



**BRUNO MIRANDA RIBEIRO DE OLIVEIRA**

**TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL PARA  
ESTIMAÇÃO DE SINAIS DE OSCILAÇÃO DE EIXO EM  
HIDROGERADORES**

**LAVRAS – MG  
2023**

**BRUNO MIRANDA RIBEIRO DE OLIVEIRA**

**TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL PARA ESTIMAÇÃO DE  
SINAIS DE OSCILAÇÃO DE EIXO EM HIDROGERADORES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas de Automação, área de concentração em Sistemas Inteligentes, para a obtenção do título de Mestre.

Prof. DSc. Daniel Augusto Pereira  
Orientador

**LAVRAS – MG  
2023**

Para citar este documento:

OLIVEIRA, Bruno Miranda Ribeiro de. **Técnicas de inteligência computacional para estimação de sinais de oscilação de eixo em hidrogeradores**. Dissertação (Mestrado em Engenharia de Sistemas de Automação – área de concentração em Sistemas Inteligentes). Lavras, 2023.

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Oliveira, Bruno Miranda Ribeiro de.

Técnicas de inteligência computacional para estimação de sinais de oscilação de eixo em hidrogeradores. / Bruno Miranda Ribeiro de Oliveira. - 2022.

111 p. : il.

Orientador(a): Daniel Augusto Pereira.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2022.

Bibliografia.

1. Hidrogeradores. 2. Inteligência computacional. 3. Regressão linear e não-linear. I. Pereira, Daniel Augusto. II. Título.

A reprodução e a divulgação total ou parcial deste trabalho são autorizadas, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

**BRUNO MIRANDA RIBEIRO DE OLIVEIRA**

**TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL PARA ESTIMAÇÃO DE  
SINAIS DE OSCILAÇÃO DE EIXO EM HIDROGERADORES**

**COMPUTATIONAL INTELLIGENCE TECHNIQUES FOR ESTIMATION OF  
SHAFT OSCILLATION SIGNS IN HYDROGENERATORS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas de Automação, área de concentração em Sistemas Inteligentes, para a obtenção do título de Mestre.

APROVADA em 15 de Dezembro de 2022.

Prof. DSc. Danton Diego Ferreira	UFLA
Prof. DSc. Paulo Cezar Monteiro Lamin Filho	UFSJ
Prof. DSc. Daniel Augusto Pereira	UFLA



Prof. DSc. Daniel Augusto Pereira  
Orientador

**LAVRAS – MG  
2023**

*Dedico esse trabalho ao meu filho Pedro, à  
minha esposa e aos meus pais.*

## AGRADECIMENTOS

Sou grato.

Grato à minha esposa, que me apoiou e me inspirou para a realização deste trabalho.

Aos meus pais, que sempre me apoiaram mesmo à distância.

Grato ao meu orientador Daniel, que me ajudou neste processo.

Ao programa de Pós-Graduação em Engenharia de Sistemas de Automação, área de concentração em Sistemas Inteligentes.

E, acima de tudo, sou grato à Deus, por toda a força que me foi conferida para seguir em frente.

Muito obrigado!

*“É difícil pensar em uma grande indústria que não será transformada pela inteligência artificial. Isso inclui saúde, educação, meios de transporte, varejo, comunicações e agricultura. Existem caminhos surpreendentemente claros para a IA fazer uma grande diferença em todas essas indústrias.”*

*(Andrew Ng)*

## RESUMO

Apresentam-se, neste trabalho, as técnicas de inteligência computacional para a regressão de oscilação do eixo dos hidrogeradores e comparação com os métodos por meio de análises estatísticas. Com o aumento contínuo da demanda por energia elétrica no Brasil, e a busca por produtores de energia para o aumento da disponibilidade desta, propôs-se a redução das “paradas não programadas”, decorrentes de falhas. É de interesse a falha de componentes mecânicos, em relação ao mancal dos grupos hidrogeradores, que pode ser identificada pelo aumento dos níveis de “oscilação do eixo” em relação ao mancal. Os sinais de oscilação podem ser adquiridos (obtidos e registrados) pela instrumentação instalada na unidade geradora, e armazenados pelo sistema digital da usina. Com base em valores de normas, é possível verificar se a unidade hidrogeradora continuará operando de forma confiável, sem riscos de falhas e eventuais acidentes. Neste trabalho, dados reais de uma unidade geradora, localizada no Brasil, foram aplicados para a comparação de técnicas de inteligência computacional, por meio de simulações realizadas no ambiente MATLAB, e comparados entre si.

**Palavras-chave:** Hidrogeradores. Vibrações. Inteligência Computacional. Regressão Linear. Regressão Não Linear. Redes Neurais.



## ABSTRACT

This work presents computational intelligence techniques for hydro generator axis oscillation regression and comparison with methods through statistical analysis. With the continuous increase in demand for electricity in Brazil and the search for energy producers to increase availability, the reduction of "unplanned outages" resulting from failures was proposed. The failure of mechanical components in relation to the bearing of the hydro generator groups, which can be identified by the increase in "axis oscillation" levels in relation to the bearing, is of interest. The oscillation signals can be acquired (obtained and recorded) by the instrumentation installed in the generator unit and stored by the digital system of the plant. Based on standard values, it is possible to verify if the hydro generator unit will continue to operate reliably without the risk of failure and potential accidents. In this work, actual data from a generator unit located in Brazil were applied to compare computational intelligence techniques through simulations performed in the MATLAB environment and compared with each other.

**Keywords:** Hydro generator. Vibrations. Computational Intelligence. Linear Regression. Nonlinear Regression. Neural Networks.

## LISTA DE FIGURAS

Figura 1 – Corte usina hidrelétrica. ....	20
Figura 2 – Sensor de proximidade (proxímetro). ....	21
Figura 3 – Sensor de aceleração (acelerômetro).....	22
Figura 4 – Sensor de velocidade (velocímetro). ....	22
Figura 5 – Sensor de entreferro. ....	23
Figura 6 – Sensor de temperatura. ....	23
Figura 7 – Aquisição de sinais.....	26
Figura 8 – Aquisitor de sinais.....	26
Figura 9 – Sinal típico. ....	27
Figura 10 – Neurônio artificial. ....	32
Figura 11 – Perceptron Multicamadas.....	33
Figura 12 – RBR.....	34
Figura 13 – GRNN. ....	34
Figura 14 – K-Fold. ....	37
Figura 15 – Base original: parte 1. ....	39
Figura 16 – Base original: parte 2. ....	39
Figura 17 – Base original: parte 3. ....	40
Figura 18 – Base original: parte 4. ....	40
Figura 19 – Base original: parte 5. ....	41
Figura 20 – Resumo da operação. ....	41
Figura 21 – Ilustração da base em Excel. ....	42
Figura 22 – Algoritmo. ....	42
Figura 23 – Início. ....	43
Figura 24 – Leitura de dados. ....	43
Figura 25 – Retirada de outliers: método grubs e normalização. ....	44
Figura 26 – Diminuição dos sinais: correlação de Person.....	44
Figura 27 – Seleção da quantidade de folds para o método de validação K-Fold.....	45
Figura 28 – Rede MVS.....	45
Figura 29 – Rede Mínimos Quadrados.....	46
Figura 30 – Rede GRNN. ....	46
Figura 31 – Rede Perceptron Multicamadas.....	47
Figura 32 – Rede RB. ....	48

Figura 33 – Resultados salvos. ....	48
-------------------------------------	----

## LISTA DE TABELAS

Tabela 1 – MVS UG01.....	50
Tabela 2 – MVS UG02.....	50
Tabela 3 – MVS UG03.....	50
Tabela 4 – MVS UG04.....	51
Tabela 5 – MVS UG05.....	51
Tabela 6 – MQ UG01.....	53
Tabela 7 – MQ UG02.....	53
Tabela 8 – MQ UG03.....	53
Tabela 9 – MQ UG04.....	54
Tabela 10 – MQ UG05.....	54
Tabela 11 – GNRR UG01.....	56
Tabela 12 – GNRR UG02.....	56
Tabela 13 – GNRR UG03.....	56
Tabela 14 – GNRR UG04.....	57
Tabela 15 – GNRR UG05.....	57
Tabela 16 – PMC UG01.....	59
Tabela 17 – PMC UG02.....	59
Tabela 18 – PMC UG03.....	59
Tabela 19 – PMC UG04.....	60
Tabela 20 – PMC UG05.....	60
Tabela 21 – RNBR UG01.....	62
Tabela 22 – RNBR UG02.....	62
Tabela 23 – RNBR UG03.....	62
Tabela 24 – RNBR UG04.....	63
Tabela 25 – RNBR UG05.....	63
Tabela 26 – EQM UGs.....	65
Tabela 27 – R-quadrado absoluto UGs.....	66
Tabela 28 – Desvio Padrão UGs.....	67

## LISTA DE GRÁFICOS

Gráfico 1 – MVS UGs. ....	52
Gráfico 2 – MQ UGs. ....	55
Gráfico 3 – GNRR UGs. ....	58
Gráfico 4 – PMC UGs. ....	61
Gráfico 5 – RNBR UGs. ....	64
Gráfico 6 – EQM UGs. ....	65
Gráfico 7 – R-quadrado absoluto UGs. ....	66
Gráfico 8 – Desvio Padrão UGs. ....	67

## LISTA DE SIGLAS

AD	Análise Discriminante
ANFIS	<i>Adaptive-network-based Fuzzy Inference System</i>
CART	Árvores de Regressão e Classificação
CSV	<i>Comma-separated Values</i>
DP	Desvio Padrão
EQM	Erro Quadrático Médio
GRNN	<i>General Regression Neural Network</i>
IC	Inteligência Computacional
MLP	<i>Multi Layer Perceptron</i>
MMO	Mínimos Quadrados Ordinários
MMQ	Método dos Mínimos Quadrados
MQ	Mínimos Quadrados
MSE	<i>Mean Squared Error</i>
MVS	Máquina de Vetor Suporte
OLS	<i>Ordinary Least Squares</i>
O&M	Operação e Manutenção
PMC	Perceptron Multicamadas
RBF	Funções de Base Radial
RBFN	<i>Radial Basis Functions Networks</i>
RBR	Rede de Base Radial
RL	Regressão Logística
RMS	<i>Room Mean Square</i>
RM	Regressões Múltiplas
RNA	Redes Neuras Artificiais
RNBR	Rede Neural de Base Radial
RNRG	Rede Neural de Regressão Generalizada
SCG	Gradiente Conjugado Escalonado
SIF	Sistemas de Inferência Fuzzy
SVM	<i>Support Vector Machine</i>

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>17</b>
<b>2 REFERENCIAL TEÓRICO .....</b>	<b>19</b>
<b>2.1 Hidrelétricas.....</b>	<b>19</b>
<b>2.2 Sistema de monitoramento de vibrações .....</b>	<b>20</b>
<b>2.3 Instrumentação .....</b>	<b>21</b>
<b>2.3.1 Sensor indutivo de proximidade.....</b>	<b>21</b>
<b>2.3.2 Sensor de aceleração e velocidade.....</b>	<b>21</b>
<b>2.3.3 Sensor de entreferro .....</b>	<b>22</b>
<b>2.3.4 Sensor de temperatura .....</b>	<b>23</b>
<b>2.4 Aquisição e processamento do sinal .....</b>	<b>25</b>
<b>2.5 Inteligência Computacional (IC) para Regressão.....</b>	<b>27</b>
<b>2.6 Técnicas de regressão lineares.....</b>	<b>30</b>
<b>2.6.1 Máquina de Vetor Suporte .....</b>	<b>31</b>
<b>2.6.2 Mínimos Quadrados .....</b>	<b>31</b>
<b>2.7 Técnicas de regressão não lineares.....</b>	<b>31</b>
<b>2.7.1 Redes neurais artificiais .....</b>	<b>31</b>
<b>2.7.1.1 Rede do tipo PMC ou MLP .....</b>	<b>33</b>
<b>2.7.1.2 Rede do tipo RBR .....</b>	<b>33</b>
<b>2.7.1.3 Rede do tipo GRNN.....</b>	<b>34</b>
<b>2.8 Métricas de avaliação .....</b>	<b>35</b>
<b>2.8.1 Erro Quadrático Médio (EQM) .....</b>	<b>35</b>
<b>2.8.2 R-quadrado absoluto.....</b>	<b>35</b>
<b>2.8.3 Desvio Padrão .....</b>	<b>36</b>
<b>2.9 Validação cruzada: K-Fold.....</b>	<b>36</b>
<b>3 METODOLOGIA.....</b>	<b>38</b>
<b>3.1 Banco de dados.....</b>	<b>38</b>
<b>3.1.1 Pré-processamento manual.....</b>	<b>38</b>
<b>3.2 Sequência do algoritmo .....</b>	<b>42</b>
<b>3.2.1 Códigos: início.....</b>	<b>43</b>
<b>3.2.2 Códigos: leitura de dados.....</b>	<b>43</b>
<b>3.2.3 Códigos: retirada de outliers usando o método de grubs e normalização.....</b>	<b>43</b>
<b>3.2.4 Códigos: diminuição dos sinais usando a correlação de Person.....</b>	<b>44</b>

3.2.5 Códigos: seleção da quantidade de folds para o método de validação cruzada = 5 do tipo K-Fold .....	45
3.2.6 Códigos: rede MVS (Máquina de Vetor Suporte) .....	45
3.2.7 Códigos: Rede Mínimos Quadrados .....	46
3.2.8 Códigos: Rede GRNN.....	46
3.2.9 Códigos: Rede Perceptron Multicamadas (PMC) .....	47
3.2.10 Códigos: Rede RB.....	48
3.2.11 Códigos: resultados salvos .....	48
4 RESULTADOS .....	49
4.1 Resultados individuais.....	49
4.1.1 Resultados Máquina de Vetor Suporte (MVS) .....	49
4.1.1.1 Resultados MVS: UG01 .....	49
4.1.1.2 Resultados MVS: UG02 .....	50
4.1.1.3 Resultados MVS: UG03 .....	50
4.1.1.4 Resultados MVS: UG04 .....	51
4.1.1.5 Resultados MVS: UG05 .....	51
4.1.1.6 MVS: médias .....	51
4.1.2 Resultados Mínimos Quadrados (MQ).....	52
4.1.2.1 Resultados MQ: UG01 .....	52
4.1.2.2 Resultados MQ: UG02 .....	53
4.1.2.3 Resultados MQ: UG03 .....	53
4.1.2.4 Resultados MQ: UG04 .....	54
4.1.2.5 Resultados MQ: UG05 .....	54
4.1.2.6 MQ: médias .....	54
4.1.3 Resultados GNRR.....	55
4.1.3.1 Resultados GNRR: UG01 .....	55
4.1.3.2 Resultados GNRR: UG02 .....	56
4.1.3.3 Resultados GNRR: UG03 .....	56
4.1.3.4 Resultados GNRR: UG04 .....	57
4.1.3.5 Resultados GNRR: UG05 .....	57
4.1.3.6 GNRR: médias .....	57
4.1.4 Resultados PMC .....	58
4.1.4.1 Resultados PMC: UG01 .....	58
4.1.4.2 Resultados PMC: UG02 .....	59



<b>4.1.4.3 Resultados PMC: UG03</b> .....	<b>59</b>
<b>4.1.4.4 Resultados PMC: UG04</b> .....	<b>60</b>
<b>4.1.4.5 Resultados PMC: UG05</b> .....	<b>60</b>
<b>4.1.4.5 PMC: médias</b> .....	<b>60</b>
<b>4.1.5 Resultados RNBR</b> .....	<b>61</b>
<b>4.1.5.1 Resultados RNBR: UG01</b> .....	<b>61</b>
<b>4.1.5.2 Resultados RNBR: UG02</b> .....	<b>62</b>
<b>4.1.5.3 Resultados RNBR: UG03</b> .....	<b>62</b>
<b>4.1.5.4 Resultados RNBR: UG04</b> .....	<b>63</b>
<b>4.1.5.4 Resultados RNBR: UG05</b> .....	<b>63</b>
<b>4.1.5.5 RNBR: médias</b> .....	<b>63</b>
<b>4.2 Resultados compilados</b> .....	<b>64</b>
<b>4.2.1 EQM – Erro Quadrático Médio</b> .....	<b>64</b>
<b>4.2.2 R-quadrado absoluto</b> .....	<b>65</b>
<b>4.2.3 Desvio Padrão</b> .....	<b>66</b>
<b>5 CONCLUSÃO</b> .....	<b>68</b>
<b>REFERÊNCIAS</b> .....	<b>70</b>

## 1 INTRODUÇÃO

A energia elétrica é fundamental para a manutenção e desenvolvimento da sociedade humana. Além de ser utilizada para movimentar as grandes linhas de produção industrial (RIBEIRO et al., 2019), também proporciona conforto e facilidades cotidianas, movimentando a economia (FURTADO, 2004). A produção de energia elétrica é dividida em diversas fontes de geração. Elas são distribuídas por meio da matriz elétrica, sendo, em 2019, 64,9% da produção oriunda de produção hidráulica (hidrelétricas), considerada a mais importante fonte de geração (ENERGÉTICA, 2019). O aumento constante da demanda por energia elétrica no Brasil, e o baixo crescimento de oferta de novas usinas, implica a busca pelas empresas do segmento por melhorias relativas à disponibilidade das usinas já instaladas. A disponibilidade é determinada pela quantidade de tempo que uma unidade geradora está pronta para a produção de energia (produzindo ou parada), e pelo tempo total no período (TRALLI, 2018). Um fator importante para a diminuição da disponibilidade são as falhas no conjunto hidrogerador, composto pela Turbina, Gerador e Associados (ALSTOM, 1998). Uma forma de prevenir ou evitar tais falhas é por meio de monitoramento das variáveis físicas dos conjuntos (PEPA; URSONIU, 2015), adicionado de eventuais paradas para não levar às falhas.

Usinas hidrelétricas podem possuir diversos sistemas instalados em sua operação (LI; AI; SHI, 2007), sendo um deles o sistema de monitoramento de vibração. Este tem como principal finalidade reconhecer o surgimento de falhas incipientes na máquina, devendo ser capaz de fornecer informações úteis para funções de Operação e Manutenção – O&M (SILVA, 2013). O sistema utiliza a medição de variáveis do processo, por meio de sensores instalados localmente, gerando alarmes que auxiliam a tomada de decisão da equipe de O&M da usina.

Uma dificuldade encontrada no cotidiano pela equipe de O&M refere-se à impossibilidade de se trocarem alguns sensores durante a operação da unidade, devido aos sensores serem localizados e instalados no interior das unidades geradoras. Para efetivar esta troca é necessária a parada da unidade, o que aumentaria o tempo de indisponibilidade. A operação da unidade sem o monitoramento pode levar a sinistros, pois muitos componentes estão sob o efeito de vibração. De forma geral, essas influências não geram dano, porém, caso ultrapassem determinados valores, podem gerar danos irreparáveis (BARBOSA et al., 2016).

Há diversas falhas que podem ocorrer na operação dos equipamentos, provocando danos irreparáveis. Essas falhas podem ser divididas em até quatro níveis (DOEBLING; FARRAR; PRIME, 1998), ou sete níveis (INMAN, 1996). Uma das principais falhas no conjunto Turbina-Gerador refere-se à falha no mancal. Há diversos indícios que podem levar a

uma falha, citando o aumento da temperatura dos metais, óleo ou água, aumento nos níveis de vibração ou oscilação de eixo. Uma das análises realizadas é a verificação da oscilação relativa de eixo (distância entre o eixo e a estrutura fixa), conforme a norma ISO (BSI, 2018). Em sua maioria, os sensores não permitem troca durante a operação da unidade.

Considerando-se esse cenário, o objetivo desta dissertação é o de investigar técnicas de Inteligência Computacional (IC) como ferramentas para previsão de sinais de oscilação de eixo utilizando os outros sinais disponíveis na usina. O uso da regressão se dará para caso haja uma falha do instrumento de medição que não possibilita troca com a unidade geradora em funcionamento. O sistema poderá ter medição estimada, técnica também conhecida como *Softsensor* ou Sensor Virtual.

Definiram-se como objetivos específicos para este trabalho:

- a) Implementação em MATLAB de algoritmos para regressão, utilizando a aplicação das técnicas:
  - Máquina de Vetor Suporte (MVS) ou, em inglês, *Support Vector Machine* (SVM);
  - GRNN (*General Regression Neural Network*);
  - Mínimos Quadrados (MQ);
  - Redes Neurais Artificiais (RNA);
  - Perceptron Multicamadas (PMC) ou, em inglês, *Multi Layer Perceptron* (MLP);
  - RNA com neurônios do tipo Funções de Base Radial (em inglês, RBF);
- b) Realizar a validação através do método do tipo K-Fold nas cinco técnicas propostas;
- c) Comparação das cinco técnicas propostas utilizando os menores valores de erro quadrático;
- d) Definição do melhor modelo de regressão.

Organizou-se esta dissertação em partes independentes que se complementam. No Capítulo 2, traz-se o Referencial Teórico. No Capítulo 3, descrevem-se o banco de dados e metodologia. No Capítulo 4, descrevem-se quais são os resultados encontrados. No Capítulo 5, apresentam-se as conclusões para o trabalho e propostas para trabalhos futuros. Por fim, são apresentados as Referências e os Apêndices com as definições e formulações complementares.

## 2 REFERENCIAL TEÓRICO

Neste capítulo apresenta-se o referencial teórico necessário para a estruturação do trabalho, bem como uma visão inicial dos componentes de uma hidrelétrica. Na sequência, o sistema de monitoramento, seguido de seus principais componentes, com enfoque aos instrumentos mais utilizados.

Além disso, expõe-se breve explicação sobre a realização da aquisição e o processamento do sinal para uma base de dados. Nos itens posteriores, apresentam-se os principais estudos de inteligência computacional para a regressão, sua importância, e um breve detalhamento de cada método computacional que será utilizado neste trabalho. Por fim, apresentam-se as métricas estatísticas para avaliação do melhor método.

### 2.1 Hidrelétricas

Uma usina hidrelétrica é composta por:

a) Barragem:

- grande estrutura civil para represamento da água;

b) Vertedouro:

- estrutura para permitir a passagem do excesso de água represada;

c) Casa de Força:

- estrutura para comportar as unidades geradoras e diversos outros componentes auxiliares;

d) Conduto forçado:


- estrutura para direcionar a água represada à unidade hidrogeradora;

e) Transformadores elevadores:

- conjunto de equipamentos para elevar a tensão gerada pelas unidades geradoras (transformadores elevadores).

A energia gerada é, então, transmitida aos consumidores por meio de linhas de transmissão, transformadores que reduzem a tensão para níveis comparáveis com a utilizadas pelos consumidores (TRALLI, 2018). Apresenta-se, na Figura 1, um corte lateral, em que é possível observar os principais componentes de uma hidrelétrica.

Figura 1 – Corte usina hidrelétrica.



Fonte: Voith Hydro (2018).

## 2.2 Sistema de monitoramento de vibrações

Historicamente, fabricantes e usuários de máquinas elétricas utilizavam apenas mecanismos simples como proteção contra sobrecorrente e sobretensão para garantir a segurança e o bom funcionamento dos equipamentos. O crescimento da quantidade e complexidade dos processos, envolvendo máquinas elétricas, levou a inúmeros desenvolvimentos na área de diagnóstico de máquinas (CHOUDHARY et al., 2019).

A medida de vibração é utilizada para diferentes fins, como: diagnóstico da condição do equipamento, controle da vibração e detecção das principais fontes de ruído. Geralmente, a instrumentação utilizada para a aquisição de um determinado sinal possui os seguintes elementos:

- a) Transdutor e instrumentos;
- b) Condicionador de sinais;
- c) Processador de sinais;
- d) Armazenamento do sinal de dados;
- e) Display (tela do computador ou outro dispositivo).

## 2.3 Instrumentação

O objetivo proposto deste trabalho é analisar as melhores técnicas. Sendo assim, será abordado superficialmente os instrumentos utilizados no processo. Em um sistema de monitoramento há diversos sensores instalados na unidade.

### 2.3.1 Sensor indutivo de proximidade

Esse sensor é utilizado para medição de distância entre elementos estáticos (mancais) e rotativos (eixo). Conhecido como vibração relativa, o monitoramento das vibrações relativas é um dos principais parâmetros para avaliação da integridade das unidades geradoras (BSI, 2018). Na Figura 2, apresenta-se um exemplo do sensor instalado e posicionado para medição.

Figura 2 – Sensor de proximidade (proxímetro).



Fonte: Do autor (2022).

### 2.3.2 Sensor de aceleração e velocidade

Ambos os sensores de aceleração e velocidade são considerados sensores de medição absoluta, pois são independentes para sua medição e trazem uma resposta em sinal diretamente do ponto onde são instalados.

O sensor de aceleração é utilizado para medição de aceleração de elementos estáticos (estator, tubo de sucção, entre outros). Na Figura 3, apresenta-se um exemplo de sensor de aceleração instalado no pacote estatórico ou núcleo do estator de um hidrogerador.

Figura 3 – Sensor de aceleração (acelerômetro).



Fonte: Do autor (2022).

O sensor de velocidade é utilizado para medição de velocidade de vibração nos elementos estáticos (mancais) (BSI, 2018). Conforme a Figura 4 é possível verificar a instalação no suporte posicionado na tampa inferior da cuba do mancal guia do hidrogerador.

Figura 4 – Sensor de velocidade (velocímetro).




Fonte: Do autor (2022).

### 2.3.3 Sensor de entreferro

Entreferro é a distância medida entre o núcleo do estator e os polos do rotor de um gerador. Variações nas forças centrífugas, térmicas e magnéticas podem causar distorções no estator e no rotor, o que faz com que o entreferro varie com o tempo, conforme a Figura 5 (POWER, 2021).

Figura 5 – Sensor de entreferro.



Fonte: Do autor (2022).

### 2.3.4 Sensor de temperatura

O sensor de temperatura é um dispositivo de medição que detecta a temperatura a partir de uma característica física correspondente do dispositivo, através de uma resistência elétrica, um campo eletromagnético ou uma radiação térmica, sendo que a maneira como um sensor de temperatura funciona depende da propriedade física que constitui o mesmo. Os sensores que foram utilizados fazem a conversão direta de resistência para temperatura em diversas aplicações: temperatura de mancal, água, óleo, ar (WIKA, s.d.). A Figura 6 é um exemplo do sensor.

Figura 6 – Sensor de temperatura.



Fonte: Do autor (2022).



Vale ressaltar que o sensor de temperatura é um dispositivo utilizado para medir a temperatura de um objeto ou ambiente. É uma peça importante em muitas aplicações, incluindo máquinas rotativas.

Em máquinas rotativas, a temperatura é um indicador importante de desempenho e saúde. Altas temperaturas podem indicar problemas como sobrecarga, atrito excessivo ou problemas de lubrificação, enquanto baixas temperaturas podem indicar problemas como falta de energia ou mal funcionamento do sistema de resfriamento. Por isso, a monitorização da temperatura é crucial para garantir a operação segura e eficiente dessas máquinas (JAIN, 2003).

Há vários tipos de sensores de temperatura disponíveis, cada um com suas próprias vantagens e desvantagens. Alguns dos tipos mais comuns incluem termistores, RTD's (Resistência Térmica Diferencial), termopares e sensores de infravermelho. A escolha do tipo de sensor de temperatura a ser utilizado depende de fatores, como, precisão, velocidade de resposta, faixa de temperatura, custo e facilidade de instalação (JAIN, 2003).

A instalação do sensor de temperatura é outro aspecto importante a ser considerado. Em máquinas rotativas, os sensores de temperatura devem ser instalados em locais estratégicos para garantir uma medição precisa e representativa da temperatura do equipamento. É importante que o sensor seja instalado de forma a evitar interferências, como radiação térmica de outros componentes ou obstruções que possam afetar a precisão da medição (JAIN, 2003).

Além da monitorização da temperatura, os sensores de temperatura também podem ser usados para controlar a temperatura em máquinas rotativas. Por exemplo, a temperatura pode ser controlada através do ajuste da velocidade de rotação ou da quantidade de lubrificante usada, ou pode ser usada para acionar sistemas de resfriamento quando a temperatura atinge um determinado nível crítico (JAIN, 2003).

Em resumo, o sensor de temperatura é uma peça importante em máquinas rotativas, permitindo a monitorização e o controle da temperatura do equipamento. É importante escolher o tipo certo de sensor e instalá-lo corretamente para garantir uma medição precisa e representativa.

## 2.4 Aquisição e processamento do sinal

A aquisição de sinais e o processamento de sinais são fundamentais em Sistemas de Monitoramento para Máquinas Rotativas. Esses sistemas permitem coletar, armazenar e analisar informações sobre o desempenho dessas máquinas, fornecendo uma visão valiosa sobre sua operação e saúde (KRISHNAN, 2009; HAYKIN, 2002; LIU, 2011).

A aquisição de sinais envolve a captura de dados sobre as máquinas rotativas, como velocidade, temperatura, tensão e corrente elétrica. Esses dados são capturados por sensores específicos e enviados para um sistema de aquisição de dados, onde são convertidos em sinais digitais para processamento e análise posterior.

