

ENGENHARIA DE CONTROLE E AUTOMAÇÃO: ESTUDOS FUNDAMENTAIS



EDITORA CONHECIMENTO LIVRE

Frederico Celestino Barbosa

Engenharia de controle e automação: estudos fundamentais

1ª ed.

Piracanjuba-GO
Editora Conhecimento Livre
Piracanjuba-GO

1ª ed.

Dados Internacionais de Catalogação na Publicação (CIP)

Barbosa, Frederico Celestino
B238E Engenharia de controle e automação: estudos fundamentais
/ Frederico Celestino Barbosa. – Piracanjuba-GO

Editora Conhecimento Livre, 2023

165 f.: il

DOI: 10.37423/2023.edcl655

ISBN: 978-65-5367-260-4

Modo de acesso: World Wide Web

Incluir Bibliografia

1. equipamentos 2. processos 3. projetos I. Barbosa, Frederico Celestino II. Título

CDU: 620

<https://doi.org/10.37423/2023.edcl655>

O conteúdo dos artigos e sua correção ortográfica são de responsabilidade exclusiva dos seus respectivos autores.

EDITORIA CONHECIMENTO LIVRE

Corpo Editorial

MSc Edson Ribeiro de Britto de Almeida Junior

MSc Humberto Costa

MSc Thays Merçon

MSc Adalberto Zorzo

MSc Taiane Aparecida Ribeiro Nepomoceno

PHD Willian Douglas Guilherme

MSc Andrea Carla Agnes e Silva Pinto

MSc Walmir Fernandes Pereira

MSc Edisio Alves de Aguiar Junior

MSc Rodrigo Sanchotene Silva

MSc Wesley Pacheco Calixto

MSc Adriano Pereira da Silva

MSc Frederico Celestino Barbosa

MSc Guilherme Fernando Ribeiro

MSc. Plínio Ferreira Pires

MSc Fabricio Vieira Cavalcante

PHD Marcus Fernando da Silva Praxedes

MSc Simone Buchignani Maigret

Dr. Adilson Tadeu Basquerote

Dra. Thays Zigante Furlan

MSc Camila Concato

PHD Miguel Adriano Inácio

MSc Anelisa Mota Gregoleti

PHD Jesus Rodrigues Lemos

MSc Gabriela Cristina Borborema Bozzo

MSc Karine Moreira Gomes Sales

Dr. Saulo Cerqueira de Aguiar Soares

MSc Pedro Panhoca da Silva

MSc Helton Rangel Coutinho Junior

MSc Carlos Augusto Zilli

MSc Euvaldo de Sousa Costa Junior

Dra. Suely Lopes de Azevedo

MSc Francisco Odecio Sales

MSc Ezequiel Martins Ferreira

MSc Eliane Avelina de Azevedo Sampaio

SUMÁRIO

CAPÍTULO 1	5
CONTROLE LQI APLICADO A UM CONVERSOR CC-CC BOOST EM UM SISTEMA FV AUTÔNOMO	
Leandro L. O. Carralero	
Hebert Batista dos Santos	
Filipe A. C. Bahia	
Carlos E. V. Nunes	
André P. N. Tahim	
DOI 10.37423/230107035	
CAPÍTULO 2	24
PREDITOR DE MERCADO ACIONÁRIO BRASILEIRO UTILIZANDO MINERAÇÃO DE DADOS POR MEIO DO ALGORITMO RANDOM FOREST	
Victor Carvalho Vieira	
DOI 10.37423/230107067	
CAPÍTULO 3	54
DIAGNÓSTICO INTELIGENTE DE FALHAS EM EQUIPAMENTOS DINÂMICOS ATRAVÉS DA TRANSFORMADA WAVELET E DADOS ESTATÍSTICOS	
Luiz Alberto Pinto	
Diego Assereuy Lobão	
DOI 10.37423/230107079	
CAPÍTULO 4	75
ROBUST MODEL BASED FAULT DETECTION AND ISOLATION OF A SIX DEGREE OF FREEDOM HELICOPTER	
Lázaro F Sanson	
Victor Augusto F de Campos	
Alain S Potts	
DOI 10.37423/230107086	
CAPÍTULO 5	94
FORMAL REQUIREMENTS SPECIFICATION FOR MICROGRID BASED IN ARCHITECTURE IEC61850	
Miguel Angel Orellana Postigo	
José Reinaldo Silva	
DOI 10.37423/230107087	
CAPÍTULO 6	111
MICROGRID SYSTEM DESIGN BASED ON MODEL BASED SYSTEMS ENGINEERING AND GOAL-ORIENTED REQUIREMENTS ENGINEERING	
Miguel Angel Orellana Postigo	
José Reinaldo Silva	
DOI 10.37423/230107088	

CAPÍTULO 7 130

DESENVOLVIMENTO E IMPLEMENTAÇÃO DO MÉTODO DOS MQR-FE ACOPLADO A UM SISTEMA DE CAMR

Henrique Coldebella

Flávio Luiz Rossini

DOI 10.37423/230107095

CAPÍTULO 8 150

DESENVOLVIMENTO E AVALIAÇÃO DE UM CONTROLADOR PREDITIVO NÃO LINEAR BASEADO EM MODELO QUASILINEAR MODIFICADO: ABORDAGEM POR VARIÁVEIS DE ESTADO

Manoel de Oliveira Santos Sobrinho

Adhemar de Barros Fontes

DOI 10.37423/230107155

Capítulo 1



10.37423/230107035

CONTROLE LQI APLICADO A UM CONVERSOR CC-CC BOOST EM UM SISTEMA FV AUTÔNOMO

Leandro L. O. Carralero

UFBA

Hebert Batista dos Santos

UFBA

Filipe A. C. Bahia


UFBA

Carlos E. V. Nunes

UFBA

André P. N. Tahim

UFBA



Resumo: Os sistemas fotovoltaicos (FV) autônomos sem armazenamento de energia são muito utilizados em áreas rurais. Neste tipo de sistemas, a tensão de saída deve ser regulada para estar em um valor fixo, independente de mudanças nas condições climáticas ou variações na carga de saída. Portanto, este artigo apresenta um controle Linear Quadrático Integral (LQI) aplicado a um conversor CC-CC boost com o objetivo de regular a tensão de saída em um sistema FV autônomo, reduzindo o impacto de fatores externos. Ainda, a modelagem matemática do conversor boost utilizado é introduzida no trabalho. O projeto do controlador LQI foi desenvolvido a partir da modelagem anterior, utilizando os valores do circuito de potência.

Finalmente, a proposta é validada por simulações e resultados experimentais obtidos através do protótipo desenvolvido. Para isso, foram realizados testes diferentes, mudando os valores de irradiação no painel FV, mudando a carga CC na saída do conversor e inserindo sombreamento no painel FV.

Palavras-chaves: Sistemas FV autônomos; tensão de saída; conversor CC-CC boost; controle LQI; projeto do controlador.

1. INTRODUÇÃO

Os sistemas fotovoltaicos (FV) autônomos são sistemas que independem da rede elétrica convencional para seu funcionamento, sendo possível sua utilização em localidades remotas e de difícil acesso à rede de distribuição elétrica (Villalva and Gazoli, 2012). Na literatura existem dois tipos de sistemas FV autônomos: com armazenamento e sem armazenamento. O primeiro tipo de subsistema pode ser utilizado em sistemas de comunicação, iluminação pública ou em residências rurais. O segundo subsistema autônomo refere-se a um sistema sem armazenamento, onde uma carga em corrente contínua (CC) é conectada, através de um conversor estático, à saída do painel FV. Sua maior utilização se encontra em sistemas de bombeamento e irrigação em áreas rurais, onde se precisa ligar bombas e outros equipamentos. Esse tipo de configuração ao apresenta maior viabilidade econômica, já que não apresenta armazenamento de energia, mas não garante a máxima extração de potência do sistema FV (Salas, 2017).

Os conversores CC-CC são os encarregados do processamento da energia nestes sistemas. Sua principal função é manter o valor da tensão fixa para alimentar as cargas, já que a corrente vai depender da potência demandada por cada equipamento. Basicamente, estes conversores são classificados em isolados e não isolados. Os isolados tem a vantagem de criar a isolação galvânica e evitar choques elétricos, entre outras. O principal problema é que ao utilizar um transformador de alta frequência o tamanho do protótipo aumenta e encarece o projeto. Entre os conversores isolados mais utilizados encontram-se flyback, forward, push-pull, entre outros. Logo, os conversores não isolados tem a vantagem de serem mais eficientes em relação aos anteriores e são mais fáceis de implementar. Os conversores não isolados mais conhecidos são buck, boost, buck-boost, Cuk, SEPIC e Zeta (Raghavendra et al., 2020).

Em sistemas FV autônomos sem armazenamento de energia estes conversores são controlados para manter a tensão do barramento CC em um valor que depende de cada equipamento.

Portanto, o controle aplicado nestes deve ser bem projetado e capaz de manter essa tensão na saída independente das mudanças que possam acontecer. Na literatura são encontrados vários métodos de controle utilizados a fim de regular a tensão de saída de um conversor e rejeitar os distúrbios experimentados por este. Alguns dos métodos mais utilizados pelos autores dentro deste contexto são: método de alocação de polos, especificação de margens de fase e de ganho, otimização de desempenho com base em funções de custo quadráticos ou ainda alguns métodos mais avançados, como controladores robustos, controladores adaptativos e controladores por lógica fuzzy (Blaabjerg

et al., 2018; Asadi et al., 2018).

Os conversores CC-CC são sistemas que apresentam um comportamento não linear devido ao chaveamento dos seus interruptores. No entanto, para projetar o controlador, os modelos matemáticos destes podem ser linearizados e considerados invariante no tempo, dessa forma, técnicas de controle lineares podem ser aplicadas afim de se obter controladores que atendam os critérios de projeto. A grande vantagem de se aplicar uma técnica de controle linear é sua sistematização e a existência de ferramentas que auxiliam no projeto dos controladores (Ogata, 2010).

O Regulador Linear Quadrático (LQR) é um controlador ótimo utilizado por uma técnica de controle baseada na realimentação de estados. No controle por realimentação de estados, o sinal de controle é uma função das variáveis de estado, as quais se supõe que são medidas ou devidamente estimadas. Esta técnica de controle é utilizada com o objetivo de atingir o equilíbrio frente a pequenas variações, melhorando o tempo de resposta e o sobressinal da dinâmica do sistema, garantindo a estabilidade (Zhang et al., 2015). Ainda, a fim de melhorar o desempenho, uma ação integradora é inserida ao LQR, obtendo o controlador Linear Quadrático Integral (LQI). Este tem por objetivo minimizar uma função custo quadrática. Por esta razão o LQI pode superar outros tipos de controladores lineares, já que melhora a operação transitória de um sistema.

Vale ressaltar que ao aplicar o controle LQI, é necessário linearizar o conversor CC-CC em torno de um ponto de operação e que o desempenho do controlador vai depender deste ponto (Malkapure and Chidambaram, 2014).

Assim, o objetivo deste trabalho consiste no projeto e desenvolvimento de um controlador LQI aplicado a um conversor CC-CC boost em um sistema FV autônomo, com o propósito de regular a tensão de saída do conversor, analisando suas respostas quando o sistema observado for submetido a variações nas condições climáticas e na carga CC de saída. Então, este artigo está organizado da seguinte forma: A próxima seção descreve o sistema FV autônomo proposto neste trabalho, assim como a modelagem matemática do conversor boost. A seção 3 aborda os valores do circuito de potência e o projeto do sistema de controle proposto. A fim de validar a proposta, simulações e resultados experimentais são apresentados na seção 4, realizando variações na irradiação, na carga de saída e inserindo sombreamento no painel FV. Finalmente, algumas conclusões são abordadas na última seção.




Figura 1. Sistema FV autônomo proposto.

2. SISTEMA PROPOSTO

O sistema FV autônomo utilizado neste trabalho está representado na Fig. 1. Neste caso, um painel FV está alimentando uma carga CC mediante um conversor CCCC boost que está sendo regulado por um controlador.

Logo, o conversor boost está formado por um interruptor (S_1), um diodo (D_1), um indutor (L), um capacitor na entrada (C_{pv}), um capacitor na saída (C) e a carga na saída (R_s). O sistema de controle mede a tensão de saída do conversor e analisa qual será o sinal que se aplicará para criar a modulação por largura de pulso (PWM) que acionará o interruptor, a fim de manter a tensão no valor de referência. Para desenvolver o sistema de controle deve se conhecer o comportamento do conversor, portanto, a seguir este será estudado com mais detalhes.

2.1 MODELAGEM DO CONVERSOR BOOST

A topologia do circuito para o conversor CC-CC boost é apresentada na Fig. 1, onde a tensão de saída do conversor é sempre maior do que a tensão de entrada, por isso recebem o nome de elevadores de tensão. Primeiramente, é necessário assumir algumas hipóteses para o circuito mostrado. Sendo assim, algumas variáveis podem ser desprezadas sem a necessidade de afetar a resposta do sistema de maneira significativa. Portanto, para os dados da modelagem, a resistência no interruptor, a tensão no diodo e a resistência nos capacitores foram consideradas desprezíveis. A resistência no indutor (R_L) foi levada em consideração, já que é a que causa perdas significativas no circuito de potência.

Este trabalho analisa o conversor boost no modo de condução contínua (MCC) (Barbi, 2015). Neste modo o conversor apresenta dois estados topológicos, como ilustrado na Fig. 2. O primeiro é quando o interruptor está ligado (ON) e o outro quando está desligado (OFF). A partir da




Figura 2. Estados topológicos do conversor boost.

Análise desenvolvida por Barbi (2015), podemos encontrar o ganho estático do conversor e o modelo matemático para os valores médios do conversor:

$$\frac{V_C}{V_{pv}} = \frac{1}{1-D} \left[\frac{R_s(1-D)^2}{R_L + R_s(1-D)^2} \right]; \quad (1)$$

$$\begin{cases} C \frac{dv_C}{dt} = (1-D)i_L - \frac{v_C}{R_s} \\ L \frac{di_L}{dt} = -(1-D)v_C - R_L i_L + V_{pv}; \end{cases} \quad (2)$$

Onde D é a razão cíclica do conversor boost para a frequência de chaveamento selecionada (f_c).

A partir do modelo médio apresentado anteriormente, é possível encontrar o modelo do conversor boost no espaço de estados. As matrizes de estado podem ser atribuídas, através da linearização do sistema em torno de um ponto de operação, através do cálculo do jacobiano (Erickson and Maksimovic, 2020). Desta forma, o modelo matemático para este conversor em espaço de estados, pode ser representado como:

$$\begin{bmatrix} \dot{v}_C \\ \dot{i}_L \end{bmatrix} = \begin{bmatrix} -\frac{1}{CR_s} & \frac{1-D}{C} \\ \frac{D-1}{L} & -\frac{R_L}{L} \end{bmatrix} \begin{bmatrix} v_C \\ i_L \end{bmatrix} + \begin{bmatrix} \frac{-I_L}{C} \\ -\frac{V_C}{L} \end{bmatrix} D; \quad (3)$$

$$y = [1 \ 0] \begin{bmatrix} v_C \\ i_L \end{bmatrix} + [0] D.$$

Assim, a partir da análise de anterior as matrizes de estados são identificadas como:

$$A = \begin{bmatrix} -\frac{1}{CR_s} & \frac{1-D}{C} \\ \frac{D-1}{L} & -\frac{R_L}{L} \end{bmatrix}; B = \begin{bmatrix} \frac{-I_L}{C} \\ \frac{V_C}{L} \end{bmatrix}; C_s = [1 \ 0]; D_s = [0]$$

3. PROJETO DE CONTROLE

Primeiramente, um painel FV da marca Komaes de 10 W foi selecionado como referencia, os valores nas condições padrão de teste (STC) são apresentados na Tabela 1.

Já o sinal PWM fixado no projeto foi gerado pelo microcontrolador Arduíno Uno, utilizando $f_c = 62,5$ kHz.

Assim, usando os valores anteriores, os componentes passivos foram encontrados utilizando a metodologia descrita em Hart (2011), estes valores são apresentados na Tabela 2.

3.1 CONTROLE LQI

No controle LQI (Farias et al., 2014), onde é acrescentado um estado adicional, o modelo do sistema aumentado é representado por:

Tabela 1. Parâmetros do painel FV em STC.

Parâmetro	Valor
Máxima potência (P_{mp})	10 W
Tensão na P_{mp} (V_{mp})	17,56 V
Tensão de circuito aberto (V_{oc})	21,52 V
Corrente na P_{mp} (I_{mp})	0,6 A
Corrente de curto circuito (I_{sc})	0,66 A

Tabela 2. Componentes passivos do sistema.

Componente	Valor
Capacitor de entrada (C_{pv})	220 μ F
Indutor (L)	60 μ H
Resistência do indutor (R_L)	0,22 Ω
Capacitor de saída (C)	220 μ F
Resistência de carga (R_s)	66 Ω

$$\begin{bmatrix} \dot{x} \\ \dot{x}_e \end{bmatrix} = \begin{bmatrix} A & 0 \\ -C_s & 0 \end{bmatrix} \begin{bmatrix} x \\ x_e \end{bmatrix} + \begin{bmatrix} B \\ 0 \end{bmatrix} u + \begin{bmatrix} 0 \\ 1 \end{bmatrix} r; \quad (4)$$

Onde além das matrizes de estados, se define um estado adicional x_e , como sendo a integral do erro. Já u é o sinal de controle, que no caso o sistema seja controlável a realimentação de estados pode ser obtida por:

$$u = -K_I x_e - Kx; \quad (5)$$

onde K_I refere-se ao ganho do integrador referente ao estado x_e . A partir desta análise, a Fig. 3 apresenta um diagrama do conversor boost com controle LQI.

Logo, as matrizes do sistema para o controle LQI sofreram ajustes devido a adição de mais um estado para o sistema.

Assim, as novas matrizes de estado A_s e B_s do novo modelo, substituindo com os valores das Tabelas 1 e 2 e escolhendo o $D = 0,5$, são:

$$A_s = \begin{bmatrix} A & 0 \\ -C_s & 0 \end{bmatrix} = 10^4 \begin{bmatrix} -0,0069 & 0,2273 & 0 \\ -1,7241 & -0,3793 & 0 \\ -0,0001 & 0 & 0 \end{bmatrix};$$

$$B_s = \begin{bmatrix} B \\ 0 \end{bmatrix} = 10^5 \begin{bmatrix} -0,0139 \\ 3,4714 \\ 0 \end{bmatrix}.$$

Os valores das matrizes Q e R devem ser escolhidos pela análise dos sinais provenientes do sistema, de modo que a resposta do sistema controlado seja admissível. Esse é um fator preponderante no projeto do controlador LQI, pois tais modificações, em Q e R , pode modificar de maneira significativa a dinâmica do sistema em malha fechada.

Então, seguindo a metodologia desenvolvida por Farias et al. (2014), onde foi utilizado o método de Bryson, as matrizes Q e R , podem ser representadas como:

$$Q = \text{diag} [0,01 \ 0,00390625 \ 6,25];$$

$$R = \text{diag} [0 \ 1].$$

Conhecendo que o sistema é controlável, os valores dos ganhos ótimos, no tempo contínuo, utilizados na realimentação dos estados serão:




Figura 3. Diagrama do conversor boost com controle LQI.

4. RESULTADOS


A fim de validar a proposta vários resultados foram obtidos, mudando condições climáticas e a carga na saída.

Primeiramente, foram realizados alguns testes utilizando um software de simulação e depois foi desenvolvido um protótipo com o objetivo de realizar a validação experimental do trabalho.


4.1 SIMULAÇÃO

Nesta etapa, o conversor boost foi simulado usando o Simulink do Matlab. Um primeiro teste foi comparar o comportamento do controlador LQI proposto com um controlador PI convencional. Com os valores dos ganhos dos controladores (PI e LQI) foi possível organizar a arquitetura dos controladores no sistema computacional (Simscape). Para esta simulação o valor da irradiância foi fixado em 700 W/m^2 e o da temperatura fixado em 25°C .

Entretanto, para encontrar os valores dos ganhos dos controladores, houve-se a necessidade de implementar a linearização das informações do sistema. Através da S-Function os controladores (PI e LQI) foram linearizados no mesmo ponto de operação ($D = 0,5$) e com um valor de entrada, para o sistema em malha aberta, de 5 V , apresentando assim os valores, no estado estacionário, para $V_C = 9,94\text{V}$ e $I_L = 0,3 \text{ A}$. A simulação da Fig. 4 foi realizada com base nas informações presentes da Tabela. 3, Nesta figura é possível observar que as respostas dos controladores lineares (PI e LQI) apresentam trajetórias satisfatórias com o objetivo de seguir uma referência programada. Ainda, observa-se que o tempo de acomodação do controlador LQI é mais satisfatório que o do controlador PI.



(a) Controlador PI



(b) Controlador LQI

Figura 4. Resposta da dinâmica dos controladores PI e LQI no sistema computacional.

Tabela 3. Dados da simulação para comparar os controladores PI e LQI.

Referência	Faixa de tempo (s)
Estacionário	0 - 1,5
12 V	1,5 - 2,5
10 V	2,5 - 3,5
12 V	3,5 - 4,5

Tabela 4. Dados para a simulação do controlador LQI sob variação na irradiação.

Faixa de tempo (s)	Taxa de Irradiância (%)
0 - 5,1	100
5,1 - 13,6	75
13,6 - 23,2	50
13,6 - 23,2	25
t > 32,4	100




Figura 5. Resposta do controlador LQI para mudanças na irradiação e na carga de saída.

Ainda, para testar o controlador LQI sob mudanças na irradiação outro teste foi desenvolvido. Estas mudanças estão representadas na Tabela 4. O sinal de tensão de referência utilizado foi de 10 V. Na Fig. 5, pode se observar que controlador LQI respondeu satisfatoriamente, excepto quando a irradiação ficou abaixo dos 50%, quando não atingiu o sinal desejado. Logo, ao voltar à irradiância máxima, teve um alto sobressinal até o o sistema se acomodar no valor de 10 V.

Finalmente, para testar o controlador LQI sob mudanças na irradiação junto a mudanças na carga CC na saída do conversor, um último teste foi desenvolvido. Estas mudanças estão representadas na Tabela. Na Fig. 6, a




Figura 6. Resposta do controlador LQI para mudanças na irradiação e na carga de saída.

Tabela 5. Dados para a simulação do controlador LQI sob variação na irradiação e na carga de saída.

Faixa de tempo (s)	Irradiância (%)	Carga de saída (Ω)
0 - 3,9	100	66
3,9 - 9,8	100	40
9,8 - 16,6	75	40
16,6 - 25,1	75	66
t > 25,1	100	66

Dinâmica do sistema em malha fechada com o controlador LQI respondeu de maneira satisfatória apresentando nas mudanças do set point um pequeno valor de sobressinal para o referencial de 10 V da tensão de saída selecionado.

4.2 EXPERIMENTAL

A fim de obter resultados experimentais, um protótipo do conversor boost foi desenvolvido e controlado pelo microcontrolador (Arduíno Uno – Atmega238P) e foi colocado em uma plataforma de testes junto com o painel FV, um refletor e um osciloscópio digital, da marca Tektronix, modelo TDS2014C, como mostrado na Fig. 7 Vale destacar que o indutor presente neste trabalho teve suas medições (indutância e resistência interna) realizadas através do indutômetro da Global Specialties modelo LCR-58 Tweezer LCR Meter. Os elementos semicondutores selecionados foram o diodo ETH06 e o interruptor MOSFET IRF540N canal tipo N. As medições foram realizadas por um sensor de temperatura DS18B20 e um sensor de irradiação K6450.

Ainda, pelo fato dos sinais advindos do microcontrolador terem valores próximos a 5V, faz-se necessária a utilização de um driver (IR2104) para que o MOSFET responsável pelo chaveamento no conversor boost seja corretamente acionado, evitando assim danos por superaquecimento gerado pelas perdas do chaveamento. O driver deverá ser capaz de fornecer ao gate do MOSFET uma tensão mínima de 10 V e máxima de 15 V. Sendo assim, um sinal de 12 V advindo do driver foi enviado ao gate do MOSFET para realizar o chaveamento. A variação da intensidade luminosa do refletor para o painel FV foi realizada por um controle de potência por ângulo de fase, projetado inicialmente para um caracterizador de curvas para painéis fotovoltaicos, desenvolvido por Nazaré et al. (2019).

Logo, alguns testes foram desenvolvidos a fim de corroborar a eficácia do controlador LQI proposto. Em um





Figura 7. Plataforma experimental desenvolvida.


Primeiro teste a tensão de referência de saída começa fixada em 10 V, logo é mudada para 12 V e finalmente, abaixada para 8 V. Na Fig. 8 é apresentada a dinâmica do sistema em malha fechada com o controlador LQI para estas mudanças no set point.



(a) Estacionário para 10 V




(b) 10 V para 12 V




(c) 12 V para 8 V

Figura 8. Resposta do sistema com o controlador LQI, mudando a tensão de referência.



(a) 66 Ω para 40 Ω




(b) 40 Ω para 66 Ω

Figura 9. Resposta do sistema com o controlador LQI, mudando a carga de saída.


O seguinte teste foi realizado mudando a carga de saída mantendo como referência 8 V na tensão de saída. Neste caso, a carga de saída começa em 66 Ω e é mudada para 40 Ω e logo volta novamente para o valor inicial de 66 Ω . O comportamento do sistema sob estas mudanças está ilustrado na Fig. 9, onde pode se observar a ação do controlador LQI proposto a fim de manter a tensão fixa na saída do conversor independente das mudanças que possam acontecer.

Um último teste foi realizado a fim de avaliar o comportamento do sistema quando submetido ao sombreamento.

Em muitos casos, os grandes períodos de sombreamento que porventura venham a ocorrer podem acarretar valores de tensão e de corrente, que saem dos terminais do painel fotovoltaico, relativamente baixos para favorecer ao conversor um ganho significativo para manter o sistema no valor da referência. Isso garantirá que a porção integral presente no controlador continue a aumentar a integral do erro de forma demasiada, sendo conhecido como termo windup. Quando o período de sombreamento cessar, o erro irá diminuir, porém o controle demandará um determinado tempo extra para reduzir a variável manipulada, devido a ação integral. Com o propósito de evitar tal acontecimento, o controlador LQI é configurado de modo



(a) Sem anti-windup



(b) Com anti-windup

Figura 10. Resposta do sistema com o controlador LQI, submetido ao sombreamento.

a parar de integrar quando a variável satura, o que é conhecido como controle com ação anti-windup. A Fig. 10 apresenta o sistema em malha fechada, com o controlador LQI, sem a ação anti-windup e com a ação anti-windup, respectivamente, quando um sombreamento na ordem de 20% da potência da luminária é incidido sobre o painel fotovoltaico por um determinado tempo. Para este teste, o sinal de referência adotado foi de 10 V. Pode-se observar que o controlador LQI com anti-windup retorna o valor de referência de saída com maior rapidez e não fica perdido por algum tempo, como acontece com o controlador LQI sem esta ação. Para a composição da ação anti-windup no controlador LQI, foi utilizado o método de integração condicional, limitando o termo integral do controlador quando o erro da integral atingisse um determinado valor, tornando-o atuante apenas nas faixas de operacionalidade do sistema.

Os resultados obtidos avaliaram o desempenho do controlador proposto e da forma como os parâmetros de sintonia contribuíram para uma resposta satisfatória do sistema.

Ainda, percebe-se que as informações de pico foram suprimidas.

Esse fato se deve ao cálculo da média que o equipamento faz como forma de reduzir o ruído aleatório, facilitando assim a visualização da resposta do sistema em malha fechada.

5. CONCLUSÕES

Este artigo apresentou o projeto e desenvolvimento de um controlador LQI aplicado a um conversor CC-CC boost em um sistema FV autônomo sem armazenamento de energia.

Foi realizada a modelagem matemática do conversor boost a fim de obter as matrizes de estado deste. A partir destas últimas e dos valores do sistema, foi projetado o controlador LQI utilizado neste trabalho. As simulações corroboraram o projeto de controle, onde foi comparado o controlador proposto com um controlador PI. Ainda, foram realizados dois testes onde foram variadas a irradiação e a carga na saída do conversor, mostrando resultados satisfatórios. Por fim, foi apresentado o protótipo implementado onde vários testes foram realizados como na simulação e introduzindo um último teste para verificar o comportamento do controlador LQI ante o sombreamento.

Neste caso, precisou se agregar uma ação anti-windup a fim de melhorar a resposta do sistema. Estes resultados demonstram a viabilidade e eficácia do controlador proposto a fim de regular a tensão de saída no conversor boost.

AGRADECIMENTOS

Os autores agradecem á CAPES pelo apoio financeiro e aos colegas do Laboratório de Eficiência Energética (LABEFEA) pela ajuda prestada ao longo da pesquisa.

REFERÊNCIAS

- Asadi, F., Eguchi, K., and Hudgins, J. (2018). Dynamics and Control of DC-DC Converters. Morgan & Claypool. doi:10.2200/S00828ED1V01Y201802PEL010.
- Barbi, I. (2015). Modelagem de Conversores CC-CC empregando Modelo médio em Espaços de Estados. Edição do autor, Florianópolis-SC.
- Blaabjerg, F., Abdelhakim, A., Dragi'cevi'c, T., Lucia, O., and Zhang, D. (2018). Control of Power Electronic Converters and Systems. Academic Press. doi:https://doi.org/10.1016/B978-0-12-816136-4.09989-9.
- Erickson, R.W. and Maksimovic, D. (2020). Fundamentals of Power Electronics. Springer International Publishing, 3rd edition.
- Farias, E., Pinto, V., Lima, A., and Siqueira, W. (2014). Regulador linear quadrático (lqr) com ação integral aplicado ao conversor boost com carga não linear. In XX Congresso Brasileiro de Automática.
- Hart, D.W. (2011). Eletrônica De Potência: Análise e Projetos de Circuitos. McGraw Hill - ARTMED.
- Malkapure, H.G. and Chidambaram, M. (2014). Comparison of two methods of incorporating an integral action in linear quadratic regulator. IFAC Proceedings Volumes, 47(1), 55–61. doi:https://doi.org/10.3182/20140313-3-IN-3024.00105.
- Nazaré, R., Carralero, L., Costa, F., and Tahim, A. (2019). Design and implementation of a curve characterizer for pv panels using a cuk converter. In 12th Seminar on Power Electronics and Control.
- Ogata, K. (2010). Modern Control Engineering. Prentice Hall, 5th Ed.
- Raghavendra, K.V.G., Zeb, K., Muthusamy, A., Krishna, T.N.V., Kumar, S.V.S.V.P., Kim, D.H., Kim, M.S., Cho, H.G., and Kim, H.J. (2020). A comprehensive review of dc–dc converter topologies and modulation strategies with recent advances in solar photovoltaic systems. Electronics, 9(1). doi:10.3390/electronics9010031.
- Salas, V. (2017). Stand-alone photovoltaic systems. In The Performance of Photovoltaic (PV) Systems, 251–296. Woodhead Publishing. doi:https://doi.org/10.1016/B978-1-78242-336-2.00009-4.
- Villalva, M. and Gazoli, J. (2012). Energia Solar Fotovoltaica: Conceitos e Aplicações. Editora Erica, 2da Ed.
- Zhang, H., Li, L., Xu, J., and Fu, M. (2015). Linear quadratic regulation and stabilization of discrete-time systems with delay and multiplicative noise. IEEE Transactions on Automatic Control, 60(10), 2599–2613. doi:10.1109/TAC.2015.2411911

Capítulo 2




10.37423/230107067

PREDITOR DE MERCADO ACIONÁRIO BRASILEIRO UTILIZANDO MINERAÇÃO DE DADOS POR MEIO DO ALGORITMO RANDOM FOREST

Victor Carvalho Vieira

Universidade Federal do ABC



Resumo: O mercado financeiro tem um papel de suma importância na economia do país e na sociedade. No Brasil, a busca por investimentos e novas formas de fazer o dinheiro render, está crescendo consideravelmente nos últimos anos, porém a falta de conhecimento atrelado ao medo do risco de perda, fazem com que muitas pessoas se afastem do mercado de ações. Em paralelo a isso, a tecnologia da informação e o volume de dados estão crescendo a tal ponto desses mundos se unirem na busca de modelos sofisticados de tratamento e mineração de dados. O trabalho em questão tem como objetivo fazer a construção de um modelo preditivo fazendo uso do algoritmo *Random Forest*, a partir de uma base construída com diferentes indicadores técnicos de dados do presente ou do passado, para tentar prever o comportamento da ação no fim do dia. Ela tem como resultado três classes diferentes, que fornecem orientação, de maneira automática, ao usuário que deseja investir. Ao longo do projeto, vários comportamentos dos dados foram identificados e ajustes na base de treino e nos dados foram realizados para aumentar a assertividade do modelo. Os resultados fornecem assertividade de até 65% dos dados testados e traz a relação dos indicadores mais relevantes para a tomada de decisão de cada classe, que evidencia a complexidade que consiste em realizar a predição do comportamento das ações. O projeto ilustra interessantes possibilidades de uso que a mineração de dados possui e a sua capacidade de ser aplicada em diferentes áreas do conhecimento.

