, dessa forma, não há como se utilizar dessas informações.

Um resumo das características do equipamento pode ser visto na Tabela 3.1.

Equipamento:	FV-41010B (Válvula de controle)
Modelo:	Fischer 8580 (Tamanho 60)
Corpo:	Borboleta
Tipo de Posicionador:	Inteligente eletropneumático
Modelo Posicionador:	Emerson DVC6200f
Tipo de Atuador:	Mola Diafragma
Falha:	Aberta

Tabela 3.1: Características do equipamento.

3.3 Aspectos Operacionais

A válvula atua sob uma malha escrava de um sistema de controle que opera em bateladas, isto é, a operação segue uma receita para as diferentes etapas que ocorrem no reator.

Essas etapas são 6, que aqui serão numeradas de 0 a 6. Um descritivo das ações tomadas e a duração (média) de cada etapa são apresentadas na Tabela 3.3.

Etapa	Ação	Duração média (normalizada)
0	Preparação e verificação de segurança para a próxima batelada.	0,03
1	Todos os materiais são carregados para o reator	0,09
2	Reator é aquecido até a temperatura de início da reação	0,06
3	Reação é iniciada e mantida até atingir o percentual de conversão desejado.	0,64
4	Conteúdo do reator é esvaziado.	0,09
5	Limpeza do reator em preparação para a próxima batelada.	0,07
6	Opcional, realização de um procedimento de purga no reator	0,03

Tabela 3.2: Tabela esquemática demonstrando a duração média das diferentes etapas de uma batelada.

Note que a duração da etapa 3 é responsável por 64% do tempo de produção, conforme pode ser visto na Figura 3.2, sendo a etapa predominante e a mais interessante para modelagem, uma vez que é o coração do processo.

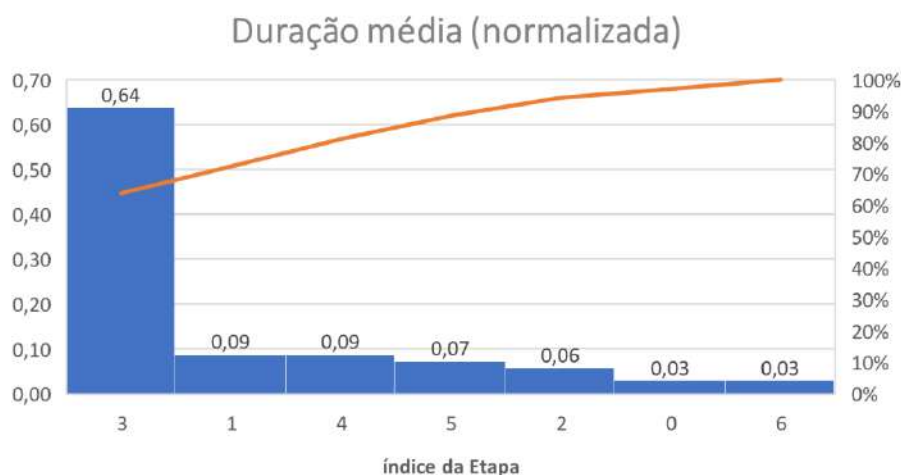


Figura 3.2: Duração normalizada das etapas da batelada.

Naturalmente, a operação da válvula muda consideravelmente entre uma etapa e outra. Além disso, o funcionamento do controle ao qual o equipamento está submetido também é alterado dependendo da etapa, modificando completamente a relação de ganhos e de abertura do equipamento, o que dificulta a análise e, conseqüentemente, a construção do modelo.

Uma figura da vazão da válvula (normalizada para um máximo em 1000 unidades) ao longo da batelada (com a separação etapas) é apresentado na Figura 3.3. Note que em momentos anteriores ao início da região de reação (em azul), a válvula permanece quase o tempo inteiro fechada mas possui um pico de abertura de 950 unidades, que não se repete em nenhum outro momento durante a batelada.



Figura 3.3: Figura esquemática mostrando a vazão da válvula de controle ao longo de uma batelada .

Repare ainda que a etapa de reação (apresentada na Figura 3.3 como "região 3") é a que apresenta mais variabilidade operacional no equipamento, além de períodos de baixas amplitudes de abertura - aspecto útil para a detecção de agarramento. Ainda, é o trecho de maior duração do batelada, conforme Figura 3.2.

Por esses motivos, apenas a etapa 3 de cada batelada será considerada para a

análise. Todavia, vale salientar que apesar de se tratar da mesma etapa, sua duração ou a intensidade de atuação no equipamento muda drasticamente, uma vez que há grandes mudanças no nível de carga e da composição do reator demandando mais da malha de resfriamento.

Capítulo 4

4.1 Pré-processamento

4.1.1 Normalização

A fim de preservar o sigilo nos dados do equipamento (que são informações referentes ao processo da indústria química), todos os dados exibidos serão normalizados, de forma a resultar em uma distribuição na escala $[0,1]$ (*min-max*) por serem de mais fácil interpretação, uma vez que não existem vazões negativas e a válvula de controle possui um limite máximo de abertura. Assim, os dados serão transformados através da Equação 4.1.

$$\hat{x} = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (4.1)$$

$\max(x)$ e $\min(x)$ representam, respectivamente, o máximo e o mínimo da distribuição x e \hat{x} o seu valor pós normalização. Na biblioteca *Scikit-learn*, existe uma implementação padrão desse estilo de normalização e pode ser acessada através da classe `MinMaxScaler()`, do pacote `sklearn.preprocessing.MinMaxScaler`.

Um exemplo prático do efeito da normalização nos dados pode ser visto na Figura 4.1:




Figura 4.1: Comparativo entre a normalização min-max e a normalização min-max, retirado de (Ben Alex Keen, 2019).

Uma demonstração do efeito da normalização da variável FC41010B.OUT (sinal de abertura da válvula) pode ser visto na Figura 4.2. Como esperado, o formato da distribuição da variável transformada é similar ao da variável original, sem prejuízo aos resultados e discussões que serão apresentados neste trabalho.

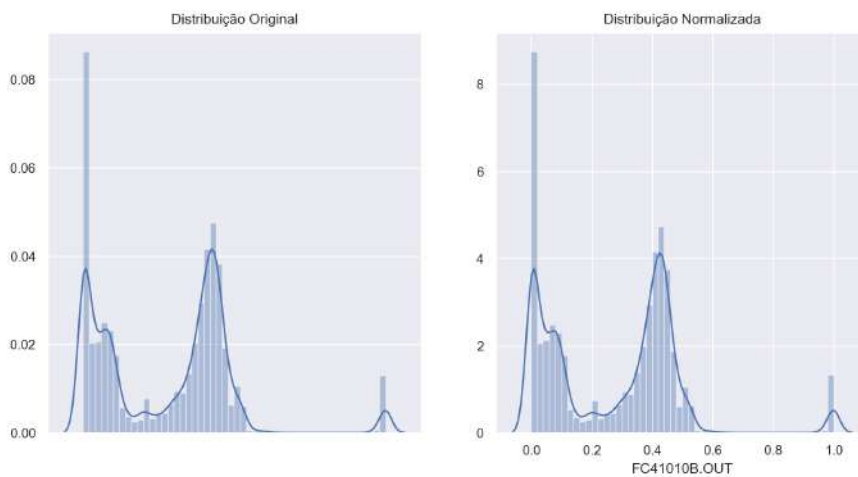


Figura 4.2: Distribuição original (valores propositalmente omitidos) e distribuição transformada através da normalização *min-max*.

4.1.2 A Base de Dados de Sensores

A base de dados é constituída por dados de sensores ao longo da linha de produção de uma indústria química nacional no período de 2014/11-2018/11, com intervalo de

aquisição de 1 minuto. Os sensores que agregam informações sobre o funcionamento da válvula de controle em questão são 3:

- FC41010B.OUT
- FC41010B.PV
- FC41010B.SP

O significado, a distribuição e suas estatísticas, de cada um deles será apresentada a seguir.

O sensor FC41010B.OUT mede o sinal de abertura da válvula de controle enviado pelo controlador, como pode ser visto na Figura 4.3. Sua faixa real em operação é de 0 a aproximadamente 0.6. Valores acima de 0.6 são momentos de operação com a válvula em outro modo de controle e serão excluídos posteriormente, na fase de remoção de *outliers* (seção 4.1.5).




Figura 4.3: Distribuição do sinal de controle de abertura enviado à válvula (FC41010B.OUT) no período de 4 anos.

Além disso, é possível notar que se trata de uma distribuição bimodal, sendo a primeira moda em torno de 0, correspondente à situação da válvula completamente fechada; e a segunda, em 0.45, associada à válvula aberta e estável em um patamar específico durante o processo. Repare também que há uma quantidade relevante de dados quando o equipamento está quase completamente fechado (entre 0 e 0.15).

Algumas estatísticas desta distribuição são apresentadas na Tabela 4.1.

FC41010B.OUT	
count	2053321.000
mean	0.271
std	0.221
min	0.000
25%	0.057
50%	0.335
75%	0.427
max	1.000

Tabela 4.1: Estatísticas da distribuição do sinal de controle de abertura enviado à válvula (FC41010B.OUT) no período de 4 anos.

O sensor FC41010B.PV mede a vazão de água que está passando pela válvula e pode ser entendido como sua abertura efetiva, isto é, o quanto a malha do atuador interno do equipamento conseguiu fechar, dado o sinal efetivo enviado à ele (FC41010B.OUT).

Como pode ser observado na Figura 4.1.2, a vazão que está passando pelo equipamento reflete o comportamento do sinal de controle (FC41010B.OUT) e apresenta também duas modas, uma centralizada em 0 (válvula completamente fechada) e outra em 0.68, patamar constante e estável durante o processo. Note que valores acima deste patamar representam momentos de operação com outra forma de controle e serão removidos posteriormente (vide Seção 4.1.5).

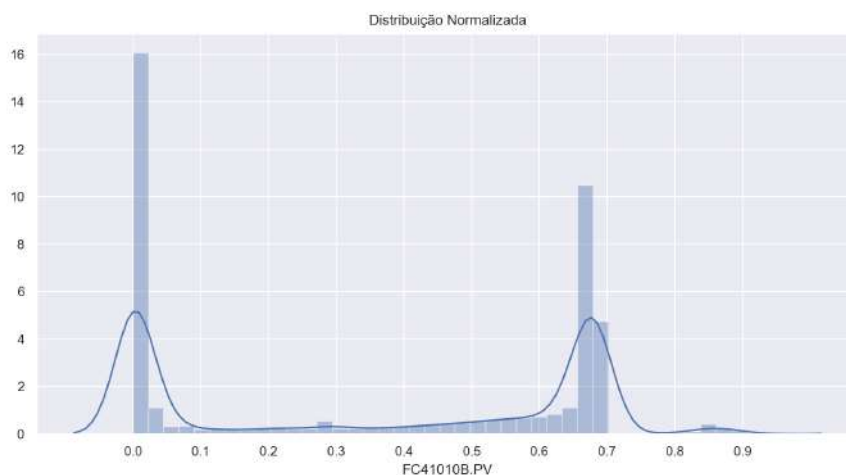


Figura 4.4: Distribuição do sinal de vazão da válvula (FC41010B.PV) no período de 4 anos.

As estatísticas desta distribuição podem ser vistas na Tabela 4.2.

FC41010B.PV	
count	2053321.000
mean	0.360
std	0.314
min	0.000
25%	0.003
50%	0.459
75%	0.678
max	1.000

Tabela 4.2: Estatísticas da distribuição do sinal de vazão da válvula (FC41010B.PV) no período de 4 anos.