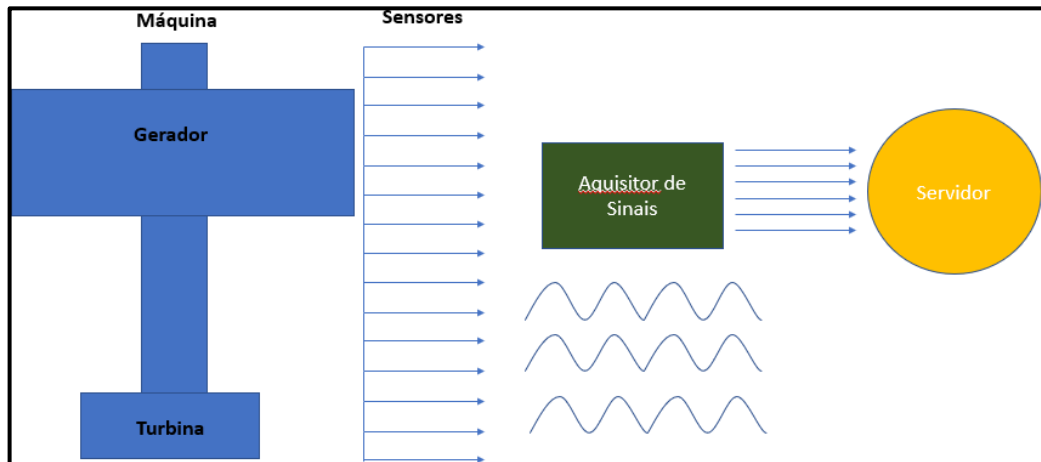
Já o processamento de sinais envolve a análise dos sinais capturados para extrair informações relevantes sobre o desempenho da máquina. Isso pode incluir a detecção de padrões anormais, a estimativa de parâmetros importantes, como a temperatura crítica, e a identificação de falhas iminentes. Alguns exemplos de técnicas de processamento de sinais comumente usadas em sistemas de monitoramento para máquinas rotativas incluem análise de espectro, detecção de falhas baseada em *wavelets* e modelagem estatística.

A combinação de aquisição de sinais e processamento de sinais permite aos sistemas de monitoramento para máquinas rotativas fornecer informações valiosas sobre o desempenho dessas máquinas, ajudando a identificar problemas antes que causem danos irreparáveis ou interrupções na produção. Isso permite aos operadores tomar medidas proativas para garantir a operação segura e eficiente dessas máquinas (KRISHNAN, 2009; HAYKIN, 2002; LIU, 2011).

Em resumo, a aquisição de sinais e o processamento de sinais são componentes críticos em Sistemas de Monitoramento para Máquinas Rotativas. Juntos, eles permitem coletar e analisar informações valiosas sobre o desempenho dessas máquinas, ajudando a identificar problemas e garantir sua operação segura e eficiente (KRISHNAN, 2009; HAYKIN, 2002; LIU, 2011).

Após a apresentação dos principais modelos de sensores, e suas aplicações, será abordado o equipamento responsável por aquisitar os sinais recebidos de forma analógica e processá-los para posterior arquivamento.


Figura 7 – Aquisição de sinais.



Fonte: Do autor (2022).

Na Figura 7, apresenta-se um sistema de aquisição de sinais, em que os instrumentos instalados na unidade são conectados eletricamente por cabos a um aquisição de sinais (Figura 8). Esses sinais são processados digitalmente, para que os valores no tempo saiam em valores unitários.


Figura 8 – Aquisitor de sinais.



Fonte: Do autor (2022).

Um sinal típico é apresentado na Figura 9 e o aquisição consegue entregar vários tipos de valores processados. Os principais são pico a pico e valor médio eficaz (RMS – *Root Mean Square*). Após o processamento, esses valores são inseridos em um banco de dados SQL, em que é possível acessá-los por meio do software específico SQL Express, e exportado em CSV.

Figura 9 – Sinal típico.



Fonte: Braga (2012).

## 2.5 Inteligência Computacional (IC) para Regressão

A Inteligência Computacional é uma área de estudo que se concentra em desenvolver algoritmos e técnicas para resolver problemas complexos de forma automatizada. Na indústria, as técnicas de inteligência computacional têm sido amplamente utilizadas em vários setores, incluindo a análise de dados, previsão de demanda e modelagem de processos.

Uma dessas técnicas é a Regressão, que é amplamente utilizada para estabelecer relações entre variáveis quantitativas e prever valores futuros. É uma técnica estatística que permite modelar uma função matemática que descreve a relação entre uma variável dependente e uma ou mais variáveis independentes (HASTIE, TIBSHIRANI; FRIEDMAN, 2009; HAND; MANILLA; SMYTH, 2001; MARSLAND, 2015).

Na indústria, as técnicas de Regressão são amplamente utilizadas em vários setores, incluindo a previsão de vendas, a análise de tendências de preços e a modelagem de processos. Por exemplo, elas podem ser usadas para prever o consumo de energia em uma fábrica, a demanda de um produto ou a produção de petróleo em uma mina (HASTIE, TIBSHIRANI; FRIEDMAN, 2009; HAND; MANILLA; SMYTH, 2001; MARSLAND, 2015).

Algumas das técnicas de inteligência computacional utilizadas na Regressão incluem Redes Neurais Artificiais, Árvores de Decisão e Algoritmos Genéticos. Cada técnica tem suas próprias vantagens e desvantagens, e a escolha da técnica adequada depende do problema específico que se deseja resolver.

Em suma, as técnicas de Inteligência Computacional para Regressão são amplamente utilizadas na indústria para estabelecer relações entre variáveis quantitativas e prever valores

futuros. Essas técnicas incluem Redes Neurais Artificiais, Árvores de Decisão e Algoritmos Genéticos, e sua escolha depende do problema específico que se deseja resolver (HASTIE, TIBSHIRANI; FRIEDMAN, 2009; HAND; MANILLA; SMYTH, 2001; MARSLAND, 2015).

Após a apresentação da hidrelétrica como um todo, o sistema de monitoramento, os principais instrumentos e sua aquisição, serão abordadas algumas das técnicas estatísticas tradicionais mais utilizadas para problemas de predição e classificação, que são: as Regressões Múltiplas (RM); Análise Discriminante (AD); e a Regressão Logística (RL), devido à sua metodologia já estabelecida. As técnicas de IC têm ganhado popularidade como métodos alternativos às técnicas tradicionais, o que levou à vários estudos, em comparação a tais abordagens em uma grande variedade de aplicações (LIMA, 2018).

Nesta seção, mostra-se uma breve revisão de alguns trabalhos nas comparações técnicas de IC.

Na área de contabilidade e finanças, o trabalho de Duliba (1991) compara modelos RNA treinados pelo algoritmo Mínimo Erro Quadrado (WIDROW; HOFF, 1989) com quatro tipos de modelos de regressão, para predizer o desempenho financeiro de um grupo de companhias de transporte. Em seu trabalho, os modelos RNA foram capazes de superar os efeitos aleatórios dos modelos de regressão, mas não os efeitos fixos.

Seguindo a área financeira, o trabalho de Malaman e Amorim (2017) refere-se à testagem de utilização da lógica *fuzzy* como uma alternativa para a avaliação de imóveis, propondo um novo método para modelar o mercado imobiliário. Além disso, possibilita a comparação dos resultados obtidos, utilizando a lógica *fuzzy*, com os resultados apresentados pelo método tradicional que, na maioria dos casos, é feito por regressão linear. A comparação entre os métodos mostrou melhores resultados para o modelo de regressão. No entanto, o modelo *fuzzy* mostrou ter um bom potencial para a avaliação de imóveis.

Na área da saúde e medicina, Razi e Athappilly (2005) realizaram uma análise comparativa da acurácia de predição de modelos de redes neurais, regressão não linear e Árvores de Regressão e Classificação (CART), por meio de uso de um grande conjunto de dados sobre hábitos de fumantes para predizer o número de dias de cama devido à doença. Os modelos RNA e CART obtiveram as melhores predições em comparação aos de regressão, quando os preditores eram variáveis binárias (ou categóricas) e a variável dependente era contínua. Entretanto, nem as RNAs, nem os modelos CART, mostraram vantagens claras de um sobre o outro. Para essa aplicação, ambos os modelos podem ser usados para predição e devem fornecer resultados mais acurados em relação à regressão.

Gu, Lam, Dhurjati (1996) usaram Regressão Quadrática para comparar os resultados de redes neurais em relação ao melhoramento da eficiência para o desenvolvimento de processos de fermentação. Seus resultados mostraram que diferentes tamanhos de redes neurais, dentro de um intervalo, obtiveram previsões igualmente boas, usando a técnica da Parada Antecipada, enquanto as regressões quadráticas são sensíveis ao tamanho do conjunto de dados.

Yilmaz e Kaynar (2011) utilizaram redes PMC, RBF e ANFIS para previsão do potencial de inchaço em solos argilosos em comparação com modelos baseados em RM. Seus resultados revelaram que as redes neurais obtiveram acurácia semelhante aos modelos ANFIS, porém as redes RBF obtiveram um desempenho superior a PMC, ANFIS e RM. Os autores concluíram que o uso de IC é uma boa ferramenta para minimizar as incertezas nos projetos de engenharia do solo.

O uso de redes neurais em marketing está associado, principalmente, à estimativa de preço e elasticidades de publicidade, bem como, de forma mais geral, à previsão dos efeitos das mudanças nas variáveis de marketing. Hruschka (1993) compara a previsão da resposta do mercado com base em dados sobre uma marca de consumo e funções de resposta do mercado representadas por redes neurais artificiais com modelos econométricos, principalmente com apenas uma unidade escondida em comparação aos modelos de regressão. Entretanto, ele reportou que, talvez, o treinamento das redes neurais estivessem com problema de *overfitting*.

Dutta, Shekhar e Wong (1994) usaram redes neurais para prever a frequência de compra de um produto e seus resultados não foram encorajadores, com apenas uma rede sendo capaz de superar os modelos de regressão em um conjunto de 14 modelos treinados.

O trabalho de Wang e Al-Hashimi (2012) buscou investigar as capacidades de previsão e estimação de modelos ANFIS e de regressão não linear. Os autores utilizaram dez conjuntos de dados não lineares com diferentes formas e tamanhos e os resultados apontaram que o método ANFIS foi, praticamente, perfeito para a estimação, enquanto, para previsão, os modelos não lineares obtiveram um desempenho levemente superior.

No trabalho de Lima (2018), foram desenvolvidos modelos capazes de estimar os requerimentos energéticos do gado bovino, uma das bases para a elaboração de dietas eficientes para os animais. Foram desenvolvidas nesse trabalho técnicas baseadas em Redes Neurais Artificiais (RNA) e Sistemas de Inferência Fuzzy (SIF), alicerces da IC, como alternativas aos métodos clássicos. As técnicas abordadas foram: Redes Perceptron Multicamadas (PMC) com treinamento *backpropagation* baseado no algoritmo Gradiente Conjugado Escalonado (SCG), Rede Neural de Regressão Generalizada (RNRG) e Sistemas

de Inferência Neuro-Fuzzy Adaptativos (ANFIS).

No trabalho de Detmann et al. (2012), objetivou-se propor e discutir um método de avaliação comparativa da eficiência de conversão do alimento em produto entre dois grupos experimentais de bovinos de corte, baseado na utilização de técnicas de regressão. A avaliação dos dados e os métodos propostos e discutidos foram desenvolvidos utilizando-se técnicas de regressão linear (DRAPER; SMITH, 2014) e não linear (BRUBAKER, 1979; SOUZA, 2008). Os ajustamentos de modelos de regressão linear basearam-se no método dos mínimos quadrados ordinários e os de modelos de regressão não linear basearam-se no método de mínimos quadrados não lineares com o uso do algoritmo iterativo de Gauss-Newton.

Seguindo o referencial, será exposta, brevemente, cada técnica que será utilizada neste trabalho para as comparações a respeito delas.

## **2.6 Técnicas de regressão lineares**

As técnicas de regressão linear são uma categoria de modelos estatísticos que permitem estimar uma variável dependente a partir de uma ou mais variáveis independentes. Esses modelos são amplamente utilizados em muitas áreas, incluindo a análise de dados em máquinas rotativas.

As máquinas rotativas são complexas e apresentam muitos parâmetros que afetam o seu funcionamento. Por exemplo, a vibração, a temperatura, a tensão, entre outros, são variáveis que podem afetar o desempenho da máquina e precisam ser monitoradas e controladas. As técnicas de regressão linear são usadas para modelar a relação entre essas variáveis e prever o comportamento futuro da máquina (LIM, 2018; JAIN; BHARGAVA, 2017; HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

As técnicas de regressão linear, por exemplo, podem ser usadas para prever a vibração de uma máquina rotativa a partir da velocidade, da temperatura, da tensão, entre outros. Isso é útil para identificar problemas como desgaste prematuro, problemas de alinhamento, problemas de equilíbrio, entre outros. Além disso, as técnicas de regressão linear podem ser usadas para otimizar o funcionamento da máquina, por exemplo, ajustando a velocidade para minimizar a vibração.

As técnicas de regressão linear são fáceis de usar, flexíveis e fornecem resultados precisos. No entanto, são importantes algumas precauções a serem tomadas na sua aplicação, como a verificação da linearidade das variáveis independentes e dependentes, a validação dos

modelos e a análise dos resíduos.

De forma resumida, as técnicas de regressão linear são uma ferramenta importante para a análise de dados em máquinas rotativas. Elas permitem modelar a relação entre variáveis críticas, prever o comportamento futuro da máquina e otimizar o seu funcionamento (LIM, 2018; JAIN; BHARGAVA, 2017; HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

### **2.6.1 Máquina de Vetor Suporte**

Máquina de Vetor Suporte (MVS) ou, em inglês *Support Vector Machine* (SVM), é um algoritmo de aprendizado de máquina supervisionado que pode ser usado para desafios de classificação ou regressão. Seu foco maior refere-se ao treinamento e à classificação de um *dataset* (ADDAN, 2019).

### **2.6.2 Mínimos Quadrados**

O Método dos Mínimos Quadrados (MMQ), ou Mínimos Quadrados Ordinários (MQO) ou OLS (do inglês *Ordinary Least Squares*), é uma técnica de otimização matemática que procura encontrar o melhor ajuste para um conjunto de dados, com o intuito de minimizar a soma dos quadrados das diferenças entre o valor estimado e os dados observados.

Consiste em um estimador que minimiza a soma dos quadrados dos resíduos da regressão, de forma a maximizar o grau de ajuste do modelo aos dados observados (KLEYNHANS et al., 2017).

## **2.7 Técnicas de regressão não lineares**

Em contraste com a regressão linear, as técnicas de aprendizado de máquina para regressão não linear permitem modelar relações complexas e possivelmente altamente não lineares entre muitas variáveis (LIANG et al., 2022).

### **2.7.1 Redes neurais artificiais**

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento; já o cérebro de um mamífero pode ter muitos bilhões de neurônios. Uma Rede Neural Artificial (RNA) é composta por várias unidades de processamento (neurônios artificiais). Estas, geralmente, são conectadas por canais de

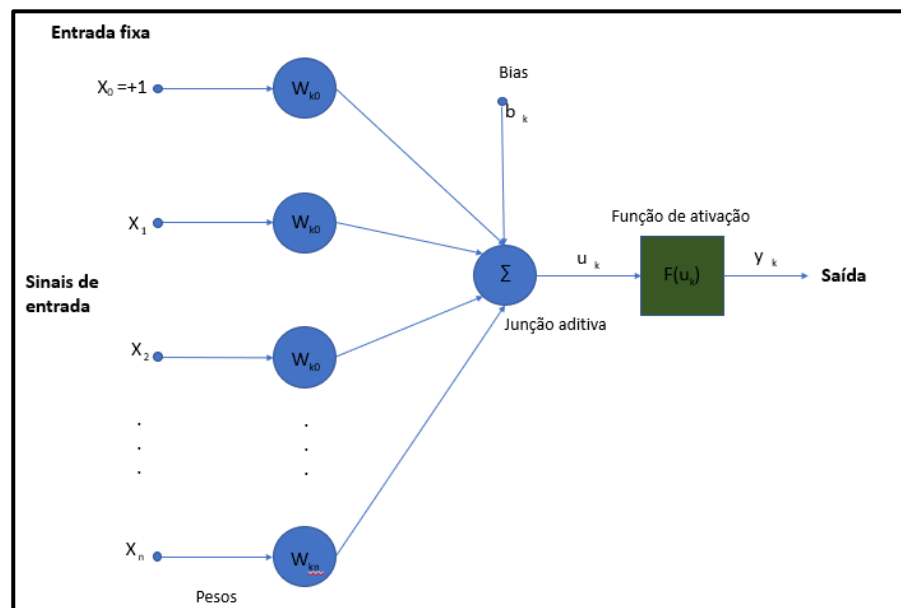


comunicação que estão associados a determinado peso. As unidades fazem operações, apenas, sobre seus dados locais, que são entradas recebidas pelas suas conexões (LACERDA, 2020).

A representação do neurônio artificial foi inicialmente proposto por McCulloch e Pitts em 1943. Sinais são apresentados à entrada e cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade. É feita a soma ponderada dos sinais que produz um nível de atividade. Se este nível de atividade exceder um certo limite (*threshold*) a unidade produz uma determinada resposta de saída.

As redes neurais podem ser classificadas em diferentes tipos, as quais são usadas para diferentes propósitos. A Figura 10 é a representação de um neurônio artificial do Perceptron e é a rede neural mais antiga, criada por Frank Rosenblatt em 1958. Ele tem um único neurônio e é a forma mais simples de uma rede neural.

Figura 10 – Neurônio artificial.



Fonte: Do autor (2022).

Os valores representados por “X0”, “X1” até “Xn”, são os sinais de entrada, sinais externos normalizados para incrementar a eficiência computacional dos algoritmos de aprendizagem. São os dados que alimentam seu modelo preditivo. Já os pesos sinápticos “W1”, “W2” até “Wn” são valores para ponderar os sinais de cada entrada da rede. Esses valores são aprendidos durante o treinamento.

A junção aditiva é responsável por agregar todos sinais de entrada que foram ponderados pelos respectivos pesos sinápticos, a fim de produzir um potencial de ativação. E, o Bias especifica qual será o patamar apropriado para que o resultado produzido pelo

combinador linear possa gerar um valor de disparo de ativação.


Com relação ao potencial de ativação “u”, é o resultado obtido pela diferença do valor produzido entre o combinador linear e o limiar de ativação. Se o valor for positivo, ou seja, se “u” for 0, então o neurônio produz um potencial excitatório; caso contrário, o potencial será inibitório. Já a função de ativação “g”, seu objetivo é limitar a saída de um neurônio em um intervalo de valores. Por fim, o sinal de saída “y” é o valor final de saída podendo ser usado como entrada de outros neurônios que estão sequencialmente interligados.

Nos próximos tópicos serão apresentados os tipos de rede utilizados nesse trabalho.

### 2.7.1.1 Rede do tipo PMC ou MLP

O Perceptron Multicamadas (PMC), ou em inglês *Multi Layer Perceptron* (MLP), é uma rede neural com uma ou mais camadas ocultas, com um número indeterminado de neurônios. A camada oculta possui esse nome porque não é possível prever a saída desejada nas camadas intermediárias (MOREIRA, 2018). Na Figura 11 é possível verificar o posicionamento das camadas de entradas, camadas escondidas e a camada de saída.

Figura 11 – Perceptron Multicamadas.



Fonte: Lacerda (2020).

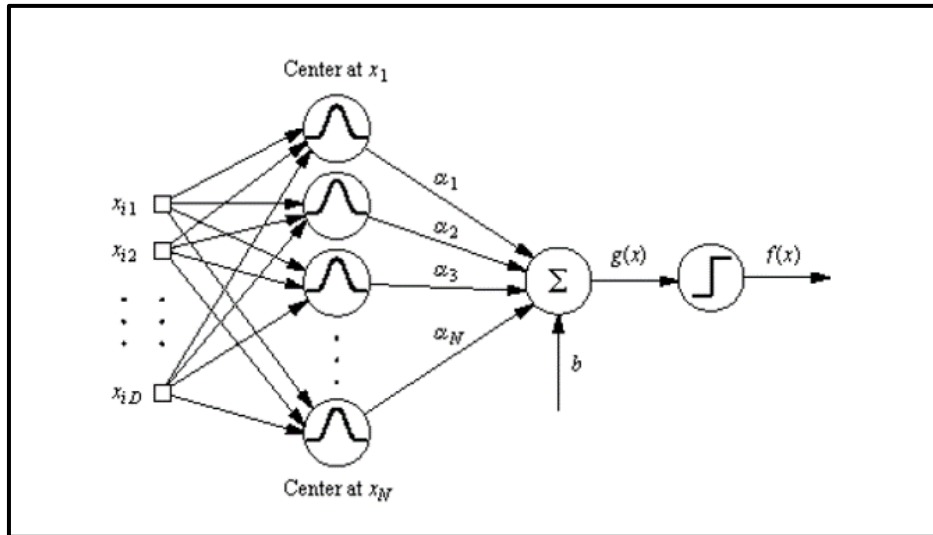
### 2.7.1.2 Rede do tipo RBR

Assim, como a rede do tipo MLP, redes de Funções de Base Radial (RBR em português, e em inglês RBFN – *Radial Basis Functions Networks*) são redes neurais multicamadas (com neurônios ocultos não lineares).

A principal diferença é que a rede RBR tem apenas uma única camada oculta, cujos neurônios possuem função de ativação gaussiana, em vez de sigmoideal (BARRETO, 2008).

A Figura 12 é a representação simplificada deste tipo de rede.

Figura 12 – RBR.




Fonte: Lacerda (2020).

### 2.7.1.3 Rede do tipo GRNN

Uma Rede Neural de Regressão Generalizada (GRNN) é frequentemente usada para a aproximação de função. Possui uma camada de base radial e uma camada linear especial. É semelhante à rede de base radial, mas possui uma segunda camada ligeiramente diferente (MATHWORKS, 2021b). Na Figura 13, apresenta-se a arquitetura para o GRNN.

Figura 13 – GRNN.



Fonte: Mathworks (2021a).

## 2.8 Métricas de avaliação

Nesta seção serão apresentadas as métricas utilizadas para a validação e a comparação entre as técnicas propostas.

### 2.8.1 Erro Quadrático Médio (EQM)

O Erro Quadrático Médio (EQM), (da sigla MSE em inglês, que significa *Mean Squared Error*), é comumente usado para verificar a acurácia de modelos e permitir um maior peso aos maiores erros, já que, ao ser calculado, cada erro é elevado ao quadrado individualmente e, posteriormente, a média desses erros quadráticos é calculada.

Sendo a métrica mais utilizada, o Erro Quadrático Médio consiste na média do erro das previsões ao quadrado. Em outras palavras, pega-se a diferença entre o valor predito pelo modelo e o valor real, eleva-se o resultado ao quadrado. O mesmo ocorre em relação aos outros pontos, que soma-se e divide-se pelo número de elementos preditos. Quanto maior esse número, pior o modelo (AZANK, 2020). Essa métrica apresenta valor mínimo 0, sem valor máximo, e pode ser descrita pela Equação 1, a seguir, sendo "n" o número de instâncias no conjunto de dados, "y" igual o valor esperado, e "yi" igual valor calculado.

$$EQM = \frac{1}{n} \sum_{i=1}^n (y - y_i)^2 \quad (1)$$

### 2.8.2 R-quadrado absoluto

O R-quadrado absoluto, ou Coeficiente de Determinação, é uma métrica que visa expressar a quantidade da variância dos dados que é explicada pelo modelo construído. Em outras palavras, essa medida calcula qual a porcentagem da variação que pôde ser prevista pelo modelo de regressão e, portanto, diz quão "próximas" as medidas reais estão do modelo matemático apresentado para regressão. O valor do seu R-quadrado varia de 0 a 1 e geralmente é representado em porcentagem. Por exemplo, um  $R^2 = 75\%$  revela que 75% da variação de dados podem ser explicados pelo modelo construído, enquanto os outros 25%, teoricamente, referem-se à uma variação residual. Na Equação 2, a seguir, apresenta-se a

fórmula dessa medida, em que “y” representa o valor real, “yi” o valor previsto e “yj” representa a média dos valores reais (AZANK, 2020).

$$R^2 = 1 - \frac{\text{VarianaResidual}}{\text{VarianaTotal}} = 1 - \frac{\sum_{i=1}^n (y - y_i)^2}{\sum_{i=1}^n (y - y_j)^2} \quad (2)$$

### 2.8.3 Desvio Padrão

O Desvio Padrão (DP) constitui medida que expressa o grau de dispersão de um conjunto de dados. Ou seja, indica o quanto um conjunto de dados é uniforme. Quanto mais próximo de 0 for o desvio padrão, mais homogêneo são os dados (GOUVEIA, 2022). Na Equação 3 apresenta-se a fórmula dessa medida, sendo “xi” o valor na posição “i” no conjunto de dados, “MA” a média aritmética dos dados e “n” a quantidade de dados.

$$DP = \sqrt{\frac{\sum_{i=1}^n (x_i - M_A)^2}{n}} \quad (3)$$

### 2.9 Validação cruzada: K-Fold

Apresentadas as técnicas estatísticas, Erro Quadrático Médio (EQM), R-quadrado absoluto e Desvio Padrão (DP), expõe-se o modelo de validação utilizado para cada modelo proposto. A validação cruzada é uma técnica para avaliar a capacidade de generalização de um modelo, com base em um conjunto de dados. O método de validação cruzada, denominado K-Fold, consiste em dividir o conjunto total de dados em “k” subconjuntos, mutuamente exclusivos, do mesmo tamanho e, a partir daí, um subconjunto é utilizado para teste e os “k-1” restantes são utilizados para estimação dos parâmetros, fazendo-se o cálculo da acurácia do modelo. Esse processo é realizado “k” vezes, alternando, de forma circular, o subconjunto de teste. Na Figura 14, apresenta-se o esquema realizado pelo K-Fold (BAK; LENNOX, 2005). Em cada interação, calculam-se 3 métricas estatísticas para a avaliação do modelo.

Figura 14 – K-Fold.

<b>Interação 1</b>	<b>Teste</b>	<b>Treino</b>	<b>Treino</b>	<b>Treino</b>	<b>Treino</b>
<b>Interação 2</b>	<b>Treino</b>	<b>Teste</b>	<b>Treino</b>	<b>Treino</b>	<b>Treino</b>
<b>Interação 3</b>	<b>Treino</b>	<b>Treino</b>	<b>Teste</b>	<b>Treino</b>	<b>Treino</b>
<b>Interação 4</b>	<b>Treino</b>	<b>Treino</b>	<b>Treino</b>	<b>Teste</b>	<b>Treino</b>
<b>Interação 5</b>	<b>Treino</b>	<b>Treino</b>	<b>Treino</b>	<b>Treino</b>	<b>Teste</b>

Fonte: Do autor (2022).

### **3 METODOLOGIA**

Apresentam-se, neste capítulo, o banco de dados e a metodologia utilizada para o pré-processamento dos dados, elaboração dos modelos de Inteligência Computacional (IC). São apresentadas, brevemente, algumas informações do funcionamento das técnicas já mencionadas no Capítulo 2, e, posteriormente, os parâmetros utilizados para execução de cada uma delas.

#### **3.1 Banco de dados**

Utilizou-se uma base de dados extraída do próprio sistema instalado na usina para aquisição de dados. O período considerado foi de 6 meses, pois era o período disponível, e com amostragem de 1 em 1 minuto por sinal. A base de dados possui 50 sinais diferentes. O motivo para a escolha do tempo de minuto em minuto se deu por ser a amostragem disponível na base, e a quantidade de sinais (50), também por ser a quantidade disponível.

##### **3.1.1 Pré-processamento manual**

A base de dados utilizada não se encontrava no formato necessário para a realização das análises propostas neste trabalho. Apesar de se encontrar em formato de Excel, formato que é possível ser utilizado pelo MATLAB, foi necessário um pré-processamento manual para dar continuidade ao trabalho, pois o sistema exportava as variáveis de forma individual, e sequencial. A Figura 15 representa a base de dados visualizada pelo software Excel, onde é possível observar que os dados foram extraídos de forma sequencial, por variável, em uma única coluna, e após as amostras destes sinais, é iniciada a apresentação dos sinais subsequentes.

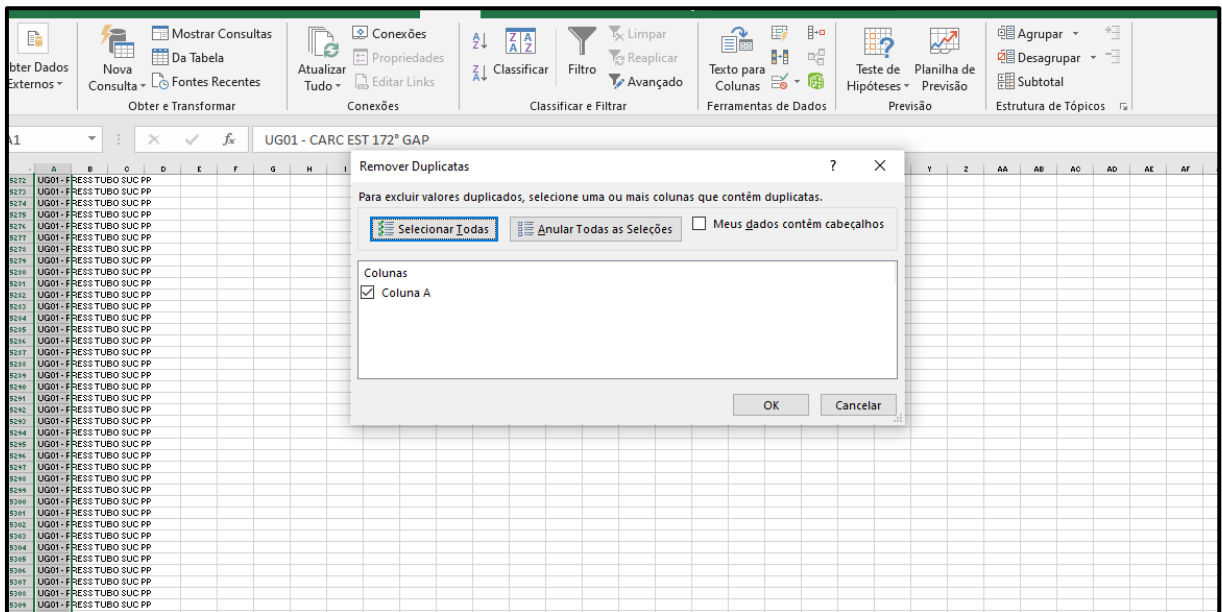
Iniciou-se a primeira etapa do pré-processamento, por meio do uso da função do Excel "texto para colunas", pois a base de dados estava em formato de CSV. As variáveis foram copiadas para uma nova aba, em que se utilizaram duas funções do Excel: primeiramente, a função de remover duplicadas e, posteriormente, após a cópia das variáveis, a função de transposição, para deixar as variáveis no formato horizontal, conforme é indicado na Figura 16, e posteriormente, na Figura 17.