Palavras-chave: Mineração de dados, Aprendizagem de máquinas, Random Forest, Mercado acionário

1. INTRODUÇÃO

O Brasil possui hoje uma das maiores bolsas de valores do mundo e seu mercado de ações tem recebido muita atenção de investidores e empresas. Após a implementação do Plano real e o controle da inflação do país, a economia se tornou mais estável e o país começou a figurar como uma das nações com maiores potenciais econômicos do mundo, chamando atenção desde pequenos investidores até investidores estrangeiros que veem no Brasil a oportunidade de ter maior diversidade em seus portfólios de investimentos (NUNES, DA COSTA JR., MEURER, 2005).

Até 1999, pessoas físicas eram inviabilizadas de participar desse mercado devido as altas taxas de corretagem necessárias para fazer as negociações. Após as operações começarem a serem realizadas eletronicamente, essas taxas diminuíram e assim permitiram a participação desse público. Passado esse fato, a própria bolsa do país criou uma série de programas para incentivar esse público a aplicar seus recursos nesse tipo de investimento.

É esperado um crescimento e popularização cada vez maior no mercado acionário brasileiro. Isso devido ao crescimento econômico e poder de compra das classes mais baixas, como a chamada classe C, que levou a sofisticação de produtos e serviços (DOS SANTOS, 2012). Pesquisas mostram (FOGAÇA, 2010) que 73% desse grupo poupam sempre ou quando podem. Essa mesma pesquisa cita que metade da população brasileira consegue poupar mesmo que de forma irregular. Tendo em vista o tamanho da população do país e as melhores rentabilidades provenientes de investimentos acionários que podem ser obtidos, é esperado que nos próximos anos essa popularização cresça significativamente.

2. REFERENCIAL TEÓRICO

Para a construção do desenvolvimento de pesquisa é importante ao leitor entender um pouco da teoria que está por traz do algoritmo preditivo aqui apresentado, esses conceitos estão aqui apresentados.

2.1 AUTOMAÇÃO DE INVESTIMENTOS

Com a popularização cada vez maior de pessoas (físicas e jurídicas) investindo na bolsa de valores, a busca pela obtenção de maiores ganhos nesse mercado vem se tornando muito intensa. Devido à enorme variedade de possibilidades disponíveis e a constante volatilidade desse mercado, questionamentos com relação a melhor opção de investimento, o valor que deve ser aplicado, o prazo que deve ser mantido e principalmente o risco que está envolvido nessa operação, são constantes pela

grande parte dos investidores. O assunto “risco”, é ainda um tema que assusta as pessoas e faz com que muitas ainda abram mão de investir seus recursos por não saber ou conseguir quantificar o quão arriscado é cada uma das possibilidades que hoje existem no mercado.

Diante dessas questões e o avanço tecnológico de desenvolvimento computacional, especialistas do mercado financeiro começaram a enxergar a possibilidade de realizar as negociações financeiras a partir de algoritmos, em outras palavras, automatizando o processo de negociação sem a necessidade de intervenção humana. Em definição de Medina e Fertig (2005) algoritmo é “um procedimento passo a passo para a solução de um problema. Uma sequência detalhada de ações a serem executadas para realizar alguma tarefa”. Olhando da perspectiva do mercado financeiro, isso consiste em repassar ao algoritmo os parâmetros e variáveis que ele deve analisar, os critérios relacionados as decisões que devem ser tomadas a partir dos dados analisados e que devem estar de acordo com a estratégia de investimento do usuário.

As vantagens de fazer uso desses “robôs” são vastas, ela permite que um usuário que não tenha conhecimentos profundos sobre mercado financeiro e investimentos, seja capaz de montar uma carteira de investimentos diversificada e que esteja de acordo com o perfil do usuário, de maneira que seu objetivo seja alcançado, seja ele em curto, médio ou longo prazo e sempre respeitando os riscos que seu utilizador está disposto a passar. Além disso, esse tipo de automação dispensa, até certo ponto, a necessidade das pessoas terem que acompanhar constantemente os rumores e flutuações do mercado, pois a aplicação estará fazendo esse acompanhamento de forma automática e tomando as decisões, sem influência de emoções, seguindo as regras e critérios já definidos.

Um dos mais conhecidos algoritmos que atuam no mercado, são os de operações em alta frequência, os *high-frequency trading (HFT)*, eles consistem em algoritmos complexos que operam de maneira mais rápida e ininterrupta que os tradicionais do mercado, pois eles operam ordens de compra e venda de grandes volumes financeiros no mercado financeiro em frações de segundo, obtendo lucros para seus usuários a partir da mínima oscilação dos preços das ações e outros ativos do mercado (MARTINI, 2015). Esse tipo de robô já é largamente utilizado no mercado mundial. Em 2007, aproximadamente 40% do mercado financeiro americano já fazia uso desse tipo de automação, dois anos depois, esse número já estava em aproximadamente 70% (SMITH, 2010). O percentual de uso desses robôs no mercado brasileiro vem aumentando, com algumas oscilações, desde 2009, atingindo pico de aproximadamente 27,5% no final do primeiro semestre de 2016 e chegando ao fim do respectivo ano com o número de 22,5% (PARANÁ, 2017).

Outro tipo de aplicação voltada ao mercado financeiro muito utilizada são os chamados robôs consultores, em inglês, *robo-advisor*, eles fornecem um serviço de consultoria financeira por um preço muito menor que a de um consultor real, traçam o perfil do usuário de acordo com sua renda e objetivos e fornecem a ele através de algoritmos inteligentes, o acesso aos melhores tipos de investimento globais de acordo com o perfil identificado a baixo custo (ARAUJO, 2018). Esse tipo de robô monitora os valores dos ativos da sua carteira e realiza as operações de compra e venda automaticamente de acordo com o seu objetivo estabelecido. Em 2014 o mercado dos consultores robôs movimentou 16 bilhões de dólares em ações nos Estados Unidos, ao final de 2015 este número pulou para 50 bilhões (Collins, 2016).

Segundo pesquisa da gestora Legg Mason (2018), 52% dos investidores brasileiros pretendem aplicar via robôs nos próximos quatro anos, ficando acima da média mundial de interesse nessa forma de aplicação de investimento (37%). Ela também evidencia que o principal utilizador desse serviço são investidores de menor porte. Fatores como novidade e falta de conhecimento ainda são barreiras que devem ser superadas pela população, motivo do qual a poupança ainda ser o principal investimento feito pelos brasileiros e que apresenta a menor rentabilidade dentre os ativos do mercado financeiro, porém o caminho já está aberto e democratizado e em questão de tempo, essas barreiras serão cada vez menores até sua completa eliminação.

2.2 MINERAÇÃO DE DADOS

Nos últimos anos, com o avanço das tecnologias e a troca constante de informações entre as pessoas, o volume de dados gerados cresceu de forma muito acelerada em diversas áreas de conhecimento, tornando cada vez mais difícil a análise e interpretação desses dados pelos seres humanos. Devido a isso, começaram a surgir técnicas que analisam, classificam e interpretam esses dados de maneira automática e transformam megabytes de linhas e linhas de dados em informações valiosas e conhecimento. (HAN, 2011). A obtenção dessas informações, foi chamada de KDD, *Knowledge Discovery in Database*, isto é, Descoberta de Conhecimento em Banco de Dados. Esse processo envolve uma série de fases que inicia com a identificação de padrões e tem como principal etapa a mineração de dados (Fayyad,1996).

Devido a sua enorme gama de aplicações, a mineração de dados tem sua definição variada de acordo com o campo de atuação dos autores. Focaremos na área de atuação voltada ao aprendizado de máquinas, que é o assunto principal deste trabalho. Fayyad (1996) define: "Mineração de Dados é um

passo no processo de Descoberta de Conhecimento que consiste na realização da análise dos dados e na aplicação de algoritmos de descoberta que, sob certas limitações computacionais, produzem um conjunto de padrões de certos dados."

A primeira etapa do processo de KDD consiste na seleção da massa de dados a ser minerada dentro da base total de dados, em seguida a etapa chamada *Data Cleaning* (ou Pré-Processamento) é realizada, onde é feita a eliminação de ruídos e inconsistências nos dados, garantindo assim a sua qualidade. A terceira etapa consiste na transformação da massa selecionada com o objetivo de mantê-la no padrão ideal do algoritmo minerador desejado. A fase seguinte consiste na mineração dos dados a partir do método escolhido. A escolha do algoritmo é de suma importância para a obtenção das informações desejadas e sua escolha deve ser feita de maneira criteriosa. Ao final dessa etapa será obtido padrões nos dados que carregam conhecimento ocultos. A última etapa consiste na identificação, dentre os padrões encontrados, aquele que são de interesse do usuário, seguindo os seus critérios. Em caso de fracasso, o processo deve começar da etapa inicial, revendo cada uma das premissas e decisões tomadas. No caso de resultado favorável, o conhecimento deve ser implantado e publicado ao usuário. A figura 4 ilustra todo o processo de KDD descrito:




Figura 1: Fases do processo de KDD (Andrade, 2007, baseado em Fayyad,1996)

O tipo de uso da mineração de dados costuma ser classificada de acordo com a tarefa a ser utilizada. Sendo seus algoritmos agrupados em dois principais grupos: de tarefas preditivas e descritivas. As tarefas preditivas têm como principal objetivo o desenvolvimento de modelos que possam prever a classe de um novo evento a partir de dados do passado com respostas já conhecidas. As tarefas

descritivas procuram identificar padrões intrínsecos em conjuntos e subconjuntos de dados (VIEIRA, 2014) Cada um desses grupos é dividido em outros dois, conforme figura 5:



Figura 2: Tarefas da Mineração de dados (Fonte: Vieira, Oliveira, 2014)

Tarefas de classificação: Consistem na predição da classe de um determinado atributo por meio de um modelo construído a partir de um conjunto de dados classificados corretamente com sua classe correspondente (HAN, 2011).

Tarefas de regressão: São similares as de classificação, porém a predição realizada é numérica e não categórica. Estimando o valor de certa variável a partir da análise dos valores das demais. (CAMILO, SILVA, 2009).

Tarefas de associação: Consistem em identificar quais atributos estão relacionados com base em certo conjunto de dados. Tem a estrutura “se X, então Y”. (CAMILO, SILVA, 2009).

Tarefas de clusterização: Consistem em aproximar os grupos de dados similares, elas não têm como objetivo classificar, estimar ou prever algum atributo. (CAMILO, SILVA, 2009).

Cada tarefa de mineração de dados possui diferentes técnicas associadas. Dentre as mais populares estão (HAN, 2011): árvores de decisão, redes neurais, regressão linear ou não linear, entre outras. Essas técnicas tem em comum três componentes principais (Fayyad,1996):

- Modelo de Representação: Descreve os padrões detectáveis do algoritmo, se for muito limitado compromete o alcance das informações obtidas, porém se for muito livre, aumenta o risco de sobreposição das informações e em resultados inconclusivos.

- **Modelo de Avaliação:** Descreve, quantitativamente, a aderência do algoritmo e seus parâmetros com as etapas e objetivos do processo de KDD.
- **Método de Busca:** Composto pelo parâmetro e modelo de busca. O parâmetro escolhido deve otimizar os critérios do modelo de avaliação observado para um modelo de representação fixado. O modelo de busca sofre o processo inverso: o modelo de representação é variado, portanto o parâmetro de busca também sofre variação gerando uma avaliação qualitativa do modelo.

A mineração de dados é um campo multidisciplinar, que exige a integração de conhecimentos em diversas áreas como tecnologia de base de dados, inteligência artificial, redes neurais, aprendizagem de máquinas e estatística, todas elas devem trabalhar em perfeita sinergia, para que a mineração consiga convergir para um ponto de interesse, transformando dados de baixo nível em conhecimento de alto nível (ANDRADE, 2007).

O processo de descoberta de informações a partir da análise dos próprios dados presentes nas organizações se tornou uma área de interesse científico e comercial, podendo ser crucial para levar vantagem competitiva no mercado. A astronomia foi uma das primeiras áreas científicas a utilizar esses conceitos para análise de imagens oriundas de observações espaciais com o objetivo de fazer a classificação e reconhecimento de objetos. No mundo de *business* esse conceito é largamente utilizado em áreas como Marketing: que visa conhecer o interesse do cliente a partir de seus dados comportamentais, Manufatura: na construção de modelos preventivos contra falhas e problemas industriais, Telecomunicações: para realizar a localização de alarmes emitidos e suas regras, Mercado financeiro: na detecção de fraudes em cartões de crédito a partir da identificação de comportamentos irregulares e fora do padrão do cliente (Fayyad,1996).

Uma das mais antigas e importantes é no mercado de ações. Esse mercado é complexo, movimenta valores absurdamente altos e sua movimentação é totalmente não trivial, onde uma série de variáveis influenciam nos valores dos produtos, isso faz com que instituições financeiras produzam grandes conjuntos de dados que constroem bases extensas com grande potencial de gerar informações úteis. A aplicação dessa tecnologia nesse mercado iniciou nos anos 80, e abrange tarefas como predição dos índices e preços das ações, gestão de riscos e sistemas de recomendação de investimento (Kaur, Mangat, 2012).

2.3 RANDOM FOREST

Métodos de aprendizagem de máquinas estão continuamente em busca de conseguir tomar decisões mais assertivas e reduzir o percentual de erros. O critério de classificação é fator decisivo para obtenção de bons desempenhos, de modo que critérios mal estabelecidos sobre determinada situação geram resultados errôneos crescentes de maneira exponencial. A partir disso é de se esperar que decisões tomadas a partir da combinação de mais de um classificador, gerem melhores resultados do que aqueles que fazem uso de apenas um. Segundo Sirikulviriya e Sinthupinyo (2011), dada uma mesma quantidade de informação que deve ser treinada, é amplamente aceito pela comunidade científica que o desempenho e a confiabilidade de muitos classificadores é geralmente melhor do que um único classificador. Esses métodos são denominados métodos *ensemble* (Dietterich, 2000).

O algoritmo de *Random Forest* (Floresta Aleatória, em português) foi introduzido por Breiman (2001) e é um termo utilizado para métodos *ensemble* que fazem uso de classificadores do tipo árvore. Esse método que é considerado um minerador de dados preditor, do tipo classificação e regressão (VIEIRA, OLIVEIRA, 2014), consiste na construção de uma grande quantidade de árvores de decisão, cada uma delas possuindo diferentes instâncias e critérios para tomada de decisões baseadas em vetores de variáveis distribuídos de maneira randômica, construídos a partir do conjunto geral de dados de interesse para realizar o treinamento do algoritmo. Cada uma das árvores irá resultar em uma classe (classificação) distinta e representa um componente preditor. Por fim, é realizada a contagem das classes vencedoras de cada uma das árvores e a classe que representa a decisão final do algoritmo é aquela com maior número de votos acumulados (LOPES, GOEDEL, PALÁCIOS, GODOY, 2017). A figura 6 apresenta o esquema de funcionamento do algoritmo:




Figura 3: Estrutura do Random Forest (Fonte: GÓMEZ, 2012)

Ao realizar a divisão dos dados em subconjuntos e utilizar cada um deles na construção e treinamento da árvore, é obtida a melhor característica de cada um desses subconjuntos aleatórios. Breiman (2001) demonstra que a taxa de erro de classificação do método aumenta com a correlação entre as árvores e diminui com a força independente de cada árvore da floresta. A escolha pela seleção aleatória dos atributos tem como objetivo diminuir a correlação entre as árvores.

Esse método apresentará maior acurácia se tiver o maior número possível de árvores, isto é, se diferentes critérios forem estabelecidos sobre cada um dos subconjuntos de dados e apresenta a significativa vantagem de que critérios errôneos aleatoriamente estabelecidos, serão diluídos pelas assertividades das outras árvores.

Um dos grandes problemas em aprendizagem de máquinas é o chamado *overfitting*, que é o termo utilizado para descrever quando um modelo estatístico se ajusta muito bem ao conjunto de dados do qual ele foi treinado, mas se mostra ineficaz para prever novos resultados (CÁRDENAS-MONTES, 2006). Esse problema dificilmente atingirá o método *Random Forest*, uma vez que cada uma das árvores foi construída a partir de subconjuntos aleatórios de características distintas e as árvores são de tamanhos menores.

Outra característica interessante desse método é que ele possibilita a mensuração da importância de cada uma das variáveis da base de dados na tomada de decisões, podendo deixar de fora do modelo determinada característica por estar levando o modelo a decisões erradas ou por não estarem contribuindo o suficiente para a predição.

3. METODOLOGIA

3.1 *RANDOM FOREST* APLICADO AO MERCADO FINANCEIRO

A implementação do algoritmo *Random Forest* tem como objetivo a classificação das instâncias com base em um sistema de votação, onde N árvores de decisões classificam cada instância de forma independente e o voto de cada uma das classes é contabilizado (Breiman, 2001). Para a aplicação desse algoritmo no Mercado financeiro foi construída uma base composta de importantes indicadores técnicos da área de economia e estatística de quatro das principais empresas listadas em bolsa (foram consideradas dados entre 2014 e 2019), sendo elas:

- Petrobrás (Empresa estatal – ramo energia);
- Itaú (Empresa privada – ramo bancário);
- Ambev (Empresa privada – ramo industrial);
- Vale (Empresa estatal – ramo mineração).

A escolha das empresas foi tomada devido a relevância na bolsa brasileira (e consequentemente na economia brasileira) das ações das mesmas, onde juntas correspondem a cerca de 35% do índice Bovespa e as características distintas dos segmentos de atuação.

A partir dessa base, é obtido um vetor de atributos por cada dia e ação de operação em bolsa, esse vetor é composto por dados e indicadores anteriores ao fechamento da ação no respectivo dia, permitindo assim a possibilidade de ocorrer a predição. Cada vetor é caracterizado com uma classe final que remete a decisão que deveria ser tomada para aquele dia e ação de operação, permitindo a tarefa de predição ser realizada como classificação.

A base é dividida aleatoriamente em treino e teste. A primeira é utilizada para o algoritmo fazer a construção das árvores e instâncias de tomada de decisão das classes e sair com um modelo de predição. A segunda, testa o modelo de predição construído pela base de treino, validando o mesmo.

A construção do algoritmo envolve etapas de definição e refinamento de parâmetros muito importantes para a mineração dos dados, sendo eles:

- Número de árvores envolvidas;
- Tamanho mínimo e máximo dos nós das árvores;
- Número de subdivisões das bases para a construção das árvores;
- Número de variáveis utilizadas para quebrar os nós das árvores.

Todos esses parâmetros são essenciais para a definição da estrutura da floresta de decisões.

3.2 INDICADORES TÉCNICOS

Para a construção do vetor de atributos, foram adotados indicadores técnicos dos mais utilizados (SILVA, et al, 2013) na área com diferentes complexidades de construção e popularidade. Como o objetivo é fazer a predição do preço de fechamento da ação em D, os dados que fazem sentido serem utilizados são de fechamentos de D-1 e abertura em D, sendo assim os indicadores foram adaptados. São eles:

- **Saldo (D-1):** Percentual de variação entre a abertura e fechamento do dia anterior;
- **Variação entre a abertura (D) e fechamento (D-1):** Variação que existe no valor da ação da empresa enquanto o mercado está fechado, que faz com que ele seja refletido apenas no preço de abertura;
- **Variação entre preço de fechamento e fechamento ajustado (D-1):** O preço de fechamento ajustado ocorre quando uma ação, dentro de qualquer dia de negociação, tem o seu preço alterado para incluir quaisquer distribuições de proventos e ações corporativas que ocorreram em qualquer momento antes da abertura do dia seguinte. Os ajustes mais comuns ocorrem por desdobramentos de ações, distribuição de dividendos e oferta de direitos (REIS, 2018)
- **Variação do dólar (D-1):** Indicador que reflete fortemente a situação econômica e política do país;
- **Variação entre abertura (D) e fechamento (D-1) do dólar:** Variação que existe no valor dólar enquanto o mercado está fechado, que faz com que ele seja refletido apenas no preço de abertura;
- **Pesquisas da empresa – Google:** A partir do Google Trends, é possível saber o quanto aquela empresa está sendo pesquisada no Google em determinado período de tempo;

- **Média Móvel Simples (MMS):** É média aritmética simples dos preços de fechamento da ação nos últimos N dias (anteriores a D). Para esse estudo, o indicador foi calculado para N igual a 3, 7 e 15 dias);
- **Média Móvel Exponencial (MME):** Esse indicador dá maior importância aos preços mais recentes, mas leva em consideração todos os preços do intervalo escolhido. Fórmula utilizada: $MME(D) = [Fechamento(D-1) - MME(D-1)] * K + MME(D-1)$
- Onde $K = 2/(1+N)$, sendo N o número de períodos
- Nesse trabalho, esse indicador foi construído para N igual a 5, 12 e 26 dias.
- **Rate of change (ROC):** Indicador que mede a taxa de variação percentual entre o D-1 e o dia D-N-1. Nesse trabalho, N foi adotado como 5;
- **Osciladores Estocásticos:** É composto por três elementos: o **%K**: Tenta medir a tendência do valor atual, considerando os valores máximos e mínimos dentro do intervalo N: $\%K = 100 * [Fechamento(D-1) - Fechamento\ Mínimo[D-1:D-N-1] / Fechamento\ Máximo[D-1:D-N-1] - Fechamento\ Mínimo[D-1:D-N-1]]$

Valores próximos a 100% indicam tendências de alta e próximos a 0% indicam tendências de baixa. Nesse trabalho, o indicador foi construído para N igual a 7, 14 e 21 dias.

- o **%D**: Média móvel simples de 3 dias de %K.
- Quando %K cruza %D para cima, indica início de tendência de crescimento, o oposto indica início de tendência de queda.
- o **Slow %D**: Média móvel simples de 3 dias de %D.
- Quando %D cruza Slow %D para cima, indica início de tendência de crescimento, o oposto indica início de tendência de queda.
- **Índices de Força Relativa (IFR):** Indicador que faz a comparação entre a média dos valores de alta (variação entre os encerramentos de D-N-1 e D-N-2 positivos) com a média dos valores de queda (variação entre os encerramentos de D-N-1 e D-N-2 negativos) de N dias. A Força Relativa é definida como:

$FR = Média\ dos\ crescimentos / Média\ das\ perdas$

O Índice de Força Relativa é uma bijeção de FR: $IFR = 100 - [100 / (1 + FR)]$

Para esse estudo, foi considerado o intervalo N igual a 9, 14 e 21 dias. Valores próximos de 100 indicam tendências de alta e próximos de 0 tendências de queda.

- **Convergência/Divergência de Médias Móveis (MACD):** Vem do nome *Moving average convergence/divergence*. É composto por três elementos: o MACD: Diferença entre uma Média Móvel Exponencial (MME) de 12 dias com uma de 26 dias. Valores positivos indicam expectativas de alta e valores negativos tendências de queda.

O Linha de sinal (S): É calculada a partir da Média Móvel Exponencial (MME) de 9 dias do MACD. Valores positivos indicam tendências de alta e negativos de baixa.

O Histograma de MACD (HMACD): Diferença entre o valor de MACD e de S no mesmo intervalo de tempo. O decrescimento de valores positivos indica que a tendência de alta está perdendo força. O crescimento de valores negativos, indicam que a tendência de queda está perdendo força.

3.3 ESTRUTURAÇÃO DAS DECISÕES

- A partir do saldo real obtido (relação entre a abertura e o encerramento) por cada ação no dia D, é necessário definir a correta decisão a ser tomada. Uma importante consideração atribuída foi a o de custo por operação (seja venda ou compra). Esse valor varia de corretora para corretora e de acordo com o tipo de conta que o cliente possui. Para esse trabalho foi considerado esse valor em 1% do valor da ação. Feito essa consideração, as possíveis decisões com relação a ação que deve ser feita são:
- Manter/Comprar: Essa decisão significa que se o investidor já possui a ação ele deve mantê-la em sua carteira de investimentos e caso ele não a possua, ele deve comprá-la, uma vez que o saldo obtido foi maior que 1%, o que cobre os custos da operação de compra e gera rentabilidade;
- Vender/Não adquirir: Essa decisão significa que se o investidor já possui a ação ele deve vendê-la e caso ele não a possua, ele não deve adquiri-la, uma vez que a perda foi maior que 1%, o que cobre os custos da operação de venda e impede que o prejuízo seja maior;
- Manter/Não adquirir: Essa decisão significa que se o investidor já possui a ação ele deve mantê-la em sua carteira de investimentos e caso ele não a possua, ele não deve adquiri-la, isso acontece quando o saldo do dia estará entre -1% e 1%, o que significa que não será

rentável para ele fazer qualquer operação de compra ou venda e a forma de se minimizar as perdas ou obter lucro é não realizando qualquer operação.

Como pode ser verificado, a estratégia de operação é definida de modo a se potencializar os lucros e minimizar as perdas. Essas três decisões foram definidas após vários testes que viabilizaram a predição e ao mesmo tempo tornaram a mesma sensível o suficiente para orientar o investidor.

Ao final da aplicação dessa regra a base possui para cada ação e para cada dia um vetor de características com os indicadores técnicos que se baseiam em dados anteriores ao fechamento da ação e uma decisão a ser tomada que foi definida a partir do saldo real obtido. Esses dados serão utilizados para predizer, a partir da técnica de mineração *Random Forest*, a decisão a ser tomada com base no vetor de características, encontrando correlações entre as variáveis, medindo a importância de cada uma delas e calculando a precisão que essas correlações entre esses dados conseguem ter na tomada de decisão que se baseia em um valor futuro.

3.4 IMPLANTAÇÃO DO ALGORITMO DE MINERAÇÃO

O Algoritmo de mineração foi implementando na plataforma RStudio, fazendo uso da linguagem de programação, de alto nível, R. É um ambiente/linguagem que vem crescendo nos últimos anos e vem se especializando em manipulação e análise de dados, além de ser gratuito e possuir bibliotecas com algoritmos de mineração de dados, incluindo o *Random Forest* (Liaw & Wiener, 2002).

Inicialmente deve ser feita a importação das bases de treino e teste, que estavam em Excel (formato .xlsx) e a ativação das bibliotecas de Machine Learning:

- Randomforest;
- Caret;
- E1079.

Primeiramente, o processo de treinamento e definição do modelo de predição será realizado com os valores padrões dos métodos, em seguida é feita a análise da precisão obtida e a troca de variáveis importantes com o objetivo de maximizar a precisão.

Para definir os parâmetros da a realização do treino da base, usa-se o comando *trControl()* e seus argumentos:

```
trControl <- trainControl(method = "cv",
number = 10,
search = "grid")
```

O método “cv” é um dos padrões para operações de reamostragem. O argumento “number” define o número de subdivisões randômicas da base em pastas de tamanho aproximadamente iguais, a chamada k-fold cross validation.. Já o “search” definido como “grid” implica na definição do modelo como avaliador de todas as possibilidades de combinação. Para executar o treinamento usa-se o comando *train()* com os parâmetros de *trControl()*:

```
set.seed(1234)
rf_default <- train(acao~,
data = Base_TG_treino,
method = "rf",
metric = "Accuracy",
trControl = trControl)
print(rf_default)
```

Esse comando irá realizar a predição de um modelo inicial fazendo uso da base “Base_TG_treino” para o campo “acao” que define a decisão estratégica que deve ser tomada para aquela ação no dia correspondente. O comando irá listar a precisão obtida para diferentes valores de mtry, que representam o número de variáveis disponíveis para dividir cada nó das árvores de decisões. Para analisar a precisão obtida em um intervalo de valores de mtry (De 1 à 30), usa-se o comando:

```
set.seed(1234)
tuneGrid <- expand.grid(.mtry = c(1: 30))
rf_mtry <- train(acao~,
data = Base_TG_treino,
method = "rf",
metric = "Accuracy",
tuneGrid = tuneGrid,
trControl = trControl,
importance = TRUE,
nodesize = 14, 17
ntree = 300)
print(rf_mtry)
```

Uma lista com a precisão obtida para cada mtry será gerada e o valor que será utilizado para o modelo final de predição será aquele que apresentar maior precisão. Os valores de “ntree” – números de árvores e “nodesize” – tamanho mínimo dos nós, foram definidos aleatoriamente e podem ser alterados com o objetivo de maximização da precisão.

A próxima variável a ser otimizada será o chamado “maxnodes” que representam o máximo número de nós que uma árvore da floresta pode ter. Para testar a precisão obtida em um intervalo de valores (De 5 à 30) usa-se o código:

```
store_maxnode <- list()
tuneGrid <- expand.grid(.mtry = best_mtry)
for (maxnodes in c(5: 30)) {
  set.seed(1234)
  rf_maxnode <- train(acao~,
    data = Base_TG_treino,
    method = "rf",
    metric = "Accuracy",
    tuneGrid = tuneGrid,
    trControl = trControl,
    importance = TRUE,
    nodesize = 14,
    maxnodes = maxnodes,
    ntree = 300)
  current_iteration <- toString(maxnodes)
  store_maxnode[[current_iteration]] <- rf_maxnode
}
results_mtry <- resamples(store_maxnode)
summary(results_mtry)
```

Onde “*expand.grid(.mtry=best_mtry)*” usa o melhor valor obtido em mtry. “store_maxnode” salva os valores obtidos com cada maxnode. O resultado final irá listar os valores de precisão obtidos para cada um dos valores de maxnode. O valor utilizado será aquele que obtém maior precisão média.

Em seguida o valor do número de árvores deve ser otimizado. Para isso, deve-se testar a precisão obtida com diferentes números de árvores:

```
store_maxtrees <- list()
for (ntree in c(250, 300, 350, 400, 450, 500, 550, 600, 800, 1000, 2000)) {
  set.seed(5678)
  rf_maxtrees <- train(acao~,
    data = Base_TG_treino,
    method = "rf",
```

```

metric = "Accuracy",
tuneGrid = tuneGrid,
trControl = trControl,
importance = TRUE,
nodesize = 14,
maxnodes = valor obtido anteriormente,
ntree = ntree)
key <- toString(ntree)
store_maxtrees[[key]] <- rf_maxtrees
}
results_tree <- resamples(store_maxtrees) 19

```

```
summary(results_tree)
```

Novamente, uma lista de precisões obtidas com diferentes números de árvores será obtida e o número de árvores com maior média de precisão será utilizado para o modelo final de predição.

No final desse processo iterativo, será obtido o modelo final de predição, com os valores de mtry, maxnode e ntree otimizados, o modelo *fit_rf*.

Com o modelo definitivo, é possível realizar a predição usando a base de teste:

```
prediction <- predict(fit_rf, Base_TG_teste)
```

Para analisar os resultados, usa-se o comando *ConfusionMatrix()*:

```

confusionMatrix(
factor(prediction, levels = c("Manter/Comprar", "Manter/Não adquirir", "Vender/Não
adquirir")),
factor(Base_TG_teste$acao, levels = c("Manter/Comprar", "Manter/Não
adquirir", "Vender/Não adquirir"))
)

```

Onde *levels* são os valores que os dados podem assumir. O Resultado será uma análise detalhada da precisão obtida e uma tabela com a comparação da quantidade de vezes que cada classe apareceu na base de referência, *Base_TG_teste\$acao*, e na predição, *prediction*. A tabela 1 apresenta a estrutura comparativa das classes:

Referência → Predição ↓	Manter/Comprar	Manter/Não adquirir	Vender/Não adquirir
Manter/Comprar	MCMC	MCMN	MCVN
Manter/Não adquirir	MNMC	MNMN	MNVN
Vender/Não adquirir	VNMC	VNMN	VNVN

Tabela 1: Quadro comparativo da quantidade predita e referência de cada classe

Os valores grifados em verde, serão aqueles preditos corretamente. O comando também irá listar o grau de assertividade de cada uma das decisões e uma série de indicadores estatísticos.

