



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Andrea Maria Nogueira Cavalcanti Ribeiro

**Gerenciamento de energia elétrica de uma indústria de resinas termoplásticas**

Recife

2022

Andrea Maria Nogueira Cavalcanti Ribeiro

## **Gerenciamento de energia elétrica de uma indústria de resinas termoplásticas**

Tese de Doutorado apresentada ao Programa de Pós-graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Doutor em Ciência da Computação.

**Área de Concentração:** Redes de Computadores e Sistemas Distribuídos

**Orientador:** Prof. Dr. Djamel Fawzi Hadj Sadok

**Coorientadora:** Profa. Dra. Patricia Takako Endo

Recife

2022

Catálogo na fonte  
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

R484g Ribeiro, Andrea Maria Nogueira Cavalcanti  
Gerenciamento de energia elétrica de uma indústria de resinas  
termoplásticas / Andrea Maria Nogueira Cavalcanti Ribeiro. – 2022.  
170 f.: il., fig., tab.

Orientador: Djamel Fawzi Hadj Sadok.  
Tese (Doutorado) – Universidade Federal de Pernambuco. CIn, Ciência da  
Computação, Recife, 2022.

Inclui referências e apêndice.

1. Redes de computadores. 2. Aprendizagem de máquina. I. Sadok, Djamel  
Fawzi Hadj (orientador). II. Título.

004.6

CDD (23. ed.)

UFPE - CCEN 2022-138

**Andrea Maria Nogueira Cavalcanti Ribeiro**

**“Gerenciamento de energia elétrica de uma indústria de resinas termoplásticas”**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Ciência da Computação. Área de Concentração: Redes de Computadores e Sistemas Distribuídos.

Aprovado em: 01/04/2022.

---

**Orientador: Prof. Dr. Djamel Fawzi Hadj Sadok**

**BANCA EXAMINADORA**

---

Prof. Dr. Aluizio Fausto Ribeiro Araújo  
Centro de Informática/UFPE

---

Prof. Dr. Nelson Souto Rosa  
Centro de Informática/UFPE

---

Prof. Dr. Gustavo Medeiros de Souza Azevedo  
Departamento de Engenharia Elétrica/UFPE

---

Prof. Dr. Eduardo James Pereira Souto  
Instituto de Computação/UFAM

---

Prof. Dr. Glauco Estácio Gonçalves  
Instituto de Tecnologia/UFPA

Dedico esta tese aos meus sobrinhos e afilhados: Bruno Rocha, Milena Rocha, Beatriz Calado, Guilherme Henrique Calado, Guilherme Duzi, Vinícius Veloso, Vinícius, Maria Clara Fantini, Maria Kahrsch, Maria Brasilino. A pesquisa nos transforma, o conhecimento nos inspira. Que possamos buscar ferramentas para ajudar a sociedade a ser ainda melhor.

"Feliz aquele que transfere o que sabe e aprende o que ensina." (CORALINA, 2012, p.121).

## RESUMO

A eletricidade se tornou uma das principais fontes de calor e de força nas indústrias, representando um percentual importante nos custos da produção. É possível afirmar que no contexto mundial, o setor industrial é o maior consumidor de energia elétrica e a fabricação com alto consumo de energia é o maior componente desse setor. No contexto nacional, o consumo de energia elétrica pelas indústrias atualmente representa 35% do consumo total de energia consumida no país. A busca por uma melhor eficiência energética pelo setor industrial vem se tornando cada vez mais frequente. O uso de dispositivos de *Internet of Things* (IoT), energias renováveis, gerenciamento e monitoramento de energia, bem como Inteligência Artificial (IA) são alternativas para alcançar a redução e o consumo consciente da energia elétrica. Desta forma, esta pesquisa de doutorado teve como objetivo o desenvolvimento de um *framework* para gerenciamento de energia elétrica em uma indústria de resinas termoplásticas. A definição dos requisitos do *framework* foi baseada em demandas reais de uma indústria. O *framework* recebe, como entrada, dados de variáveis elétricas e variáveis de processo da planta industrial e produz, como saída, informações para auxiliar a tomada de decisão: gráficos com a predição do indicador de desempenho energético; alertas; faixas de vazão de produção e tempo de produção; retorno de investimento de um dado equipamento ou material, dentre outros. O processamento desses dados é realizado por meio da integração entre três modelos baseados em técnicas de IA (modelo de predição do indicador de desempenho energético), otimização linear (modelo de escalonamento da vazão de produção) e lei da afinidade (viabilidade técnica e econômica de tecnologias - materiais, equipamentos e sistemas). A validação do *framework* foi realizada com sua implantação, por meio de um estudo de caso, numa indústria real. Os resultados apresentaram uma economia de 9,74% (no período 2015 - 2019), oriunda da aplicação do modelo de escalonamento; uma economia mensal de aproximadamente R\$ 9.000,00 e o *payback* de cinco meses oriundos do modelo de viabilidade. Além disso, o modelo de predição de energia elétrica, representado pelo GRU-1-30 (uma camada e 30 neurônios), apresentou um desempenho superior, quando comparado com a técnica manual utilizada na indústria e outras técnicas de IA (*Recurrent Neural Networks* (RNN), *Long Short-Term Memory* (LSTM), *Support*

*Vector Machines Regression* (SVR) e Random forest), com valores de *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE) e *Mean Absolute Error* (MAE), iguais a 0,0305; 4,33%; e 0,0305, respectivamente. Por fim, o *framework* contribuiu para a manutenção da certificação da ISO 50001 na indústria objeto do estudo de caso.

**Palavras-chave:** eficiência energética; predição de energia; aprendizado profunda; aprendizado de máquina; escalonamento da vazão; viabilidade econômica.

## ABSTRACT

Electricity has become one of the primary sources of heat and power in industries, representing an essential percentage of production costs. It is possible to affirm that in the global context, the industrial sector is the largest consumer of electricity and energy-intensive manufacturing is the most significant component of this sector. In the national context, the consumption of electric energy by the industries currently represents 35% of the total consumption of energy consumed in the country. The industrial sector's search for better energy efficiency is becoming increasingly frequent. The use of Internet of Things (IoT) devices, renewable energy, energy management and monitoring, and Artificial Intelligence (AI) are alternatives to achieve the reduction and conscious consumption of electricity. Thus, this doctoral research aimed to develop a framework for electrical energy management in the thermoplastic resins industry. The framework requirements definition was based on real industrial demands. The framework receives as input data of electrical variables and process variables of the industrial plant and produces as output information to help decision making - graphs with the prediction of the energy performance indicator; alerts; production flow ranges and production time; return on investment of a given equipment or material, among others. The processing of this data is performed through the integration of three models based on AI techniques (energy performance indicator prediction model), linear optimization (production flow scaling model) and affinity law (technical and economic feasibility of technologies - materials, equipment and systems). The framework's validation was carried out with its implementation, through a case study, in a real industry. The results obtained showed savings of 9.74% (in the period 2015 - 2019) arising from the application of the scheduling model; a monthly saving of approximately R\$9,000.00 and the five-month *payback* arising from the feasibility model. In addition, the electrical energy prediction model, represented by the GRU-1-30 (one layer and 30 neurons), presented a superior performance when compared with the manual technique used in the industry and other AI techniques (Recurrent Neural Networks (RNN)), Long Short-Term Memory (LSTM), Support Vector Machines Regression (SVR) and Random forest), with Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE) and Mean Absolute Error (MAE) values equal

to 0.0305; 4.33%; and 0.0305, respectively. Finally, the framework contributed to the maintenance of ISO 50001 certification in the industry object of the case study.

**Keywords:** energy efficiency; forecasting of the energy; deep learning; machine learning; flow scaling; economic viability.

## LISTA DE FIGURAS

Figura 1 – Representação do consumo anual de energia elétrica no Brasil, por unidades consumidoras, referente ao ano de 2019. . . . .	25
Figura 2 – Estrutura da tese. . . . .	28
Figura 3 – Cadeia produtiva dos plásticos. . . . .	45
Figura 4 – Forma granulada das resinas termoplásticas. . . . .	46
Figura 5 – Reação para obtenção do <i>Polietileno Tereftalato</i> (PET): (a) primeira etapa e (b) segunda etapa. . . . .	47
Figura 6 – Processo de fabricação do PET. . . . .	48
Figura 7 – Etapas do processo de Polimerização do estado Sólido (SSPOLI). . . . .	48
Figura 8 – Visão do cenário industrial. . . . .	51
Figura 9 – Comunicação entre o cliente e servidor OPC. . . . .	52
Figura 10 – Representação do desempenho energético. . . . .	53
Figura 11 – Características dos trabalhos relacionados referente a temática de predição. . . . .	59
Figura 12 – Características dos trabalhos relacionados referente a temática de gerenciamento de energia. . . . .	61
Figura 13 – Pilares do <i>framework</i> desenvolvido nesta tese. . . . .	62
Figura 14 – Interação entre os modelos de predição, escalonamento e viabilidade. . . . .	65
Figura 15 – Representação do <i>framework</i> . . . . .	67
Figura 16 – Elementos que compõem o <i>módulo de coleta de dados</i> . . . . .	68
Figura 17 – Modelo de análise do desempenho energético da indústria. . . . .	69
Figura 18 – Escalonamento da vazão de produção. . . . .	70
Figura 19 – Suporte de dados. . . . .	75
Figura 20 – Conjunto de dados diários de (a) consumo de energia elétrica, (b) vazão de produção para o processo de Polimerização (POLI) e (c) vazão de produção para o processo de SSPOLI. . . . .	82
Figura 21 – Distribuição do indicador de desempenho energético no ano de 2016. . . . .	84
Figura 22 – Comportamento da média do indicador de desempenho em relação à variação das faixas de vazão de produção. . . . .	84

Figura 23 – Tela de viabilidade do inversor. . . . .	89
Figura 24 – Fluxo de interação de telas. . . . .	95
Figura 25 – Representação das telas (a) <i>login</i> , (b) visão geral — consumo de energia, (c) visão geral — gráfico do consumo de energia, e (d) visão geral — representação dos eventos. . . . .	98
Figura 26 – Representação da tela de visão geral (a) do gráfico do indicador de desempenho energético, e (b) do gráfico da média do indicador de desempenho energético. . . . .	100
Figura 27 – Infraestrutura de rede no estudo de caso. . . . .	101
Figura 28 – Configuração do modelo <i>Short Term Load Forecasting</i> (STLF). . .	107
Figura 29 – Resultados da análise da convergência para os modelos de aprendizado profundo baseados em (a) <i>Recurrent Neural Networks</i> (RNN)-1-30, (b) RNN-4-30, (c) <i>Long Short-Term Memory</i> (LSTM)-1-30, e (d) <i>Gated Recurrent Unit</i> (GRU)-1-30. . . . .	108
Figura 30 – Resultado do <i>grid search</i> para o modelo STLF baseado em técnicas de aprendizado profundo. . . . .	110
Figura 31 – Resultado do <i>grid search</i> para o modelo STLF baseado em técnicas de aprendizado de máquina. . . . .	112
Figura 32 – Predição do consumo de energia usando (a) o modelo RNN-1-30, (b) o modelo RNN-4-30, (c) o modelo LSTM-1-30, e (d) o modelo GRU-1-30. . . . .	117
Figura 33 – Predição do consumo de energia usando (a) o modelo <i>Support Vector Machines Regression</i> (SVR)-0.1-linear, (b) o modelo <i>Random Forest-3-50</i> , (c) o modelo <i>Random Forest-6-50</i> , e (d) o modelo <i>Random Forest-6-100</i> . . . . .	118
Figura 34 – Predição do consumo de energia usando (a) o modelo manual e (b) o modelo <i>Autoregressive Integrated Moving Average</i> (ARIMA). . .	119
Figura 35 – Configuração do modelo <i>Medium Term Load Forecasting</i> (MTLF). . .	121
Figura 36 – Resultado do <i>grid search</i> para o modelo MTLF baseado em técnicas de aprendizado profundo. . . . .	122
Figura 37 – Resultado do <i>grid search</i> para o modelo MTLF baseado em técnicas de aprendizado de máquina. . . . .	124

Figura 38 – Predição do modelo que apresentou o melhor desempenho <i>Extreme Gradient Boosting</i> (XGBoost)-3-50. . . . .	127
Figura 39 – Configuração do modelo da predição da vazão de produção de 30 dias. . . . .	127
Figura 40 – Resultado do <i>grid search</i> para o modelo de predição da vazão de produção baseado em técnicas de aprendizado profundo. . . . .	129
Figura 41 – Resultado do <i>grid search</i> para o modelo de predição da vazão de produção baseado em técnicas de aprendizado de máquina. . . . .	131
Figura 42 – Predição do modelo SVR-0,5- <i>Radial Basis Function</i> (RBF) para vazão de produção de 30 dias. . . . .	133

## LISTA DE TABELAS

Tabela 1 – Indicadores de Desempenho Energético (IDE)s definidas para este estudo. . . . .	32
Tabela 2 – Características da classificação da predição de carga elétrica relacionada ao intervalo de medição. . . . .	34
Tabela 3 – Resinas termoplásticas mais populares e suas possíveis aplicações.	45
Tabela 4 – Benefícios do gerenciamento de energia na indústria. . . . .	54
Tabela 5 – Saída do <i>módulo de escalonamento</i> . . . . .	71
Tabela 6 – Média do consumo de energia elétrica por faixa de vazão. . . . .	90
Tabela 7 – Resultado dos experimentos com o <i>módulo de escalonamento</i> . . .	91
Tabela 8 – <i>Endpoints expostos pela API do framework</i> . . . . .	94
Tabela 9 – Parâmetros e níveis utilizados no <i>grid search</i> . . . . .	108
Tabela 10 – Parâmetros e níveis utilizados no <i>grid search</i> . . . . .	111
Tabela 11 – Resultados das métricas dos melhores modelos de aprendizado profundo. . . . .	115
Tabela 12 – Média do tempo de inferência para os modelos. . . . .	116
Tabela 13 – Resultados do teste estatístico <i>Diebold-Mariano</i> (DM). . . . .	119
Tabela 14 – Parâmetros e níveis utilizados no <i>grid search</i> . . . . .	121
Tabela 15 – Parâmetros e níveis utilizados no <i>grid search</i> . . . . .	123
Tabela 16 – Resultado das melhores configurações do MTLF. . . . .	125
Tabela 17 – Resultados do <i>Model Confidence Set</i> (MCS) do MTLF. . . . .	126
Tabela 18 – Parâmetros e níveis utilizados no <i>grid search</i> . . . . .	128
Tabela 19 – Parâmetros e níveis utilizados no <i>grid search</i> . . . . .	130
Tabela 20 – Resultados das métricas das melhores configurações. . . . .	132
Tabela 21 – Resultados do MCS. . . . .	133

## LISTA DE ABREVIATURAS E SIGLAS

<b>AES</b>	<i>Applied Energy Sources</i>
<b>ANN</b>	<i>Artificial Neural Networks</i>
<b>API</b>	<i>Application Programming Interface</i>
<b>ARIMA</b>	<i>Autoregressive Integrated Moving Average</i>
<b>ARMA</b>	<i>Autoregressive Moving Average</i>
<b>BD</b>	Banco de Dados
<b>BTU</b>	<i>British Thermal Units</i>
<b>CAPEX</b>	<i>Capital Expenditure</i>
<b>CNN</b>	<i>Convolutional Neural Network</i>
<b>CO<sub>2</sub></b>	<i>Dióxido de Carbono</i>
<b>DBN</b>	<i>Deep Belief Network</i>
<b>DFNN</b>	<i>Deep Feed Forward Neural Networks</i>
<b>DM</b>	<i>Diebold-Mariano</i>
<b>DNN</b>	<i>Deep Neural Network</i>
<b>DRNN</b>	<i>Deep Recurrent Neural Networks</i>
<b>DSHW</b>	<i>Double Seasonal Holt–Winters</i>
<b>DT</b>	<i>Decision Tree</i>
<b>EES</b>	<i>Energy-Efficient Scheduling</i>
<b>GRU</b>	<i>Gated Recurrent Unit</i>
<b>HD</b>	<i>Hard Disk</i>
<b>HVAC</b>	<i>Heating, Ventilation, and Air Conditioning</i>
<b>IA</b>	Inteligência Artificial ou <i>Artificial Intelligence</i>
<b>IDE</b>	Indicadores de Desempenho Energético
<b>ILP</b>	<i>Integer-Linear Programming</i>

<b>IoT</b>	<i>Internet of Things</i>
<b>ISO</b>	<i>International Organization for Standardization</i>
<b>JSON</b>	<i>JavaScript Object Notation</i>
<b>Lasso</b>	<i>Least Absolute Shrinkage and Selection Operator</i>
<b>LR</b>	<i>Linear Regression</i>
<b>LSTM</b>	<i>Long Short-Term Memory</i>
<b>LTLF</b>	<i>Long Term Load Forecasting</i>
<b>MAD</b>	<i>Mean Absolute Deviation</i>
<b>MAE</b>	<i>Mean Absolute Error</i>
<b>MAPE</b>	<i>Mean Absolute Percentage Error</i>
<b>MCS</b>	<i>Model Confidence Set</i>
<b>ME</b>	<i>Mean Error</i>
<b>MLP</b>	<i>Multi-Layer Perceptrons</i>
<b>MSE</b>	<i>Mean Squared Error</i>
<b>MSP</b>	<i>Molten State Polymerization</i>
<b>MTLF</b>	<i>Medium Term Load Forecasting</i>
<b>NPU</b>	Unidade de Purificação de Nitrogênio
<b>OPC</b>	<i>Openness, Productivity, Connectivity</i>
<b>PEAD</b>	Polietileno de Alta Densidade
<b>PEBD</b>	Polietileno de Baixa Densidade
<b>PET</b>	<i>Polietileno Tereftalato</i>
<b>PIMS</b>	<i>Project Information Management System</i>
<b>PLC</b>	<i>Programmable Logic Controller</i>
<b>POLI</b>	Polimerização
<b>PP</b>	Polipropileno
<b>PS</b>	Poliestireno
<b>PVC</b>	Policloreto de Vinila

<b>RAM</b>	<i>Random Access Memory</i>
<b>RBF</b>	<i>Radial Basis Function</i>
<b>RMSE</b>	<i>Root Mean Squared Error</i>
<b>RNN</b>	<i>Recurrent Neural Networks</i>
<b>RRMSE</b>	<i>Relative Root Mean Square Error</i>
<b>SDG</b>	<i>Sustainable Development Goals</i>
<b>SGE</b>	Sistema de Gestão de Energia
<b>SMS</b>	<i>Short Message Service</i>
<b>SNN</b>	<i>Shallow Neural Network</i>
<b>SSD</b>	<i>Solid-State Drive</i>
<b>SSPOLI</b>	Polimerização do estado Sólido
<b>STLF</b>	<i>Short Term Load Forecasting</i>
<b>SVM</b>	<i>Support Vector Machines</i>
<b>SVR</b>	<i>Support Vector Machines Regression</i>
<b>UCI</b>	Universidade da Califórnia em Irvine
<b>VSTLF</b>	<i>Very Short Term Load Forecasting</i>
<b>XGBoost</b>	<i>Extreme Gradient Boosting</i>

## LISTA DE SÍMBOLOS

$MAE$	Erro médio absoluto
$P_i$	Valor da predição
$R_i$	Valor real
$MAPE$	Erro médio percentual absoluto
$RMSE$	Raiz do erro quadrático médio
$e_i$	Erros relacionados aos dados de $F$
$f_i$	Previsões relacionadas ao conjunto de dados $F$
$y_i$	Dados reais
$r_i$	Erros relacionados aos dados de $G$
$g_i$	Previsões relacionadas ao conjunto de dados $G$
$T$	Duração da série temporal
$d_i$	Diferença da perda
$\gamma$	Função autocorrelação
$Consumo_d$	Consumo de energia elétrica total
$E_q$	Média do consumo de energia elétrica para cada valor de $q$
$d_q$	Quantidade de dias para cada valor de $q$
$V_T$	Volume total de produção
$FV_q$	Faixa de vazão para cada valor de $q$
$P_L$	Prazo limite para a produção