Figura 15 – Base original: parte 1.

UG01 - CARC EST 172' GAP	103054432,7803422,7803422,7803422	2018-03-12 17:56:30.000			
UG01 - CARC EST 172' GAP	103054432,8307512,8307512,8307512	2018-03-12 18:03:30.000			
UG01 - CARC EST 172' GAP	103054432,8814182,8814182,8814182	2018-03-12 18:17:30.000			
UG01 - CARC EST 172' GAP	103054432,932232,932232,932232	2018-03-12 18:33:30.000			
UG01 - CARC EST 172' GAP	103054432,8818262,8818262,8818262	2018-03-12 19:09:30.000			
UG01 - CARC EST 172' GAP	103054432,8659562,8659562,8659562	2018-03-12 20:50:30.000			
UG01 - CARC EST 172' GAP	103054432,815732,815732,815732	2018-03-12 21:42:30.000			
UG01 - CARC EST 172' GAP	103054432,7655332,7655332,7655332	2018-03-12 21:57:30.000			
UG01 - CARC EST 172' GAP	103054432,7152,7152,7152	2018-03-12 22:12:30.000			
UG01 - CARC EST 172' GAP	103054432,7054092,7054092,7054092	2018-03-12 22:29:30.000			
UG01 - CARC EST 172' GAP	103054432,6544122,6544122,6544122	2018-03-12 23:05:30.000			
UG01 - CARC EST 172' GAP	103054432,6042372,6042372,6042372	2018-03-13 01:03:30.000			
UG01 - CARC EST 172' GAP	103054432,6544122,6544122,6544122	2018-03-13 01:49:30.000			
UG01 - CARC EST 172' GAP	103054432,7055432,7055432,7055432	2018-03-13 01:59:30.000			
UG01 - CARC EST 172' GAP	103054432,7569912,7569912,7569912	2018-03-13 02:06:30.000			
UG01 - CARC EST 172' GAP	103054432,8082112,8082112,8082112	2018-03-13 02:14:30.000			
UG01 - CARC EST 172' GAP	103054432,8585322,8585322,8585322	2018-03-13 02:22:30.000			
UG01 - CARC EST 172' GAP	103054432,9095452,9095452,9095452	2018-03-13 02:34:30.000			
UG01 - CARC EST 172' GAP	103054432,9599042,9599042,9599042	2018-03-13 02:45:30.000			
UG01 - CARC EST 172' GAP	103054433,0101463,0101463,0101462	2018-03-13 03:17:30.000			
UG01 - CARC EST 172' GAP	103054433,0609473,0609473,0609472	2018-03-13 04:13:30.000			
UG01 - CARC EST 172' GAP	103054433,112343,112343,112342	2018-03-13 05:57:30.000			
UG01 - CARC EST 172' GAP	103054433,0027113,0027113,0027112	2018-03-13 05:59:30.000			
UG01 - CARC EST 172' GAP	103054433,0530043,0530043,0530042	2018-03-13 06:02:30.000			
UG01 - CARC EST 172' GAP	103054433,1031513,1031513,1031512	2018-03-13 06:23:30.000			
UG01 - CARC EST 172' GAP	103054433,1531863,1531863,1531862	2018-03-13 06:51:30.000			
UG01 - CARC EST 172' GAP	103054433,2036743,2036743,2036742	2018-03-13 07:03:30.000			
UG01 - CARC EST 172' GAP	103054433,375023,375023,375022	2018-03-13 07:06:30.000			
UG01 - CARC EST 172' GAP	103054433,3243753,3243753,3243752	2018-03-13 07:13:30.000			
UG01 - CARC EST 172' GAP	103054433,2710213,2710213,2710212	2018-03-13 07:22:30.000			

Fonte: Do autor (2022).

Figura 16 – Base original: parte 2.



Fonte: Do autor (2022).





Figura 19 – Base original: parte 5.

	UG01 - CA	UG01 - CA	UG01 - CA	UG01 - CA	UG01 - CA	UG01 - EN	UG01 - EN	UG01 - EN	UG01 - FLU	UG01 - FO	UG01 - FO	UG01 - FO	UG01 - FO	UG01 - FO	UG01 - MC	UG01 - MC	UG01 - MC	UG01 - MC
2018-03-1	2,780342	2,671939	3,06389	2,489434	1,925811	25,6301	25,9736	23,87809	0,925912	4,718295	5,482857	5,773271	5,719007	0,395037	0,390139	119,5968	103,5298	451
2018-03-1	2,830751	2,671939	3,06389	2,489434	1,925811	25,74967	25,43717	24,07899	0,925912	4,738419	5,478555	5,775812	5,725774	0,38497	0,386814	120,0011	106,1898	448
2018-03-1	2,881418	2,671939	3,06389	2,489434	1,925811	25,50491	25,58314	23,93859	0,925912	4,730332	5,482	5,787804	5,734539	0,391107	0,387643	106,7815	102,2422	460
2018-03-1	2,93223	2,671939	3,06389	2,489434	1,925811	25,45813	25,64994	24,25452	0,925912	4,717477	5,488135	5,791367	5,730412	0,381309	0,369879	119,3183	98,05909	458
2018-03-1	2,881826	2,671939	3,06389	2,489434	1,925811	25,74665	26,04753	24,72315	0,925912	4,736076	5,520681	5,815666	5,735944	0,382549	0,379538	107,4155	94,95598	461
2018-03-1	2,865956	2,80733	3,154169	2,590515	2,019458	25,889	25,99645	24,5604	0,935261	4,727679	5,532012	5,817521	5,726206	0,396789	0,385987	105,4928	91,86478	463
2018-03-1	2,81573	2,80733	3,154169	2,590515	2,019458	26,23341	26,27592	24,91567	0,935261	4,763406	5,724398	5,854148	5,589966	0,433335	0,406777	101,0547	100,3921	467
2018-03-1	2,765533	2,80733	3,053281	2,590515	2,019458	26,41738	26,40322	25,24515	0,935261	4,769603	5,696304	5,844819	5,611285	0,418025	0,399528	94,07411	95,26397	467
2018-03-1	2,715	2,80733	3,053281	2,590515	2,019458	26,70118	26,63464	25,47086	0,935261	4,774278	5,740728	5,85502	5,570736	0,437703	0,413836	100,2575	89,63654	47
2018-03-1	2,705409	2,607722	2,985424	2,436974	1,859431	26,57669	26,72766	25,49168	0,944638	4,770935	5,732852	5,856856	5,579258	0,431185	0,41186	84,96266	102,3709	472
2018-03-1	2,654412	2,607722	2,985424	2,436974	1,859431	26,39423	26,37099	25,27344	0,944638	4,762562	5,706744	5,84573	5,605007	0,425813	0,401917	97,4218	104,4192	474
2018-03-1	2,604237	2,607722	2,985424	2,436974	1,859431	26,4029	26,65489	25,40993	0,944638	4,775691	5,725845	5,852013	5,588807	0,439657	0,417014	97,95588	106,3786	481
2018-03-1	2,654412	2,607722	2,985424	2,436974	1,859431	25,28998	25,91043	24,4718	0,944638	4,729	5,47692	5,782768	5,729481	0,384472	0,373974	120,8504	101,2224	447
2018-03-1	2,705543	2,607722	2,985424	2,436974	1,859431	25,43422	25,89822	24,17867	0,944638	4,735491	5,468253	5,77428	5,736993	0,390096	0,385333	125,5703	114,1408	456
2018-03-1	2,756991	2,607722	2,985424	2,436974	1,859431	25,19281	25,42926	24,37125	0,944638	4,733756	5,473873	5,771531	5,727414	0,390124	0,385506	125,6964	111,3645	451
2018-03-1	2,808211	2,607722	2,985424	2,436974	1,859431	25,39937	25,17059	24,14474	0,944638	4,721814	5,478675	5,784655	5,732198	0,385561	0,370004	114,8802	100,3581	453
2018-03-1	2,858532	2,607722	2,985424	2,436974	1,859431	25,19313	25,53513	24,03811	0,944638	4,72628	5,485354	5,775319	5,724082	0,381667	0,376662	125,8732	104,7694	454
2018-03-1	2,909545	2,607722	2,985424	2,436974	1,859431	25,43302	25,48329	23,98466	0,944638	4,724055	5,482841	5,78189	5,72899	0,384948	0,378897	114,0318	102,9371	453
2018-03-1	2,959904	2,859242	2,985424	2,436974	2,061758	24,94968	25,59598	23,85067	0,944638	4,726486	5,47182	5,775213	5,74111	0,392454	0,383519	127,855	104,3648	454
2018-03-1	3,010146	2,859242	2,985424	2,436974	2,162707	25,21237	25,28455	24,07883	0,944638	4,729268	5,476852	5,783262	5,73352	0,388454	0,384386	118,9416	104,818	460
2018-03-1	3,060947	2,859242	2,985424	2,436974	2,162707	25,18464	25,42689	24,05034	0,944638	4,722298	5,470224	5,773355	5,737991	0,388202	0,377407	124,6997	104,1793	460

Fonte: Do autor (2022).

Figura 20 – Resumo da operação.

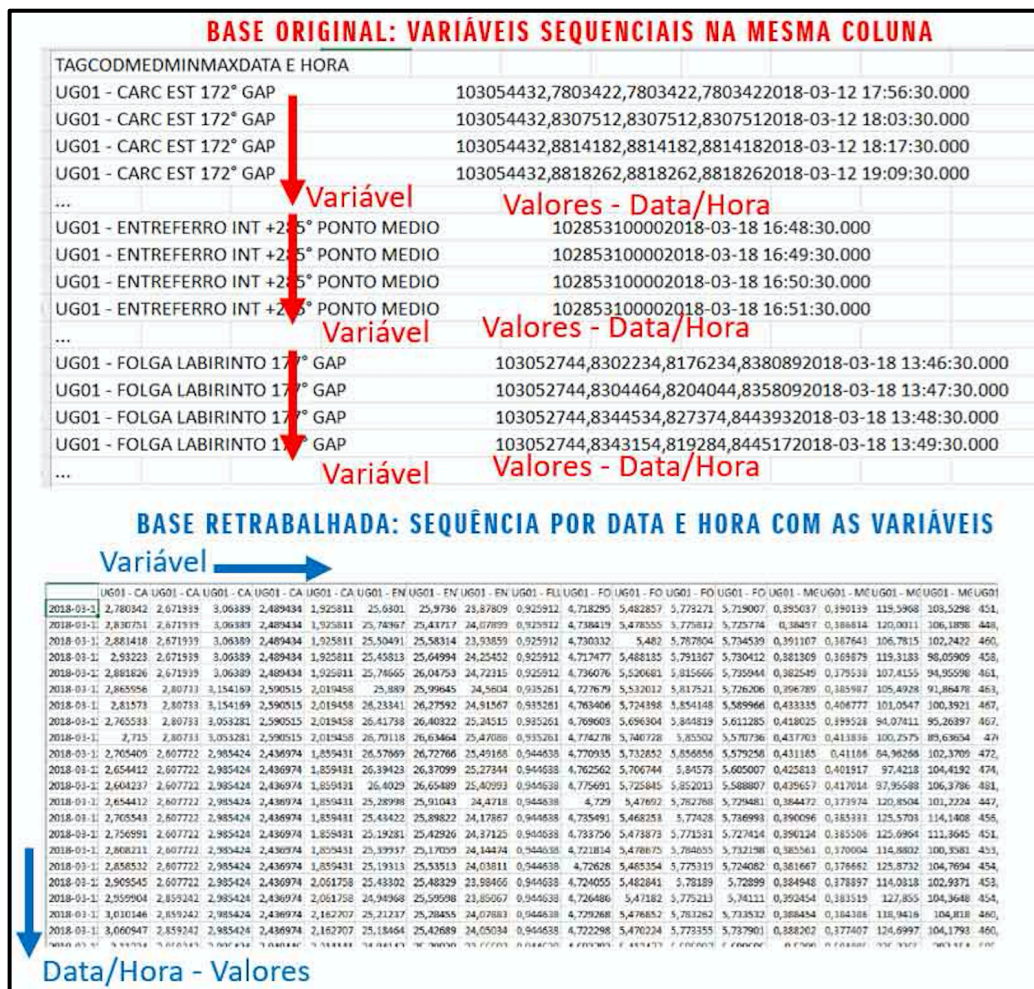


Figura 21 – Ilustração da base em Excel.

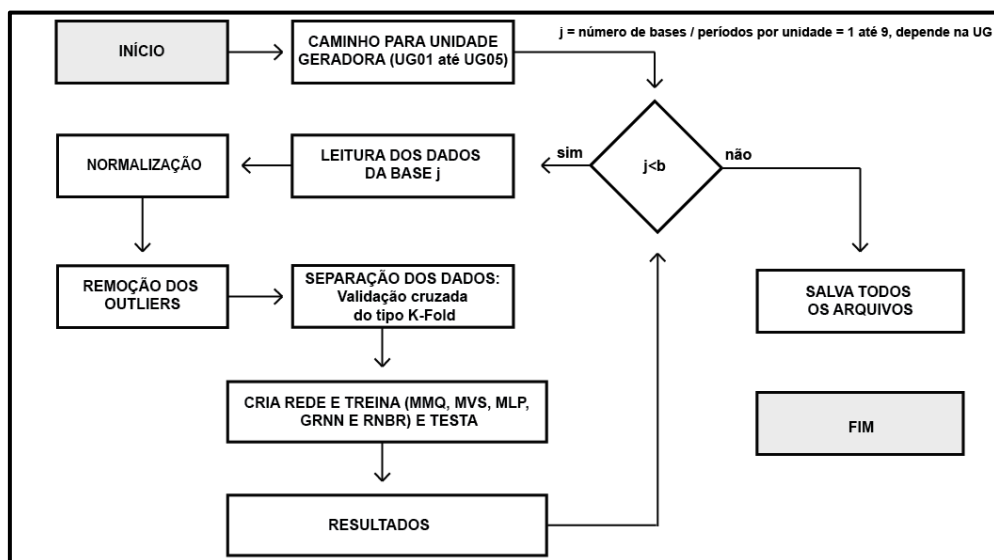
DATA-HORA	UG01 - CARC EST 172° GAP	UG01 - FLUXO MAGNETIC	UG01 - FOLGA LABIRINTO	UG01 - MGG - RELATIVA	UG01 - MGG - RELATIVA	UG01 - MGT - ABSOLUTA	UG01 - NUCL EST - ABSOLUTA	UG01 - PBUS VELOCIDADE	UG01 - MGG - RELATIVA
2018-03-12 17:57:	2,780342	0,9259118	4,716309	100,1181	441,8369	0,842673	0,00662417	85,81399	113,029
2018-03-12 17:58:	2,780342	0,9259118	4,713129	103,0252	436,0195	0,842673	0,00665572	85,78746	111,814
2018-03-12 17:59:	2,780342	0,9259118	4,722318	95,89693	437,5798	0,842673	0,00677408	85,73025	127,634
2018-03-12 18:00:	2,780342	0,9259118	4,720762	94,59599	448,0489	0,842673	0,00680681	85,78182	108,262
2018-03-12 18:01:	2,780342	0,9259118	4,719357	95,45531	442,2023	0,842673	0,00675893	85,77334	114,860
2018-03-12 18:02:	2,780342	0,9259118	4,714128	93,36095	450,5008	0,842673	0,00682718	85,77677	109,170
2018-03-12 18:03:	2,780342	0,9259118	4,702118	95,01729	444,8479	0,842673	0,00683203	85,72962	113,089
2018-03-12 18:04:	2,830751	0,9259118	4,729241	96,08775	441,7126	0,842673	0,00677402	85,72181	106,015
2018-03-12 18:05:	2,830751	0,9259118	4,71716	101,8105	451,9661	0,842673	0,00676365	85,72151	101,276
2018-03-12 18:06:	2,830751	0,9259118	4,722521	88,09095	442,9989	0,842673	0,00681279	85,71255	121,034
2018-03-12 18:07:	2,830751	0,9259118	4,717078	94,76483	444,2924	0,842673	0,00671985	85,6977	108,347
2018-03-12 18:08:	2,830751	0,9259118	4,700782	86,92476	448,3339	0,842673	0,00684218	85,67949	104,126
2018-03-12 18:09:	2,830751	0,9259118	4,70461	97,76048	453,9247	0,842673	0,00687871	85,66487	102,654
2018-03-12 18:10:	2,830751	0,9259118	4,718889	91,4574	447,5154	0,842673	0,00694273	85,70093	97,6777
2018-03-12 18:11:	2,830751	0,9259118	4,709244	95,55563	451,6226	0,842673	0,00682601	85,63944	103,002
2018-03-12 18:12:	2,830751	0,9259118	4,711363	85,50906	446,5872	0,842673	0,00677744	85,64732	100,216
2018-03-12 18:13:	2,830751	0,9259118	4,715545	92,45638	444,2998	0,842673	0,00686785	85,64113	103,604
2018-03-12 18:14:	2,830751	0,9259118	4,70595	95,90086	448,3997	0,842673	0,00702222	85,63015	108,820
2018-03-12 18:15:	2,830751	0,9259118	4,708366	87,3654	446,5105	0,842673	0,00678209	85,64966	99,9086
2018-03-12 18:16:	2,830751	0,9259118	4,708448	92,87145	449,1926	0,842673	0,00678079	85,66346	100,19
2018-03-12 18:17:	2,830751	0,9259118	4,718886	95,86938	442,4873	0,842673	0,00679285	85,64838	100,202
2018-03-12 18:18:	2,881418	0,9259118	4,728783	87,14934	454,619	0,842673	0,00686872	85,64124	98,7057
2018-03-12 18:19:	2,881418	0,9259118	4,722534	92,67802	447,0038	0,842673	0,00690274	85,69286	116,124
2018-03-12 18:20:	2,881418	0,9259118	4,712948	94,90089	449,8503	0,842673	0,00694842	85,67231	104,374
2018-03-12 18:21:	2,881418	0,9259118	4,718555	95,53501	450,355	0,842673	0,0069507	85,6585	104,356

Fonte: Do autor (2022).

### 3.2 Sequência do algoritmo

Com a base de dados pronta<sup>1</sup> iniciou-se o desenvolvimento do algoritmo necessário para o trabalho proposto nesta dissertação. Conforme mencionado anteriormente, o *software* escolhido foi o MATLAB. Neste capítulo, demonstram-se as etapas do algoritmo, criado para o trabalho proposto.

Figura 22 – Algoritmo.



Fonte: Do autor (2022).

<sup>1</sup> Base de dados. Disponível em: [https://github.com/brunomirol/msc\\_sy\\_eng](https://github.com/brunomirol/msc_sy_eng).

Na Figura 22 apresenta-se o fluxograma do algoritmo, e na sequência do trabalho, os códigos de forma individual, dos quais foram utilizadas as siglas em inglês.

### 3.2.1 Códigos: início

Nessa etapa, como pode ser visto na Figura 23, todas as variáveis são limpas do compilador. Qualquer aplicação que possa estar aberta é fechada.

Figura 23 – Início.

```
1 clear variables
2 close all
3 clc
4 rng default
```

Fonte: Do autor (2022).

### 3.2.2 Códigos: leitura de dados

Na Figura 24, indicou-se o caminho que será utilizado para ler as bases, a quantidade de *folds* e neurônios para as camadas escondidas.

Figura 24 – Leitura de dados.

```
1 xls = '.xlsx';
2 path = 'data/UG01/';
3 baseInicial = 1;
4 baseFinal = 9;
5 bases = (baseFinal-baseInicial)+1;
6 folds = 5; %valor entre 5 e 10;
7 neuronios_CamadaEscondida = 4;
```

Fonte: Do autor (2022).

### 3.2.3 Códigos: retirada de *outliers* usando o método de *grubs* e normalização

É possível visualizar na Figura 25 que foi realizada a normalização (processo para todas as variáveis ficarem na mesma base), e os *outliers* (dados fora do padrão) foram removidos.

Figura 25 – Retirada de *outliers*: método *grubbs* e normalização.

```

1 for j=baseInicial:baseFinal
2 a = j;
3 a = num2str(a);
4 filename = strcat(path,a,xls);
5 [data, ~, ~] = xlsread(filename);
6 clear a;
7 data = rmoutliers(data, 'grubbs');
8 Maximo_variaveis = 40;
9 Maximo_variaveis = Maximo_variaveis -1;
10 X = [data(2:end, 1:13) data(2:end, 15:end)];
11 Y = data(2:end, 14); % vibra o -> Alvo
12 epocas = 1000;
13 clear data
14 Xn = mapminmax(X')';
15 Yn = mapminmax(Y')';
16 clear X Y

```

Fonte: Do autor (2022).

### 3.2.4 Códigos: diminuição dos sinais usando a correlação de Person

Na Figura 26, pode ser visto que diminuiu-se a quantidade de variáveis para o número estabelecido, utilizando a correlação de Person.

Figura 26 – Diminuição dos sinais: correlação de Person.

```

1 [r] = corrcoef(Xn); %Retorna a correlacao linear das minhas ...
    variaveis
2 [~,rindex] = sort(abs(r(1,:)), 'ascend');
3 Xmenor = Xn(:, [1 rindex(1:Maximo_variaveis)]);

```

Fonte: Do autor (2022).

### 3.2.5 Códigos: seleção da quantidade de *folds* para o método de validação cruzada = 5 do tipo K-Fold

Nesta etapa, conforme Figura 27, definiu-se que a validação será do tipo K-Fold e inserida a quantidade de *folds*, predefinida no início do algoritmo.

Figura 27 – Seleção da quantidade de *folds* para o método de validação K-Fold.

```
1 Validacao_cruzada = cvpartition(length(Yn), 'KFold', folds);
```

Fonte: Do autor (2022).

### 3.2.6 Códigos: rede MVS (Máquina de Vetor Suporte)

De acordo com a Figura 28, o algoritmo é referente ao método Máquina de Vetor Suporte (MVS). Salvaram-se os valores de R-quadrado absoluto, Erro Quadrático Médio (EQM) e Desvio Padrão (DP) no vetor para comparação posterior.

Figura 28 – Rede MVS.

```
1 SVM{i,j} = fitrsvm(xTreino',yTreino'); %M quina de ...
   Vetores Suporte
2 ySimulado_SVM = predict(SVM{i,j},xTeste');
3 ISE_SVM = ((ySimulado_SVM - yTeste').^2);
4 for k = 1:length(ISE_SVM)
5     RMSE2(k) = sqrt(mean(ISE_SVM(1:k)));
6 end
7 MSE_SVM(i,j) = mean(RMSE2);
8
9 r = corrcoef(yTeste, ySimulado_SVM);
10 R_SVM(i,j) = r(1,2);
11 clear r;
12 STD_SVM(i,j) = std(ySimulado_SVM - yTeste');
```

Fonte: Do autor (2022).

### 3.2.7 Códigos: Rede Mínimos Quadrados

O algoritmo, na Figura 29, é referente ao método Mínimos Quadrados (MQ). Salvaram-se os valores de R-quadrado absoluto, Erro Quadrático Médio (EQM) e Desvio Padrão (DP) no vetor para comparação posterior.

Figura 29 – Rede Mínimos Quadrados.

```

2     LM{i} = fitlm(xTreino',yTreino'); %LM
3     ySimulado_LM = predict(LM{i},xTeste');
4     ISE_LM = ((ySimulado_LM - yTeste').^2);
5     for k = 1:length(ISE_LM)
6         RMSE3(k) = sqrt(mean(ISE_LM(1:k)));
7     end
8     MSE_LM(i,j) = mean(RMSE3);
9
10    r = corrcoef(yTeste,ySimulado_LM);
11    R_LM(i,j) = r(1,2);
12    clear r;
13    STD_LM(i,j) = std(ySimulado_LM - yTeste');

```

Fonte: Do autor (2022).

### 3.2.8 Códigos: Rede GRNN

Na Figura 30, o algoritmo é referente ao método Rede do tipo GRNN, do inglês *General Regression Neural Network*. Salvaram-se os valores de R-quadrado absoluto, Erro Quadrático Médio (EQM) e Desvio Padrão (DP) no vetor para comparação posterior.

Figura 30 – Rede GRNN.

```

1     netGRNN{i,j} = newgrnn(xTreino,yTreino);
2     ySimulado_GRNN = sim(netGRNN{i,j},xTeste);
3     MSE_GRNN(i,j) = sqrt(mse(netRB{i,j},yTeste,ySimulado_GRNN));
4     r = corrcoef(yTeste,ySimulado_GRNN);
5     R_GRNN(i,j) = r(1,2);
6     clear r;
7     STD_GRNN(i,j) = std(ySimulado_GRNN - yTeste);

```

Fonte: Do autor (2022).

### 3.2.9 Códigos: Rede Perceptron Multicamadas (PMC)

Conforme a Figura 31, o algoritmo é referente ao método Rede Neural do tipo PMC (Perceptron Multicamadas). Salvaram-se os valores de R-quadrado absoluto, Erro Quadrático Médio (EQM) e Desvio Padrão (DP) no vetor para comparação posterior.

Figura 31 – Rede Perceptron Multicamadas.

```

1
2     netMLP{i,j} = feedforwardnet(neuronios_CamadaEscondida);
3     netMLP{i,j} = configure(netMLP{i,j},xTreino,yTreino);
4     netMLP{i,j}.divideParam.trainRatio = 1;
5     netMLP{i,j}.divideParam.valRatio = 0;
6     netMLP{i,j}.divideParam.testRatio = 0;
7     netMLP{i,j}.trainFcn = 'trainscg';
8     netMLP{i,j}.performFcn = 'mse';
9     netMLP{i,j}.trainParam.epochs = epocas;
10    netMLP{i,j}.trainParam.showWindow = false;
11    netMLP{i,j}.layers{1:end-1}.transferFcn = 'tansig';
12    netMLP{i,j}.layers{end}.transferFcn = 'purelin';
13    netMLP{i,j} = init(netMLP{i,j});
14    netMLP{i,j} = train(netMLP{i,j},xTreino,yTreino);
15    idxTeste = test(Validacao_cruzada,i);
16    xTeste = Xmenor(idxTeste,:);
17    yTeste = Yn(idxTeste,:);
18    ySimulado_MLP = sim(netMLP{i,j},xTeste);
19    MSE_MLP(i,j) = mse(netMLP{i,j},yTeste,ySimulado_MLP);
20    r = corrcoef(yTeste,ySimulado_MLP);
21    R_MLP(i,j) = r(1,2);
22    clear r;
23    STD_MLP(i,j) = std(ySimulado_MLP - yTeste);

```

Fonte: Do autor (2022).



### 3.2.10 Códigos: Rede RB

O algoritmo, na Figura 32, é referente ao método Rede Neural de Base Radial. Salvaram-se os valores de R-quadrado absoluto, Erro Quadrático Médio (EQM) e Desvio Padrão (DP) no vetor para comparação posterior.

Figura 32 – Rede RB.

```

1     netRB{i,j} = newrb(xTreino,yTreino,0,1,2);
2     ySimulado_RB = sim(netRB{i,j},xTeste);
3     MSE_RB(i,j) = sqrt(mse(netRB{i,j},yTeste,ySimulado_RB));
4     r = corrcoef(yTeste,ySimulado_RB);
5     R_RB(i,j) = r(1,2);
6     clear r;
7     STD_RB(i,j) = std(ySimulado_RB - yTeste);

```

Fonte: Do autor (2022).

### 3.2.11 Códigos: resultados salvos

Nesta etapa, conforme Figura 33, todos os resultados foram compilados em uma única matriz, para facilitar as análises.

Figura 33 – Resultados salvos.

```

1
2 TodosDados = cat(1,MSE_GRNN, R_GRNN, STD_GRNN, MSE_LM, R_LM, ...
    STD_LM, MSE_MLP, R_MLP, STD_MLP, MSE_RB, R_RB, STD_RB, ...
    MSE_SVM, R_SVM, STD_SVM);

```

Fonte: Do autor (2022).

## 4 RESULTADOS

Neste capítulo são apresentados os resultados individuais, para cada método, na ordem a seguir:

- a) MVS – Método Linear – Máquina de Vetor Suporte;
- b) MQ – Método Linear – Mínimos Quadrados;
- c) GNRR – Rede Neural do tipo GNRR;
- d) MLP ou PMC – Rede Neural do tipo MLP ou PMC;
- e) RNBR – Rede Neural do tipo RNBR.

### 4.1 Resultados individuais

A ordem dos resultados individuais foi definida em virtude dos dois primeiros métodos serem métodos de regressão linear e os três últimos, métodos de regressão não linear por rede neural. Em cada método, apresenta-se uma tabela com os resultados por unidade hidrogeradora (UG01 até UG05). Nas tabelas é possível analisar, individualmente, cada resposta estatística (EQM, R-quadrado absoluto e Desvio Padrão) por período. Sendo que cada período é de 1 semana. Para o EQM (Erro Quadrático Médio), quanto mais perto de 0, melhor. Para o R-quadrado absoluto, quanto mais perto de 1, melhor. E, para o Desvio Padrão, quanto mais perto de 0, melhor. Ao final de cada seção, apresenta-se um gráfico com as médias por unidade hidrogeradora dos períodos completos.

#### 4.1.1 Resultados Máquina de Vetor Suporte (MVS)

Nesta seção serão apresentados os resultados para o método de regressão não linear Máquina de Vetor Suporte.

##### 4.1.1.1 Resultados MVS: UG01

Na Tabela 1, é possível verificar os resultados da unidade hidrogeradora UG01 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 8, seguidos pela média, em cada um deles.

Tabela 1 – MVS UG01.

<b>MVS</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>PER7</b>	<b>PER8</b>	<b>Média</b>
EQM	0,0987	0,0978	0,0404	0,0787	0,0336	0,0807	0,0337	0,093	0,0696
R <sup>2</sup>	0,9171	0,9739	0,9962	0,959	0,9974	0,9225	0,9987	0,9564	0,9652
DP	0,1128	0,0829	0,0279	0,1073	0,0332	0,1574	0,0326	0,1236	0,0847

Fonte: Do autor (2022).