O sensor FC41010B.SP mede o sinal de *set-point*, ou *target*, do controlador da malha de vazão. É através deste alvo que o controlador realizará o calculo de quanto deve ser o próximo sinal de abertura (FC41010B.OP) para a válvula a fim de colocá-la em um determinado patamar de vazão (FC41010B.PV). Um equipamento e uma malha de controle ideais (perfeitos) implicariam que o sinal *target* FC41010B.SP fosse exatamente idêntico ao realizado FC41010B.PV.

A distribuição do sensor FC41010B.SP pode ser visto na Figura 4.1.2, onde é possível perceber a similaridade (em forma) com a distribuição do sensor FC41010B.PV apresentado na Figura 4.1.2.

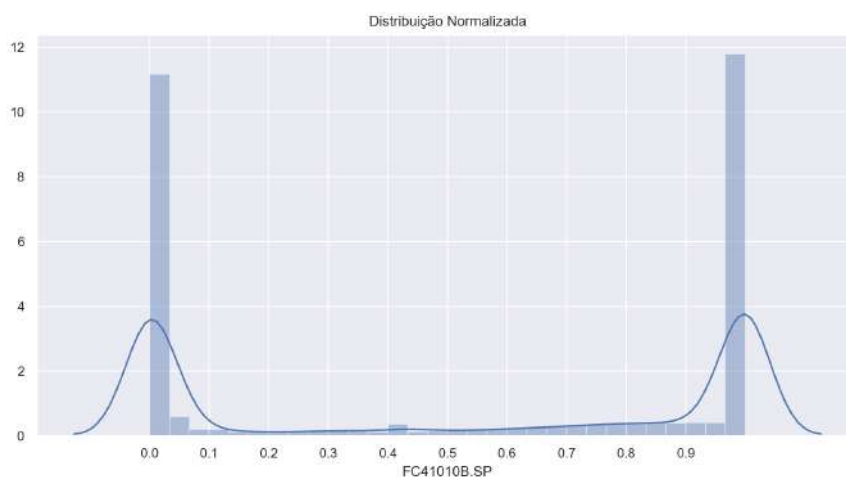


Figura 4.5: Distribuição do sinal de *set-point* do controlador (FC41010B.SP) no período de 4 anos.

As estatísticas desta distribuição podem ser vistas na Tabela 4.3.

FC41010B.SP	
count	2053321.000
mean	0.526
std	0.459
min	0.000
25%	0.000
50%	0.679
75%	1.000
max	1.000

Tabela 4.3: Estatísticas da distribuição do sinal de *set-point* do controlador (FC41010B.SP) no período de 4 anos.

4.1.3 A Base de Eventos de Falha

A base de eventos de falha foi montada através de registros de manutenção da área (física) em que o equipamento se encontra. Após a seleção dos registros que se referem ao equipamento, foi realizada uma categorização da possível origem do problema através de um texto descritivo. A tabela resultante é apresentada em 4.4.

Note, todavia, que a confiabilidade dessas informações é baixa, uma vez que ela é realizada pela equipe de operadores de forma manual, sem garantias da intervenção e da causa real do evento. Além disso, a descrição do evento é susceptível a erros, podendo referir-se a outro equipamento e, portanto, registrada incorretamente. Infelizmente, não havia maneiras - frente a empresa que cedeu os dados - de se obter informações mais confiáveis das indicadas.

Índice	Data Relato	Descrição	Categoria
1	28/04/2015	Valvula descalibrada	Descalibracao
2	07/07/2015	FV-41010B vazando pela Gaxeta	Gaxeta
3	10/07/2015	Tubing de vinil esta danificado	Tubing
4	09/08/2015	FV-41010B vazando pela gaxeta	Gaxeta
5	28/09/2015	Oscilações na indicação	Oscilacoes
6	13/01/2016	Sem informações	N/a
7	29/02/2016	FV-41010B vazando pela gaxeta	Gaxeta
8	07/03/2016	Descalibrada e dando passagem	Descalibracao
9	23/12/2016	Valvula descalibrada	Descalibracao
10	27/07/2017	Tubing de AI danificado	Tubing
11	19/12/2017	Tampa do posicionador solta	Posicionador

Tabela 4.4: Tabela com a informação dos eventos de falha e suas categorias.

Um outro fator de complexidade é o fato de que a data do registro não necessariamente se refere ao momento da intervenção, sendo que ele pode ter sido feito algumas horas ou dias depois. Isso acontece porque o operador aguarda o melhor momento para não prejudicar a produção e, caso não seja uma falha grave, pode até mesmo optar por continuar a operação com uma potência reduzida.

Dessa forma, como uma premissa neste projeto, foi adotada uma margem de até 5 dias em relação a data fim de cada evento, que representaria o limite máximo para a realização da manutenção. Assim, cada evento de falha constitui, ao invés de um instante, uma região em que o equipamento está em manutenção.

Além disso, a descrição dos eventos é pouco relevante para o trabalho, uma vez que o evento foi classificado. Desta forma, essa informação será retirada e, em conjunto com a data fim, teremos a tabela final de falhas exibida em 4.5.

Índice Relato	Data Relato	Data Fim	Categoria
1	28/04/2015	03/05/2015	DESCALIBRACAO
2	07/07/2015	12/07/2015	GAXETA
3	10/07/2015	15/07/2015	TUBING
4	09/08/2015	14/08/2015	GAXETA
5	28/09/2015	03/10/2015	OSCILACOES
6	13/01/2016	18/01/2016	N/A
6	29/02/2016	05/03/2016	GAXETA
7	07/03/2016	12/03/2016	DESCALIBRACAO
8	23/12/2016	28/12/2016	DESCALIBRACAO
9	27/07/2017	01/08/2017	TUBING
10	19/12/2017	24/12/2017	POSICIONADOR

Tabela 4.5: Tabela final informativa dos eventos de falha, considerando a data de fim do evento e as categorias.

4.1.4 A Base de Bateladas

A base referente as bateladas possui informações de data e hora de início, fim, a resina que estava em produção e a duração total da batelada (em minutos), conforme pode ser visto na Tabela 4.6.

	Start	End	Resina	Duration
0	2014-11-26 02:00:00	2014-11-26 08:34:00	3.0	394.0
1	2014-11-26 08:35:00	2014-11-27 00:35:00	3.0	960.0
2	2014-11-29 05:22:00	2014-11-29 16:03:00	3.0	641.0
3	2014-11-29 16:04:00	2014-11-29 22:24:00	3.0	380.0
4	2014-11-29 22:25:00	2014-11-30 05:25:00	3.0	420.0
5	2014-11-30 05:25:00	2014-11-30 11:27:00	3.0	362.0
6	2014-11-30 11:29:00	2014-11-30 17:41:00	3.0	372.0
7	2014-11-30 19:59:00	2014-12-01 02:29:00	3.0	390.0
8	2014-12-01 02:37:00	2014-12-01 12:30:00	1.0	593.0
9	2014-12-01 12:31:00	2014-12-01 20:36:00	1.0	485.0

Tabela 4.6: Demonstração da estrutura dos dados do registro das bateladas.

As estatísticas de duração das bateladas podem ser vistas na Tabela 4.7. Na média, tais eventos duram aproximadamente 7 horas; a de menor duração, 5 horas;

e a de maior duração cerca de 10 dias.

Duration	
count	3975.000000
mean	418.022642
std	360.891951
min	300.000000
25%	345.000000
50%	364.000000
75%	403.000000
max	15245.000000

Tabela 4.7: Estatísticas de duração das bateladas.

A Figura 4.6 apresenta a distribuição da produção das duas diferentes resinas, para a qual é observada uma proporção de aproximadamente 62% para a Resina 1 e aproximadamente 38% para a Resina 3. Como mostrado na na Seção 3.3, as resinas influenciam diretamente na forma e na intensidade em que a válvula de controle é operada, impactando no treinamento do modelo.




Figura 4.6: Distribuição das duas diferentes resinas em produção nas bateladas.

Além disso, a proporção entre as resinas a cada mês não é constante, uma vez que depende - majoritariamente - de decisões comerciais. A Tabela 4.8 apresenta a quantidade de bateladas de cada resina ao longo dos meses para todo o período

disponível. Em destaque, os anos e meses que apresentaram uma alta quantidade de bateladas (maior que 80), também exibindo proporções equilibradas entre as resinas 1 e 3 (implicando em percentual de Resina 3 próximo de 50%).

Ano	Mês	Nº Bateladas	% de Resina 3	2017	1	96	24.0
2014	11	8	100.0	2	91	44.0	
	12	51	31.4	3	98	38.8	
2015	1	112	13.4	4	104	60.6	
	2	64	0.0	5	100	31.0	
	3	71	0.0	6	80	53.8	
	4	108	52.8	7	103	8.7	
	5	108	82.4	8	8	87.5	
	6	68	32.4	9	4	0.0	
	7	91	74.7	10	84	82.1	
	8	87	42.5	11	95	30.5	
	9	59	62.7	12	111	10.8	
	10	106	47.2	2018	1	61	1.6
	11	107	9.3	2	60	100.0	
	12	82	46.3	3	28	46.4	
2016	1	102	29.4	4	53	0.0	
	2	45	20.0	5	67	0.0	
	3	102	66.7	6	65	0.0	
	4	79	43.0	7	104	19.2	
	5	96	29.2	8	96	40.6	
	6	91	56.0	9	90	40.0	
	7	62	32.3	10	81	0.0	
	8	113	18.6	11	74	1.4	
	9	98	80.6				
	10	117	43.6				
	11	91	30.8				
	12	104	64.4				

Tabela 4.8: Proporção da produção de resinas 1 e 3 ao longo do tempo.

4.1.5 Remoção de *outliers*

A remoção de *outliers* será feita em dois níveis. O primeiro deles será através da própria informação gerada pelo historiador, que atribui uma variável (*Good* ou *Bad*) a cada instante de coleta para cada sensor individualmente. Assim, caso haja algum problema na comunicação na rede, ele adota alguma estratégia de preenchimento

do dado (que depende de cada fabricante e da configuração), como interpolação ou repetição do último valor coletado, e atribui o valor *Bad*. No *dataset*, há aproximadamente 8% de dados *Bad* no período considerado.

Um exemplo desses momentos pode ser visto na Figura 4.9.

	FC41010B.OUT	FC41010B.PV	FC41010B.SP	FC41010B.OUT_quality	FC41010B.PV_quality	FC41010B.SP_quality	phase
Date							
2017-10-03 14:21:00	1.0	0.006300	0.009278	Good	Good	Good	-1
2017-10-03 14:22:00	1.0	0.006233	0.009180	Good	Good	Good	-1
2017-10-03 14:23:00	1.0	0.006167	0.009082	Good	Good	Good	-1
2017-10-03 14:24:00	1.0	0.006100	0.008984	Good	Good	Good	-1
2017-10-03 14:25:00	1.0	0.006034	0.008886	Good	Good	Good	-1
2017-10-03 14:26:00	1.0	0.005190	0.007643	Bad	Bad	Bad	-1
2017-10-03 14:27:00	1.0	0.005190	0.007643	Bad	Bad	Bad	-1
2017-10-03 14:28:00	1.0	0.005190	0.007643	Bad	Bad	Bad	-1
2017-10-03 14:29:00	1.0	0.005190	0.007643	Bad	Bad	Bad	-1
2017-10-03 14:30:00	1.0	0.005190	0.007643	Bad	Bad	Bad	-1

Tabela 4.9: Exemplo de dados com atribuição *Bad* pelo historiador e demonstrando a etapa atual (*phase* da batelada)

Nesse projeto, todos os instantes de qualidade *Bad* para alguma das três variáveis (.OUT, .PV ou .SP) foram removidos.