Para analisar a importância de cada uma das variáveis do vetor de característica no modelo de predição, usar o comando:

```
varImp(fit_rf)
```

4. DISCUSSÕES E RESULTADOS

Inicialmente, foi verificado a assertividade que o algoritmo teria se fosse informado a coluna do saldo obtido em D (que calcula a variação do preço da ação no dia), uma vez que as decisões eram baseadas nessa coluna (como descrito no item 3.3), era esperado que um modelo altamente preciso fosse gerado. E como esperado, o modelo gerado acertou 100% dos casos da massa de testes, mostrando que o modelo identificou o padrão estabelecido nessa característica corretamente. Esses resultados são explicitados na figura 7:

Confusion Matrix and Statistics

Prediction	Reference			
	Alto Crescimento	Baixo Crescimento	Baixa Perda	Alta Perda
Alto Crescimento	168	0	0	0
Baixo Crescimento	0	205	0	0
Baixa Perda	0	0	182	0
Alta Perda	0	0	0	147

Overall statistics

Accuracy : 1

Figura 4: Teste com coluna de saldo do dia (Fonte: própria)

Nesse momento, as decisões estavam divididas em quatro possibilidades: Alto crescimento, Baixo crescimento, Alta perda e Baixa perda. Porém, nos testes seguintes verificou-se que a assertividade,

dessas quatro categorias não eram muito altas e o padrão de três categorias descritos no item 3.3 foi adotado.

No início, os testes estavam sendo realizados fazendo uso de apenas uma ação (Petrobrás) com dados de aproximadamente 5 anos. Ao retirar a coluna de variação do dia da ação, os dados eram 100% baseados em informações do passado e a análise da predição poderia ser realizada efetivamente. No primeiro teste realizado, foi obtido 41,31% de assertividade.

Considerando que cada categoria tem 33,33% de chance de ser escolhida, o ganho não era muito significativo, o teste seguinte foi realizado removendo algumas variações que a partir da análise de importância, foram consideradas as mais irrelevantes, o resultado obtido foi uma assertividade de 40,98%, o que reforça uma característica do *Random Forest* de que o algoritmo deixa de fora do modelo determinadas características que estão levando o modelo a decisões erradas ou por não estarem contribuindo o suficiente para a predição, sendo assim informações irrelevantes não prejudicam a assertividade do algoritmo.

Em seguida, com o objetivo de aumentar a precisão das predições, foi dobrado o tamanho das bases, agora o modelo foi realizado para as ações da Petrobrás e do Itaú, com o mesmo período de tempo. O resultado obtido foi de 47,61% de precisão, isto é, houve um aumento na precisão, porém ajustes ainda deveriam ser realizados.

Foi incluída então a base de ações da Ambev e o resultado obtido foi de 51,3% de precisão. Um fato que foi verificado é que as bases continham muitos casos com a decisão “Manter/Não adquirir”, fazendo com que a assertividade desses casos fosse de 97%, mas que como resultado, o modelo predissesse 92% dos resultados como o dessa classe, onde na verdade esse número era de 48%. Conforme a figura 8:

Prediction	Reference		
	Manter/Comprar	Manter/Não adquirir	Vender/Não adquirir
Manter/Comprar	5	0	1
Manter/Não adquirir	685	1401	676
Vender/Não adquirir	65	34	133
Overall statistics			
Accuracy : 0.513			

Figura 5: Resultado com três ações (Fonte: própria)

Um dado interessante dessa análise é que, mesmo apenas 8% dos dados terem as classes diferentes de “Manter/Não adquirir”. Esses dados quando foram identificados como tais, tiveram considerável assertividade: 57,3% para “Vender/Não adquirir” e 83,3% para “Manter/Comprar”.

Visto essa realidade, foi reorganizada a base de treino de maneira que os dados tivessem a classificação mais distribuída: 33,13% “Manter/Comprar”, 31,33% “Manter/Não adquirir” e 35,54% “Vender/Não adquirir”, o que na prática também fez com que os dados mais antigos (2014 e 2015) fossem consideravelmente removidos. Os resultados obtidos do modelo de predição tiveram 59,37% de assertividade. Conforme figura 9:

Confusion Matrix and Statistics

Prediction	Reference		
	Manter/Comprar	Manter/Não adquirir	Vender/Não adquirir
Manter/Comprar	309	2	119
Manter/Não adquirir	337	705	352
Vender/Não adquirir	109	7	339

Overall Statistics

Accuracy : 0.5937

Figura 6: Resultado com três ações ajustado (Fonte: própria)

As estatísticas obtidas para cada uma das classes são apresentadas na figura 10:

Statistics by Class:

	Class: Manter/Comprar	Class: Manter/Não adquirir
Sensitivity	0.4093	0.9874
Specificity	0.9206	0.5597
Pos Pred Value	0.7186	0.5057
Neg Pred Value	0.7588	0.9898
Prevalence	0.3313	0.3133
Detection Rate	0.1356	0.3093
Detection Prevalence	0.1887	0.6117
Balanced Accuracy	0.6649	0.7736
	Class: Vender/Não adquirir	
Sensitivity	0.4185	
Specificity	0.9210	
Pos Pred Value	0.7451	
Neg Pred Value	0.7418	
Prevalence	0.3554	
Detection Rate	0.1487	
Detection Prevalence	0.1996	
Balanced Accuracy	0.6698	

Figura 7: Dados estatísticos com três ações (Fonte: própria)

Como pode ver verificado, mesmo com uma base mais distribuída, a assertividade da classe “Manter/Não adquirir” foi de 98,74%. Quando é analisado as outras classes “Manter/Comprar” obteve 40,93% e “Vender/Não adquirir” 41,95%.

Analizando a assertividade daquilo que o preditor afirmou com relação aos itens preditos como de cada classe (linha horizontal de cada classe), “Manter/Comprar” obteve precisão de 71,86%, “Vender/Não adquirir” obteve 74,5% e “Manter/Não adquirir” o percentual de 50,68%. Porém analisando a quantidade de predições de cada classe, é possível identificar um ponto de atenção, conforme figuras 11 e 12:

Distribuição dados - Base treino




Figura 8: Distribuição dos dados da base treino com três ações (Fonte: própria)

Distribuição dados preditos - Base treino



Figura 9: Distribuição dos dados preditos da base treino com três ações (Fonte: própria)

Como pode ser verificado nos gráficos, o modelo fez a predição de um percentual muito elevado de dados da classe “Manter/Não adquirir”, mesmo a base tendo uma composição quase igualitária entre as classes. Extraíndo um arquivo .csv da base predita, foi verificado que mesmo a base tendo sido manipulada para ter uma distribuição igualitária entre as classes, essa ação foi realizada a partir dos dados mais antigos, sendo assim, os dados de anos mais recentes, permaneciam tendo a classe “Manter/Não adquirir” como dominante e a variabilidade de classes preditas aconteciam nos anos em que a distribuição foi realizada. Visto essas considerações algumas medidas foram realizadas para as predições seguintes:

- Inclusão da base de 5 anos das ações da Vale, com o objetivo de aumentar o número e variabilidade de dados;
- Normalização de alguns dados, com o objetivo de evidenciar alterações relevantes nos dados;
- Inclusão do dia da semana para cada dado, com o objetivo de fornecer mais uma variável que pode ser importante na predição;
- Distribuição igualitária dos dados da base treino a cada ano, com o objetivo de garantir a variabilidade das classes em todos os anos, uma vez que cada ano pode ter diferentes características nas árvores de decisões.

Foram realizados testes com diferentes massas de teste. A assertividade máxima atingida para predição está apresentada na figura 13:

Confusion Matrix and Statistics

Prediction	Reference		
	Manter/Comprar	Manter/Não adquirir	vender/Não adquirir
Manter/Comprar	178	38	40
Manter/Não adquirir	76	286	72
vender/Não adquirir	81	60	244

Overall Statistics

Accuracy : 0.6586

Figura 10: Resultado com quatro ações (Fonte: própria)

As estatísticas obtidas para cada uma das classes são descritas na figura 14:

Statistics by class:

	Class: Manter/Comprar	Class: Manter/Não adquirir
Sensitivity	0.5313	0.7448
Specificity	0.8946	0.7858
Pos Pred Value	0.6953	0.6590
Neg Pred Value	0.8083	0.8471
Prevalence	0.3116	0.3572
Detection Rate	0.1656	0.2660
Detection Prevalence	0.2381	0.4037
Balanced Accuracy	0.7130	0.7653

	Class: Vender/Não adquirir
Sensitivity	0.6854
Specificity	0.8039
Pos Pred Value	0.6338
Neg Pred Value	0.8377
Prevalence	0.3312
Detection Rate	0.2270
Detection Prevalence	0.3581
Balanced Accuracy	0.7446

Figura 11: Dados estatísticos com quatro ações (Fonte: própria)

Como pode ser verificado nas figuras acima, a assertividade geral obteve valor superior ao anterior e analisando a distribuição dos resultados, foram obtidas evoluções significativas. A assertividade de cada uma das classes está mais distribuída: “Manter/Não adquirir” com 74,48%, “Manter/Comprar” com 53,13% e “Vender/Não adquirir” com 68,54% e analisando números absolutos, cada classe de referência teve sua respectiva classe predita como majoritária entre as predições. Além disso, a distribuição dos dados reais e preditos também está mais uniforme, conforme figuras 15 e 16:

Distribuição dados reais - Base teste




Figura 12: Distribuição dos dados da base teste com quatro ações (Fonte: própria)

Distribuição dados preditos - Base teste




Figura 13: Distribuição dos dados preditos da base treino com quatro ações (Fonte: própria)

Analisando a assertividade por empresa e por classe, obtemos a tabela 2 comparativa:

Assertividade	% Erro	% Acerto	Total Geral
Ambev	31.20%	68.80%	100.00%
Manter/Comprar	76.60%	23.40%	100.00%
Manter/Não adquirir	0.00%	100.00%	100.00%
Vender/Não adquirir	91.30%	8.70%	100.00%
Itaú	35.58%	64.42%	100.00%
Manter/Comprar	47.83%	52.17%	100.00%
Manter/Não adquirir	8.26%	91.74%	100.00%
Vender/Não adquirir	63.64%	36.36%	100.00%
Petrobras	33.09%	66.91%	100.00%
Manter/Comprar	25.81%	74.19%	100.00%
Manter/Não adquirir	66.67%	33.33%	100.00%
Vender/Não adquirir	16.36%	83.64%	100.00%
Vale	36.43%	63.57%	100.00%
Manter/Comprar	51.46%	48.54%	100.00%
Manter/Não adquirir	90.70%	9.30%	100.00%
Vender/Não adquirir	7.46%	92.54%	100.00%
Total Geral	34.14%	65.86%	100.00%

Tabela 2: Visão de assertividade por empresa (Fonte: própria)

Como pode ser verificado, a performance de cada empresa de maneira geral é bem equilibrada, porém quando é analisado a classe de cada uma das empresas, é possível verificar alguns pontos interessantes: A assertividade da classe “Manter/Não adquirir” da Ambev e do Itaú é muito alta, mostrando que o algoritmo consegue identificar com considerável assertividade, pequenas variações no preço final das ações dessas empresas. A Vale apresenta alta performance na classe “Vender/Não adquirir”, mostrando que o algoritmo identifica com muita precisão comportamentos de queda considerável dessa empresa e a Petrobrás, por sua vez, apresenta boa performance nas classes “Manter/Comprar” e “Vender/Não adquirir”, evidenciando que o modelo prediz bem as variações consideráveis dessa empresa (tanto positivas, quanto negativas).

Verificando as variáveis que foram mais significativas para a tomada de decisão do modelo predito para cada uma das classes é obtida a tabela 3:

	Manter/Comprar	Manter/Não adquirir	Vender/Não adquirir
1º	HMACD	Pesquisas	Variação do dólar (D-1)
2º	Variação do dólar (D-1)	MME (26 dias)	Variação entre encerramento (D-1)
3º	Saldo (D-1)	MMS (15 dias)	Saldo (D-1)
4º	Slow%D (7 dias)	Variação entre abertura (D) e encerramento(D-1)	Variação dólar entre encerramento(D-1) e abertura(D)
5º	MME (26 dias)	HMACD	MME (12 dias)
6º	Variação entre abertura(D) e encerramento(D-1)	MME (12 dias)	S
7º	Slow%D (14 dias)	S	MME (5 dias)
8º	ROC (5 dias)	MMS (3 dias)	MMS (3 dias)
9º	MMS (15 dias)	MME (5 dias)	MMS (15 dias)
10º	Slow%D (21 dias)	MMS (7 dias)	MACD

Tabela 3: Ranking dos indicadores mais relevantes para cada classe

Importante destacar que a tabela mostra apenas os 10 mais significativos indicadores, mas que todos os 30 foram importantes e tiveram sua contribuição para a tomada de decisão. Como pode ser verificado, cada classe teve de forma bem distinta, os indicadores mais relevantes para a tomada de decisão. Destaque para os indicadores relacionados a variação do dólar, que aparece em destaque

para duas classes, mostrando que a valorização (ou desvalorização) da moeda americana em detrimento a nossa, tem impacto no preço das ações do mercado brasileiro. Destaque também para o indicador de pesquisas, que foi o mais relevante para uma das classes, mostrando que a busca pela empresa na internet está relacionada ao seu valor de mercado acionário.

5. CONCLUSÃO

Esse trabalho apresenta a união de duas áreas do conhecimento que muitos imaginam serem muito distantes que são o mercado financeiro e a aprendizagem de máquinas, que têm como produto final uma orientação de investimentos automatizada, que reconhece padrões a partir de variáveis conhecidas no presente para prever o resultado futuro. O Mercado acionário apresenta influência de fatores externos diversos que fazem com que muitas vezes a predição não possa ser 100% assertiva, porém existem uma série de indicadores e variáveis que podem nos fornecer uma orientação, baseada nos dados e comportamentos passados, sobre como determinada ação pode se comportar no futuro.

Após análise minuciosa sobre os melhores indicadores que poderiam ser utilizados para quantificar o comportamento do mercado financeiro e visto a complexidade desses dados, que muitas vezes podem ser irrelevantes para ditar tal comportamento, a escolha do algoritmo de *Machine Learning* escolhido foi de crucial importância, pois as características do *Random Forest* atendem as necessidades dos dados apresentados. A escolha das ações a serem consideradas também foi uma decisão importante, pois a relevância dessas empresas é muito significativa no mercado brasileiro, permitindo que o modelo preditivo tenha alta aplicabilidade.

Os resultados obtidos são promissores, ficou evidente o poder que a base possui de fornecer informações valiosas quanto ao comportamento futuro das ações. Mesmo a assertividade obtida ter sido de no máximo 65%, o trabalho mostra a força da correlação entre os dados, obtendo números significativos de assertividades para cada uma das empresas e classes, que permite fornecer uma boa orientação sobre o comportamento futuro da ação, que hoje, sem análise preditiva, exige um vasto conhecimento em economia, que pode não ser suficiente e preciso como esse modelo.

Os resultados dos indicadores mais relevantes para cada uma das classes, evidencia o quão complexo é fazer a predição do comportamento de mercado das ações para um ser humano, mesmo para alguém especialista no assunto, o resultado é fruto da combinação de diferentes indicadores, cada um tendo a sua parcela de contribuição, evidenciando a dificuldade e trabalho operacional que existe em fazer a predição dos preços.

Os testes realizados geraram conhecimentos novos sobre o comportamento dos dados. Verificando a necessidade de aumentar o volume de dados, de fazer a escolha da melhor classificação possível para as decisões, de mantê-los de forma distribuída em suas classificações a cada subgrupo de dados de modo a evitar agrupamento de resultados de mesma classe, fazer a normalização dos dados, entre outras, foram formas encontradas para aumentar a precisão do modelo preditivo, que foram premissas identificadas durante os testes realizados, evidenciando que o cuidado com a seleção e tratamento dos dados é de suma importância para a identificação de modelos preditos corretos.

6. BIBLIOGRAFIA

ANDRADE, A. A. Desenvolvimento de sistema especialista com operacionalidade de aprendizado para operar em tempo real com sistemas industriais automatizados, 2007. Tese de Doutorado. Universidade de São Paulo.

ARAUJO, M. V. M. Investimento em tecnologia nas instituições financeiras e a influência das Fintechs. 2018. Tese de Doutorado.

BREIMAN, L. Random forests. *Machine learning*, v. 45, n. 1, p. 5-32, 2001. CAMILO, C. O; SILVA, J.C. Mineração de dados: Conceitos, tarefas, métodos e ferramentas. Universidade Federal de Goiás (UFG), p. 1-29, 2009.

CÁRDENAS-MONTES, M. Sobreajuste–overfitting. *Ciemat (Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas)*, 2006. COLLINS, P. Robo-Advisers. *Bloomberg*. 2016. Disponível em <https://www.bloomberg.com/quicktake/robo-advisers>. Acesso em: 04 abr. 2019.

DIETTERICH, T. G. Ensemble methods in machine learning. In: *International workshop on multiple classifier systems*. Springer, Berlin, Heidelberg, 2000. p. 1-15.

DOS SANTOS, J.J. A ascensão da classe C à Bolsa de Valores. IX Convibra Administração – Congresso Virtual Brasileiro de Administração, nov. 2012.

FOGAÇA, G. A Classe C vai à Bolsa, *Revista EXAME*, São Paulo, ed. 960. nº. 1, p. 96-99, jan. 2010. Disponível em: <https://docplayer.com.br/18988725-A-classe-c-vai-a-bolsa.html>. Acesso em 6 abr. 2019.

GÓMEZ, S.N. et al. Random forests estocástico. Porto Alegre, 2012. HAN, J; PEI, J;

KAMBER, M. *Data mining: concepts and techniques*. Elsevier, 2011.

LANZARINI, J.J.S. et al. O processo de desconcentração e pulverização dos investimentos e a popularização do mercado de ações brasileiro pós 2001. *Revista Catarinense da Ciência Contábil*, v. 9, n. 26, p. 45-61, 2011;

LIAW, A; WIENER, M. Classification and Regression by randomForest. *R News* 2(3), p. 18–22, 2002. LOPES, T. D; GOEDTEL, A; PALÁCIO, R. H. C; GODOY, W. F. Aplicação do algoritmo Random Forest como classificador de padrões de falhas em rolamentos de motores de indução. Porto Alegre, RS, BR, out. 2017.

KAUR, S; MANGAT, V. Applications of data mining in stock market. *Journal of Information and Operations Management*, v. 3, n. 1, p. 86, 2012.

NUNES, M. S; DA COSTA JR, N. C. A; MEURER, R. A relação entre o mercado de ações e as variáveis macroeconômicas: uma análise econométrica para o Brasil. *Revista Brasileira de Economia*, v. 59, n. 4, p. 585-607, 2005.

MARTINI, G.H. High-frequency trading: os algoritmos e as operações de alta frequência nas bolsas de valores. 2015.

MEDINA, M; FERTIG, C. Algoritmos e Programação: Teoria e Prática. São Paulo: Novatec, 2005.
PARANÁ, E. A digitalização do mercado de capitais no Brasil: tendências recentes. 2017.

SIRIKULVIRIYA, N; SINTHUPINYO, S. Integration of rules from a random forest, 2011 International Conference on Information and Electronics Engineering, Vol. 6, pp. 194–198, 2011.

SILVA, B. et al. Avaliação de uma Abordagem de Aprendizado Supervisionado para Operações no Mercado de Ações. In: Anais do IX Simpósio Brasileiro de Sistemas de Informação. SBC, 2013. p. 109-120.

SMITH, R. Is high-frequency trading inducing changes in market microstructure and dynamics?. 2010.
VIEIRA, F. D.; OLIVEIRA, S.R. M. Mineração de dados: conceitos e um estudo de caso sobre certificação racial de ovinos. Embrapa Informática Agropecuária-Capítulo em livro científico (ALICE), 2014.

Capítulo 3



10.37423/230107079


DIAGNÓSTICO INTELIGENTE DE FALHAS EM EQUIPAMENTOS DINÂMICOS ATRAVÉS DA TRANSFORMADA WAVELET E DADOS ESTATÍSTICOS

Luiz Alberto Pinto

Instituto Federal do Espírito Santo

Diego Assereuy Lobão

Instituto Federal do Espírito Santo



Resumo: Este artigo aborda o tema do diagnóstico de falhas em equipamentos dinâmicos aplicando técnicas de aprendizado de máquina com a utilização de descritores extraídos por meio da *Transformada Wavelet (TW)*, e descritores estatísticos calculados no domínio do tempo. Os desempenhos dos modelos de classificação obtidos pelos algoritmos *k-Nearest Neighbour (k-NN)*, *Support Vector Machine (SVM)*, *Floresta Aleatória (FA)* e *Redes Neurais Artificiais - Multilayer Perceptron (RNA-MLP)* são comparados. Além disso, o trabalho traz uma breve abordagem sobre redução de dimensionalidade através da Análise de Componentes Principais (PCA). O conjunto de dados utilizado nos experimentos foi obtido no simulador de máquinas rotativas *Mafaulda*, e o melhor resultado foi alcançado com a Floresta Aleatória (98,46%), com os dados no domínio *wavelet*.

Palavras-chave: diagnóstico de falhas; aprendizado de máquina; transformada *wavelet*; extração de características; análise de vibração; *mafaulda*; reconhecimento de padrões.

1 INTRODUÇÃO

Motores elétricos são responsáveis por cerca de 40% de todo o consumo de energia elétrica do mundo. Suas boas condições de funcionamento dependem, grandemente, das condições de conservação dos mancais de rolamento. Os mancais de rolamento têm como função dar suporte mecânico às partes rotativas, reduzir o coeficiente de atrito do movimento e garantir a precisão da rotação. Portanto, uma vez que exista um defeito no rolamento, a estabilidade de todo o conjunto pode ser afetada, provocando danos ao equipamento, condições inseguras e interrupções na produção. Além disso, deve ser levado em consideração que, em alguns processos, como aeronaves em operação e atividades hospitalares críticas, as falhas não são toleradas (*Chambers, Johnston and Slack, 2002*).

Entre as estratégias de manutenção existentes, a manutenção preditiva tem sido o enfoque de várias empresas. Nessa estratégia, o objetivo principal é a eliminação de falhas através do monitoramento das condições operacionais de um equipamento, através da medição das variáveis dos processos. Dessa forma, falhas podem ser detectadas e diagnosticadas ainda em seu estágio inicial, possibilitando assim que as intervenções sejam realizadas conforme uma programação que concilie os objetivos de continuidade da produção, otimização da vida útil das peças a serem substituídas e redução do tempo de parada devido a falhas inesperadas.

As abordagens atuais mais comumente aplicadas para detecção e diagnóstico de falhas em rolamentos, consiste na utilização de técnicas de reconhecimento de padrões através do uso de algoritmos de classificação. Nessa abordagem, através da análise dos sinais das variáveis extraídas de um processo, é possível conhecer a sua natureza de operação, seja ela uma condição normal ou uma condição de falha. Nesse contexto, a análise dos sinais de vibração tem se mostrado um caminho muito promissor. Uma vez que falhas em rolamentos alteram o regime de vibração do sistema, a aquisição e análise desses sinais pode fornecer informações importantes sobre o estado de conservação desses componentes.

Uma variedade de soluções para elaboração de diagnósticos inteligentes de falhas em rolamentos de motores elétricos tem sido proposta na literatura. Por exemplo, *Support Vector Machine (SVM)*, Árvore de Decisão (AD), Redes Neurais Artificiais (RNA), Redes Neurais Convolucionais (*Convolutional Neural Networks – CNN*), e aplicação de outras arquiteturas de redes profundas. As principais etapas para elaboração de diagnósticos de falhas são: (1) aquisição dos sinais do processo; (2) processamento dos sinais e (3) classificação (elaboração do diagnóstico). Outra abordagem que tem se mostrado

eficiente é a utilização da *Transformada Wavelet* (Mallat, 1989), juntamente com algoritmos de classificação. Nesse caso, os descritores das falhas são extraídos dos sinais do processo após os mesmos serem transformados para o domínio *wavelet*.

Este trabalho apresenta um estudo sobre o diagnóstico de falhas em equipamentos dinâmicos utilizando a *Transformada Wavelet* (TW), através da análise dos sinais de vibração. Para a construção dos modelos, foram utilizados os sinais de vibração do conjunto de dados da bancada experimental *Mafaulda* (Machinery Fault Database), e os modelos foram implementados por meio dos algoritmos *k-Nearest Neighbour* (k-NN), *Support Vector Machine* (SVM), Redes Neurais Artificiais - *Multilayer Perceptron* (RNA-MLP) e Floresta Aleatória (FA).

O restante deste trabalho contém os seguintes capítulos: a *Seção 2* apresenta uma breve revisão da literatura sobre diagnóstico de falhas em rolamentos, e a aplicação da *Transformada Wavelet* para extração de descritores. A *Seção 3* aborda a teoria de RNAs, falhas em rolamentos e métricas de desempenho. Em seguida, na *Seção 4*, apresentam-se as ferramentas e métodos utilizados na implementação e execução do trabalho. Em seguida, na *Seção 5*, os resultados obtidos são apresentados e discutidos, e finalmente, na *Seção 6*, são elaboradas as conclusões e comentários finais.

2 REVISÃO BIBLIOGRÁFICA

Pesquisas envolvendo diagnóstico de falhas através do processamento de sinais de vibração já tem sido realizadas ao longo das últimas décadas.

O trabalho desenvolvido por *Prabhakar et al. (2002)* apresenta um estudo sobre diagnóstico de falhas em mancais de rolamentos de esferas utilizando a *Transformada Wavelet Discreta* (TWD) para análise dos sinais de vibração. O experimento aborda falhas nas pistas interna e externa de cinco mancais. O trabalho se baseia na análise multiresolução, e realiza a decomposição dos sinais de vibração utilizando a *wavelet* da família *Daubechies* (db4). Esse procedimento possibilita a análise da sensibilidade da detecção das condições de falhas presentes nos diversos níveis de detalhe. Os autores investigaram também a utilização de parâmetros estatísticos obtidos no domínio do tempo, e verificaram que a *curtose* e o *valor rms* do sinal são parâmetros sensíveis às diferentes falhas, contudo, não possuem a capacidade de detectar falhas em estágios iniciais. Por último, os autores investigaram a utilização da *curtose*, calculada a partir dos sinais de detalhe em diversos níveis de decomposição, e verificaram a grande sensibilidade desse parâmetro à detecção de falhas incipientes. O experimento

concluiu que o uso de técnicas envolvendo a *TWD* combinadas com extração de parâmetros estatísticos favorecem o diagnóstico de falhas em mancais de rolamentos.

Uma metodologia de diagnóstico de falhas em máquinas rotativas é apresentada no trabalho de *Santiago et al. (2004)*. O autor utilizou a *Transformada Wavelet Contínua (TWC)* da família Morlet para análise da resposta à sinais de vibração em regimes transientes e estacionários. Para a classificação das condições de falha foi utilizada a energia contida nas bandas de frequência extraídas através do algoritmo *Wavelet Packet Transform (WPT)*, em conjunto com uma *RNA*, técnica conhecida como *Wavelet Packet Neural Network (WPNN)*. Os resultados obtidos mostraram que o *WPNN* como técnica de classificação e diagnóstico de falhas em máquinas rotativas é eficiente, tendo sido obtida acurácia próxima de 100%.

Pesquisas sobre diagnóstico inteligente de falhas em rolamentos de esferas aplicando *RNA* e *SVM* foram apresentadas no trabalho de *Kankar et al. (2011)*. Através da análise e extração de descritores de sinais de vibração, os autores investigaram diversas falhas nos rolamentos de esferas, tais como, defeitos nas pistas externa e interna, defeitos nos elementos rolantes e uma combinação de todos eles. Métodos estatísticos foram utilizados para extração de descritores no domínio do tempo, como a *média*, o *desvio padrão*, a *assimetria*, a *amplitude*, a *curtose* e o *fator de crista*. Técnicas de seleção de variáveis que empregam algoritmos de aprendizado de máquina foram utilizados para redução da dimensionalidade do conjunto. Apesar da baixa acurácia devido a pequena quantidade de amostras contida no conjunto de dados, 71,23% para o modelo utilizando *RNA* e 73,97% para o modelo utilizando *SVM*, os autores consideraram que os resultados da classificação se mostraram promissores e com grande potencial de aplicação em sistemas de diagnósticos inteligentes para prevenção de falhas.

Pesquisas que utilizaram métodos de similaridades foram realizadas por *Ribeiro et al. (2017)*. Nessa técnica, a utilização do modelo de similaridade auxiliou na geração de descritores para um classificador, e pode ser utilizado também como classificador independente. O modelo baseado em similaridade é um algoritmo não paramétrico, capaz de procurar pelo menor número de amostras representativas que sejam suficientes e eficazes para descrever cada classe. Os autores utilizaram dados estatísticos no domínio do tempo e da frequência para extração dos descritores, e como classificador foi utilizado um modelo baseado em *Floresta Aleatória (FA)*. Resultados experimentais utilizando os conjuntos de dados *Mafaulda* e *CWRU (Case Western Reserve University)* mostraram o poder de generalização do modelo. Os autores relatam taxas de acerto acima de 96%.

Uma combinação de *Rede Neural Convolutacional (RNC)* e *Extreme Learning Machine (ELM)* foi utilizada no trabalho de *Chen et al. (2019)*. A pesquisa foi realizada utilizando uma bancada experimental composta por um motor acionador, um transdutor de torque e uma caixa multiplicadora, na qual foram introduzidas falhas nos mancais de rolamentos e nas engrenagens. O experimento utiliza sinais de vibração coletados através de acelerômetros instalados no equipamento. Esses sinais foram processados utilizando a *TWC*, a partir dos quais foram gerados escalogramas. Na segunda etapa foi utilizado uma *RNC* para a extração do vetor de características das imagens que foram classificadas por uma rede *ELM*. Durante os testes, foram reproduzidos sete tipos de falhas, num total de 2100 amostras, sendo 300 amostras para cada classe. Segundo os autores, o método proposto superou técnicas tradicionais de *machine learning* que utilizaram descritores baseados na *Transformada Rápida de Fourier*. O melhor resultado obtido com o método proposto, que utilizou a combinação *RNC-ELM*, obteve acurácia acima de 99%.

3 REFERENCIAL TEÓRICO

Esta seção descreve os princípios que fundamentam os algoritmos de classificação, bem como apresenta os fundamentos matemáticos da *Transformada Wavelet*, aqui utilizada para extração de descritores no domínio tempo/frequência.

3.1 ALGORITMOS DE CLASSIFICAÇÃO

A etapa de classificação no presente trabalho foi realizada com a aplicação dos algoritmos *k-Nearest Neighbour (k-NN)*, *Support Vector Machine (SVM)*, *Floresta Aleatória (FA)* e *Redes Neurais Artificiais – Multilayer Perceptron (RNA - MLP)*. No que segue é feita uma breve descrição desses algoritmos.

k-NN: o *k-NN* é um classificador não paramétrico que atribui a amostra desconhecida à mesma classe das *k* amostras mais próximas, segundo um critério de decisão. Sua simplicidade e eficácia fazem com que esse algoritmo seja amplamente utilizado em problemas de classificação (*Fayed and Atiya, 2009*). O princípio sobre o qual o *k-NN* se baseia, é de que amostras similares tendem a se concentrar em uma mesma região do espaço. Apesar de sua implementação ser simples, o *k-NN* não é muito robusto quando os dados apresentam *outliers* (*Sugiyama, 2015*). Para a classificação, o modelo necessita de uma regra de decisão, que geralmente consiste em atribuir à classe desconhecida a classe da maioria dos *k* vizinhos-mais-próximos. Além disso, o valor de *k*, bem como a métrica de distância a ser utilizada devem ser definidos previamente. Nesta pesquisa foram utilizados os valores de *k=1, 3* e *5*, e a distância euclidiana foi adotada como métrica de distância.