#### 4.1.1.2 Resultados MVS: UG02

Na Tabela 2, é possível verificar os resultados da unidade hidrogeradora UG02 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 3, seguidos pela média, em cada um deles.

Tabela 2 – MVS UG02.

<b>MVS</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>Média</b>
EQM	0,1924	0,2084	0,2845	0,2284
R <sup>2</sup>	0,311	0,6267	0,3977	0,4451
DP	0,2019	0,2365	0,2427	0,227

Fonte: Do autor (2022).

#### 4.1.1.3 Resultados MVS: UG03

Na Tabela 3, é possível verificar os resultados da unidade hidrogeradora UG03 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 6, seguidos pela média, em cada um deles.

Tabela 3 – MVS UG03.

<b>MVS</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>Média</b>
EQM	0,238	0,255	0,2139	0,1346	0,1306	0,1728	0,1908
R <sup>2</sup>	0,6102	0,723	0,5946	0,923	0,9513	0,8853	0,7812
DP	0,2327	0,2657	0,2168	0,1504	0,1404	0,1624	0,1947

Fonte: Do autor (2022).

#### 4.1.1.4 Resultados MVS: UG04

Na Tabela 4, é possível verificar os resultados da unidade hidrogeradora UG04 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 7, seguidos pela média, em cada um deles.

Tabela 4 – MVS UG04.

<b>MVS</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>PER7</b>	<b>Média</b>
EQM	0,1869	0,1827	0,4389	0,209	0,2129	0,1953	0,1782	0,2291
R <sup>2</sup>	0,603	0,892	0,7708	0,6744	0,7212	0,9644	0,8851	0,7873
DP	0,1785	0,1538	0,3587	0,2127	0,2936	0,1264	0,1533	0,211

Fonte: Do autor (2022).

#### 4.1.1.5 Resultados MVS: UG05

Na Tabela 5, é possível verificar os resultados da unidade hidrogeradora UG05 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 2. Não se computou a média, pois os resultados, para os períodos 3 até 5, não convergiram (nenhum resultado foi encontrado). Com isso, as médias não seriam reais.

Tabela 5 – MVS UG05.

<b>MVS</b>	<b>PER1</b>	<b>PER2</b>
EQM	0,1965	0,2155
R <sup>2</sup>	0,7761	0,7625
DP	0,1983	0,2517

Fonte: Do autor (2022).


#### 4.1.1.6 MVS: médias

Nesta seção serão apresentadas as médias dos resultados para o método de regressão não linear Máquina de Vetor Suporte.

No Gráfico 1, observam-se as médias dos resultados compilados para todas as unidades apresentadas neste trabalho (UG01 UG02, UG03 e UG04), com exceção da UG05,

que não foi utilizada devido apenas dois períodos terem sido convergidos em resultados, utilizando o método Máquina de Vetor Suporte (MVS).

Gráfico 1 – MVS UGs.



Fonte: Do autor (2022).

Analisando os resultados é possível verificar que houve um aumento no EQM e no Desvio Padrão na UG02, e depois um pequeno decréscimo, porém ficando estável nas UG03 e UG04. O comportamento inverso é possível ser verificado no R-quadrado absoluto, onde o alvo é o oposto das outras métricas. Como foi mencionado anteriormente no item 4.1.1.5, o método, apesar de apresentar valores coerentes, não conseguiu trazer todos os resultados, uma vez que 3 períodos não trouxeram resultados.

#### 4.1.2 Resultados Mínimos Quadrados (MQ)

Nesta seção serão apresentados os resultados para o método de regressão não linear Mínimos Quadrados (MQ).

##### 4.1.2.1 Resultados MQ: UG01

Na Tabela 6, é possível verificar os resultados da unidade hidrogeradora UG01 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 8, seguidos pela média, em cada um deles.

Tabela 6 – MQ UG01.

<b>MQ</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>PER7</b>	<b>PER8</b>	<b>Média</b>
EQM	0,1016	0,0998	0,0404	0,0788	0,0323	0,0802	0,0331	0,0924	0,0698
R <sup>2</sup>	0,9183	0,9739	0,9963	0,959	0,9977	0,9231	0,9987	0,9568	0,9655
DP	0,112	0,083	0,0278	0,1072	0,0319	0,1569	0,0326	0,123	0,0843

Fonte: Do autor (2022).

#### 4.1.2.2 Resultados MQ: UG02

Na Tabela 7, é possível verificar os resultados da unidade hidrogeradora UG02 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 3, seguidos pela média, em cada um deles.

Tabela 7 – MQ UG02.

<b>MQ</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>Média</b>
EQM	0,1923	0,2083	0,2844	0,2283
R <sup>2</sup>	0,313	0,6286	0,3971	0,4462
DP	0,2016	0,2359	0,2424	0,2266

Fonte: Do autor (2022).

#### 4.1.2.3 Resultados MQ: UG03

Na Tabela 8, é possível verificar os resultados da unidade hidrogeradora UG03 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 6, seguidos pela média, em cada um deles.

Tabela 8 – MQ UG03.

<b>MQ</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>Média</b>
EQM	0,2374	0,257	0,2126	0,1323	0,1289	0,173	0,19
R <sup>2</sup>	0,6153	0,7442	0,5986	0,9256	0,9541	0,9017	0,7899
DP	0,2315	0,2567	0,216	0,1478	0,1364	0,1511	0,1899

Fonte: Do autor (2022).

#### 4.1.2.4 Resultados MQ: UG04

Na Tabela 9, é possível verificar os resultados da unidade hidrogeradora UG04 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 7, seguidos pela média, em cada um deles.

Tabela 9 – MQ UG04.

<b>MQ</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>PER7</b>	<b>Média</b>
EQM	0,2092	0,1781	0,3431	0,2041	0,2186	0,1857	0,1737	0,2161
R <sup>2</sup>	0,5055	0,8926	0,7744	0,6906	0,7364	0,9657	0,8869	0,7789
DP	0,6722	0,1534	0,3165	0,2074	0,2611	0,1241	0,1522	0,2695

Fonte: Do autor (2022).

#### 4.1.2.5 Resultados MQ: UG05

Na Tabela 10, é possível verificar os resultados da unidade hidrogeradora UG05 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 2. Não se computou a média, pois os resultados, para os períodos 3 até 5, não convergiram (nenhum resultado foi encontrado). Com isso, as médias não seriam reais.

Tabela 10 – MQ UG05.

<b>MQ</b>	<b>PER1</b>	<b>PER2</b>
EQM	0,195	0,2147
R <sup>2</sup>	0,7772	0,7683
DP	0,1978	0,2488

Fonte: Do autor (2022).


#### 4.1.2.6 MQ: médias

Nesta seção serão apresentadas as médias dos resultados de regressão não linear Mínimos Quadrados (MQ).

No Gráfico 2, observam-se as médias dos resultados compilados para todas as unidades apresentadas neste trabalho (UG01, UG02, UG03 e UG04), com exceção da UG05,

que não foi utilizada devido a apenas dois períodos terem sido convergidos em resultados, utilizando o método Máquina de Mínimos Quadrados (MQ).

Gráfico 2 – MQ UGs.



Fonte: Do autor (2022).

Analisando os resultados é possível verificar que houve um aumento no EQM e no Desvio Padrão na UG02, e depois um pequeno decréscimo, porém ficando estável nas UG03 e UG04. O comportamento inverso é possível ser verificado no R-quadrado absoluto, onde o alvo é o oposto das outras métricas. Como foi mencionado anteriormente, no item 4.1.2.5, o método, apesar de apresentar valores coerentes, não conseguiu trazer todos os resultados, uma vez que 3 períodos não trouxeram resultados.

### 4.1.3 Resultados GNRR

Nesta seção serão apresentados os resultados utilizando a Rede Neural do tipo GNRR.

#### 4.1.3.1 Resultados GNRR: UG01

Na Tabela 11, é possível verificar os resultados da unidade hidrogeradora UG01 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 8, seguidos pela média, em cada um deles.



Tabela 11 – GNRR UG01.

<b>GNRR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>PER7</b>	<b>PER8</b>	<b>Média</b>
EQM	0,1814	0,1268	0,0766	0,1637	0,0722	0,2314	0,0752	0,1618	0,1361
R <sup>2</sup>	0,8079	0,9445	0,9713	0,9285	0,9881	0,8695	0,9931	0,9341	0,9296
DP	0,1806	0,1269	0,0766	0,1636	0,0716	0,2304	0,0746	0,1618	0,1358

Fonte: Do autor (2022).

#### 4.1.3.2 Resultados GNRR: UG02

Na Tabela 12, é possível verificar os resultados da unidade hidrogeradora UG02 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 3, seguidos pela média, em cada um deles.

Tabela 12 – GNRR UG02.

<b>GNRR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>Média</b>
EQM	0,2062	0,247	0,2461	0,2331
R <sup>2</sup>	0,2881	0,588	0,3706	0,4156
DP	0,2058	0,2471	0,2463	0,2331

Fonte: Do autor (2022).

#### 4.1.3.3 Resultados GNRR: UG03

Na Tabela 13, é possível verificar os resultados da unidade hidrogeradora UG03 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 6, seguidos pela média, em cada um deles.

Tabela 13 – GNRR UG03.

<b>GNRR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>Média</b>
EQM	0,2532	0,292	0,2298	0,1419	0,1467	0,1717	0,2059
R <sup>2</sup>	0,5551	0,7662	0,5974	0,9317	0,9467	0,8716	0,7781
DP	0,2529	0,2917	0,2289	0,1419	0,1467	0,1715	0,2056

Fonte: Do autor (2022).

#### 4.1.3.4 Resultados GNRR: UG04

Na Tabela 14, é possível verificar os resultados da unidade hidrogeradora UG04 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 7, seguidos pela média, em cada um deles.

Tabela 14 – GNRR UG04.

<b>GNRR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>PER7</b>	<b>Média</b>
EQM	0,2081	0,2365	0,3837	0,2438	0,2993	0,1509	0,1681	0,2415
R <sup>2</sup>	0,4431	0,8478	0,7321	0,6268	0,7408	0,953	0,8953	0,7484
DP	0,2079	0,2361	0,3836	0,2433	0,2991	0,15	0,1661	0,2409

Fonte: Do autor (2022).

#### 4.1.3.5 Resultados GNRR: UG05

Na Tabela 15, é possível verificar os resultados da unidade hidrogeradora UG05 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 5, seguidos pela média, em cada um deles.

Tabela 15 – GNRR UG05.

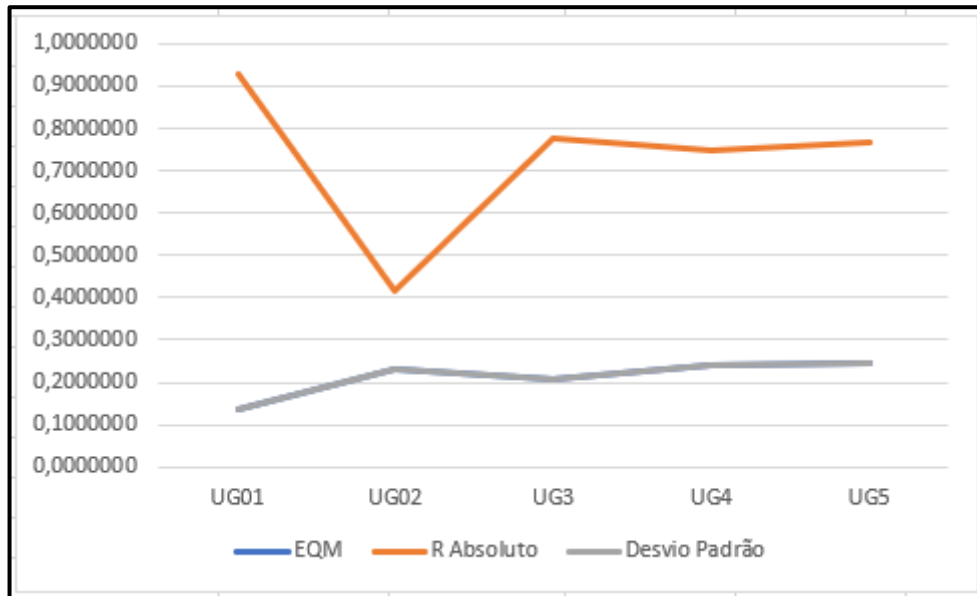
<b>GNRR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>Média</b>
EQM	0,2291	0,2778	0,2448	0,2188	0,2601	0,2461
R <sup>2</sup>	0,7537	0,7506	0,6533	0,8559	0,8206	0,7668
DP	0,2287	0,2758	0,2441	0,2181	0,2556	0,2444

Fonte: Do autor (2022).

#### 4.1.3.6 GNRR: médias

Nesta seção serão apresentadas as médias dos resultados da Rede Neural do tipo GNRR. No Gráfico 3, observam-se as médias dos resultados compilados para todas as unidades apresentadas neste trabalho (UG01, UG02, UG03, UG04 e UG05), utilizando o método GNRR.

Gráfico 3 – GNRR UGs.



Fonte: Do autor (2022).

Analisando os resultados é possível verificar que houve um aumento no EQM e no Desvio Padrão na UG02, e depois um pequeno decréscimo, porém ficando estável nas UG03, UG04 e UG05. O comportamento inverso é possível ser verificado no R-quadrado absoluto, onde o alvo é o oposto das outras métricas. Também é possível verificar que diferentemente dos métodos lineares Máquina de Vetor Suporte e Mínimos Quadrados, todos os resultados foram convergidos.

#### 4.1.4 Resultados PMC

Nesta seção serão apresentados os resultados para o método de regressão utilizando a Rede Neural do tipo Perceptron Multicamadas (PMC).

##### 4.1.4.1 Resultados PMC: UG01

Na Tabela 16, é possível verificar os resultados da unidade hidrogeradora UG01 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 8, seguidos pela média, em cada um deles.

Tabela 16 – PMC UG01.

PMC	PER1	PER2	PER3	PER4	PER5	PER6	PER7	PER8	Média
EQM	0,0065	0,005	0,0007	0,0108	0,0007	0,0209	0,0007	0,0128	0,0073
R <sup>2</sup>	0,9586	0,981	0,9967	0,9615	0,9984	0,9354	0,9991	0,9637	0,9743
DP	0,0806	0,0708	0,0262	0,1039	0,0265	0,1442	0,0265	0,1132	0,074

Fonte: Do autor (2022).

#### 4.1.4.2 Resultados PMC: UG02

Na Tabela 17, é possível verificar os resultados da unidade hidrogeradora UG02 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 3, seguidos pela média, em cada um deles.

Tabela 17 – PMC UG02.

PMC	PER1	PER2	PER3	Média
EQM	0,0357	0,0579	0,0664	0,0533
R-QUADRADO ABSOLUTO	0,4583	0,611	0,3621	0,4772
DESV	0,1888	0,2407	0,2573	0,229

Fonte: Do autor (2022).

#### 4.1.4.3 Resultados PMC: UG03

Na Tabela 18, é possível verificar os resultados da unidade hidrogeradora UG03 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 6, seguidos pela média, em cada um deles.

Tabela 18 – PMC UG03.

PMC	PER1	PER2	PER3	PER4	PER5	PER6	Média
EQM	0,0435	0,0286	0,0403	0,019	0,0143	0,0106	0,026
R <sup>2</sup>	0,7036	0,8986	0,6678	0,9352	0,9649	0,9559	0,8543
DP	0,2084	0,1685	0,2007	0,1377	0,1196	0,1024	0,1562

Fonte: Do autor (2022).

#### 4.1.4.4 Resultados PMC: UG04

Na Tabela 19, é possível verificar os resultados da unidade hidrogeradora UG04 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 7, seguidos pela média, em cada um deles.

Tabela 19 – PMC UG04.

PMC	PER1	PER2	PER3	PER4	PER5	PER6	PER7	Média
EQM	0,0264	0,0191	0,044	0,0331	0,039	0,0089	0,0175	0,0269
R <sup>2</sup>	0,6892	0,9145	0,9081	0,7725	0,8602	0,9804	0,9159	0,863
DP	0,1623	0,1379	0,2091	0,1819	0,1971	0,0943	0,1315	0,1592

Fonte: Do autor (2022).

#### 4.1.4.5 Resultados PMC: UG05

Na Tabela 20, é possível verificar os resultados da unidade hidrogeradora UG05 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 5, seguidos pela média, em cada um deles.

Tabela 20 – PMC UG05.


PMC	PER1	PER2	PER3	PER4	PER5	Média
EQM	0,0307	0,033	0,0285	0,0168	0,0232	0,0265
R <sup>2</sup>	0,8302	0,8845	0,8134	0,93	0,9228	0,8762
DP	0,1752	0,1815	0,1686	0,1293	0,1523	0,1614

Fonte: Do autor (2022).

#### 4.1.4.5 PMC: médias

Nesta seção serão apresentadas as médias dos resultados para o método de regressão utilizando a Rede Neural do tipo Perceptron Multicamadas (PMC). No Gráfico 4, observam-se as médias dos resultados compilados para todas as unidades apresentadas neste trabalho (UG01, UG02, UG03, UG04 e UG05), utilizando o método PMC.

Gráfico 4 – PMC UGs.



Fonte: Do autor (2022).

Analisando os resultados é possível verificar que houve um aumento no EQM e no Desvio Padrão na UG02, e depois um pequeno decréscimo, porém ficando estável nas UG03, UG04 e UG05. O comportamento inverso é possível ser verificado no R-quadrado absoluto, onde o alvo é o oposto das outras métricas. É possível verificar que diferentemente dos métodos lineares, Máquina de Vetor Suporte e Mínimos Quadrados, todos os resultados foram convergidos da mesma forma que o método GNRR.

#### 4.1.5 Resultados RNBR

Nesta seção serão apresentados os resultados para o método de regressão utilizando a Rede Neural do tipo RNBR.

##### 4.1.5.1 Resultados RNBR: UG01

Na Tabela 21, é possível verificar os resultados da unidade hidrogeradora UG01 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 8, seguidos pela média, em cada um deles.

Tabela 21 – RNBR UG01.

<b>RNBR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>PER7</b>	<b>PER8</b>	<b>Média</b>
EQM	0,202	0,192	0,0865	0,2072	0,1794	0,2245	0,2884	0,2013	0,1977
R <sup>2</sup>	0,7009	0,8512	0,9633	0,8364	0,9233	0,8359	0,8914	0,8792	0,8602
DP	0,202	0,1921	0,0864	0,2072	0,1794	0,2238	0,2885	0,2014	0,1976

Fonte: Do autor (2022).

#### 4.1.5.2 Resultados RNBR: UG02

Na Tabela 22, é possível verificar os resultados da unidade hidrogeradora UG02 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 3, seguidos pela média, em cada um deles.

Tabela 22 – RNBR UG02.

<b>RNBR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>Média</b>
EQM	0,2109	0,2561	0,2516	0,2395
R <sup>2</sup>	0,1226	0,5346	0,3015	0,3196
DP	0,2107	0,2563	0,2518	0,2396

Fonte: Do autor (2022).

#### 4.1.5.3 Resultados RNBR: UG03

Na Tabela 23, é possível verificar os resultados da unidade hidrogeradora UG03 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 6, seguidos pela média, em cada um deles.

Tabela 23 – RNBR UG03.

<b>RNBR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>Média</b>
EQM	0,2603	0,337	0,2183	0,1552	0,2167	0,2113	0,2331
R <sup>2</sup>	0,4625	0,4804	0,5866	0,9181	0,8793	0,7965	0,6873
DP	0,2602	0,3372	0,2183	0,1552	0,2168	0,2114	0,2332

Fonte: Do autor (2022).

#### 4.1.5.4 Resultados RNBR: UG04

Na Tabela 24, é possível verificar os resultados da unidade hidrogeradora UG04 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 7, seguidos pela média, em cada um deles.

Tabela 24 – RNBR UG04.

<b>RNBR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>PER6</b>	<b>PER7</b>	<b>Média</b>
EQM	0,2111	0,2489	0,4271	0,2545	0,3302	0,2779	0,2779	0,2896
R <sup>2</sup>	0,3264	0,6791	0,5208	0,4623	0,5188	0,8135	0,5212	0,5488
DP	0,2111	0,2487	0,4271	0,2545	0,3299	0,2779	0,2779	0,2896

Fonte: Do autor (2022).

#### 4.1.5.4 Resultados RNBR: UG05

Na Tabela 25, é possível verificar os resultados da unidade hidrogeradora UG05 para o Erro Quadrático Médio, R-quadrado absoluto e Desvio Padrão para os períodos 1 até o 5, seguidos pela média, em cada um deles.

Tabela 25 – RNBR UG05.

<b>RNBR</b>	<b>PER1</b>	<b>PER2</b>	<b>PER3</b>	<b>PER4</b>	<b>PER5</b>	<b>Média</b>
EQM	0,2536	0,3142	0,2053	0,2244	0,2588	0,2512
R <sup>2</sup>	0,5924	0,5914	0,7086	0,7693	0,7562	0,6836
DP	0,2534	0,3142	0,2048	0,2244	0,2587	0,2511


Fonte: Do autor (2022).

#### 4.1.5.5 RNBR: médias

Nesta seção serão apresentadas as médias dos resultados para o método de regressão utilizando a Rede Neural do tipo RNBR. No Gráfico 5, observam-se as médias dos resultados compilados para todas as unidades apresentadas neste trabalho (UG01, UG02, UG03, UG04 e UG05), utilizando o método RNBR.



Gráfico 5 – RNBR UGs.



Fonte: Do autor (2022).

Analisando os resultados é possível verificar que houve um aumento no EQM e no Desvio Padrão na UG02, e depois um pequeno decréscimo, porém ficando estável nas UG03, UG04 e UG05. O comportamento inverso é possível ser verificado no R-quadrado absoluto, onde o alvo é o oposto das outras métricas. Também é possível verificar que diferentemente dos métodos lineares, Máquina de Vetor Suporte e Mínimos Quadrados, todos os resultados foram convergidos da mesma forma que o método GNRR e o MLP.

## 4.2 Resultados compilados

Nesta seção serão apresentados os resultados compilados para cada método estatístico, na seguinte sequência:

- a) Erro Quadrático Médio (EQM);
- b) R-quadrado absoluto;
- c) Desvio Padrão (DP).

### 4.2.1 EQM – Erro Quadrático Médio

Na Tabela 26, é possível verificar a média dos períodos de cada unidade hidrogeradora, referente à Erro Quadrático Médio, em cada um dos métodos utilizados. Ressalta-se que o EQM, quando mais perto do zero, tem um modelo mais fiel.


Tabela 26 – EQM UGs.

EQM	UG01	UG02	UG03	UG04	UG05
MVS	0,0696	0,2284	0,1908	0,2291	-
MQ	0,0698	0,2283	0,19	0,2161	-
GNRR	0,1361	0,2331	0,2059	0,2415	0,2461
PMC	0,0073	0,0533	0,026	0,0269	0,0265
RNBR	0,1977	0,2395	0,2331	0,2896	0,2512

Fonte: Do autor (2022).

Dois análises são importantes na Tabela 26 e no Gráfico 6. A primeira refere-se à discrepância entre o modelo utilizado para a rede neural do tipo PMC (ou MLP) e os outros modelos. A segunda, aos modelos lineares (MVS, ou SVM, e MQ), que não obtiveram resultados em todas as bases de dados.

Gráfico 6 – EQM UGs.



Fonte: Do autor (2022).

#### 4.2.2 R-quadrado absoluto

Considerando-se a Tabela 27 e o Gráfico 7, duas análises são importantes. A primeira refere-se ao fato de que o modelo utilizado para a rede neural do tipo PMC (ou MLP)

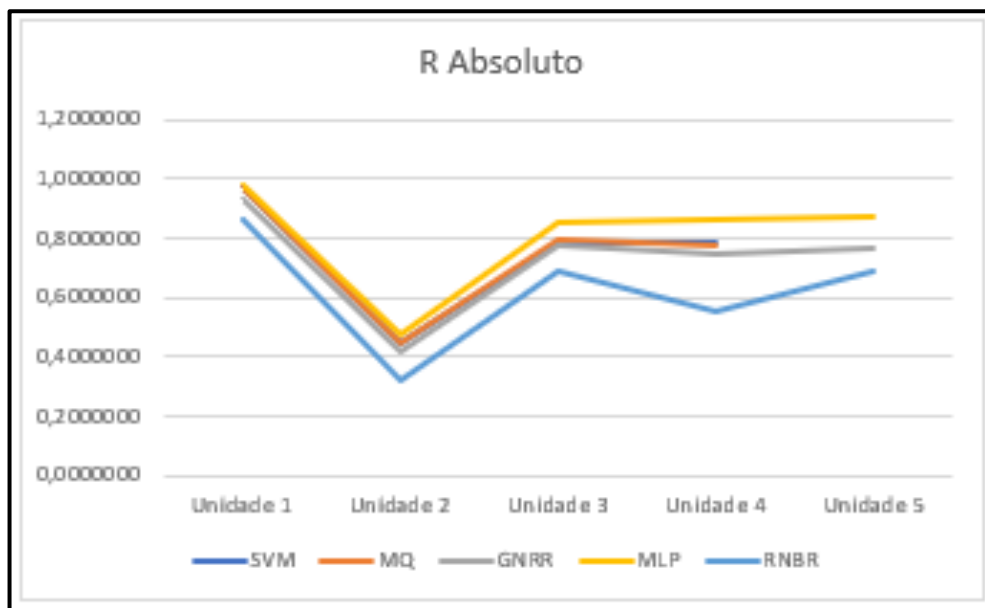
continua superior aos outros modelos. A segunda, que os modelos lineares, MVS (ou SVM) e MQ, não conseguiram obter resultados em todas as bases de dados.

Tabela 27 – R-quadrado absoluto UGs.

<b>R<sup>2</sup> ABSOLUTO</b>	<b>UG01</b>	<b>UG02</b>	<b>UG03</b>	<b>UG04</b>	<b>UG05</b>
MVS	0,9652	0,4451	0,7812	0,7873	-
MQ	0,9655	0,4462	0,7899	0,7789	-
GNRR	0,9296	0,4156	0,7781	0,7484	0,7668
PMC	0,9743	0,4772	0,8543	0,863	0,8762
RNBR	0,8602	0,3196	0,6873	0,5488	0,6836

Fonte: Do autor (2022).

Gráfico 7 – R-quadrado absoluto UGs.



Fonte: Do autor (2022).

#### 4.2.3 Desvio Padrão


Considerando-se a Tabela 28 e o Gráfico 8, observa-se que o modelo utilizado para a rede neural do tipo PMC (ou MLP), novamente, foi superior aos outros modelos, apesar da diferença ser menos significativa, e, também, que os modelos lineares, MVS (ou SVM) e MQ, não obtiveram resultados em todas as bases de dados.

Tabela 28 – Desvio Padrão UGs.

<b>DESVIO PADRÃO</b>	<b>UG01</b>	<b>UG02</b>	<b>UG03</b>	<b>UG04</b>	<b>UG05</b>
MVS	0,0847	0,227	0,1947	0,211	-
MQ	0,0843	0,2266	0,1899	0,2695	-
GNRR	0,1358	0,2331	0,2056	0,2409	0,2444
PMC	0,074	0,229	0,1562	0,1592	0,1614
RNBR	0,1976	0,2396	0,2332	0,2896	0,2511

Fonte: Do autor (2022).

Gráfico 8 – Desvio Padrão UGs.



Fonte: Do autor (2022).

O destaque fica com a metodologia Perceptron Multicamadas (PMC), que mostrou um desempenho estatístico superior aos outros modelos. Apesar de essa técnica apresentar uma complexidade maior, com maior tempo de execução e número de cálculos, o ganho estatístico representa um ganho em relação às outras metodologias.

## 5 CONCLUSÃO

Investigaram-se, e compararam-se, nesta dissertação de mestrado, as técnicas de Inteligência Computacional (IC), como ferramentas para a construção de modelos capazes de estimar os sinais de oscilação de eixo em hidrogeradores, com base em diversos métodos, os quais foram apresentados no curso no trabalho. Entre eles, os modelos baseados em Redes Neurais Artificiais (RNA), do tipo PMC, GRNN e RNBR, além de Regressões pelo Método dos Mínimos Quadrados (MMQ) e Máquina de Vetor Suporte (MVS).

O método Erro Quadrático Médio (EQM) foi utilizado para verificar o erro dos resultados e os valores reais, já que ele dá um maior peso aos erros, pois, quando encontrados, são elevados ao quadrado, sempre um por um e após o fim da execução a média é calculada. Já o método R-quadrado absoluto, para verificar o quanto o conjunto de dados permanece fiel a dados. Em suma, essa medida calcula qual a porcentagem da variância que pôde ser prevista pelo modelo de regressão e, portanto, diz o quão “próximo” as medidas reais estão do modelo matemático apresentado para regressão.

Com relação ao método Desvio Padrão, serviu para analisar o desvio dos dados calculados da base. Este método utiliza o valor médio dos pontos de dados. Este valor é a soma de todos os valores divididos pelo número de pontos. E, para finalizar, foi utilizada a subtração do valor de cada ponto dos dados do valor médio.

Com base em todo o exposto nesta dissertação, observou-se que a melhor metodologia é a PMC. Comparando com as demais metodologias, apresentou um desempenho melhor e se mostrou superior nos três aspectos analisados. Mesmo com toda a complexidade de implementação que ela envolve, é benéfica, mais do que as outras, estatisticamente falando. Outro contra é que ela não justifica suas respostas, e, por isso, é objeto de constantes estudos para um conhecimento melhor de sua estrutura.

Todos os grupos de dados foram treinados e validados pelo método de validação K-Fold, utilizando a quantidade de 5 *folds*, a mais recomendada conforme apresentado no referencial teórico. A rede PMC pode ser dividida em camada de entrada, camada oculta e camada de saída. A camada responsável pelos cálculos é a camada oculta, e ela também reproduz algo significativo. Este tipo de rede pode ser aperfeiçoado com treinamentos e após o aperfeiçoamento podem ser utilizadas para classificar dados novos.