Além disso, para cada instante de tempo, temos a informação da etapa atual da batelada, denominada *phase*. Dessa forma, apenas os dados de sensores da *phase* 3 serão considerados, que correspondem à etapa de reação (*phase* = 3), conforme relatado na Seção 3.3. Na Figura 4.9, por exemplo, trata-se de um momento fora de operação e, portanto, sua indicação de *phase* é -1.

4.2 Visualização da Operação

Após as premissas adotadas e descritas na etapa de pré-processamento, é importante, para uma melhor compreensão dos leitores, demonstrar o funcionamento do equipamento (refletido nos sensores) durante as bateladas para as duas diferentes resinas.

4.2.1 Resina 1

Para o período de 01/10/2015 à 03/10/2015 apenas a resina 1 foi produzida, conforme apresentado na Figura 4.7.

	Start	End	Resina	Duration
827	2015-10-01 06:11:00	2015-10-01 12:21:00	1.0	370.0
828	2015-10-01 12:23:00	2015-10-01 18:10:00	1.0	347.0
829	2015-10-01 18:11:00	2015-10-02 00:28:00	1.0	377.0
830	2015-10-02 00:30:00	2015-10-02 06:17:00	1.0	347.0
831	2015-10-02 06:20:00	2015-10-02 12:12:00	1.0	352.0
832	2015-10-02 12:19:00	2015-10-02 18:05:00	1.0	346.0
833	2015-10-02 18:06:00	2015-10-03 00:03:00	1.0	357.0
834	2015-10-03 00:04:00	2015-10-03 17:59:00	1.0	1075.0
835	2015-10-03 18:00:00	2015-10-03 23:50:00	1.0	350.0
836	2015-10-03 23:52:00	2015-10-04 05:28:00	1.0	336.0

Figura 4.7: Período de operação da Resina 1 em 2015/10.

O sinal de vazão do equipamento pode ser visto na Figura 4.8. Note que o grau de oscilação da segunda batelada nessa figura é muito maior que nas demais.

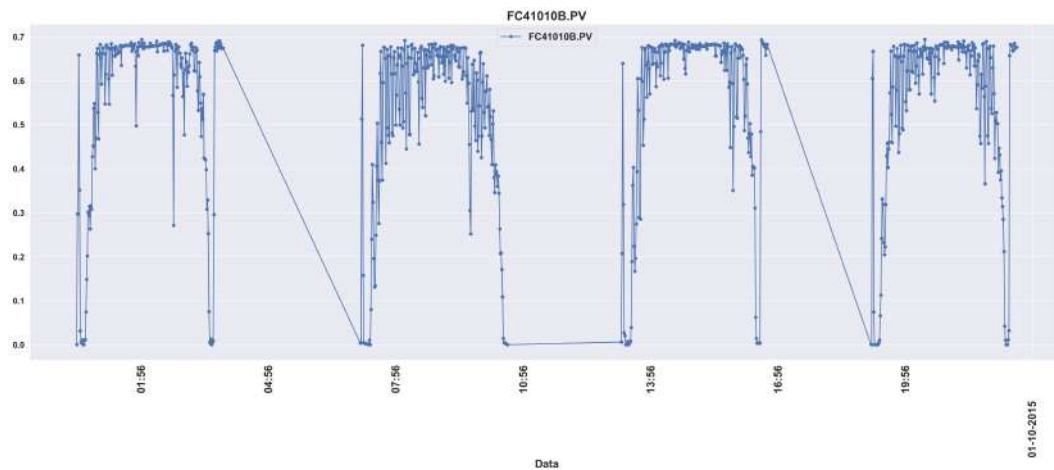


Figura 4.8: Sinal de vazão do equipamento para um período de produção da Resina 1 em 2015/10.

O sinal de *set-point* pode ser visto na Figura 4.9, onde é possível notar que a oscilação maior na segunda batelada provém do controlador, seguindo a operação da malha de controle externa ao qual ele é escravo.




Figura 4.9: Sinal de *set-point* do equipamento para um período de produção da Resina 1 em 2015/10.

Por fim, o sinal de controle enviado ao equipamento pode ser visto na Figura 4.10.

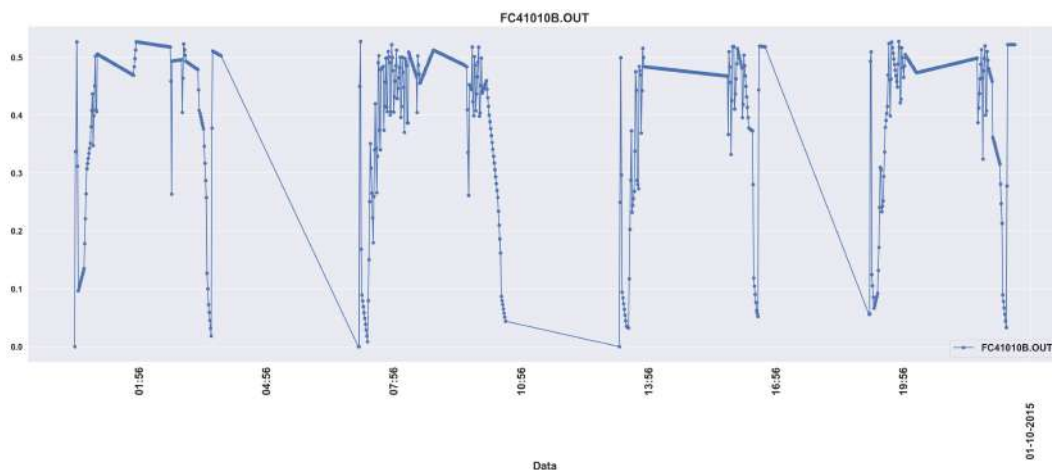


Figura 4.10: Sinal de controle enviado ao equipamento para um período de produção da Resina 1 em 2015/10.

4.2.2 Resina 3

Para o período de 10/10/2015 à 12/10/2015, apenas a resina 3 foi produzida, conforme apresentado na Figura 4.11.

	Start	End	Resina	Duration
858	2015-10-10 08:36:00	2015-10-10 15:34:00	3.0	418.0
859	2015-10-10 15:45:00	2015-10-10 22:09:00	3.0	384.0
860	2015-10-10 22:12:00	2015-10-11 04:16:00	3.0	364.0
861	2015-10-11 04:17:00	2015-10-11 10:21:00	3.0	364.0
862	2015-10-11 10:23:00	2015-10-11 16:10:00	3.0	347.0
863	2015-10-11 16:12:00	2015-10-11 22:09:00	3.0	357.0
864	2015-10-11 22:10:00	2015-10-12 04:16:00	3.0	366.0
865	2015-10-12 04:17:00	2015-10-12 10:13:00	3.0	356.0
866	2015-10-12 10:14:00	2015-10-12 16:09:00	3.0	355.0
867	2015-10-12 16:10:00	2015-10-12 21:59:00	3.0	349.0

Figura 4.11: Período de operação da Resina 3 em 2015/10.

O sinal de vazão do equipamento pode ser visto na Figura 4.10. Repare que, diferentemente da Resina 1, ele é muito mais regular e a amplitude das oscilações é consideravelmente menor.




Tabela 4.10: Sinal de vazão do equipamento para um período de produção da Resina 3 em 2015/10.

O sinal de *set-point* pode ser visto na Figura 4.2.2, onde é possível notar, também, a maior regularidade em sua forma se comparado com o da Resina 1.




Figura 4.12: Sinal de *set-point* do equipamento para um período de produção da Resina 3 em 2015/10.

O sinal de controle enviado ao equipamento pode ser visto na Figura 4.2.2.

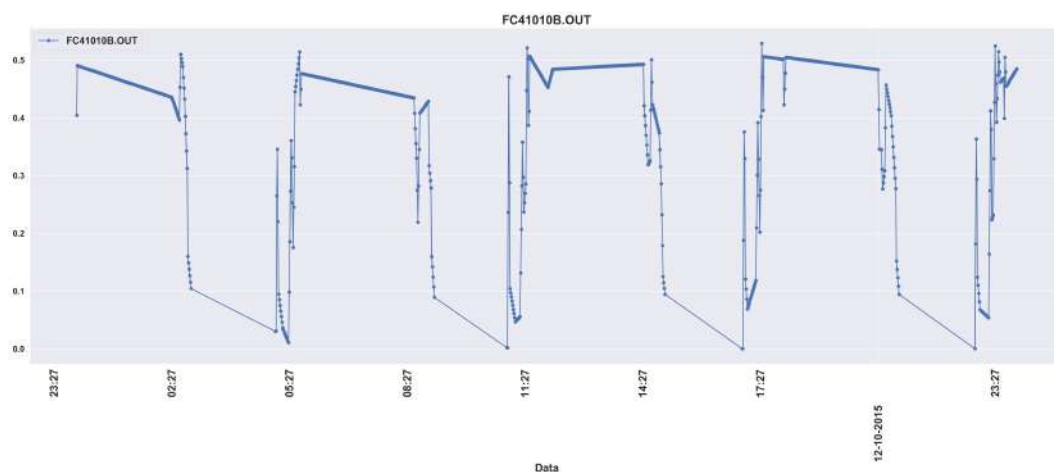


Figura 4.13: Sinal de controle do equipamento para um período de produção da Resina 3 em 2015/10.

4.3 Treinamento e Dimensionamento da Rede

O princípio fundamental da proposta desse trabalho é criar um modelo que aprenda o padrão de funcionamento do equipamento no período considerado normal e, por comparação, forneça insumos para a detecção de momentos de operação anômalos que possam ser oriundos de uma situação de falha.

Dessa forma, há dois fatores muito importantes para o sucesso dessa abordagem. São eles:

1. Primeiro: que o modelo seja treinado em um período considerado representativo; isto é, que todas as formas (ou faixas de operação) do equipamento sejam visitadas, preferencialmente, de forma balanceada, para que o modelo não dê prioridade a uma delas mais que as outras. Para o equipamento em estudo, isto significa que o período de treinamento deve incluir momentos de produção das duas resinas disponíveis (1 e 3). Caso não haja este cuidado, o modelo tende a errar mais em momentos de operação que ele não viu no treinamento, levando a uma conclusão incorreta quanto a tendência de falha na análise do resíduo.
2. Segundo: o período de treino escolhido não pode ser imediatamente sucedido por um momento de falha. Isso porque provavelmente já existe uma tendência de degradação acelerada do equipamento, e levaria o modelo a aprender este padrão. Por outro lado, períodos imediatamente posteriores a um período de falha também são arriscados, dado que a operação pode realizar ajustes no equipamento nesses momentos. Para saber se o período escolhido para o treinamento foi correto, basta observar nos gráficos do resíduo se as tendências fazem sentido perto e longe de dos momentos de falhas, ou seja, se O modelo aprendeu um padrão de degradação como “normal”, estas tendências estarão invertidas.

Para atender ao primeiro critério, foram avaliados períodos (de um mês) em que a produção das duas resinas foi aproximadamente igual. Conforme a Tabela 4.8, os meses candidatos foram: 4/2015, 10/2015, 12/2015, 06/2016 e 06/2017.

Depois, foi considerado o segundo critério, de forma a observar na lista da tabela de falhas (apresentada na Tabela 4.4) os meses candidatos mais distantes destes momentos defeituosos.