$Payback$	Retorno do investimento
$CAPEX_{tecnologia}$	Despesas de capital
$Economia_{mensal}$	Economia mensal
$C_{sem_{tecnologia}}$	Custo de operação e consumo de energia sem a tecnologia inserida
$C_{com_{tecnologia}}$	Custo de operação e consumo de energia com a tecnologia inserida
$n$	Indicador de desempenho energético
$C$	Consumo de energia elétrica
$F$	Vazão de produção
$D_a$	Duração dos dados analisados (amostrados)
$\eta$	Eficiência da bomba
$U_{kWh}$	Custo unitário médio do $kWh$
$P_{max}$	Potência máxima da bomba
$E$	Energia elétrica
$P$	Potência da bomba
$Q$	Fluxo
$N$	Rotação da bomba
$H$	Altura manométrica ou pressão
$X'_i$	Dado normalizado
$X_i$	Dado real
$min(x)$	Mínimo valor do conjunto de dados
$max(x)$	Máximo valor do conjunto de dados

$C_{previsto}$	Consumo de energia elétrica previsto
$F_{planejado}$	Vazão de produção planejada
$n_{anterior}$	Indicador de desempenho energético anterior
$x(t)$	Valor estimado
$\alpha$	Polinômio relacionado ao operador autoregressivo de ordem $p$
$\beta$	Polinômio relacionado ao operador de média móvel da ordem $q$
$\varepsilon$	Diferença entre o valor estimado e o valor real

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>24</b>
1.1	OBJETIVOS	27
1.1.1	<b>Objetivo geral</b>	<b>27</b>
1.1.2	<b>Objetivos específicos</b>	<b>27</b>
1.2	ORGANIZAÇÃO DA TESE	27
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>29</b>
2.1	EFICIÊNCIA ENERGÉTICA INDUSTRIAL	29
2.1.1	<b>Indicadores de desempenho energético industrial</b>	<b>30</b>
2.1.2	<b>Problemas na indústria que impactam o consumo de energia</b>	<b>32</b>
2.2	PREDIÇÃO DO CONSUMO DE ENERGIA ELÉTRICA INDUSTRIAL	33
2.2.1	<b>Aprendizado Profundo</b>	<b>34</b>
2.2.1.1	Recurrent Neural Networks	35
2.2.1.2	Long Short-Term Memory	35
2.2.1.3	Gated Recurrent Unit	36
2.2.2	<b>Aprendizado de máquina</b>	<b>36</b>
2.2.2.1	Support Vector Machines Regression	37
2.2.2.2	Random Forest	37
2.2.2.3	Extreme Gradient Boosting	38
2.2.3	<b>Técnicas estatísticas</b>	<b>38</b>
2.2.3.1	Autoregressive Integrated Moving Average	39
2.2.4	<b>Abordagens para análise comparativa de modelos de predição</b>	<b>39</b>
2.2.4.1	Mean Absolute Error	40
2.2.4.2	Mean Absolute Percentage Error	41
2.2.4.3	Root Mean Squared Error	41
2.2.4.4	Teste Diebold-Mariano	41
2.2.4.5	Model Confidence Set	43
2.3	INDÚSTRIA DE RESINAS TERMOPLÁSTICAS	44

2.3.1	<b>Polietileno tereftalato</b> . . . . .	<b>46</b>
2.3.2	<b>Processos da indústria de resinas termoplásticas</b> . . . . .	<b>47</b>
2.4	GERENCIAMENTO DE ENERGIA ELÉTRICA INDUSTRIAL . . . . .	49
2.4.1	<b>Cenário industrial</b> . . . . .	<b>50</b>
2.4.2	<b>ISO 50001</b> . . . . .	<b>52</b>
2.4.3	<b>Benefícios do gerenciamento de energia industrial</b> . . . . .	<b>53</b>
<b>3</b>	<b>TRABALHOS RELACIONADOS</b> . . . . .	<b>55</b>
3.1	PREDIÇÃO DE CARGA DE CURTO PRAZO NA INDÚSTRIA . . . . .	55
3.2	SISTEMA DE GERENCIAMENTO DE ENERGIA ELÉTRICA NA INDÚSTRIA . . . . .	59
<b>4</b>	<b>FRAMEWORK PARA GERENCIAMENTO DE ENERGIA ELÉTRICA NA INDÚSTRIA</b> . . . . .	<b>62</b>
4.1	VISÃO GERAL DO <i>FRAMEWORK</i> . . . . .	63
4.2	<i>FRAMEWORK</i> PARA GERENCIAMENTO DE ENERGIA . . . . .	66
4.2.1	<b>Coleta de dados</b> . . . . .	<b>67</b>
4.2.2	<b>Sistema de processamento e armazenamento de dados</b> . . . . .	<b>68</b>
4.2.2.1	Predição . . . . .	68
4.2.2.2	Escalonamento . . . . .	70
4.2.2.2.1	<b><i>Definição do problema</i></b> . . . . .	<b>72</b>
4.2.2.2.2	<b><i>Algoritmo de otimização</i></b> . . . . .	<b>72</b>
4.2.2.3	Viabilidade . . . . .	73
4.2.2.4	Armazenamento . . . . .	74
4.2.2.5	<i>Suporte de dados</i> . . . . .	75
4.2.2.5.1	<b><i>Medição</i></b> . . . . .	<b>75</b>
4.2.2.5.2	<b><i>Configuração</i></b> . . . . .	<b>76</b>
4.2.2.5.3	<b><i>Controle de acesso</i></b> . . . . .	<b>77</b>
4.2.2.6	API REST . . . . .	77
4.2.3	<b>Interface de aplicação</b> . . . . .	<b>78</b>
4.3	CONSIDERAÇÕES FINAIS . . . . .	78

<b>5</b>	<b>ESTUDO DE CASO EM UMA INDÚSTRIA DE RESINAS TERMOPLÁSTICAS</b>	<b>80</b>
5.1	CARACTERÍSTICAS DA INDÚSTRIA DE RESINAS TERMOPLÁSTICAS	80
<b>5.1.1</b>	<b>Ações realizadas</b>	<b>80</b>
5.2	CARACTERÍSTICAS DO <i>FRAMEWORK</i> NO ESTUDO DE CASO	85
<b>5.2.1</b>	<b>Armazenamento</b>	<b>85</b>
<b>5.2.2</b>	<b>Suporte de dados</b>	<b>85</b>
<b>5.2.3</b>	<b>Viabilidade</b>	<b>86</b>
5.2.3.1	Custo com o consumo de energia sem o uso do inversor	87
5.2.3.2	Custo com o consumo de energia com o uso do inversor	87
<b>5.2.4</b>	<b>Escalonamento</b>	<b>89</b>
<b>5.2.5</b>	<b>Predição</b>	<b>92</b>
<b>5.2.6</b>	<b>API REST</b>	<b>93</b>
<b>5.2.7</b>	<b>Interface de aplicação - funcionalidades e telas</b>	<b>94</b>
<b>5.2.8</b>	<b>Infraestrutura</b>	<b>100</b>
5.3	CONSIDERAÇÕES FINAIS	102
<b>6</b>	<b>ANÁLISE DE MODELOS DE PREDIÇÃO</b>	<b>104</b>
6.1	MATERIAL E MÉTODO	104
<b>6.1.1</b>	<b>Conjunto de Dados</b>	<b>104</b>
<b>6.1.2</b>	<b>Pré-processamento dos dados</b>	<b>105</b>
<b>6.1.3</b>	<b>Métricas de avaliação</b>	<b>106</b>
6.2	PREDIÇÃO DO CONSUMO DE ENERGIA DE CURTO PRAZO	106
<b>6.2.1</b>	<b>Configuração do modelo de aprendizado profundo</b>	<b>107</b>
6.2.1.1	Configuração do modelo de aprendizado de máquina	110
<b>6.2.2</b>	<b><i>Baselines</i></b>	<b>113</b>
<b>6.2.3</b>	<b>Resultados modelo de predição do consumo de energia de curto prazo</b>	<b>114</b>
6.2.3.1	Teste estatístico Diebold-Mariano	119
6.3	PREDIÇÃO DO CONSUMO DE ENERGIA DE MÉDIO PRAZO	120
<b>6.3.1</b>	<b>Configuração do modelo de aprendizado profundo</b>	<b>121</b>

6.3.2	<b>Configuração do modelo de aprendizado de máquina . . . . .</b>	<b>123</b>
6.3.3	<b>Resultados do modelo de predição do consumo de energia de médio prazo . . . . .</b>	<b>124</b>
6.4	PREDIÇÃO DA VAZÃO DE PRODUÇÃO DE MÉDIO PRAZO . . . . .	127
6.4.1	<b>Configuração do modelo de aprendizado profundo . . . . .</b>	<b>128</b>
6.4.2	<b>Configuração do modelo de aprendizado de máquina . . . . .</b>	<b>129</b>
6.4.3	<b>Resultados do modelo de predição da vazão de produção para 30 dias . . . . .</b>	<b>131</b>
6.5	CONSIDERAÇÕES FINAIS . . . . .	133
<b>7</b>	<b>CONCLUSÃO . . . . .</b>	<b>135</b>
7.1	CONSIDERAÇÕES FINAIS . . . . .	135
7.2	LIMITAÇÕES DA PESQUISA . . . . .	137
7.3	SUGESTÕES PARA TRABALHOS FUTUROS . . . . .	138
7.4	CONTRIBUIÇÕES TÉCNICAS . . . . .	138
7.5	CONTRIBUIÇÕES CIENTÍFICAS . . . . .	139
7.5.1	<b>Publicações associadas à tese de Doutorado . . . . .</b>	<b>139</b>
7.5.2	<b>Publicações de artigos em área correlata . . . . .</b>	<b>139</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>141</b>
	<b>APÊNDICE A – ENDPOINTS API REST . . . . .</b>	<b>156</b>

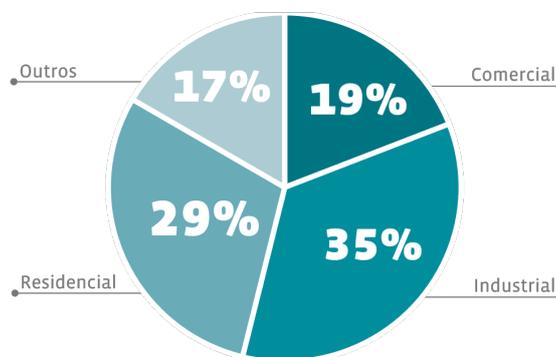
## 1 INTRODUÇÃO

O setor industrial é o maior consumidor de energia elétrica em todo o mundo. Neste setor, alguns tipos de indústrias se destacam pelo alto consumo de energia: alimentos, bebidas, celulose e papel, produtos químicos básicos, refinaria, ferro e aço, metais não ferrosos e metais não metálicos (EIA, 2016; EIA, 2019). A intensidade energética é impulsionada pela combinação de atividades em alguns setores, incluindo estoques de produtos químicos básicos, processo (incluindo aquecimento e resfriamento) e montagem, vapor e cogeração e consumo de energia relacionados à construção (por exemplo: iluminação, aquecimento e ar condicionado) (EIA, 2016). Prevê-se que o consumo mundial de energia industrial cresça de 242 quatrilhões de *British Thermal Units* (BTU), em 2018, para cerca de 315 quatrilhões de BTUs, em 2050; a proporção do setor industrial de alto consumo de energia deve permanecer em aproximadamente 50%, durante esse período (EIA, 2019).

No Brasil, o consumo de energia elétrica por unidade consumidora, em 2020, foi distribuído conforme mostra a Figura 1: 35% pela indústria, 19% pelo comércio e 29% por unidades residenciais (EPE, 2020). O setor industrial, mesmo apresentando uma quantidade de unidades inferior aos outros setores, sempre liderou o consumo de energia no Brasil, pois a quantidade de carga e o tempo de uso de cada carga no chão de fábrica são elevados.

Em abril de 2021 o setor industrial de Pernambuco foi alvo da maior revisão tarifária, quando comparado com os outros setores (residencial e comercial), correspondendo a um aumento de 11,89%. O reajuste foi justificado, principalmente devido aos custos com compra de energia, pagamento de encargos setoriais e transporte de energia (AID, 2021). Esses constantes aumentos de tarifa de energia refletem e impactam o resultado das indústrias.

Figura 1 – Representação do consumo anual de energia elétrica no Brasil, por unidades consumidoras, referente ao ano de 2019.



Fonte: (EPE, 2020).

É amplamente aceito que o consumo de energia está diretamente relacionado com o crescimento econômico (GOZGOR; LAU; LU, 2018); no entanto, neste cenário pode ser incluído o impacto ambiental desse consumo. Como parte dos objetivos de desenvolvimento sustentável das Nações Unidas, *Sustainable Development Goals* (SDG), o SDG 9 tem metas industriais para reduzir a emissão de *Dióxido de Carbono* (CO<sub>2</sub>) por unidade de valor agregado, por meio do aumento da eficiência do uso de recursos, maior adoção de tecnologias e processos industriais limpos e ambientalmente corretos (SDG9, 2020). Para cumprir essas metas, governos em todo o mundo estão impondo regulamentos e tributos para reduzir o impacto ambiental do consumo de energia industrial. As previsões do consumo de energia nas indústrias são essenciais para a tomada de decisão de medidas de precaução e mitigação, por parte da Administração, para minimizar o impacto ambiental, gerenciar o fluxo de caixa e reduzir ou eliminar o risco (SUNDARAKANI et al., 2010). O monitoramento preciso no nível da indústria também pode melhorar a qualidade dos dados disponíveis para a formulação de políticas e ações locais, regionais e nacionais.

O advento da *International Organization for Standardization* (ISO) 50001 (FOSSA; SGARBI, 2017) — Sistemas de Gestão da Energia — em 2001, que provê os requisitos mínimos que assegurem a melhoria constante do desempenho energético, possibilitou que muitas empresas buscassem, de forma contínua, a redução do consumo de ener-

gia e o aumento da eficiência energética de seus processos, contribuindo com o meio ambiente, bem como aumentando o nível de competitividade. A implementação, no ambiente industrial, de um sistema de gestão de energia baseado na ISO 50001 proporciona, dentre outros benefícios, a comunicação mais fácil e transparente sobre o gerenciamento energético; implementação de melhores práticas de gestão energética; implementação de tecnologias mais eficientes no uso da energia; integração com outros sistemas organizacionais de gerenciamento (ABNT, 2018).

Diante dessa contextualização, alguns problemas que podem impactar e estão relacionados ao consumo de energia elétrica na indústria de resinas termoplásticas foram destacados, como: carência de informação referente à integração de dados de consumo de energia elétrica e variáveis de processo; planejamento de produção ineficiente; processos ineficientes; baixa utilização de tecnologia da informação e equipamentos mais eficientes; dificuldade da implantação e manutenção da ISO 50001; e dificuldade de aplicabilidade de experimentos inovadores em ambientes industriais.

Conforme a problemática apresentada, é possível considerar como a principal pergunta da pesquisa desta tese: "*Como utilizar dados coletados de variáveis elétricas e de processos para gerar informações que darão suporte à tomada de decisão, no contexto de produção de uma indústria de resinas termoplásticas?*". Essa pergunta é respondida através da formulação e implementação de um sistema de apoio à decisão que se caracteriza por um *framework*<sup>1</sup> de gerenciamento de energia elétrica industrial. O *framework* recebe, como entrada, dados de variáveis elétricas e variáveis de processo da planta industrial e produz, como saída, informações para auxiliar a tomada de decisão: gráficos com a predição do indicador de desempenho energético; alertas; faixas de vazão de produção e tempo de produção; tempo de retorno de investimento de materiais, equipamentos e sistemas, dentre outros. O processamento desses dados é realizado através da integração entre três modelos: (1) o modelo de predição<sup>2</sup> do indicador de desempenho energético; (2) o modelo de escalonamento da vazão de produção; e (3) o modelo de viabilidade técnica e econômica da inserção de tecnologias (materiais, equipamentos e sistemas). Para o estudo de caso, a implementação dos

<sup>1</sup> Nesta tese assumimos que o termo *framework* é sinônimo de arcabouço.

<sup>2</sup> Nesta tese o termo predição (*forecasting*) está sendo utilizado conforme as referências (SILVA, 2016; WEI et al., 2019).

modelos foi baseada em técnicas de Inteligência Artificial ou *Artificial Intelligence* (IA), otimização linear e lei da afinidade, respectivamente.

Esta tese foi integrada ao projeto de eficiência de uma indústria de resinas termoplásticas. Desta forma, a definição dos requisitos do *framework* se baseou em demandas reais da indústria. Bem como, sua validação foi realizada pela implantação do *framework*, por meio de um estudo de caso nessa indústria.

## 1.1 OBJETIVOS

### 1.1.1 Objetivo geral

Desenvolver um sistema de apoio à decisão caracterizado por um *framework* de gerenciamento de energia elétrica de uma indústria termoplástica, por meio dos modelos de predição do indicador de desempenho energético, escalonamento da vazão de produção e viabilidade de tecnologias.

### 1.1.2 Objetivos específicos

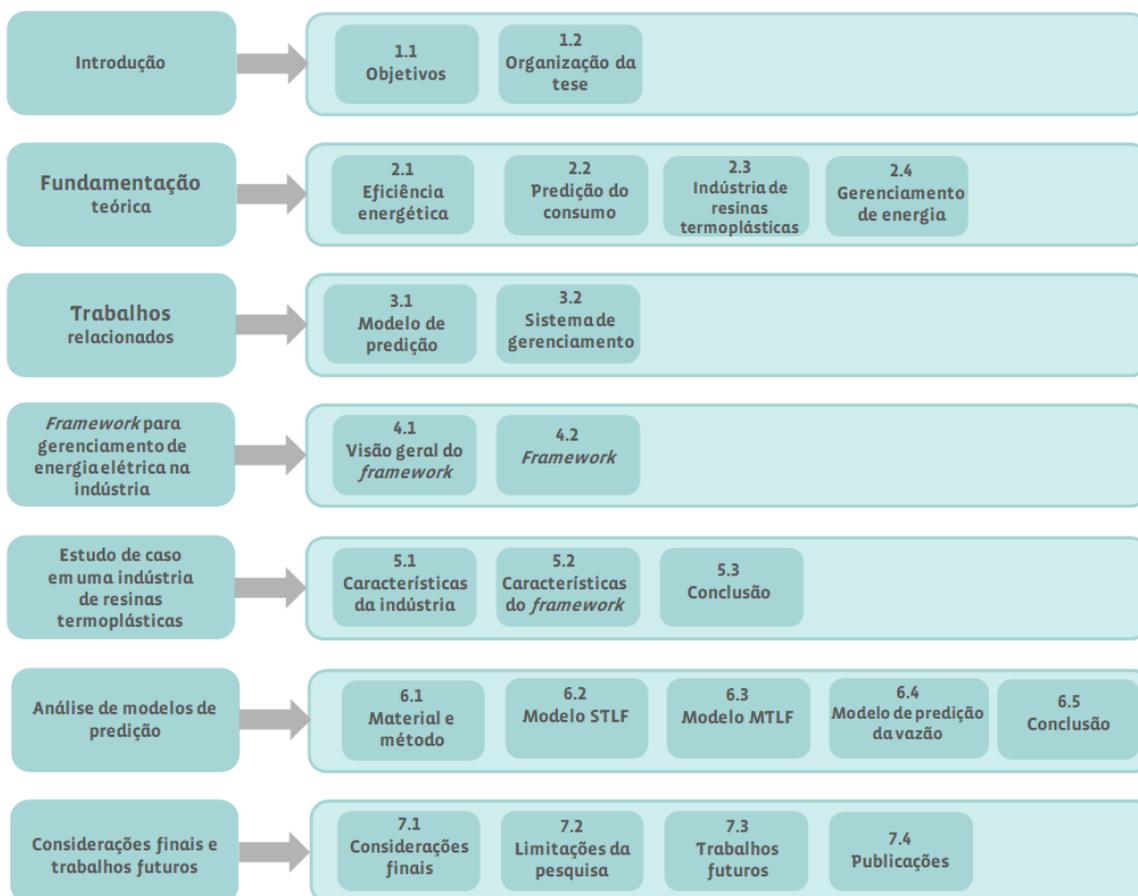
- Configurar e avaliar o modelo de predição de energia elétrica para análise do indicador de desempenho energético de uma indústria;
- Propor e avaliar um modelo de escalonamento da vazão de produção, por meio de identificação de faixas de vazão eficientes e variáveis determinantes para a redução de custo com energia elétrica;
- Elaborar um modelo de viabilidade de investimento de tecnologias (equipamentos, materiais, sistemas);

## 1.2 ORGANIZAÇÃO DA TESE

A tese está estruturada em sete capítulos, detalhados na Figura 2, iniciando com uma abordagem sobre os principais temas que serão tratados na pesquisa (Capítulo 1), uma fundamentação teórica (Capítulo 2), trabalhos relacionados (Capítulo 3), deta-

lhamento da proposta (Capítulo 4), estudo de caso (Capítulos 5 e 6), e considerações finais (Capítulo 7).