Assim, os modelos de rede neural do tipo PMC treinados podem ser aperfeiçoados para trabalhos futuros. Sendo também possível expandir o uso de redes recorrentes, redes do tipo Narmax, para previsão de sinal futuro e não em tempo real, como é proposto neste trabalho e

implementar os códigos em linguagem Python, para facilitar a implementação em sistemas já existentes, devido a sua ampla utilização e por ser de código aberto.

## REFERÊNCIAS

- ACEVEDO, J.; PISTIKOPOULOS, E. N. **Computational studies of stochastic optimization algorithms for process synthesis under uncertainty**. Computers and Chemical Engineering, 20(SUPPL.1), S1, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00011-7](https://doi.org/10.1016/0098-1354(96)00011-7).
- ADDAN, Diego. **Support Vector Machine**. Unibrasil, 34 p., 2019. Disponível em: <https://www.inf.ufpr.br/dagoncalves/IA07.pdf>. Acesso em: 01 dez. 2021.
- ADJIMAN, C. S. et al. **A global optimization methods abb, for process design c.s. I**. 20(96), 419–424, 1996.
- AG, D. T. **Universal inputs and outputs and secure monitoring**. 2022. Disponível em: [www.delphin.com/products/measuring-and-testing-devices/expert-vibro/functions.html](http://www.delphin.com/products/measuring-and-testing-devices/expert-vibro/functions.html). Acesso em: 31 out. 2021.
- AGGARWAL, Apoorva., RAWAT, Tarun Kumar; UPADHYAY, Dharmendra Kumar. **Design of optimal digital FIR filters using evolutionary and swarm optimization techniques**. AEU - International Journal of Electronics and Communications, 70(4), 373–385, 2016. DOI: <https://doi.org/10.1016/j.aeue.2015.12.012>.
- AGRAWAL, Sakshi et al. **Plant development and crop protection using phytonanotechnology: A new window for sustainable agriculture**. Chemosphere, vol. 299, 2022. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134465>.
- AKIYAMA, Masahiro et al. **Potential of methylmercury toxicity by combined metal exposure: In vitro and in vivo models of a restricted metal exposome**. Chemosphere, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134374>.
- ALABI, O. Adenrele et al. **Comparative study of the reproductive toxicity and modulation of enzyme activities by crude oil-contaminated soil before and after bioremediation**. Chemosphere, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134352>.
- ALBERTELLI, P., GOLETTI, M.; MONNO, M. **An improved receptance coupling substructure analysis to predict chatter free high speed cutting conditions**. Procedia CIRP, 12, 19–24, 2013. DOI: <https://doi.org/10.1016/j.procir.2013.09.005>.
- ALESSANDRI, Angelo; ROSSI, Anna. **Time-varying increasing-gain observers for nonlinear systems**. Automatica, 49(9), 2845–2852, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.026>.
- ALLEVA, Jessica M. et al. **A longitudinal study investigating positive body image, eating disorder symptoms, and other related factors among a community sample of men in the UK**. Body Image, 41, 384–395, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.007>.
- ALMEIDA, Fabrício. C. L. de. **Diagnóstico automático de falhas em grupos geradores hidroelétricos utilizando técnicas preditivas de manutenção e redes neurais artificiais**. 2008. 277f. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Estadual

Paulista Júlio Mesquita Filho, Ilha Solteira, 2008. Disponível em: <https://repositorio.unesp.br/handle/11449/94565>. Acesso em: 26 jun. 2022.

ALSTOM. **Treinamento de turbinas**. [S.l.]: [S.n.], 1998. 200p.

ALTAFINI, C. **Stability analysis of diagonally equipotent matrices**. *Automática*, 49(9), 2780–2785, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.016>.

AMINI, H. et al. **Feedback stabilization of discrete-time quantum systems subject to non-demolition measurements with imperfections and delays**. *Automatica*, 49(9), 2683–2692, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.012>.

AMSEL, A. K.; OLSSON, O.; KÜMMERER, K. **Inventory of biodegradation data of ionic liquids**. *Chemosphere*, vol. 299, 2022. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134385>.

ANDERSON, R. C.; REEB, D. M. **Founding-Family Ownership and Firm Performance: Evidence from the S&P 500**. *Journal of Finance*, 58(3), 1301–1327, 2003. DOI: <https://doi.org/10.1111/1540-6261.00567>.

ANDERSSON, R. et al. **Dose-response-time modelling: Second-generation turnover model with integral feedback control**. *European Journal of Pharmaceutical Sciences*, 81, 189–200. 2016. DOI: <https://doi.org/10.1016/j.ejps.2015.10.018>.

ANGULO, M. T.; FRIDMAN, L.; MORENO, J. A. **Output-feedback finite-time stabilization of disturbed feedback linearizable nonlinear systems**. *Automatica*, 49(9), 2767–2773, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.013>.

APPADURAI, A. **Modern at Large: Cultural Dimensions of Globalization**, 20(96), 1–13, 1996.

ARÁOZ, Rodolfo García.; BRINGAS, Maria de Los Angeles Lucero; RIBBERT, Elsa. **La Gestión del Desempeño en la Empresa Familiar**. *Ciências Administrativas*, 109, 2022. DOI: <https://doi.org/10.24215/23143738E109>.

ARIJS, D. et al. **Family business employer brand: Understanding applicants' perceptions and their job pursuit intentions with samples from the US and Belgium**. *Journal of Family Business Strategy*, 9(3), 180–191, 2018. DOI: <https://doi.org/10.1016/J.JFBS.2018.08.005>.

ARROYO, A.; SOUTHARD, B. A. S.; MARTZ, D. **Feminist embodiment, body talk, and body image among mothers and daughters**. *Body Image*, 41, 354–366, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.005>.

ASANTE, N. D. K.; Zhu, X. X. **An automated approach for heat exchanger network retrofit featuring minimal topology modifications**. *Computers and Chemical Engineering*, 20(suppl.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00013-0](https://doi.org/10.1016/0098-1354(96)00013-0).

ASGARI, S. et al. **Electrospun Ag-decorated reduced GO-graft-chitosan composite nanofibers with visible light photocatalytic activity for antibacterial performance**. *Chemosphere*, vol. 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134436>.



ASHABANI, S. M.; MOHAMED, Y. A. R. I. **New family of microgrid control and management strategies in smart distribution grids-analysis, comparison and testing.** IEEE Transactions on Power Systems, 29(5), 2257–2269, 2014. DOI: <https://doi.org/10.1109/TPWRS.2014.2306016>.

ATHIER, G. et al. **Optimization of heat exchanger networks by coupled simulated annealing and NLP procedures.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00012-9](https://doi.org/10.1016/0098-1354(96)00012-9).

ATTUDA, Santiago D. F. de. **Diagnóstico de falhas em máquinas rotativas utilizando transformada de Wavelet e redes neurais artificiais.** [S.l.]: [S.n.], 2004.

AZADEGAN, S.; TRIPATHI, A. **A parallel join algorithm for SIMD architectures.** Journal of Systems and Software, 39(3), 265–280, 1997. DOI: [https://doi.org/10.1016/S0164-1212\(97\)00056-3](https://doi.org/10.1016/S0164-1212(97)00056-3).

AZANK, Felipe. **Como avaliar seu modelo de regressão:** as principais métricas para avaliar seus modelos de regressão. Medium, 2020. Disponível em: <https://medium.com/turing-talks/como-avaliar-seu-modelo-de-regress%C3%A3o-c2c8d73dab96>. Acesso em: 08 abr. 2021.

AZZEH, M.; NASSIF, A. B. **A hybrid model for estimating software project effort from Use Case Points.** Applied Soft Computing Journal, 49, 981–989, 2016. DOI: <https://doi.org/10.1016/j.asoc.2016.05.008>.

AZZEH, M.; NASSIF, A. B.; MINKU, L. L. **An empirical evaluation of ensemble adjustment methods for analogy-based effort estimation.** Journal of Systems and Software, 103, 36–52, 2015. DOI: <https://doi.org/10.1016/j.jss.2015.01.028>.

BAK, T. H.; LENNOX, G. G. Historical background. **Dementia with Lewy Bodies: and Parkinson's Disease Dementia**, p. 1–8, 2005. ISSN 00263745. DOI: <https://doi.org/10.5743/cairo/9789774160097.003.0002>.

BALDACCHINO, T.; ANDERSON, S. R.; KADIRKAMANATHAN, V. **Computational system identification for Bayesian NARMAX modelling.** Automatica, 49(9), 2641–2651, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.023>.

BALIKHIN, M. A. et al. **Using the NARMAX approach to model the evolution of energetic electrons fluxes at geostationary orbit.** Geophysical Research Letters, 38(18), 1–5, 2011. DOI: <https://doi.org/10.1029/2011GL048980>.

BARBOSA, T. S. et al. **Fault Detection and Classification in Cantilever Beams Through Vibration Signal Analysis and Higher-Order Statistics.** Journal of Control, Automation and Electrical Systems, 27(5), 535–541, 2016. DOI: <https://doi.org/10.1007/s40313-016-0255-1>.

BAROLO, M. et al. **Some issues in the design and operation of a batch distillation column with a middle vessel.** Computers and Chemical Engineering, 20(SUPPL.1), 37–42, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00017-8](https://doi.org/10.1016/0098-1354(96)00017-8).

BARRETO, Guilherme de Alencar. **Redes Neurais Artificiais: Funções de Base Radial**. 2008, 17p. Apresentação. Treinamento Companhia Energética do Ceará, 2008. Disponível em: [http://200.17.137.109:8081/xiscanoe/Members/elaine/mestrado-cin-ufpe/rbf-radial-basis-function-networks/slides\\_RBF.pdf](http://200.17.137.109:8081/xiscanoe/Members/elaine/mestrado-cin-ufpe/rbf-radial-basis-function-networks/slides_RBF.pdf). Acesso em: 05 jun. 2022.

BASE. **Revista de Administração e Contabilidade da Unisinos** (ISSN: 1984-8196). (n.d.). Disponível em: <https://revistas.unisinos.br/index.php/base>. Acesso em: 18 nov. 2021.

BASTURK, H. I.; KRSTIC, M. **Adaptive wave cancelation by acceleration feedback for ramp-connected air cushion-actuated surface effect ships**. *Automatica*, 49(9), 2591–2602. 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.017>.

BATISTELLA, C. B.; MACIEL, M. R. W. **Modeling, simulation and analysis of molecular distillators: Centrifugal and falling film**. *Computers and Chemical Engineering*, 20(SUPPL.1), 2–7, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00014-2](https://doi.org/10.1016/0098-1354(96)00014-2).

BAUER, M. H.; STICHLMAIR, J. **Superstructures for the mixed integer optimization of nonideal and azeotropic distillation processes**. *Computers and Chemical Engineering*, 20(SUPPL.1), 25–30, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00015-4](https://doi.org/10.1016/0098-1354(96)00015-4).

BAUSA, J.; WATZDORF, R. V.; MARQUARDT, W. **Minimum energy demand for nonideal multicomponent distillations in complex columns**. *Computers and Chemical Engineering*, 20(suppl.1), 55–60, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00020-8](https://doi.org/10.1016/0098-1354(96)00020-8).

BEHREND, N.; WARSCHBURGER, P. **Validation of a German version of the Body Appreciation Scale-2 (BAS-2)**. *Body Image*, 41, 216–224, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.01.020>.

BELSNES, M. M. et al. **Applying successive linear programming for stochastic short-term hydropower optimization**. *Electric Power Systems Research*, 130, 167–180, 2016. DOI: <https://doi.org/10.1016/j.epsr.2015.08.020>.

BENAVIDES-VELASCO, C. A.; QUINTANA-GARCÍA, C.; GUZMÁN-PARRA, V. F. **Trends in family business research**. *Small Business Economics*, 40(1), 41–57. DOI: <https://doi.org/10.1007/S11187-011-9362-3>.

BENNEDSEN, M.; NIELSEN, K. M.; PEREZ-GONZALEZ, F.; WOLFENZON, D. **Inside the family firm: The role of families in succession decisions and performance**. *Quarterly Journal of Economics*, 122(2), 647–691, 2007. DOI: <https://doi.org/10.1162/QJEC.122.2.647>.

BERNARDESCHI, C., FANTECHI, A.; GNESI, S. **An industrial application for the JACK environment**. *Journal of Systems and Software*, 39(3), 249–264. DOI: [https://doi.org/10.1016/S0164-1212\(97\)00057-5](https://doi.org/10.1016/S0164-1212(97)00057-5).

BERRONE, P., CRUZ, C.; GOMEZ-MEJIA, L. R. **Socioemotional Wealth in Family Firms: Theoretical Dimensions, Assessment Approaches, and Agenda for Future Research**. *Family Business Review*, 25(3), 258–279, 2012. DOI: <https://doi.org/10.1177/0894486511435355>.

- BIERNAT, A.; JACKIEWICZ, K.; BIENKOWSKI, K. **Analysis of radial vibrations frequency structure of variable reluctance generator.** International Symposium on Electrical Machines, SME 2018, 41, 2018. DOI: <https://doi.org/10.1109/ISEM.2018.8442473>.
- BIKIĆ, D.; GLAVIČ, P. **Innovative designs of reactor networks from reaction and mixing principles.** Computers and Chemical Engineering, 20(SUPPL.1), 455–460, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00086-5](https://doi.org/10.1016/0098-1354(96)00086-5).
- BINKOWSKI, C. **Síntese das técnicas de identificação de sistemas não lineares: estruturas de modelo de Hammerstein-Wiener e NARMAX.** [S.l.]: [S.n], 2016.
- BLOCK, J. H. **How to pay nonfamily managers in large family firms: A principal-agent model.** Family Business Review, 24(1), 9–27, 2011. DOI: <https://doi.org/10.1177/0894486510394359>.
- BLUMENTRITT, T. P.; KEYT, A. D.; ASTRACHAN, J. H. **Creating an environment for successful nonfamily CEOs: An exploratory study of good principals.** Family Business Review, 20(4), 321–335, 2007. DOI: <https://doi.org/10.1111/J.1741-6248.2007.00102.X>.
- BOMFIM, S. A. et al. **Toward efficient electrocatalytic degradation of iohexol using active anodes: A laser-made versus commercial anodes.** Chemosphere, vol. 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134350>.
- BONELL, S., AUSTEN, E.; GRIFFITHS, S. **Australian women’s motivations for, and experiences of, cosmetic surgery: A qualitative investigation.** Body Image, 41, 128–139, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.010>.
- BORGES, F. et al. **An Unsupervised Method based on Support Vector Machines and Higher-Order Statistics for Mechanical Faults Detection.** IEEE Latin America Transactions, 18(6), 1093–1101, 2020. DOI: <https://doi.org/10.1109/TLA.2020.9099687>.
- BOSSCHERE, D.; FIGUEIREDO, D. **Author index: Author index.** *Aging Cell*, 2(6), 345–347, 2003. DOI: <https://doi.org/10.1046/j.1474-9728.2003>.
- BOYADJIEV, C. et al. **Optimal energy integration in batch antibiotics manufacture.** Computers and Chemical Engineering, 20(SUPPL.1), 31–36, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00016-6](https://doi.org/10.1016/0098-1354(96)00016-6).
- BOYNTON, R. J. et al. **Using the NARMAX OLS-ERR algorithm to obtain the most influential coupling functions that affect the evolution of the magnetosphere.** Journal of Geophysical Research: Space Physics, 116(5), 1–8, 2011. DOI: <https://doi.org/10.1029/2010JA015505>.
- BRAGA, Newton C. **Inglês instrumental - RMS e PMPO (ING046).** Instituto NCB, 2012. Disponível em: <https://www.newtonbraga.com.br/index.php/ingles-para-eletronica/4937-ing046.html>. Acesso em: 17 fev. 2021.
- BRUBAKER, Thomas A; O’KEEFE, Kelly R. **Nonlinear parameter estimation.** [S.l.]: Academic Pr, 1979. v. 51. 341 p. ISSN 00032700. ISBN 0120782502. Disponível em:

<https://datapdf.com/nonlinear-parameter-estimation-american-chemical-society.html>. Acesso em: 14 set. 2021.

BRUNET, J.; PRICE, J.; HARRIS, C. **Body image in women diagnosed with breast cancer: A grounded theory study.** *Body Image*, 41, 417–431 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.012>.

BRUNNLIEB, C. et al. **Vasopressin modulates neural responses related to emotional stimuli in the right amygdala.** *Brain Research*, 1499, 29–42, 2022. DOI: <https://doi.org/10.1016/j.brainres.2013.01.009>.

BSI. **ISO 20816-1:2018 Mechanical vibration** — Measurement and evaluation of machine vibration — Part 1: General guidelines. 60 p. 2018.

BURKART, M.; PANUNZI, F.; SHLEIFER, A. **Family Firms.** *Journal of Finance*, 58(5), 2167–2202, 2003. DOI: <https://doi.org/10.1111/1540-6261.00601>.

BYRNE, R. P.; BOGLE, I. D. L. **An accelerated interval method for global optimization.** *Computers and Chemical Engineering*, 20(SUPPL.1), 49–54, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00019-1](https://doi.org/10.1016/0098-1354(96)00019-1).

CAO, X. et al. **Co-adsorption capabilities and mechanisms of bentonite enhanced sludge biochar for de-risking norfloxacin and Cu<sup>2+</sup> contaminated water.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134414>.

CARDINALI, R.; NORDMANN, R.; SPERBER, A. **Dynamic simulation of non-linear models of hydroelectric machinery.** *Mechanical Systems and Signal Processing*, 7(1), 29–44, 1993. DOI: [https://doi.org/10.1016/0888-3270\(93\)90003-F](https://doi.org/10.1016/0888-3270(93)90003-F).

CARDOZO, S. V.; MANLY, B. F. J.; DIAS, C. T. dos Santos. **Comparison of logistic regression methods and discrete choice model in the selection of habitats.** *Scientia Agricola*, 67(3), 327–333, 2010. DOI: <https://doi.org/10.1590/s0103-90162010000300011>.

CARVALHO, A. A. de et al. **Medição Em Tempo Real Do Teor De Umidade Em Óleo.** [S.l.]: [S.n.], 2000.

CARVALHO, L. R. de; PINHO, S. Z. de; MISCHAN, M. M. **Methods to verify parameter equality in nonlinear regression models.** *Scientia Agricola*, 67(2), 218–222, 2010. DOI: <https://doi.org/10.1590/s0103-90162010000200014>.

CARVALHO, M. M.; FLEURY, A.; LOPES, A. P. **An overview of the literature on technology roadmapping (TRM): Contributions and trends.** *Technological Forecasting and Social Change*, 80(7), 1418–1437, 2013. DOI: <https://doi.org/10.1016/J.TECHFORE.2012.11.008>.

CASTAGNA, F. et al. **Prosody recognition and audiovisual emotion matching in schizophrenia: The contribution of cognition and psychopathology.** *Psychiatry Research*, 205(3), 192–198, 2013. DOI: <https://doi.org/10.1016/j.psychres.2012.08.038>.

CERONE, V.; PIGA, D.; REGRUTO, D. **A convex relaxation approach to set-membership identification of LPV systems.** *Automatica*, 49(9), 2853–2859, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.028>.

CERRADA, M. et al. **Fault diagnosis in spur gears based on genetic algorithm and random forest.** *Mechanical Systems and Signal Processing*, 70–71, 87–103, 2015. DOI: <https://doi.org/10.1016/j.ymssp.2015.08.030>.

CHANG, S. J.; SHIM, J. **When does transitioning from family to professional management improve firm performance?** *Strategic Management Journal*, 36(9), 1297–1316, 2015. DOI: <https://doi.org/10.1002/SMJ.2289>.

CHEN, G. D.; WANG, Z. C. **Response to the Letter to Editor by Dr. M. Feldman Entitled “a Signal Decomposition or Lowpass Filtering with Hilbert Transform.”** *Mechanical Systems and Signal Processing*, 25(8), 3204, 2011. DOI: <https://doi.org/10.1016/j.ymssp.2011.05.010>.

CHEN, J., BANDONI, A.; ROMAGNOLI, J. A. **Robust statistical process monitoring.** *Computers and Chemical Engineering*, 20(SUPPL.1), 497–502, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00092-0](https://doi.org/10.1016/0098-1354(96)00092-0).

CHEN, L. et al. **CeO<sub>2</sub> nanoparticles improved cucumber salt tolerance is associated with its induced early stimulation on antioxidant system.** *Chemosphere*, vol. 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134474>.

CHENG, J.; WANG, L.; XIONG, Y. **An improved cuckoo search algorithm and its application in vibration fault diagnosis for a hydroelectric generating unit.** *Engineering Optimization*, 50(9), 1593–1608, 2018. DOI: <https://doi.org/10.1080/0305215X.2017.1401067>

CHENG, J. et al. **An Imitation medical diagnosis method of hydro-turbine generating unit based on Bayesian network.** *Transactions of the Institute of Measurement and Control*, 41(12), 3406–3420, 2019. DOI: <https://doi.org/10.1177/0142331219826665>.

CHITTOOR, R.; DAS, R. **Professionalization of management and succession performance - A vital linkage.** *Family Business Review*, 20(1), 65–79, 2007. DOI: <https://doi.org/10.1111/J.1741-6248.2007.00084.X>.

CHOI, J. S.; KIM, K.; PARK, K.; PARK, J. W. **Long-term exposure of the Mediterranean mussels, *Mytilus galloprovincialis* to polyethylene terephthalate microfibers: Implication for reproductive and neurotoxic effects.** *Chemosphere*, vol. 299. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134317>.

CHOUDHARY, Aburag et al. **Condition monitoring and fault diagnosis of induction motors: A review.** *Archives of Computational Methods in Engineering*, v. 26, p. 1221–1238, 2019. ISSN 18861784. DOI: <https://doi.org/10.1007/s11831-018-9286-z>.

CHRISMAN, J. J.; MEMILI, E.; MISRA, K. **Nonfamily managers, family firms, and the winner’s curse: The influence of noneconomic goals and bounded rationality.** *Entrepreneurship: Theory and Practice*, 38(5), 1103–1127, 2014. DOI: <https://doi.org/10.1111/ETAP.12014>.

COELHO, L. dos Santos; PESSÔA, M. W.; SUGUIMOTO, R. M. **Identificação Narmax polinomial de um trocador de calor usando algoritmo dos mínimos quadrados ortogonais.** [S.l.]: [S.n.], 2006.

COMPUTERS; CHEMICAL ENGINEERING EDITOR. **Computers & Chemical Engineering Editor.** [S.l.]: [S.n.], 1996.

CONSOLINI, L.; MAGGIORE, M. **Control of a bicycle using virtual holonomic constraints.** *Automatica*, 49(9), 2831–2839, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.021>.

CORRÊA, M. V. **Identificação de sistemas dinâmicos não-lineares utilizando modelos NARMAX racionais** – aplicação a sistemas reais. Tese (Doutorado) – Universidade Federal de Minas Gerais, 2001.

CUCCULELLI, M., PERUZZI, V.; ZAZZARO, A. **Relational capital in lending relationships: evidence from European family firms.** *Small Business Economics*, 52(1), 277–301, 2018. DOI: <https://doi.org/10.1007/s11187-018-0019-3>.

DAŹBROWSKA, A. **The first evidence of the Indian meal moth** (*Plodia interpunctella*) interaction with the silicone moulds. *Chemosphere*, vol. 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134451>.

DANIELSON, C. et al. **Constrained flow control in storage networks: Capacity maximization and balancing.** *Automatica*, 49(9), 2612–2621, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.014>.

DANTHINNE, E. S. **Beauty and the big business: A qualitative investigation of the development and implementation of the CVS Beauty Mark.** *Body Image*, 41, 74–83, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.01.012>.

DASCALU, T. et al. **Removal of the indigo color by laser beam-denim interaction.** *Optics and Lasers in Engineering*, 34(3), 179–189, 2000. DOI: [https://doi.org/10.1016/S0143-8166\(00\)00087-7](https://doi.org/10.1016/S0143-8166(00)00087-7).

DAWSON, A. **Private equity investment decisions in family firms: The role of human resources and agency costs.** *Journal of Business Venturing*, 26(2), 189–199, 2011. DOI: <https://doi.org/10.1016/J.JBUSVENT.2009.05.004>.

DEAN, J. P.; DERVAKOS, G. A. **Design of process-compatible biological agents.** *Computers and Chemical Engineering*, 20(SUPPL.1), 67–72, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00022-1](https://doi.org/10.1016/0098-1354(96)00022-1).

DEKKER, J. C. et al. **Family Firm Types Based on the Professionalization Construct: Exploratory Research.** *Family Business Review*, 26(1), 81–99, 2013. DOI: <https://doi.org/10.1177/0894486512445614>.

DEKKER, J. et al. **The Effect of Family Business Professionalization as a Multidimensional Construct on Firm Performance.** *Journal of Small Business Management*, 53(2), 516–538, 2015. DOI: <https://doi.org/10.1111/JSBM.12082>.

DELGADO, A.; VELO, E.; PUIGJANER, L. *IIJ*, 20(96), 297–302, 1996.

DERBY, A. P. et al. **Effects of temperature and salinity on bioconcentration and toxicokinetics of permethrin in pyrethroid-resistant *Hyaella azteca***. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134393>.

DETMANN, Edenio et al. **Uso de técnicas de regressão na avaliação, em bovinos de corte, da eficiência de conversão do alimento em produto: comparação entre grupos experimentais**. *Revista brasileira de zoo*, v. 41, p. 138–146, 2012.

DHARMSAKTU, K. S. et al. **Measurement of vibration with Young's fringe modulated speckle patterns in a photorefractive correlator**. *Optics and Lasers in Engineering*, 34(3), 191–202, 2000. DOI: [https://doi.org/10.1016/S0143-8166\(00\)00086-5](https://doi.org/10.1016/S0143-8166(00)00086-5).

DIMITRIADIS, V. D. et al. **A case study in hybrid process safety verification**. *Computers and Chemical Engineering*, 20(SUPPL.1), 503–508, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00093-2](https://doi.org/10.1016/0098-1354(96)00093-2).

DING, J. et al. **A stochastic games framework for verification and control of discrete time stochastic hybrid systems**. *Automatica*, 49(9), 2665–2674, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.025>.

DING, L. et al. **Consensus of second-order multi-agent systems via impulsive control using sampled hetero-information**. *Automatica*, 49(9), 2881–2886 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.014>.

DIWEKAR, U. M.; KALAGNANAM, J. R. **Robust design using an efficient sampling technique**. *Computers and Chemical Engineering*, 20(SUPPL.1), 389–394, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00075-0](https://doi.org/10.1016/0098-1354(96)00075-0).

DOEBLING, Scott W.; FARRAR, Charles R.; PRIME, Michael B. **A summary review of vibration-based damage identification methods**. *Shock and Vibration Digest*, v. 30, p. 91–105, 1998. ISSN 05831024.

DÖHLER, M.; MEVEL, L. **Subspace-based fault detection robust to changes in the noise covariances**. *Automatica*, 49(9), 2734–2743, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.019>.

DONCKELS, R.; FRÖHLICH, E. **Are Family Businesses Really Different?** European Experiences from STRATOS. *Family Business Review*, 4(2), 149–160, 1991. DOI: <https://doi.org/10.1111/J.1741-6248.1991.00149.X>.

DRAPER, Norman R.; SMITH, Harry. **Applied regression analysis**. Wiley Online Library, 2014. 1-716 p. ISBN 9781118625590. Disponível em: <https://onlinelibrary.wiley.com/doi/book/10.1002/9781118625590>. Acesso em: 18 jun. 2022.

DU, J.; WANG, S.; ZHANG, H. **Layered clustering multi-fault diagnosis for hydraulic piston pump**. *Mechanical Systems and Signal Processing*, 36(2), 487–504, 2013. DOI: <https://doi.org/10.1016/j.ymsp.2012.10.020>.

DULIBA, K. A. **Contrasting neural nets with regression in predicting performance in the transportation industry.** Proceedings of the Annual Hawaii International Conference on System Sciences, v. 4, p. 163–170, 1991. ISSN 15301605. DOI: 10.1109/HICSS.1991.184056.

DUTTA, Soumitra; SHEKHAR, Shashi; WONG, W. Y. **Decision support in non-conservative domains: Generalization with neural networks.** Decision Support Systems, v. 11, p. 527–544, 1994. ISSN 01679236. DOI: [https://doi.org/10.1016/0167-9236\(94\)90023-X](https://doi.org/10.1016/0167-9236(94)90023-X).

DYER, W. G. **Culture and Continuity in Family Firms.** Family Business Review, 1(1), 37–50, 1998. DOI: <https://doi.org/10.1111/J.1741-6248.1988.00037.X>.

EDDLESTON, K. A.; SARATHY, R.; BANALIEVA, E. R. **When a high-quality niche strategy is not enough to spur family-firm internationalization: The role of external and internal contexts.** Journal of International Business Studies, 50(5), 783–808, 2019. DOI: <https://doi.org/10.1057/S41267-018-0199-8>.

EDITORIAL BOARD. **Body Image**, 41, ii, 2022. DOI: [https://doi.org/10.1016/s1740-1445\(22\)00088-2](https://doi.org/10.1016/s1740-1445(22)00088-2).

EGUSQUIZA, M. et al. **Dynamic response of Pelton runners: Numerical and experimental analysis in prototypes.** Renewable Energy, 157, 116–129. DOI: <https://doi.org/10.1016/j.renene.2020.04.110>.

ELKAMEL, A.; KARKOUB, M.; GHARBI, R.  **$T \div -gZ-x \text{ osw } OUw + uo = \theta Oz \text{ tll. } 20(96)$** , 515–520, 1996.

EMPRESA DE PESQUISA ENERGÉTICA. **Matriz Energética e Elétrica.** 2019. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-ben>. Acesso em: 17 ago. 2021.

ENES, I.; SARAIVA, P. **Optimization of operating strategies in  $\beta$ -carotene microalgae bioreactors.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00094-4](https://doi.org/10.1016/0098-1354(96)00094-4).