FA: FA é uma coleção de árvores de decisão (*Breiman et al., 1984*). Árvores de decisão são algoritmos estruturados em forma de grafo, constituídos por nós de decisão e arcos, aos quais estão associadas as regras que serão aplicadas à classificação (*Furnkranz et al., 2012*). A classificação de amostras desconhecidas resulta do conjunto de decisões, segundo critérios específicos, que são tomadas ao se percorrer a árvore. Critérios de decisão que podem ser utilizados são, por exemplo, a *entropia* e *índice de Gini*. De forma geral, árvores de decisão apresentam bons desempenhos em tarefas de classificação. Contudo, para problemas que envolvam grandes conjuntos de dados e alta variância, a FA pode ser mais adequada. Uma das formas de se implementar a FA é a utilização do *bagging*. O *bagging* particiona o conjunto de treino em diversos subconjuntos. Para cada subconjunto, características são selecionadas, e um modelo é treinado formando diversas árvores, cujos resultados são combinados. Ao estimar uma entrada, cada árvore irá classificar o subconjunto de forma independente, sendo que a decisão a respeito da classe a qual a amostra desconhecida será atribuída, resultará de um processo de votação, e a classe atribuída será aquela com maior número de votos. Nesta pesquisa foi utilizada uma coleção de 100 árvores.

SVM: SVMs são classificadores lineares binários não probabilísticos que se baseiam na teoria do aprendizado estatístico (*Cortes and Vapnik, 1995*). Para a classificação, o algoritmo busca um hiperplano de separação entre duas classes, de forma a maximizar a distância entre dois objetos mais próximos. Em problemas não lineares, o SVM utiliza funções *kernel*, as quais realizam a transformação do espaço dimensional dos dados não linearmente separáveis para uma dimensão superior, onde pode ser encontrado um limite de decisão linear. Por se tratar de um classificador binário, problemas de classificação que envolvam mais de duas classes requerem a aplicação de métodos multiclasse. Os métodos multiclasse mais utilizados são *one-vs-one* e *one-vs-all*. No primeiro, conhecido como *todos-contra-todos*, dadas n classes são gerados $n(n - 1)/2$ classificadores binários, sendo cada um deles responsável por determinar apenas um par de classes. O resultado é definido pelo método de votação, sendo a classe mais votada atribuída à amostra. No segundo método, denominado *um-contra-todos*, para um problema com n classes, são gerados n classificadores binários, cada um especializado em uma classe. Essa técnica pode apresentar desvantagem quando ocorre um desbalanceamento considerável no conjunto de dados (*Faceli et al., 2011*). Como decisão de projeto, foi utilizado o método multiclasse *one-vs-one* e *kernel linear*.

RNA-MLP: RNA-MLP são compostas por uma ou mais camadas intermediárias de neurônios, e uma camada de saída. Na topologia MLP, o fluxo de informação é iniciado na camada de entrada e, na

sequência, percorre as camadas intermediárias até alcançarem a camada de saída (Haykin, 2010). Para o ajuste dos pesos, essa arquitetura de rede utiliza o algoritmo *backpropagation*, que consiste em duas etapas: *forward* e *backward*. Na primeira, *forward*, cada neurônio da primeira camada recebe a amostra e aplica a função de ativação. A saída dessa camada é utilizada como entrada para a camada seguinte, assim sucessivamente até que seja obtida a saída da rede. Na segunda etapa, *backward*, a saída da rede é comparada com o valor desejado e o valor do erro é calculado. Os valores dos pesos sinápticos e dos limiares dos neurônios são ajustados num caminho que percorre a camada de saída até a primeira camada intermediária. Existe uma grande variação do algoritmo *backpropagation*, neste projeto foi utilizado o *Levenberg-Marquardt*, (Hagan and Menhaj, 1994). A rede neural utilizada nesse trabalho contém duas camadas ocultas, sendo a primeira com quarenta neurônios e a segunda com vinte, e o número de épocas de treinamento foi limitado a vinte.

3.2 TRANSFORMADA WAVELET - TW

A TW é uma ferramenta matemática eficiente para processamento de sinais, notadamente, quando aplicada a sinais não estacionários. Uma das vantagens de sua utilização é a possibilidade de, ao mesmo tempo, analisar um trecho específico, ou um intervalo do sinal, retendo as informações espectrais importantes e não visíveis no domínio original, característica que pode ser vantajosa para aplicações de detecção de falhas (Al-Badour et al., 2011).

A TWC (Strang and Nguyen, 1996) pode ser definida de acordo com a Equação (1),

$$TWC(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

com $a \neq 0$, onde $x(t)$ é o sinal a ser analisado, e a função $\psi(t)$ é denominada *wavelet-mãe*. A Equação (1) pode ser interpretada como a convolução do sinal no domínio do tempo. A função $\psi(t - b/a)$ corresponde a *wavelet-mãe* dilatada/contraída pela escala a e transladada pelo fator b (Strang and Nguyen, 1996). O termo $1/\sqrt{|a|}$ é utilizado para assegurar que os valores da TWC em todas as escalas possam ser diretamente comparados, mantendo constante a energia (Strang and Nguyen, 1996).

A versão discreta da transformada pode ser diretamente obtida da TWC pela discretização dos parâmetros a e b , fazendo $a=a_0$ e $b=kb_0a_0^j$, sendo j, k valores inteiros e $a > 1, b > 0$. Fazendo $a_0=2$ e $b_0=1$, obtém-se um caso particular de discretização, denominado discretização diádica (Strang and Nguyen, 1996). Nesse caso, pode-se obter a *Transformada Wavelet Discreta - TWD* de forma computacionalmente eficiente através do uso de bancos de filtros passa-altas e passa-baixas. A Figura

1 apresenta o esquema do banco de filtros de decomposição para cálculo da *TWD*. Neste exemplo, foram considerado três níveis de resolução para a decomposição do sinal de entrada $f(x)$.




Figura 1: Banco de filtros de decomposição para cálculo dos coeficientes wavelet do sinal $f(x)$

A estrutura do banco de filtros de decomposição consiste em um par de filtros, sendo um passa-baixas (h_0) e um passa-altas (h_1), seguidos por operações de subamostragem. As saídas subamostradas dos filtros passa-baixas e passa-altas são denominadas, coeficientes de aproximação e coeficientes de detalhe, respectivamente. As operações de filtragem/subamostragem podem ser reaplicadas, recursivamente, aos coeficientes de aproximação até o número de níveis de resolução especificado pelo analista. Os filtros h_0 e h_1 são de comprimento finito e, portanto, cada coeficiente de aproximação e detalhe corresponde a um trecho do sinal original. Como já anteriormente destacado esta característica de localização espacial é uma das principais vantagens da *transformada wavelet* sobre a *transformada de Fourier*.

4 O CONJUNTO DE DADOS MAFAULDA

Para a realização dos experimentos foi utilizado o conjunto de dados *Mafaulda*, de propriedade do *Signals, Multimedia, and Telecommunications Laboratory - COPPE/UFRJ*, que pode ser obtido livremente no site da instituição. O conjunto de dados *Mafaulda* é constituído por 1951 sinais de vibração, distribuídos entre dez classes, gerados na bancada experimental *Machinery Fault Database - Mafaulda*, para análise e diagnóstico de falhas em máquinas rotativas. A bancada é composta por um motor CC de 0,25 CV, e a faixa de velocidade utilizada nos testes variou de 700 a 3600 RPM. Para aquisição dos sinais de vibração, foram utilizados sensores do tipo acelerômetro fixados sobre os mancais do equipamento, configurados para realizar medidas nas direções, radial e axial. A coleta dos dados foi realizada com uma taxa de amostragem de 50 kHz durante 5 segundos, totalizando 250 mil pontos por amostra. O experimento contém dez condições de operação do equipamento sendo (i) operação normal (NR), (ii) desalinhamento paralelo (DP), (iii) desalinhamento angular (DA), (iv) desbalanceamento (DB), (v) falha no elemento rolante do mancal 1 (FRM1), (vi) falha na gaiola do

mancal 1 (FGM1), (vii) falha na pista externa do mancal 1 (FPM1), (viii) falha no elemento rolante do mancal 2 (FRM2), (ix) falha na gaiola do mancal 2 (FGM2) e (x) falha na pista externa do mancal 2 (FPM2). A Tabela 1 mostra a quantidade de amostras para cada condição de operação.

Tabela 1: Classes, condição de operação e quantidade de amostras por classe do conjunto Mafaulda

Classe	Condição de operação	Nº de amostras
C1	Normal	49
C2	Desalinhamento paralelo	197
C3	Desalinhamento angular	301
C4	Desbalanceamento	333
C5	Falha no elemento rolante do mancal 1	186
C6	Falha na gaiola do mancal 1	188
C7	Falha na pista externa do mancal 1	184
C8	Falha no elemento rolante do mancal 2	137
C9	Falha na gaiola do mancal 2	188
C10	Falha na pista externa do mancal 2	188
Total		1951

As falhas por desalinhamentos foram simuladas com a instalação de calços nos suportes dos mancais (variando de 0mm a 2mm). Para simular as falhas por desbalanceamento, massas variando de 6 a 35 gramas foram acrescentadas no rotor. Devido à complexidade das falhas em mancais de rolamento, o fabricante da bancada forneceu rolamentos defeituosos com três tipos de falhas distintas sendo (i) falha na gaiola, (ii) falha na pista externa e (iii) falha no elemento rolante. Cada rolamento defeituoso foi colocado, um por vez, em posições diferentes entre o rotor e o motor (mancal 1), e na posição externa (mancal 2). A Figura 2 mostra uma ilustração da bancada experimental, e a posição de instalação dos acelerômetros. Os pontos de coleta dos sinais de vibração estão localizados nos mancais 1 e 2 e são representados por 1A, 1H e 1V, referentes ao mancal 1, e os pontos 2A, 2H e 2V, referentes ao mancal 2. Os sensores radiais são identificados como vertical (V) e horizontal (H), e permitem identificar falhas geradas por forças no sentido perpendicular ao eixo central do equipamento. As medições no sentido axial (A) permitem identificar vibrações por movimentos paralelos ao eixo (Moblely, 1999).




Figura 2: Bancada experimental Mafaulda

5 METODOLOGIA

Esta seção apresenta as etapas executadas para a realização dos experimentos. São descritas as etapas de extração de características, pré-processamento, normalização dos dados, redução de dimensionalidade e treinamento dos classificadores.

5.1 EXTRAÇÃO DE CARACTERÍSTICAS

(1) Domínio do Tempo: na ocorrência de uma falha, as estruturas mecânicas rígidas no entorno do equipamento são afetadas produzindo sinais de vibração. De acordo com *Rauber et al. (2015)*, *Nayana and Geethanjali (2017)* e *Tahir et al. (2017)*, o comportamento da falha representado pelo sinal de vibração pode ser adequadamente descrito por parâmetros estatísticos tais como, o valor médio (x_m), a amplitude da raiz (x_{root}), a raiz quadrada média (x_{rms}), o valor de pico (x_{peak}) e o desvio padrão (x_{std}). Esses atributos refletem as variações na intensidade de uma falha consolidada, porém, não são sensíveis a detecção de falhas em estágios iniciais. Para compensar a baixa sensibilidade dos parâmetros anteriormente mencionados, outras grandezas estatísticas podem ser utilizadas, entre elas, a assimetria ($x_{skewness}$), a curtose ($x_{kurtosis}$), o fator de crista (x_{crest}), o fator de folga ($x_{clearance}$), o fator de forma (x_{shape}) e o fator de impulso ($x_{impulse}$). A utilização dos referidos parâmetros para representar os sinais de vibração no domínio do tempo, pode resultar em sistemas de diagnósticos sensíveis a falhas precoces, mas que ainda mantenham o bom desempenho com o aumento da severidade destas (Lei, 2016). A Tabela 2 apresenta a descrição matemática dos parâmetros estatísticos extraídos dos sinais no domínio do tempo. Para cada uma das amostras do sinal de vibração obtida por cada um dos seis sensores, onze parâmetros foram extraídos, constituindo assim um conjunto de dados com 1951 amostras e 66 descritores.

Tabela 2: Parâmetros estatísticos extraídos dos sinais de vibração nos domínios, do tempo e tempo/frequência (Lei, 2016)

Parâmetro	Descrição matemática
Valor médio	$x_m = \frac{\sum_{n=1}^N x(n)}{N}$
Valor de pico	$x_{peak} = \max x(n) $
Fator de folga	$x_{clearance} = \frac{x_{peak}}{x_{root}}$
Amplitude da raiz	$x_{root} = \left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N} \right)^2$
Curtose	$x_{kurtosis} = \frac{\sum_{n=1}^N (x(n) - x_m)^4}{(N - 1)x_{std}^4}$

Fator de impulso	$x_{impulse} = \frac{x_{peak}}{\frac{1}{N} \sum_{n=1}^N x(n) }$
Desvio padrão	$x_{std} = \sqrt{\frac{\sum_{n=1}^N (x(n) - x_m)^2}{N - 1}}$
Skewness	$x_{skewness} = \frac{\sum_{n=1}^N (x(n) - x_m)^3}{(n - 1)x_{std}^3}$
Fator de forma	$\frac{x_{rms}}{\frac{1}{N} \sum_{n=1}^N x(n) }$
Raíz quadrada média	$x_{rms} = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$
Fator de crista	$x_{crest} = \frac{x_{peak}}{x_{rms}}$

A Figura 3 é uma ilustração de amostras dos sinais de vibração, capturado pelo sensor 1V, em cada uma das condições de operação no período de 0,1 segundos, numa velocidade próxima de 60 Hz. Pode-se notar que as diferentes condições de operação são refletidas nas diferenças entre as magnitudes em cada caso. Dessa forma, descritores baseados em parâmetros estatísticos podem representar diferentes padrões de comportamento para cada natureza de falha.




Figura 3: Amostras dos sinais de vibração do conjunto de dados Mafaulda em cada uma das condições de operação

(2) Domínio tempo/frequência: para extração de descritores no domínio tempo/frequência foi aplicada a análise multiresolução, utilizando a *TW* como ferramenta para sua implementação. Considerando sua utilização em trabalhos similares anteriores, nesse trabalho, para a decomposição dos sinais de vibração, foi aplicada a função *wavelet db10* da família *Daubechies*, e os sinais foram decompostos em 10 níveis de resolução. A Figura 4 apresenta a árvore de decomposição dos sinais, bem como as frequências em cada nível de aproximação e detalhe após a aplicação dos filtros passa-baixas e passa-altas. Na Figura 4, *S* representa o sinal original, *A_i* e *D_i* representam os sinais de aproximação e detalhe no *i*-ésimo nível. Para a representação dos sinais de vibração no domínio tempo/frequência, foi calculado o valor da *entropia de Shannon*. Este indicador reflete a distribuição de energia contida no sinal, sendo definida matematicamente pela Equação (2) (Correa and Guzman, 2020).

$$H_E = - \sum_{j=1}^n p_j \log p_j \quad (2)$$




Figura 4: Árvore de decomposição wavelet utilizando o filtro wavelet db10

A Figura 5 apresenta o valor médio da entropia de *Shannon* para cada nível de decomposição em cada condição de operação. Nos gráficos, a primeira barra representa o valor da entropia de *Shannon* do sinal de aproximação (A10) e as demais barras representam, na ordem, as entropias nos níveis de detalhe de D1 a D10. Para cada sensor, onze valores de entropia foram extraídos, totalizando sessenta e seis descritores.




Figura 5: Entropia dos níveis de resolução para cada condição de operação do conjunto

5.2 NORMALIZAÇÃO DOS DADOS

A normalização é uma transformação numérica utilizada quando o conjunto de dados possui atributos com escalas e ordens de grandeza diferentes. Sua aplicação tem por objetivo evitar que o valor de um atributo predomine sobre os outros, e dessa forma exerça maior influência no modelo, ainda que não seja o mais relevante (Faceli et al., 2011). A técnica de normalização utilizada nessa pesquisa foi a denominada normalização por reescala, definida pela Equação (3), no qual os valores dos atributos estarão dentro do intervalo de zero a um.

$$x_{novo} = \frac{x_{atual} - x_{min}}{x_{max} - x_{min}} \quad (3)$$

5.3 ANÁLISE DE COMPONENTES PRINCIPAIS

Análise de Componentes Principais (Principal Component Analysis - PCA) é uma técnica de extração de características, na qual novas variáveis são encontradas através de combinações lineares das variáveis originais (Pearson, 1901). A PCA busca obter uma representação do espaço amostral em uma região

com menor dimensionalidade, através da realização de projeções ortogonais do espaço original, de maior dimensão, sobre um espaço com menor dimensão.

A *Figura 6* ilustra a representação das variáveis originais em três dimensões, e ao lado a representação bidimensional das duas primeiras componentes principais. O objetivo é encontrar uma representação espacial de menor dimensão em um conjunto de dados, maximizando a variância do conjunto.




Figura 6: Redução da dimensão do espaço amostral de três para duas dimensões utilizando PCA

Nesta pesquisa, a *PCA* foi utilizada para a redução da quantidade de descritores no domínio do tempo e no domínio tempo/frequência. Em ambos os casos, a variância retida foi 99% da variância total contida no conjunto original. A *Figura 7* apresenta a relação entre o número de componentes principais e a variância explicada quando a *PCA* foi aplicada aos descritores no domínio do tempo e no domínio tempo/frequência. Observa-se que, quando aplicada no domínio do tempo, a *PCA* reduz a quantidade de descritores de 66 para 27, o que corresponde a uma redução de 59,09%. Por sua vez, para os descritores no domínio tempo/frequência, obtidos pela decomposição *wavelet* dos sinais, houve uma redução de 66 para 37 descritores, o que equivale a uma redução de 43,94% do total.




Figura 7: Variância explicada versus o número de componentes principais extraídas pela PCA

5.4 TREINAMENTO DO CLASSIFICADOR

Para a modelagem, o conjunto de dados foi particionado em treino e teste, com 70% e 30% das amostras, respectivamente. Os modelos foram obtidos utilizando os algoritmos k-NN, SVM, FA e RNA-MLP, que foram treinados por validação cruzada, utilizando 10 partições. Como métrica de avaliação de desempenho foi utilizada a acurácia. Todos os testes foram realizados no Matlab® R2019a.

6 RESULTADOS

A Tabela 3 apresenta os resultados dos testes no domínio do tempo. Para os experimentos, duas configurações do conjunto de dados foram utilizadas sendo (i) utilização de todos os sessenta e seis descritores do conjunto de dados (66-D) e (ii) utilização das vinte e sete componentes principais (27-CP) obtidas com a aplicação da PCA. Em todos os casos foi verificado o desempenho do classificador nas fases de treino e teste.

Tabela 3: Desempenho dos classificadores utilizando descritores estatísticos no domínio do tempo

ALGORITMO	ACURÁCIA			
	66-D		27-CP	
	Treino	Teste	Treino	Teste
1-NN	91,80	79,83	91,80	80,51
3-NN	90,34	81,54	90,48	80,85
5-NN	88,87	81,20	88,95	81,71
SVM	95,31	28,55	92,75	75,38
RNA-MLP	97,00	73,68	98,75	51,97
FA	96,56	90,43	91,15	81,20

Como pode ser observado na *Tabela 3*, de forma geral, todos os classificadores apresentaram bom desempenho. Utilizando o conjunto original de variáveis (66-D), o melhor resultado foi obtido com o modelo *FA*, com uma taxa de acerto na etapa de teste de 90,43%. Quando os classificadores foram treinados utilizando o conjunto reduzido através da *PCA* (27-CP), de forma geral, os resultados obtidos foram equivalentes aos obtidos pelos modelos com todas as variáveis. Contudo, nesta configuração o melhor resultado obtido, acurácia de 81,71% com o modelo 5-NN, foi inferior ao melhor resultado obtido com todos os descritores, 90,43% com o modelo *FA*.

Testes utilizando os descritores extraídos no domínio tempo/frequência, com a aplicação da análise multiresolução implementada através da *TW* foram realizados utilizando a mesma abordagem adotada para os descritores no domínio do tempo. Foram realizados testes com (i) todo o conjunto original de descritores (66-D) e (ii) as trinta e sete componentes principais (37-CP) obtidas pela *PCA*, os resultados estão apresentados na *Tabela 4*.

Tabela 4: Desempenho dos classificadores utilizando descritores estatísticos no domínio tempo/frequência

ALGORITMO	ACURÁCIA (%)			
	66-D		27-CP	
	Treino	Teste	Treino	Teste
1-NN	88,80	86,67	87,41	85,98
3-NN	84,41	84,44	83,60	82,74
5-NN	84,11	84,10	82,43	82,91
SVM	98,98	79,83	90,41	77,09
RNA-MLP	95,24	83,59	94,65	76,92
FA	98,98	98,46	93,48	88,03

Conforme pode ser visto na *Tabela 4*, todos os modelos apresentaram bons resultados na classificação. O modelo baseado em *FA* obteve os melhores resultados em todos os testes. Utilizando o conjunto original de descritores (66-D) foi obtido uma acurácia de 98,46%, e utilizando o conjunto reduzido (37-CP) a taxa de acerto foi 88,03%.

Quando analisados os desempenhos dos classificadores, verifica-se que a utilização de um único descritor (*entropia de Shannon*), no domínio *wavelet*, supera os resultados dos classificadores que utilizaram descritores extraídos no domínio do tempo, ou seja, em todos os testes, os resultados dos modelos utilizando descritores baseados no domínio tempo/frequência foram superiores. Pode-se notar também que o modelo utilizando *FA* obteve o melhor resultado, com acurácia de 98,46% utilizando descritores no domínio tempo/frequência. A redução da dimensionalidade através da *PCA*,

mantendo 99% de variância, reduziu o desempenho dos classificadores nos dois domínios em que os testes foram realizados, o que significa que informações relevantes são perdidas.

Para fins de comparação dos desempenhos nos domínios do tempo e tempo/frequência, a *Figura 8* apresenta os resultados de forma gráfica, para a modelagem com todos os descritores (66-D) e utilizando o conjunto reduzido através da *PCA*. A abordagem que utiliza análise multiresolução através da *TW* obteve, em geral, desempenhos superiores, se comparado ao método utilizando descritores no domínio do tempo.




Figura 8: Comparação dos desempenhos dos classificadores nos domínios do tempo e tempo/frequência, com todos os descritores e com a redução pela *PCA*.

7 CONCLUSÃO

Os resultados obtidos nos testes mostram a viabilidade de se implementar sistemas inteligentes de monitoramento em equipamentos dinâmicos. As amostras investigadas possuem características de separabilidade, o que facilita o bom desempenho dos algoritmos de classificação, tendo, alguns modelos, atingido acurácia superior a 90%. Em geral, o melhor desempenho foi obtido com o modelo *FA* (90,43% e 98,46%) nos testes nos domínios, do tempo e tempo/frequência, respectivamente, o que demonstra a possibilidade da elaboração de diagnósticos precisos e confiáveis.

Nas estratégias envolvendo a redução da dimensionalidade através da *PCA*, foram obtidas taxas de acerto de no máximo 88,03% utilizando o modelo *FA* (37-CP). Os resultados comprovam que informações relevantes são perdidas durante a transformação dos dados.

De forma geral, os resultados demonstram que técnicas de reconhecimento de padrões ganham cada vez mais atenção em aplicações que envolvem o monitoramento de equipamentos de grande porte, ou até mesmo plantas de processos. No contexto atual, o monitoramento das variáveis de processos, combinadas com dados históricos dos equipamentos, juntamente com a utilização de técnicas de *machine learning* formam uma ferramenta poderosa para diagnóstico de falhas. Totalmente alinhada ao conceito de *Prognostics and Health Management*, podem estimar a ocorrência de falhas, programando intervenções quando estas ainda se encontram em fase inicial, o que reduz os custos de manutenção. A intervenção sobre o processo, ainda quando as falhas não estão consolidadas, evita ocorrências emergenciais que, de forma geral, são mais prejudiciais, pois, resultam em perdas de produção, impactos ambientais e danos aos equipamentos ou pessoas.

REFERÊNCIAS BIBLIOGRÁFICAS

- Al-Badour, F., Sunar, M., and Cheded, L. (2011). Vibration analysis of rotating machinery using time-frequency analysis and wavelet techniques. *Mechanical Systems and Signal Processing*, 25(6), 2083-2101.
- Breiman, L., Friedman, J., Stone, C.J., and Olshen, R.A. (1984). *Classification and Regression Trees*. CRCpress.
- Chambers, S., Johnston, R.; Slack, N. *Administração da produção*. São Paulo: Atlas, 2002.
- Chen, X., Zhang, B., and Gao, D. (2020). Bearing fault diagnosis based on multi-scale cnn and lstm model. *Journal of Intelligent Manufacturing*.
- Chen, Z., Gryllias, K., and Li, W. (2019). Mechanical fault diagnosis using convolutional neural networks and extreme learning machine. *Mechanical Systems and Signal Processing*, 133, 106272.
- Correa, J.C.J. and Guzman, A.L. (2020). *Mechanical vibrations and condition monitoring*. Elsevier.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- Faceli, K., Lorena, A.C., Gama, J. and de Carvalho, A.C. (2011). *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*, volume 1. LTC, Rio de Janeiro.
- Fayed, H.A. and Atiya, A.F. (2009). A novel template reduction approach for the k-nearest neighbor method. *IEEE Transactions on Neural Networks*, 20(5), 890-896.
- Furnkranz, J., Gamberger, D. and Lavrac, N. (2012). *Foundations of rule learning*. Springer Science & Business Media.
- Hagan, M.T. and Menhaj, M.B. (1994). Training feed-forward networks with the marquardt algorithm. *IEEE transactions on Neural Networks*, 5(6), 989-993.
- Haykin, S. (2010). *Neural Networks and Learning Machines*, 3ed. Pearson Education India.
- Kankar, P., Sharma, S.C. and Harsha, S. (2011). Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with Applications*, 38(3), 1876 - 1886. doi:https://doi.org/10.1016/j.eswa.2010.07. 119. URL <http://www.sciencedirect.com/science/article/pii/S0957417410007475>.
- Lei, Y. (2016). *Intelligent fault diagnosis and remaining useful life prediction of rotating machinery*. Butterworth-Heinemann.
- Lu, S., Qian, G., He, Q., Liu, F., Liu, Y. and Wang, Q. (2020). In situ motor fault diagnosis using enhanced convolutional neural network in an embedded system. *IEEE Sensors Journal*, 20(15), 8287-8296.
- Mobley, R.K. (1999). *Vibration fundamentals*. Elsevier.
- Nayana, B.R. and Geethanjali, P. (2017). Analysis of statistical time-domain features effectiveness in identification of bearing faults from vibration signal. *IEEE Sensors Journal*, 17(17), 5618-5625.

Pearson, K. (1901). On lines and planes of closest t to systems of points in space. The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science, 2(11), 559-572.

Prabhakar, S., Mohanty, A. and Sekhar, A. (2002). Application of discrete wavelet transform for detection of ball bearing race faults. Tribology International, 35(12), 793 - 800. doi:[https://doi.org/10.1016/S0301-679X\(02\)00063-4](https://doi.org/10.1016/S0301-679X(02)00063-4). URL <http://www.sciencedirect.com/science/article/pii/S0301679X02000634>.

Rauber, T.W., de Assis Boldt, F. and Varejão, F.M. (2015). Heterogeneous feature models and feature se-lection applied to bearing fault diagnosis. IEEE Transactions on Industrial Electronics, 62(1), 637-646.

Ribeiro, F., Marins, M., Netto, S. and da Silva, E. (2017). Rotating machinery fault diagnosis using similarity-based models. doi:10.14209/sbrt.2017.133.

Santiago, D.F.d.A. et al. (2004). Diagnostico de falhas em máquinas rotativas utilizando transformada de wavelet e redes neurais artificiais, 2004, Tese de doutorado.

Strang, G. and Nguyen, T. (1996). Wavelet and Filter Banks. Wellesley: Cambridge Press.

Sugiyama, M. (2015). Introduction to statistical machine learning. Morgan Kaufmann.

Tahir, M.M., Khan, A.Q., Iqbal, N., Hussain, A. and Badshah, S. (2017). Enhancing fault classification accuracy of ball bearing using central tendency based time domain features. IEEE Access, 5, 72-83.

Capítulo 4



10.37423/230107086

ROBUST MODEL BASED FAULT DETECTION AND ISOLATION OF A SIX DEGREE OF FREEDOM HELICOPTER

Lázaro F Sanson


Universidade Federal do ABC

Victor Augusto F de Campos

Universidade Federal do ABC

Alain S Potts

Universidade Federal do ABC



Abstract: Helicopters are high cost and safety systems with a strong control system designed to maintain the helicopter performance, stability, and flight qualities. However, there exist faults that negatively affect the helicopter desirable behaviour; therefore, fault detection and isolation must be done to early detect, isolate and eliminate these faults. Because of helicopters are strongly nonlinear systems, and are affected by uncertainties and by external disturbances as wind bursts, robust residuals generation is required to correctly detect and isolate faults in the helicopter actuators and sensors. This paper leads with the robust fault detection and isolation of a six-degree of freedom helicopter benchmark using the disturbance decoupling method and the unknown input observer robust residuals generator. A generalized observer scheme is employed for fault isolation purposes.

Keywords: fault detection and isolation, robust residual generation, disturbance decoupling, unknown input observer, eigenstructure assignment.

1. INTRODUCTION

In the last decades the Fault Detection and Isolation (FDI) methods have increased the interest of researchers in the academic and industry. This is due to the fact that more efficiency, safety, availability and autonomy are required in processes. Frequently, control systems cannot detect behaviours that could lead the process to malfunctions and failures (Isermann, 2006). FDI, as a part of the monitoring and supervision process, allows an early detection and isolation of faults. FDI also helps in the decision making and predictive maintenance (Isermann, 2011), representing an economical saving, and guaranteeing the safety of the process and the environment protection.

A fault is an unpermitted deviation in at least one characteristic, property or parameter of the system from the standard or normal behaviour, as shown in Isermann and Balle (1997). This condition could lead the system to a malfunction or failure. Therefore, faults should be detected, isolated, treated, and eventually eliminated to maintain the system in the normal state of performance. In general, three approaches have been adopted for FDI: Model-based FDI, Knowledge-Based FDI and Data-Driven FDI (Isermann, 2006; Venkatasubramanian et al., 2003c,b,a).

Model-based approach has been developed over the last years. The main issue in this approach is the need of a good model of the system. However, obtaining a good model of the system is not easy. Thus, system identification methods are often used to build an adequate model of the system (Ljung, 1999; Aguirre, 2015).

The major research problem in FDI is the robust residual generation. Residuals are affected by nonlinearities, uncertainty, modelling errors, noise, disturbances, etc. A lot of work in this research field is available. Freddi et al. (2009); Tahraoui et al. (2014); Negash et al. (2016); Chaves et al. (2018); Zhang et al. (2018) are examples of results on robust FDI.

Among the robust FDI methods, Unknown Input Observer (UIO) have been useful in the robust residual generation. There are evidence of UIO applications in many processes such as chemical processes, electrical systems, aircraft and helicopters (Chen and Patton, 1999; Termehchy et al., 2013; Zhang et al., 2016; MA et al., 2018).

Helicopters are aircrafts with a complex dynamics and behaviour. These aircrafts are considered very unstable and relevant research about its modelling and control may be found in Luo et al. (2003); Padfield (2008); Cook (2012); Ren et al. (2012). In order to achieve desirable flight qualities and system stability, helicopters are equipped with sensors and actuators from which a lot of information is

obtained, processed and monitored. That information is useful in designing and applying FDI schemes. Fault detection and isolation of helicopter sensors and actuators have a tremendous impact in economy and safety. The faults occurrence in sensors and actuators can lead to a non-desirable and dangerous situation compromising the helicopter flight qualities and stability, and, in the worst case, a system break-down can arise.

This paper addresses the robust FDI of a six Degree of Freedom (DoF) helicopter using simple Unknown Inputs Observers as robust residuals generators. A Generalized Observer Scheme (GOS) is adopted to implement sensor and actuator faults isolation schemes based on UIOs. A linear model of the helicopter in the state of hover is employed for the FDI system design.

2. HELICOPTER MODEL

Helicopters are high order systems with a strong non- linear dynamics and complex behaviour. The helicopter dynamics in flight can be modelled as the combination of a large number of interacting subsystems. The equations governing this dynamical interaction are obtained from the application of physical laws to the individual components of the helicopter and generally have the form of nonlinear differential equations as (1).

$$\frac{dx}{dt} = f(x, u_c, t) \quad (1)$$

where, $x(t)$ is the state vector, $u_c(t)$ is the control vector and, $f(x, u_c, t)$ is a nonlinear function of the aircraft motion (Padfield, 2008).