Assim, o mês escolhido para o **treinamento** foi o de 10/2015, que apresenta 106 bateladas e totaliza 23.742 instantes para o treinamento da rede. Para essa tarefa, foi utilizada a normalização *MinMaxScaler* apresentada em 4.1.1, mas apenas no período de treinamento (a partir dos dados originais) a fim de não trazer informações de todo o dataset para o conhecimento da rede e assim inserir algum viés no resultado.

Para o período de **validação**, foi escolhido o mês de 12/2015, propositalmente próximo ao de treino (preservando o padrão “normal” aprendido) e que apresenta um bom balanceamento entre as resinas disponíveis e contém 82 bateladas e 22041 para avaliação.

Os sinais de entrada e saída do modelo são: FC41010B.OUT, sinal efetivo enviado à válvula; FC41010B.SP, *set-point* do controlador (feedforward, avançado);

FC41010B.PV, Vazão de água que passa pelo equipamento. Esses sinais são representados esquematicamente na Figura 4.14.



Figura 4.14: Representação de treinamento do modelo com as entradas e saídas utilizadas

Em seguida, diversas estruturas e parâmetros da rede foram consideradas e testadas através de uma busca iterativa *GridSearch*, a fim de se encontrar a estrutura que apresentava melhor dimensionamento. O resultado dessa busca através da variação do número de neurônios pode ser visto na Figura 4.15. O treinamento foi feito com $batch_size = 50$ e $learning_rate = 0.001$, usando o *framework* Keras, Chollet et al. (2015), com *Tensorflow*, Abadi et al. (2015). O algoritmo de otimização utilizado foi o gradiente descendente (SGD) sem *momentum*. Além disso, todos os neurônio da camada intermediária tinham como função de ativação do tipo *tanh*.




Figura 4.15: Métrica R2 (Draper et al. (1998)) para diferentes números de neurônios na camada intermediária.

Como é possível notar, o aumento do número de neurônios a partir de 8 leva

a ganhos marginais, não compensando a elevação do custo computacional relativamente ao tempo de treinamento e inferência. Assim, a estrutura escolhida é de 8 neurônios na camada intermediária.

A Figura 4.16 apresenta as curvas de aprendizado do modelo escolhido (com 8 neurônios na camada intermediária), representadas através do erro médio quadrático MSE , ao longo das épocas, para o período de teste e de validação. Note que a rede consegue minimizar ambos os erros até a convergência na época 200.




Figura 4.16: Métrica R2 para diferentes números de neurônios na camada intermediária.

4.4 Resultados

4.4.1 Operação do Modelo

A fim de exemplificar a operação do modelo em uma batelada e demonstrar o seu aprendizado, os gráficos referentes a sua variável de predição (vazão de saída do equipamento) em relação ao sinal de abertura do controlador e do sinal de *set-point* para um dia do período de validação, são mostrados abaixo.

Na Figura 4.17 é apresentada a comparação da predição do modelo em relação ao valor real de vazão do equipamento (normalizados pela vazão máxima histórica). Note que o modelo satura em um patamar levemente abaixo ao do equipamento, e no

geral, apresenta boas previsões. Em amarelo, a marcação dos dados que pertencem a uma mesma batelada.

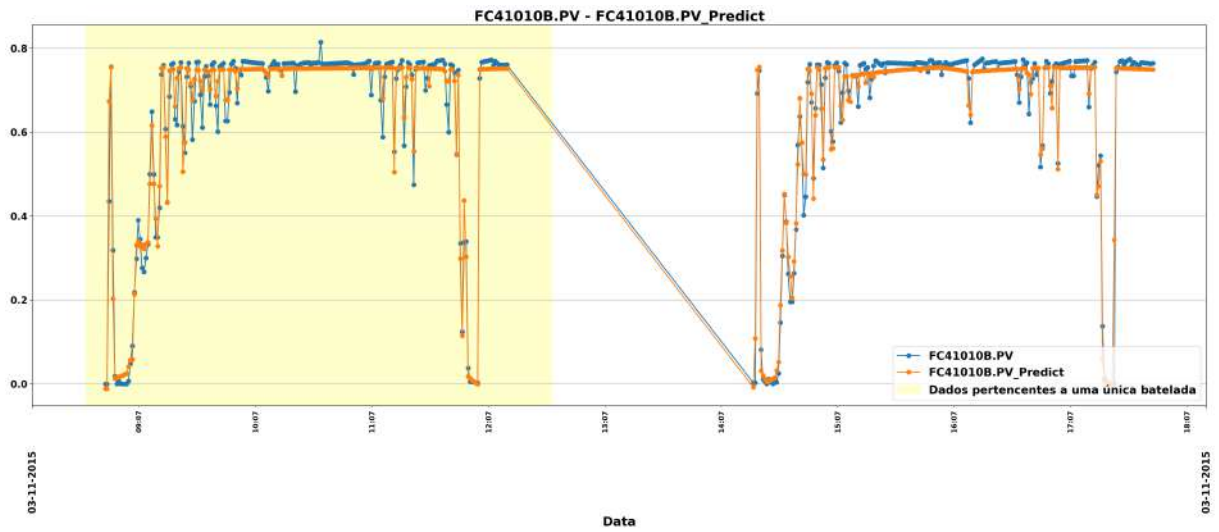


Figura 4.17: Exemplo de operação do modelo no período instantâneo de treinamento para os sinais de vazão (normalizados).

Para o mesmo período, o erro relativo entre a previsão do modelo e o valor real é apresentado em 4.18. Novamente, em amarelo, há a representação dos valores que estão na mesma batelada. Na próxima seção, eles serão agrupados na forma de erro médio absoluto.

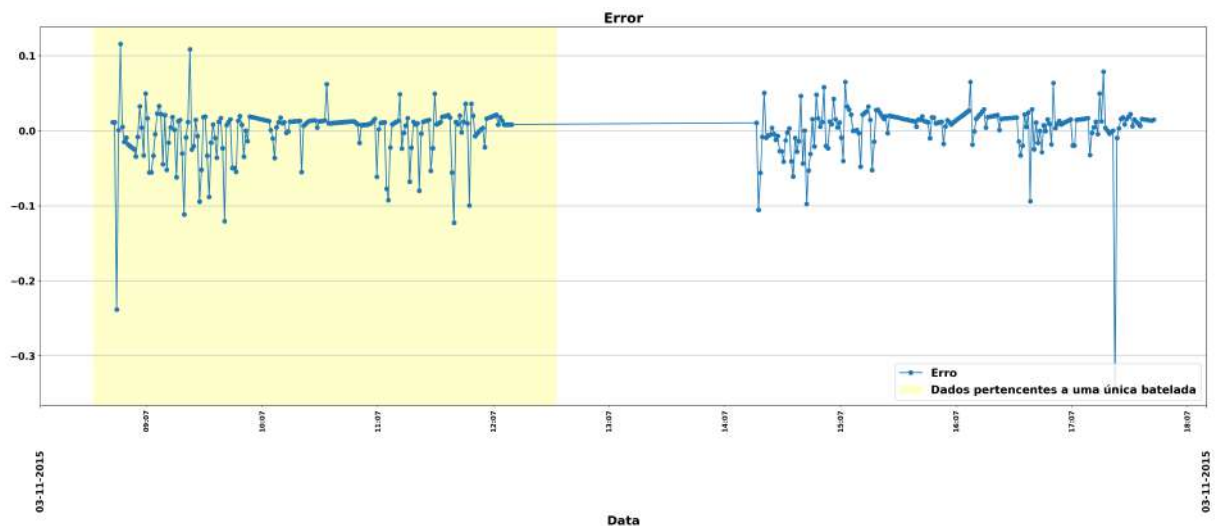


Figura 4.18: Erro relativo de previsão do modelo para o período de treinamento.

A Figura 4.19 apresenta o sinal de abertura solicitado pelo controlador (normalizado pelo seu valor máximo histórico), que é entrada para o modelo. Repare que ele fica em torno de 0.5 nos instantes de vazão constante, uma vez que a válvula não atinge sua vazão máxima em instantes normais de batelada.

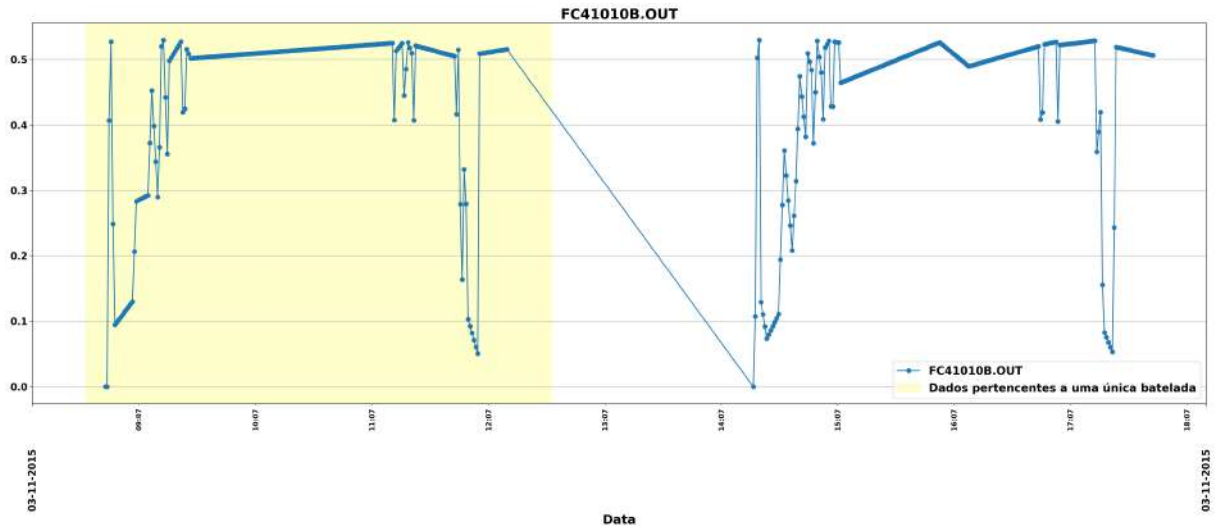


Figura 4.19: Exemplo de operação do modelo no período instantâneo de treinamento para o sinal de abertura enviado pelo controlador.

Por fim, a Figura 4.20 apresenta o sinal de *set-point* do controlador para o período (normalizado pela vazão máxima histórica), que é entrada para o modelo.

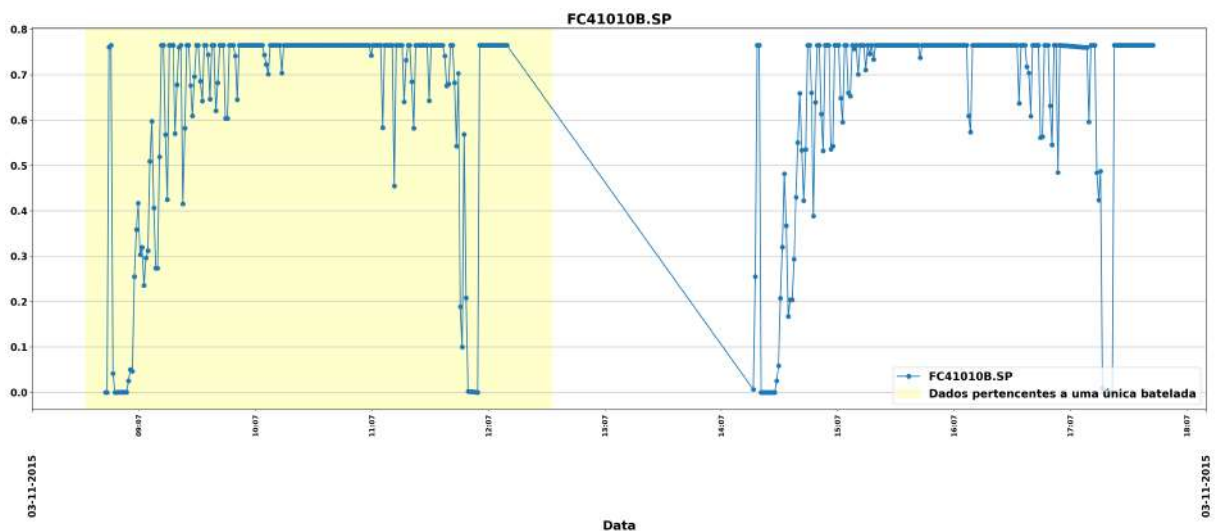


Figura 4.20: Exemplo de operação do modelo no período instantâneo de treinamento para o sinal de *set-point* (normalizado pelo seu valor máximo histórico).