Figura 2 – Estrutura da tese.



Fonte: O autor.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os principais conceitos teóricos já consolidados na literatura e necessários para o desenvolvimento e melhor entendimento da tese. A Seção 2.1 aborda o conceito de eficiência energética no contexto industrial; desta forma, serão apresentados os indicadores de desempenho energético e discutidos alguns problemas na indústria que impactam no consumo de energia. A Seção 2.2 contempla aspectos relacionados à predição do consumo de energia elétrica industrial; assim, serão exibidas as características da *Very Short Term Load Forecasting* (VSTLF), STLF, *Medium Term Load Forecasting* (MTLF) e *Long Term Load Forecasting* (LTLF); em seguida, serão apresentadas técnicas para definição de modelos de predição do consumo de energia elétrica na indústria; por fim, serão apresentadas diferentes abordagens para realizar a análise comparativa entre os modelos de predição. A Seção 2.3 apresenta as características da indústria de resinas termoplásticas, enquanto a Seção 2.4 detalha aspectos relacionados ao gerenciamento de energia elétrica industrial, no lado da demanda.

### 2.1 EFICIÊNCIA ENERGÉTICA INDUSTRIAL

Reduzir a demanda de energia nas indústrias é indispensável para o desenvolvimento sustentável porque o uso e o suprimento de energia causam efeitos ambientais negativos (emissões de gases de efeito estufa, acidificação, dentre outros). No entanto, a energia é um fator de produção não substituível e, por isso, a redução de sua demanda é limitada. Portanto, melhorar a relação entre a entrada de energia e a produção desejada de um processo de produção — melhorando a eficiência energética — é um dos aspectos centrais da indústria sustentável (PATTERSON, 1996).

A eficiência energética, segundo Duran et al. (DURAN; ARAVENA; AGUILAR, 2015), pode ser considerada como uma fonte de energia adicional resultante da redução do consumo de energia e mantendo um determinado nível de produção. Essa redução no consumo de energia pode ser obtida por meio da melhoria da tecnologia ou da efici-

ência do processo. Também a eficiência energética permite que as indústrias reduzam sua intensidade energética, seja reduzindo os desperdícios ou otimizando os recursos tecnológicos, para alcançar o mesmo nível de produção com custos mais baixos e menos poluição.

A aplicação da *Energy-Efficient Scheduling* (EES) é uma das medidas adotadas por diversas indústrias: trata-se de uma medida organizacional que não demanda muitos investimentos para sua implantação, e que influencia na quantidade total de demanda *Applied Energy Sources* (AES) e/ou no custo dessa demanda (GAHM et al., 2016).

A eficiência energética industrial é crucial para a economia de custos e a competitividade sustentável, mas seu potencial não é explorado devidamente, por conta de diversas barreiras, como: de informação, relacionada à carência de disponibilidade de tecnologias de eficiência energética; econômicas; envolvendo custos com auditorias energéticas, investimento em tecnologias de eficiência energética, implantação de novas tecnologias, que exigem parada, ao menos parcial, na produção; percepção de que a indústria já é eficiente, e que os custos com energia não apresentam impacto relevante em relação aos custos de produção, dentre outros (CAGNO et al., 2013). Portanto, em uma indústria é crucial a avaliação do desempenho energético e a definição de suas metas, para tornar possível empreender as ações de melhoria (FOSSA; SGARBI, 2017).

Segundo Alexandre (CAPELLI, 2013), para que uma indústria alcance uma eficiência energética considerável, é preciso contemplar cinco ações: (1) compreender o consumo de energia elétrica; (2) entender como é realizada a cobrança; (3) sinalizar ações que oportunizem a redução dos custos com energia; (4) realizar o diagnóstico energético; e (5) definir indicadores para acompanhar a redução do consumo de energia.

### **2.1.1 Indicadores de desempenho energético industrial**

Antes da apresentação dos Indicadores de Desempenho Energético (IDE) é relevante mencionar desempenho energético. Segundo a ABNT (ABNT, 2016), o desempenho energético faz a relação entre três diferentes conceitos: eficiência energética, consumo de energia e como essa energia é utilizada. Logo, para realizar o gerenciamento do

---

desempenho energético de sistemas e processos industriais é fundamental acompanhar o histórico do consumo de energia e entender como essa energia é utilizada.

O IDE é a representação da eficiência energética e do consumo de energia em processos, equipamentos e sistemas, de forma quantificada. O IDE permite acompanhar temporalmente o desempenho energético de uma indústria e identificar se o mesmo está alcançando as metas energéticas especificadas, dado que as metas para o desempenho energético definidas no processo de planejamento energético são caracterizadas pelos IDEs. Para as indústrias, o IDE é frequentemente utilizado para gerenciamento de melhorias no desempenho energético (ABNT, 2016). Desta forma, o IDE pode ser comparado com uma meta interna ou até mesmo um *benchmark* externo para fornecer a indicação do desempenho de uma determinada indústria (VIKHOREV; GREENOUGH; BROWN, 2013).

Os IDEs podem ser classificados em basicamente quatro tipos: valor de energia medido (exemplo: consumo de energia individualizada, consumo de energia em um horário específico, consumo de energia total, dentre outros); proporção dos valores medidos (exemplo: consumo de energia por produção —  $kWh/ton.$ , consumo de energia por área —  $kWh/m^2$ , consumo de energia por unidade de venda, dentre outros); modelo estatístico; e modelo de engenharia (exemplo: modelos onde cálculos ou simulações exibem interações entre variáveis importantes para o sistema) (ABNT, 2016). É possível observar que os IDEs são representados por variáveis relevantes, isto é, que influência no desempenho energético.

Devido à importância da energia nos custos de produção e a necessidade da participação das indústrias na melhoria do clima global, elas estão sendo motivadas a reduzir os custos e perdas energéticas, bem como diminuir os impactos ambientais decorrentes de suas atividades (SCHMIDT et al., 2016). Nesta tese, foram definidos basicamente dois IDEs: o primeiro, do tipo de valor de energia medido, e o segundo, do tipo proporção dos valores medidos (Tabela 1). Através do comportamento do consumo de energia por um determinado período, será possível analisar a economia absoluta da indústria. A vazão de produção é uma das variáveis importantes para as indústrias de resinas termoplásticas; logo, com a análise do comportamento da relação entre o

consumo de energia elétrica e a vazão de produção ( $kWh/ton.$ ) (CAPELLI, 2013), será possível realizar comparações entre a eficiência da mesma indústria em anos diferentes ou até mesmo comparações entre indústrias diferentes.

Tabela 1 – IDEs definidas para este estudo.

Níveis de IDE	Tipo de IDE	Usuários do IDE
Consumo de energia diário ( $kWh/dia$ )	Valor de energia medido	Gerentes de orçamento
		Tomadores de decisão
Consumo de energia por vazão de produção ( $kWh/ton.$ )	Razão dos valores medidos	Gerente de produção
		Gerente de orçamento

**Fonte:** O autor.

### 2.1.2 Problemas na indústria que impactam o consumo de energia

O consumo de energia na indústria é impactado por diversos problemas provenientes do mau uso de equipamentos; dificuldades de configuração de parâmetros de processo; *big data*, que pode ser dividida no "5Vs— volume, velocidade, variedade, variabilidade e valor — o que pode dificultar a extração adequada de informação (DEMCHENKO et al., 2013; DEMCHENKO; LAAT; MEMBREY, 2014); como também pouco incentivo para a redução de consumo.

O monitoramento do processo fabril é de fundamental importância para o direcionamento do uso adequado dos equipamentos. Para tanto, são necessários parâmetros bem definidos para serem acompanhados. O tempo é uma variável importante a ser analisada. Por meio dessa variável é possível verificar a duração do uso das máquinas em cada processo, identificar a existência de tempo ocioso e desperdício de energia como consequência (HERRMANN; THIEDE, 2009). Além disso, é possível apontar a necessidade de manutenção ou de substituição, dado que cada equipamento tem sua vida útil específica.

A definição adequada de parâmetros de processo, bem como a especificação e escolha de equipamentos são importantes para a obtenção de um sistema otimizado. A

ausência de análises dos dados e a dificuldade de realização de experimentos fazem parte de uma realidade no setor industrial que dificulta essa definição. Assim, o uso de sensores, válvulas, motores, e outros equipamentos em alguns processos poderia ser desnecessário.

A quarta revolução industrial contribuiu para a geração de um elevado volume de dados no setor industrial. Mas, ainda há uma carência do uso adequado desses dados para geração de informação, bem como uso de técnicas de IA (RAPTIS; PASSARELLA; CONTI, 2019). Com esses dados, a predição do consumo de energia elétrica pode ser utilizada para auxiliar a identificação de problemas que impactam o consumo de energia, pois provê a identificação de anomalias (WANG et al., 2019; WANG; LIU; BAO, 2016), o gerenciamento do consumo (detectar, prever e planejar o consumo de energia); a comercialização de energia industrial (HUANG et al., 2019), dentre outros.

Para otimizar a planta industrial e minimizar alguns problemas que impactam o consumo de energia industrial, Alexandre (CAPELLI, 2013) sugere aplicar quatro práticas: (1) substituir equipamentos que não são eficientes por equipamentos mais eficientes; (2) evitar o uso de equipamento em mais de um processo, de forma simultânea; (3) fazer alterações de processos e de alguns hábitos; e (4) implantar automação nos diferentes setores industriais, dentre eles o setor de produção.

## 2.2 PREDIÇÃO DO CONSUMO DE ENERGIA ELÉTRICA INDUSTRIAL

Há diferentes abordagens, na literatura, para realizar a predição de consumo de energia elétrica na indústria. Nessa pesquisa serão utilizadas técnicas de aprendizado profundo, bem como técnicas de aprendizado de máquina e técnicas estatísticas. As abordagens que usam IA já foram utilizadas para essa finalidade, em diferentes pesquisas científicas; contudo, uma boa parte é aplicada em contextos diferentes, como residências (KONG et al., 2017; SHI; XU; LI, 2017; GÜNGÖR; AKŞANLI; AYDOĞAN, 2019), comerciais (PETRI et al., 2014; XYPOLYTOU; MEISEL; SAUTER, 2017) e edifícios (DAUT et al., 2017; LIU et al., 2020).

Antes de apresentar as características das diferentes abordagens para criar modelos para predição do consumo de energia, é importante definir as diferentes classificações

da predição do consumo de energia de acordo com o intervalo de tempo da medição — anos, mês, dia, hora, minuto e segundo.

As cargas elétricas na indústria podem ser basicamente de dois tipos: (1) as cargas industriais representadas pelos motores, caldeiras, máquinas de solda, dentre outros; e (2) as cargas não industriais como o sistema de iluminação, refrigeração, equipamentos de escritório, dentre outros. A predição de carga elétrica é responsável por prever a energia necessária para atender a demanda industrial.

Existem quatro tipos diferentes de classificação da predição de carga elétrica relacionados ao intervalo de tempo das medições: VSTLF, STLF, MTLF e LTLF) (PATEL; PATEL; PATEL, 2019; FEINBERG; GENETHLIOU, 2005) (Tabela 2). Dependendo da operação (diagnóstico, compra de energia elétrica, dentre outras) a ser realizada no ambiente industrial, haverá a necessidade de escolha adequada relacionada a essa classificação. Nesta tese, a predição do consumo de energia será utilizada para o sistema de diagnóstico e para auxiliar o planejamento energético; logo, serão aplicados modelos com base no STLF e MTLF.

Tabela 2 – Características da classificação da predição de carga elétrica relacionada ao intervalo de medição.

Classificação	Características
Predição de carga de um prazo muito curto (VSTLF)	Predição que varia de alguns minutos até uma hora, bastante utilizada para aplicações de rede inteligente e mercados de eletricidade baseados em leilões
Predição de carga de curto prazo (STLF)	Predição para faixa de algumas horas até uma semana.
Predição de carga de médio prazo (MTLF)	Predição na faixa de uma semana até um ano.
Predição de carga de longo prazo (LTLF)	Predição para uma faixa de mais de um ano.

**Fonte:** Adaptado de (PATEL; PATEL; PATEL, 2019; FEINBERG; GENETHLIOU, 2005).

### 2.2.1 Aprendizado Profundo

O aprendizado profundo é uma técnica de aprendizado de máquina capaz de criar modelos hierárquicos complexos que visam simular o aprendizado humano (GOODFELLOW et al., 2016). Os principais modelos de aprendizado profundo utilizados para

---

realizar predição incluem, por exemplo, *Recurrent Neural Networks* (RNN) (VERMAAK; BOTHA, 1998; BENGIO; SIMARD; FRASCONI, 1994; CHUNG et al., 2014), *Long Short-Term Memory* (LSTM) (HE et al., 2019; KONG et al., 2017; SUNDERMEYER; SCHLÜTER; NEY, 2012; YU et al., 2019), e *Gated Recurrent Unit* (GRU) (WANG et al., 2018; WU et al., 2019; KUAN et al., 2017).

Nas análises comparativas desta tese serão utilizadas essas três técnicas, por apresentarem os melhores resultados dentre as disponíveis de aprendizado profundo.

### 2.2.1.1 Recurrent Neural Networks

A RNN é um tipo de *Artificial Neural Networks* (ANN), projetado para reconhecer padrões em fluxos de dados sequenciais. Em uma RNN, a decisão, a classificação ou o aprendizado em um determinado momento  $t-1$  influenciam a decisão, a classificação ou o aprendizado em um momento subsequente  $t$  na série temporal.

As RNNs contêm duas fontes de entrada, o presente e o passado recente. Esses dados são combinados para determinar como os novos dados são previstos. As RNNs têm uma memória que, por exemplo, *Multi-Layer Perceptrons* (MLP) e *Convolutional Neural Network* (CNN) não têm. Como tal, a RNN usa informações na própria sequência para realizar tarefas que outras ANNs são incapazes de fazer.

Além disso, como limitação mais significativa, as RNNs têm dificuldade em treinar RNNs para capturar dependências de longo prazo devido a problemas de gradiente de desaparecimento e explosão (BENGIO; SIMARD; FRASCONI, 1994; CHUNG et al., 2014). LSTM e GRU são variações das RNN que superam tais problemas.

### 2.2.1.2 Long Short-Term Memory

A LSTM (SUNDERMEYER; SCHLÜTER; NEY, 2012) é uma variação da RNN e supera problemas de gradiente utilizando uma estrutura em cadeia contendo quatro redes neurais e diferentes blocos de memória (HOCHREITER; SCHMIDHUBER, 1997). Além disso, a LSTM atualiza seus estados de unidade usando três portas: uma de esquecimento, uma de entrada e uma de saída. A porta de esquecimento exclui informações que não são mais úteis na unidade (HOCHREITER; SCHMIDHUBER, 1997). A entrada

---

atual  $x_t$  e a saída da unidade anterior  $h_{t-1}$  são multiplicadas pela matriz de peso. O resultado é passado por uma função de ativação que fornece uma saída binária que faz com que os dados sejam esquecidos. A porta de entrada realiza a adição de informações úteis ao *status* da unidade. Primeiro, a informação é ajustada usando uma função *sigmoid*. Então, a função tangente hiperbólica é usada para criar um vetor que produz valores no intervalo de  $-1$  a  $+1$ . Finalmente, a porta de saída completa a tarefa de extrair informações úteis do estado atual da unidade para serem exibidas como uma saída. Para isso, um vetor é gerado, aplicando uma função tangente hiperbólica a uma célula.

Devido à sua estrutura, as LSTMs podem prever séries temporais com intervalos de tempo de duração desconhecida (Gers; Schmidhuber; Cummins, 1999). Essa é uma vantagem significativa sobre as RNNs tradicionais. Apesar disso, o longo tempo de treinamento constitui uma limitação significativa (JOZEFOWICZ; ZAREMBA; SUTSKEVER, 2015).

### 2.2.1.3 Gated Recurrent Unit

Os GRUs reduzem a complexidade das LSTMs utilizando apenas uma porta de atualização e uma de reinicialização para determinar como os valores nos estados ocultos são calculados (CHUNG et al., 2014). Em GRUs, apenas um estado oculto é transferido entre as etapas de tempo (CHUNG et al., 2014). Este estado consegue manter dependências de longo e curto prazo, ao mesmo tempo. Os *gates* GRUs são treinados para filtrar seletivamente qualquer informação irrelevante, enquanto mantêm o que é útil. Essas portas são vetores que contêm valores binários, como na LSTM, e determinam a importância da informação. Crucialmente, as referências sugerem que GRUs têm tempos de treinamento significativamente mais rápidos, com desempenho comparável à LSTM (CHUNG et al., 2014; JOZEFOWICZ; ZAREMBA; SUTSKEVER, 2015).

## 2.2.2 Aprendizado de máquina

O aprendizado de máquina é a capacidade que a máquina tem de adquirir conhecimento, extraindo padrões a partir dos dados brutos (GOODFELLOW et al., 2016). Os modelos tradicionais de aprendizado de máquina incluem, por exemplo, *Support*

---

*Vector Machines Regression* (SVR) (GOLKARNARENJI et al., 2018; SAPANKEVYCH; SANKAR, 2009; MÜLLER et al., 1997; CEPERIC; CEPERIC; BARIC, 2013; CHEN; TAN, 2017; CHEN et al., 2017; GROLINGER et al., 2016), *Random Forest* (LAHOUAR; SLAMA, 2015; LI et al., 2018; LI; ZHANG; XIANG, 2019), *Extreme Gradient Boosting* (XGBoost) (ZHU; GENG; WANG, 2021; ZHENG; YUAN; CHEN, 2017) e ANN (GROLINGER et al., 2016; SINGH; HUSSAIN; BAZAZ, 2017). Essas são as técnicas que serão utilizadas ao longo desta tese.

### 2.2.2.1 Support Vector Machines Regression

O *Support Vector Machines* (SVM) é uma técnica de aprendizado de máquina baseada na teoria de aprendizado estatístico (VAPNIK, 1995). A literatura sugere que o SVM tem um bom desempenho na predição de séries temporais (MÜLLER et al., 1997; SIMON, 1999; SAPANKEVYCH; SANKAR, 2009). Já o SVR é uma técnica de regressão baseada em SVM (DRUCKER et al., 1997). As principais diferenças entre essas técnicas estão relacionadas aos formatos e tipos de entrada e saída. As funções do *kernel* são usadas para mapear os dados por funções não lineares em um espaço n-dimensional. Dessa forma, é possível transformar problemas não lineares em problemas lineares.

O estudo de Golkarnarenji et al. (GOLKARNARENJI et al., 2018) sugere que o SVR apresenta resultados precisos para prever o consumo de energia e, como tal, é comumente usado com esse objetivo. Apesar de suas vantagens, a falta de heurísticas predeterminadas para o projeto e parametrização dos modelos de SVR é uma grande desvantagem no uso de SVR (SAPANKEVYCH; SANKAR, 2009). Assim, os estudos tendem a ser específicos da aplicação e carecem de generalização (SAPANKEVYCH; SANKAR, 2009).