This research only considers the special case of a six DoF of the rigid body approximation. The six DoF are the three translational movements and the movements of pitching, yawing and rolling. This case is a suitable one and very employed in helicopter control systems. The state vector comprises the six DoF is:

$$x = [u, w, q, \theta, v, p, \phi, r, \psi]^T \quad (2)$$

where, u , v and w are the translational velocity components, p , q , r the rotational velocity components and, ϕ , θ , ψ the Euler angles.

The nonlinear equations of motion are divided into force (3), moment (4), and attitude (5) equations (Padfield,2008).

$$\begin{aligned}
\dot{u}(t) &= -(wq - vr) + \frac{X}{M_a} - g \sin \theta \\
\dot{v}(t) &= -(ur - wp) + \frac{Y}{M_a} - g \cos \theta \sin \psi \\
\dot{w}(t) &= -(vp - uq) + \frac{Z}{M_a} - g \cos \theta \sin \psi
\end{aligned} \tag{3}$$

$$\begin{aligned}
I_{xx}\dot{p}(t) &= (I_{yy} - I_{zz})qr + I_{xz}(\dot{r} + pq) + L \\
I_{yy}\dot{q}(t) &= (I_{zz} - I_{xx})qr + I_{xz}(r^2 - p^2) + M \\
I_{zz}\dot{r}(t) &= (I_{xx} - I_{yy})qr + I_{xz}(\dot{p} + qr) + N
\end{aligned} \tag{4}$$

$$\begin{aligned}
\dot{\phi}(t) &= p + (q \sin \phi + r \cos \phi) \tan \theta \\
\dot{\theta}(t) &= q \cos \phi - r \sin \phi \\
\dot{\psi}(t) &= \frac{q \sin \phi + r \cos \phi}{\cos \theta}
\end{aligned} \tag{5}$$

where, M_a is the mass of the fuselage, X, Y, Z are the external forces, L, M, N are analytic functions of the disturbed motion variables and their derivatives, and $I_{xx}, I_{yy}, I_{zz}, I_{xz}$, are the fuselage moments of inertia about the reference axes, A nonlinear model is hard to manipulate and difficult to employ in fault detection and diagnosis, since the state-space observer-based methods for robust FDI are generally based on linear models of the system; a linear model of the helicopter system in equations (3), (4), (5) is given. The helicopter here studied is the DRA research Westland Lynx Mk7 and the process of linearization is exposed in Padfield (2008) and Luo et al. (2003). This is a known benchmark aircraft and is widely used in research to calibrate agility standards of future helicopter types. Equation (6) presents the state-space representation of the helicopter linear model.

$$\begin{aligned}
\dot{x}(t) &= Ax(t) + Bu_c(t) \\
y(t) &= Cx(t)
\end{aligned} \tag{6}$$

where, $x = [u \ w \ q \ \theta \ v \ p \ \phi \ r]^T$ and $u_c = [\theta_0 \ \theta_{1s} \ \theta_{1c} \ \theta_{0T}]^T$ θ_0 is the main rotor collective pitch control, $(\theta_{1s}, \theta_{1c})$ are the cyclic collective pitch controls, and θ_{0T} is the tail rotor collective pitch control. The output vector is selected as $y(t) = [q \ \theta \ \phi \ r]^T$.

3. ROBUST MODEL-BASED FAULT DETECTION AND ISOLATION SYSTEM

Nonlinearities, modelling errors, signal noise, disturbances and uncertainty, negatively impact the performance and the reliability of a diagnosis system. Model-based FDI methods require a good mathematical model of the plant in order to make steady-state output error tends to zero. The accuracy of the model is compromised by disturbances and unknown inputs which decrease the sensitivity of residuals to faults and increase the number of false alarms and wrong classifications.

A system can be modelled in the state-space as in equation (7), where $x(t) \in R^n$, $u(t) \in R^r$ and $y(t) \in R^m$. The vector $d(t) \in R^q$ is an unknown input term which is an additive disturbance vector, matrix E is the disturbance distribution matrix.

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu_c(t) + Ed(t) \\ y(t) &= Cx(t) \end{aligned} \quad (7)$$

Disturbance decoupling approach is widely used for robust residual generation (Chen and Patton, 1999; Patton et al., 2013; Simani et al., 2003). The objective of the disturbance decoupling methods is to decouple faults from disturbances and increase the sensitivity of the residuals to faults. In this research, a method from disturbance decoupling approach is employed to achieve robust fault detection and isolation.

3.1 UNKNOWN INPUT OBSERVERS

Unknown input observers are a special kind of observers in which all disturbance signals are considered as unknown inputs to the model of the plant. A formal definition of UIO is shown below.

Definition 1. An unknown input observer is an observer in which the state estimation error vector $e(t)$ approaches zero asymptotically, regardless of the presence of the unknown inputs or disturbances on the system (Chen and Patton, 1999).

A full order observer structure is shown in equation (8), where $z(t) \in R^n$ is the full order observer state vector and $\hat{x}(t) \in R^n$ is the estimated state vector. If matrices F, T, K and H are selected correctly, the full order observer in equation (8) is converted in an UIO and disturbance decoupling is achieved.

$$\begin{aligned}\dot{z}(t) &= Fz(t) + TBu_c(t) + Ky(t) \\ \hat{x}(t) &= z(t) + Hy(t)\end{aligned}\quad (8)$$

When the observer in equation (8) is applied to the system in equation (7), the state estimation error is governed by equation (9).

$$\begin{aligned}\dot{e}(t) = \dot{x}(t) - \dot{\hat{x}}(t) &= (A - HCA - K_1C)e(t) \\ &+ [F - (A - HCA - K_1C)]z(t) \\ &+ [K_2 - (A - HCA - K_1C)H]y(t) \\ &+ [T - (I - HC)]Bu(t) + (HC - I)Ed(t)\end{aligned}\quad (9)$$

In order to make:

$$\dot{e}(t) = Fe(t) \quad (10)$$

the conditions in equation (11) must be reached.

$$\begin{aligned}(HC - I)E &= 0 \\ T &= I - HC \\ F &= A - HCA - K_1C \\ K_2 &= FH \\ K &= K_1 + K_2\end{aligned}\quad (11)$$

Matrix F must be a stable matrix, i.e. the eigenvalues of F lie in the open left complex half-plane. Therefore, e(t) will approach asymptotically to zero, so the full order observer in equation (8) is an unknown input observer of the system in equation (7). Now, the necessary and sufficient conditions for the existence of the unknown input observer is given by Theorem 1

Theorem 1. Necessary and sufficient conditions for the existence of unknown input observer:

$$(1) \text{ rank}(CE) = \text{rank}(E)$$

$$(2) (C, A_1) \text{ is a detectable pair, where}$$

$$A_1 = A - E[(CE)^T CE]^{-1}(CE)^T CA$$

The proof of this theorem will be omitted but it is shown in Chen and Patton (1999). If the first condition of theorem 1 is achieved, then a solution for conditions in equation (11) is given in equation (12).

$$H = E[(CE)^T CE]^{-1}CE^T \quad (12)$$

3.2 ROBUST FAULT DETECTION AND ISOLATION SCHEMES BASED ON UIOS

The fault isolation procedure is the determination of the sensor or the actuator in which a fault has occurred. The strategy here is to design a structured residual set which is sensitive to a group of faults and insensitive to others. The ideal situation is to make each residual sensitive to a particular fault. This ideal situation is hard to achieve; even when it is possible. Usually, the design freedom available will be exhausted and no other improvements will be performed including robustness. An accepted criterion is to design residuals to be sensitive to all faults except to faults in one sensor or actuator.

The system in equation (7) with faults in actuators and sensors could be modelled in state space as in equation (13). Vectors $f_a(t) \in \mathbb{R}^r$ and $f_s(t) \in \mathbb{R}^m$ are the actuator and sensor faults respectively and matrices $L_1 = B$ and $L_2 = Im$ are the fault distribution matrices.

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu_c(t) + Ed(t) + L_1 f_a(t) \\ y(t) &= Cx(t) + L_2 f_s(t) \end{aligned} \quad (13)$$

If the UIO in equation (8) is applied to the system in equation (13) the estimation error ($\dot{e}(t) = Fe(t)$) and the residual will be:

$$\begin{aligned} \dot{e}(t) &= \dot{x}(t) - \hat{\dot{x}}(t) = (A_1 - K_1 C)e(t) \\ &\quad + TBf_a(t) - K_1 f_s(t) - H\dot{f}_s(t) \\ r(t) &= Ce(t) + f_s(t) \end{aligned} \quad (14)$$

From equation (14) a fault in the i th actuator will affect the residual if and only if $Tb_{i\text{th}} \neq 0$, $b_{i\text{th}}$ is the i th column of matrix B . In the same way, if a fault occurs in the i th sensor, the residual must be sensitive to this fault to detect it. However, $f_s(t)$ has a direct effect on the residual and this condition is normally satisfied.

The fault isolation schemes based on UIOs generalized observer schemes are well explained in Chen and Patton (1999). The implementation is summarized below.

3.3 ROBUST ACTUATOR FAULTS ISOLATION SCHEME

For actuator fault isolation scheme it is assumed that there is no faults in sensors. Then system in equation (13) can be described as:

$$\begin{aligned}\dot{x}(t) &= Ax(t) + B^i u_c^i(t) + B^i f_a^i(t) + E^i d^i(t) \\ y(t) &= Cx(t)\end{aligned}\quad (15)$$

where, $B^i \in R^{n \times (r-1)}$ is the matrix B by deleting the i_{th} column, $u^i \in R^{r-1}$ is the input vector by deleting the i_{th} input, f_a^i is the fault vector by deleting the fault in the i_{th} actuator f_{ai} , $E^i = [E \ b_{i_{th}}]$ and $d^i(t) = \begin{bmatrix} d_i(t) \\ u_{c_i}(t) + f_{ai} \end{bmatrix}$, where $u_i(t)$ is the i_{th} system input, for $i = 1, 2, \dots, r$. The r_{th} UIO residual generator is constructed as in equation (16). The residuals generated from the i_{th} UIO are sensitive to all faults except the i_{th} actuator fault.

$$\begin{aligned}\dot{z}^i(t) &= F^i z^i(t) + T^i B^i u_c^i(t) + K^i y(t) \\ r^i(t) &= (I - CH^i)y(t) - Cz^i(t), \\ i &= 1, 2, \dots, r\end{aligned}\quad (16)$$

3.4 ROBUST SENSOR FAULTS ISOLATION SCHEME

In the case of sensor faults isolation scheme, it is assumed that no faults occur in actuators. The system in equation (13) is described as:

$$\begin{aligned}\dot{x}(t) &= Ax(t) + Bu_c(t) + Ed(t) \\ y^j(t) &= C^j x(t) + f_s^j(t) \\ y_j(t) &= c_j x(t) + f_{sj}(t), \\ j &= 1, 2, \dots, m\end{aligned}\quad (17)$$

where $c_j \in R^{(1 \times n)}$ is the j_{th} row of matrix C, $C^j \in R^{(m-1 \times n)}$ is obtained from the matrix C by deleting c_j , y_j is the j_{th} component of y , and $y^j \in R^{(m-1)}$ is obtained from y by deleting y_j .

The m_{th} UIO residual generator are constructed as in equation (18). The residuals generated from the j_{th} UIO are sensitive to all faults except the j_{th} sensor fault.

$$\begin{aligned}
\dot{z}^j(t) &= F^j z^j(t) + T^j B u_c(t) + K^j y^j(t) \\
r^j(t) &= (I - C^j H^j) y^j(t) - C^j z^j(t), \\
j &= 1, 2, \dots, m
\end{aligned} \tag{18}$$

4. RESULTS

The linear model of the helicopter presented in equation (6) is used in the design of a FDI system based on UIOs following the theoretical basis established in the last sections. The helicopter hover operating point is considered, i.e. flight at 0m/s. Matrices A and B are obtained from the first-order partial derivatives of function $f(x, u, t)$ with respect to the state vector and the input vector respectively as shown in Padfield (2008). Matrices A, B, and C are presented in equations (19), (20), and (21) respectively.

$$A = \begin{bmatrix} -0.0199 & 0.0215 & 0.6674 & -9.7837 \\ 0.0237 & -0.3108 & 0.0134 & -0.7215 \\ 0.0468 & 0.0055 & -1.8954 & 0 \\ 0 & 0 & 0.9985 & 0 \\ 0.0207 & 0.0002 & -0.1609 & 0.0380 \\ 0.3397 & 0.0236 & -2.6449 & 0 \\ 0 & 0 & -0.0039 & 0 \\ 0.0609 & 0.0089 & -0.4766 & 0 \end{bmatrix} \tag{19}$$

$$\begin{bmatrix} -0.0205 & -0.1600 & 0 & 0 \\ -0.0028 & -0.0054 & 0.5208 & 0 \\ 0.0588 & 0.4562 & 0 & 0 \\ 0 & 0 & 0 & 0.0532 \\ -0.0351 & -0.6840 & 9.7697 & 0.0995 \\ -0.2715 & -10.9759 & 0 & -0.0203 \\ 0 & 1.0000 & 0 & 0.0737 \\ -0.0137 & -1.9367 & 0 & -0.274 \end{bmatrix}$$

$$B = \begin{bmatrix} 6.9417 & -9.2860 & 2.0164 & 0 \\ -93.9179 & -0.0020 & -0.0003 & 0 \\ 0.9554 & 26.4011 & -5.7326 & 0 \\ 0 & 0 & 0 & 0 \\ -0.3563 & -2.0164 & -9.2862 & 3.6770 \\ 7.0476 & -33.2120 & -152.9537 & -0.7358 \\ 0 & 0 & 0 & 0 \\ 17.3054 & -5.9909 & -27.5911 & -9.9111 \end{bmatrix} \tag{20}$$

$$C = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \tag{21}$$

Uncertainty in helicopter hover operating point is simulated as a random input variable, representing the uncertainties in the flapping blades. It is considered a random variable with zero mean and a relatively high covariance of 5% to represent the aerodynamic and atmospheric parameters. The unknown input uncertainty signal is shown in figure 1.




Figure 1. Helicopter hover state flapping blades uncertainty simulation.

Two Unknown Input Observers banks are designed. Each bank has four UIOs and consequently, four sets of robust residuals are available. One bank of observers is dedicated to detect and isolate faults in the helicopter actuators. The other bank is dedicated to detect and isolate faults in the helicopter sensors. It is assumed that two faults do not exist at the same time, that is a realistic assumption because the probability of the occurrence of two faults at the same instance of time is almost zero.

A fault in the main rotor collective pitch actuator is simulated as a step signal of magnitude 0.5. A simple Luenberger observer-based residual generator is designed. The residuals obtained are sensitive to both the fault and the uncertainty as shown in figure 2.

On the other hand, robust residuals are obtained by applying the proposed methodology. They are shown in figures 3, 4, 5, and 6. In this case, residuals are sensitive to the fault in the main rotor collective actuator and insensitive to the uncertainty. Due to the isolation scheme applied, it is possible to determine that the fault has occurred in this actuator by analyzing the residuals. The residuals

generated by the UIO corresponding to the main rotor collective actuator, are insensitive to the fault as




Figure 2. Non robust residuals for a fault in the main rotor collective pitch actuator.

shown in figure 3. Nevertheless, the other residuals are sensitive to the fault.




Figure 3. Robust residuals generated from the first UIO of the input bank of observers, which excludes the main rotor collective control input.

For the detection and isolation of faults in sensors, a fault in the rotational velocity respect to axis - z (r) sensor is simulated. The fault is considered a step signal of magnitude 2.0. Following the same methodology employed in the main rotor collective pitch fault situation, a simple Luenberger observer is designed and non-robust residuals are obtained see figure 7.

When a fault occurs in the rotational velocity sensor, the resultant residuals obtained from the second bank of observers are robust to the system uncertainty and sensitive to the sensor fault. Figures 8, 9, 10, and 11 present the robust residuals when this kind of fault occurs. As a result of the isolation scheme applied, the residuals generated by the UIO correspondent to the rotational velocity sensor, are insensitive to that fault, see figure 11. The other residuals are all sensitive. Then, it is possible to isolate the fault and determine in which sensor the fault has occurred.




Figure 4. Robust residuals generated from the second UIO of the input bank of observers, which excludes the lateral cyclic control input.




Figure 5. Robust residuals generated from the third UIO of the input bank of observers, which excludes the longitudinal cyclic control input




Figure 6. Robust residuals generated from the fourth UIO of the input bank of observers, which excludes the tail rotor collective control input




Figure 7. Non robust residuals for a fault in the rotational velocity sensor respect to axis -z.




Figure 8. Robust residuals generated from the first UIO of the output bank of observers, which excludes the rotational velocity in axis -y sensor output.




Figure 9. Robust residuals generated from the second UIO of the output bank of observers, which excludes the θ angle sensor output.

5. CONCLUSIONS

Unknown input observers method allows decoupling disturbances from fault residuals increasing the sensitivity of




Figure 10. Robust residuals generated from the third UIO of the output bank of observers, which excludes the ϕ angle sensor output.




Figure 11. Robust residuals generated from the first UIO of the output bank of observers, which excludes the rotational velocity in axis -z sensor output.

the residuals to faults and reducing the effect of unknown inputs on them. This method could be employed to detect faults in actuators such as in sensors. Applying isolation schemes based on UIOs, faults can be isolated and located. This method could be applied to systems where a good mathematical model is provided.

Despite linearization error, uncertainty, noise and disturbances affecting the helicopter behaviour, the UIO method applied to the aircraft system decouples this unknown signals and robust residuals are generated. From this residuals, fault detection and isolation can be performed leading to condition maintenance and predictive maintenance which have a tremendous impact in economic saving, safety, quality, autonomy and availability.

Fault tolerant control system can be implemented by using this FDI system for online reconfiguration of the control law. Hence the helicopter flight qualities will be guaranteed and the helicopter performance will be maintained despite of the faults. The interaction between robust model-based FDI and Fault tolerant control is under research.

REFERENCES

- Aguirre, L. (2015). *Introdução á Identificação de Sistemas técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. Editora UFMG.
- Chaves, E.R.Q., Maitelli, A.L., and Lopes, K.R. (2018). Unknown input observer-based robust sensor fault estimation in discrete-time takagi-sugeno systems. In *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, 2475–2480.
- Chen, J. and Patton, R.J. (1999). *Robust Model-Based Fault Diagnosis for Dynamic Systems* - Jie Chen, R.J. Patton. Springer.
- Cook, M.V. (2012). *Flight dynamics principles: a lin- ear systems approach to aircraft stability and control*. Butterworth-Heinemann.
- Freddi, A., Longhi, S., and Monteriaú, A. (2009). A model-based fault diagnosis system for unmanned aerial vehicles. *IFAC Proceedings Volumes*, 42(8), 71 – 76. 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes.
- Isermann, R. (2006). *Fault-diagnosis systems: An intro- duction from fault detection to fault tolerance*. Springer Berlin Heidelberg.
- Isermann, R. (2011). *Fault-Diagnosis Applications*. Springer Berlin Heidelberg.
- Isermann, R. and Balle, P. (1997). Trends in the appli- cation of model-based fault detection and diagnosis of technical processes. *Control engineering practice*, 5(5), 709–719.
- Ljung, L. (1999). *System Identification: Theory for the User*. Prentice Hall information and system sciences series. Prentice Hall PTR.
- Luo, C.C., Liu, R.F., Yang, C.D., and Chang, Y.H. (2003).
- Helicopter Hinf control design with robust flying qual- ity. *Aerospace Science and Technology*, 7, 159–169.
- MA, Z., Wang, S., Shi, J., Li, T., and Wang, X. (2018).
- Fault diagnosis of an intelligent hydraulic pump based on a nonlinear unknown input observer. *Chinese Journal of Aeronautics*, 31(2), 385 – 394.
- Negash, L., Kim, S.H., and Choi, H.L. (2016). An eigenstructure assignment embedded unknown input ob- serve approach for actuator fault detection in quadro- tor dynamics. *IFAC-PapersOnLine*, 49(17), 426 –431. 20th IFAC Symposium on Automatic Control in AerospaceACA 2016.
- Padfield, G.D. (2008). *Helicopter flight dynamics*. John Wiley & Sons, Ltd.
- Patton, R.J., Frank, P.M., and Clark, R.N. (eds.) (2013). *Issues of fault diagnosis for dynamic systems*. Springer Science & Business Media.

Ren, B., Ge, S.S., Chen, C., Fua, C.H., and Lee, T.H. (2012). Modeling, control and coordination of helicopter systems. Springer Science & Business Media.

Simani, S., Fantuzzi, C., and Patton, R.J. (2003). Model- based Fault Diagnosis in Dynamic Systems Using Iden- tification Techniques. Advances in Industrial Control. Springer London, London.

Tahraoui, S., Meghebbar, A., and Boubekeur, D. (2014). Generation of robust residuals based on unknown input observers with optimal approximate decoupling. In 2014 International Conference on Electrical Sciences and Technologies in Maghreb, CISTEM 2014. Institute of Electrical and Electronics Engineers Inc.

Termehchy, A., Afshar, A., and Javidsharifi, M. (2013). A novel design of unknown input observer for fault diagnosis in the tennessee-eastman process system to solve non-minimum phase problem. In 2013 IEEE In- ternational Conference on Smart Instrumentation, Mea- surement and Applications (ICSIMA), 1–6.

Venkatasubramanian, V., Rengaswamy, R., and Kavuri,

S.N. (2003a). A review of process fault detection and diagnosis part II: Qualitative models and search strategies. Computers and Chemical Engineering, 27(3), 313–326.

Venkatasubramanian, V., Rengaswamy, R., Yin, K., and Kavuri, S.N. (2003b). A review of fault detection and diagnosis. Part III: Process history based methods. Computers and Chemical Engineering, 27, 327–346.

Venkatasubramanian, V., Rengaswamy, R., Yin, K., and Kavuri, S.N. (2003c). A review of process fault detection and diagnosis part I. Computers & Chemical Engineer- ing, 27(3), 293–311.

Zhang, K., Jiang, B., and Cocquempot, V. (2016). Fuzzy unknown input observer-based robust fault estimation design for discrete-time fuzzy systems. Signal Process- ing, 128, 40 – 47.

Zhang, K., Jiang, B., Shi, P., and Cocquempot, V. (2018). Observer-Based Fault Estimation Techniques, volume 127 of Studies in Systems, Decision and Control. Springer International Publishing

Capítulo 5



10.37423/230107087


FORMAL REQUIREMENTS SPECIFICATION FOR MICROGRID BASED IN ARCHITECTURE IEC61850

Miguel Angel Orellana Postigo

Universidade do Estado do Amazonas - UEA

José Reinaldo Silva

Universidade de São Paulo - USP



Abstract: Smart Grid (SG) systems are considered a sustainable alternative to power supply problems all over the world. SG systems are open, distributed and heterogeneous, what raises a huge demand over its design process. At the present, SG projects are usually done by applying deductive methods, where requirement- specifications do not reach a complete model. On the other hand, considering the importance of the requirements phase, it is necessary to provide methods, tools, and concepts to better characterize, understand and specify the application domain of SG systems. This work proposes the introduction of a formal requirements analysis in the SG life cycle that fits IEC61850 architecture. Requirements would be represented in a goal oriented approach (GORE) specifically using visual diagrams based on KAOS method that will be transformed in a extended Petri Nets representation, which enables to manage the modes of operation of a microgrid. Practical results are shown through an example showing the application of GORE methodology and Petri Nets modeling with the corresponding analysis to fit specific requirements associated to microgrid for the Amazon region.

Keywords: Microgrids, Architecture IEC 61850, Petri Nets, Formal modeling, Gore methods.

1 INTRODUCTION

Electric power is key issue improve life quality. However, according to (Brazilian Institute of Geography and Statistics, 2018), in 2010, approximately 729 thousand Brazilian families lacks any type of electrical energy source.

Thus, the implementation of SG systems with renewable generation has proven to be a feasible alternative to meet power supply needs, specially if based on the integration of different sources in alternative architectures for sustainable distributed generation.

SG systems inherit some complexities from heterogeneous, open and distributed systems (Falcão, 2010). In addition, design and application computer environments are disjointed tackling different phases separately and keeping knowledge from each approach departed, with little or no interaction.

A recent alternative approach to SG systems design is based on use of reference model architectures, as the IEC 61850. This model architecture facilitates the design of automated microgrid systems and is currently being used by many researchers and designers of this area.

Actually, introducing a requirements phase in the life cycle of SG systems is a novelty. Deductive methods are used instead, where the problem is represented by a model, which is analyzed directly to provide a solution that could be verified and tested.

In the academy the systemic approach is more popular as it is shown in the literature:

- Lu et al. (Lu et al., 2014), proposed a microgrid strategic control operation, which analyzes each composite device looking for contradictions about the rapid switching in operation mode or some slowness in the communication with the system management. The proposed control architecture is based on IEC 61850 using adaptive control;
- Deng (Deng et al., 2015) it proposes to improve a plug and play microgrid function each time a new source or equipment is inserted in the system, with different information protocols. He also presents a solution based on IEC 61850 with the extra function "plug and play".
- Ustun et al. (Ustun et al., 2012) developed a protection system to communicate with and monitor microgrids in order to update relay failure currents according to the variations in the system. This author also presents a model based on IEC61850 and IEC61850-7-420 communication standards.

In this work, we present a purpose for a method to generate a formal model to analyze re- quirements elicited by a goal oriented approach and represented in KAOS for microgrid systems based on the architecture IEC 61850.

The advantage of the proposed method is the systematic way to obtain Petri Nets as a formal model that can represent the dynamic of the au- tomated distributed system. In fact the KAOS method also generate a formalism in LTL (Linear Time Logic) and that could be used to analysis (Van Lamsweerde, 2009). However, as any for- malism based on logic and automata, LTL could not represent a distributed system in a compact form. To do that a product of different represen- tations should be used.

The Petri Net representation model can also support property analysis to be used on the re- quirements model.

In the following sections the method based on the reference model IEC 61850 is described and its application to microgrids is illustrated.

2 CONCEPTUAL DESCRIPTION OF THE METHOD

A conceptual description of the method is depicted in Figure 1.




Figure 1: Method owchart

In the first stage, is defined a scenario, in which the requirements for its operation are first surveyed using the IEC 61850 standard as a ref- erence. Thus, to execute the requirements sur- vey, the operational characteristics, such as forms of energy production, environmental restrictions, and so on, are analyzed. In fact, this is one of the more complicated steps, since much of the infor- mation may not be available.

In the second step, the requirements of the microgrid are developed, considering the inherent complexity of the SG systems, in this step the system of IEC 61850 is used for the requirements specification. Therefore, the operation of the mi- crogrid follows the recommendations of IEC 61850 standard.

In the third step requirements will be formalized using the GORE (Goal Oriented Requirement Engineering) method, specifically the KAOS tool. The use of this method introduces a more direct approach, synthesizing functional and non functional requirements aspects, and using the reference model to check the minimal topics to turn on a microgrid service integrating a more general dynamic energy ecosystem.

The fourth step is to model integrated automation in Petri Net. A Petri Net model will be synthesized from the requirement model represented in KAOS diagrams obtained in the previous step. Therefore, KAOS diagrams will be translated to a Petri Nets through a transfer algorithm called ReKPlan (Silva and Silva, 2015).

The main idea is to rely on the reading of Smart Electronic Devices (IDE's) to feed the developed Petri net which could reproduce the dynamic of the microgrid operation using a system of systems approach.

The final step is validation, through the analysis of the behavioral properties and performance evaluation of the GHENeSys network, aims, to design a control solution for microgrid, considering the particularity and constraints of the Amazon region.

3 THE PROPOSED APPROACH

The proposed method combines a new approach to Requirements Engineering based on objectives, with the reference model approach frequently used in power systems design. will be applied to microgrid, in which the geographic characteristics, environmental and technical restrictions should be considered.

3.1 MICROGRID SYSTEM

A microgrid can be considered as a low voltage distribution network and interconnected to the utility grid through a common coupling point (PCC). A typical microgrid system consists of a set of components, which include Distributed Energy Resources (DERs), battery energy storage system (BESS), a computerized control to switch among different energy sources and optimize energy supply, and so forth. Therefore, a microgrid can be characterized as an automatized flexible service system.

The characteristics and dynamics regarding DERs operation present a special challenge about the control and operation of the network. Depending on the characteristics of (DERs) and BESS systems

within a microgrid, the desired power management system may be significantly different from a conventional power electric system.

A typical microgrid runs in two operating modes (Asmus, 2010): connected network or normal operation. In this first scenario, the microgrid is connected to the main energy distribution resources (DER). In stand-by or isolated mode this scenario happens when some abnormal fault or circumstance occurs in the main network and the microgrid must supply the loads (at least the essential loads) with only the DER.

When the microgrid has only renewable energy sources, additional transition modes are needed to synchronize distributed generation (DG) with and main source or to provide energy locally without the main source. In addition, when demand-response programs are activated, it is considered as another operation mode which combines renewable and main energy source.

Thus, based on the context of the IEC 61850 standard, the DER's were grouped into programmable DER's (DER-P) and non-programmable DER's (DER-NP). The battery power storage system (BESS) and combined heat and power (CHP) are part of the DER-P (Deng et al., 2015). Renewable energy sources such as PV and WP belong to the DER-NP, due to their uncertainty of energy generation, and randomness in energy production, affected by natural factors, so the central management system will be responsible for the reconfiguration of DER's.




Figure 2: Proposed scenario for the microgrid

The microgrid system, the object of study in

this work, comprises two parts: the information system and the power system, as shown in Figure 3. Both parts should be developed using as requirements the reference model included in the standard architecture IEC 61850 which we present succinctly in the next section.

3.2 IEC 61850

The IEC 61850 architecture began to be developed in 1994 by IEEE, UCA, and IEC, technical committee 57. The purpose of IEC 61850 is to specify requirements and provide a framework for achieving interoperability between intelligent electronic devices (IED's). In 2005, all parts of the standard have been published as official IEC standard. In 2010, the United States National Institute of Standards and Technologies (NIST) recognized IEC 61850 as one of the key facilitators for SG implementation, emerging as a standard for future SG implementations (Li, 2014).




Figure 3: Architecture Microgrid based IEC 61850

Initially, this standard was designed with the objective of providing protection and promoting the automation of substations. Currently, there are already additional information models defined for domains, hydroelectric plants, wind power plants, microgrids and others.

One of the advantages of the IEC 61850 standard is its extensibility characteristic, resulting from the independence of communication and application, specifying services and objects. It allows to design applications in an independent way of specific protocols. Consequently, the data objects defined in the standard can be applied in several communication solutions without having to modify the models.

Moreover, lots of the critical processes of a microgrid, when related to centralized control, suppose a decrease in some capacities and functionalities of the microgrid.

Therefore, direct communication between devices provides to microgrids advanced control capabilities and reduces the amount of information circulating across the network.

The choice of the IEC 61850 standard in this work is due to the fact that this standard has an architecture that allows microgrids automation, through object-oriented tools that allow standardization of the system communication, as well as to fulfill the requirements of interoperability and extensibility between equipment from manufacturers and legacy generation systems in the applications of microgrids (Wen et al., 2014).

On the other hand, IEC 61850 aims to implement protocols with open standards, with an architecture that performs a fast and effective control of microgrid operation modes.

It is recognized for academy and practitioner communities that the automation process based on IEC 61850 standard allows a reduction of project resources, time, and consequently financial costs.

3.3 REQUIREMENTS SPECIFICATION IN KAOS

In this work, a tool called Objectiver (Objectiver, 2015) is utilized to model requirements in goal-oriented KAOS diagrams, that consider relations among user agents and the system environment covering different scenarios (Graa et al., 2012).

Requirements are represented together with IEC 61850 reference architecture (as is done when reference models are used) resulting in the KAOS model shown in Figure 4. It can be observed analyzing the KAOS model that the IDE's of the microgrid, based on the IEC 61850 Architecture, ended up being agents in the KAOS model.

Table 1 describes the requirements corresponding to the operating dynamics based on the IEC 61850 standard.

3.4 TRANSFORMING REQUIREMENTS IN PETRI NETS

From the developed KAOS model, a Petri Net is synthesized by using a transference algorithm proposed by (Silva and Silva, 2015). The Petri Net used here is a Unified model, that is, a modeling environment that implements the standard ISO/IEC 15909 including basic Place/Transitions nets up to High Level nets and some extensions. Some basic elements used in GHENeSys are illustrated in Figure 6. Similarly, Figure 5 illustrates how basic elements of KAOS model are translated into GHENeSys network and Figure 7 shows how AND/OR refinement of goal-oriented model is translated

into structural components. A key operation appears when the microgrid is connected to the main grid sharing excedent energy generated in the local grid with the general (electric) energy provider.