4.4.2 Análise do Resíduo Médio

Como apresentado nas seções anteriores, o equipamento opera em batelada; e cada uma delas apresenta momentos mais fáceis ou mais difíceis para o modelo, relacionado com a amplitude e a frequência de abertura do equipamento – requisitos para o controlador.

Assim, uma forma de evitar artefatos periódicos na análise do resíduo e facilitar a visualização de tendências, optou-se por se considerar a **média do erro absoluto** dos resíduos de cada batelada, ao invés de sua avaliação puramente instantânea. Assim, o resultado de uma batelada inteira (cerca de 6h) se tornou um único dado. Essa forma de agregação também tende a tornar a análise mais robusta, uma vez que avalia um período de comportamento ao invés de um único instante, que é mais susceptível a ruídos de medição.

A fim de preservar o sigilo dos dados, esse resultado de média foi normalizado com a vazão máxima histórica do equipamento, resultando em um percentual (0-1) deste valor.

Em seguida, a fim de transformar os resultados das médias das bateladas normalizados em uma tendência, foi aplicado uma média móvel de 10 pontos.

O resultado da tendência médias normalizadas para todo o intervalo de tempo disponível pode ser visto na Figura 4.21.

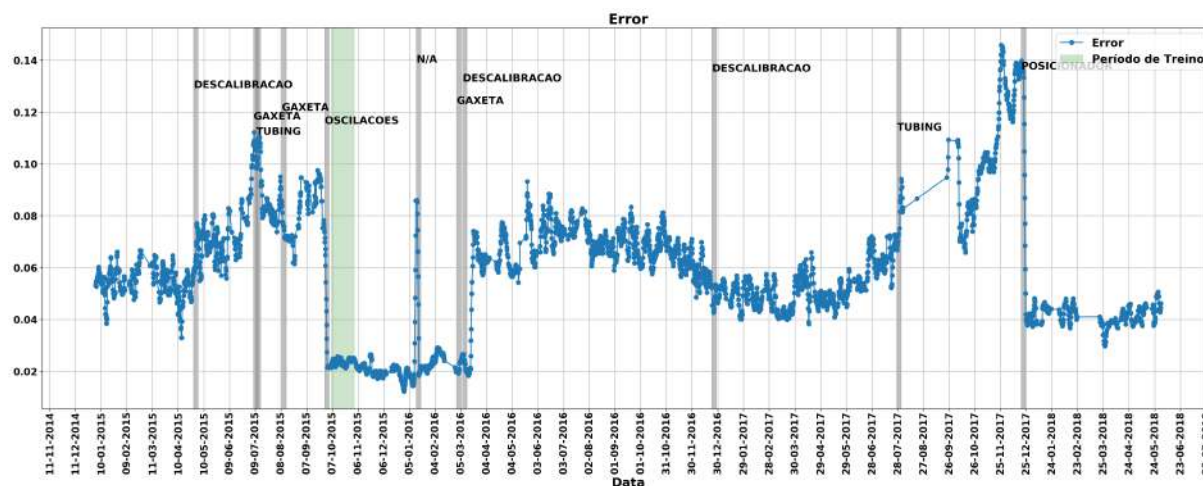


Figura 4.21: Gráfico da média dos resíduos por batelada, normalizados pela vazão máxima do equipamento, para todo o período disponível, com os momentos de falha marcados em cinza.

O primeiro aspecto a ser notado nesse gráfico é que o período de 10/2015 a 03/2016, que engloba o período de treino, é aquele que apresenta um menor patamar de erro – em torno de 0.02. Note que em 01/01/2016, há uma tendência

extremamente elevada anterior a uma falha sem descrição, mas de forte impacto no equipamento, resultando em diferenças de vazões cada vez maiores, como mostrado na Figura 4.22. Após esse evento, o erro segue em um patamar baixo até as duas marcações de falha (29/02/2016 Gaxeta e 07/03/2016 Descalibracao) onde, possivelmente, ocorreu uma intervenção no equipamento que alterou sua forma padrão de operação.

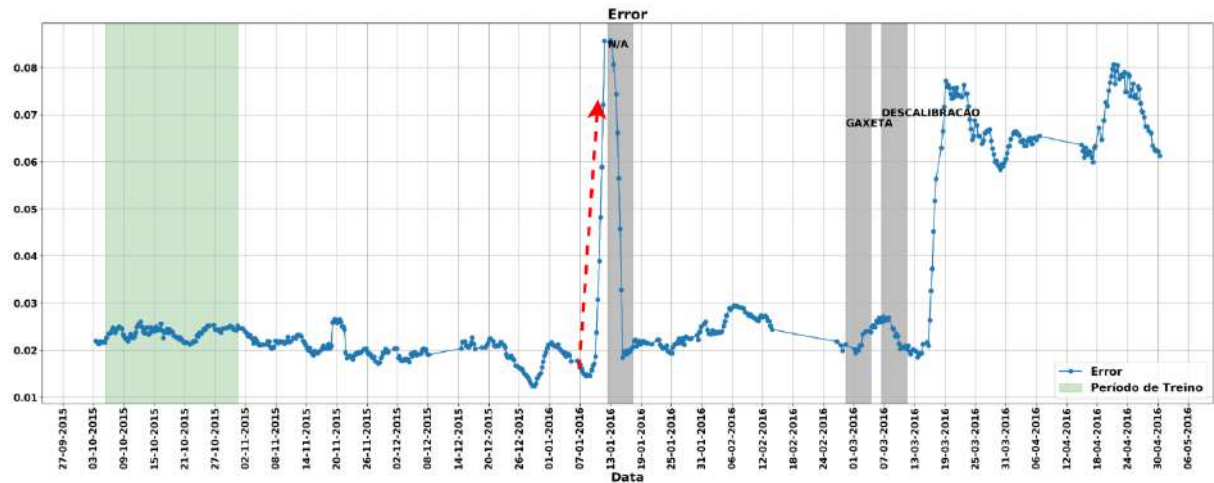


Figura 4.22: Período de erro baixo, com um forte evento em 13/01/2016. A linha tracejada em vermelho apresenta um auxílio gráfico da tendência aproximada de crescimento.

A primeira tendência interessante acontece no início do gráfico, entre 02/2015 à 10/2015, como pode ser visto na Figura 4.23. Note no crescimento gradual e consistente, consolidando a falha de Oscilações em 28/09/2015. Esse resultado pode significar que o equipamento sofreu degradação gradual, com as características da oscilação aparecendo lentamente.

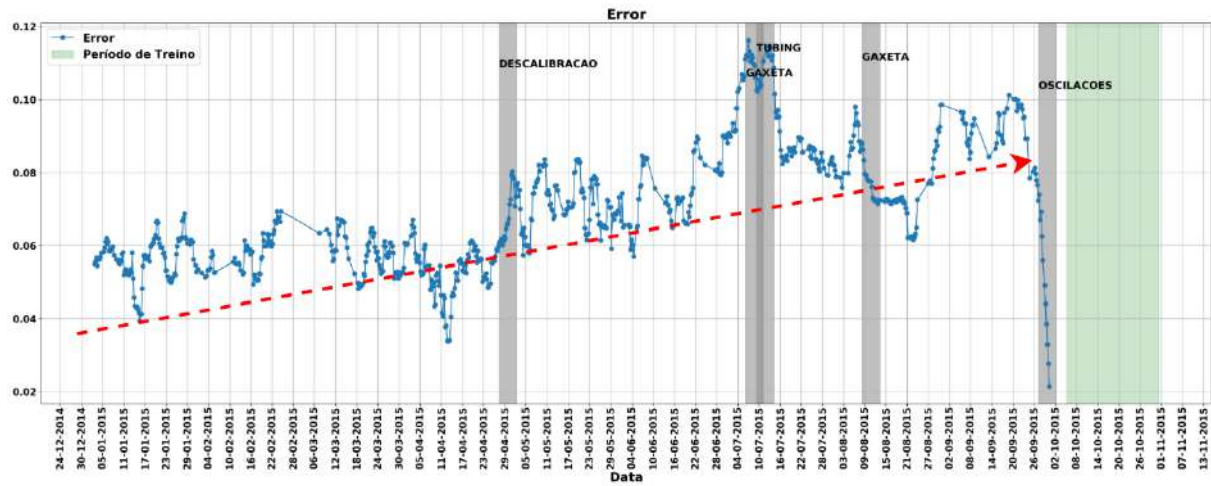


Figura 4.23: Período de 02/2015-10/2015, onde acontece um crescimento gradual da tendência até a falha de oscilações em 28/09/2015. A linha tracejada em vermelho apresenta um auxílio gráfico da tendência aproximada de crescimento.

Todavia, outro ponto interessante dentro desse período é uma segunda tendência - dentro dessa principal -, conforme destacado na Figura 4.24. Repare na mudança de crescimento da tendência principal (Oscilações) até as falhas de Tubing e Gaxeta, em 10/07/2015 e 09/08/2015, respectivamente. Essa característica mostra que uma dessas falhas possui característica agressiva, e seu impacto é imediato na performance, ao contrário da degradação gradual visto na falha de Oscilações.

Além disso, na mesma Figura 4.24 também é possível notar uma pequena elevação imediatamente anterior a falha de Gaxeta em 09/08/2015.




Figura 4.24: Tendência em anterior as falhas de Tubing e Gaxeta, em 10/07/2015 e 09/08/2015, demonstrando a característica agressiva dessas falhas, e anterior a falha de Gaxeta em 09/08/2015. A linha tracejada em vermelho apresenta um auxílio gráfico da tendência aproximada de crescimento.

O período de 04/2016 a 04/2017 não apresenta características de falha – com o valor do resíduo em decréscimo em alguns momentos -, e mesmo a falha assinalada como Descaibração em 12/2016 não apresenta uma tendência aparente.

De 04/2017 a 12/2017 temos uma tendência clara e forte em direção a falha de Posicionador, em 19/12/2017, como pode ser visto na Figura 4.25. Note que, após a falha, o patamar de erro cai drasticamente, retornando ao mesmo patamar anterior ao de início da tendência. Da mesma forma que a falha de Oscilações, a falha de Posicionador também parece se agravar gradualmente.