### 2.2.2.2 Random Forest

O *Random Forest* é uma técnica de aprendizado de máquina baseada em diferentes árvores de decisão. A implementação do *Random Forest* envolve a seleção aleatória de recursos com base na posição do nó raiz. A saída do modelo consiste na média dos resultados de todas as árvores. Quando comparada a uma única árvore de decisão, a *Random Forest* apresenta um melhor desempenho (BREIMAN, 2001; LIAW; WIENER

---

et al., 2002; CUTLER et al., 2007). Quanto maior o número de árvores, normalmente melhor será o desempenho do modelo, mas torna o modelo mais lento e ineficiente para previsões em tempo real. É uma das técnicas de aprendizado de máquina mais popular, usada para problemas de classificação e regressão (LAHOUAR; SLAMA, 2015; LI et al., 2018; LI; ZHANG; XIANG, 2019). A popularidade do *Random Forest* é frequentemente atribuída à sua maior precisão, quando comparada com ANN e SVR (CARUANA; KARAMPATZIAKIS; YESSINALINA, 2008).

### 2.2.2.3 Extreme Gradient Boosting

O *Extreme Gradient Boosting* popularmente conhecida como o XGBoost é uma técnica de aprendizado de máquina supervisionada, baseada na árvore de decisão (CHEN; GUESTRIN, 2016). Faz uso de processamento paralelo, manipulação de valores ausentes e regularização, evitando *overfitting* e visando obter melhores resultados com menores recursos computacionais. Esta técnica permite a utilização de um elevado número de dados, trabalhar com complexidade, seleção automática de recursos, escalabilidade (LI; ZHANG, 2018; HU et al., 2021). Assim, é bastante utilizada para predição em diferentes contextos, dentre eles do consumo de energia elétrica (LIAO et al., 2019).

### 2.2.3 Técnicas estatísticas

As técnicas estatísticas quando comparadas com as técnicas de aprendizado de máquina e aprendizado profundo são mais antigas. Desta forma, nesta tese foi escolhida a técnica *Autoregressive Integrated Moving Average* (ARIMA) para ser *baseline* na análise comparativa das diferentes configurações de modelos que utilizam aprendizado de máquina e aprendizado profundo para a predição do consumo de energia elétrica.

A justificativa para a escolha do ARIMA nesta pesquisa está relacionada com os trabalhos anteriores que fazem uso desta técnica para modelos de predição de consumo de energia (RYU; NOH; KIM, 2017; SEN; ROY; PAL, 2016; AL-MUSAYLH et al., 2018; YUAN; LIU; FANG, 2016).

### 2.2.3.1 Autoregressive Integrated Moving Average

O ARIMA é uma generalização do *Autoregressive Moving Average* (ARMA) (NASON, 2006; SEN; ROY; PAL, 2016). A técnica ARMA, não sazonal, é representada como ARIMA  $(p, d, q)$ , onde  $p$  é a ordem da autorregressiva,  $d$  e  $q$  são a ordem da média móvel.

O ARIMA é usado, normalmente, em aplicações em que a série temporal segue uma tendência não estacionária. O ARIMA aplica um estágio inicial de diferenciação para eliminar o comportamento não estacionário, transformando a série temporal em estacionária para aprendizado (YUAN; LIU; FANG, 2016). Normalmente, para o ARIMA funcionar bem, ele precisa trabalhar com um longo conjunto de dados históricos (SEN; ROY; PAL, 2016).

### 2.2.4 Abordagens para análise comparativa de modelos de predição

A avaliação do desempenho dos modelos preditivos é uma etapa fundamental para identificar o poder preditivo de cada modelo. Desta forma, é possível reconhecer o comportamento e as características de cada modelo com o conjunto de dados utilizado nesta tese, subsidiando a seleção do modelo mais adequado para cada contexto, além de identificar melhorias contínuas.

Há diferentes estratégias para permitir uma análise comparativa de modelos de predição: (1) análise de métricas associadas aos erros de predição (estratégia mais tradicional); (2) teste estatístico *Diebold-Mariano* (DM) (estratégia formal); e o (3) *Model Confidence Set* (MCS):

1. Métricas associadas aos erros de predição: erro médio absoluto ou *Mean Absolute Error* (MAE), raiz do erro quadrático médio ou *Root Mean Squared Error* (RMSE), e erro médio percentual absoluto ou *Mean Absolute Percentage Error* (MAPE) são as métricas mais utilizadas para análise do desempenho de modelos que fazem predição do consumo de energia (DEBNATH; MOURSHED, 2018; RYU; NOH; KIM, 2017; CHEN et al., 2018; YEOM; CHOI, 2018); por isso, serão uti-

lizadas com o auxílio da biblioteca *numpy* do *Python*. O tempo de inferência e a convergência podem complementar essas análises.

2. Teste estatístico DM: exemplo de teste estatístico utilizado para avaliar normalmente o desempenho em casos em que a estratégia tradicional apresenta resultados muito próximos um dos outros, pois o teste estatístico DM foi desenvolvido para solucionar o problema de *data snooping* (DIEBOLD; MARIANO, 1995). Nesta tese, foi utilizada a função *dm.test* de *Python* para auxiliar a aplicação do teste estatístico DM.
3. MCS: utilizado para avaliar o desempenho de modelos de predição quando é necessário corrigir os efeitos do *data snooping*. Como é baseado no teste de equivalência é capaz de gerar um conjunto formado por todos os modelos que apresentam melhores desempenhos baseados em determinado nível de significância e não há a necessidade de definir um modelo *benchmark* (HANSEN; LUNDE; NASON, 2011). Para aplicar o MCS nos modelos apresentados nesta tese, foi utilizada a função *arch.bootstrap* do pacote MCS de *Python*.

#### 2.2.4.1 Mean Absolute Error

A *Mean Absolute Error* (MAE) é a média da diferença absoluta entre o valor real ( $R_i$ ) e o valor predito ( $P_i$ ) de  $N$  amostras (Equação 2.1) (HSIEH; HSIAO; YEH, 2011; BERRIEL et al., 2017; LI; ZHANG; XIANG, 2019). Contorna o problema da nulidade dos termos apresentado na *Mean Error* (ME) e o minimizador dessa métrica é a mediana. Ao contrário das outras métricas (ME, *Mean Absolute Percentage Error* (MAPE) e *Root Mean Squared Error* (RMSE)), a MAE depende da escala dos dados e não é sensível a *outliers*, pois trata todos os erros da mesma maneira. Desta forma, é bastante utilizada quando a base de dados apresenta ruídos e é normalmente utilizada para quantificar a capacidade de predição de um determinado modelo.

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - R_i| \quad (2.1)$$

### 2.2.4.2 Mean Absolute Percentage Error

A MAPE é amplamente usada para avaliar modelos de predição, particularmente quando a qualidade da predição é necessária, em estudos de predição de consumo de energia. A MAPE é definida na Equação 2.2 (AZADEH; GHADERI; SOHRABKHANI, 2008; HSIEH; HSIAO; YEH, 2011; RYU; NOH; KIM, 2017) e expressa a precisão do erro como uma porcentagem. Pode ser aplicada em diferentes contextos, pois é uma interpretação relativamente intuitiva de erros relativos. No entanto, só pode ser usada se os valores no conjunto de dados diferirem de zero.

$$MAPE\% = \frac{100}{N} \sum_{i=1}^N \left| \frac{P_i - R_i}{R_i} \right| \quad (2.2)$$

### 2.2.4.3 Root Mean Squared Error

A RMSE é definida como a raiz quadrada do erro médio quadrático ou *Mean Squared Error* (MSE) (WILLMOTT; MATSUURA, 2005) (Equação 2.3 (HSIEH; HSIAO; YEH, 2011; LI; ZHANG; XIANG, 2019)), ou seja, é o desvio padrão da amostra da diferença entre o valor previsto e o valor real. A RMSE é mais sensível a erros mais significativos (*outliers*), pois eleva ao quadrado a diferença entre o valor previsto e o valor real. É uma métrica independente da escala e apresenta a mesma dimensão da variável analisada (exemplo: se esta variável for o consumo de energia, a unidade do RMSE será *kWh*) (WILLMOTT; MATSUURA, 2005). É amplamente aplicada em modelos que usam séries temporais (KOLOMVATSOS et al., 2019).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - R_i)^2} \quad (2.3)$$

Analisando as três métricas estatísticas relacionadas à precisão do modelo de predição, é possível afirmar que, quanto menor o valor dessa métrica, melhor será o desempenho do modelo avaliado.

### 2.2.4.4 Teste Diebold-Mariano

O DM é um teste estatístico capaz de avaliar a precisão dos modelos preditivos mediante análise comparativa entre as previsões obtidas das séries temporais a cada

dois modelos. Este teste fornece níveis de significância que facilitam o discernimento da avaliação das habilidades preditivas dos modelos. Além disso, o teste DM está sendo bastante utilizado para comparar modelos de predição, devido à facilidade de interpretação e simplicidade de implementação (MARIANO; PREVE, 2012).

Por meio da verificação da hipótese da igualdade entre os valores previstos de cada dois modelos de previsões diferentes, o teste DM considera a série temporal dos erros de predição. Os dois modelos de predição analisados geram previsões representadas por um conjunto de dados  $f_1, f_2, \dots, f_n$  e  $g_1, g_2, \dots, g_n$ , respectivamente. E a série temporal dos dados reais é representada por  $y_1, y_2, \dots, y_n$ . Com esses dados, são calculados os erros de cada predição ( $e_i$  e  $r_i$ ), através das Equações 2.4, 2.5.

$$e_i = f_i - y_i \quad (2.4)$$

$$r_i = g_i - y_i \quad (2.5)$$

O valor de  $d_i$  pode ser definido de diferentes maneiras, dependendo do critério que será analisado, a MSE (Equação 2.6); a *Mean Absolute Deviation* (MAD) (Equação 2.7); a MAPE (Equação 2.8) (DIEBOLD; MARIANO, 1995).

$$d_i = e_i^2 - r_i^2 \quad (2.6)$$

$$d_i = |e_i| - |r_i| \quad (2.7)$$

$$d_i = \frac{|e_i - y_i|}{y_i} \quad (2.8)$$

A série temporal com duração  $T$  que irá representar a perda diferencial está representada na Equação 2.9.

$$\bar{d} = \frac{1}{T} \sum_{i=1}^T d_i \quad (2.9)$$

Assumindo  $h \geq 1$ , a estatística do DM pode ser definida, conforme a Equação 2.10.

$$DM = \frac{\bar{d}}{\sqrt{[\gamma_0 + 2 \sum_{k=1}^{h-1} \gamma_k]/n}} \quad (2.10)$$

A hipótese nula do teste é representada por  $H_0 : E[d_t] = 0$ . É possível representar duas hipóteses alternativas, 1.  $H_a : E[d_t] > 0$ , modelo  $j$  apresenta melhor poder de predição do que o modelo  $i$ ; 2.  $H_a : E[d_t] < 0$ , modelo  $i$  apresenta melhor poder de predição do que o modelo  $j$ . As estatísticas do teste seguem a distribuição *student-T* com grau de liberdade  $(T - 1)$ .

#### 2.2.4.5 Model Confidence Set

A ferramenta matemática MCS, definida por Hansen et al. (HANSEN; LUNDE; NASON, 2011), realiza a comparação de um conjunto de modelos de predição e consegue avaliar a capacidade preditiva de cada um deles. Para a realização das análises, o MCS utiliza testes de equivalência ( $\delta_M$ ) e a aplicação de uma regra de eliminação de modelos ( $e_M$ ) que estão sendo avaliados. Desta forma, se o teste de equivalência for rejeitado, é considerado que os modelos avaliados não são igualmente eficientes. Então, é necessário aplicar a regra de eliminação, visando excluir o modelo que apresenta o pior desempenho. A regra de eliminação será repetida até que o teste de equivalência não seja rejeitado e os modelos aceitos são classificados como os mais eficientes. Desta forma, é possível garantir que com a aplicação do MCS, não é necessária a definição de um modelo *benchmark* e considera possíveis limitações dos dados (HANSEN; LUNDE; NASON, 2011).

A sequência de testes de equivalência aplicados pelo MCS objetiva determinar um conjunto  $M^*$  que contém objetos estatisticamente superiores aos objetos de  $M^0$  (conjunto que contém um número finito de objetos  $i = 1, 2, 3, \dots, m_0$ ), respeitando a hipótese nula e alternativa do teste (Equação 2.11 e Equação 2.12).

$$H_{0,M} : E(d_{ij,t}) = 0 \text{ para todo } i, j \in M \quad (2.11)$$

$$H_{A,M} : E(d_{ij,t}) \neq 0 \text{ para todo } i, j \in M \quad (2.12)$$

em que  $M \subset M^0$ .

A técnica utilizada para a implementação do MCS é a do *bootstrap* (WHITE, 2000), devido à sua praticidade e conveniência, quando existem alguns modelos preditivos a serem avaliados. O procedimento do MCS contempla basicamente às três etapas apresentadas a seguir ((HANSEN; LUNDE; NASON, 2011)):

- Etapa 1 — Definir  $M = M^0$ .
- Etapa 2 — Testar  $H_0, M$  usando  $\delta_M$  e o nível de significância discricionário  $\alpha$ .
- Etapa 3 — Se  $H_0, M$  não for rejeitado, definir  $\hat{M}_{1-\alpha}^*$ . Caso contrário, usar  $e_M$  para eliminar o objeto inferior de  $M$  e repetir o procedimento desde o Passo 1.

### 2.3 INDÚSTRIA DE RESINAS TERMOPLÁSTICAS

As macromoléculas do plástico são produzidas usando milhares de moléculas de monômeros (matéria-prima do plástico), denominadas polímeros. Os plásticos que apresentam macromoléculas formadas de cadeias lineares ou ramificadas e se mantêm unidas por forças intermoleculares, são definidos como termoplásticos (NUNES; SANTOS, 2015). Os polímeros termoplásticos (PET, Polietileno de Alta Densidade (PEAD), Policloreto de Vinila (PVC), Polietileno de Baixa Densidade (PEBD), Polipropileno (PP), Poliestireno (PS), dentre outros) estão presentes em diversos produtos da vida cotidiana (Tabela 3). Esses polímeros têm a propriedade de se tornarem flexíveis quando aquecidos, possibilitando a modelagem de produtos e endurecendo após o seu resfriamento.

Na Figura 3 é possível visualizar a cadeia produtiva das resinas termoplásticas. O processo é iniciado com a extração e refino da matéria-prima (exemplo: petróleo, fontes alternativas, dentre outras) representado pela refinaria. Na primeira geração, a matéria-prima é fracionada e transformada em petroquímicos básicos (exemplo: eteno,

Tabela 3 – Resinas termoplásticas mais populares e suas possíveis aplicações.

Resinas termoplásticas	Aplicações
Poliétileno tereftalato (PET)	Garrafas, embalagens e fibras têxteis.
Poliétileno de alta densidade (PEAD)	Frascos para detergente e óleos, sacolas de compras.
Policloreto de vinila (PVC)	Tubulações, brinquedos, mangueiras.
Poliétileno de baixa densidade (PEBD)	Sacos de lixo, filme para embalagens.
Polipropileno (PP)	Canudos, seringas, peças automotivas.
Poliestireno (PS)	Potes para sorvetes, bandejas, aparelhos de telefone.

**Fonte:** (PLASTIVIDA, 2020; ABIPLAST, 2019).

propeno, buteno, dentre outros). A segunda geração é caracterizada pela transformação de petroquímicos básicos em resinas termoplásticas (ver Tabela 3). A terceira geração é caracterizada pelo processo de transformação, pois são os produtores que fazem a aquisição das resinas termoplásticas e geram o produto final (exemplo: filmes, garrafas, sacolas, recipientes, dentre outros) (PLASTIVIDA, 2020; ABIPLAST, 2019).

Figura 3 – Cadeia produtiva dos plásticos.



**Fonte:** Adaptado de (PLASTIVIDA, 2020; ABIPLAST, 2019).

A Figura 4 mostra a forma granulada das resinas termoplásticas e como são disponibilizadas para os produtores da terceira geração.

Figura 4 – Forma granulada das resinas termoplásticas.

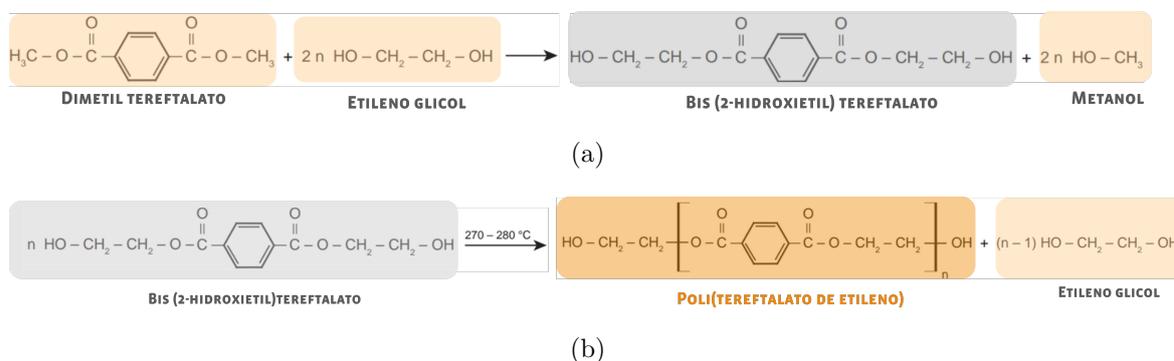


**Fonte:** (PLASTIVIDA, 2020; ABIPLAST, 2019).

### 2.3.1 Polietileno tereftalato

O PET é classificado como um poliéster saturado com alta massa molar (superior a 10.000 g/mol), resultado da reação de condensação entre o poliol e um ácido dibásico (NUNES; SANTOS, 2015; WHINFIELD, 1946). Na Figura 5 é possível verificar que há duas etapas para a obtenção do PET: (a) com a temperatura elevada ( $150 - 210^{\circ}C$ ) haverá uma transesterificação de ésteres dando origem ao bis(2-hidroxiethyl) tereftalato e o metanol; (b) em seguida, elevando ainda mais a temperatura ( $270 - 280^{\circ}C$ ) e variando a pressão o PET é obtido.

Figura 5 – Reação para obtenção do PET: (a) primeira etapa e (b) segunda etapa.



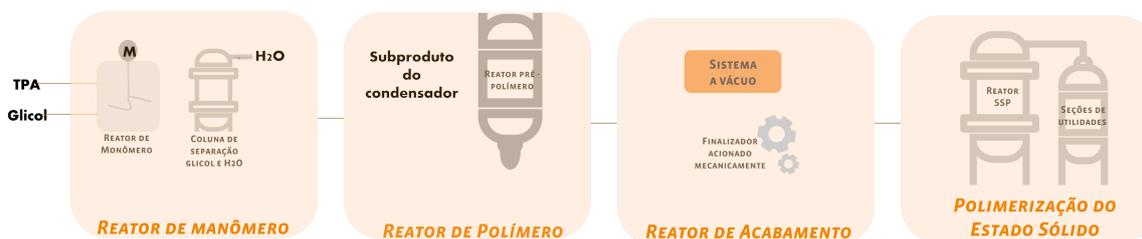
**Fonte:** Adaptada de (NUNES; SANTOS, 2015).

Historicamente, no cenário mundial o PET foi utilizado pela primeira vez em meados de 1945 (WHINFIELD, 1946), para aplicações têxteis. Apenas em 1970, iniciou sua trajetória no âmbito das embalagens. Foi utilizado no Brasil, pela primeira vez, no ano de 1988, no contexto da indústria têxtil (NUNES; SANTOS, 2015). Quando comparado com as resinas termoplásticas mais consumidas no Brasil, o PET representa 5,4% (ABIPLAST, 2019) do consumo, mas muitas são as suas aplicações. No cenário nacional, 71% do uso do PET é para as indústrias de embalagens (terceira geração) (MACDONALD, 2002).

### 2.3.2 Processos da indústria de resinas termoplásticas

O processo produtivo de uma indústria de resinas termoplásticas de produção de PET é representado basicamente por dois principais processos — Polimerização (POLI) e Polimerização do Estado Sólido (SSPOLI) (Figura 6). O processo de SSPOLI tem sua planta fabril precedida por uma planta do processo de POLI (MACDONALD, 2002). Nesta tese, serão considerados dados de vazão de produção relacionados ao processo SSPOLI.