ENGEL, Paulo M. **Sistema de Inferência Fuzzy baseado em Redes Adaptativas (ANFIS)** Disponível em: <http://www.inf.ufrgs.br/~engel/data/media/file/cmp121/ANFIS.pdf>. Acesso em: 13 nov. 2021.

ENSAFI, A. A. et al. **Graphene-like sheets supported Fe–Co layered double hydroxides nanoflakes as an efficient electrocatalyst for both hydrogen and oxygen evolution reaction, A green investigation.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134251>.

ERKAYA, S. **Prediction of vibration characteristics of a planar mechanism having imperfect joints using neural network.** Journal of Mechanical Science and Technology, 26(5), 1419–1430, 2012. DOI: <https://doi.org/10.1007/s12206-012-0308-8>.



FAGIANO, L.; TEEL, A. R. **Generalized terminal state constraint for model predictive control.** *Automatica*, 49(9), 2622–263, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.019>.

FANG, H., CALLAFON, R. A. CORTÉS, J. **Simultaneous input and state estimation for nonlinear systems with applications to flow field estimation.** *Automatica*, 49(9), 2805–2812, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.010>.

FARIAS, D. S. D. de et al. **Bioaccumulation of total mercury, copper, cadmium, silver, and selenium in green turtles (*Chelonia mydas*) stranded along the Potiguar Basin, northeastern Brazil.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134331>.

FELLER, C.; EBENBAUER, C. **A stabilizing iteration scheme for model predictive control based on relaxed barrier functions.** *Automatica*, 80, 328–339, 2017. DOI: <https://doi.org/10.1016/j.automatica.2017.02.001>.

FENG, J. R.; DENG, Q. X.; NI, H. G. **Photodegradation of phthalic acid esters under simulated sunlight: Mechanism, kinetics, and toxicity change.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134475>.

FERNANDEZ, O. et al. **A decision support maintenance management system: Development and implementation.** *International Journal of Quality and Reliability Management*, 20(8), 965–979, 2003. DOI: <https://doi.org/10.1108/02656710310493652>.

FERREIRA, I. J., et al. **Assessment of deep eutectic solvents toxicity in zebrafish (*Danio rerio*).** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134415>

FEVOTTE, G.; BARUDIO, I.; MCKENNA, T. F. **Computer-aided parameter estimation and on-line monitoring of emulsion and solution polymerisation reactors.** *Computers and Chemical Engineering*, 20(SUPPL.1), 581–586, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00106-8](https://doi.org/10.1016/0098-1354(96)00106-8).

FIGUEROA, J. L.; DESAGES, A. C.; ROMAGNOLI, J. A. **Steady-state back-off calculation: Use of piecewise lineal approximation.** *Computers and Chemical Engineering*, 20(SUPPL.1), 527–532, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00097-x](https://doi.org/10.1016/0098-1354(96)00097-x).

FINNIE, G. R.; WITTIG, G. E.; DESHARNAIS, J. M. **A comparison of software effort estimation techniques: Using function points with neural networks, case-based reasoning and regression models.** *Journal of Systems and Software*, 39(3), 281–289, 1997. DOI: [https://doi.org/10.1016/S0164-1212\(97\)00055-1](https://doi.org/10.1016/S0164-1212(97)00055-1).

FLEMING, P. et al. **Editorial Board.** *Automatica*, 49(9), I, 2013. DOI: [https://doi.org/10.1016/s0005-1098\(13\)00383-x](https://doi.org/10.1016/s0005-1098(13)00383-x).

FONYO, Z.; BENKO, N. **Enhancement of process integration by heat pumping.** *Computers and Chemical Engineering*, 20(SUPPL.1), 1–6, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00025-7](https://doi.org/10.1016/0098-1354(96)00025-7).

FRAGA, E. S.; MATIAS, T. R. S. **Synthesis and optimization of a nonideal distillation system using a parallel genetic algorithm.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00024-5](https://doi.org/10.1016/0098-1354(96)00024-5).

FRAILE-ARDANUY, J. et al. **Variable-speed hydro generation: Operational aspects and control.** IEEE Transactions on Energy Conversion, 21(2), 569–574, 2006. DOI: <https://doi.org/10.1109/TEC.2005.858084>.

FRANK, P.; HEDMAN, B.; HODGSON, K. O. **XAS spectroscopy, sulfur, and the brew within blood cells from *Ascidia ceratodes*.** Journal of Inorganic Biochemistry, 131, 99–108, 2014. DOI: <https://doi.org/10.1016/j.jinorgbio.2013.11.004>.

FRARE, Anderson B. et al. **Empresa familiar versus empresa não familiar: características das ferramentas e sistemas de controle gerencial.** Revista de Administração, Contabilidade e Economia da Fundace. (n.d.). Disponível em: <https://www.fundace.org.br/revistaracef/index.php/racef/article/view/747>. Acesso em: 27 abr. 2021.

FRASER, E.; MISENER, K.; LIBBEN, M. **Exploring the impact of a gratitude-focused meditation on body dissatisfaction: Can a brief auditory gratitude intervention protect young women against exposure to the thin ideal?** Body Image, 41, 331–341, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.002>.

FREDERICK, D. A. et al. **Demographic and sociocultural predictors of face image satisfaction: The U.S. Body Project I.** Body Image, 41, 1–16 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.01.016>.

FRKA, S. et al. **Seasonal variability of nitroaromatic compounds in ambient aerosols: Mass size distribution, possible sources and contribution to water-soluble brown carbon light absorption.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134381>.

FURTADO, R. M. **Identificação de falhas estruturais usando sensores e atuadores piezelétricos e redes neurais artificiais.** p. 154, 2004. Disponível em: <http://hdl.handle.net/11449/94553>. Acesso em: 18 mar. 2022.

GALLORINI, A.; LOIZEAU, J. L. **Lake snow as a mercury methylation micro-environment in the oxic water column of a deep peri-alpine lake.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134306>.

GANSON, K. T.; RODGERS, R. F. **Problematic muscularity-oriented behaviors: Overview, key gaps, and ideas for future research.** Body Image, 41, 262–266, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.03.005>.

GAO, H. et al. **Lag associations of gestational phthalate exposure with maternal serum vitamin D levels: Repeated measure analysis.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134319>.

GAVRILA, I. S.; IEDEMA, P. **Phenomena-driven process design.** 20(96), 103–108. [S.l.]: [S.n], 1996.

- GAYE, O. et al.  **$H_{\infty}$  stabilization of the current profile in tokamak plasmas via an LMI approach.** *Automatica*, 49(9), 2795–2804, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.011>.
- GENÇ, O.; KIŞI, Ö.; ARDIÇLIOĞLU, M. **Determination of Mean Velocity and Discharge in Natural Streams Using Neuro-Fuzzy and Neural Network Approaches.** *Water Resources Management*, 28(9), 2387–2400, 2014. DOI: <https://doi.org/10.1007/s11269-014-0574-6>.
- GEREMIA, C. A.; SCHMITT, D. C.; ZANELLA, C. **Nível de maturidade em gerenciamento de projetos: estudo de caso em empresa familiar de médio porte do ramo alimentício.** *Revista de Gestão e Projetos*, 11(2), 110–132, 2020. DOI: <https://doi.org/10.5585/gep.v11i2.16911>.
- GHIASI, M. M. et al. **Application of ANFIS soft computing technique in modeling the CO<sub>2</sub> capture with MEA, DEA, and TEA aqueous solutions.** *International Journal of Greenhouse Gas Control*, 49, 47–54, 2016. DOI: <https://doi.org/10.1016/j.ijggc.2016.02.015>.
- GIOVANNONI, E.; MARAGHINI, M. P.; RICCABONI, A. **Transmitting knowledge across generations: The role of management accounting practices.** *Family Business Review*, 24(2), 126–150, 2011. DOI: <https://doi.org/10.1177/0894486511406722>.
- GLASS, R. L. **Cobol: Is it dying - Or thriving?** *Data Base for Advances in Information Systems*, 30(1), 15–18, 1999. DOI: [https://doi.org/10.1016/s0164-1212\(97\)80357-3](https://doi.org/10.1016/s0164-1212(97)80357-3).
- GLASS, R. L.; NI, D. C. *Systems and*. 39. [S.l]: [S.n], 1997.
- GOH, P. S. et al. **Nanomaterials for microplastic remediation from aquatic environment: Why nano matters?** In *Chemosphere* (Vol. 299). Elsevier Ltd, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134418>.
- GOHIL, P. P.; SAINI, R. P. **Effect of temperature, suction head and flow velocity on cavitation in a Francis turbine of small hydro power plant.** *Energy*, 93, 613–624, 2015. DOI: <https://doi.org/10.1016/j.energy.2015.09.042>.
- GOLDFARB, S.; DEALMEIDA, J. O. E. *Pergamon*. 20(96), 91–96, 1996.
- GOMEZ-MEJIA, L. R.; NEACSU, I.; MARTIN, G. **CEO Risk-Taking and Socioemotional Wealth: The Behavioral Agency Model, Family Control, and CEO Option Wealth.** *Journal of Management*, 45(4), 1713–1738, 2019. DOI: <https://doi.org/10.1177/0149206317723711>.
- GOMEZ-MEJIA, L. R.; NUÑEZ-NICKEL, M.; GUTIERREZ, I. **The role of family ties in agency contracts.** *Academy of Management Journal*, 44(1), 81–95, 2001. DOI: <https://doi.org/10.2307/3069338>.
- GOMES, L. A. de V. et al. **Unpacking the innovation ecosystem construct: Evolution, gaps and trends.** *Technological Forecasting and Social Change*, 136, 30–48, 2018. DOI: <https://doi.org/10.1016/J.TECHFORE.2016.11.009>. Acesso em: 19 mai. 2022.

GONÇALVES, A. R. **Fundamentos e Aplicações de Técnicas de Aprendizado de Máquina**. 2008. Disponível em: <https://andrerick.github.io/posts/2018/05/blog-post-2/>. Acesso em: 08 fev. 2022.

GONDHALEKAR, R.; OLDEWURTEL, F.; JONES, C. N. **Least-restrictive robust periodic model predictive control applied to room temperature regulation**. *Automatica*, 49(9), 2760–2766, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.009>.

GONZÁLEZ, A. **Robust stabilization of linear discrete-time systems with time-varying input delay**. *Automatica*, 49(9), 2919–2922, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.031>.

GOUVEIA, Rosimar. **Desvio Padrão**. Toda Matéria, 2022. Disponível em: <https://www.todamateria.com.br/desvio-padrão/#:~:text=Odesviopadrão%20uma,maishomogêneos%20dados>. Acesso em: 22 jul. 2021.

GRABOT, B. et al. **ERP 2.0, what for and how?** *Computers in Industry*, 65(6), 976–1000, 2014. DOI: <https://doi.org/10.1016/j.compind.2014.02.017>.

GRAÇA, C. A. L. et al. **Presence of metals and metalloids in crumb rubber used as infill of worldwide synthetic turf pitches: Exposure and risk assessment**. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134379>.

GRIFFITHS, S. et al. **“Spring is the best time to lose weight”**: Evidence that dieting is seasonal and reaches peak intensity during Spring. *Body Image*, 41, 406–416, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.011>.

GROSSMANN, I. E.; TORKAY, M. **Equations**. 20(96), 339–344, 1996.

GRUBER, E.; KALKBRENNER, M. T.; HITTER, T. L. **A complex conceptualization of beauty in Latinx women: A mixed methods study**. *Body Image*, 41, 432–442, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.008>.

GRUHN, G.; COLDITZ, S. **Interval approach to process system engineering problems**. *Computers and Chemical Engineering*, 20(SUPPL.1), 533–538, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00098-1](https://doi.org/10.1016/0098-1354(96)00098-1).

GU, Zhengrong; LAM, Harry.; DHURJATI, Prasad S. **Feature correlation method for enhancing fermentation development: A comparison of quadratic regression with artificial neural networks**. *Computers and Chemical Engineering*, v. 20, 1996. ISSN 00981354. DOI: [https://doi.org/10.1016/0098-1354\(96\)00078-6](https://doi.org/10.1016/0098-1354(96)00078-6).

GUAN, Z. et al. **Fe–O–Zr in MOF for effective photo-Fenton Bisphenol A degradation: Boosting mechanism of electronic transmission**. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134481>.

GUDMUNSON, C. G.; DANES, S. M. **Family social capital in family businesses: A stocks and flows investigation**. *Family Relations*, 62(3), 399–414, 2013. DOI: <https://doi.org/10.1111/FARE.12017>.

GULATI, S. ET AL. **Improving the air quality with Functionalized Carbon Nanotubes: Sensing and remediation applications in the real world.** In *Chemosphere* (Vol. 299). Elsevier Ltd, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134468>.

GUNDERSEN, T.; DUVOLD, S.; HASHEMI-AHMADY, A. **An extended vertical MILP model for heat exchanger network synthesis.** *Computers and Chemical Engineering*, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00027-0](https://doi.org/10.1016/0098-1354(96)00027-0).

GUO, B. Z.; JIN, F. F. **The active disturbance rejection and sliding mode control approach to the stabilization of the Euler-Bernoulli beam equation with boundary input disturbance.** *Automatica*, 49(9), 2911–2918, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.018>.

GUO, J. et al. **Development of single-event-effects analysis system at the IMP microbeam facility.** *Nuclear Instruments and Methods in Physics Research, Section B: Beam Interactions with Materials and Atoms*, 404, 250–253, 2017. DOI: <https://doi.org/10.1016/j.nimb.2017.02.012>.

GUO, R. et al. **The environmental fate of biomass associated polybrominated diphenyl ethers.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134397>.

GUO, W.; YANG, J. **Dynamic performance analysis of hydro-turbine governing system considering combined effect of downstream surge tank and sloping ceiling tailrace tunnel.** *Renewable Energy*, 129, 638–651, 2017. DOI: <https://doi.org/10.1016/j.renene.2018.06.040>.

HAINSTOCK, M. L.; TANG, Y. **Potential step study of electrooxidation of methanol in 1-butyl-3-methylimidazolium tetrafluoroborate.** *Measurement: Journal of the International Measurement Confederation*, 58, 21–26, 2014. DOI: <https://doi.org/10.1016/j.measurement.2014.08.021>.

HALL, A.; NORDQVIST, M. **Professional management in family businesses: Toward an extended understanding.** *Family Business Review*, 21(1), 51–69, 2008. DOI: <https://doi.org/10.1111/J.1741-6248.2007.00109.X>.

HAN, E. S.; ANNIE GOLEMAN DANIEL; BOYATZIS, R. M. **Design & Simulation of Fuzzy PID for Hydro Power Plant.** *Journal of Chemical Information and Modeling*, 53(9), 1689–1699, 2019.

HAND, D.; MANNILA, H. SMYTH, P. **Principles of data mining.** [S.l.]: MIT Press, 2001.  
HARJUNKOSKI, I. et al. **Different formulations for solving trim loss problems in a paper-converting mill with ILP.** *Computers and Chemical Engineering*, 20(SUPPL.1), 121–126, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00031-2](https://doi.org/10.1016/0098-1354(96)00031-2).

HARRIGER, J. A. et al. **The dangers of the rabbit hole: Reflections on social media as a portal into a distorted world of edited bodies and eating disorder risk and the role of algorithms.** In *Body Image* (Vol. 41, pp. 292–297), 2022. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.bodyim.2022.03.007>.

HARROP, E. N.; KATTARI, S. K. **“I’m coming out!”: An autoethnographic situation of self/ves within queer fat chronically ill identity.** *Body Image*, 41, 209–215, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.005>.

HASANZADEH, R. et al. **Low-emission and energetically efficient co-gasification of coal by incorporating plastic waste: A modeling study.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134408>.

HASHEMZADEH, F.; HASSANZADEH, I.; TAVAKOLI, M. **Teleoperation in the presence of varying time delays and sandwich linearity in actuators.** *Automatica*, 49(9), 2813–2821, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.012>.

HASSAN, A. et al. **Vibration control of a Stirling engine with an electromagnetic active tuned mass damper.** *Control Engineering Practice*, 51, 108–120, 2016. DOI: <https://doi.org/10.1016/j.conengprac.2016.03.014>.

HASTIE, J.; TIBSHIRANI, R.; FRIEDMAN, T. **The elements of statistical learning: data mining, inference, and prediction.** [S.l.]: Springer, 2009.

HAUAN, S.; LIEN, K. M. **Geometric visualisation of reactive fixed points.** *Computers and Chemical Engineering*, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00033-6](https://doi.org/10.1016/0098-1354(96)00033-6).

HAUKSDÓTTIR, D.; MORTENSEN, N. H.; NIELSEN, P. E. **Identified adjustability dimensions when generating a product specific requirements specification by requirements reuse.** *Computers in Industry*, 65(6), 952–966, 2014. DOI: <https://doi.org/10.1016/j.compind.2014.02.011>.

HAYKIN, S. **Adaptive filter theory.** [S.l.]: Prentice Hall, 2002.

HAZZARD, V. M. et al. **Measurement invariance of body image measures by age, gender, sexual orientation, race, weight status, and age: The U.S. Body Project I.** *Body Image*, 41, 97–108, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.01.015>.

HE, Y.; KENNES, C.; LENS, P. N. L. **Enhanced solventogenesis in syngas bioconversion: Role of process parameters and thermodynamics.** In *Chemosphere* (Vol. 299), 2022. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134425>.

HEIAT, A. **Comparison of artificial neural network and regression models for estimating software development effort.** *Information and Software Technology*, 44(15), 911–922, 2002. DOI: [https://doi.org/10.1016/S0950-5849\(02\)00128-3](https://doi.org/10.1016/S0950-5849(02)00128-3).

HEIDARI, E.; SOBATI, M. A.; MOVAHEDIRAD, S. **Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN).** *Chemometrics and Intelligent Laboratory Systems*, 155, 73–85, 2016. DOI: <https://doi.org/10.1016/j.chemolab.2016.03.031>.

HEIKKILÄ, A. M.; HURME, M.; JÄRVELÄINEN, M. **Safety considerations in process synthesis.** *Computers and Chemical Engineering*, 20(SUPPL.1), 2006. DOI: [https://doi.org/10.1016/0098-1354\(96\)00030-0](https://doi.org/10.1016/0098-1354(96)00030-0).

HERNANDEZ-VARGAS; E. A., COLANERI, P.; MIDDLETON, R. H. **Optimal therapy scheduling for a simplified HIV infection model.** *Automatica*, 49(9), 2874–2880, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.001>

HEYEN, G.; MARÉCHAL, E.; KALITVENTZEFF, B. **Sensitivity calculations and variance analysis in plant measurement reconciliation.** *Computers and Chemical Engineering*, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00099-3](https://doi.org/10.1016/0098-1354(96)00099-3).

HILLEN, C.; LAVARDA, C. E. F. **Orçamento e sucessão intergeracional em empresa familiar.** *Advances in Scientific and Applied Accounting*. 2022. DOI: <https://doi.org/10.14392/ASAA.2021140309>.

HOCH, P. M.; ELICECHE, A. M. **Pergamon**. 20(96), 1996.

HORČIČKOVÁ, Z.; STASIULIS, N. **Philosophy of economics and management: Youth participation in family business and national economy.** *Filosofija, Sociologija*, 30(1), 17–26, 2019. DOI: <https://doi.org/10.6001/FIL-SOC.V30I1.3912>.

HORI, Y.; TAKADA, M.; HARA, S. **Biochemical oscillations in delayed negative cyclic feedback: Existence and profiles.** *Automatica*, 49(9), 2581–2590, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.04.020>.

HORN, C. S. et al. **Computer-aided process design: The design of an affinity-based continuous separation process.** *Computers and Chemical Engineering*, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00032-4](https://doi.org/10.1016/0098-1354(96)00032-4).

HOWORTH, C. et al. **Company metamorphosis: professionalization waves, family firms and management buyouts.** *Small Business Economics*, 47(3), 803–817. 2016. DOI: <https://doi.org/10.1007/S11187-016-9761-6>.

HRUSCHKA, Harald. **Determining market response functions by neural network modeling: A comparison to econometric techniques.** *European Journal of Operational Research*, v. 66, p. 27–35, 1993. ISSN 03772217. DOI: [https://doi.org/10.1016/0377-2217\(93\)90203-Y](https://doi.org/10.1016/0377-2217(93)90203-Y).

HU, Q., ZHANG, Y.; YAO, J. **Family involvement in middle management and its impact on the labor productivity of family firms.** *Management and Organization Review*, 14(2), 249–274, 2018. DOI: <https://doi.org/10.1017/MOR.2018.5>.

HU, X. L.; WELSH, J. S. **Necessary and sufficient convergence conditions of the instrumental variable method for identification.** *Automatica*, 49(9), 2693–2703 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.004>.

HUA, J. Z.; BRENNECKE, J. F.; STADTHER, M. A. **Reliable phase stability analysis for cubic equation of state models.** *Computers and Chemical Engineering*, 20(SUPPL.1), 395–400. 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00076-2](https://doi.org/10.1016/0098-1354(96)00076-2).

HUANG, M. et al. **Effects of pyrolysis temperature on proton and cadmium binding properties onto biochar-derived dissolved organic matter: Roles of fluorophore and chromophore.** *Chemospher*, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134313>.

HUANG, S. J. **Application of genetic based fuzzy systems to hydroelectric generation scheduling.** IEEE Transactions on Energy Conversion, 14(3), 724–730, 1999. DOI: <https://doi.org/10.1109/60.790942>.

HUNG, S. C.; WHITTINGTON, R. **Agency in national innovation systems: Institutional entrepreneurship and the professionalization of Taiwanese IT.** Research Policy, 40(4), 526–538, 2011. DOI: <https://doi.org/10.1016/J.RESPOL.2011.01.008>.

HYDRO, V. **Treinamento de turbina.** [S.l.]: [S.n.], [s.d.].

IBRAHIM, I. et al. **Highly stable gold nanolayer membrane for efficient solar water evaporation under a harsh environment.** Chemosphere, 299. 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134394>.

IGNOVA, M. et al. **Towards intelligent process supervision: industrial penicillin p- process data (validation ~ " sensor failure– ~ action ( fault ~ (simulation detection performance) estimation ) I Diagnosis Fault 1 Corrective Action.** 2(96), 1996.

IRIS POWER. **Air gap monitoring.** Iris Power, 2021. Disponível em: <https://irispower.com/monitoring/air-gap-monitoring/>. Acesso em: 04 mai. 2021.

INMAN, Daniel. **Engineering vibration.** [S.l.]: [S.n.], 1996. 560 p.

JACKSON, A. M. et al. **Body image and eating behaviors: A latent profile analysis.** Body Image, 41, 396–405, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.013>.

JACOBS, R. et al. **A knowledge based system for reactor selection.** Computers and Chemical Engineering, 20(SUPPL.1), 65–70, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00038-5](https://doi.org/10.1016/0098-1354(96)00038-5).

JAHROMI, M. E.; EHSAN, M.; MEYABADI, A. F. **A dynamic fuzzy interactive approach for DG expansion planning.** International Journal of Electrical Power and Energy Systems, 43(1), 1094–1105, 2012. DOI: <https://doi.org/10.1016/j.ijepes.2012.06.017>.

JIN, A. K. **An introduction to temperature sensors.** Sensor review, vol. 23, nº2, 2003, p. 120.

JAIN, A. K; BHARGAVA, P. **Handbook of industrial instrumentation.** [S.l.]: Springer, 2017.

JAKSLAND, C.; GANI, R. **An integrated approach to process/product design and synthesis based on properties-process relationship.** Computers and Chemical Engineering, 20(SUPPL.1), 151–156, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00036-1](https://doi.org/10.1016/0098-1354(96)00036-1).

JENSEN, A. K.; GANI, R. **A computer aided system for generation of problem specific process models.** Department of Chemical Engineering, Technical University of Denmark i Parts of an Integrated Computer Aided System. 20(96), 145–150, 1996.

JIAO, Y.; QIAO, W. **A hierarchical power management strategy for multiple single-phase roadway microgrids.** IEEE Power and Energy Society General Meeting, 1–5, 2013. DOI: <https://doi.org/10.1109/PESMG.2013.6673029>.



JIN, Y. et al. **Axiomatic Design Method for Supercritical Rotor Dynamics Integrating Nonlinear Deep Knowledge**. *Procedia CIRP*, 53, 237–246, 2016. DOI: <https://doi.org/10.1016/j.procir.2016.06.100>.

JONES, C. D.; MAKRI, M.; GOMEZ-MEJIA, L. R. **Affiliate directors and perceived risk bearing in publicly traded, family-controlled firms: The case of diversification**. *Entrepreneurship: Theory and Practice*, 32(6 SPEC. ISS.), 1007–1026, 2008. DOI: <https://doi.org/10.1111/J.1540-6520.2008.00269.X>.

JUNIOR, G. M. D. O. **Máquina de Vetores Suporte: estudo e análise de parâmetros para otimização de resultado**. [S.l.]: [S.n.]. 2010.

JÚNIOR, W. R. L.; ALMEIDA, V. M.; MARTINS, S. Â. M. **Identificação de um motor/gerador CC por meio de modelos polinomiais autoregressivos e redes neurais artificiais**. XIII Simpósio Brasileiro de Automação Inteligente, 2017.

KAFAROV, V. et al. **Computer aided design of multifunctional composite materials**. *Computers and Chemical Engineering*, 20(SUPPL.1), 431–434, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00082-8](https://doi.org/10.1016/0098-1354(96)00082-8).

KALDMÄE, A. et al. **Measurement feedback disturbance decoupling in discrete-time nonlinear systems**. *Automatica*, 49(9), 2887–2891, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.013>.

KANDPAL, H. C.; MEHTA, D. S.; VAISHYA, J. S. **Simple method for measurement of surface roughness using spectral interferometry**. *Optics and Lasers in Engineering*, 34(3), 139–148, 2000. DOI: [https://doi.org/10.1016/S0143-8166\(00\)00098-1](https://doi.org/10.1016/S0143-8166(00)00098-1).

KAPLAN, K.; KUNCAN, M.; ERTUNÇ, H. M. **Sistem i model i kullanarak kest i rilmes i neuro-fuzzy inference system**. 1–4. [S.l.]: [S.n.]. 2015.

KELLECI, R. et al. **CEO Personality: A Different Perspective on the Nonfamily Versus Family CEO Debate**. *Family Business Review*, 32(1), 31–57, 2019. DOI: <https://doi.org/10.1177/0894486518811222>.

KHAN, S.; ZEYAD, M. T.; MALIK, A. **Genotoxicity assessment of textile waste contaminated soil and characterization of textile dye degradation by a novel indigenous bacterium *Ochrobactrum intermedium* BS39**. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134082>.

KHONG, S. Z. et al. **Unified frameworks for sampled-data extremum seeking control: Global optimisation and multi-unit systems**. *Automatica*, 49(9), 2720–2733, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.020>.

KHOSROVYAN, A. et al. **Polyamide microplastic exposure elicits rapid, strong and genome-wide evolutionary response in the freshwater non-biting midge *Chironomus riparius***. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134452>.

KHUONG, D. A. et al. **The investigation of activated carbon by K<sub>2</sub>CO<sub>3</sub> activation: Micropores- and macropores-dominated structure.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134365>.

KING, J. M. P.; BAÑARES-ALCÁNTARA, R. **The extension and evolution of the process design representation.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00039-7](https://doi.org/10.1016/0098-1354(96)00039-7).

KIRANOUDIS, C. T.; MAROULIS, Z. B.; MARINOS-KOURIS, D. **Drying of solids: Selection of some continuous operation dryer types.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00040-3](https://doi.org/10.1016/0098-1354(96)00040-3).

KLEINSCHRODT, F. J.; JONES, J. D. **Industrial vision for process optimization.** Computers and Chemical Engineering, 20(SUPPL.1), 473–483, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00089-0](https://doi.org/10.1016/0098-1354(96)00089-0).

KLEYNHANS, Tania et al. **Predicting top-of-atmosphere thermal radiance using merra-2 atmospheric data with deep learning.** Remote Sensing, v. 9, p. 1–16, 2017. ISSN 20724292. DOI: <https://doi.org/10.3390/rs9111133>.

KŁODOWSKI, A. et al. **The use of the flexible multibody approach for lower body skeletal loading analysis.** Procedia IUTAM, 2, 93–100, 2011. DOI: <https://doi.org/10.1016/j.piutam.2011.04.010>.

KOH, K. Y. et al. **Leaching of organic matters and formation of disinfection by-product as a result of presence of microplastics in natural freshwaters.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134300>.

KRISHNAN, R. **Signal processing for machine condition monitoring and fault diagnosis.** [S.l.]: Springer, 2009.

KRISHNAN, S.; UMASANKAR, P.; MOHANA, P. **A smart FPGA based design and implementation of grid connected direct matrix converter with IoT communication.** Microprocessors and Microsystems, 76, 2020. DOI: <https://doi.org/10.1016/j.micpro.2020.103107>.

KYRIAKOPOULOU, D. J.; KALITVENTZEFF, B. **Validation of measurement data using an interior point SQP.** Computers and Chemical Engineering, 20(SUPPL.1), 563–568, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00103-2](https://doi.org/10.1016/0098-1354(96)00103-2).

LABABIDI, H. M. S.; ALATIQUI, I. M.; BAÑARES-ALCÁNTARA, R. **Application of controllability analysis tools during the conceptual design stage.** Computers and Chemical Engineering, 20(SUPPL.1), 207–212, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00045-2](https://doi.org/10.1016/0098-1354(96)00045-2).

LACERDA, W. S. **Arquitetura das RNAs.** [S.l.: s.n.], 2020.

LAI, R.; LI, X. **Verification of the ISO ACSE protocol using deductive machine.** Journal of Systems and Software, 39(3), 223–247, 1997. DOI: [https://doi.org/10.1016/S0164-1212\(97\)00116-1](https://doi.org/10.1016/S0164-1212(97)00116-1).

LANGMING, Z.; XIAOHU, Z.; BANGLEI, G. **A flexible method for multi-view point clouds alignment of small-size object.** *Measurement: Journal of the International Measurement Confederation*, 58, 115–129, 2014. DOI: <https://doi.org/10.1016/j.measurement.2014.08.023>.