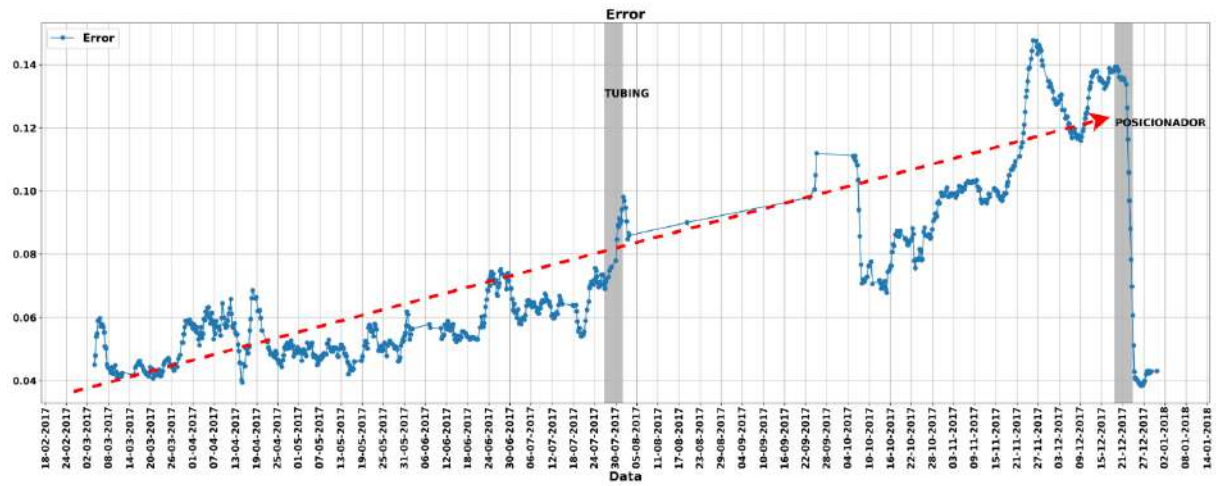


Figura 4.25: Período de 04/2017 a 12/2017 apresentando uma tendência clara e forte em direção a falha de Posicionador. A linha tracejada em vermelho apresenta um auxílio gráfico da tendência aproximada de crescimento.

No meio da tendência de Posicionador, há uma segunda falha de Tubing, marcada com data de 27/07/2019, mas que não apresenta uma tendência.

4.4.3 Operação do Modelo nos Períodos Pré-Falha

A partir das tendências apontadas na figuras anteriores é interessante observar a operação do equipamento em relação ao modelo. Para tanto, os gráficos das vazões (prevista x real) e das variáveis de entrada (.SP e .OUT) serão apresentados.

4.4.4 Falha de Tubing/Gaxeta em 10/07/2015

Conforme pode ser visto na Figura 4.26, em períodos anteriores a falha o modelo apresenta um *offset* no período estacionário em relação ao equipamento, com essa diferença em constante crescimento.

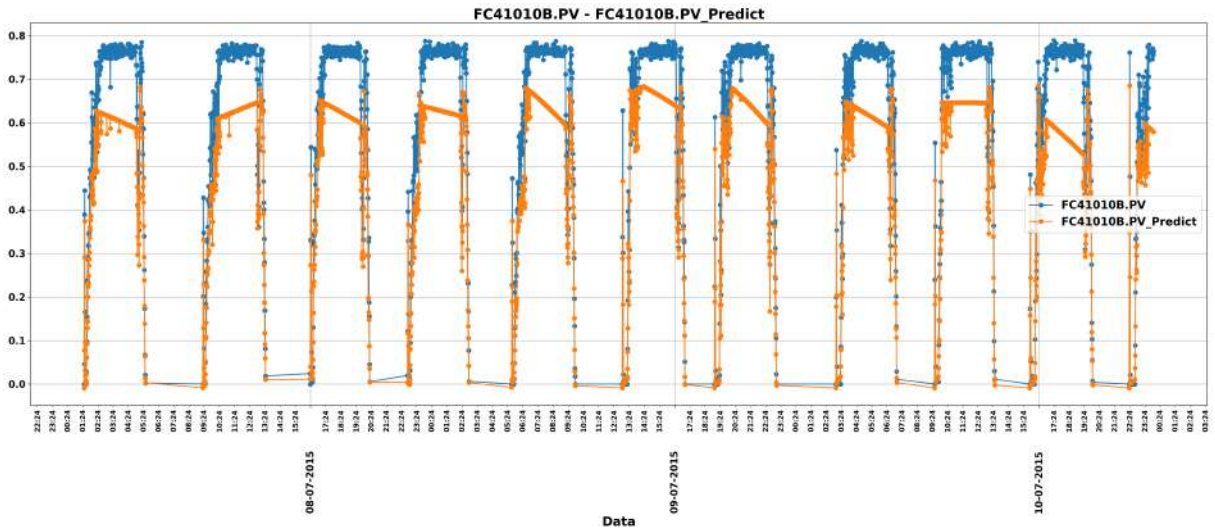


Figura 4.26: Comparação da vazão da válvula e a predita em dias anteriores a falha de 10/07/2015.

Todavia, ao analisar o sinal de *set-point* do controlador, na Figura 4.27, nota-se que a operação continua em um patamar normal, apesar de apresentar um ruído mais significativo na transição de subida.




Figura 4.27: Sinal de *set-point* do controlador em dias anteriores a falha de 10/07/2015.

A maior diferença, porém, vem ao notar o sinal do controle de abertura do equipamento apresentado na Figura 4.28, onde, inicialmente, o período estacionário

apresentava um sinal estático em torno de 0.5, agora ele se encontra em torno de 0.4 e decaindo ao longo do tempo, com forte instabilidade.




Figura 4.28: Sinal de abertura enviado pelo controle em dias anteriores a falha de 10/07/2015.

4.4.5 Falha de Oscilações em 28/09/2015

Como pode ser observado na Figura 4.29, em períodos anteriores a falha de Oscilações em 28/09/2015 há uma deformação na predição do modelo. Todavia, é nas primeiras horas do dia específico da falha que o problema se desenvolve a um nível crítico, com o equipamento tendo notória dificuldade em se manter em regime de *steady-state* e uma forte oscilação se inicia.




Figura 4.29: Comparação da vazão da válvula e a predita em dias anteriores a falha de 28/09/2015.

O sinal de *set-point* na Figura 4.30 mostra esse comportamento do ponto de vista do controle, em que deliberadamente tenta corrigir a posição do equipamento.

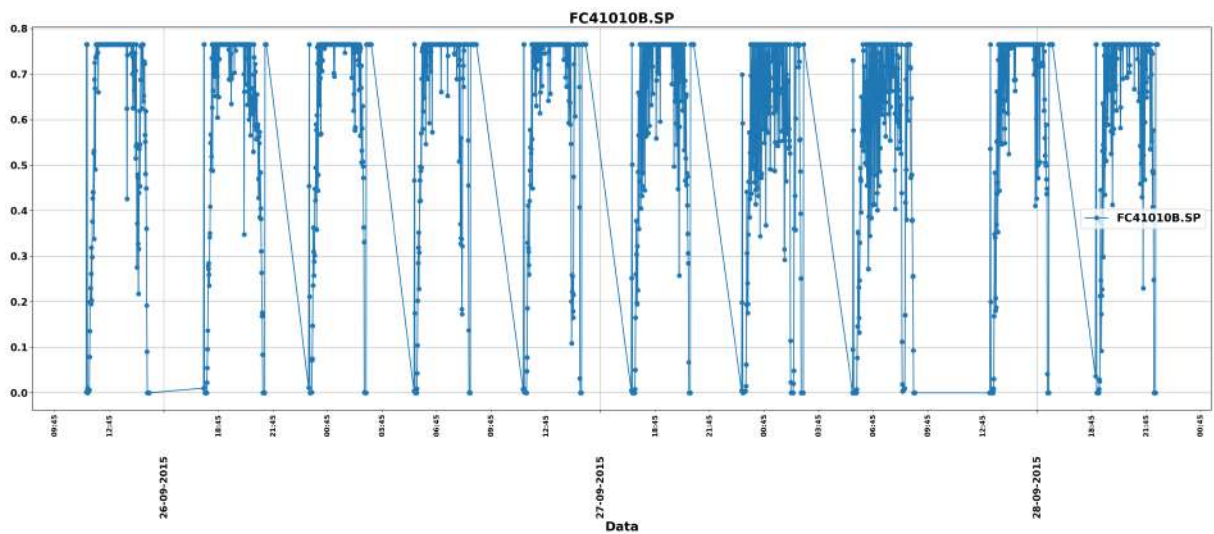


Figura 4.30: Sinal de *set-point* do controlador em dias anteriores a falha de 28/09/2015.

Por fim, a Figura 4.31 mostra o sinal de abertura enviado ao equipamento. Repare que o equipamento já vinha operando a um patamar mais baixo (0.4), bem como reflete as oscilações. Após solicionado, ele retorna ao patamar normal de operação em torno de 0.5 em seu momento *steady-state*.




Figura 4.31: Sinal de abertura enviado pelo controle em dias anteriores a falha de 28/09/2015.

4.4.6 Falha sem Classificação em 13/01/2016

Para a falha sem classificação em 13/01/2016, há uma redução gradual mas de forte intensidade na vazão do equipamento, conforme pode ser visto na Figura 4.32. Note que o modelo continua operando perfeitamente, demonstrando que os demais componentes estão em perfeito estado, mas o equipamento tende a abrir cada vez mais.




Figura 4.32: Comparação da vazão da válvula e a predita em dias anteriores a falha de 13/01/2016.

O *set-point* do controlador pode ser visto na Figura 4.33. Note que ele permanece operando em sua normalidade.




Figura 4.33: Sinal de *set-point* do controlador em dias anteriores a falha de 13/01/2016.

Por fim, na Figura 4.34 é apresentado o sinal de abertura enviado pelo controlador. A medida que o equipamento abre cada vez menos, o controle envia um sinal de abertura cada vez maior em compensação, não sendo suficiente para manter o equipamento dentro de sua normalidade.

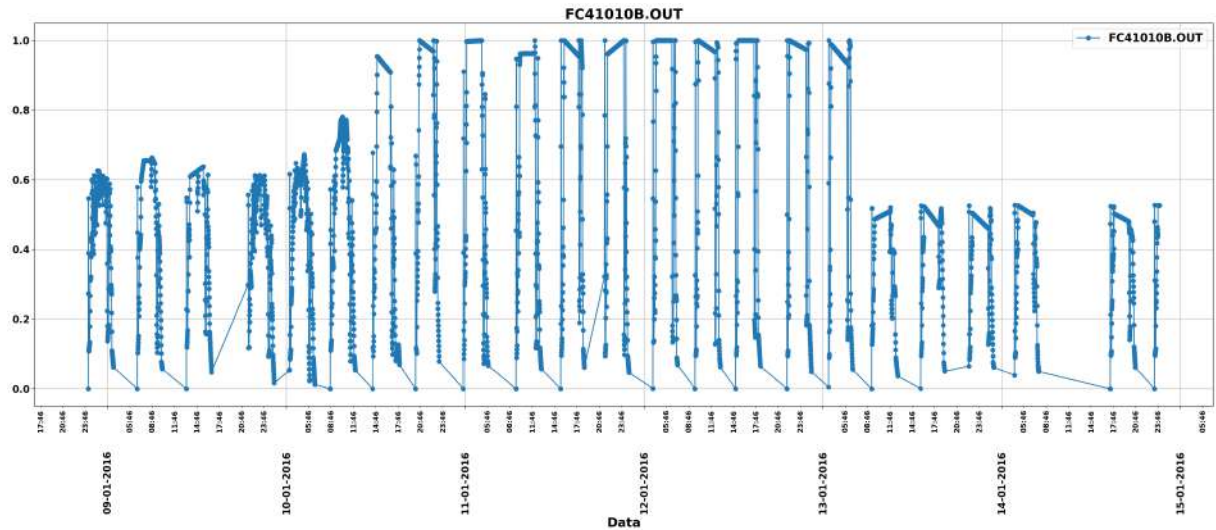


Figura 4.34: Sinal de abertura enviado pelo controle em dias anteriores a falha de 13/01/2016.