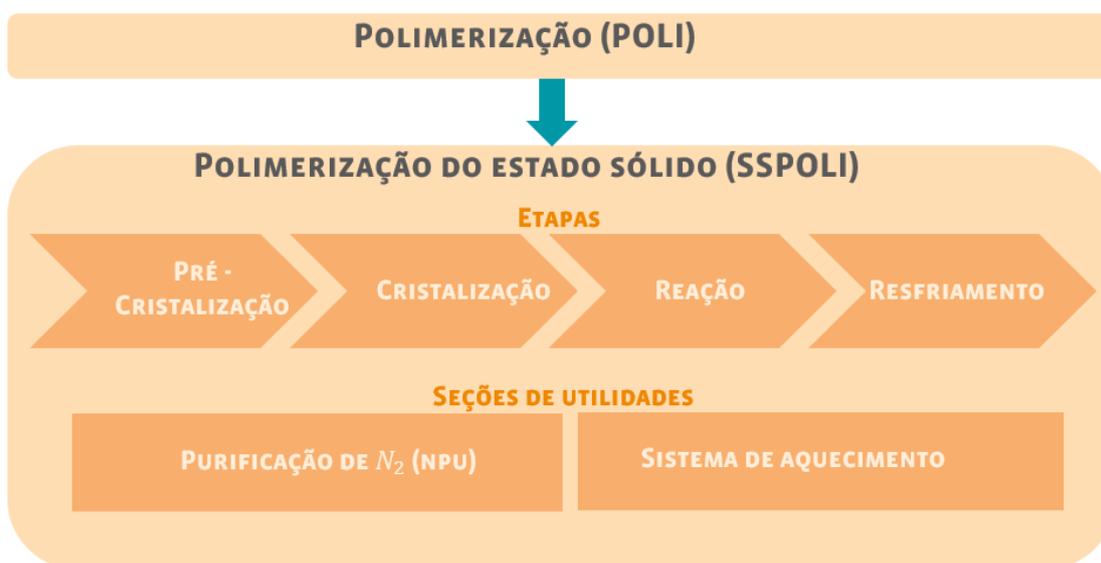
Figura 6 – Processo de fabricação do PET.



Fonte: Adaptado de (MACDONALD, 2002).

A planta SSPOLI normalmente contempla algumas etapas e algumas seções de utilidades. Na Figura 7 é possível verificar a representação de quatro etapas (pré-cristalização, cristalização, reação e resfriamento) e duas seções de utilidades (Unidade de Purificação de Nitrogênio (NPU) e sistema de aquecimento).

Figura 7 – Etapas do processo de SSPOLI.



Fonte: Adaptado de (EVANGELISTA, 2010).

A primeira etapa da SSPOLI é representada pela pré-cristalização, em que as partículas oriundas da *Molten State Polymerization* (MSP) são transferidas ao silo alimen-

---

tador da SSPOLI e as impurezas são eliminadas. As operações de carga e descarga entre silos da MSP e SSPOLI são controlados automaticamente, por um sistema de controle de nível.

A segunda etapa da SSPOLI é caracterizada pela cristalização. Nesta etapa, a temperatura da operação varia entre  $188 - 210^{\circ}\text{C}$ . A média da duração das etapas relacionadas à cristalização é de cerca de uma hora.

A terceira etapa da SSPOLI é representada pela reação, isto é, as partículas já cristalizadas são alimentadas no reator de polimerização, vaso cilíndrico vertical encamisado projetado para que a viscosidade intrínseca aumente uniformemente ao longo de seu comprimento até o nível desejado. Nesta etapa, a temperatura é controlada automaticamente, já a vazão para a camisa do reator é ajustada manualmente, por um operador. O tempo de residência médio nesta etapa é de aproximadamente doze horas.

## 2.4 GERENCIAMENTO DE ENERGIA ELÉTRICA INDUSTRIAL

Para a gestão energética de uma indústria ser considerada eficaz é preciso ter uma medição sistemática e respectivo monitoramento, pois não é possível gerenciar o que não é medido e também é necessário realizar a análise e avaliação dos resultados, possibilitando a tomada de decisões sobre o desempenho energético. O processo de monitoramento dos indicadores é fundamental para a avaliação dos desvios entre os valores previstos e os realizados. Os resultados da eficiência energética da indústria, quando divulgados, podem ter impacto no mercado, junto aos acionistas, clientes, fornecedores, empregados e sociedade (FOSSA; SGARBI, 2017; VIKHOREV; GREENOUGH; BROWN, 2013).

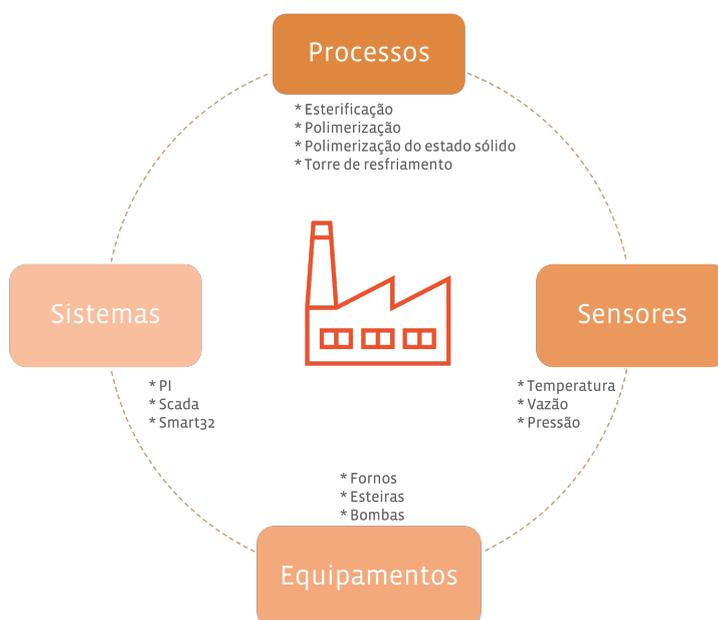
Para a implementação de um sistema de gerenciamento de energia elétrica industrial, alguns módulos precisam ser definidos: armazenamento (SHROUF; MIRAGLIOTTA, 2015), simulação (SHROUF; MIRAGLIOTTA, 2015), otimização (SHROUF; MIRAGLIOTTA, 2015), e visualização (VIKHOREV; GREENOUGH; BROWN, 2013). Mas, para alcançar a eficiência energética na fabricação, não basta realizar medição, e monitoramento, geração de relatório. É preciso incorporar técnicas mais sofisticadas de medição, análise e controle (ZAMPOU et al., 2014). Nesta tese, serão apresentados al-

guns desses módulos como parte do *framework* para gerenciamento de energia em uma indústria de resinas termoplásticas e serão propostos módulos baseados em IA e em algoritmo de otimização (Capítulo 4).

### 2.4.1 Cenário industrial

As indústrias de resinas termoplásticas produzem a matéria-prima para os produtos baseados no PET, PEAD, PVC, PEBD, dentre outros (PLASTIVIDA, 2020; ABIPLAST, 2019). A Figura 8 apresenta uma visão geral do cenário dessas indústrias. É possível destacar quatro categorias que representam esse ecossistema industrial: processos, sensores, equipamentos e sistemas. Os processos industriais são representados pelas etapas necessárias para o desenvolvimento do produto (esterificação, POLI, SSPOLI, resfriamento, dentre outros). Os sensores (sensor de temperatura, sensor de vazão, sensor de pressão, dentre outros) e equipamentos (fornos, esteiras, bombas, dentre outros) são dispositivos espalhados pela planta industrial que viabilizam a execução dos processos industriais. Os sistemas industriais são representados por alguns *softwares* que auxiliarão a visualização de dados, atuação remota e configuração de parâmetros de processos, como: *Smart 32* (GESTAL, 2019b), *Exaquantum* (YOKOGAWA, 2000), *PI System* (OSI-SOFT, 1980), dentre outros. Os sistemas citados foram utilizados no estudo de caso desta tese, por isso serão detalhados adiante.

Figura 8 – Visão do cenário industrial.



**Fonte:** O autor.

O *Smart 32* é um *software* de controle e gerenciamento de energia elétrica e utilidades; normalmente é instalado no contexto industrial e predial. Ele permite integrar dados oriundos de medidores de energia de diferentes fabricantes, pois a solução é formada pela unidade de controle e unidades concentradoras (GESTAL, 2019b). Recorrendo ao acesso ao banco de dados da aplicação do *Smart 32*, é possível acessar os dados do sistema para integrá-lo em outras aplicações.

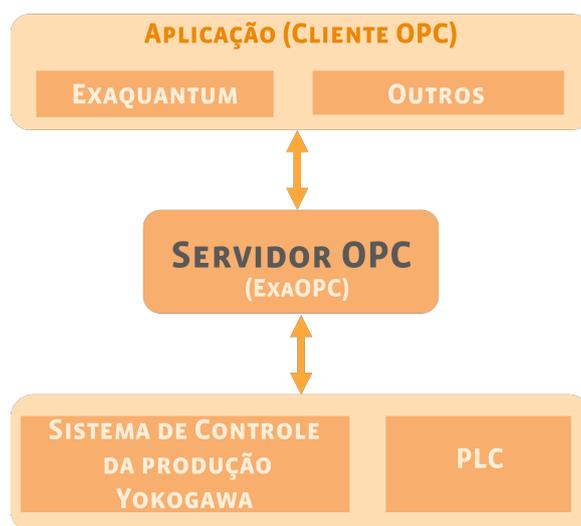
O *Exaquantum* é um *Project Information Management System* (PIMS), isto é, um *software* de gestão para controle de processos industriais; é um produto da empresa Yokogawa, bastante robusto e capaz de integrar dados de diferentes dispositivos da planta industrial (sensores e equipamentos).

O *Openness, Productivity, Connectivity* (OPC) é um padrão de comunicação para acesso aos diferentes dados do processo industrial. O *OPC Foundation* foi estabelecido em 1996, com o objetivo de promover a Neo Revolução Industrial, por meio da

construção de um sistema aberto capaz de interagir com diferentes fabricantes. Provê a interação dos dados entre o sistema de controle de processo e o sistema de execução industrial. Garante que os dados possam ser coletados e utilizados em *software* industriais. A *Yokogawa* é membro da *OPC Foundation Exaquantum*; assim a comunicação é compatível com o padrão OPC, que garante segurança e reduz falhas para troca de dados (YOKOGAWA, 2000).

Na Figura 9 é possível observar a arquitetura do sistema da *Yokogawa*. O cliente OPC normalmente se comunica com o servidor OPC através da comunicação *ethernet*. Já o servidor OPC se comunica com o *Programmable Logic Controller* (PLC) e com o sistema de controle de produção *Yokogawa* utilizando o barramento de controle.

Figura 9 – Comunicação entre o cliente e servidor OPC.



Fonte: Adaptado de (YOKOGAWA, 2000).

## 2.4.2 ISO 50001

O gerenciamento de energia, conscientização, treinamentos e implantação são algumas práticas adotadas por indústrias de diferentes países, visando aumentar IDE (SOLA; MOTA, 2015). A implementação da ISO 50001 vem contribuindo para a melhoria da eficiência das indústrias que aderiram aos requisitos de uma boa gestão energética.

A norma 50001 define alguns requisitos para o uso e consumo de energia (medição, documentação, projetos e processos que contribuam para o desempenho energético) com o intuito de estabelecer, implementar, e garantir a manutenção e melhoria de um Sistema de Gestão de Energia (SGE). A revisão energética é um desses requisitos e, para ser desenvolvida, é preciso realizar a predição do uso e consumo de energia; definir o desempenho energético da organização; determinar as instalações, processos, e equipamentos que afetam o uso e o consumo de energia; e definir variáveis relevantes que afetam o consumo de energia (ABNT, 2018).

Na Figura 10 é possível observar como o desempenho energético pode ser representado.

Figura 10 – Representação do desempenho energético.



**Fonte:** (ABNT, 2018).

### 2.4.3 Benefícios do gerenciamento de energia industrial

Na revisão sistemática realizada por Fadi e Giovanni (SHROUF; MIRAGLIOTTA, 2015) foram extraídos os principais benefícios oriundos do gerenciamento de energia elétrica baseado em *Internet of Things* (IoT), no contexto industrial. Na Tabela 4 é possível analisar cada um desses benefícios e as práticas utilizadas com uso da tecnologia IoT.

Tabela 4 – Benefícios do gerenciamento de energia na indústria.

Benefícios	Práticas
Identificação de fontes de desperdícios de energia.	Comparar o consumo de energia: para o mesmo processo em ambientes diferentes; com o nível de produção.
Aprimoramento da programação da produção.	Integração dos dados de consumo e de processo. Analisar o consumo de energia individualizado em diferentes configurações.
Redução do custo com energia elétrica.	Identificar o horário de pico e reduzir o consumo neste horário. Compra de energia em diferentes fornecedores.
Gestão de manutenção eficiente.	Manutenção baseada no padrão de uso de energia.
Melhoramento da reputação ambiental.	Medir e reduzir a emissão de $CO_2$ .

**Fonte:** (SHROUF; MIRAGLIOTTA, 2015).

### 3 TRABALHOS RELACIONADOS

A pesquisa se iniciou com o estudo dos trabalhos relacionados ao tema proposto, tornando possível conhecer o que já foi desenvolvido e apresentar as principais contribuições. A estratégia utilizada foi realizar o estudo no âmbito da STLF (Seção 3.1) na indústria e sistema de gerenciamento de energia elétrica na indústria (Seção 3.2).

#### 3.1 PREDIÇÃO DE CARGA DE CURTO PRAZO NA INDÚSTRIA

A STLF, usando aprendizado profundo e aprendizado de máquina, foi analisada a partir de diferentes perspectivas. Por exemplo, existe uma literatura bem estabelecida sobre o consumo de energia do lado da oferta e predição de demanda usando aprendizado profundo da perspectiva da gestão e otimização de sistemas de energia e redes de eletricidade. O estado da arte inclui estudos usando *Deep Neural Network* (DNN) (RYU; NOH; KIM, 2017), *Deep Belief Network* (DBN) (QIU et al., 2017), *Convolutional Neural Network* (CNNs) (DONG; QIAN; HUANG, 2017), Autoencoder e LSTM (GENSLER et al., 2016), SVM e *Random Forest* (LI; ZHANG; XIANG, 2019), dentre outros. O foco da pesquisa realizada é o lado da demanda (indústria). A STLF para as concessionárias de energia tem uma motivação e contexto fundamentalmente diferentes, quando comparada com os interesses das indústrias, uma vez que estas visam a maximização do lucro, eficiências operacionais e outros objetivos de negócios.

Vários estudos se debruçaram sobre a utilização de aprendizado profundo para prever o consumo de energia de diferentes tipos de consumidores: residenciais (KONG et al., 2017; SHI; XU; LI, 2017; GÜNGÖR; AKŞANLI; AYDOĞAN, 2019), comerciais (PETRI et al., 2014; XYPOLYTOU; MEISEL; SAUTER, 2017) e industriais (AZADEH; GHADERI; SOHRABKHANI, 2008; OLANREWAJU, 2019). Os casos de uso residencial e comercial têm padrões de consumo de energia fundamentalmente diferentes dos da indústria, em termos de tempo de tomada de decisão, padrões de código de construção, densidade populacional, projeto de construção e resposta ao clima regional, dentre outros (HOBBY; TUCCI, 2011). Conforme discutido no Capítulo 1, o setor industrial faz

---

uso intensivo de energia e apresenta um perfil de consumo de energia significativamente diferente de outros consumidores (residencial, comercial, dentre outros). Em particular para o setor industrial, há uma tendência do perfil do consumo de energia relacionada ao processo, e não a mudanças climáticas, e o gerenciamento de energia é a capacidade central de seus negócios. Como a produção é fundamental para a indústria, a demanda por energia é derivada do planejamento da produção e da predição e otimização de energia com base nas demandas predominantes de produção (HADERA et al., 2016).

Ryu et al. (RYU; NOH; KIM, 2017) exploraram o STLF do lado da demanda, para quarenta clientes industriais. Usando dados oriundos de uma concessionária coreana, os autores propuseram uma estrutura STLF baseada em DNN, utilizando categoria da indústria, padrões temporais, localização e condições climáticas como variáveis do modelo. Uma análise comparativa foi realizada com três diferentes técnicas de predição — *Shallow Neural Network* (SNN), *Double Seasonal Holt–Winters* (DSHW) e ARIMA — por meio da análise de duas métricas (MAPE e *Relative Root Mean Square Error* (RRMSE)). Os resultados sugerem que o modelo STLF, baseado em DNN, obteve o melhor desempenho quando comparado aos outros modelos com MAPE inferior (2,19%) e RRMSE inferior (2,76%).

Mawson e Hughes (MAWSON; HUGHES, 2020) estudaram o uso de *Deep Feed Forward Neural Networks* (DFNN) e *Deep Recurrent Neural Networks* (DRNN) para STLF, em uma indústria de médio porte. As entradas para os modelos DNNs incluíam condições climáticas e programações de usinagem. Os resultados sugerem que ambos os modelos tiveram bom desempenho, mas o DRNN superou o DFNN para previsões de consumo de energia de edifícios, alcançando uma precisão de 96,8%, em comparação aos 92,4% do DFNN. O foco adotado pelos autores foi otimizar os processos de *Heating, Ventilation, and Air Conditioning* (HVAC). O impacto do processo de produção não constituiu um foco, embora os dados de energia da caldeira, energia de resfriamento e programação da máquina tenham sido considerados. Diferentemente desta pesquisa de doutorado, o consumo de energia relacionado ao processo específico não foi considerado e o foco não foi a fabricação com uso intensivo de energia. Além disso, os autores usaram dados simulados, enquanto nesta pesquisa foi utilizado um

---

conjunto de dados reais para treinar e testar os modelos.

Em contraste com os estudos realizados por Ryu et al. (RYU; NOH; KIM, 2017) e Mawson e Hughes (MAWSON; HUGHES, 2020), o estudo de Chen et al. (CHEN et al., 2018) utilizaram o DNN para STLF, em uma indústria de alto consumo de energia. Estes autores desenvolveram um modelo de previsão do consumo de energia para um processo específico de um forno elétrico a arco. O desempenho do modelo DNN foi comparado com diferentes modelos (*Linear Regression* (LR), SVM e *Decision Tree* (DT)), utilizando a análise do coeficiente de correlação dos modelos e do MAE. O DNN proposto superou os outros modelos com o maior índice de correlação, em 0,854, e o menor MAE, em 1,5%. Embora os resultados do trabalho estejam mais próximos dos encontrados nesta tese, os autores se concentraram em um único processo e não buscaram calcular o consumo geral de energia da planta industrial. Além do mais, embora identifiquem o potencial do aprendizado profundo em relação às abordagens estatísticas e de aprendizado de máquina tradicional, os autores não avaliaram o desempenho relativo em comparação com outras técnicas de aprendizado profundo.

Yeom e Choi (YEOM; CHOI, 2018) descrevem uma plataforma chamada, a E-IoT, que coleta uma ampla gama de dados (mais de 1.556 variáveis em um dos processos analisados, dentre três existentes) em uma indústria coreana. A partir dos dados coletados pela E-IoT, é utilizada uma técnica, *Least Absolute Shrinkage and Selection Operator* (Lasso), com base no aprendizado de máquina, a fim de extrair variáveis relevantes para o STLF em nível da planta industrial. Após a definição das variáveis relevantes, o modelo LSTM é aplicado para prever o consumo de energia. Esse modelo proposto alcançou um MAE de 0,07 e uma precisão de 79%. O trabalho de Yeom e Choi é carente de detalhes. Por exemplo, não está claro se a planta de fabricação é de alto consumo de energia; também não está claro por que apenas o primeiro estágio do processo de manufatura foi usado e quantos outros processos estão envolvidos. Além disso, nenhum detalhe é fornecido sobre como a configuração do modelo LSTM foi selecionada, além de não existir comparação com as técnicas existentes ou outros modelos de aprendizado profundo.