LEE, J.; UM, K. **Comparison in a back-bead prediction of gas metal arc welding using multiple regression analysis and artificial neural network.** *Optics and Lasers in Engineering*, 34(3), 149–158, 2000. DOI: [https://doi.org/10.1016/S0143-8166\(00\)00097-X](https://doi.org/10.1016/S0143-8166(00)00097-X).

LEE, K.; CHO, H.; JUNG, M. **Simultaneous control of vehicle routing and inventory for dynamic inbound supply chain.** *Computers in Industry*, 65(6), 1001–1008, 2014. DOI: <https://doi.org/10.1016/j.compind.2014.03.001>.

LEE, K. W. et al. **Stochastic dynamic simulation of chemical processes with changing uncertainties.** *Computers and Chemical Engineering*, 20(SUPPL.1), 557–562, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00102-0](https://doi.org/10.1016/0098-1354(96)00102-0).

LEE, S. H. et al. **Distribution patterns and transportation behavior of alkylphenol polyethoxylate degradation metabolites among river, port area, and coastal water bodies of Kaohsiung City, Taiwan.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134411>.

LEE, S.; PARK, S. **Synthesis of mass exchange network using process graph theory.** *Computers and Chemical Engineering*, 20(SUPPL.1), 0–4, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00044-0](https://doi.org/10.1016/0098-1354(96)00044-0).

LEGAULT, L.; SAGO, A. **When body positivity falls flat: Divergent effects of body acceptance messages that support vs. undermine basic psychological needs.** *Body Image*, 41, 225–238, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.013>.

LEITE, D. **PSI 531 – Sistemas Fuzzy.** [S.l.]: [S.n.], 2020.

LEONE, H. **A knowledge-based system for HAZOP studies.** *Computers & Chemical Engineering*, 20(96), S369–S374, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00072-5](https://doi.org/10.1016/0098-1354(96)00072-5).

LEYDEN, E. et al. **Short-term seawater inundation induces metal mobilisation in freshwater and acid sulfate soil environments.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134383>.

LI, H. et al. **Pumping phase modulation analysis for operational quality of a pumped-storage generating system.** *Energy Conversion and Management*, 199(June), 111989, 2019. DOI: <https://doi.org/10.1016/j.enconman.2019.111989>.

LI, K. et al. **Catalytic pyrolysis of film waste over Co/Ni pillared montmorillonites towards H<sub>2</sub> production.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134440>.

LI, X.; GENG, G.; JIANG, Q. **A hierarchical energy management strategy for grid-connected microgrid.** *IEEE Power and Energy Society General Meeting*, 2014-*Octob*(October), 2014. DOI: <https://doi.org/10.1109/PESGM.2014.6939515>.

LI, Zhaohui; AI, Y.; SHI, Huixuan. **Optimal maintenance information system of gezhouba hydro power plant.** IEEE Power Engineering Society General Meeting, PES, p. 1–5, 2007. DOI: 10.1109/PES.2007.385722.

LI, Z. et al. **Virtual prototype and experimental research on gear multi-fault diagnosis using wavelet-autoregressive model and principal component analysis method.** Mechanical Systems and Signal Processing, 25(7), 2589–2607, 2011. DOI: <https://doi.org/10.1016/j.ymsp.2011.02.017>.

LIANG, Dejua et al. **Examining the utility of nonlinear machine learning approaches versus linear regression for predicting body image outcomes: The u.s. body project i.** Body Image, Elsevier Ltda, v. 41, p. 32–45, 6, 2022. ISSN 17401445. DOI: <https://doi.org/10.1016/j.bodyim.2022.01.013>.

LIANG, R. H. **A noise annealing neural network for hydroelectric generation scheduling with pumped-storage units.** IEEE Transactions on Power Systems, 15(3), 1008–1013, 2000. DOI: <https://doi.org/10.1109/59.871726>.

LIAO, G. P. et al. **Hydroelectric Generating Unit Fault Diagnosis Using 1-D Convolutional Neural Network and Gated Recurrent Unit in Small Hydro.** IEEE Sensors Journal, 19(20), 9352–9363, 2019. DOI: <https://doi.org/10.1109/JSEN.2019.2926095>.

LIAO, G. P. et al. **Hydroelectric Generating Unit Fault Diagnosis Using 1-D Convolutional Neural Network and Gated Recurrent Unit in Small Hydro.** IEEE Sensors Journal, 19(20), 9352–9363, 2019. DOI: <https://doi.org/10.1109/JSEN.2019.2926095>.

LIENQUEO, M. E. et al. **An expert system for the selection and synthesis of multistep protein separation processes.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00042-7](https://doi.org/10.1016/0098-1354(96)00042-7).

LIM, T. H. **Rotating machinery vibration: from analysis to troubleshooting.** John Wiley & Sons, 2018.

LIMA, Robson R. **Estudo comparativo de técnicas de inteligência computacional para estimação dos requerimentos energéticos de gado bovino.** 2018. 96f. Dissertação (Mestrado em Engenharia de Sistemas e Automação) – Universidade Federal de Lavras, Lavras, 2018. Disponível em: [http://repositorio.ufla.br/bitstream/1/30474/1/DISSERTA%c3%87%e3%83O\\_Estudo%20comparativo%20de%20t%c3%a9cnicas%20de%20intelig%c3%aancia%20computacional%20para%20estima%c3%a7%e3%a3o%20dos%20requerimentos%20energ%c3%a9ticos.pdf](http://repositorio.ufla.br/bitstream/1/30474/1/DISSERTA%c3%87%e3%83O_Estudo%20comparativo%20de%20t%c3%a9cnicas%20de%20intelig%c3%aancia%20computacional%20para%20estima%c3%a7%e3%a3o%20dos%20requerimentos%20energ%c3%a9ticos.pdf). Acesso em: 01 jul. 2021.

LINGAMDINNE, L. P. et al. **Highly efficient surface sequestration of Pb<sup>2+</sup> and Cr<sup>3+</sup> from water using a Mn<sub>3</sub>O<sub>4</sub> anchored reduced graphene oxide: Selective removal of Pb<sup>2+</sup> from real water.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134457>.

LISSONI, J. et al. **Empresas familiares: Como a família e apropriedade modelam a profissionalização do negócio.** Revista Brasileira de Gestao de Negocios, 12(37), 464–479, 2010. DOI: <https://doi.org/10.7819/RBGN.V12I37.637>.

LIU, B. **Fault diagnosis and signal processing in mechanical systems.** [S.l.]: Springer, 2011.

LIU, B. et al. **Chronic exposure to tralopyril induced abnormal growth and calcium regulation of turbot (*Scophthalmus maximus*).** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134405>.

LIU, H. et al. **An experimental investigation of two Wavelet-MLP hybrid frameworks for wind speed prediction using GA and PSO optimization.** *International Journal of Electrical Power and Energy Systems*, 52(1), 161–173, 2013. DOI: <https://doi.org/10.1016/j.ijepes.2013.03.034>.

LIU, M. et al. **A health survey of Beijing middle-aged registered nurses during menopause.** *Maturitas*, 74(1), 84–88, 2013. DOI: <https://doi.org/10.1016/j.maturitas.2012.10.006>.

LIU, Z. et al. **Nonlinear adaptive noise-induced algorithm and its application in penetration signal.** *Measurement: Journal of the International Measurement Confederation*, 58, 556–565, 2014. DOI: <https://doi.org/10.1016/j.measurement.2014.08.025>.

LOEBLEIN, C.; PERKINS, J. D. **On-Line Process Optimization Systems.** *Science*, 20(1994-1996).

LOHMANN, B.; MARQUARDT, W. **On the systematization of the process of model development.** *Computers and Chemical Engineering*, 20(SUPPL.1), 213–218, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00046-4](https://doi.org/10.1016/0098-1354(96)00046-4).

LOMADZE, V. **The PBH test for multidimensional LTID systems.** *Automatica*, 49(9), 2933–2937, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.010>.

LOXTON, R.; LIN, Q.; TEO, K. L. **Minimizing control variation in nonlinear optimal control.** *Automatica*, 49(9), 2652–2664, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.027>.

LU, J., et al. **Facilitating retroflexed endoscopic full-thickness resection through loop-mediated or rope-mediated countertraction (with videos).** *Gastrointestinal Endoscopy*, 83(1), 223–228, 2016. DOI: <https://doi.org/10.1016/j.gie.2015.08.063>.

MA, C. et al. **Long-term trends of fluorotelomer alcohols in a wastewater treatment plant impacted by textile manufacturing industry.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134442>.

MA, H. et al. **Time-varying mesh stiffness calculation of spur gears with spalling defect.** *Engineering Failure Analysis*, 66, 166–176, 2016. DOI: <https://doi.org/10.1016/j.engfailanal.2016.04.025>.

MACIEL, A. de Oliveira et al. **Carbonic anhydrase to boost CO<sub>2</sub> sequestration: Improving carbon capture utilization and storage (CCUS).** *Chemosphere (Vol. 299)*, 2022.. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134419>.

MACKEOWN, H. et al. **The study of polar emerging contaminants in seawater by passive sampling:** A review. In *Chemosphere* (Vol. 299), 2022. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134448>.

MAES, C.; VANDENBOSCH, L. **Adolescent girls' Instagram and TikTok use:** Examining relations with body image-related constructs over time using random intercept cross-lagged panel models. *Body Image*, 41, 453–459, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.015>.

MAHESHWARAN, S. et al. **Hydrothermally constructed AgWO<sub>4</sub>-rGO nanocomposites as an electrode enhancer for ultrasensitive electrochemical detection of hazardous herbicide crisquat.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134434>.

MAIA, E. et al. **Método de comparação de modelos de regressão não-lineares em bananeiras.** *Ciência Rural*, 39(5), 1380–1386, 2009. DOI: <https://doi.org/10.1590/s0103-84782009000500012>.

MALAMAN, Carolina S.; AMORIM, Amilton. **Método para determinação de valores na avaliação imobiliária:** Comparação entre o modelo de regressão linear e lógica fuzzy. *Boletim de Ciências Geodésicas*, v. 23, p. 87–100, 2017. ISSN 19822170. DOI: <http://dx.doi.org/10.1590/s1982-21702017000100006>.

MALTI, R. **A note on  $\mathcal{L}_p$ -norms of fractional systems.** *Automatica*, 49(9), 2923–2927, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.002>.

MANIKANDAN, V. et al. **Microwave-assisted thermochemical conversion of Zr–FeOOH nanorods to Zr–ZnFe<sub>2</sub>O<sub>4</sub> nanorods for bacterial disinfection and photo-Fenton catalytic degradation of organic pollutants.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134363>.

MARANAS, C. D. et al. **Locating all azeotropes in homogeneous azeotropic systems.** *Computers and Chemical Engineering*, 20(SUPPL.1), 413–418, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00079-8](https://doi.org/10.1016/0098-1354(96)00079-8).

MARCELINO-ARANDA, M. et al. **Professionalization in the family business: evolution and lines of research.** *Nova Scientia*, 12(25), 1–32, 2020. DOI: <https://doi.org/10.21640/NS.V12I25.2508>.

MARCOULAKI, E.; KOKOSSIS, A. **Stochastic optimisation of complex reaction systems.** *Computers and Chemical Engineering*, 20(SUPPL.1), 231–236, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00049-x](https://doi.org/10.1016/0098-1354(96)00049-x).

MARIA, G.; RIPPIN, D. W. T. **Recursive robust kinetics estimation by using a mechanistic short-cut technique and a pattern-recognition procedure.** *Computers and Chemical Engineering*, 20(SUPPL.1), 587–592, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00107-x](https://doi.org/10.1016/0098-1354(96)00107-x).

MARSLAND, S. **Machine learning:** an artificial intelligence approach. [S.l.]: Springer, 2015.

MARTINI, R. F.; WOLF-MACIEL, M. R. **A new methodology for mixture characterization and solvent screening for separation process application.** Computers and Chemical Engineering, 20(SUPPL.1), 219–224, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00047-6](https://doi.org/10.1016/0098-1354(96)00047-6).

MATERS, E. C. et al. **Laboratory study of iron isotope fractionation during dissolution of mineral dust and industrial ash in simulated cloud water.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134472>.

MATHWORKS. **Design Time Series NARX Feedback Neural Networks.** 2020. Disponível em: <https://www.mathworks.com/help/deeplearning/ug/design-time-series-narx-feedback-neural-networks.html>. Acesso em: 04 jul. 2021.

MATHWORKS. **Generate fuzzy inference system object from data.** 2021. Disponível em: <https://www.mathworks.com/help/fuzzy/genfis.html>. Acesso em: 21 jan. 2022.

MATHWORKS. **Tune Sugeno-type fuzzy inference system using training data.** 2021. Disponível em: <https://www.mathworks.com/help/fuzzy/anfis.html>. Acesso em: 03 abr. 2021.

MATLAB. **Generalized Regression Neural Networks.** 2021. Disponível em: <https://www.mathworks.com/help/deeplearning/ug/generalized-regression-neural-networks.html>. Acesso em: 03 jul. 2021.

MATZEK, A. E.; GUDMUNSON, C. G.; DANES, S. M. **Spousal capital as a resource for couples starting a business.** Family Relations, 59(1), 60–73, 2010. DOI: <https://doi.org/10.1111/J.1741-3729.2009.00586.X>.

MAU, K.; NOLAN, P. F.; STEELE, C. H. **The development of a real-time emergency advisory system for batch reactors.** Fire and Explosion Group Chemical Engineering Research Centre South Bank University Borough Road London SE1 OAA Abstract: Each year a number of runaway incidents occur i. 1354(96), 593–598, 1996.

MAZINAI, A. et al. **Sulfonated calixarene modified Poly(methyl methacrylate) nanoparticles: A promising adsorbent for Removal of Vanadium Ions from aqueous media.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134459>.

MCKENNA, T. F. **Computer aided process design: Short-cut design for polymer production.** Computers and Chemical Engineering, 20(SUPPL.1), 237–242, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00050-6](https://doi.org/10.1016/0098-1354(96)00050-6).

MEHROTRA, V. et al. **Adoptive expectations: Rising sons in Japanese family firms.** Journal of Financial Economics, 108(3), 840–854, 2013. DOI: <https://doi.org/10.1016/J.JFINECO.2013.01.011>.

MEHTA, D. P.; SAHNI, S. **Models, techniques, and algorithms for finding, selecting, and displaying patterns in strings and other discrete objects.** Journal of Systems and Software, 39(3), 201–221, 1997. DOI: [https://doi.org/10.1016/S0164-1212\(96\)00110-0](https://doi.org/10.1016/S0164-1212(96)00110-0).

MELO, M. M. D. C. de; SOUZA; W. V. de; COUTO, G. B. L. **Comparison of multivariate regression methods in the study of determining factors for tooth decay in children |**

Comparação de métodos de regressão multivariada no estudo de determinantes da cárie dentária em crianças. *Revista Brasileira de Saúde Materno Infantil*, 14(4), 343–352, 2014. DOI: <https://doi.org/10.1590/S1519-38292014000400004>.

MENDONÇA, J. C. et al. **Comparação entre métodos de estimativa da evapotranspiração de referência (ET<sub>o</sub>) na região Norte Fluminense, RJ.** *Revista Brasileira de Engenharia Agrícola e Ambiental*, 7(2), 275–279, 2003. DOI: <https://doi.org/10.1590/s1415-43662003000200015>.

MICHIELS, A. **Formal compensation practices in family SMEs.** *Journal of Small Business and Enterprise Development*, 24(1), 88–104, 2017. DOI: <https://doi.org/10.1108/JSBED-12-2015-0173>.

MICORBIAL, M. et al. **Fermentation process by a self-tunninf vision system (STVS).** 20(96), 321–326. [S.l.]: [S.n.], 1996.

MILLER, D. et al. **When do Non-Family CEOs Outperform in Family Firms? Agency and Behavioural Agency Perspectives.** *Journal of Management Studies*, 51(4), 547–572, 2014. DOI: <https://doi.org/10.1111/JOMS.12076>.

MILLER, D.; MINICHILLI, A.; CORBETTA, G. **Is family leadership always beneficial?** *Strategic Management Journal*, 34(5), 553–571, 2013. DOI: <https://doi.org/10.1002/SMJ.2024>.

MOEYERSOMS, J. et al. **Comprehensible software fault and effort prediction: A data mining approach.** *Journal of Systems and Software*, 100, 80–90. 2015. DOI: <https://doi.org/10.1016/j.jss.2014.10.032>.

MOHAN, A. et al. **Nanostructured nickel doped zinc oxide material suitable for magnetic, supercapacitor applications and theoretical investigation.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134366>.

MOLINA, J. M. et al. **Hydroelectric power plant management relying on neural networks and expert system integration.** *Engineering Applications of Artificial Intelligence*, 13(3), 357–369, 2000. DOI: [https://doi.org/10.1016/S0952-1976\(00\)00009-9](https://doi.org/10.1016/S0952-1976(00)00009-9).

MONTAVON, G. et al. **Uranium retention in a Callovo-Oxfordian clay rock formation: From laboratory-based models to in natura conditions.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134307>.

MONTEYNE, G.; BAETEN, P.; SCHOUKENS, J. **Guidelines to determine the optimal variables for the MTC measurement by noise analysis.** *Annals of Nuclear Energy*, 38(9), 1924–1929, 2011. DOI: <https://doi.org/10.1016/j.anucene.2011.05.004>.

MORADI, O.; ALIZADEH, H.; SEDAGHAT, S. **Removal of pharmaceuticals (diclofenac and amoxicillin) by maltodextrin/reduced graphene and maltodextrin/reduced graphene/copper oxide nanocomposites.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134435>.



- MOREIRA, A. E. L. M. **Monitoramento de Condição de uma Unidade Geradora Hidrelétrica** Monitoramento de Condição de uma Unidade Geradora. [S.l.]: [S.n.], 2016, p. 75.
- MOREIRA, Sandro. **Rede Neural Perceptron Multicamadas**. 2018. 2 p. Disponível em: <https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9>. Acesso em: 07 jul. 2021.
- MU, B. Q.; CHEN, H. F. **Recursive identification of errors-in-variables Wiener systems**. *Automatica*, 49(9), 2744–2753, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.022>.
- MUBARAALI, L.; KUPPUSWAMY, N.; MUTHUKUMAR, R. **Intelligent fault diagnosis in microprocessor systems for vibration analysis in roller bearings in whirlpool turbine generators real time processor applications**. *Microprocessors and Microsystems*, 76, 103079, 2020. DOI: <https://doi.org/10.1016/j.micpro.2020.103079>.
- MULLINS, F. **A Piece of the Pie? The Effects of Familial Control Enhancements on the Use of Broad-Based Employee Ownership Programs in Family Firms**. *Human Resource Management*, 57(5), 979–992, 2018. DOI: <https://doi.org/10.1002/HRM.21828>.
- MYERS, T. A. **What about being a feminist is protective?** An examination of constructs related to feminist beliefs as moderators of the relationship between media awareness and thin-ideal internalization. *Body Image*, 41, 248–261, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.03.001>.
- MYLLYLÄ, T. et al. **Measurement of cerebral blood flow and metabolism using high power light-emitting diodes**. *Measurement: Journal of the International Measurement Confederation*, 58, 387–393, 2014. DOI: <https://doi.org/10.1016/j.measurement.2014.08.027>.
- NAGATA, J. M. et al. **Associations among romantic and sexual partner history and muscle dysmorphia symptoms, disordered eating, and appearance- and performance-enhancing drugs and supplement use among cisgender gay men**. *Body Image*, 41, 67–73, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.004>.
- NAM, Y.; KIM, T. J.; CHOI, W. **The moderating effect of international trade on outside director system in Korean firms**. *Journal of Korea Trade*, 23(1), 19–34, 2019. DOI: <https://doi.org/10.1108/JKT-05-2018-0038>.
- NASSIF, A. B.; HO, D.; CAPRETZ, L. F. **Towards an early software estimation using log-linear regression and a multilayer perceptron model**. *Journal of Systems and Software*, 86(1), 144–160, 2013. DOI: <https://doi.org/10.1016/j.jss.2012.07.050>.
- NGUYEN, H. N. et al. **Implicit improved vertex control for uncertain, time-varying linear discrete-time systems with state and control constraints**. *Automatica*, 49(9), 2754–2759, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.007>.
- NGUYEN, M. K. et al. **Evaluate the role of biochar during the organic waste composting process: A critical review**. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134488>.

NICMANIS, M.; HOUNSLOW, M. J. **A finite element analysis of the steady state population balance equation for particulate systems: Aggregation and growth.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00054-3](https://doi.org/10.1016/0098-1354(96)00054-3).

NORONHA, S.; GRUHN, G. **Synthesis and optimization of an isothermal CSTR-network for the cyclohexane oxidation process.** Computers and Chemical Engineering, 20(SUPPL.1), 255–260, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00053-1](https://doi.org/10.1016/0098-1354(96)00053-1).

NUGNES, R. et al. **Toxic impact of polystyrene microplastic particles in freshwater organisms.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134373>.

OLIVEIRA JÚNIOR, C. de. **Prevendo Números: Entendendo as métricas R<sup>2</sup>, MAE, MAPE, MSE e RMSE.** 2021. Disponível em: <https://medium.com/data-hackers/prevendo-números-entendendo-métricas-de-regressão-35545e011e70>. Acesso em: 30 dez. 2021.

OLIVEIRA, Luiz Fernando de et al. **Comparação de metodologias de preenchimento de falhas de séries históricas de precipitação pluvial anual.** Revista Brasileira de Engenharia Agrícola e Ambiental, 14(11), 1186–1192, 2010. DOI: <https://doi.org/10.1590/s1415-43662010001100008>.

OPOKU, P. A. et al. **Scaled-up multi-anode shared cathode microbial fuel cell for simultaneous treatment of multiple real wastewaters and power generation.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134401>.

ORLANDO, P. F.; JOÃO, S. **De falhas mecânicas em motores de indução trifásicos.** 151–156. [S.l.]: [S.n.], 2003.

OZYURT, B. et al. **A hierarchical approach to simultaneous design of products and processes.** Computers and Chemical Engineering, 20(SUPPL.1), 73–78, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00023-3](https://doi.org/10.1016/0098-1354(96)00023-3).

PADHY, M. K.; SAINI, R. P. **Study of silt erosion mechanism in Pelton turbine buckets.** Energy, 39(1), 286–293, 2012. DOI: <https://doi.org/10.1016/j.energy.2012.01.015>.

PALOSCHI, J. R. **Steady state simulation using MIMD machines in the speedup simulator.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00059-2](https://doi.org/10.1016/0098-1354(96)00059-2).

PARK, J. G.; JO, S. **Approximate Bayesian MLP regularization for regression in the presence of noise.** Neural Networks, 83, 75–85, 2016. DOI: <https://doi.org/10.1016/j.neunet.2016.07.010>.

PARKER, J. E. et al. **Prospective relationships between skin color satisfaction, body satisfaction, and binge eating in Black girls.** Body Image, 41, 342–353, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.004>.

PASTUKHOV, A. M. et al. **Purification of in situ leaching solution for uranium mining by removing solids from suspension.** Minerals Engineering, 55, 1–4, 2014. DOI: <https://doi.org/10.1016/j.mineng.2013.09.007>.

PATTABIRAMAN, T. R.; SRINIVASAN, K.; MALARMOHAN, K. **Assessment of sideband energy ratio technique in detection of wind turbine gear defects.** Case Studies in Mechanical Systems and Signal Processing, 2, 1–11, 2015. DOI: <https://doi.org/10.1016/j.csmssp.2015.07.001>.

PAUL, S.; BARI, M. A. **Elucidating sources of VOCs in the Capital Region of New York State: Implications to secondary transformation and public health exposure.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134407>.

PEPA, Damaschin; URSONIU, Cosmin. **Monitoring systems for hydropower plants.** Analele Universitații “Eftimie Murgu” Res, i, ta, v. 1, 2015.

PEREZ-MONSERRAT, E. M. et al. **Contribution of analytical techniques to determine the technologies used in the ceramic materials from the Former Workers Hospital of Maudes, Madrid (Spain).** Journal of the European Ceramic Society, 33(3), 479–491, 2013. DOI: <https://doi.org/10.1016/j.jeurceramsoc.2012.09.007>.

PERTSINIDIS, A.; PAPADOPOULOS, E.; KIPARISSIDES, C. **Computer aided design of polymer reactors.** Computers and Chemical Engineering, 20(SUPPL.1), 449–454, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00085-3](https://doi.org/10.1016/0098-1354(96)00085-3).

PESCARINI, M. H.; BARROS, A. A. C.; WOLF-MACIEL, M. R. **Development of a software for simulating separation processes using a nonequilibrium stage model.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00057-9](https://doi.org/10.1016/0098-1354(96)00057-9).

PETRACCI, N. C.; HOCH, P. M.; ELICECHE, A. M. **Flexibility analysis of an ethylene plant.** Computers and Chemical Engineering, 20(SUPPL.1), 443–448, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00084-1](https://doi.org/10.1016/0098-1354(96)00084-1).

PETROVIĆ, M.; FIKET, Ž. **Environmental damage caused by coal combustion residue disposal: A critical review of risk assessment methodologies.** Chemosphere, vol. 299, 2022. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134410>.

PETTRES, R. **Regressão múltipla linear e não-linear para o cálculo de volumes de aterros e método iterativo para o reconhecimento de linhas de fluxo a partir de dados digitais de elevação e de terreno.** Revista de Engenharia Civil IMED, vol. 8, Issue 1. Complexo de Ensino Superior Meridional S.A, 2021. DOI: <https://doi.org/10.18256/2358-6508.2021.v8i1.3803>.

PHAM, T. M. et al. **Design synthesis of Y-90 glass microspheres and study of their therapeutic effects on mouse liver cancer cell line Hep3B.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134431>.

PICASSO, B.; COLANERI, P. **Non-minimal factorization approach to the  $\ell_\infty$ -gain of discrete-time linear systems.** Automatica, 49(9), 2867–2873, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.003>.

PILAVACHI, P. A. **European Commission.** 20(96), 467–472. [S.l.]: [S.n.], 1996.

PILLONETTO, G. **Consistent identification of Wiener systems: A machine learning viewpoint.** *Automatica*, 49(9), 2704–2712, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.005>.

PILOTO-RODRÍGUEZ, R. et al. **Prediction of the cetane number of biodiesel using artificial neural networks and multiple linear regression.** *Energy Conversion and Management*, 65, 255–261, 2013. DOI: <https://doi.org/10.1016/j.enconman.2012.07.023>.

PISZCZEK, M. M.; DEARMOND, S.; FEINAUER, D. **Employee work-to-family role boundary management in the family business.** *Community, Work and Family*, 21(2), 111–132, 2018. DOI: <https://doi.org/10.1080/13668803.2017.1366297>.

POINTS, A. F. **Engineering, T. Subject Index.** 212(97), 295–299. [S.l.]: [S.n.], 1997.

POUSINHO, H. M. I., MENDES, V. M. F.; CATALÃO, J. P. S. **A risk-averse optimization model for trading wind energy in a market environment under uncertainty.** *Energy*, 36(8), 4935–4942, 2011. DOI: <https://doi.org/10.1016/j.energy.2011.05.037>.

PRINCE, R. G. H.; CONNOLLY, A. F. **Chemical Engineering Department University of Sydney Australia 2006.** 20(96), 273–278. [S.l.]: [S.n.], 2006.

PROSKURNIKOV, A. V. **Average consensus in networks with nonlinearly delayed couplings and switching topology.** *Automatica*, 49(9), 2928–2932, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.007>.

QIAO, R. et al. **2,6-Dichloro-1,4-benzoquinone formation from chlorination of substituted aromatic antioxidants and its control by pre-ozonation in drinking water treatment plant.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134498>.

QIN, J.; YU, C. **Cluster consensus control of generic linear multi-agent systems under directed topology with acyclic partition.** *Automatica*, 49(9), 2898–2905, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.017>.

QIN, J. et al. **Generation of micro(nano)plastics and migration of plastic additives from Poly(vinyl chloride) in water under radiation-free ambient conditions.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134399>.

QUEIROZ, J. G. O. **Predição não-linear de curvas de produção de petróleo via redes neurais recursivas.** [S.l.]: [S.n.], vol. 17, issue 34, p. 299, 2019. DOI: <https://doi.org/10.22409/tn.17i34.p38061>.

QUIÑONES, I. C.; HERBOZO, S.; HAEDT-MATT, A. A. **Body dissatisfaction among ethnic subgroups of Latin women: An examination of acculturative stress and ethnic identity.** *Body Image*, 41, 272–283, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.03.006>.

RABIEE, N. et al. **Synthesis of green benzamide-decorated UiO-66-NH<sub>2</sub> for biomedical applications.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134359>.

RADWAN, A. A. A.; MOHAMED, Y. A. R. I. **Networked control and power management of AC/DC hybrid microgrids**. *IEEE Systems Journal*, 11(3), 1662–1673, 2017. DOI: <https://doi.org/10.1109/JSYST.2014.2337353>.

RAHMOUNE, M. et al. **Control and diagnostic of vibration in gas turbine system using neural network approach**. *Proceedings of 2016 8th International Conference on Modelling, Identification and Control, ICMIC 2016*, 573–577, 2017. DOI: <https://doi.org/10.1109/ICMIC.2016.7804177>.

RAJU, V. **Implementing impedance-based health monitoring**. [S.l.]: [S.n.], 1998.

RATHBONE, J. A.; JETTEN, J.; CRUWYS, T. **Perceived legitimacy of weight-based discrimination: Consequences for group identity, collective action, body satisfaction, and self-esteem**. *Body Image*, 41, 156–162, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.006>.

RAZI, Muhammad A.; ATHAPPILLY, Kuriakose. **A comparative predictive analysis of neural networks (nns), nonlinear regression and classification and regression tree (cart) models**. *Expert Systems with Applications*, v. 29, p. 65–74, 2005. ISSN 09574174. DOI: <https://doi.org/10.1016/j.eswa.2005.01.006>.