4.4.7 Falha de Posicionador em 19/12/2017

Por fim, para a falha de posicionador, o equipamento apresenta forte instabilidade em seu sinal de vazão, como pode ser visto em 4.35. Além disso, a predição do modelo se encontra num patamar mais baixo que o real. Repare, ainda, que apesar da falha estar datada em 19/12, a manutenção efetiva só foi realizada 22/12/2017, onde o equipamento retorna ao seu padrão normal de operação.

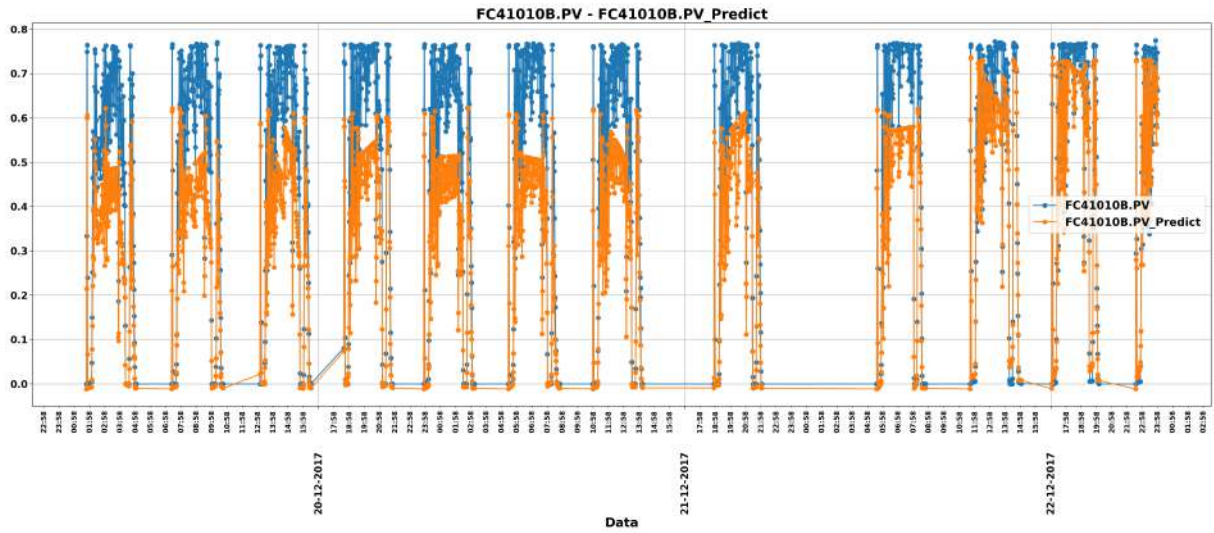


Figura 4.35: Comparação da vazão da válvula e a predita em dias anteriores a falha de 19/12/2017.

O sinal de *set-point* é apresentado Na Figura 4.36. Repare a presença das oscilações, com a malha de controle tentando corrigir sua posição




Figura 4.36: Sinal de *set-point* do controlador em dias anteriores a falha de 19/12/2017.

O sinal de abertura do equipamento é apresentado em 4.37, onde é notória a mudança de patamar de operação após a manutenção.

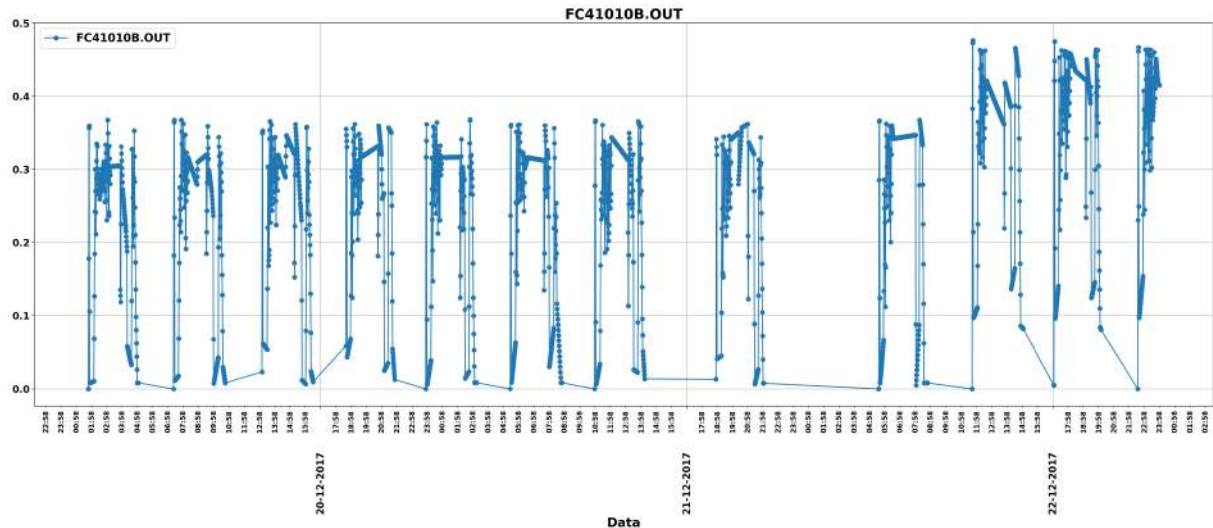


Figura 4.37: Sinal de abertura enviado pelo controle em dias anteriores a falha de 19/12/2017.

4.4.8 Lógica de Decisão baseada em Limiares Fixos

A partir da tendência do resíduo apresentada em 4.21, é possível traçar diversas lógicas e algoritmos para a geração de alarmes e a tomada de decisão quanto a parar o equipamento.

A lógica mais simples, implementada em produção nos projetos desenvolvidos usando essa estratégia até a presente data, é baseada em patamares fixos. Assim, a partir da tendência do resíduo observada em 4.21, deve-se realizar uma análise para uma definição (heurística), considerando-se os seguintes aspectos:

- O valor médio do resíduo nos períodos sem tendência, logo afastado dos períodos de falha (considerados normais).
- A intensidade da tendência anterior aos momentos de falha.
- Os valores máximos atingidos próximos aos períodos de falha.
- A frequência/quantidade de falsos-positivos considerada aceitável pela equipe de manutenção e operação do equipamento.

Note que há, essencialmente, um *trade-off* entre a antecedência da predição - traduzida pelo limiar de alarme - e a quantidade de falsos positivos. Ao escolher um limiar baixo, há mais antecedência para a detecção da falha, mas a chance de falsos positivos é maior. Por outro lado, escolher um limiar muito elevado pode fazer com que o cruzamento se dê quando o equipamento já se encontra em estado crítico, não

dando margem para a tomada de decisão sobre o melhor momento de parada do ponto de vista comercial.

Na esperança de se alcançar o melhor dos dois mundos, adotou-se uma estratégia de 2 limiares, representando diferentes criticidades: o primeiro, chamado de limiar de atenção, representa um valor que, a partir dele, deve-se monitorar mais de perto o equipamento e a tendência do resíduo, buscando o acompanhamento do seu crescimento; e o segundo, chamado de limiar de pré-falha, em que se deve realizar uma averiguação (e se for procedente uma manutenção) o mais rápido possível, logo correspondendo a uma situação de iminência de falha.

Uma heurística interessante para a definição desses limiares é buscar, para o limiar de pré-falha, um valor tal que a maior parte dos eventos aconteça após seu cruzamento, porém com a quantidade mínima possível de falsos positivos. Em outras palavras, para esse limiar, é importante uma baixíssima quantidade de falsos positivos de forma que haja uma total confiabilidade por parte da equipe de operação/manutenção do equipamento, uma vez que tais ocorrências correspondem a uma situação de alta gravidade. E, para o limiar de atenção, deve se considerar um valor o mais baixo possível a partir do limiar de pré-falha, de forma que suas ocorrências aconteçam com a máxima antecedência (da falha) mas sem ocasionar um aumento expressivamente no número de falsos positivos.

Uma observação importante sobre o número de falsos positivos: caso alarmes sejam gerados com alguma frequência (como uma vez ao mês) de forma improcedente, a experiência mostra que a equipe de operação tende a considerar aquele comportamento intrínseco do sistema e deixam de creditá-lo rapidamente, fazendo com que não acreditem em alarmes procedentes que venham a acontecer no futuro. Por isso, apesar de ser natural a tentativa de maximização da geração de alarmes corretos ao custo de falsos positivos, é importante ter em mente esse efeito frente aos operadores, uma vez que cabe a eles a verificação do equipamento. Dessa forma, caso a ferramenta caia em descrédito, todo o trabalho desenvolvido será em vão.

Segundo a heurística apresentada, pode-se escolher os seguintes limiares, já considerando a média móvel de 10 predições, conforme descrito na subseção 4.4.2 :

- Limiar de atenção: 0.085
- Limiar de pré-falha: 0.095

Para esses valores, temos o cenário representado na Figura 4.38. Em verde, os instantes de tempo considerados normais. Em amarelo, os que ultrapassaram o limiar de atenção, finalmente, em vermelho os que superaram o limiar de pré-falha.

Repare que, das falhas que demonstraram algum sinal de tendência e foram discutidas nas subseções anteriores, a maior parte possui um alarme de pré-falha anterior, exceto pela falha sem classificação (N/A) em 13/01/2016 (subseção 4.4.6),

que não chegou a atingir o segundo limiar. Note ainda que, para a falha de posicionador em 19/12/2017 (subseção 4.4.7), há 2 meses de operação em condições ruins, acima do limiar de pré-falha. Nesse caso, todavia, é creditado a uma decisão estratégia da operação de esperar um momento adequado (frente a prioridade de produção) para a manutenção do equipamento.



Figura 4.38: Resultado para todo o período com lógica de decisão baseada em limiares implementada.

Para a realização de uma análise numérica, foi utilizado como premissa de acerto a geração de um alarme dentro de 20 dias anteriores a evento de falha. Para a contabilização do número de alarmes gerados, considera-se o cruzamento entre os limiares. Ao longo de 3438 instantes (período equivalente a 3 anos), as estatísticas de classificação para o limiar de atenção (nível 1) e para o limiar de pré-falha (nível 2) são apresentados nas Figuras 4.39.




Figura 4.39: Estatísticas de classificação para os dois limiares para todo o período de operação (3 anos).

Um aspecto importante sobre esse resultado é que apesar de, à princípio, 45% parecer pouco (5 dentre 11 eventos detectados para cada um dos dois níveis de alarme), a comparação é feita em relação a não implementação de nenhum algoritmo preditivo (realidade industrial brasileira) e, portanto, a não detecção de nenhum dos eventos. Além disso, é importante salientar que esse resultado não representa o acaso, uma vez que a especificidade tende 100% dado que há uma infinidade de instantes demarcados como verdadeiros negativos, uma vez que a tendência permanece abaixo dos limiares durante quase todo o tempo.

Há ainda pouquíssimos casos de falsos positivos, com apenas 12 eventos para a limiar de atenção e 7 eventos para o limiar de pré-falha, resultando em uma taxa de acerto de 29 e 42% respectivamente.

A Tabela 4.11 apresenta em detalhes os registros de falha e as datas de primeiro alarme (dentro de até 20 dias de antecedência) para cada grau de severidade, bem como a antecedência gerada pelas previsões.

Tabela 4.11: Sumário de resultados de antecipação das falhas através da geração dos alarmes pelo cruzamento dos limiares.