Li et al. (LI; ZHANG; XIANG, 2019) investigaram a STLF para clientes industriais, na

---

China, utilizando dados oriundos de uma indústria de cabos e uma indústria de lítio, localizadas em Chongqing. Os autores propõem dois modelos de predição de consumo de energia de curto prazo (20 dias), usando SVM e *Random Forest*. Seu trabalho utilizou a base de dados do histórico de consumo de energia, dados sazonais (feriados), dados do custo de metais não ferrosos e consumo de matéria-prima, relacionados a cada indústria. Ambos os modelos desenvolvidos previram com precisão o consumo de energia elétrica. Os valores da MAPE para o modelo SVM e *Random Forest* foram semelhantes para cada indústria, 5% para a indústria de cabos e 2% para a indústria de lítio. Para aumentar a precisão, o estudo destacou a necessidade do uso de variáveis adicionais específicas da indústria e de um conjunto de dados relativos a um período maior do que dois anos.

Como pôde ser visto na Figura 11, há uma escassez de pesquisas sobre STLF do lado da demanda para manufatura com uso intensivo de energia utilizando aprendizado profundo e modelos de aprendizado de máquina. A tomada de decisões para empresas de serviços públicos tem pouco em comum com os fabricantes. Da mesma forma, STLF para uso residencial e comercial tem pouca relevância para casos de uso industrial e, dentro do consumo de energia industrial, a manufatura com uso intensivo de energia é idiossincrática. Os poucos estudos semelhantes carecem de detalhes sobre o consumo de energia da indústria, agregam todo o consumo de energia ou se concentram em um único processo. Além disso, quando os modelos de aprendizado profundo e de aprendizado de máquina propostos foram comparados, eles foram avaliados apenas em comparação com as técnicas tradicionais ou em outros modelos de aprendizado profundo, ou não foram avaliados. Esta tese de doutorado contempla essas deficiências.

Figura 11 – Características dos trabalhos relacionados referente a temática de predição.

#	TRABALHOS RELACIONADOS	ANÁLISE COMPARATIVA		DADOS		PERFIL DA INDÚSTRIA
		APRENDIZADO PROFUNDO	APRENDIZADO DE MÁQUINA	REAIS	BRASIL	DE RESINAS TERMOPLÁSTICAS
1	Ryu, 2017	✓	×	✓	×	×
2	Chen et al., 2018	✓	✓	✓	×	×
3	Yeom, Choi, 2018	✓	×	✓	×	×
4	Li et al., 2019	×	✓	✓	×	×
5	Mawson e Hughes, 2020	✓	×	×	×	×
	Esta pesquisa	✓	✓	✓	✓	✓

Fonte: O autor.

### 3.2 SISTEMA DE GERENCIAMENTO DE ENERGIA ELÉTRICA NA INDÚSTRIA

O uso de sistemas de gerenciamento de energia elétrica em contextos industriais é um assunto de grande interesse, pois provê a redução do custo neste setor, bem como o melhor aproveitamento dos recursos. Existem, na literatura, pesquisas que aprofundam esse tema e apresentam algumas soluções.

Vikhorev et al. (VIKHOREV; GREENOUGH; BROWN, 2013) apresentaram um novo paradigma estrutural para o gerenciamento avançado de energia elétrica em tempo real, nas indústrias. Além da aquisição de dados do consumo de energia, esse *framework* realiza o processamento e correlações de dados (metadados sobre exatidão e precisão, datas de manutenção, dados climáticos, tipo de combustível) para a obtenção de informações significativas da planta industrial. O *framework* provê padrão de energia, algoritmo para análise de fluxos de dados em tempo real e é capaz de oferecer informações de suporte à decisão para aumentar a eficiência energética e indica falhas na produção. Diferente do que é proposto nesta tese, o trabalho realizado por Vikhorev et al. não apresenta uma análise para o consumo de energia total, nem inclui processos de produção, nem uma exploração do potencial de economia de energia.

---

Chen et al. (CHEN et al., 2018) propõem um *framework* para monitoramento de energia industrial baseado em IoT. A pesquisa fez um estudo de caso em uma oficina de usinagem de uma indústria e alcançou melhorias na eficiência energética. O sistema proposto é composto por quatro camadas — aquisição de dados, transmissão de dados, processamento de dados e camada de aplicação. Com a aplicação do *framework* foi possível garantir a redução do consumo e o custo de energia, bem como gerenciar, de forma efetiva, o processo de usinagem industrial.

Zampou et al. (ZAMPOU et al., 2014) apresentam um *framework* para gerenciamento de energia e suporte à decisão, uma solução de sistema da informação com consciência energética. A arquitetura conceitual do *framework* consiste basicamente no módulo de gestão e controle do processo de produção, módulo de planejamento e otimização da produção, módulo de negociação de emissão de carbono e módulo de captura de dados de energia.

Sistemas industriais que oferecem a funcionalidade de gerenciamento de energia elétrica que está disponível comercialmente conseguem realizar notificações, enviar alertas e criar previsões de consumo (GESTAL, 2019a; SEICA, 2019; BREBNER, 2012; ESIGHT ENERGY, 2019; NANSEN, 2019). Mas, diferente do *framework* proposto nesta tese, não realizam a integração de dados de consumo de energia com dados referentes aos processos de produção, não apresentam a tendência do desempenho energético, nem histórico relacionado com a vazão de produção. Na maioria das vezes, essas soluções contemplam principalmente o gerenciamento de medidores, fazendo uso de geração de relatórios de monitoramento de dados de energia.

Para facilitar a visualização e comparação das características dos trabalhos relacionados referente a temática de gerenciamento de energia e serviram como referencial teórico para esta pesquisa foi significativo construir a Tabela 12.

Figura 12 – Características dos trabalhos relacionados referente a temática de gerenciamento de energia.

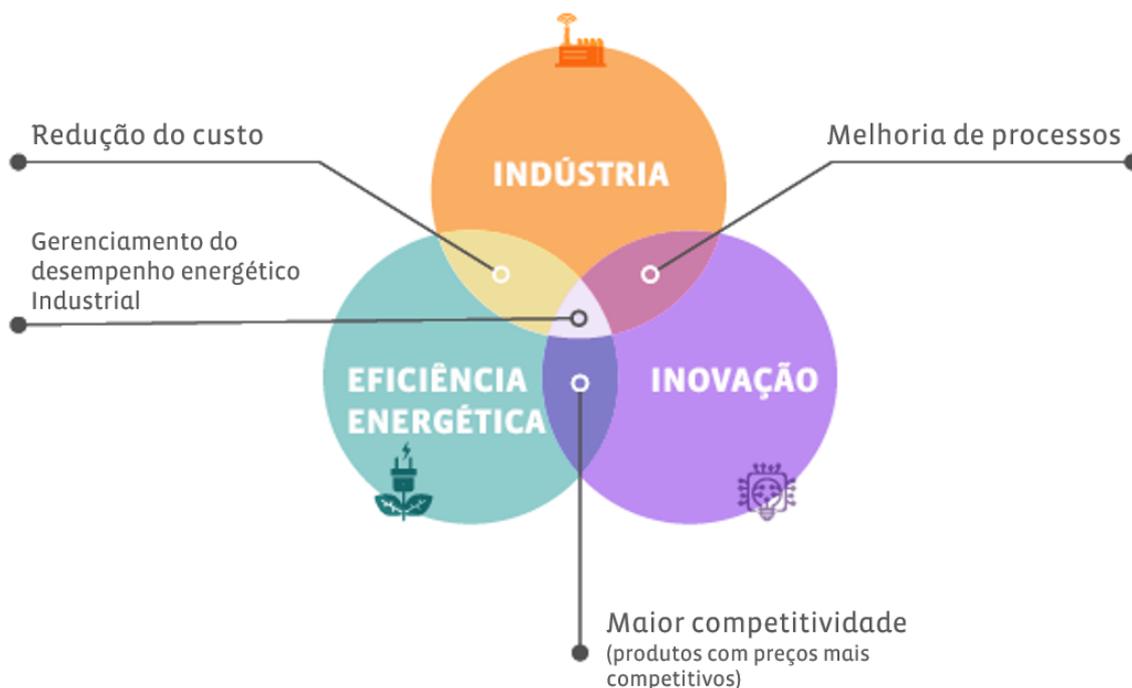
#	TRABALHOS RELACIONADOS	MONITORAMENTO DA IDE	INTEGRAÇÃO DE VARIÁVEIS	PREDIÇÃO	ESCALONAMENTO	VIABILIDADE
1	VIKHOREV; GREENOUGH; BROWN, 2013	✓	✓	~	~	~
2	Zampou et al, 2014	~	✓	×	~	×
3	Chen et al, 2018	✓	✓	×	×	×
4	Sistemas industriais	~	×	✓	~	~
	Esta pesquisa					

**Fonte:** O autor.

## 4 FRAMEWORK PARA GERENCIAMENTO DE ENERGIA ELÉTRICA NA INDÚSTRIA

Esta tese está fundamentada em três pilares: indústria; inovação, advinda da indústria 4.0; e eficiência energética. Na Figura 13 é possível observar que a interseção entre esses pilares resulta em uma indústria capaz de gerenciar o desempenho energético, bem como de analisar dados e tomar decisões mais precisas para prover a melhoria de processos industriais, além de mitigar os elevados gastos com energia elétrica, dispondo, assim, de produtos com preços mais competitivos.

Figura 13 – Pilares do *framework* desenvolvido nesta tese.



**Fonte:** O autor.

Neste capítulo são apresentados e detalhados os estudos necessários para o desenvolvimento do *framework* para gerenciamento de energia elétrica. Na Seção 4.1 é oferecida

---

uma visão geral do *framework* proposto; e na Seção 4.2 são especificados os módulos que fazem parte do *framework* para gerenciamento de energia elétrica na indústria.

#### 4.1 VISÃO GERAL DO *FRAMEWORK*

O consumo de energia elétrica e a escassez de informações que possibilitem aos gestores tomar decisões são alguns problemas que impactam diretamente na eficiência da produção industrial de resinas termoplásticas. É sabido que o ambiente industrial gera um elevado volume de dados, por meio de diferentes dispositivos e sistemas. Para que esses dados, que estão na sua forma bruta, sejam transformados em informações para possibilitar a geração de conhecimento, é preciso que sejam processados.

O *framework* para gerenciamento de energia elétrica em uma indústria de resinas termoplásticas visa fornecer essas informações, utilizando a interdependência entre a predição, escalonamento e viabilidade. Com esta configuração, é possível contribuir com o planejamento da produção e manutenção, análise do desempenho industrial, e aumento da eficiência energética em indústrias dessa natureza.

Os dados relacionados às variáveis elétricas (exemplo: tensão, corrente, potência, dentre outros) e às variáveis de processo (exemplo: vazão de produção, temperatura, pressão, dentre outros) — oriundas dos sensores e medidores de energia —, alimentam os modelos de IA para a predição, sendo possível realizar o monitoramento e a análise do desempenho energético, baseado no indicador de desempenho energético mensal. Desta forma, é possível identificar se o processo de produção está satisfatório e se há algum equipamento sendo utilizado inadequadamente (detecção de anomalias, isto é, um sistema de diagnóstico), dado que o monitoramento em tempo real, comparado com a curva de predição mensal, fornecerá de forma gráfica essa informação.

O estudo de viabilidade técnica e econômica de materiais, equipamentos e sistemas visa verificar se é válida a inserção de novas tecnologias em processos industriais específicos. A viabilidade pode ser motivada pelo comportamento das curvas de predição. Essa troca de informação entre a predição e a viabilidade é fundamental para a obtenção de *insight* de melhoria na eficiência da produção, pois serve como entrada dos módulos. Após a validação da viabilidade técnica, a tecnologia será inserida na

planta industrial, alterando, assim, o consumo e impactando diretamente na predição e escalonamento.

O escalonamento está diretamente relacionado à demanda e prazo de produção. Logo, por intermédio de uma ferramenta matemática baseada em algoritmo de otimização linear, será possível avaliar qual a faixa de vazão de produção mais eficiente e, com os dados oriundos da predição e viabilidade, será possível indicar as melhores combinações para o tempo que cada faixa de vazão de produção será utilizada. No escalonamento é necessário garantir o atendimento dos clientes, bem como uma produção mais eficiente.

A principal contribuição desta pesquisa está na definição dos módulos de predição, de escalonamento e de viabilidade. Na Figura 14 é possível verificar que esses módulos não estão trabalhando de forma individualizada, há uma colaboração entre eles. Com essa colaboração foi possível realizar melhorias nos processos, aprimorar o planejamento de produção reduzir o custo com energia elétrica no contexto da indústria de resinas termoplásticas.

Na predição é obtido o monitoramento das variáveis impactantes do desempenho energético (consumo de energia em *kWh* e vazão de produção em *ton.*), disponibilizando informações para tomada de decisão e apoio no planejamento da produção. A curva que representa o histórico do consumo de energia, bem com a curva de predição são exemplos de informações disponibilizada pelo módulo de predição e que auxiliam a análise de diagnósticos e tomada de decisão.

No escalonamento da vazão buscou-se identificar de níveis de vazão mais eficientes e também um conjunto de informações de apoio à decisão. Este módulo possibilitam o equilíbrio entre o atendimento da demanda dos clientes e os resultados de produções industriais.

A viabilidade está relacionada com a melhoria da eficiência energética, por meio da avaliação de novas tecnologias (equipamentos e materiais) que podem subsidiar a obtenção de melhores resultados no consumo e na produção. No entanto, é fundamental o estudo de viabilidade para verificar o tempo de retorno do investimento e sua viabilidade técnica.

O fluxo de informações entre os módulos de predição, escalonamento e viabilidade faz com que haja uma interdependência entre eles.

Figura 14 – Interação entre os modelos de predição, escalonamento e viabilidade.



Fonte: O autor.

O objetivo do *framework* para gerenciamento de energia elétrica desenvolvido nesta tese é subsidiar a análise de dados e a tomada de decisão nas indústrias de resinas termoplásticas. O monitoramento setorizado e o gerenciamento do desempenho energético contribuirão para a obtenção da certificação ISO 50001 e sua manutenção nessas indústrias.

O *framework* concentra dados de natureza diferente — variáveis elétricas e variáveis de processos. Ele utiliza recursos das novas tecnologias — IA, *big data*, IoT — e disponibiliza uma *interface web* para a visualização das informações. Visando facilitar a integração com outras aplicações e sistemas, o *framework* proposto dispõe de uma *Application Programming Interface* (API) REST. Desta forma, será possível que outras aplicações integrem seus módulos ao *framework*.

Para que o *framework* seja implantado em uma indústria de resinas termoplásticas, é necessária a instalação de medidores em pontos estratégicos da planta, visando obter o monitoramento setorizado, a identificação das variáveis de processos que, combinadas, apontem inconsistências, aumentando a confiabilidade e eficiência no processo analisado.

---

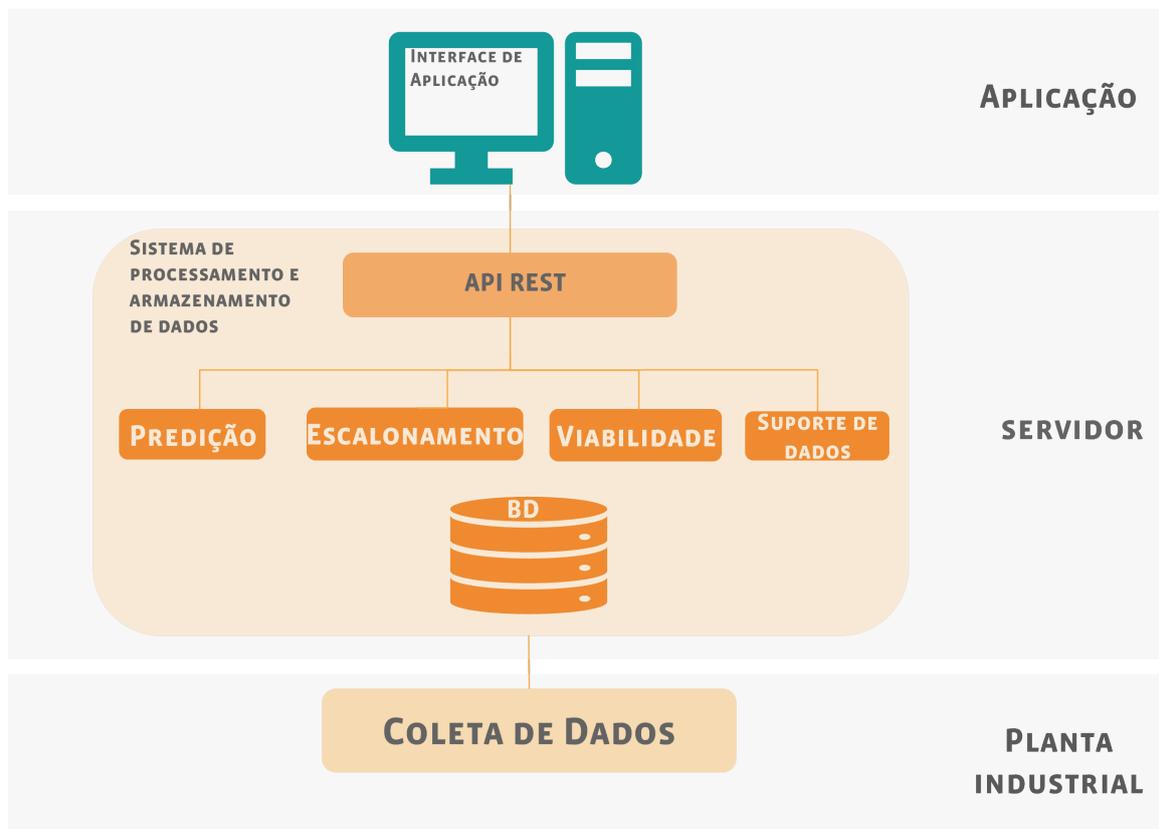
## 4.2 FRAMEWORK PARA GERENCIAMENTO DE ENERGIA

A implementação do *framework* visa prover a análise de dados e tomada de decisão na indústria 4.0, com a integração dos processos produtivos com o comportamento elétrico da indústria de resinas termoplásticas. Desta forma, para que o *framework* atenda o objetivo proposto nesta pesquisa, alguns requisitos funcionais foram definidos, baseados na demanda real, de uma empresa de resinas termoplásticas; bem como referências de trabalhos relacionados. Segue abaixo:

- **Requisitos funcionais:**
  - Integrar dados de variáveis de naturezas diferentes;
  - Monitorar as variáveis impactantes no desempenho energético;
  - Possibilitar coleta de dados de consumo de energia elétrica de forma geral e setorizada;
  - Apresentar o comportamento da relação entre a vazão de produção e consumo de energia elétrica;
  - Prover mecanismo para redução de custo no setor industrial.

Para que todos os requisitos sejam contemplados, alguns módulos foram propostos para serem integrados ao *framework* (Figura 15). O *framework* é formado por três módulos que interagem entre si, sendo nomeados como: *coleta de dados*, *sistema de processamento e armazenamento de dados*, e *interface de aplicação*.

Figura 15 – Representação do *framework*.



Fonte: O autor.

#### 4.2.1 Coleta de dados

A *coleta de dados* possibilita a comunicação entre o *framework* e o meio físico, com duas principais finalidades: alimentar o *framework* por meio da coleta de dados dos diferentes sistemas e/ou subsistemas de processos industriais; atuação manual nesses processos, para realização de melhorias.

Este módulo, *coleta de dados*, é composto por diferentes elementos (dispositivos IoT, máquinas, equipamentos, *gateways*, servidores). Na Figura 16 é possível observar como estão localizados e conectados cada um desses elementos.

Figura 16 – Elementos que compõem o *módulo de coleta de dados*.



Fonte: O autor.

#### 4.2.2 Sistema de processamento e armazenamento de dados

A etapa de processamento dos dados do *framework* é responsabilidade do *sistema de processamento e armazenamento de dados*. Este módulo irá processar os dados oriundos dos módulos subsequentes (*módulo de coleta de dados*) e irá transformá-los em informações úteis aos usuários, facilitando, assim, a tomada de decisão, além de se responsabilizar pelo armazenamento de todos os dados.