REES, E. M. et al. **Inconsistent emotion recognition deficits across stimulus modalities in Huntington's disease**. *Neuropsychologia*, 64, 99–104, 2014. DOI: <https://doi.org/10.1016/j.neuropsychologia.2014.09.023>.

RIBEIRO, Diogo Aranha et al. **Mechanical fault detection in electric motors measured by a digital signal processing device in an optical mouse**. *Measurement: Journal of the International Measurement Confederation*, Elsevier Ltd, v. 138, p. 350–355, 2019. ISSN 02632241. Disponível em: <https://doi.org/10.1016/j.measurement.2019.02.050>. Acesso em: 24 set. 2021.

ROBERTS, S. R. et al. **Incorporating social media and muscular ideal internalization into the tripartite influence model of body image: Towards a modern understanding of adolescent girls' body dissatisfaction**. *Body Image*, 41, 239–247, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.03.002>.

RODGERS, R. F. et al. **Bopo: Enhancing body image through body positive social media-evidence to date and research directions**. *Body Image* (Vol. 41, pp. 367–374). Elsevier Ltd, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.03.008>.

RONDON, I. F.; DA SILVA, J. G. **Medição Do Teor De Umidade Em Óleo Lubrificante De Turbinas**. *Impactos Das Tecnologias Na Engenharia Mecânica*, 185–195, 2019. DOI: <https://doi.org/10.22533/at.ed.46319050416>.

RONG, X. et al. **Mechanically durable anti-bacteria non-fluorinated superhydrophobic sponge for highly efficient and fast microplastic and oil removal**. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134493>.

ROSSE, L. N.; VENCOVSKY, R.; FERREIRA, D. F. **Comparação de métodos de regressão para avaliar a estabilidade fenotípica em cana-de-açúcar**. *Pesquisa*

Agropecuária Brasileira, 37(1), 25–32, 2002. DOI: <https://doi.org/10.1590/s0100-204x2002000100004>.

ROTEIRO DE ESTUDO ORIENTADO PARTE III. **Pesquisa Bibliográfica e Comunicação Científica** – PSI-515.1–2, 2021.

RU, Y.; MARTÍNEZ, S. **Coverage control in constant flow environments based on a mixed energy-time metric**. *Automatica*, 49(9), 2632–2640, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.024>.

RUIZ-HERNÁNDEZ, I. M. et al. **Trace element and lipidomic analysis of bottlenose dolphin blubber from the Yucatan coast: Lipid composition relationships**. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134353>.

SAHLAN, R. N.; TODD, J.; SWAMI, V. **Psychometric properties of a Farsi translation of the Functionality Appreciation Scale (FAS) in Iranian adolescents**. *Body Image*, 41, 163–171, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.011>.

SALVATO, C.; CORBETTA, G. **Transitional Leadership of Advisors as a Facilitator of Successors' Leadership Construction**. *Family Business Review*, 26(3), 235–255, 2013. DOI: <https://doi.org/10.1177/0894486513490796>.

SALVATO, C.; MINICHILLI, A.; PICCARRETA, R. **Faster Route to the CEO Suite: Nepotism or Managerial Proficiency?** *Family Business Review*, 25(2), 206–224, 2012. DOI: <https://doi.org/10.1177/0894486511427559>.

SAMIAN, YHOSEP, G. Y. Y; ZAIDAN, A. H.; WIBOWO, H. **Gasoline level sensor based on displacement sensor using fiber coupler. Measurement**: *Journal of the International Measurement Confederation*, 58, 342–348, 2014. DOI: <https://doi.org/10.1016/j.measurement.2014.08.024>.

SAMSATLI, N. J.; SHAH, N. **Pergamon**. 20(96). [S.l.]: [S.n.], 1996.

SANEIFAR, H. et al. **Enhancing passage retrieval in log files by query expansion based on explicit and pseudo relevance feedback**. *Computers in Industry*, 65(6), 937–951, 2014. DOI: <https://doi.org/10.1016/j.compind.2014.02.010>.

SARAVACOS, G. D.; KOSTAROPOULOS, A. E. **Engineering properties in food processing simulation**. *Computers and Chemical Engineering*, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00087-7](https://doi.org/10.1016/0098-1354(96)00087-7).

SARKAR, A.; PAUL, B.; DARBHA, G. K. **The groundwater arsenic contamination in the Bengal Basin-A review in brief**. *Chemosphere*, vol. 299, 2022. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134369>.

SARKHEYLI, A.; ZAIN, A. M.; SHARIF, S. **Robust optimization of ANFIS based on a new modified GA**. *Neurocomputing*, 166, 357–366, 2015. DOI: <https://doi.org/10.1016/j.neucom.2015.03.060>.

SCHEUERMANN, A.; LEUKEL, J. **Supply chain management ontology from an ontology engineering perspective**. *Computers in Industry*, 65(6), 913–923, 2014. DOI: <https://doi.org/10.1016/j.compind.2014.02.009>.

SCHILDROTH, S. et al. **Correlates of non-persistent endocrine disrupting chemical mixtures among reproductive-aged Black women in Detroit, Michigan**. *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134447>.

SCHMUHL, J. et al. **Structural parameter approach and multicriteria optimization techniques for complex chemical engineering design**. *Computers and Chemical Engineering*, 20(SUPPL.1), 327–332, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00065-8](https://doi.org/10.1016/0098-1354(96)00065-8).

SCHUG, B. W.; REALFF, M. J. **Design of Standardized, Modular, Chemical Processes Georgia Institute of Technology**. 20(96), 435–441. [S.l.]: [S.n.], 1996.

SCHULZE, W. S.; KELLERMANN, F. W. **Reifying socioemotional wealth. Entrepreneurship: Theory and Practice**, 39(3), 447–459, 2015. DOI: <https://doi.org/10.1111/ETAP.12159>.

SCIENCE, E.; BRITAIN, G. **Computers chem. Eng.** 20(96), 375–380. [S.l.]: [S.n.], 1996.

SELAK, L.; BUTALA, P.; SLUGA, A. **Condition monitoring and fault diagnostics for hydropower plants**. *Computers in Industry*, 65(6), 924–936, 2014. DOI: <https://doi.org/10.1016/j.compind.2014.02.006>.

SEMENOVA, I. V. et al. **Strain solitary waves in inhomogeneous wave guides**. *Optics and Lasers in Engineering*, 34(3), 159–168, 2000. DOI: [https://doi.org/10.1016/S0143-8166\(00\)00092-0](https://doi.org/10.1016/S0143-8166(00)00092-0).

SEO, Y. S.; BAE, D. H.; JEFFERY, R. **Areion: Software effort estimation based on multiple regressions with adaptive recursive data partitioning**. *Information and Software Technology*, 55(10), 1710–1725, 2013. DOI: <https://doi.org/10.1016/j.infsof.2013.03.007>.

SEURET, A.; GOUAISBAUT, F. **Wirtinger-based integral inequality: Application to time-delay systems**. *Automatica*, 49(9), 2860–2866, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.030>.

SEYYEDI, R. ET AL. **Functional test environment for time-triggered control systems in complex MPSoCs**. *Microprocessors and Microsystems*, 76, 103072, 2020. DOI: <https://doi.org/10.1016/j.micpro.2020.103072>.

SHARMA, P.; CHRISMAN, J. J.; CHUA, J. H. **Strategic management of the family business: Past research and future challenges**. *Family Business Review*, 10(1), 1–35, 1997. DOI: <https://doi.org/10.1111/J.1741-6248.1997.00001.X>.

SHARP, G.; GERRARD, Y. **The body image “problem” on social media: Novel directions for the field**. *Body Image*, 41, 267–271, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.03.004>.

SHEORAN, K. et al. **Recent advances of carbon-based nanomaterials (CBNMs) for wastewater treatment: Synthesis and application.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134364>.

SHORT, J. C. et al. **Family Firms and Entrepreneurial Orientation in Publicly Traded Firms: A Comparative Analysis of the S&P 500.** Family Business Review, 22(1), 9–24, 2009. DOI: <https://doi.org/10.1177/0894486508327823>.

SILVA, D.; CARAZAS, F.; SOUZA, G. **Method to select instrumentation for hydraulic turbines in retrofitting process.** International Conference on Computers and Industrial Engineering, CIE 2009, 1192–1197, 2009. DOI: <https://doi.org/10.1109/iccie.2009.5223837>.

SILVA, Derick H. de Jesus. **Processamento de sinais para monitoramento de vibrações em unidades geradoras hidrelétricas.** 2013. 136f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte, 2013. Disponível em: <https://www.ppgee.ufmg.br/defesas/1001M.PDF>. Acesso em: 15 abr. 2022.

SILVA, R. A. **Pressure wave behaviour and leak detection in pipelines.** Computers and Chemical Engineering, 20(SUPPL.1), 491–496, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00091-9](https://doi.org/10.1016/0098-1354(96)00091-9).

SIM, H. Y. et al. **Empirical investigation of acoustic emission signals for valve failure identification by using statistical method.** Measurement: Journal of the International Measurement Confederation, 58, 165–174, 2014. DOI: <https://doi.org/10.1016/j.measurement.2014.08.028>.

SIMANI, S.; ALVISI, S.; VENTURINI, M. **Fault tolerant control of a simulated hydroelectric system.** Control Engineering Practice, 51, 13–25, 2016. DOI: <https://doi.org/10.1016/j.conengprac.2016.03.010>.

SIMPSON-PORCO, J. W.; DÖRFLER, F.; BULLO, F. **Synchronization and power sharing for droop-controlled inverters in islanded microgrids.** Automatica, 49(9), 2603–2611, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.018>.

SIMULATION, S. P. **Sparse Bounded Homotopies.** Science, 20(96), 285–290, 1996.

SKOKO, B.; MAROVIĆ, G.; BABIĆ, D. **Radioactivity in the mediterranean flora of the kaštela bay, croatia.** Journal of Environmental Radioactivity, 135, 36–43, 2014. DOI: <https://doi.org/10.1016/j.jenvrad.2014.04.005>.

SKRIFVARS, H. et al. **Comparison of different MINLP methods applied on certain chemical engineering problems.** Computers and Chemical Engineering, 20(SUPPL.1), 333–338, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00066-x](https://doi.org/10.1016/0098-1354(96)00066-x).

SOOTLA, A.; SOU, K. C.; RANTZER, A. **Parametrized model reduction based on semidefinite programming.** Automatica, 49(9), 2840–2844, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.022>

SOUZA, Geraldo da Silva. **Introdução aos modelos de regressão linear e não-linear.** [S.l.]: Embrapa, 2008. 491 p. ISBN 9788573830200.



SPRENG, F.; EBERHARD, P.; FLEISSNER, F. **An approach for the coupled simulation of machining processes using multibody system and smoothed particle hydrodynamics algorithms.** *Theoretical and Applied Mechanics Letters*, 3(1), 13005, 2013. DOI: <https://doi.org/10.1063/2.1301305>.

STANTON, A. G. et al. **Black women's experiences of gendered racial sexual objectification, body image, and depressive symptoms.** *Body Image*, 41, 443–452, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.014>.

STEWART, A.; HITT, M. A. **Why Can't a Family Business Be More Like a Nonfamily Business?** *Modes of Professionalization in Family Firms.* *Family Business Review*, 25(1), 58–86, 2012. DOI: <https://doi.org/10.1177/0894486511421665>.

STURGESS, C. M. B.; Stinson, D. A. **Fat embodiment for resistance and healing from weight stigma.** *Body Image*, 41, 52–57, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.007>.

SUDHA, R.; MURALI, D. **Low-Cost Real-Time Design and Implementation of Phasor Measurement Unit using Analog Discovery.** *Microprocessors and Microsystems*, 76, 2020. DOI: <https://doi.org/10.1016/j.micpro.2020.103102>.

SUMMERS, S. et al. **Stochastic system controller synthesis for reachability specifications encoded by random sets.** *Automatica*, 49(9), 2906–2910, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.016>.

SUN, L. et al. **A modified surrogate-assisted multi-swarm artificial bee colony for complex numerical optimization problems.** *Microprocessors and Microsystems*, 76, 2020. DOI: <https://doi.org/10.1016/j.micpro.2020.103050>.

SUN, Z., LI et al. **Steel pickling rinse wastewater treatment by two-stage MABR system: Reactor performance, extracellular polymeric substances (EPS) and microbial community.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134402>.

TAHIR, F.; JAIMOUKHA, I. M. **Causal state-feedback parameterizations in robust model predictive control.** *Automatica*, 49(9), 2675–2682, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.015>.

TAKAI, Y. et al. **Combined effect of diazepam and polystyrene microplastics on the social behavior of medaka (*Oryzias latipes*).** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134403>.

TALAS, P.; FRANKLIN, D. E.; PALYLYK, R. A. **Application of an On-Line Air-Gap Monitor for Hydroelectric Generator Protection and Problem Diagnosis.** *IEEE Power Engineering Review*, PER-7(12), 27, 1987. DOI: <https://doi.org/10.1109/MPER.1987.5526824>.

TANSCHKEIT, R. **Sistemas fuzzy.** *Carcinogenesis*, vol. 12, issue 7, pp. 1319–1323, 1991. DOI: <https://doi.org/10.1093/carcin/12.7.1319>.

TASCA, L. C.; DE FREITAS, E. P.; WAGNER, F. R. **A study on the performance impact of programmable logic controllers based on enhanced architecture and organization.** *Microprocessors and Microsystems*, 76, 103082, 2020. DOI: <https://doi.org/10.1016/j.micpro.2020.103082>.

TIGGEMANN, M. **Digital modification and body image on social media: Disclaimer labels, captions, hashtags, and comments.** *Body Image*, vol. 41, pp. 172–180, 2022. Elsevier Ltd. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.012>.

TONG, L. et al. **Zinc oxide nanoparticles dissolution and toxicity enhancement by polystyrene microplastics under sunlight irradiation.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134421>.

TRALLI, Fernando Cunha. **Modelagem dinâmica de rotores de unidades hidrogeradoras.** 2018. 132f. Dissertação (Mestrado em Engenharia de Controle e Automação Mecânica) – Universidade Federal de São Paulo, São Paulo, 2018. DOI: 10.11606/D.3.2018.tde-18092018-072843.

TRINH, M. H. et al. **Guidance using bearing-only measurements with three beacons in the plane.** *Control Engineering Practice*, 51, 81–91, 2016. DOI: <https://doi.org/10.1016/j.conengprac.2016.03.013>.

TRUONG, H. B. et al. **Magnetic visible-light activated photocatalyst ZnFe<sub>2</sub>O<sub>4</sub>/BiVO<sub>4</sub>/g-C<sub>3</sub>N<sub>4</sub> for decomposition of antibiotic lomefloxacin: Photocatalytic mechanism, degradation pathway, and toxicity assessment.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134320>.

TYLKA, T. L. et al. **Short forms of the Body Appreciation Scale-2 (BAS-2SF): Item selection and psychometric evaluation.** *Body Image*, 41, 308–330, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.001>.

URTASUN, A. et al. **Frequency-based energy-management strategy for stand-alone systems with distributed battery storage.** *IEEE Transactions on Power Electronics*, 30(9), 4794–4808, 2015. DOI: <https://doi.org/10.1109/TPEL.2014.2364861>.

VALL, O. M. M.; M’HIRI, R. **An approach to polynomial NARX/NARMAX systems identification in a closed-loop with variable structure control.** *International Journal of Automation and Computing*, 5(3), 313–318, 2008. DOI: <https://doi.org/10.1007/s11633-008-0313-7>.

VAN DALEN, M. et al. **Acceptability and feasibility of an online psychosocial intervention for Dutch adolescents with a visible difference: A mixed-methods study.** *Body Image*, 41, 298–307, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.03.003>.

VAN ECK, N. J.; WALTMAN, L. **Software survey: VOSviewer, a computer program for bibliometric mapping.** *Scientometrics*, 84(2), 523–538, 2010. DOI: <https://doi.org/10.1007/S11192-009-0146-3>.

VÁZQUEZ-ROMÁN, R.; KING, J. M. P.; BAÑARES-ALCÁNTARA, R. **KBMoSS: A process engineering modelling support system.** Computers and Chemical Engineering, 20(SUPPL.1), 309–314, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00062-2](https://doi.org/10.1016/0098-1354(96)00062-2).

VEJVODOVÁ, K. et al. **Effect of peat organic matter on sulfide weathering and thallium reactivity: Implications for organic environments.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134380>.

VELMURUGAN, R.; INCHAROENSAKDI, A. **Metabolic transformation of cyanobacteria for biofuel production.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134342>

VENKATESAN, M. et al. **Research on FPGA controlled three phase PV inverter using multi carrier PWM control schemes.** Microprocessors and Microsystems, 76, 2020. DOI: <https://doi.org/10.1016/j.micpro.2020.103089>.

VINATORU, M. **Monitoring and control of hydro power plant.** IFAC Proceedings Volumes (IFAC-PapersOnline), vol. 1, issue part 1, 2007. IFAC. DOI: <https://doi.org/10.3182/20070709-3-ro-4910.00007>.

VLADIMIR, V. F. **Gastronomía Ecuatoriana y Turismo Local.**, 1(69), 5–24. [S.l.]: [S.n.], 1997.

VLASENKO, B. et al. **Modeling phonetic pattern variability in favor of the creation of robust emotion classifiers for real-life applications.** Computer Speech and Language, 28(2), 483–500, 2014. DOI: <https://doi.org/10.1016/j.csl.2012.11.003>.

VOROS, N.; MAROULIS, Z. B.; MARINOS-KOURIS, D. **Optimization of reverse osmosis networks for seawater desalination.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00068-3](https://doi.org/10.1016/0098-1354(96)00068-3).

VUČINA, D.; ČURKOVIĆ, M.; NOVKOVIĆ, T. **Classification of 3D shape deviation using feature recognition operating on parameterization control points.** Computers in Industry, 65(6), 1018–1031, 2014. DOI: <https://doi.org/10.1016/j.compind.2014.04.001>.

WAI, P. P. C. et al. **Process synthesis and simulation strategies for integrated biochemical process design.** Computers and Chemical Engineering, 20(SUPPL.1), 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00070-1](https://doi.org/10.1016/0098-1354(96)00070-1).

WALTMAN, L. **A review of the literature on citation impact indicators.** Journal of Informetrics, 10(2), 365–39, 2016. DOI: <https://doi.org/10.1016/J.JOI.2016.02.007>.

WANG, D. **K-nearest neighbors based methods for identification of different gear crack levels under different motor speeds and loads: Revisited.** Mechanical Systems and Signal Processing, 70–71, 201–208, 2016. DOI: <https://doi.org/10.1016/j.ymsp.2015.10.007>.

WANG, H. **Flocking of networked uncertain Euler-Lagrange systems on directed graphs.** Automatica, 49(9), 2774–2779, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.029>.

WANG, Q. W.; HE, Z. H. **Solvability conditions and general solution for mixed Sylvester equations.** *Automatica*, 49(9), 2713–2719, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.009>.

WANG, Xiangjun.; AL-HASHIMI, Muzahem. **The comparison of adaptive neuro-fuzzy inference system (anfis) with nonlinear regression for estimation and prediction.** 2012 International Conference on Information Technology and e-Services, ICITeS 2012, IEEE, 2012. DOI: <https://doi.org/10.1109/ICITeS.2012.6216601>.

WANG, Y. et al. **Effects of prenatal exposure to arsenic on neonatal birth size in Wujiang, China.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134441>.

WATKINS-FASSLER, K.; DEL CARMEN BRIANO-TURRENT, G.; RODRÍGUEZ-ARIZA, L. **Performance and abilities of family-member ceos in a context of formal institutional weakness.** *Trimestre Económico*, 86(341), 179–219, 2019. DOI: <https://doi.org/10.20430/ETE.V86I341.657>.

WELLMAN, J. D. et al. **Identifying as fat: Examining weight discrimination and the rejection-identification model.** *Body Image*, 41, 46–51, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.02.008>.

WEN, G. X.; LIU, Y. J. **Adaptive fuzzy-neural tracking control for uncertain nonlinear discrete-time systems in the NARMAX form.** *Nonlinear Dynamics*, 66(4), 745–753, 2011. DOI: <https://doi.org/10.1007/s11071-011-9947-z>.

WENG, Z. et al. **Associations of genetic risk factors and air pollution with incident hypertension among participants in the UK Biobank study.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134398>.

WIDROW, Bernard; HOFF, Marcian E. **Adaptive switching circuits.** 1989. 709-717 p.

WIJAYA, Y. **The prospect of familism in the global era: A study on the recent development of the ethnic-Chinese business, with particular attention to the Indonesian context.** *Journal of Business Ethics*, 79(3), 311–317, 2008. DOI: <https://doi.org/10.1007/S10551-007-9399-Z>.

WIKA. **Sensor.** [S.l.]: [S.n.], [s.d.].

WOL, E.; SCIENCE, E.; BRITAIN, G. **A markovian intensities approach for predicting.** 1354(96). [S.l.]: [S.n.], 1996.

WON, C.; KIM, J.; BAE, J. K. **Using genetic algorithm based knowledge refinement model for dividend policy forecasting.** *Expert Systems with Applications*, 39(18), 13472–13479, 2012. DOI: <https://doi.org/10.1016/j.eswa.2012.06.001>.

WOOD, M.; PILA, E. **Investigating the effects of fit-normative and weight-inclusive Instagram images on women’s exercise motivations.** *Body Image*, 41, 460–471, 2022. DOI: <https://doi.org/10.1016/j.bodyim.2022.04.003>.

WU, N. et al. **Enhancing anaerobic methane production in integrated floating-film activated sludge system filled with novel MWCNTs-modified carriers.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134483>.

WU, P. et al. **An advanced architecture of multiple microgrids interfacing with UCC.** *IEEE Power and Energy Society General Meeting*, 2018-Janua, 1–5, 2018. DOI: <https://doi.org/10.1109/PESGM.2017.8274468>.

XI, B. et al. **Environmental behaviors and degradation methods of microplastics in different environmental media.** *Chemosphere*, 299, 2022, Elsevier Ltd. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134354>.

XI, J. et al. **Mapping the field of family business research: past trends and future directions.** *International Entrepreneurship and Management Journal*, 11(1), 113–132, 2015. DOI: <https://doi.org/10.1007/S11365-013-0286-Z>.

XIA, X. et al. **A novel method for fault diagnosis of hydro generator based on NOFRFs.** *International Journal of Electrical Power and Energy Systems*, 71, 60–67, 2015. DOI: <https://doi.org/10.1016/j.ijepes.2015.02.022>.

XU, B. et al. **Modeling oscillation modal interaction in a hydroelectric generating system.** *Energy Conversion and Management*, 174(August), 208–217, 2018. DOI: <https://doi.org/10.1016/j.enconman.2018.08.034>.

XU, B. et al. **Modeling and stability analysis of a fractional-order Francis hydro-turbine governing system.** *Chaos, Solitons and Fractals*, 75, 50–61, 2015. DOI: <https://doi.org/10.1016/j.chaos.2015.01.025>.

XU, B. et al. **Bayesian network approach to fault diagnosis of a hydroelectric generation system.** *Energy Science and Engineering*, 7(5), 1669–1677, 2019. DOI: <https://doi.org/10.1002/ese3.383>.

XU, J. et al. **A unified empirical modeling approach for particulate matter and NO<sub>2</sub> in a coastal city in China.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134384>.

XUE, X.; YANG, X.; LI, P. **Evaluation of Ground Vibration Due to Blasting Using Fuzzy Logic.** *Geotechnical and Geological Engineering*, 35(3), 1231–1237, 2017. DOI: <https://doi.org/10.1007/s10706-017-0162-7>.

YANG, W.; COURT, R.; JIANG, J. **Wind turbine condition monitoring by the approach of SCADA data analysis.** *Renewable Energy*, 53, 365–376, 2013. DOI: <https://doi.org/10.1016/j.renene.2012.11.030>.

YANG, W. et al. **Hydraulic damping mechanism of low frequency oscillations in power systems: Quantitative analysis using a nonlinear model of hydropower plants.** *Applied Energy*, 212(January), 1138–1152, 2018. DOI: <https://doi.org/10.1016/j.apenergy.2018.01.002>.

YANG, X.; MCGREAVY, C. **Requirements for sharing process data in the life cycle of process plants.** *Computers and Chemical Engineering*, 20(SUPPL.1), 363–368, 1996. DOI: [https://doi.org/10.1016/0098-1354\(96\)00071-3](https://doi.org/10.1016/0098-1354(96)00071-3).

YANG, Y. et al. **The inhibiting effects of organic acids on arsenic immobilization by ferrihydrite: Gallic acid as an example.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134286>.

YEH, L. et al. **Inactivation of Escherichia coli by dual-functional zerovalent Fe/Al composites in water.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134371>.

YILDIRIM-ÖKTEM, Ö.; ÜSDIKEN, B. **Contingencies versus external pressure: Professionalization in boards of firms affiliated to family business groups in late-industrializing countries.** *British Journal of Management*, 21(1), 115–130, 2010. DOI: <https://doi.org/10.1111/J.1467-8551.2009.00663.X>.

YILMAZ, Isik; KAYNAR, Oguz. **Multiple regression, ann (rbf, mlp) and anfis models for prediction of swell potential of clayey soils.** *Expert Systems with Applications*, v. 38, p. 5958–5966, 2011. ISSN 09574174. DOI: <https://doi.org/10.1016/j.eswa.2010.11.027>.

YOU, D. et al. **Per- and polyfluoroalkyl substances (PFASs) in the blood of police and Beagle dogs from Harbin, China: Concentrations and associations with hematological parameters.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134367>.

YU, C.; ZHANG, C.; XIE, L. **Blind system identification using precise and quantized observations.** *Automatica*, 49(9), 2822–2830, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.020>.

YU, X. et al. **Biogeographic patterns of benthic microbial communities in metal(loid)-contaminated semi-enclosed bay.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134412>.

YUAN, B. et al. **Perturbative analysis of cross-talk of two pieces of photorefractive phase gratings stored in one point by angle multiplexing.** *Optics and Lasers in Engineering*, 34(3), 169–178, 2010. DOI: [https://doi.org/10.1016/S0143-8166\(00\)00091-9](https://doi.org/10.1016/S0143-8166(00)00091-9).

ZAIDI, A. A. et al. **On optimal policies for control and estimation over a Gaussian relay channel.** *Automatica*, 49(9), 2892–2897, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.06.011>.

ZARE, F.; ZARE, H. K.; FALLAHNEZHAD, M. S. **Software effort estimation based on the optimal Bayesian belief network.** *Applied Soft Computing Journal*, 49, 968–980, 2016. DOI: <https://doi.org/10.1016/j.asoc.2016.08.004>.

ZENG, J. Y. et al. **Serum multiple organochlorine pesticides in relation to testosterone concentrations among Chinese men from an infertility clinic.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134469>.

ZHAN, L. et al. **Comparison of atmospheric polycyclic aromatic hydrocarbons (PAHs) over six years at a CAWNET background site in central China: Changes of seasonal variations and potential sources.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134298>.

ZHANG, J.; MA, H. **Adoption of professional management in Chinese family business: A multilevel analysis of impetuses and impediments.** *Asia Pacific Journal of Management*, 26(1), 119–139, 2009. DOI: <https://doi.org/10.1007/S10490-008-9099-Y>.

ZHANG, R. et al. **Supervision localization of timed discrete-event systems.** *Automatica*, 49(9), 2786–2794, 2013. DOI: <https://doi.org/10.1016/j.automatica.2013.05.015>.

ZHANG, X. et al. **Vibrant fault diagnosis for hydroelectric generator units with a new combination of rough sets and support vector machine.** *Expert Systems with Applications*, 39(3), 2621–2628, 2012. DOI: <https://doi.org/10.1016/j.eswa.2011.08.117>.

ZHANG, Z. W. et al. **A new method for measuring airborne elemental carbon using PUF disk passive samplers.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134323>.

ZHAO, R. et al. **Insights into Cr(VI) removal mechanism in water by facile one-step pyrolysis prepared coal gangue-biochar composite.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134334>.

ZHAO, X. et al. **Energy Management Strategy of Multiple Supercapacitors in a DC Microgrid Using Adaptive Virtual Impedance.** *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 4(4), 1174–1185, 2016. DOI: <https://doi.org/10.1109/JESTPE.2016.2601097>.

ZHAO, X. et al. **Energy Management Strategy of Multiple Supercapacitors in a DC Microgrid Using Adaptive Virtual Impedance.** *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 4(4), 1174–1185, 2016. DOI: <https://doi.org/10.1109/JESTPE.2016.2601097>.

ZHAO, Z. et al. **A coordinated optimization framework for flexible operation of pumped storage hydropower system: Nonlinear modeling, strategy optimization and decision making.** *Energy Conversion and Management*, 194(April), 75–93, 2019. DOI: <https://doi.org/10.1016/j.enconman.2019.04.068>.

ZHONG, Y. et al. **Abiotic degradation behavior of polyacrylonitrile-based material filled with a composite of TiO<sub>2</sub> and g-C<sub>3</sub>N<sub>4</sub> under solar illumination.** *Chemosphere*, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134375>.

ZHU, W. et al. **A novel KICA-PCA fault detection model for condition process of hydroelectric generating unit. Measurement: Journal of the International Measurement Confederation**, 58, 197–206, 2014. DOI: <https://doi.org/10.1016/j.measurement.2014.08.026>.

ZHU, W. et al. **A novel KICA-PCA fault detection model for condition process of hydroelectric generating unit. Measurement: Journal of the International Measurement Confederation**, 58, 197–206, 2014. DOI: <https://doi.org/10.1016/j.measurement.2014.08.026>.

ZHU, X. et al. **Blood ethylene oxide, systemic inflammation, and serum lipid profiles: Results from NHANES 2013–2016.** Chemosphere, 299, 2022. DOI: <https://doi.org/10.1016/j.chemosphere.2022.134336>.

ZUBEN, F. J. VON; ATTUX, R. R. F. **Redes Neurais com Funções de Ativação de Base Radial. 1–37.** Apresentação. 2018. Unicamp. Disponível em: [ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia353\\_1s07/topico9\\_07.pdf](ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia353_1s07/topico9_07.pdf). Acesso em: 23 jun. 2022.