Registros	Data da falha	Categoria	Severidade do Alarme	Data do primeiro sinal	Antecedência do Alarme (dias anteriores)
1	07/07/2015	DESCALIBRACAO	Atenção Pré-Falha	n/a	n/a
2	07/07/2015	GAXETA	Atenção Pré-Falha	22/06/2015 07:12 04/07/2015 09:19	14 dias 16:48:00 2 dias 14:41:00
3	10/07/2015	TUBING	Atenção Pré-Falha	22/06/2015 07:12 04/07/2015 09:19	17 dias 16:48:00 5 dias 14:41:00
4	09/08/2015	GAXETA	Atenção Pré-Falha	20/07/2015 08:27 06/08/2015 19:34	19 dias 15:33:00 2 dias 04:26:00
5	28/09/2015	OSCILACOES	Atenção Pré-Falha	08/09/2015 04:53 09/09/2015 04:58	19 dias 19:07:00 18 dias 19:02:00
6	13/01/2016	N/A	Atenção Pré-Falha	12/01/2016 08:43 n/a	0 dias 15:17:00 n/a
7	29/02/2016	GAXETA	Atenção Pré-Falha	n/a	n/a
8	07/03/2016	DESCALIBRACAO	Atenção Pré-Falha	n/a	n/a
9	23/12/2016	DESCALIBRACAO	Atenção Pré-Falha	n/a	n/a
10	27/07/2017	TUBING	Atenção Pré-Falha	n/a	n/a
11	19/12/2017	POSICIONADOR	Atenção Pré-Falha	n/a* 30/11/2017 02:24	n/a* 18 dias 21:36:00

* = nos 20 dias anteriores a falha o resíduo já estava acima do limiar de Pré-Falha.

Como pode ser notado, os limiares escolhidos foram capazes de gerar o efeito esperado: o primeiro limiar denota um período de atenção e demanda um acompanhamento mais próximo do equipamento e da tendência do resíduo, resultando em um alarme com uma antecedência mínima de 14 dias para os casos que apresentaram uma tendência. Por outro lado, o segundo limiar representa uma iminência do evento, com uma antecedência mínima de 2 dias para os referidos eventos.

Entre outras possíveis estratégias a serem avaliadas, considerada entre possíveis trabalhos futuros, é avaliar a derivada da tendência do resíduo, a fim de detectar com uma severidade maior as falhas de propagação rápida, como a Falha sem Classificação em 13/01/2016 (seção 4.4.6), que apenas cruzaram o limiar de alerta.

Capítulo 5

5.1 Conclusão

Neste trabalho foi apresentado um *framework* para a detecção de falhas em equipamentos industriais com baixa repetibilidade de eventos, tendo como seu principal diferencial o uso de dados apenas do período normal de operação do equipamento, de forma que os dados de períodos próximos a eventos de falha servem apenas para validação e ajustes do critério de decisão. Os principais pontos positivos desta abordagem são:

- A geração de tendência representando o desgaste do equipamento (fornecendo auxílio em seu monitoramento).
- O fornecimento de insumo para a geração automatizada de alarmes, seja através do critério de limiares fixos (abordada) ou de outras, tais como análise da derivada ou frequencial da tendência.
- A possibilidade de ajuste na agressividade na geração dos alarmes junto com os operadores do equipamento, ajustando-se conforme o *trade-off* entre antecedência no alarme e tolerância a falsos positivos.

No estudo de caso deste trabalho a estratégia se mostrou bem sucedida, mostrando-se capaz de identificar tendências de degradação em 6 dentre 11 registros de falha com uma baixíssima quantidade de falsos positivos. Há uma boa chance, inclusive, de que os demais 5 registros não sejam verdadeiros para o equipamento em questão, devido a inexistência de uma estrutura mais adequada para o armazenamento e o registro das notas de manutenção dos equipamentos. A antecedência mínima dos alarmes gerados cada evento de falha considerado é de 14 dias para o nível 1 (limiar de atenção) e 2 dias para o nível 2 (limiar de pré-falha).

Por outro lado, os principais negativos desta abordagem são:

- A necessidade de se treinar o modelo com dados de todos os patamares de operação do equipamento.

- O fornecimento uma resposta imprecisa sobre quando o equipamento vai falhar.
- A não possibilidade de se definir, sem uma segunda análise sobre o resíduo, o modo de falha.
- A abordagem apresentada baseada em limiares fixos foi baseada em heurística.

5.2 Trabalhos Futuros

Como trabalhos futuros e novas pesquisas, sugere-se:

- Buscar uma metodologia de definição estatística dos limiares de decisão baseados em limiares fixos.
- Propor novas estratégias de geração de alarme baseados em série de diferença (derivativa) e frequencial (FFT).
- Discutir e analisar sobre um possível retreino automatizado do modelo ao longo do tempo.
- Avaliar os resultados após implementação em produção (*online*) da metodologia, fornecendo-se novas sugestões e estudos de caso.

Referências Bibliográficas

- M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. URL <https://www.tensorflow.org/>. Software available from tensorflow.org.
- Ben Alex Keen. Feature scaling with scikit-learn, 2019. URL <http://benalexkeen.com/feature-scaling-with-scikit-learn/>. [Online; accessed 31-October-2019].
- F. Chollet et al. Keras. <https://keras.io>, 2015.
- N. Draper, N. Draper, H. Smith, and H. Smith. *Applied Regression Analysis*. Number v. 1 in Applied Regression Analysis. Wiley, 1998. ISBN 9780471170822. URL <https://books.google.com.br/books?id=8n8pAQAAMAAJ>.
- Emerson. Fisher 8580 high performance butterfly valve, 2019. URL <https://www.emerson.com/en-us/catalog/fisher-8580>. [Online; accessed 08-November-2019].
- Estadão. Bem vindos À quarta revolução industrial, 2019. URL <http://especiais.estadao.com.br/mundodigital/ola-mundo/>. [Online; accessed 09-August-2020].
- Forbes: Why Everyone Must Get Ready For The 4th Industrial Revolution. 4.0 industry, 2016. URL <https://www.forbes.com/sites/bernardmarr/2016/04/05/why-everyone-must-get-ready-for-4th-industrial-revolution/#6dd6829a3f90>. [Online; accessed 08-September-2019].

- R. Gouriveau, K. Medjaher, and N. Zerhouni. *From Prognostics and Health Systems Management to Predictive Maintenance 1: Monitoring and Prognostics*. 10 2016. doi: 10.1002/9781119371052.
- A. Hafaifa, A. Zohair Djeddi, and A. Daoudi. Fault detection and isolation in industrial control valve based on artificial neural networks diagnosis. *Control Engineering and Applied Informatics*, 15:61–69, 09 2013.
- S. S. Haykin. *Neural networks and learning machines*. Pearson Education, Upper Saddle River, NJ, third edition, 2009.
- M. Karpenko and N. Sepehri. A neural network based fault detection and identification scheme for pneumatic process control valves. In *2001 IEEE International Conference on Systems, Man and Cybernetics. e-Systems and e-Man for Cybernetics in Cyberspace (Cat.No.01CH37236)*, volume 1, pages 93–98 vol.1, Oct 2001. doi: 10.1109/ICSMC.2001.969794.
- M. Karpenko, N. Sepehri, and D. Scuse. Diagnosis of process valve actuator faults using a multilayer neural network. *Control Engineering Practice*, 11:1289–1299, 11 2003. doi: 10.1016/S0967-0661(02)00245-9.
- Limble CMMS. A complete guide to predictive maintenance, 2019. URL <https://limblecmms.com/blog/predictive-maintenance/#>. [Online; accessed 09-August-2020].
- M. C. J. MOUTINHO, M. V. B. Detecção de falhas em internos de válvulas de controle atuando em múltiplas regiões de operação. *Programa de Pós-Graduação em Engenharia Elétrica*, 2016.
- K. Prabakaran, T. U. Mageshwari, D. Prakash, and A. Suguna. Fault diagnosis in process control valve using artificial neural network. 2013.
- A. R. S. Venceslau. Detecção e diagnostico de agarramento em válvulas posicionadoras. *Programa de Pós-Graduação em Engenharia Elétrica e de Computação*, 2013. URL <https://repositorio.ufrn.br/jspui/handle/123456789/19934>.

Apêndice A

Redes Neurais Artificiais (RNA)

As redes neurais artificiais representam uma técnica que se baseia no funcionamento de neurônios biológicos do sistema nervoso de animais. Sua estrutura mais simples é o de um neurônio (índice k), formado por um conjunto de pesos sinápticos, uma função aditiva e uma função de ativação, conforme Figura A.1.

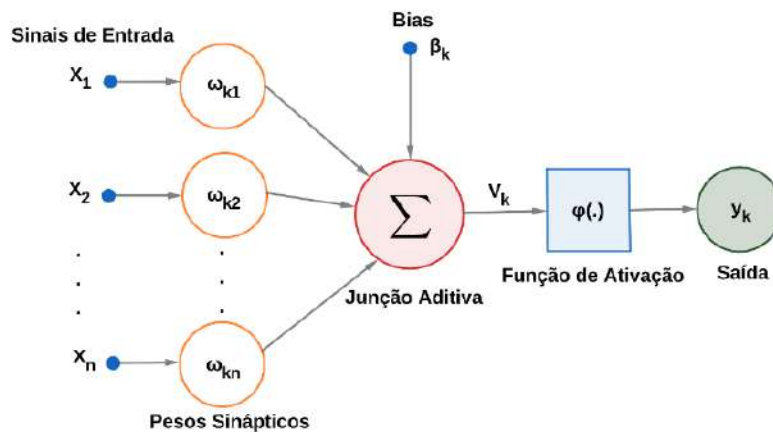


Figura A.1: Diagrama esquemático de um neurônio artificial

Os sinais da entrada no neurônio são representados pelo vetor $X = [x_1, x_2, x_3, \dots, x_n]$ e são multiplicados pelos respectivos pesos sinápticos, que são definidos pelos elementos do vetor $W = [w_1, w_2, w_3, \dots, w_n]$, gerando o valor v_k , comumente denominado potencial de ativação, de acordo com a expressão:

$$v_k = \sum_{i=1}^N x_i w_i + b_k \quad (\text{A.1})$$

O termo adicional b_k na Eq. A.1 provê um grau de liberdade a mais, que não é afe-

tado pela entrada nessa expressão, correspondendo tipicamente ao “bias” (viés). Em seguida, O valor v_k passa então por uma função matemática de ativação $\varphi(\cdot)$, com a característica de ser não linear, produzindo o valor final de saída y_k do neurônio. Algumas funções de ativação usadas são a degrau, sigmoide, tangente hiperbólica, softmax e ReLU (Rectified Linear Unit).

A combinação de neurônios em uma estrutura de camadas constitui o que é comumente referido como Perceptron Multicamadas (“Multi Layer Perceptron — MLP”). O vetor de valores de entrada x passa pela camada inicial, cujos valores de saída são ligados às entradas da camada seguinte, e assim por diante, até a rede fornecer como resultado os valores de saída da última camada. Pode-se arranjar a rede em várias camadas, tornando-a profunda e capaz de aprender relações cada vez mais complexas, conforme Figura A.2.




Figura A.2: Representação de uma rede multi-camadas.

O treinamento da rede geralmente é feito através do algoritmo *backpropagation* que, como o nome sugere, retropropaga o erro entre o valor predito pela rede e o valor real para promover o ajuste dos pesos (e limiares) de cada neurônio em cada camada da rede, atualizando os valores de acordo com a direção que minimiza a função custo, efetivamente realizando uma otimização por gradiente descendente.