O *sistema de processamento e armazenamento de dados* é baseado na: *predição, escalonamento, viabilidade, suporte de dados, e armazenamento*. Eles serão responsáveis por diferentes funcionalidades. Para facilitar o acesso ao *sistema de processamento e armazenamento de dados*, eles serão representados como microserviços e terão uma API REST.

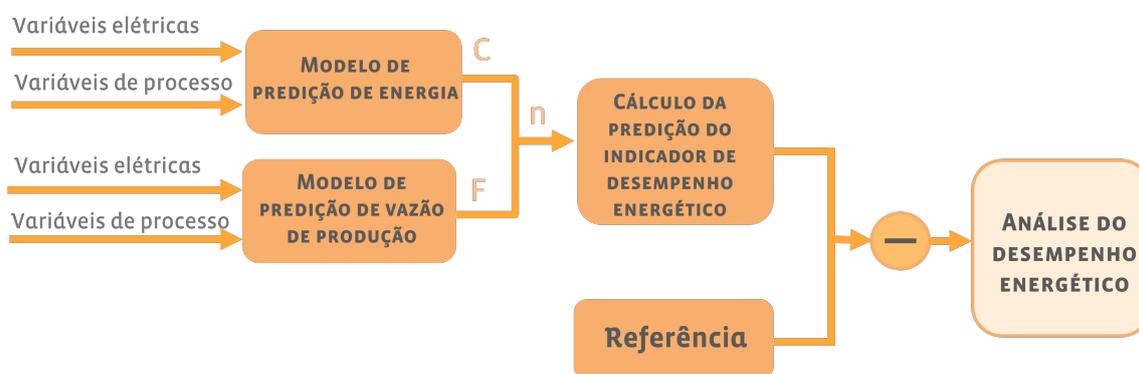
##### 4.2.2.1 Predição

O *módulo de predição* é responsável pela análise do desempenho energético, através da predição do consumo de energia elétrica e da vazão de produção. Esse módulo é baseado em IA. Com a criação e implementação desse módulo, é possível identificar previamente o comportamento da produção da indústria *versus* consumo de energia e realizar ações que possam reparar algum resultado

indesejado proativamente. Diariamente, a análise é atualizada, para verificar o impacto da ação tomada no desempenho energético.

O modelo de análise do desempenho energético utiliza dados de dois outros modelos — modelo de previsão do consumo de energia e modelo de previsão do indicador de desempenho energético. A análise referente à curva de previsão do consumo de energia é definida por um número que representa a diferença entre a previsão do indicador de desempenho referente ao mês e o indicador de desempenho de referência (índice a ser atingido, definido pela indústria). Na Figura 17 é possível verificar as conexões entre os modelos.

Figura 17 – Modelo de análise do desempenho energético da indústria.



Fonte: O autor.

Como foi mencionando, o valor da análise do desempenho energético é alterado diariamente e, à medida que os dias vão passando, são considerados os dados reais das variáveis elétricas e variáveis de processo. Sendo assim, no final de um período a análise está relacionada, apenas, com os dados reais.

No *módulo interface de aplicação* (detalhado na Seção 4.2.3) será possível monitorar a curva do consumo de energia por meio de uma representação gráfica. E, com a análise representada quantitativamente, será possível identificar se a curva está coerente com o planejamento energético da indústria.

Para a implementação do *módulo de previsão*, foi realizado um estudo da eficácia dos modelos de previsão no setor industrial, especificamente para a indústria

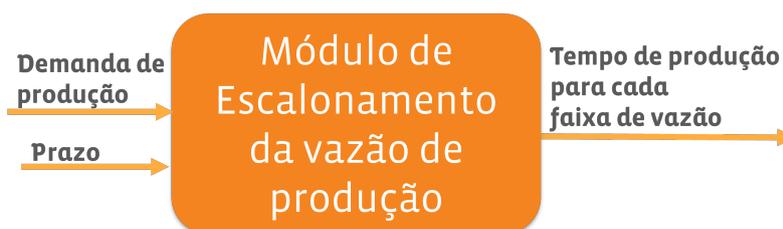
de resinas termoplásticas, contribuindo, assim com a comunidade científica, por ser uma das primeiras pesquisas nessa área. Com o monitoramento dos dados futuros originados desse módulo, será possível prever falhas, gerar alertas, ter ganhos com uma programação da produção, além de subsidiar a implantação e/ou a manutenção da certificação ISO 50001.

#### 4.2.2.2 Escalonamento

O atendimento à demanda de produção pode ser realizado para alcançar o maior nível de eficiência possível, tendo em vista que alguns fatores interferem no resultado da produção, tais como: consumo de energia, faixa de vazão de produção, interrupções por falhas no processo, dentre outros. Desta forma, foi definido o *módulo de escalonamento* (Figura 18), que visa aumentar o nível de eficiência no processo produtivo sem a necessidade de realizar investimentos, como compras de equipamentos e/ou insumos. Assim, através de um modelo baseado em otimização linear o gestor de produção terá acesso à informação que auxiliará na tomada de decisão resultando em um processo mais eficiente.

O prazo (tempo limite para produção —  $P_L$ ) e a demanda de produção (volume a ser produzido —  $V_T$ ) são dois fatores fundamentais para a definição do planejamento da produção, ou seja, definição da faixa de vazão e o tempo de utilização.

Figura 18 – Escalonamento da vazão de produção.



Fonte: O autor.

Para ilustrar, suponha que uma indústria terá que produzir 30.000 toneladas no período de um mês. Com o *módulo de escalonamento* será possível informar

ao usuário opções de combinações de vazão otimizadas a serem produzidas por dia. No exemplo dado, suponha que as combinações das vazões sejam a saída desse módulo (Tabela 5).

O *módulo de escalonamento* define o conjunto de valores do tempo de produção por faixa de vazão que conduza a um menor consumo de energia elétrica total. Inicialmente, foi feita a formulação do problema, sendo necessário definir: a função objetivo, as restrições do problema, a variável de decisão e o espaço de busca. Em seguida, o modelo foi implementado utilizando *Integer-Linear Programming* (ILP).

Tabela 5 – Saída do *módulo de escalonamento*.

Qtd. de dias	Vazão (ton.)	Vazão total (ton.)
22 dias	900	19.800
2 dias	1200	2.400
6 dias	1300	7.800
		<b>30.000</b>

**Fonte:** O autor.

Foi assumido que o consumo de energia elétrica total (*Consumo*) segue uma relação linear, que varia de acordo com a quantidade de dias ( $d_q$ ) para cada valor de  $q$ . Sabendo que  $q$  corresponde ao índice da faixa de vazão ( $q = 1, \dots, m$ ), e que  $m$  é a quantidade de faixas de vazão definidas. O relacionamento associado pode ser modelado como

$$Consumo = \sum_{q=1}^m E_q \cdot d_q \quad (4.1)$$

onde  $E_q$  é a média do consumo de energia elétrica ao longo de um período associada a uma faixa de vazão  $q$ .

#### 4.2.2.2.1 Definição do problema

A solução do problema foi definida por algoritmos de otimização, dado que seu objetivo era estabelecer a melhor combinação possível entre as faixas de vazão de produção e o período, em dias, que seria utilizado. Portanto, o problema de otimização pode ser resolvido utilizando a  $\min \text{Consumo}(d_1, d_2, \dots, d_m)$  sujeita a

$$V_T \leq \sum_{q=1}^m FV_q \cdot d_q \leq (1 + \alpha)V_T \quad (4.2)$$

$$P_L \leq \sum_{q=1}^m d_q \quad (4.3)$$

$$0 \leq d_q \leq P_L, q = 1, \dots, m \quad (4.4)$$

onde  $V_T$  representa o volume total de produção. Já  $FV_q$  corresponde à faixa de vazão de produção para cada valor de  $q$ . Os limites inferior e superior da restrição apresentada na Equação 4.2 correspondem a  $V_T$  e  $(1 + \alpha)V_T$ , respectivamente. Onde  $\alpha$  representa o valor percentual que define o limite superior em relação ao limite inferior e é estabelecido pelo usuário. Já o  $P_L$  indica o prazo limite para a produção.

#### 4.2.2.2.2 Algoritmo de otimização

A implementação do *módulo de escalonamento* foi baseada no modelo de programação linear inteira (ILP), pois o problema apresenta a função, objetivo e todas as três funções de restrições representadas como funções lineares; e a variável de decisão ( $d_q$ ) do problema é representada por números inteiros (SARKER; NEWTON, 2007). A biblioteca do *Python* utilizada na implementação foi a PULP (PYPI, 2021), que ofereceu recursos simples para a execução do modelo proposto para o *módulo de escalonamento*. O solucionador utilizado foi o CBC (PULP\_CBC\_CMD).

O *módulo de escalonamento* trará melhores resultados para as indústrias de resinas termoplásticas sem a necessidade de investimento, permitindo alguns pontos de melhorias, como: redução do custo com energia elétrica, dados de apoio à decisão no processo de planejamento da produção, e possibilidade de programação da manutenção preventiva.

#### 4.2.2.3 Viabilidade

O *módulo de viabilidade* foi definido para realizar o estudo de viabilidade de tecnologias (materiais, equipamentos e sistemas) em um novo processo industrial, por uma avaliação técnica e econômica. Desta forma, o modelo implementado neste módulo irá fornecer informações necessárias aos gestores (por exemplo, tempo de retorno do investimento, economia com o uso do equipamento no novo processo), possibilitando ao usuário definir qual ação deverá ser tomada.

Para iniciar o estudo de viabilidade de tecnologias em um determinado processo industrial, alguns dados do processo precisam ser fornecidos: configuração do processo; especificação técnica dos componentes do processo (bombas, válvulas, dentre outros); histórico de dados de vazão, abertura de válvulas, pressão, dentre outros. Em seguida, é realizado o cálculo do consumo de energia elétrica do processo sem ( $C_{semtecnologia}$ ) e com ( $C_{comtecnologia}$ ), a utilização de novas tecnologias, que pode ser representada pela inserção de materiais, equipamentos ou até mesmo sistemas.

Dentre os indicadores comumente utilizados pelo mercado para analisar o tempo de retorno do investimento, será utilizado nesse módulo o cálculo do tempo de retorno de investimento, *Payback* (Equação 4.5) (KOSMADAKIS, 2019). Bem como a *Economia<sub>mensal</sub>* e a *Economia*, definidas nas Equações 4.6 e 4.7, respectivamente. Os cálculos e os dados serão fornecidos aos usuários por meio da *interface de aplicação*.

$$Payback = \frac{CAPEX_{tecnologia}}{Economia_{mensal}} \quad (4.5)$$

$$Economia_{mensal} = \frac{Economia}{R_m} \quad (4.6)$$

$$Economia = C_{semtecnologia} - C_{comtecnologia} \quad (4.7)$$

Onde  $CAPEX_{tecnologia}$  corresponde ao valor investido na compra da tecnologia (materiais, equipamentos e sistemas).  $R_m$ , é a razão da duração dos dados pelo valor correspondente a um mês, considerando a unidade (exemplo: se a duração dos dados é de 5256 horas, o valor de  $R_m = 5256h/720h = 7,3meses$ ).

O *módulo de viabilidade* também permitirá realizar simulações com dados que variam o consumo do processo, exemplo, definição do valor de rotação do motor, tendo como entrada a vazão do fluido que será bombeado.

Utilizando a análise de viabilidade, será possível realizar estudos de melhoria de processos, visando o aumento do nível de eficiência da produção. Uma vez que, o *módulo de viabilidade* irá apontar quais tecnologias serão possíveis de serem incrementados na planta industrial através de análises de diferentes opções de materiais, equipamentos e sistemas computacionais.

#### 4.2.2.4 Armazenamento

O *módulo de armazenamento* é responsável por armazenar dados oriundos do *módulo coleta de dados* e de outros módulos do *framework* (*predição, escalonamento, viabilidade e suporte de dados*).

Dependendo da complexidade do cenário de aplicação, é relevante a construção de diferentes estruturas de armazenamento de dados, não necessariamente usando o mesmo Banco de Dados (BD). A flexibilidade no armazenamento de dados subsidiará uma gerência mais adequada dos dados coletados de diferentes fontes (SHEN et al., 2017) e aprimorará a capacidade de processar o elevado volume de dados (SUN; ANSARI, 2016; BREBNER, 2012).

#### 4.2.2.5 Suporte de dados

Para o funcionamento do *framework*, alguns microserviços básicos foram necessários. O *suporte de dados* é responsável pelo gerenciamento das medições, dados relacionados às configurações do sistema, bem como controle de acesso dos usuários (Figura 19).

Figura 19 – Suporte de dados.



Fonte: O autor.

##### 4.2.2.5.1 Medição

O *módulo medição* é responsável por todas as variáveis (energia, vazão de produção, temperatura, pressão, dentre outras) relacionadas à medição, bem como aos eventos associados à uma medição. Esse módulo pode ser representado por uma API REST, capaz de retornar uma lista com todas as medições de variáveis elétricas em um dado período, existentes no BD, por meio de solicitação por requisição GET; além de estar apto para realizar inserções de medições de variáveis elétricas, variáveis de processo e indicador de desempenho energético para o BD, usando a requisição POST, é possível associar um evento a uma determinada medição, com a atualização do documento de medição na adição deste evento, usando uma requisição PUT.

#### 4.2.2.5.2 Configuração

O *módulo configuração* é responsável pela definição dos alertas e notificações, eventos, *ranges* de variáveis, além de possibilitar a criação de novas configurações. Nem todos os usuários terão acesso a esse módulo, pois como são definições importantes e terão um impacto no gerenciamento energético, é relevante que sejam bem estudados e estabelecidos. Logo, apenas os usuários administradores terão acesso.

Os alertas e as notificações podem ser realizados, mediante envio de e-mail ou *Short Message Service* (SMS) para os usuários registrados. Cada alerta estará associado a uma lista de usuários (administrador e não administrador), visando o envio dos alertas específicos para cada usuário. O alerta será definido por meio de uma combinação de regras com os dados de variáveis elétricas e variáveis de processo. Essas funcionalidades do *módulo configuração* facilitarão a tomada de decisão, otimizando o processo de monitoramento e gerenciamento energético.

Os eventos que ocorrem na fábrica podem ser listados e os usuários poderão associá-los ao dia da ocorrência. Assim, além de uma justificativa para o desempenho energético, será possível registrar os eventos para um melhor monitoramento do histórico. Os eventos precisam ser ocorrências que impactam o consumo de energia industrial, por exemplo: a manutenção preventiva e corretiva, a alteração da vazão de produção, a parada na planta, dentre outros. Com o histórico desses eventos, o *framework* conseguirá indicar um futuro evento que poderá acontecer, apenas, com o comportamento das variáveis elétricas e variáveis de processo.

Na representação gráfica das variáveis elétricas e de processo, elas podem ser melhor interpretadas quando houver uma sinalização dos limites inferiores e superiores; ou até mesmo quando houver a representação de faixas de variáveis de processo relevantes para esta análise. Desta forma, com a indicação de *ranges* para diferentes variáveis, será possível representar melhor os dados, para facilitar sua interpretação.

---

O *módulo configuração* também pode ser representado por uma API REST capaz de realizar as requisições de PUT e GET.

#### 4.2.2.5.3 Controle de acesso

Nos ambientes industriais há informações às quais nem todos os usuários podem ter acesso, o mesmo acontecendo com determinadas ações. Isso por conta da segurança no acesso, que é fundamental.

Visando garantir o controle do acesso, com base no papel do usuário, foi criado o *módulo controle de acesso*. Por meio desse módulo é possível gerar informações referentes aos usuários. Isso porque, no *framework*, será necessária a criação, edição e exclusão de usuários. Serão representados também, neste módulo, dois perfis de usuários — usuários administradores e usuários não administradores. Os usuários não administradores são capazes, apenas, de visualizar graficamente os dados na *interface de aplicação*. Os usuários administradores são aqueles que têm acesso ao *módulo de configuração*, isto é, conseguem visualizar os dados e editá-los.

Para facilitar o acesso do *front-end* deste *framework* aos dados desse módulo e ser possível realizar diferentes requisições no padrão HTTP (POST, GET, PUT e Delete), uma API REST poderá ser exposta para esse módulo. Sendo possível criar, editar e deletar a lista de usuários. A ideia é que cada usuário seja representado por um código (identificador). Para a criação de um usuário é necessária a definição de algumas informações mínimas, como: nome, e-mail, senha, nível de acesso, matrícula, dentre outras.

#### 4.2.2.6 API REST

A proposta é que o *framework* seja um serviço *web*. Desta forma, um dos padrões utilizados para a criação e a utilização de serviços *web* é o padrão REST, capaz de garantir uma comunicação mais simples entre os serviços, por meio de um conjunto de operações (MASSE, 2011).

Os recursos oferecidos pelos serviços são identificados por *endpoints* (similares às *URLs*) e respondem às operações com informações estruturadas em diferentes formatos (como HTML e *JavaScript Object Notation* (JSON)).

O *módulo API REST* permite, sem muita complexidade, que o *módulo interface de aplicação* acesse os serviços contidos no *backend* do *framework*, utilizando algumas requisições no padrão HTTP — GET (leitura), POST (inserção), PUT (atualização) e Delete (remoção) (Apêndice A).

### 4.2.3 Interface de aplicação

Visando facilitar o acesso dos usuários ao *framework*, uma *interface* gráfica de aplicação foi projetada e desenvolvida de maneira simples e intuitiva. Desta forma, os usuários são capazes de monitorar os dados oriundos dos dispositivos do chão de fábrica (sensores, atuadores, medidores, dentre outros), com uma apresentação clara e objetiva, associada a diagnósticos. Essas informações são apresentadas por mensagens, gráficos, tabelas e relatórios. Além de possibilitar a configuração de alertas e notificações, otimizam o processo de monitoramento e gerenciamento do desempenho energético industrial.

Para cada indústria é importante que a *interface de aplicação* seja customizada. Na Seção 5.2.7 são apresentados os detalhes do que foi desenvolvido e implementado para o estudo de caso.

## 4.3 CONSIDERAÇÕES FINAIS

O sistema de apoio à decisão caracterizado pelo *framework* de gerenciamento de energia elétrica pode ser implantado em indústrias com diferentes perfis. Desta forma, uma metodologia foi definida:

1. Definir as variáveis que impactam no IDE.
2. Estabelecer a configuração mais precisa para o modelo de predição:
  - Pré-processamento dos dados.
  - Escolha das técnicas de IA e métricas de avaliação.

- Aplicação do método *grid search*.
  - Seleção dos modelos (método tradicional, teste DM e MCS).
3. Customizar o modelo de escalonamento da vazão de produção:
- Definição da quantidade e valores das faixas de vazão de produção.
  - Identificação da média de consumo de energia diário por faixa de vazão.
4. Adaptar o modelo de viabilidade técnica e econômica:
- Análise dos dados do processo (esquemático, especificação técnica dos equipamentos, histórico dos dados de variáveis do processo).
  - Identificação da nova tecnologia (equipamentos e/ou materiais).
  - Definir técnica para cálculo do consumo de energia elétrica.
  - Cálculo do retorno do investimento.

## 5 ESTUDO DE CASO EM UMA INDÚSTRIA DE RESINAS TERMOPLÁSTICAS

O estudo de caso do *framework* foi através de sua implantação em uma indústria real, visando avaliá-lo e validá-lo. Para isso, inicialmente foi necessário entender as necessidades da indústria e identificar como cada funcionalidade do *framework* poderia se adequar à realidade da indústria em questão.

### 5.1 CARACTERÍSTICAS DA INDÚSTRIA DE RESINAS TERMOPLÁSTICAS

A indústria em que foi realizado o estudo de caso é do segmento de resinas termoplásticas. Uma indústria internacional de grande porte, presente em mais de 30 países e que integra em seu quadro de funcionários cerca de 20.000 profissionais. A filial da indústria estudada está localizada no Brasil, ocupando uma área de cerca de 50.000  $m^2$  e apresenta uma capacidade de produção de aproximadamente 500.000 *ton./ano*.