The Petri net model is obtained by the RekPlan (Engineering Requirement for Planning Problems) tool(Martinez Silva, 2016), which automatically transforms KAOS diagrams into Petri Nets. The obtained Petri Nets is suitable to simulate the proper mode of operation, depending on the reading of the IDE's responsible for collecting the microgrid information.

Petri Net was adopted here to model the dynamic of the automated grid system and the information flow associated with the behavior of the

Table 1: Operating requirements of microgrid based on IEC 610850.

Requirements	Description
Grid mode connected	Normal operation happens when the microgrid is connected to the main grid and distributed energies (DER)
Autonomous Mode	Isolated operation occurs whenever an abnormal fault or circumstance occurs in the main grid and the microgrid is supposed supply the loads (at least the most sensitive loads) with the DER only.
Synchronization Mode	When the microgrid has only renewable energy, additional transition modes are required to synchronize distributed generation (DG) with and without the main grid. In addition, when demand-response programs are active it is considered as another mode of operation that is part of the connected grid mode.
Fault Mode	Each time the main PCC interconnect switch closes the microgrid, it accesses the mains and switches to the connected grid mode and, when the PCC switch is open, the microgrid is separated from the service grid and switches to stand-alone mode.

microgrid system, i.e., the allow the analysis of re- lationship, organization, and communication between the components of the microgrid.

Another important issue of using Petri Nets is the possibility to analyze and validate require- ments, a process normally neglected in old fashion systems design and regarded as a key issue for au- tomated microgrid design.

3.5 VALIDATION OF REQUIREMENTS IN PETRI NETS

The whole process depicted here is based on the hypothesis that requirements should be formalized before turning out to be specifications. Therefore, requirements are introduced as semi-formal disciplined statements (since we are using reference models) and should be analyzed formally (using Linear Temporal Logic or Petri Nets) and fur- ther validated using simulation and property anal-




Figure 4: KAOS diagram of the microgrid system

Element	Name
	Box
	Activity
	Pseudo-Box
	Arc
	Enabled Arc
	Macro-Box
	Macro-Activity

Figure 5: GHENeSys basic Elements

ysis. That is very important to an automatic system that interacts with electric energy distribution system. Petri Net is used instead of LTL because it is suitable to deal with distributed systems, which is the case of the microgrid and of the overall energy providing system.

Thus the resultant Petri net can indicate the operating modes of the microgrid according to the readings of the IDE's. In the Petri net, the inboxes (or input places) represent the IDE's.

By considering analysis techniques regarding the generated reachability tree, it can be concluded that:

- The Petri Net obtained is deadlock-free
- All markings are reachable from the initial

marking (lifeless property), which also indicates that the local grid composes a proper




Figure 6: Equivalence for transformation from KAOS to GHENeSys

system with the remaining energy distribu- tion system.

- The net is finite (as expected) because the reachability tree is finite too. That also implies the system is closed and controllable.




Figure 7: GHENeSys Network

4. APPLICATION SCENARIO

In this section, the proposed method is described, using as a case study the microgrid for communities in the county side of a Brazilian province called Amazonas, which has proper geographical characteristics (it includes the largest tropical forest of the world), as well as environmental technical restrictions.

The first step of the proposed method is to define the scenario, using the IEC 61850 model as a reference. Depending on the locality of Amazonas community we should have a different spectrum of energy sources available (or admissible), such as Biomass, Biogas, solar, hydraulics, wood, natural gas, oil, besides the electrical energy distribution.

In the second step requirements are developed and the microgrid is modeled, in the scope of a system power generation through CHP systems, and BESS, the supply of electricity in low voltage through the energy concessionaire.

Another characteristic of the system is that the DER's would be able to maintain, at the peak of its production, only critical loads. The DER's and diesel generators together must fulfill the energy needs of the community in situations of medium or low production of renewable energies.

In the third step, goal-driven requirements are synthesized, based on the IEC 61850 reference architecture, and considering the geographic, environmental, and technical restrictions, we obtain as results the KAOS model shown in Figure 4.

In the fourth step, a Petri Net is derived from a KAOS model, modeling the automation of the microgrid system operation, as shown in Figure 5.

In this step, when analyzing the readings of the IDE's, the Petri nets developed should switch the most appropriate mode of operation for the microgrid system.

The final step is the validation, through the analysis of behavioral properties and performance evaluation, which support the design of a control solution to the microgrid, considering the particularity and constraints of the Amazon region.

In the Figure 7, it shows the working dynamic of microgrid modeled in Petri Net. The control of the microgrid operation is in charge of receiving the control signals through the IDE's, processing and transmitting the signals for the system. Thus, once the controller receives a signal from the IDE's, it

will enable the triggering of the transition bypassing the system to the Stand-By state, in the autonomous mode.

From the control processing, that is, the evaluation of operations (Available BESS), (Available DG) the system can change to operate with BESS or DG activating or deactivating controllable transitions. Also available from this Stand-By state are two switching possibilities of the Available Utility Grid Supply (U), and Utility Grid Disturbance (UD) control locations which may lead to a possible change or return of the operating state to Synchronization Operation.

Each time the controller detects the PCC circuit breaker the microgrid accesses the grid and switches Grid-Connected mode, the power supply initially happens through the state called Utility, depending on the load demand can switch to the Utility + BESS states, Utility + DG or Utility + BESS + DG.

When the PCC switch is open, the microgrid is disconnected from the Utility services network and switches to Autonomous-Mode, that is, a situation where the system is in isolated mode, in which the power supply is through the DERs, BESS and CHP, the switching will depend on the load.

5 CONCLUSIONS

The present work is based on the hypothesis that distributed power supply should be diversified and based on harmonic deal with small consumer unities that can also provide energy by local grids (microgrids). Such local facilities should be from different arrangements of renewable energy sources and conventional (electric) energy power supply.

To achieve good performance these systems should be automated and therefore its design should be no longer based on good practices and experience based on intuitive and/or tacit knowledge. Automation would also insert autonomy in control systems which could be a source of problems instead of an advance, if not well managed.

Thus, the proposal presented here combines methods already used and reference architectures with modern goal-oriented methods of requirements modeling, specification and analysis to provide reliable design of microgrids, capable to deal with simple urban problems up to more sophisticated environmental restricted cases, such as the one of small communities in the jungle.

Besides using Goal-oriented Requirements Engineering, the proposal introduces requirements analysis and (formal) validation based on Petri Nets. Preliminary results presented in this work were

obtained using classic Place / Transition nets, in which the drives of operation modes depend on the sensing performed by IDE's.

Future steps in this research will look into the possibility of using Petri Nets to model the probabilistic type information that runs through the microgrid. In addition to being an extension of the current job, new features can be introduced, such as time. Besides, the microgrid arrangement supposed here follows the recent tendency to have energy supply as a Service System of Systems open space new ambitious architectures (Silva and Nof, 2015).

The results of this work indicate that it is possible to develop a method for formal specification of requirement which enables to manage the modes of operation of a microgrid based on the IEC 61850 architecture, the use of the GORE methodology and Petri Nets modeling, which allowed to propose a model for the automation of operation of the microgrid system, taking into account adaptations and restrictions.

ACKNOWLEDGEMENTS

Thanks to the University of Amazon State (UEA), and University of São Paulo (USP) for the support and collaboration in the elaboration of this work.

REFERENCES

- Asmus, P. (2010). Microgrids, virtual power plants and our distributed energy future, *The Electricity Journal* 23(10): 72–82. Brazilian Institute of Geography and Statistics
- (2018). <https://ww2.ibge.gov.br/home/>. Accessed: 2018-02-26.
- Deng, W., Pei, W., Shen, Z., Zhao, Z. and Qu, H. (2015). Adaptive micro-grid operation based on IEC 61850, *Energies* 8(5): 4455–4475.
- Falcão, D. M. (2010). Integração de tecnologias para viabilização da smart grid, III Simposio Brasileiro de Sistemas Elétricos pp. 1–5.
- Graa, M., Cuppens-Boulahia, N., Autrel, F., Azkia, H., Cuppens, F., Coatrieux, G., Cavalli, A. and Mammar, A. (2012). Using requirements engineering in an automatic security policy derivation process, *Data Privacy Management and Autonomous Spontaneous Security*, Springer, pp. 155–172.
- Li, Y. W. (2014). Smart grid and its application, *Advanced Materials Research*, Vol. 986, Trans Tech Publ, pp. 533–536.
- Lu, W., Zhao, Y., Li, W. and Du, H. (2014). Design and application of microgrid operation control system based on IEC 61850, *Journal of Modern Power Systems and Clean Energy* 3(2): 256–263.
- Martinez Silva, J. (2016). Modelagem e análise de conhecimento para planejamento automático: uma abordagem baseada em GORE e redes de Petri., PhD thesis, Universidade de São Paulo.
- Silva, J. M. and Silva, J. R. (2015). Combining chaos and genesys in the requirement and analysis of service manufacturing, *IFAC-PapersOnLine* 48(3): 1634–1639.
- Silva, J. and Nof, S. (2015). Manufacturing service: From e-work and service-oriented approach towards a product-service architecture, *IFAC Papers-on-line* 48: 1628–1633.
- Ustun, T. S., Ozansoy, C. and Zayegh, A. (2012). Modeling of a centralized microgrid protection system and distributed energy resources according to IEC 61850-7-420, *IEEE Transactions on Power Systems* 27(3): 1560–1567.
- Van Lamsweerde, A. (2009). Requirements engineering: From system goals to UML models to software, Vol. 10, Chichester, UK: John Wiley & Sons.
- Wen, L., Yangdong, Z., Weixing, L. and Hongwei, D. (2014). Design and application of microgrid operation control system based on IEC 61850, *Journal of Modern Power Systems and Clean Energy* 2(3): 256–263.

Capítulo 6



10.37423/230107088


MICROGRID SYSTEM DESIGN BASED ON MODEL BASED SYSTEMS ENGINEERING AND GOAL- ORIENTED REQUIREMENTS ENGINEERING

Miguel Angel Orellana Postigo

Universidade do Estado do Amazonas - UEA

José Reinaldo Silva

Universidade de São Paulo - USP



Abstract: Microgrids appear as a practical, clean and reliable solution to meet the demand of populations that, for various reasons, do not have access to electricity. The complexity of microgrid systems, requires considerable engineering effort in the design process. To design this type of complex systems, new approaches, methods, concepts and engineering tools are needed. Where, the requirements analysis has a preponderant role to better characterize, understand and specify the application domain and the problem that the microgrids must solve. This work proposes the introduction of a formal analysis of requirements in the life cycle of microgrid systems, using IEC 61850 as a reference architecture. The requirements would be represented in an Object Oriented Requirements Engineering (GORE) approach, using specifically visual diagrams based on the KAOS (Keep All Objectives Satisfied) method, where the operation and control of the network will be formally represented. The requirements analysis is presented using a combined representation that uses the GORE and Petri Nets methodology for dynamic modeling and formal verification. A case study for small communities in the Amazon rainforest is used as a case study for the proposed method.

Keywords: System Design, Formal Modeling, GORE methodology, Petri Nets, microgrid

INTRODUCTION

The growth in the consumption of electric energy in Brazil and in the world has represented a challenge for the energy sector, one of the alternatives found by the referred sector to overcome this situation is the use of alternative sources of distributed generation.

Advances in research and development of energy alternatives based on renewable sources are changing this scenario. In this context, microgrid arises as a technically and economically viable opportunity to meet the demand of populations who, for various reasons, had never (or have limited form) access to electricity.

Microgrid systems has a viable alternative to diversifying and streamlining energy supply needs, where fossil fuels are being replaced by renewable sources (solar and wind generators, biomass and combined heat and power systems, etc. (Liserre et al., 2010). The integration of renewable sources and changes in the consumption side are causing new challenges and offering opportunities in the electricity sector.

In this context, microgrid is emerging as a new research area in Brazil that is essential for the care of isolated communities. However, there are still gaps in the technical, economic and management fields. Addressing these technical and operational issues represents a breakthrough in knowledge, which can be translated into benefits for the microgrid assisted consumer through improvements in the quality of energy supplied and an economical tariff, as well as for the utility, through the implementation more efficient and sustainable systems.

Microgrids have been used for many decades as part of rural electrification programs in remote and isolated locations, mainly in developing countries. However, the modern concept of microgrids, involves their integration with the electrical system, mainly to the distribution network and with the potential to operate in connected or island mode.

Besides, microgrid have inherent complexity because they are eminently heterogeneous, open and distributed systems, that could be adapted to different situations and application environments. Such characteristics imply the modeling of knowledge domains that combine general and local information during the design process.

In this context, the life-cycle of the this systems becomes more important at the early phase, which is characterized by incomplete knowledge. On the other hand, in the early requirements phase, it is strategically easier to deal with difficulties originated by the lack of information or incomplete

requirements and introducing changes that prove to be necessary. That turns the requirements phase a key issue for the success of the whole design.

A structured requirements phase emerges from the formalization of microgrid requirements, and became a recent trend in electrical systems which challenge researchers and developers. Consequences for the absence of formal methods to model and analyze requirements are studied for some authors (Silva and Silva, 2015) to reinforce the need of a new approach.

Despite the great variety of works related to the design of energy systems, there is still a growing demand to introduce modern, more robust, consistent, and flexible requirement engineering methods (Mazzolini et al., 2011).

Some models and architectures have been proposed, such as IntelliGrid by the Electric Power Research Institute (EPRI, USA) (Commission et al., 2008) or the Smart Grid Architecture Model (Uslar et al., 2012). Both claim to give relevance to the requirements phase, which includes requirement elicitation, based on IEC / PAS 62559 and modeling - using Unified Modeling Language (UML) (Uslar et al., 2019). Thus, a repository of requirements for Smart Grid systems was built, including features to transmission, distribution, and integration.

Working with informal requirements seems to facilitate the work, but it can lead to undetectable failures during requirements specification (where error costs are lower) including the possibility to miss non-functional requirement using approaches object-oriented such as UML. Also, the complexity of dealing with a distributed arrangement of subsystems is another important factor that justifies the use of formal approaches

This paper proposes a recent alternative approach to microgrid systems design is based on use of reference model architectures, as the IEC 61850 (Deng et al., 2015). This model architecture facilitates the design of automated microgrid systems and is currently being used by many researchers and designers of this area.

The proposal also includes a systems approach, that includes a method to generate a formal analysis model of requirements elicited based in GORE and represented in KAOS, in addition to, a schematic representation on Petri nets.

The advantage of the proposed method is the systematic way to obtain Petri Nets as a formal model that can represent the dynamic of the automated distributed system. In fact the KAOS method also

generate a formalism in LTL (Linear Time Logic) and that could be used to analysis (Van Lamsweerde, 2009).

However, as any formalism based on logic and automata, LTL could not represent a distributed system in a compact form. To do that a product of different representations should be used. The Petri Net representation model can also support property analysis to be used on the requirements model.

The paper is organized as follows: Section 2 brings a conceptual description of the proposed method. Section 3 presents a new approach combining KAOS and Petri Net representation. A case study is presented in Section 4. Finally, a conclusion section resumes the method and suggests prospective contributions in further work.

2 CONCEPTUAL DESCRIPTION OF THE METHOD

A general schema for the proposed method is depicted in Figure 1, where the target microgrid requirements is mapped in the architecture IEC 61850, modeled in KAOS to insert details and the interaction with the user, and then transferred (automatically) to Petri Nets to be formally verified.




Figure 1: General schema of the proposed design method.

The microgrid initial scenario is defined by general information about the operational constraints, geographic characteristics, environmental and local restrictions. A reference architecture is selected to guide the process. For the proposed method we choose the IEC 61850.

A requirements model is then developed using Goal Oriented Requirement Engineering, and KAOS diagrams. Here, it is necessary to delimit the application domain and development scope, that is, define all inputs and outputs, interface and forms of communication.

The next step focus in the workflow model which is the base of the automation schema, which implies in transferring the KAOS model to Petri Nets. An algorithm called ReKPlan was developed by some of the authors to automate this process (Silva and Silva, 2019)(Silva and Silva, 2015). The main idea is

to collect the reading of Intelligent Electronic Devices (IED) to feed the developed Petri net which could reproduce the dynamic of the microgrid operation using a system of systems approach.

Finally, requirements analysis and validation is performed evaluating behavioral properties and the performance target system, as well as the constraints and restrictions to the control automation algorithm.

In what follows we will describe in more details each one of the steps briefly mentioned in this overview of the method.

3 THE PROPOSED APPROACH

The proposed method combines a new approach to requirements modeling, Goal-oriented Requirements Engineering (GORE,) with reference models frequently used in energy system design, normally applied to the operation of microgrids adding technical constraints and local peculiarities.

3.1 MICROGRID SYSTEM SCENARIO

Technically, a microgrid is a low voltage distribution network, located downstream of a distribution substation through a Point of Common Connection (PCC). The microgrid consists is a multi-source system composed by conventional Renewable Energy Sources (RES), a storage systems and controllable loads, as shown in the Figure 2. The interface between the service network and the microgrid is used to interact with the microgrid; it provides voltage control, power balancing, and load sharing. A communications infrastructure, provide the transfer and exchange of data, in real time.

Therefore, microgrids play a key role in the integration of distributed generators and, in particular in the integration of Renewable Energy Sources (RES)(Sechilariu and Locment, 2016). However, the intermittent and unpredictable nature of the power supply remains a problem to the integration with the service network, resulting in




Figure 2: Proposed scenario for the microgrid

voltage and / or frequency fluctuations, harmonic pollution, and some difficulty in charge management.

On the other hand, there is great potential to develop and test new technologies for sustainable generation, specially in countries belonging to BRICS. The integration of these technologies has become a priority in microgrids in response to the pressure to implement a net of distributed energy resources, also including the integration of intelligent electronic devices. This arrangement should be surrounded by sensing and measurement systems, network nodes with computing capacities, actuation devices to allow supervision and the proper integration and coupling with user needs.

3.2 THE ARCHITECTURE IEC-61850

The IEC 61850 architecture was developed to define communication protocols to integrate power electric systems, focused in protection, control, monitoring and diagnostics functions in substations (Naumann et al., 2014). A multidisciplinary group was launched to create this standard in 1995.

More recently the standard was expanded to include the modeling of information tailored to the needs of the electric power industry (Berger and Iniewski, 2012), which includes the automation and distribution of electric systems.

Although the IEC 61850 originally addressed only substation automation recent versions also include additional information models based on the original standard to cover other domains such as renewable energy (Berger and Iniewski, 2012). In 2010, the US National Institute of Standards and Technology (NIST) recognized IEC 61850 as a major facilitator to design and implementation of microgrid systems.

One of the main goals of the current IEC 61850 architecture is solving interface problems and to provide a standard to communication avoiding the use of specific protocols defined by different manufacturers. Another goal is to provide a base to automation and control functions that allow electrical systems to evolve towards a microgrid mesh (Naumann et al., 2014).

Therefore, current versions of the standard include extensions and additional information models to microgrids domains. IEC 61850-7-420 provides information model and Logical Node (LNs) for distributed energy resources at the process level, including controllers, generators, power converters, DC converters, and auxiliary systems (such as smart meters and other devices). IEC 61850 7-1, 7-2, 7-3 and 7-4 provide the principle for modeling equipment information. Finally, the standard IEC 61850 also provides object-oriented models for inverters, power storage systems, and others, (Hongwei, 2014), approaching to new methods of engineering design and model based engineering.

3.3 GORE: GOAL-ORIENTED REQUIREMENTS ENGINEERING

New approaches to requirements engineering evolved towards requirements management (elicitation, modeling and analysis) based on objectives - instead of functionality - decreasing the traditional dichotomy between functional and non-functional requirements. A requirement is viewed as a necessary condition to reach a goal in a specific application domain (Horkoff et al., 2017).

Functional requirements are more intuitive, generally associated with services provided to customers, in contrast with non-functional requirements, normally related to quality, performance or resources required for the service, and/or related to external demands such as safety, performance, scalability, operability, etc. Thus, in conventional the approach non-functional requirements are frequently neglected or fail to compose a complete and consistent set. Goal-oriented methods became an interesting alternative (Ghezzi and Tamburrelli, 2009).

3.4 KAOS MODELING AND THE GORE METHOD

KAOS (Knowledge Acquisition in Automated Specification) is a GORE method for modeling requirements as objectives (Horkoff et al., 2019). It is an efficient schema for adjusting descriptions, analyze problems, clarify responsibilities and manage different views between stakeholders. Improvements in traceability, completeness evaluation, reducing of ambiguity in requirement analysis are perceptible advantages of KAOS.

A comprehensive model of requirements is defined by four diagrams (only): Goal, Objects, Responsibility, and Operations, which can be resumed in a LTL (Linear Temporal Logic) formalism. Figure 3 show the main elements of a KAOS diagram.




	Goal to be achievement
	Goal assigned to single agent in software-to-be.
	Goal assigned to single agent in environment.
	Descriptive statements on environment (physical laws, organizational policies).
	Operation to be realized to achieve a goal, requirement or expectation.
	Agent responsible for the achievement of any goal, expectation or requirement

Figure 3: KAOS Elements

A goal diagram is a tree in which the root is represented by the main primary objective. This goal could be further refined into sub-objectives (requirements or expectations) which are the leaves of this top-bottom node.

Agents are responsible for satisfying one or more objectives (requirements or expectations). If the agent is part of the system to be developed then the objective is a requirement, whereas if the objective is linked to an agent belonging to the application domain the objective is an expectation. In some specific situations, goals, requirements, or expectations need to be modeled as obstacles to a goal or requirement fulfillment - a fault detection, for instance.

Using obstacles is essential for safety-critical systems since that allows domain specialist to identify and address exceptional circumstances at the requirements stage, and converge towards robust requirements that could mitigate or avoid obstacles.

3.5 CONVERTING KAOS DIAGRAMS INTO PETRI NETS

A transfer algorithm called REKPlan (Requirement Engineering in KAOS for Planning) was proposed by some of the authors (Silva and Silva, 2015) to synthesize automatically a Petri Net from Goal diagrams. This Petri Net is used as reference model, integrating the application domain and the electric power plant.

Some advantages of Petri Nets as a reference formalism are: i) to be an efficient modeling schema to represent the dynamics associated with an automated grid system, ii) formally represent the flow of information associated with the behavior of microgrids. In addition, Petri Nets is a sound representation for analysis, and verification of requirements, as will be introduced in the following.

3.6 VERIFICATION OF REQUIREMENTS BASED ON PETRI NETS

Verification is a key issue to the proposed design process for power electronic mesh of sustainable resource, integrated in the conventional electric distribution system. The basic assumption is that requirements specifications should be formalized (modeled) analysed and verified before the effective design of the solution and its implementation. As any automated systems, integrated electric power plants has to guarantee the proper convergence of objectives towards the satisfaction of user needs (as services) while also guarantee the avoidance of undesirable states and obstacles. That could be obtained from the modeling and verification of requirements, which would lead to the design of solutions that could also be verified using the same formalism, increasing traceability in the whole design process.

Verification could be done by generating the state space and analysing workflows (of control and items), by property analysis of the Petri Nets, or both. Temporal and hierarchical extensions are also welcomed.

4 APPLICATION OF THE PROPOSED METHOD TO MICROGRIDS

The case study presented here was based on the R&D Project “Microgrids with intermittent sources applied in isolated areas”, presented by the Energy Group of the Department of Automation and Electrical Engineering of Polytechnic School- USP in the year of 2012 (Martinez et al., 2016).

The main objective of this project was to supply energy to small isolated communities in the interior of the Amazon. Those communities have the ability to use microgrids, based on sustainable energy sources.

Microgrids should provide power for the isolated loads of interconnected systems. They are generally systems that rely on the use of some firm source of conventional energy (to ensure regularity and stability in the supply of electricity), and a range of renewable sources (to minimize the use of the conventional energy source).

Based on the context information and following the IEC 61850 standard, distributed energy resources (DER) are divided in two groups: Programmable DER (DER-P) and Not Programmable DER (DER-NP) (Postigo and Silva, 2018). The battery energy storage system (BESS) and the combined heat and power (CHP) are part of the DER-P. On the other hand, natural sources like Photovoltaic system (PV) and Wind Power (WP) belong to DER-NP, due to the uncertainty of power generation and randomization in renewable energy production. A microgrid control will be responsible for the switching of the DERs.

The microgrid connected to an electrical network by the common connection point (PCC), whenever the PCC interconnect switch is closed (grid-connected mode). If the PCC is open, the microgrid is separated from the electrical network and goes into autonomous mode. Figure 4. shows the operating dynamics based on IEC61850

Different modes are defined as:

- **Autonomous Mode:** Whenever the microgrid supplies power to the loading with the only Distributed Generator (DG), every time an uncommon situation of the main network or manual operation occurs.
- **Grid-connected Mode:** Normal operation occurs when the microgrid is connected to the main network and distributed energies (DER).

- Fault Operation: Whenever a fault is detected, the PCC switch opens, and micro-grid is separated from the service network and switches to Automatic Mode.
- Synchronization Operation: Whenever the network power is reestablished, transition mechanism are required to synchronize distributed generation (GD) with the main network.




Figure 4: Operation Microgrid IEC-61850

After defining the basic requirements, the next step is concerned with the synthesis of goal-driven requirements based on the IEC 61850 reference architecture and considering the geographic, environmental, and technical restrictions. For KAOS modeling, we used the ObjectivER 3.0 tool developed by Respect-IT. The resulting KAOS model is shown in Figure 5.

In the objective model, a microgrid is modeled through a Top Down view. The main purpose of this system is to provide a "Control Operation of microgrid". This objective is refined




Figure 5: Objectives Diagram

into two other sub objectives which are: operation on "Automatic Mode" and operation "Grid-connected mode" these sub objectives are refined into an expectation that evaluates "Manual operation" and the sub objectives "Synchronization operation" and "Commutation PCC" which assesses whether any "Fault operation" is related obstacle has been detected.

The final refinement passes by "Disturbance on Grid" requirements and "Utility grid supply", each one linked to the IDE-1 and IDE-2 agents respectively.

In the fourth step, a Petri Net is derived from a KAOS model, modeling the automation of the microgrid system operation. In this step, when analyzing the readings of the IED's, the Petri nets developed should switch the most appropriate mode of operation for the microgrid system.

Figure 6 shows the working dynamic of microgrid modeled in Petri Net. The control of the microgrid operation is in charge of receiving control signals through the IED's, processing and transmitting signals to the system. Thus, once the controller receives a signal from the IED's, it will enable the triggering of the transition "grid- connected mode" or "autonomous mode".

From the control processing, also available




Figure 6: Petri Net of microgrid control

Stand-By state and two switching possibilities, the available "Utility Grid Supply", and "Disturbance Grid" control locations which may lead to a possible change or return of the operating state the Synchronization.

Each time the controller detects the PCC circuit breaker the microgrid accesses the grid and switches to Grid-Connected mode, the power supply initially operates on state called Utility, and, depending on the load demand, can switch to the Utility + DER-NP + DER-P, or Utility + DER-NP or Utility + DER-P.

When the PCC switch is open, the microgrid is disconnected from the Utility services network and switches to Autonomous-Mode, that is, a situation where the system is in isolated mode, in which the power supply is through the DERs, BESS and CHP, the switching will depend on the load.

The final step is the validation of the requirements model, which allows us to verify that the model is in accordance with the specification, that is, it meets the requirements, considering the particularities and restrictions of the Amazon region.

To validate the requirements model, the functional properties of the Petri Net are used. The objective is to support Design by solving problems related to incomplete states, ambiguities and inconsistencies.

The Petri net model shows the control solution for the microgrid. In which the modes of operation change according to the readings of the IEDs. The inboxes (places of entry) in the petri net, representing the IEDs.

Figure 7 shows the summary of analysis of the properties of the Petri Net, using the PIPE2 tool.




Figure 7: PetriNets Analysis

Based on the functional properties (dependent on marking) of Petri Net, it can be concluded that:

- The Petri Net obtained is live, because it's deadlock-free;
- All markings are reachable from the initial marking. Indicating that the network adequately represents the microgrid, which is part of the rest of the energy system;
- The net is finite (as expected) because the reachability tree is finite too. That also implies the system is closed and controllable.

Analysis of structural properties using invariants, can also be used to obtain mathematical information on the structure of the network, which enables the analysis and verification of Petri Net and will be the subject of a further study.

Finally, a method and guidelines for the design of a microgrid was established, applied in a case study for small communities in the Amazon rainforest. The results of this study were shown in the Design of the system itself, composed of the KAOS diagrams Figure 5, the Petri Net model Figure 6 and the verification of the network Figure 7.

5 CONCLUSIONS

The balance between energy production and distribution points to an evolution of microgrid systems with the characteristics of being open, distributed, heterogeneous and scalable. These systems will require sophisticated multidisciplinary design approaches, which required a revision in old (functional) methods. Old approaches tend to be replaced by systemic model based methods, starting with the requirements. Prospective methods can be objective-oriented; system-oriented and holistic - not just focused on components - distributed, and resource sharing. That imposes a discipline oriented to service, more than to products. Such approaches have also the advantage to couple with users in a client-server flavor. In this paper, we proposed a method to explore an alternative approach, based on goal-oriented requirements and a formal modeling based on Petri nets to model microgrids. Some guidelines were introduced that were applied to a microgrid-based case study in small communities in Amazon equatorial forest. Besides the formal requirements modeling and verification techniques the case study serve to evaluate applicability of the proposed method in a critical situation.

Our conclusion is that, using GORE methods, a reference model to the architecture (based on the standard IEC 61850), and a formal representation based on Petri nets can lead to more flexible

analysis, including regional constraints and value co-creation in the coupling with users. That can improve the efficiency of the system that will be implemented. We noticed that this case study is real and was already implemented. Therefore, the analysis and its new prescriptions could be compared with the real system.

Further work points to the improvement of the formal method, to improve the transference between KAOS diagrams to Petri Nets - in this work just focused in objective diagrams - to include object, operation and responsibility diagrams as well. That will allow to reinforce the concept of traceability and the applicability of the proposed method.

ACKNOWLEDGEMENTS

The authors acknowledge their respective institutions for the support to their research activities: University of Amazon State (UEA), Escola Polit cnica, University of S o Paulo (USP), and Amazonas State Research Support Foundation (FAPEAM).

REFERENCES

- Berger, L. T. and Iniewski, K. (2012). *Smart grid: applications, communications, and security*, Wiley.
- Commission, I. E. et al. (2008). *Intelligrid Methodology for Developing Requirements for Energy Systems*, IEC.
- Deng, W., Pei, W., Shen, Z., Zhao, Z. and Qu, H. (2015). Adaptive micro-grid operation based on iec 61850, *Energies* 8(5): 4455–4475.
- Ghezzi, C. and Tamburrelli, G. (2009). Reason- ing on non-functional requirements for in- tegrated services, 2009 17th IEEE Interna- tional Requirements Engineering Conference, IEEE, pp. 69–78.
- Hongwei, D. (2014). Design and application of microgrid operation control system based on iec 61850.
- Horkoff, J., Aydemir, F. B., Cardoso, E., Li, T., Mat´e, A., Paja, E., Salnitri, M., Piras, L., Mylopoulos, J. and Giorgini, P. (2017). Goal-oriented requirements engineering: an extended systematic mapping study, *Require- ments Engineering* pp. 1–28.
- Horkoff, J., Aydemir, F. B., Cardoso, E., Li, T., Mat´e, A., Paja, E., Salnitri, M., Piras, L., Mylopoulos, J. and Giorgini, P. (2019). Goal-oriented requirements engineering: an extended systematic mapping study, *Require- ments engineering* 24(2): 133–160.
- Lisserre, M., Sauter, T. and Hung, J. Y. (2010). Future energy systems: Integrating renew- able energy sources into the smart power grid through industrial electronics, *IEEE indus- trial electronics magazine* 4(1): 18–37.
- Martinez, J. R., Saidel, M. A. and Fadigas, E. A. (2016). Influence of non-dispatchable energy sources on the dynamic performance of mi- crogrids, *Electric Power Systems Research* 131: 96–104.
- Mazzolini, M., Brusaferrri, A. and Carpanzano, E. (2011). An integrated framework for model-based design and verification of dis- crete automation solutions, *Industrial Infor- matics (INDIN)*, 2011 9th IEEE Interna- tional Conference on, IEEE, pp. 545–550.
- Naumann, A., Bielchev, I., Voropai, N. and Sty- czynski, Z. (2014). Smart grid automation using iec 61850 and cim standards, *Control Engineering Practice* 25: 102–111.
- Postigo, M. A. O. and Silva, J. R. (2018). Mod- eling in petri nets for micro smart grid operation based on iec 61850 architecture, 2018 Simposio Brasileiro de Sistemas Elet- ricos (SBSE), IEEE, pp. 1–6.
- Sechilariu, M. and Locment, F. (2016). *Urban DC Microgrid: Intelligent Control and Power Flow Optimization*, Butterworth-Heinemann.
- Silva, J. M. and Silva, J. R. (2015). Combin- ing kaos and ghenesys in the requirement and analysis of service manufacturing, *IFAC- PapersOnLine* 48(3): 1634–1639.
- Silva, J. M. and Silva, J. R. (2019). A new hi- erarchical approach to requirement analysis of problems in automated planning, *Engi- neering Applications of Artificial Intelligence* 81: 373–386.

Uslar, M., Rohjans, S. et al. (2019). Applying the smart grid architecture model for design- ing and validating system-of-systems in the power and energy domain: A european per- spective, *Energies* 12(2): 258.

Uslar, M., Specht, M., D'anezas, C., Trefke, J., Ro- hjans, S., Gonz'alez, J. M., Rosinger, C. and Bleiker, R. (2012). *Standardization in smart grids: introduction to IT-related methodolo- gies, architectures and standards*, Springer Science & Business Media.

Van Lamsweerde, A. (2009). *Requirements engi- neering: From system goals to UML models to software*, Vol. 10, Chichester, UK: John Wiley & Sons.

Capítulo 7



10.37423/230107095


DESENVOLVIMENTO E IMPLEMENTAÇÃO DO MÉTODO DOS MQR-FE ACOPLADO A UM SISTEMA DE CAMR

Henrique Coldebella

*Universidade Tecnológica Federal do Paraná
campus Campo Mourão*

Flávio Luiz Rossini

*Universidade Tecnológica Federal do Paraná
campus Campo Mourão*



Resumo: O presente artigo acoplou o Método dos Mínimos Quadrados Recursivo com Fator de Esquecimento (MQR-FE) a um sistema de Controle Adaptativo por Modelo de Referência (CAMR) e descreveu uma análise para uma planta de segunda ordem com parâmetros variantes e desconhecidos. No contexto industrial, processos fabris demandam de ser controlados, contudo há parâmetros variantes e mesmo desconhecidos, consequência de dinâmicas não modeladas. Assim, propôs-se um algoritmo capaz de estimar os ganhos do controlador a partir do MQR-FE. Em seguida, realizou-se a simulação do CAMR e foram obtidos os resultados numéricos, quanto aos parâmetros alvos do sistema de controle. Por meio da descrição matemática e da simulação computacional, os resultados se mostraram promissores, como a convergência dos ganhos do controlador. Portanto, este artigo têm a finalidade de contribuir com estudantes e profissionais da área de Controle e Automação, os quais buscam modelos de sistemas de controle adaptativo, a fim de checar, comparar e implementar novas tecnologias embarcadas.

Palavras-Chave: Controle Adaptativo por Modelo de Referência (CAMR); Método dos Mínimos Quadrados Recursivo com Fator de Esquecimento (MQR-FE); Simulação numérica.

I. INTRODUÇÃO

O conceito de adaptação parte do princípio de ação cujo objetivo é alterar um determinado comportamento a fim de ajustar sob novas condições. No contexto de controle industrial, existem processos que são passíveis de alterações em seu comportamento dinâmico, sejam por erros de característica imprevisível ou propriamente alterações em seus parâmetros de operação original [1][2].

Durante a década de 1950, deu-se início aos primeiros estudos direcionados a projeto de controle adaptativo, o qual passava a ajustar sua ação de controle para se adaptar às alterações dinâmicas no processo. Nesse contexto, foi durante o desenvolvimento de sistemas de piloto automático (do inglês "*autopilot*") para aeronaves, surgiram os primeiros modelos de controle adaptativo [3]. Apesar disso, foi apenas durante as décadas de 1970 e 1980, quando os argumentos matemáticos relacionados a estabilidade foram devidamente provados, que os primeiros modelos comerciais de controladores adaptativos surgiram no mercado [4].

Dessa forma, o campo de pesquisa de controle adaptativo se encontra significativamente associado a aplicação de ferramentas matemáticas avançadas. Assim, torna-se importante a compreensão de métodos de identificação de sistemas, relacionados à área da modelagem matemática [5]. A utilização de técnicas de identificação de sistemas dinâmicos permite modelar a dinâmica do processo com pouco ou nenhum conhecimento prévio sobre a planta [6].

Dentre os métodos de identificação de sistemas, torna-se possível dividir esses em duas abordagens distintas: (i) métodos *offline*, e (ii) métodos online. Métodos de identificação *offline* são métodos baseados em um conjunto de amostras disponível [7]. Por outro lado, um método de identificação é dito online, se esse executa simultaneamente a operação do processo a ser identificado, ou seja, é atualizado recursivamente a cada nova amostra [8]. Neste sentido, métodos *online* possuem característica essencial de identificar mudanças paramétricas em tempo real ao longo da operação e controle do processo [9].

Um dos métodos de identificação mais difundido, com bibliografia detalhada, é o Método dos Mínimos Quadrados, sendo um método inicialmente *offline*, o qual pode ser modificado da forma a se obter um algoritmo dos Mínimos Quadrados Recursivo com Fator de Esquecimento (MQR-FE), sendo um método *online* de caráter recursivo. O MQR-FE é amplamente aplicado na estimação de parâmetros em processos variantes no tempo [6] [8].

Neste trabalho, realizou-se uma aplicação de uma técnica de projeto de controle adaptativo, denominada de Controle Adaptativo por Modelo de Referência (CAMR). Essa técnica essencialmente consiste de um sistema seguidor de modelo, dessa forma se estabeleceu um modelo que descreve o comportamento dinâmico esperado do sistema de malha fechada. Nessa técnica, aplicou-se um algoritmo de adaptação capaz de atualizar os ganhos da lei de controle com base na diferença entre a saída do processo e a saída do modelo [11] [13].


O presente artigo se encontra organizado da seguinte maneira: na Seção II, descreveu-se sobre o Controle Adaptativo por Modelo de Referência (CAMR); na Seção III, apresentou-se os fundamentos do Método dos Mínimos Quadrados Recursivo com Fator de Esquecimento (MQR-FE); na Seção IV, demonstrou-se a modelagem da processo a controlar; na Seção V, estabeleceu-se a metodologia utilizada no trabalho; na Seção VI, descreveram-se os resultados simulados; e na Seção VII, analisaram-se os resultados obtidos.

II. CONTROLE ADAPTATIVO POR MODELO DE REFERÊNCIA (CAMR)

Inicialmente proposto no final da década de 1950, o sistema de CAMR, tem como objetivo regular um determinado sistema de forma que seu sinal de saída rastreie um certo sinal obtido do modelo pré-estabelecido no projeto [10] [12][14]. Esse sinal de referência é o que caracteriza essa técnica, sendo $y_m(s)$ o sinal que descreve o comportamento esperado em malha fechada do sistema CAMR.

O diagrama de blocos do sistema típico de CAMR, encontra-se ilustrado na Fig. 1 com os respectivos fluxos de sinais e blocos de processamento.

Fig. 1: Diagrama de blocos do Controle Adaptativo por Modelo de Referência



Fonte: Adaptado de (COLDEBELLA; BROLIN; ROSSINI, 2022)

O esquema ilustrado na Fig. 1 estabelece como ferramenta central um mecanismo de adaptação. Esse mecanismo representa um algoritmo que recebe a informação do erro de rastreamento $\tilde{y}(t)$, esse por sua vez computa a diferença entre o sinal de saída do processo $y(t)$, e o sinal de saída do modelo de referência $y_m(t)$. Tal bloco de processamento recebe simultaneamente a informação do sinal de controle $y(t)$, o qual controla o processo. A partir dessas informações, o algoritmo de adaptação fornece ao controlador do sistema um vetor de ganhos $\hat{\theta}(t)$ [11] [10] [12].

Para a construção do mecanismo de adaptação, realizou-se a inserção de um algoritmo de estimação de parâmetros. Assim, adaptou-se um método de identificação *online*, sendo esse a partir das medições dos sinais de entrada e de saída do processo, o qual efetuou a estimação em tempo real dos parâmetros da planta [11] [12]. Assim, além de realizar a estimação de parâmetros do sistema dinâmico, há necessidade de acoplar esse algoritmo a lei de controle adaptativa [12] [13]. No contexto de projeto do sistema CAMR, o algoritmo frequentemente utilizado para compor o mecanismo de adaptação é o desenvolvido pelo Instituto de Tecnologia de Massachusetts (do inglês "Massachusetts Institute of Technology" MIT), o chamado Método do Gradiente (MG), também encontrado em outras bibliografias como Regra do MIT (do inglês "MIT Rule") [10] [11] [12].

Dessa forma, considerou-se um processo P de primeira ordem ordinário

$$G_P(s) = \frac{b_p}{s + a_p} \quad (1)$$

sendo $G_P(s)$ a função de transferência de malha aberta do processo, a_p , b_p , s os parâmetros da planta e s a variável do domínio de Laplace.

E um modelo de referência F_m de primeira ordem da forma

$$F_m(s) = \frac{b_m}{s + a_m} \quad (2)$$

sendo $F_m(s)$ a função de transferência do modelo de referência, a_m e b_m sendo seus respectivos parâmetros.

O processo recebe um sinal de controle $u(t)$ da forma

$$u(t) = \hat{\theta}^T(t)\omega(t) \quad (3)$$

sendo $\omega(t)$ um vetor que representa os regressores do sistema, isto é, os sinais que percorrem a malha de controle de forma que $\omega(t) = [y(t) \ r(t)]^T$, com $y(t)$ e $r(t)$, os fluxos de sinais de saída e

entrada, respectivamente, do sistema CAMR e $\hat{\vartheta}(t)$ representa um vetor de ganhos estimados do controlador.

Em seguida, aplicou-se a Transformada de Laplace na Eq. (3)

$$U(s) = \hat{\vartheta}_1 R(s) - \hat{\vartheta}_2 Y(s) \quad (4)$$

A Regra do MIT surge como uma forma de modificar os parâmetros $\hat{\vartheta}_1$ e $\hat{\vartheta}_2$ (na direção do gradiente negativo com a aplicação de uma função custo $J(\hat{\vartheta})$. Essa função custo é definida por

$$J(\vartheta) = \frac{1}{2} \tilde{y}^2 \rightarrow 0 \quad (5)$$

Pela Regra do MIT ao realizar a derivada parcial, obtém-se

$$\frac{d\vartheta}{dt} = -\gamma \frac{\partial J}{\partial \vartheta} \quad (6)$$

sendo γ um fator de ganho constante positivo.

Realizou-se a derivada parcial em ambos os lados da igualdade da Eq. (5) da forma

$$\frac{dJ}{dt} = \tilde{y} \frac{\partial \tilde{y}}{\partial \vartheta} \quad (7)$$

Substituiu-se, portanto, a Eq. (7) em (6) sendo obtido

$$\frac{d\vartheta}{dt} = -\gamma \tilde{y} \frac{\partial \tilde{y}}{\partial \vartheta} \quad (8)$$

Para que as saídas da planta e do modelo sejam equivalentes, $Y(s) = Y_m(s)$

$$\frac{d\vartheta}{dt} = -\gamma \tilde{y} \frac{\partial \tilde{y}}{\partial \vartheta} \quad (9)$$

Comparou-se o resultado ao modelo de referência da Eq. (2)

$$\frac{b_p \vartheta_1}{s + a_p + b_p \vartheta_2} = \frac{b_m}{s + a_m} \quad (10)$$

No entanto, a Eq. (10) torna-se verdadeira se ambos os parâmetros a_p e b_p são conhecidos. Contudo, ao considerar um projeto de CAMR em que os parâmetros do processo são desconhecidos, buscou-se uma forma de contornar tal situação.

Considerou-se s como a representação de uma derivada temporal, tem-se no domínio do tempo

$$y(t) = \frac{b_p \hat{\vartheta}_1}{\frac{d(\cdot)}{dt} + a_p + b_p \hat{\vartheta}_2} r(t) \quad (11)$$

Realizou-se a derivada parcial da Eq. (11) em relação $\hat{\vartheta}_1$

$$\frac{\partial y(t)}{\partial \vartheta_1} = \frac{b_p}{\frac{d(\cdot)}{dt} + a_p + b_p \hat{\vartheta}_2} r(t) \quad (12)$$

Assim como, derivou-se parcialmente a Eq. (11) em relação $\hat{\vartheta}_2$

$$\frac{\partial y(t)}{\partial \vartheta_2} = \frac{b_p^2 \hat{\vartheta}_1}{\left(\frac{d(\cdot)}{dt} + a_p + b_p \hat{\vartheta}_2\right)^2} r(t) \quad (13)$$

A Eq. (13), pode ser manipulada para obter-se

$$\frac{\partial y(t)}{\partial \vartheta_2} = - \frac{b_p \hat{\vartheta}_1}{\frac{d(\cdot)}{dt} + a_p + b_p \hat{\vartheta}_2} \left[\frac{b_p}{\frac{d(\cdot)}{dt} + a_p + b_p \hat{\vartheta}_2} r(t) \right] \quad (14)$$

Conforme a Eq. (12), rearranjou-se a Eq. (14) da forma

$$\frac{\partial y(t)}{\partial \vartheta_2} = - \frac{b_p \hat{\vartheta}_1}{\frac{d(\cdot)}{dt} + a_p + b_p \hat{\vartheta}_2} y(t) \quad (15)$$

Dessa forma substituíram-se as derivadas parciais das Eq. (12) e (15) em (8) na forma

$$\frac{d\hat{\vartheta}_1}{dt} = -\gamma \tilde{y} \frac{b_p}{\frac{d(\cdot)}{dt} + a_p + b_p \hat{\vartheta}_2} r(t) \quad (16)$$

E para $\hat{\vartheta}_2$

$$\frac{d\hat{\vartheta}_2}{dt} = \gamma \tilde{y} \frac{b_p \hat{\vartheta}_1}{\frac{d(\cdot)}{dt} + a_p + b_p \hat{\vartheta}_2} y(t) \quad (17)$$

Como a_p e b_p são desconhecidos, efetuou-se a seguinte aproximação

$$a_p + b_p \hat{\vartheta}_2 \cong a_m \quad (18)$$

Logo, pode-se reescrever as Eq. (16) e (17) apenas com parâmetros do modelo de referência, da forma

$$\frac{d\hat{\vartheta}_1}{dt} = -\gamma \tilde{y} \left[\frac{a_m}{\frac{d(\cdot)}{dt} + a_m} r(t) \right] \quad (19)$$

E para $\hat{\vartheta}_2$

$$\frac{d\hat{\vartheta}_2}{dt} = \gamma \tilde{y} \left[\frac{a_m}{\frac{d(\cdot)}{dt} + a_m} y(t) \right] \quad (20)$$

sendo $\frac{a_m}{s+a_m}$ representa um filtro $\phi(t)$ aplicado nos sinais regressores.

Para processos de ordem $n \geq 1$, o filtro auxiliar pode ser executado da forma

$$\phi(t) = F_m(s)\mathbf{I}\omega \quad (21)$$

Considerou-se também a avaliação do erro de estimação, ou erro aumentado. Este é fundamental para a análise de estabilidade, dessa forma, a seguinte igualdade foi considerada

$$F_m(s)(\vartheta^* \omega) = \vartheta^* (F_m(s)\omega) \quad (22)$$

onde $\vartheta^* = \vartheta - \hat{\vartheta}$

Reescreveu-se a Eq. (22) como

$$F_m(s)(\vartheta^T \omega) - F_m(s)(\hat{\vartheta}^T \omega) = \vartheta^T (F_m(s)\omega) - \hat{\vartheta}^T (F_m(s)\omega) \quad (23)$$

Considerou-se a Eq. (21) de forma que a Eq. (23) foi reescrita da forma

$$\hat{\vartheta}^T \phi - F_m(s)(\hat{\vartheta}^T \omega) = \vartheta^T \phi - F_m(s)(\vartheta^T \omega) \quad (24)$$

A igualdade da Eq. (24) favorece o cálculo do erro aumentado em ambiente digital, pois este representa o erro acumulado da estimação digital do parâmetro desejado. Dessa forma, somou-se o termo $\hat{\vartheta}^T \phi - F_m(s)(\hat{\vartheta}^T \omega)$ ao valor de erro de rastreamento $\tilde{y}[k]$, para obter digitalmente o valor do erro de estimação

$$E_1[k] = y[k] + \hat{\vartheta}^T [k]\phi[k] - F_m(s)(\hat{\vartheta}^T [k]\omega[k]) \quad (25)$$

Com isso, utilizou-se para processos de ordem $n \geq 1$ a seguinte lei adaptativa para atualizar o vetor de parâmetros $\hat{\vartheta}$ da forma normalizada [11]

$$\frac{d\hat{\vartheta}}{dt} = \gamma \frac{\varphi(t)E_1(t)}{1 + \phi(t)\phi^T(t)} \quad (26)$$

sendo $[1 + \phi(t)\phi^T(t)]$ um sinal de normalização para garantir que a derivada seja sempre negativa [12].

III. MÉTODO DOS MÍNIMOS QUADRADOS RECURSIVO COM FATOR DE ESQUECIMENTO (MQR-FE)

Para modelar qualquer sistema de controle é essencial ter alguma informação da dinâmica do processo a ser controlado.

Nesse sentido, processos com características dinâmicas variantes, chamados de sistemas variantes no tempo, oferecem um desafio a modelagem do sistema de controle. Nesses casos, torna-se essencial que a estimação dos parâmetros do sistema pondere com maior peso as informações mais recentes de sua dinâmica, assim um estimador recursivo é recomendado [6][9].

Dessa forma, o método dos Mínimos Quadrados Recursivo (MQR) pode ser aplicado para estimar os parâmetros da planta, de forma alternativa a Regra do MIT [12] [13]. Semelhante a Regra do MIT, o algoritmo do MQR tem como objetivo minimizar a função de custo do erro quadrático, expressada por

$$J(\vartheta) = \frac{1}{2} \int_0^t E_1^2(\tau) d\tau \quad (27)$$

Uma lei de estimação de parâmetros do tipo MQR caracteriza-se por possuir uma matriz de covariância P , essa armazena as informações de direção dos parâmetros à estimar [8][12]. A matriz P pode ser utilizada para alterar a velocidade de adaptação dos ganhos do controlador em função do tempo ou amostras, e é atualizada conforme

$$\frac{dP}{dt} = -\frac{P(t)\phi(t)\phi^T(t)P(t)}{1 + \phi(t)\phi^T(t)} \quad (28)$$

Com o computo da matriz de covariância, o vetor de ganhos $\hat{\vartheta}$ é atualizado da forma [8][12].

$$\frac{d\hat{\vartheta}}{dt} = -P(t) \frac{\phi(t)E_1(t)}{1 + \phi(t)\phi^T(t)} \quad (29)$$

sendo $\phi(t)$, $E_1(t)$ atualizados por meio de (21) e (25) respectivamente.

Para uma implementação digital, pode ser aplicado um método de discretização na forma de se obter uma relação amostral para ambas as derivadas temporais das Eq. (28) e (29). Um algoritmo para o computo da matriz de covariância P discreto pela Aproximação Bilinear é expresso por

$$P[k] = P[k-1] - \frac{T}{2} \frac{P[k]\phi[k]\phi^T[k]P[k]}{1 + \phi[k]\phi^T[k]} \dots \\ - \frac{T}{2} \frac{P[k-1]\phi[k-1]\phi^T[k-1]P[k-1]}{1 + \phi[k-1]\phi^T[k-1]} \quad (30)$$

Da mesma forma, $\hat{\vartheta}$ pode ser atualizado conforme

$$\hat{\vartheta}[k] = \hat{\vartheta}[k-1] - \frac{T}{2} P[k] \frac{\phi[k]E_1[k]}{1 + \phi[k]\phi^T[k]} \dots \\ - \frac{T}{2} P[k-1] \frac{\phi[k-1]E_1[k-1]}{1 + \phi[k-1]\phi^T[k-1]} \quad (31)$$

Para que o algoritmo atualize as variações paramétricas com maior capacidade, o algoritmo do MQR digital pode ser reescrito ao aplicar um fator de esquecimento, o chamado algoritmo dos Mínimos Quadrados Recurso com Fator de Esquecimento (MQR-FE) [6].

$$P[k] = \frac{1}{\lambda} P[k-1] - \frac{1}{\lambda} \left\{ \frac{T}{2} \frac{P[k] \phi[k] \phi^T[k] P[k]}{\lambda + \phi[k] \phi^T[k]} \right\} \dots$$

$$- \frac{1}{\lambda} \left\{ \frac{T}{2} \frac{P[k-1] \phi[k-1] \phi^T[k-1] P[k-1]}{\lambda + \phi[k-1] \phi^T[k-1]} \right\} \quad (32)$$

A Eq. (31) pode ser reescrita na forma

$$\hat{\vartheta}[k] = \hat{\vartheta}[k-1] - \frac{T}{2} P[k] \frac{\phi[k] E_1[k]}{\lambda + \phi[k] \phi^T[k]} \dots$$


$$- \frac{T}{2} P[k-1] \frac{\phi[k-1] E_1[k-1]}{\lambda + \phi[k-1] \phi^T[k-1]} \quad (33)$$

Sendo λ o fator de esquecimento, $\lambda \in (0,1)$ [6] [9].

IV. MODELAGEM DO PROCESSO

Para validar os conceitos desenvolvidos na Seção II e III foi selecionada uma planta de segunda ordem com parâmetros variantes no tempo. A planta selecionada foi um modelo em espaço de estados de um servomotor de corrente contínua (CC) representado na Fig. 2.

Fig. 2: Simulação do CAMR com parâmetros conhecidos



Fonte: Adaptado de (CANAL; VALDIERO; REIMBOLD, 2017)

Conforme o circuito da Fig. 2, o processo de servoposicionamento foi modelado com base nos parâmetros elétricos de resistência R , tensão de alimentação $r(t)$, corrente de armadura $i_a(t)$ e indutância L . O modelo apresenta também parâmetros mecânicos e eletromecânicos, como o próprio rotor M e os valores de energia mecânica F e velocidade angular $x(t)$, [15].

Conforme o circuito, Fig. 2, a equação do movimento angular pode ser descrita da forma

$$F \frac{dx}{dt} = -bx(t) + T_F \quad (34)$$

Sendo $T_F = k_f i_a$, k_f é a constante de proporcionalidade de força, b o torque em $N.m$

A Eq. (34) pode ser reescrita como

$$\frac{dx}{dt} = -\frac{b}{F}x(t) + \frac{k_f}{F}i_a \quad (35)$$

Assim, efetuou-se a análise do somatório das tensões do circuito a fim de obter-se a seguinte equação de malha

$$L \frac{di_a}{dt} + Ri_a + V_M - V = 0 \quad (36)$$

Sendo $V_M = k_e x(t)$, que corresponde a tensão eletromotriz do rotor.

Reescreveu-se a Eq. (36) em função da derivada da corrente do motor, da forma

$$\frac{di_a}{dt} = -\frac{R}{L}i_a(t) - \frac{k_e}{L}x(t) + \frac{1}{L}r(t) \quad (37)$$

Dessa modo, com as equações diferenciais obtidas em (35) e (37), obtém-se o seguinte modelo em espaço de estados

$$\begin{bmatrix} \dot{x}(t) \\ \dot{i}_a(t) \end{bmatrix} = \begin{bmatrix} -b/F & k_f/F \\ -k_e/L & -R/L \end{bmatrix} \begin{bmatrix} x(t) \\ i_a(t) \end{bmatrix} + \begin{bmatrix} 0 \\ 1/L \end{bmatrix} r(t) \quad (38)$$

$$y(t) = [1 \quad 0] \begin{bmatrix} x(t) \\ i_a(t) \end{bmatrix} \quad (39)$$

Considera-se $k_f = k_e = k$.

O modelo descrito pelas Eq. (38) e (39) será utilizado para validar o CAMR projetado com base no algoritmo MQR-FE.

V. METODOLOGIA

Conforme descrito na seção IV, utilizou-se um processo de servoposicionamento de um motor CC. Dessa forma, com base nas equações de estados apresentadas foram selecionados os seguintes parâmetros para simulação do processo.

$$\begin{bmatrix} \dot{x}(t) \\ \dot{i}_a(t) \end{bmatrix} = \begin{bmatrix} -\frac{0,1 \text{ kg.m}^2/s}{0,01 \text{ kg.m}^2} & \frac{0,01 \text{ Nm/A}}{0,01 \text{ kg.m}^2} \\ \frac{0,01 \text{ Nm/A}}{0,5 \text{ H}} & -\frac{R}{0,5 \text{ H}} \end{bmatrix} \begin{bmatrix} x(t) \\ i_a(t) \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \\ 0,5 \text{ H} \end{bmatrix} r(t) \quad (40)$$

O parâmetro de resistência R , por sua vez, pode sofrer variações conforme alterações de temperatura ou desgaste com o tempo, portanto, considerou-se R como um parâmetro variante no tempo da forma

$$R = \begin{cases} 1 \Omega, & 0 \leq t < 120 \\ 0,92 \Omega, & t \geq 120 \end{cases} \quad (41)$$

Para a validação do CAMR baseado no algoritmo do MQR-FE, não é necessário qualquer conhecimento dos parâmetros aqui arbitrados, apenas da ordem do processo. O conhecimento prévio da ordem possibilita a correta seleção do modelo de referência para uma resposta adequada na simulação. Dessa forma, foi selecionado um modelo de referência no domínio de Laplace para se obter a seguinte especificação de projeto.

$$F_m(s) = \begin{cases} T_p = 3 \\ M_p = 0,07 \end{cases} \quad (42)$$

Sendo T_p o tempo de pico em segundos e M_p o máximo de sobressinal da resposta.


Dessa forma, o modelo de referência $F_m(s)$ pode ser definido como uma função de transferência da forma

$$F_m(s) = \frac{1,882}{s^2 + 1,773s + 1,882} \quad (43)$$

Na Fig. 3, ilustra-se a simulação do modelo de referência para uma entrada em sinal pulsado positivo.

Na Fig. 4, representa-se um fluxograma de funcionamento do algoritmo do MQR-FE acoplado a lei adaptativa do sistema CAMR.

Fig. 3: Simulação do modelo de referência



Fonte: Autoria Própria, 2022.

Portanto, para validar o projeto do controlador e o algoritmo do MQR-FE proposto, será inicialmente simulado o modelo de motor CC proposto e o modelo de referência selecionado.

Em seguida, será executado o algoritmo do MQR-FE proposto na Seção III. Deverão ser avaliados tanto a progressão dos parâmetros em direção aos ganhos necessários para que a saída do processo siga o modelo estabelecido, quanto a taxa de erro de rastreamento e o sinal de ação de controle fornecido pelo controlador principal do sistema CAMR.

VI. RESULTADOS

Para o projeto do CAMR baseado na lei adaptativa do MQR-FE, representado já na forma discreta pelas Eqs. (33) e (32). Para o computo da matriz de covariância P foi feita a inicialização desta matriz da forma $P, P(0) = P_0 I, P_0 = 10.000$

. Note que é importante a inicialização desta matriz com valor significativamente elevado para que o algoritmo de estimação de ganhos do controlador seja rápido o suficiente para seguir as especificações de desempenho, esse valor pode ser regulado conforme a necessidade de desempenho.

A partir de uma rotina de execuções e testes, foi selecionado um fator de esquecimento $\lambda = 0,9958$. Estabeleceu-se o valor para que o controlador se ajuste com precisão a alteração paramétrica de R durante sua operação. Para toda a simulação, usou-se a taxa de amostragem de $T = 0,01s$ constante.

Na Fig. 5, ilustra-se a progressão dos parâmetros do controlador.

Nota-se uma grande variação em $t = 120s$ onde ocorre uma alteração no valor de resistência do rotor.

Nota-se também a eficiência do algoritmo em armazenar informações quanto a direção dos parâmetros. Isso ocorre devido a atualização da matriz de covariância a cada iteração.


Para validar o CAMR projetado, na Fig. 6 se representa a saída do sistema controlado em relação ao modelo de referência definido na Eq. (43).

O desempenho do CAMR pode também ser analisado conforme o sinal de ação de controle $u[k]$ gerado pelo controlador em malha aberta com a planta. Essa ação de controle é representada na Fig. 7.

Por fim, na Fig. 8, mostra-se o sinal de erro de rastreamento. Isto é, o quanto a saída do processo desviou em relação a saída do modelo de referência, esse que representa as Especificações desejadas do projeto. Esse é um importante critério de desempenho do sistema em malha fechada, pois Apresenta de forma quantitativa se o controlador rastreou de forma significativa a saída do modelo, o qual contém as especificações pré-estabelecidas.


Nota-se um maior desvio da saída do CAMR em relação a especificação durante o primeiro pulso, isso se deve principalmente pelo algoritmo de adaptação se tratar de um algoritmo recursivo, ou seja, quanto mais amostras recentes estão disponíveis, mais eficiente se torna o algoritmo MQR-FE ao estimar os parâmetros necessários para o controlador.

Fig. 4: Fluxograma para o algoritmo do MQR-FE acoplado a lei adaptativa




Fonte: Autoria Própria, 2022.

Fig. 5: Estimação dos ganhos do controlador




Fonte: Autoria Própria, 2022.

Fig. 6: Saída controlada conforme o algoritmo MQR-FE




Fonte: Autoria Própria, 2022.

Fig. 7: Ação de controle para os ganhos estimados pelo algoritmo do MQR-FE



Fonte: Autoria Própria, 2022.

Fig. 8: Erro de rastreamento do sistema CAMR



Fonte: Autoria Própria, 2022.

VII. CONCLUSÃO

Neste trabalho, desenvolveu-se uma revisão de bibliografia relacionada a problemática do projeto de Controlador Adaptativo por Modelo de Referência. Foram estudados os conceitos básicos de Controle Adaptativo, as ferramentas e desenvolvimentos matemáticos utilizados pelas principais bibliografias, e o estudo aprofundado de algoritmos de estimação de parâmetros aplicados como lei de adaptação para um sistema CAMR.

Foi proposto por este trabalho, a utilização de um algoritmo dos Mínimos Quadrados Recursivo com Fator de Esquecimento como substituto do típico algoritmo do Gradiente utilizado no projeto de CAMR.

Dessa forma, foi proposto um processo de segunda ordem com parâmetro variante com a finalidade de simular no software MATLAB® e como consequência realizar a análise do acoplamento do MQR-FE no CAMR em tempo discreto.

Os resultados validaram o desenvolvimento matemático propostos nas bibliografias aqui listadas, em especial para casos onde não se conhece por completo a planta a ser controla, isso ocorre frequentemente nos processos industriais, principalmente as variações paramétricas que possam interferir no desempenho do sistema de controle.

Neste sentido, o sistema CAMR projetado a partir do MQRFE para a lei de adaptação, ofereceu um resultado promissor para processos de características dinâmicas com parâmetros variantes ou mesmo desconhecidos. Demonstrou capacidade numérica e convergência dos valores dos parâmetros, assim

como manteve a saída do sistema de controle conforme as especificações de desempenho pré-estabelecidas.

Por meio desse trabalho, os autores acreditam na motivação de outros profissionais na exploração dos assuntos aqui tratados, além de fornecer material bibliográfico para estudo, checagem e comparação de estudantes e demais profissionais da área de controle e automação industrial.

REFERÊNCIAS

- [1] ÅSTRÖM, K. J.; WITTENMARK, B. Adaptive Control, Second Edition. Addison-Wesley, 1995.
- [2] PAWELSKI, L. ; BROLIN, L. C. ; ROSSINI, F. L. . Projeto e implementação de um controlador digital aplicado a uma estação de solda com temperatura variável. In: XXVII Seminário de Iniciação Científica e Tecnológica (SICITE), 2022, Santa Helena. XXVII Seminário de Iniciação Científica e Tecnológica (SICITE), 2022.
- [3] GREGORY, P.; Self adaptive flight control. Flight Control Symposium. 1959.
- [4] LANDAU, I. D.; LOZANO, R.; MŠSAAD, M.; KARIMI, A. Adaptive control: algorithms, analysis and applications. [S.l.]: Springer Science & Business Media, 2011.
- [5] DONDA, R. A. ; ROSSINI, F. L. . Projeto, Simulação e Análise de um Sistema de Controle por Modo Deslizante Aplicado ao Conversor CC-CC Buck: Estudo de Caso. In: João Dallamuta; Henrique Ajuz Holzmänn. (Org.). Engenharia elétrica: Sistemas de energia elétrica e telecomunicações 2. 1ed.Ponta Grossa: Atena Editora, 2022, v. 1, p. 14-24.
- [6] ROSSINI, F. L.; Métodos de Filtragem, Estimação e Controle Adaptativo Indireto Aplicados a Sistemas de Teleoperação Bilateral. pt. PhD thesis. Faculdade de Engenharia Elétrica e de Computação—Universidade Estadual de Campinas, 2020.
- [7] TAKEMOTO, V. S. ; ROSSINI, F. L. ; CORRÊA, W. J. . Modelagem de um sistema caixa-cinza por meio do método dos mínimos quadrados a partir de identificação ARX. In: XXVII Seminário de Iniciação Científica e Tecnológica (SICITE), 2022, Santa Helena. XXVII Seminário de Iniciação Científica e Tecnológica (SICITE), 2022.
- [8] AGUIRRE, L. A. Introdução à Identificação de Sistemas: Técnicas Lineares e Não- Lineares. [S.l.]: Editora UFMG – 3ª Edição, 2007.
- [9] ROSSINI, Flávio Luiz; Oliveira, Luiz Fernando Pinto de ; GIESBRECHT, MATEUS . Identificação Recursiva de Sistemas Dinâmicos Contínuos Variantes no Tempo através do Filtro de Kalman Estendido e da Filtragem de Variáveis de Estado pelo Método dos Mínimos Quadrados Recursivos. In: Julianno Pizzano Ayoub; Marcel Ricardo Nogueira de Oliveira. (Org.). Desvendando a Engenharia sua abrangência e multidisciplinaridade. 1ed.Guarujá: Editora Científica Digital, 2021, v. 2, p. 284-302.
- [10] CANHAN, D. C. ; BROLIN, L. C. ; ROSSINI, F. L. . Aplicação do Método do Gradiente e do Método dos Mínimos Quadrados Recursivo para Análise de Desempenho do Controle Adaptativo por Modelo de Referência. In: João Dallamuta; Henrique Ajuz Holzmänn. (Org.). Engenharia elétrica: Sistemas de energia elétrica e telecomunicações 2. 1ed.Ponta Grossa: Atena Editora, 2022, v. 1, p. 91-100.
- [11] IOANNOU, P. A.; SUN, J. Robust Adaptive Control. PTR Prentice-Hall. 1996.
- [12] COLDEBELLA, H. ; BROLIN, L. C. ; ROSSINI, F. L. . . In: João Dallamuta; Henrique Ajuz Holzmänn. (Org.). Engenharia elétrica: Sistemas de energia elétrica e telecomunicações 2. 1 ed. Ponta Grossa: Atena Editora, 2022, v. 1, p. 47-58.

[13] COLDEBELLA, H. ; BROLIN, L. C. ; ROSSINI, F. L. . Comparação entre Algoritmos de Adaptação Paramétrica aplicados ao Projeto de Controlador Adaptativo por Modelo de Referência. In: XXVII Seminário de Iniciação Científica e Tecnológica (SICITE), 2022, Santa Helena.

XXVII Seminário de Iniciação Científica e Tecnológica (SICITE), 2022.

[14] WHITAKER, H. P., YAMRON, J., KEZER, A.; Design of modelreference adaptive control systems for aircraft. Massachusetts Institute of Technology, Instrumentation Laboratory. 1958.

[15] CANAL, I. P., VALDIERO, A. C., REIMBOLD, M. M. P.; Modelagem Matemática de Motor de Corrente Contínua e Análise Dinâmica. Proceeding Series of the Brazilian Society of Applied and Computational Mathematics, Vol. 5, N. 1. 2017.

[16] NISE, Norman S. Engenharia de sistemas de controle. 6. ed. Tradução e revisão técnica: Jackson Paul Matsuura. Rio de Janeiro: LTC, 2013.

Capítulo 8



10.37423/230107155


DESENVOLVIMENTO E AVALIAÇÃO DE UM CONTROLADOR PREDITIVO NÃO LINEAR BASEADO EM MODELO QUASILINEAR MODIFICADO: ABORDAGEM POR VARIÁVEIS DE ESTADO

Manoel de Oliveira Santos Sobrinho

*Universidade Federal do Vale do São
Francisco*

Adhemar de Barros Fontes

Universidade Federal da Bahia



Resumo: Neste artigo desenvolve-se um controlador preditivo não linear baseado em modelo bilinear, descrito por variáveis de estado, o qual é linearizado a cada instante de amostragem e utilizado no cálculo das predições. Na linearização, utilizam-se os valores das variáveis de estado, conhecidos em cada instante de amostragem, e valores futuros calculados a partir do modelo da planta, para se atualizarem os coeficientes do modelo preditor. Resultados de simulação são apresentados utilizando-se um sistema bilinear com não linearidades bastantes expressivas, para se avaliar o desempenho do controlador.

Palavras-chave: Controle Preditivo Não Linear, Modelos Bilineares, Linearização, Variáveis de Estado.

1 INTRODUÇÃO

O controle preditivo baseado em modelo (MPC) é uma classe de algoritmo que calcula uma sequência de ajustes no sinal de controle de forma a otimizar o comportamento futuro da saída de um sistema. É uma técnica de controle bastante conhecida e utilizada, tanto no meio acadêmico como na indústria (Qin and Badgwell, 2003). Originalmente desenvolvida para atender à necessidade de controle especializado de refinarias de petróleo (Richalet et al, 1978), esta técnica de controle recebeu bastante destaque nas últimas décadas, obtendo grande aceitabilidade no ambiente industrial, com uma grande variedade de aplicação em várias áreas, incluindo indústria química, processamento de alimentos, automotiva, aeroespacial, metalúrgica e de papel. Isto porque, os controladores preditivos têm-se mostrado bastante eficazes no controle de plantas monovariáveis e multivariáveis, com retardo, de fase não mínima e instáveis (Camacho e Bordons, 2004). Isto é o que caracteriza a maioria dos processos industriais, os quais têm seus próprios critérios de desempenho e exigência de confiabilidade. Em plantas industriais mais complexas é crescente a demanda pelo controle preditivo não linear (NMPC). Isto é devido a fatores, tais como: o atual nível de especificação de alta qualidade de produção; a crescente demanda de produtividade; a atual legislação ambiental, que é mais rigorosa e ainda, as exigentes considerações econômicas na indústria que levam os processos a operar mais próximos dos limites admissíveis (Allgöwer et al, 2004). Sabe-se que as técnicas de projeto de controladores lineares são largamente empregadas na indústria química e petroquímica e, em particular, o controlador preditivo baseado em modelos lineares (Richalet, 1993). No entanto, o controlador preditivo não linear, que utiliza um modelo do processo não linear, mais realista, frequentemente mais complexo, tipicamente sacrifica a simplicidade associada às técnicas lineares de forma a alcançar um melhor desempenho, (Eaton e Rawlings, 1990; Biegler e Rawlings, 1991).

Do ponto de vista conceitual, o NMPC não apresenta dificuldades, já que é possível considerar a mesma função objetivo utilizada no caso linear e um modelo não linear para o cálculo das previsões. O que se pretende, novamente, é encontrar a sequência de controle que minimize a função objetivo sujeito a um conjunto de restrições. No entanto, do ponto de vista prático, são várias as dificuldades encontradas neste problema, se comparado ao caso linear, quais sejam: a determinação do modelo do processo, quando este deve ser obtido por identificação; a obtenção do sinal de controle que requer, em geral, a solução de um problema de otimização não convexa e a análise de estabilidade e robustez da solução (Henson, 1998, Mayne et al, 2000).

Um dos métodos mais difundidos para a solução do NMPC é a utilização de modelos linearizados na predição da saída, a qual é considerada na função objetivo. Neste caso, a otimização quadrática pode ser utilizada, o que consiste na principal vantagem do método. Na literatura, encontram-se diversas abordagens para esta metodologia, tais como: a utilização de múltiplos modelos lineares, que é muito explorada para o desenvolvimento do MPC robusto (Torrico e Normey-Rico, 2004; Sakizlis et al, 2005), do MPC escalonado (Lu and Arkunl, 2003) e do MPC adaptativo; o método min-max, (Wan and Kotare, 2002) e linearização a cada período de amostragem, utilizada, por exemplo, na técnica da quasilinearização por degrau de tempo (Goodhart, et al, 1994), quasilinearização com termos de compensação (Fontes et al, 2002), NEPSAC (De Keyser, 1998), MPC Prático para sistemas não lineares - PNMPC (Plucênio, 2010), quasilinearização modificada, (Sobrinho e Fontes, 2016).

Entre os modelos não lineares utilizados para descrever as dinâmicas de um processo, encontram-se os modelos bilineares que são mais simples do que os modelos não lineares genéricos e representam o comportamento do processo melhor do que os modelos lineares. Além disso, estes modelos acomodam melhor outras dinâmicas, diferentes das dinâmicas bilineares, em comparação com os modelos lineares. (Fontes et al., 2002). A escolha de modelos bilineares para representar as dinâmicas de um processo é também devido ao fato que esses modelos são matematicamente mais fáceis de tratar do que os modelos não lineares genéricos e a bilinearidade está presente no comportamento dinâmico de muitos sistemas físicos (King e James, 1990). Convém observar ainda que o modelo bilinear é linear nos parâmetros, o que permite o uso de todas as técnicas de identificação de sistemas lineares, o que se constitui em uma importante vantagem deste tipo de modelo. Muitos controladores preditivos apresentados na literatura são baseados em modelos bilineares (Bloemen et al, 2001; Liu e Li, 2004; Sobrinho et al, 2011; Sobrinho et al, 2012). Deve-se salientar que o aperfeiçoamento em relação ao desempenho do controle preditivo baseado em modelo bilinear tem ainda seu grau de importância enfatizado, se considerarmos a abordagem que utiliza multi modelos bilineares. Nesta abordagem, que tem grande aplicação em sistemas com não linearidades acentuadas, e que operam em uma larga faixa, utilizam-se modelos bilineares em diversos pontos de operação, com o controlador preditivo bilinear ajustado para cada ponto (Fontes et al, 2007).

Neste artigo, desenvolve-se um controlador preditivo baseado em modelo bilinear descrito por variáveis de estado, o qual é linearizado utilizando-se os valores da resposta livre calculada em cada instante de amostragem. Essa linearização é semelhante àquela apresentada na quasilinearização modificada (Sobrinho e Fontes, 2016), utilizada na linearização de modelos polinomiais de entrada-

saída. Utiliza-se o algoritmo do GPC (Generalized Predictive Control), (Clark et al, 1987) para se obter a sequência de entradas de controle. A quasilinearização modificada tem origem no processo de quasilinearização por degrau de tempo (Goodhart, et al, 1994). No entanto, as modificações propostas e implementadas melhoram o desempenho de controle, como será mostrado pelos resultados de simulações realizadas em um sistema bilinear, com não linearidades bastante expressivas.

2 DESENVOLVIMENTO DO MÉTODO

O modelo a ser considerado para o desenvolvimento do controlador é da seguinte forma:

$$\begin{aligned} x(k+1) &= Ax(k) + Bu(k) + Fx(k) \otimes u(k) \\ y(k) &= Cx(k), \end{aligned} \quad (1)$$

em que: $k \in \mathbb{N}$ é o instante de tempo atual; $x \in \mathbb{R}^n$ é o vetor de estado; $u \in \mathbb{R}^p$ é o vetor de entrada; $y \in \mathbb{R}^q$ é o vetor de saída; $A \in \mathbb{R}^{n \times n}$ é a matriz de estado; $B \in \mathbb{R}^{n \times p}$ é a matriz de entrada e $C \in \mathbb{R}^{q \times n}$ é a matriz de saída. A matriz F é da forma $F = [F_1 \ F_2 \ \dots \ F_n]$, sendo $F_i \in \mathbb{R}^{n \times p}$ e $x(k) \otimes u(k)$ é o produto de Kronecker definido por:

$$x(k) \otimes u(k) = \begin{bmatrix} x_1(k)u(k) \\ x_2(k)u(k) \\ \vdots \\ x_n(k)u(k) \end{bmatrix}. \quad (2)$$

Objetivando atender o desenvolvimento do método proposto, a equação (1) é reescrita na seguinte forma:

$$x(k+1) = Ax(k) + \left[B + \sum_{l=1}^n F_l x_l(k) \right] u(k). \quad (3)$$

Fazendo: $B_x = \left[B + \sum_{l=1}^n F_l x_l(k) \right]$, obtém-se o seguinte modelo linearizado:

$$x(k+1) = Ax(k) + B_x u(k). \quad (4)$$

O termo B_x depende diretamente de $x(k)$, ou seja, depende do valor do estado no instante atual k , que é conhecido e pode ser utilizado para se obter numericamente a matriz B_x neste instante.

A predição é a essência do controlador preditivo e o desenvolvimento de um modelo preditor adequado é sempre necessário. Esse modelo preditor deve ser implementado a partir de um modelo incremental. Neste caso, assegura-se que o erro de posição, quando há rastreamento ao degrau, é

nulo. Assim, o modelo preditor será formulado a partir da equação (4) escrita na sua forma incremental, dada por:

$$\Delta x(k+1) = \Delta A x(k) + B_x \Delta u(k), \quad (5)$$

Sendo: $\Delta x(k+1) = x(k+1) - x(k)$ e $\Delta u(k) = u(k) - u(k-1)$.

A equação (5) é então reescrita na seguinte forma:

$$x(k+1) = x(k) + \Delta A x(k) + B_x \Delta u(k), \quad (6)$$

ou ainda:

$$x(k+1) = [I + \Delta A]x(k) + B_x \Delta u(k). \quad (7)$$

Para uma predição das variáveis de estado j -passos à frente o modelo preditor é dado por:

$$x(k+j) = [I + \Delta A]x(k+j-1) + B_{xi} \Delta u(k+j-1), \quad (8)$$

em que j varia de 1 até o horizonte de predição N_y . A notação B_{xi} , com $i=j-1$, expressa a dependência desta matriz com os estados futuros, que não são conhecidos. Então, para se obter B_{xi} numericamente, em cada instante de amostragem, os termos futuros $x(k+j)$, serão substituídos pelos seus respectivos valores obtidos na resposta livre, $x_{Li}(k+j)$, a qual é calculada em cada instante de amostragem. Deste modo, B_{xi} é diferente para cada horizonte de predição e também é atualizada em cada instante de amostragem. Tem-se assim, uma aproximação do modelo preditor. Deve-se observar que a predição dos estados um passo à frente, $x(k+1)$, é exata, pois não ocorre aproximação alguma, visto que, como foi mostrado na equação (4), $x(k+1)$ depende apenas de $x(k)$ que é conhecido no instante atual k . Admite-se que as variáveis de estado estão disponíveis para medição. Caso contrário, utilizar-se-ia um observador de estado de robustez e velocidade adequadamente escolhidas. Observa-se que, com a notação B_{xi} , apresentada na equação (8), a matriz B_x das equações (4) a (7), passa a ser escrita como B_{x0} .

Desta forma, tem-se uma diferenciação dos termos utilizados para se realizar a referida aproximação, ao longo do horizonte de predição, e atualizados em cada instante de amostragem k . Isto proporciona a este algoritmo uma melhor aproximação no cálculo das predições, podendo-se obter deste modo, um melhor desempenho do controlador. Convém salientar que quanto melhor a predição, ou seja, menor erro de predição, melhor o desempenho do controlador preditivo, cuja essência é a predição. Deve-se observar que, à medida que a saída do sistema se aproxima do valor de referência de controle,

a resposta livre tende para os valores de saída do sistema. Isto lineariza de forma exata o modelo preditor no ponto de operação.

A predição da saída é dada por:

$$y(k+j) = C x(k+j), \quad (9)$$

Assim, utilizando-se a equação (8), a predição um passo à frente é dada por:

$$x(k+1) = [I + A]x(k) - Ax(k-1) + B_{x0}\Delta u(k). \quad (10)$$

Para a predição dois passo à frente tem-se:

$$x(k+2) = [I + A + A^2]x(k) - [A + A^2]x(k-1) + [I + A]B_{x0}\Delta u(k) + B_{x1}\Delta u(k+1). \quad (11)$$

E a predição três passos à frente é dada por:

$$x(k+3) = [I + A + A^2 + A^3]x(k) - [A + A^2 + A^3]x(k-1) + [I + A + A^2]B_{x0}\Delta u(k) + [I + A]B_{x1}\Delta u(k+1) + B_{x2}\Delta u(k+2). \quad (12)$$

Assim, utilizando-se a equação de saída pode-se generalizar o modelo preditor j-passos à frente na seguinte forma:

$$Y = \Phi x(k) - \Gamma x(k-1) + \Theta_{xi} \Delta U, \quad (13)$$

sendo:

$$\Phi = \begin{bmatrix} C(I+A) \\ C(I+A+A^2) \\ C(I+A+A^2+A^3) \\ \vdots \\ C \sum_{j=0}^{N_y} A^j \end{bmatrix}_{(qN_y) \times (n)}; \quad \Gamma = \begin{bmatrix} CA \\ C(A+A^2) \\ C(A+A^2+A^3) \\ \vdots \\ C \sum_{j=1}^{N_y} A^j \end{bmatrix}_{(qN_y) \times (n)};$$

$$\Theta_{xi} = \begin{bmatrix} CB_0 & 0 & 0 & \dots & 0 \\ C(I+A)B_0 & CB_1 & 0 & \dots & 0 \\ C(I+A+A^2)B_0 & C(I+A)B_1 & CB_2 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ C \sum_{j=0}^{N_y-1} A^j B_0 & C \sum_{j=0}^{N_y-2} A^j B_1 & C \sum_{j=0}^{N_y-2} A^j B_2 & \dots & CB_{N_y-1} \end{bmatrix}.$$

A resposta livre e a resposta forçada podem escritas de forma independentes. A resposta livre é dada por:

$$Y_L = \Phi x(k) - \Gamma x(k-1). \quad (14)$$

E a resposta forçada é dada por:

$$Y_F = \Theta_{xi} \Delta U. \quad (15)$$

Observa-se que o modelo preditor obtido é linear em cada instante de amostragem. Isto permite que se utilize o algoritmo do GPC, uma vez que o mesmo foi desenvolvido para modelos lineares. Vale lembrar que a estratégia dos controladores preditivos utiliza o modelo da planta, em cada instante de amostragem, para realizar as previsões.

O objetivo do GPC é minimizar futuros desvios da saída do processo em relação à referência. Essencialmente, esse algoritmo tenta minimizar a seguinte função custo:

$$J(k) = \sum_{j=1}^{N_y} \|y(k+j) - T_r(k+j)\|^2 Q + \sum_{j=0}^{N_u-1} \|\Delta u(k+j)\|^2 R, \quad (16)$$

sendo:

N_y , $y(k+j)$ e Δu , como já definidas previamente;

N_u é o horizonte de controle;

T_r é a trajetória de referência;

$Q_{(qN_y) \times (qN_y)}$ é a matriz de ponderação do erro de rastreamento;

$R_{(pN_u) \times (pN_u)}$ é a matriz de ponderação do sinal de controle.

Por simplicidade, utilizou-se neste trabalho $Q=I$ e $R = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$, sendo λ_i os parâmetros de sintonia.

A solução do algoritmo GPC fornece a sequência do sinal de controle, $u(k), u(k+1), \dots, u(k+N_u-1)$, que minimiza a função objetivo J . É a solução analítica para o caso sem restrições. Esta solução é dada por (Maciejowski, 2012):

$$\Delta U = (\Theta_x^T Q \Theta_x + R)^{-1} \Theta_x^T Q E, \quad (17)$$

sendo E o vetor de erro, definido como a diferença entre a trajetória de referência e a resposta livre, dado por:

$$E = T_r - Y_L = T_r - (\Phi x(k) - \Gamma x(k-1)). \quad (18)$$

De acordo com o princípio do horizonte móvel, somente o primeiro elemento de ΔU é aplicado, e no próximo instante de amostragem, toda a sequência é recalculada.

A aproximação das predições pela resposta livre conduz, obviamente, a uma predição subótima. Contudo, deve-se observar que este é um artifício interessante, visto que, na formulação da lei de controle do *GPC*, a minimização da função objetivo J , leva em conta a diferença entre a trajetória de referência T_r e a resposta livre como pode ser verificado pelas Equações (17) e (18).

3 RESULTADOS DE SIMULAÇÃO

Seja uma planta descrita pelo seguinte modelo SISO bilinear de segunda ordem:

$$\begin{bmatrix} x_1(k+1) \\ x_2(k+1) \end{bmatrix} = \begin{bmatrix} 0.8 & -0.2 \\ 0 & 0.6 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \end{bmatrix} u(k) + \begin{bmatrix} 4 & 6 \\ 5 & 7 \end{bmatrix} \left(\begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} \otimes u(k) \right) \quad (19)$$

$$y(k) = \begin{bmatrix} 1 & 1 \end{bmatrix} x(k).$$

Este sistema possui não linearidades bastante expressivas, como pode ser observado pelos valores dos coeficientes bilineares e pelos resultados de simulação que apresentaram grande variação de ganho estático e de comportamento dinâmico. Para se efetuar o controle deste sistema hipotético, foram projetados os controladores quasilinear em variáveis de estado, conforme descrito em Sobrinho et al, (2011) e o quasilinear modificado aqui proposto. Os controladores foram sintonizados com o horizonte de predição $N_y=4$. Em seguida, foi sintonizado a ponderação na ação de controle, λ , diminuindo-se o máximo possível para se obter um menor tempo de estabelecimento, assegurando-se a estabilidade do sistema em malha fechada. Como já era esperado, o esforço de controle foi sempre muito grande. Por se tratar de um caso teórico, não foram impostas restrições, visto que no caso real se consideraria as limitações do atuador. Para o controlador quasilinear, o menor valor possível foi $\lambda = 290$. Para o controlador quasilinear modificado foi possível sintonizar com qualquer valor de $\lambda > 0$, sendo utilizado $\lambda = 0,01$. Os resultados da simulação são apresentados nas Figuras 1 e 2. Na Figura 1 observa-se um melhor desempenho do controlador quasilinear modificado, o qual reduziu em cerca de 38% o tempo de estabelecimento.

Observa-se que o esforço de controle, no caso do algoritmo proposto, é ligeiramente maior, conforme é mostrado na Figura 2. Isto é devido ao fato que, neste caso, as predições são provavelmente mais precisas em virtude da melhoria do modelo utilizado na predição.




Figura 1. Saída do sistema controlado pelos controladores quasilinear e quasilinear modificado




Figura 2. Esforço de controle para as saídas mostradas na Fig. 1.

Para se avaliar quantitativamente o desempenho de cada controlador, utilizou-se o índice de desempenho de Goodhart (Goodhart *et al*, 1994). Este índice é composto por três parcelas:

1) O esforço de controle médio total realizado para se atingir uma dada resposta, representado por:

$$\varepsilon_1 = \frac{\sum_{k=1}^T \Delta u_i(k)}{T}, \quad (20)$$

em que T é um número inteiro que representa a quantidade de ações de controle, tomadas para se obter a resposta desejada;

2) A variância do sinal de controle em torno da média, dada por:

$$\varepsilon_2 = \frac{\sum_{k=1}^T (\Delta u_i(k) - \varepsilon_{1,i})^2}{T}, \quad (21)$$

3) O desvio total com relação ao valor da referência desejada, dado por:

$$\varepsilon_3 = \frac{\sum_{k=1}^T |r_i(k) - y_i(k)|}{T}, \quad (22)$$

em que $r(k)$ é o valor da referência. Deve-se observar que o índice ε_3 influencia diretamente na qualidade do produto a ser obtido, tendo grande importância na análise qualitativa do processo. Esses valores foram normalizados, dividindo-se pelo valor máximo da grandeza correspondente, para torná-los adimensional, obtendo-se os ε_{in} . O índice de desempenho normalizado é então dado por:

$$\varepsilon_n = \alpha_1 \varepsilon_{1n} + \alpha_2 \varepsilon_{2n} + \alpha_3 \varepsilon_{3n}, \quad (23)$$

em que α_1 , α_2 e α_3 são os pesos atribuídos individualmente a cada índice. Adotaram-se os pesos α_1 , α_2 e α_3 como sendo 0,2, 0,3 e 0,5, respectivamente. Isto porque se objetivou dar maior importância ao cálculo do desvio com relação à referência desejada, já que na maioria dos casos essa situação está relacionada com a qualidade do produto em um processo. Na tabela 1 apresentam-se os índices de desempenho obtidos para os controladores simulados. Observa-se um melhor desempenho para o controlador aqui proposto.

Tabela1 Índices de desempenho

Controladores	ε_{1n}	ε_{2n}	ε_{3n}	ε_n
Proposto	0,023	0,0491	0,1469	0,0928
Quasilinear	0,023	0,0319	0,1920	0,1101

Em seguida, efetuou-se uma simulação variando-se a referência, a fim de se observar o desempenho do controlador proposto nestas condições de funcionamento. O controlador quasilinear modificado consegue conduzir o sistema a rastrear a referência, com a mesma sintonia sem anomalias, como está mostrado na Figura 3. O esforço de controle para esta simulação está mostrado na Figura 4. O controlador quasilinear não conseguiu realizar o controle com a mesma sintonia, pois a saída do sistema divergiu. Isso se deve, provavelmente, à deficiência do modelo preditor.




Figura 3. Saída do sistema controlado pelo controlador quasilinear modificado variando-se a referência.




Figura 4. Esforço de controle para a saída mostrada na Fig. 3.

4 CONCLUSÃO

A modificação na quasilinearização, para modelos descritos por variáveis de estado, aqui apresentada, proporcionou melhorias no desempenho do controlador, principalmente quando as não linearidades do sistema são mais expressivas. Uma diferença importante entre os controladores aqui analisados é que na abordagem com o controlador quasilinear atualizam-se os polos do modelo linearizado, a cada instante de amostragem, alterando a dinâmica inerente a esse modelo. Já na abordagem com o controlador quasilinear modificado, atualizam-se os zeros do modelo a cada instante de amostragem e também para cada horizonte de predição. Isto nos permite concluir que, tanto o ganho do modelo preditor, como também a sua dinâmica são modificadas, objetivando diminuir a distância entre o modelo real e o modelo preditor. Observou-se melhorias na optimalidade do controle, como também na estabilidade do algoritmo, quando se variou a ponderação na ação de controle, para o sistema aqui simulado. Essas melhorias foram devidas principalmente às predições mais precisas, decorrentes da atualização do modelo preditor, não somente a cada instante de amostragem, como também ao longo do horizonte de predição.

REFERÊNCIAS BIBLIOGRÁFICAS

- Allgöwer F., Findeisen R. e Nagy Z. K. (2004). Nonlinear model predictive control: from theory to application. *Journal of the Chinese Institute of Chemical Engineers*, 35(3): 299–315.
- Biegler, L. e Rawlings J. (1991). Optimization approaches to nonlinear predictive control. In *Proc.4th International Conference of Chemical Process Control*.
- Bloemen, H. H. J., van den Boom, T. J. J. e Verbruggen, H. B. (2001). An Optimization Algorithm Dedicated to a MPC Problem for Discrete Time Bilinear Models. *Proceedings of the American Control Conference*, Arlington, VA, p.2371-2381.
- Camacho, E. F. e Bordons, C. (2004). *Model Predictive Control*. Springer- Verlag, London.
- Clarke, D. W., Mohtadi, C. e Tuffs, P. S. (1987) "Generalized Predictive Control, *Automatica*, vol. 21, nº 2.
- De Keyser, R. M. C. (1998). A gentle introduction to model based predictive control. In *PADI2 International Conference on Control Engineering and Signal Processing*, Piura, Peru.
- Eaton, J. e J. Rawlings. (1990) "Feedback control of chemical process using on-line optimization techniques." *computing Chemical Engineering*, 1990; Vol. 14, pp. 469-479.
- Fontes, A. B., Maitelli, A. L. e Salazar, A. O. (2002). A new Bilinear Generalized Predictive Control Approach: Algorithm and Results. In *15th Triennial World Congress of the International Federation of Automatic Control*, Barcelona.
- Fontes A. B., Cavalcanti A. L. O. e Maitelli, A. L. (2007) "Generalized Predictive Control Based in Multivariable Bilinear Multi-Model," in *Proc. 8th International IFAC Symposium on Dynamics and Control of Process Systems*, vol. 3, jun. 2007, Cancún, México, pp. 91-96.
- Goodhart S. G., Burnham K. J. e D. James. (1994). Bilinear self-tuning control of a high temperature heat treatment plant. *IEE Procedure Control Theory Applications*. Vol. 141, No 1, pp. 12 -18.
- Henson, M. A. (1998). Nonlinear model predictive control: current status and future directions. *Computer and Chemical engineering*, 23, 187-202.
- King, J., Burnham, J. e James G. (1990). Comparison of two identification techniques for bilinear systems, *Control and Computation*, Vol. 18, nº.1, pp. 428.
- Liu, G. Z. e Li, P. (2004). Generalized Predictive Control for a Class of Bilinear Systems. *IFAC 7th Symposium on Advanced Control of Chemical Processes*, Hong Kong, China, p.952-956.
- Lu, Y. e Arkunl, Y. A. (2003). Practical multiple model adaptive strategy for single-loop mpc. *Control Engineering Practice*, 11:141–159.
- Maciejowski, J. M. (2002). *Predictive control with constraints*. Pearson Education Limited. England.
- Mayne, D. Q., Rawlings, J. B., Rao, C. V. e Sokaert, P. O. M. (2000). Constrained model predictive control: Stability and optimality. *Automatica*, 36, 789–814.

Plucênio A. Desenvolvimento de Técnicas de Controle Não-linear para Elevação de Fluidos Multifásicos. (2010). Tese de Doutorado em Engenharia Elétrica, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, Brasil.

Qin, S. J. e Badgwell T. A. (2003). A Survey of Industrial Model Predictive Control technology. Control Eng. Practice 11, 733–764.

Richalet J., Rault A., Testud I. L. e Pappon J., Model Predictive Heuristic Control: Applications to Industrial Processes, Automatica, Vol.14, 413-418, 1978.

Richalet, J. Industrial Applications of Model Based Predictive Control. Automatica, 1993; 29(5):1951-1274.

Sakizlis, V., Manthanwar, A. M. e Pistikopoulos, E. N. (2005). Robust parametric predictive control design for polytopically uncertain systems. American Control Conference.

Sobrinho, M. O. S., Fontes, A. B. e Dórea, C. E. T. (2011). A New Algorithm for Bilinear Predictive Control. In 9th IEEE International Conference on Control and Automation. Santiago, Chile.

Sobrinho, M. O. S., Fontes, A. B. e Dórea, C. E. T. (2012). Desenvolvimento de um Controlador Preditivo Não Linear Baseado em Modelo Compensado Aplicado a uma Coluna de Destilação Simulada, Caracterizada por um Modelo NARMAX. XIX Congresso Brasileiro de Automática, Campina Grande, PB.

Sobrinho, M. O. S. e Fontes, A. B.. (2016). Desenvolvimento e Avaliação de um Controlador Preditivo Não Linear Baseado em Modelo Quasilinear Modificado XXI Congresso Brasileiro de Automática, Vitória, ES.

Torrico, B. C. e Normey-Rico, J. E. (2004). Controle Preditivo de Sistemas Não Lineares com Atraso, XV Congresso Brasileiro de Automática.

Wan, Z. e Kotare, M. V. (2002). Robust output feedback model predictive control using off-line linear matrix inequalities. Journal of Process Control 12, 763-774.

ENGENHARIA DE CONTROLE E AUTOMAÇÃO: ESTUDOS FUNDAMENTAIS



conhecimentolivre.org/home



contato@conhecimentolivre.org



[editoraconhecimentolivre](https://www.instagram.com/editoraconhecimentolivre)



EDITORIA CONHECIMENTO LIVRE