Esta indústria de resinas termoplásticas adota uma política ambiental de respeito às normas legais do meio ambiente e de redução de impactos ambientais. O estudo de caso foi realizado no contexto de um projeto que já estava em andamento, projeto este visando o aumento da eficiência energética, a manutenção e aprimoramento do Sistema de Gestão de Energia baseado na ISO 50001. Desta forma, a integração desse *framework* complementou os estudos que estavam sendo realizados. O *framework* trouxe inovação para o meio industrial, com auxílio de ferramentas da indústria 4.0: IA, IoT, *big data*, dentre outras.

#### 5.1.1 Ações realizadas

Visando a melhoria do monitoramento e gerenciamento de energia, foi identificada a necessidade de realizar medições setoriais; assim, novos pontos de medição foram criados. Vinte grupos de medições foram identificados como re-

---

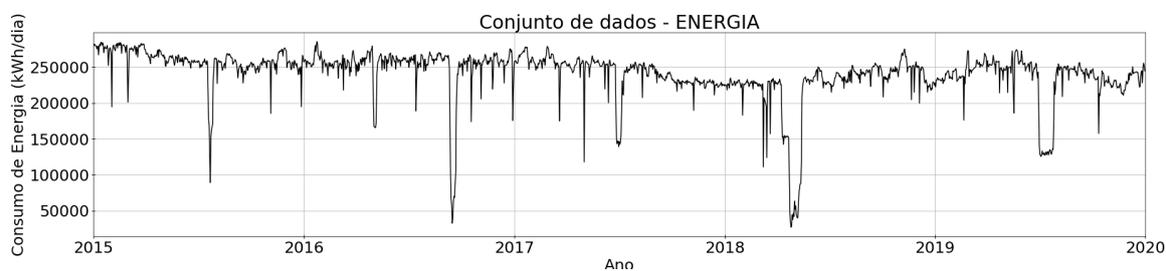
levantados para serem monitorados, compreendendo equipamentos de refrigeração, bombas, prédios, dentre outros. Conforme os grupos de medições, foi necessário instalar 71 novos pontos de medição de energia.

O monitoramento setorial foi iniciado de forma escalar, pois, para cada área, as variáveis monitoradas e as características dos alertas são diferentes. Assim, foram definidas, com engenheiros especializados no processo, as características do monitoramento e gerenciamento setorial. Além dessas definições, foi relevante identificar como seria representado o indicador de desempenho da indústria de resinas termoplásticas. Então, mais uma vez com os especialistas, ficou definido que o indicador de desempenho energético ( $n$ ) seria representado por meio da relação entre o consumo de energia ( $C$ ) e a vazão de produção ( $F$ ) da indústria, por dia (Equação 5.1), cuja unidade é  $kWh/ton$ .

$$n = \frac{C}{F} \quad (5.1)$$

Foi realizado um estudo baseado na análise da relação entre três conjuntos de dados: (a) consumo de energia (Figura 20a), vazão de produção para os processos de (b) POLI (Figura 20b) e (c) SSPOLI (Figura 20c). Com esses conjuntos de dados foi possível verificar como o indicador de desempenho energético se comportou durante o período de cinco anos (2015 – 2019).

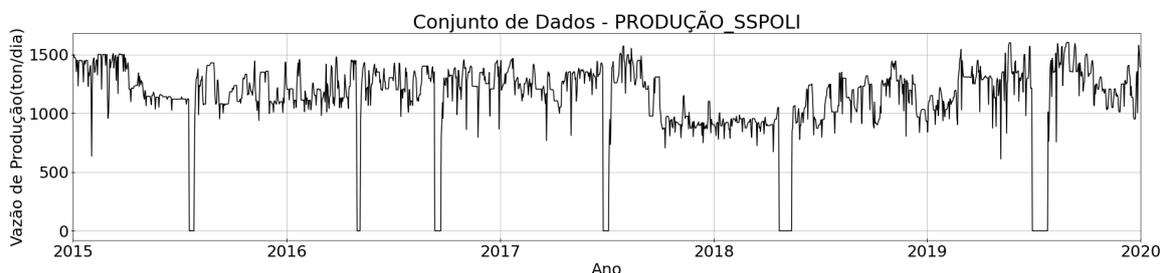
Figura 20 – Conjunto de dados diários de (a) consumo de energia elétrica, (b) vazão de produção para o processo de POLI e (c) vazão de produção para o processo de SSPOLI.



(a)



(b)



(c)

**Fonte:** O autor.

Foi relevante visualizar esses dados de maneira diferente e identificar as faixas de vazão relevantes para o estudo. Assim, foram executadas as etapas abaixo:

1. Representação da série temporal completa (cinco anos) do indicador de desempenho energético, com o intuito de verificar em que janela o indicador de desempenho energético está compreendido. O indicador de desempenho

---

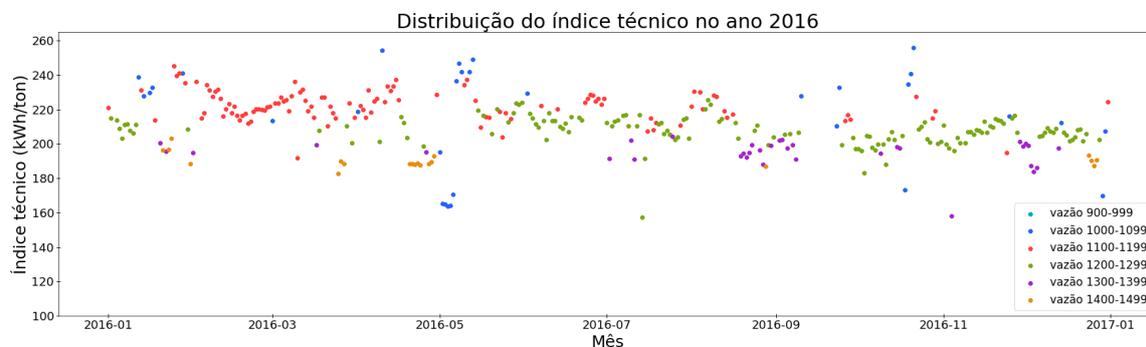
energético, durante esses cinco anos, apresentou limite inferior igual a 150  $kWh/ton.$  e um limite superior de 250  $kWh/ton.$ , embora, em alguns dias, a curva ultrapasse esses valores.

2. Definição das faixas de vazão diárias relevantes que serão analisadas. Após análise com especialistas da indústria e observando as características da planta industrial, foram definidas seis faixas (900 – 999, 1000 – 1099, 1100 – 1199, 1200 – 1299, 1300 – 1399, 1400 – 1499).
3. Identificação do comportamento do IDE ao longo dos meses. Diante disso, a análise foi feita por ano. Nesta mesma etapa foi verificada a distribuição da faixa de vazão diária ao longo do ano, utilizando a representação das cores. Assim, foi possível identificar as faixas predominantes em cada mês e qual faixa não apareceu. Na Figura 21 é possível observar uma predominância de vazões na faixa de vazão 1200 – 1299 ton./dia e que vazões entre 900 – 999 ton./dia não foram representadas no ano de 2016.
4. Análise da média do indicador de desempenho energético, por meio da representação de gráfico em barra.

Com a análise do indicador de desempenho energético, foi possível afirmar que os valores da média do indicador de desempenho energético são mais elevados à medida que os valores das vazões decrescem, isto é, os valores com médias mais elevadas se concentram em faixas de vazão menores (Figura 22).

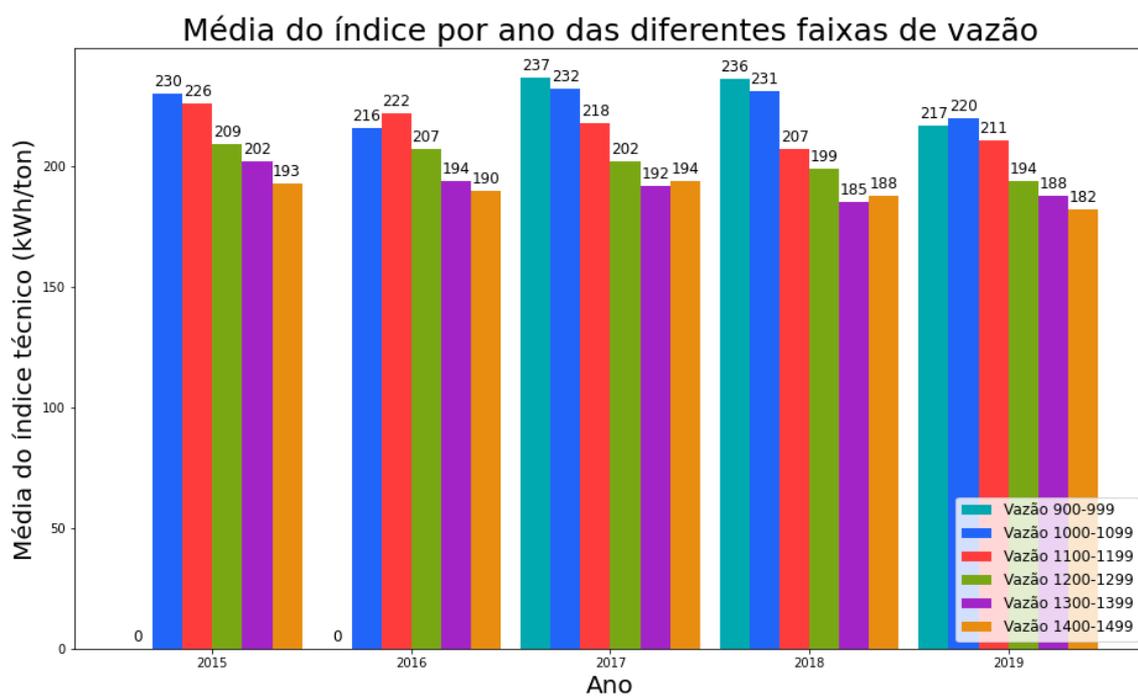
Para coletar os dados e alimentar o *framework* foi necessário identificar como os equipamentos, dispositivos IoT e sistemas se comunicavam. Foi verificado que os funcionários já tinham acesso aos dados das variáveis de processo e das variáveis elétricas, por meio de diferentes sistemas, *Exaquantum* (YOKOGAWA, 2000) e *Smart 32* (GESTAL, 2019b), respectivamente. Assim, como os modelos implementados no *framework* precisam ser alimentados simultaneamente com esses dois tipos de variáveis, foi definido como melhor forma de integração o acesso aos dados utilizando esses sistemas. Os dados de variáveis de processo foram obtidos com a utilização de um *script* que gera uma planilha a cada cinco minutos, com as variáveis desejadas. Já os dados oriundos do sistema do *Smart 32* foram obtidos por meio do compartilhamento de uma pasta com todos os

Figura 21 – Distribuição do indicador de desempenho energético no ano de 2016.



Fonte: O autor.

Figura 22 – Comportamento da média do indicador de desempenho em relação à variação das faixas de vazão de produção.



Fonte: O autor.

dados que constam no BD do sistema legado na indústria onde o estudo foi realizado.

## 5.2 CARACTERÍSTICAS DO *FRAMEWORK* NO ESTUDO DE CASO

O *framework* desenvolvido nesta pesquisa permite que seus dados e funcionalidades sejam facilmente integrados com outros sistemas, por meio de APIs. Essa é uma característica que difere dos sistemas comerciais, que normalmente são sistemas fechados. Devido à simplicidade e flexibilidade do *framework*, combinado com a independência que a indústria teria, foi preferível não integrar nenhum módulo no interior de sistemas legados na fábrica (*PI System* (OSI-SOFT, 1980), *Exaquantum* (YOKOGAWA, 2000), e *Smart 32* (GESTAL, 2019b)). Isso geraria um custo adicional para a indústria, dado que seria necessária a aquisição de novas licenças de *software*.

Após algumas ações, foi verificado que os módulos do *framework* para a implantação, na indústria seguiriam o que foi apresentado na Figura 15. A representação do *módulo de coleta de dados* se deu pelos sistemas (*softwares*) já existentes na indústria, *Exaquantum* e *Smart 32*.

### 5.2.1 Armazenamento

O BD utilizado para o armazenamento de todos os dados do *framework* — dados de variáveis elétricas e de processos, de predição, de indicador de desempenho energético, de eventos, de configuração, e dados de usuário — no *módulo de armazenamento*, foi o MongoDB, versão 4.4. Geralmente, esse tipo de BD é recomendado para armazenar dados vinculados a aplicações IoT, pois sua arquitetura provê um melhor desempenho (EYADA et al., 2020).

### 5.2.2 Suporte de dados

O *módulo de suporte de dados* apresenta os dados dos usuários cadastrados — *login*, senha, e-mail, nível de acesso (administrador e não administrador), bem como dados referentes aos *ranges* de consumo de energia, definição das

---

faixas de vazão, regras para inserção dos alertas, dentre outros. Assim como os dados referente às medições das variáveis elétricas e variáveis de processo. No Apêndice A é possível visualizar as estruturas dos documentos JSON para cada requisição.

### 5.2.3 Viabilidade

Com a análise dos dados oriundos do modelo de predição do consumo de energia diário, juntamente com os dados históricos do consumo de energia, vazão e abertura de válvulas, foi possível identificar que havia um inversor subutilizado em um processo específico na indústria de resinas termoplásticas em estudo, pois o conjunto moto-bomba estava sempre trabalhando na vazão máxima.

Os inversores de frequência são equipamentos capazes de controlar os motores por meio da alteração da velocidade de rotação. Com esse equipamento integrado a um sistema formado por motor, bombas, válvulas e sensores, é possível otimizar os seus parâmetros para que a vazão fornecida pelas bombas seja variável. Desta forma, o conjunto motor-bomba fornecerá a vazão de fluido necessária para o processo, reduzindo o desperdício de energia. Porém, como nesse caso o motor sempre opera com velocidade máxima, não é necessário o uso do inversor.

Como a indústria já havia feito o investimento da tecnologia (inversor), o ideal seria realizar o estudo de viabilidade técnica desse inversor para que pudesse ser inserido em outro processo dessa mesma indústria. Com essa alteração, como o motor não tem uma rotação constante, a variação da velocidade de rotação impacta diretamente no consumo de energia no novo processo.

O estudo de viabilidade técnica e econômica foi realizado através da análise da especificação (exemplo: rotação, altura monométrica, rendimento, potência, curva característica da bomba, dentre outras) dos equipamentos (exemplo: bomba, motor, válvulas, dentre outros) que fazem parte do novo processo. Bem como configuração dos processos da planta industrial (exemplo: diâmetro da tubulação, taxa volumétrica do líquido da sessão, fator de fricção, coeficiente do fluido, dentre outras).

Após a verificação da viabilidade técnica do inversor no novo processo foi realizado o cálculo do tempo de retorno do investimento e da economia, por meio das Equações 4.5, 4.6 e 4.7 foram realizados. Para isso, foi necessário o cálculo do custo sem o uso do inversor  $C_{sem\,inversor}(\eta, D_a)$  e o custo com o uso do inversor  $C_{com\,inversor}(D_a)$ , considerando que a eficiência da bomba ( $\eta$ ) é de 67% e a duração dos dados amostrados em horas ( $D_a$ ), é 5256 amostras.

### 5.2.3.1 Custo com o consumo de energia sem o uso do inversor

Para verificar se é viável economicamente a inserção do inversor para controle da rotação de uma bomba no novo processo, foi importante calcular o custo do consumo de energia sem o uso do inversor. Isto é, será considerado que o sistema funcionará com uma rotação da bomba sempre constante e igual a 1780rpm, dado que não usará inversor e sistema de controle.

Será assumido que a bomba operará em regime completo, gerando um fluxo constante durante  $D_a = 5256$  horas. Assim, o custo de energia sem o uso do inversor é calculado pela Equação 5.2, sabendo que o valor de  $U_{kWh} = 0,32$  R\$/kWh e o valor de  $P_{max} = 43,8kW$ .

$$C_{sem\,inversor}(\eta, D_a) = P_{max} * U_{kwh} * D_a \quad (5.2)$$

$$C_{sem\,inversor}(67\%, 5256) = 43,8kW * 0,32 * 5256h \quad (5.3)$$

$$C_{sem\,inversor}(67\%, 5256) = R\$73.668,096 \quad (5.4)$$

### 5.2.3.2 Custo com o consumo de energia com o uso do inversor

Como já mencionado, no estudo de caso, o equipamento analisado foi o inversor. Dessa forma, o cálculo do custo oriundo do consumo de energia elétrica do novo processo com o uso do inversor ( $C_{com\,inversor}$ ) foi obtido através da aplicação da Equação 5.5.

$$C_{com_{inversor}}(D_a = 5256) = E_{Total}(Q(i), Da) = \sum_{i=1}^{Na} E(i) \quad (5.5)$$

Para o cálculo da energia ( $E(i)$ ) foi necessário o cálculo da potência ( $P(i)$ ) (Equação 5.6), dado que o valor unitário de cada  $kWh$  ( $U_{kwh}$ ), em real, corresponde a R\$0,32. A potência ( $P(i)$ ) foi obtida utilizando a Lei da Afinidade (SIMPSON; MARCHI, 2013; GIBSON, 1994), que apresenta as relações entre o fluxo oferecido pela bomba ( $Q$ ) e a rotação da bomba ( $N$ ) entre a potência da bomba e o cubo das rotações ( $N^3$ ) e entre a altura manométrica ( $H$ ) e o quadrado da rotação ( $N^2$ ) (Equações 5.7, 5.8 e 5.9).

$$E(i) = P(i) * U_{kwh} \quad (5.6)$$

$$\frac{Q_2}{Q_1} = \frac{N_2}{N_1} \quad (5.7)$$

$$\frac{P_2}{P_1} = \left(\frac{N_2}{N_1}\right)^3 \quad (5.8)$$

$$\frac{H_2}{H_1} = \left(\frac{N_2}{N_1}\right)^2 \quad (5.9)$$

Com a utilização do inversor no novo processo foi possível reduzir o consumo de energia de uma forma significativa, gerando uma  $Economia_{mensal}$  igual a R\$9.877,64. Com o *Capital Expenditure* (CAPEX) referente ao inversor e a  $Economia_{mensal}$ , foi possível garantir que o tempo de retorno de investimento fosse de cinco meses.

Com o *módulo de viabilidade* foi possível garantir a reutilização do inversor, já adquirido pela indústria. A integração do inversor em outro processo contribuiu com a redução do consumo de energia e garantiu uma utilização mais adequada dos equipamentos do processo.

O usuário visualiza na *interface de aplicação* o tempo de retorno do investimento, bem como as economias oriundas da análise de viabilidade econômica.

Além disso, é possível "simular" para um sistema de rotação constante qual o respectivo valor de rotação, dando como entrada a vazão do fluido (fluxo). Na Figura 23 é possível verificar a *interface de aplicação* com a tela da funcionalidade de "viabilidade dos inversores".

Figura 23 – Tela de viabilidade do inversor.

Viabilidade dos Inversores

Sistema de controle

Tempo de Retorno Geral 5 Meses

Sistema com rotação constante

Inserir Fluxo: 5 m<sup>3</sup>/h **CALCULAR** = Rotação: 32,4 RPM

[Baixar histórico de rotação](#)

**Fonte:** O autor.

#### 5.2.4 Escalonamento

Com a análise do histórico dos dados do indicador de desempenho energético, bem como a análise dos gráficos de dispersão do consumo de energia relacionado com a faixa de vazão, verificou-se que alterações no planejamento da produção diária poderiam prover uma redução do consumo de energia elétrica. Assim, considerando a Equação 4.1 apresentada no Capítulo 4, foi definido, para o estudo de caso, que  $m$  seria igual a seis, uma vez que as possíveis faixas de vazão diárias utilizadas seriam: 900 – 999 ton./dia, 1000 – 1099 ton./dia, 1100 – 1199 ton./dia, 1200 – 1299 ton./dia, 1300 – 1399 ton./dia e 1400 – 1499 ton./dia. Além disso, foi utilizada a média do consumo de energia, durante os cinco anos (2015 – 2019), associada a cada faixa de vazão (Tabela 6).

Tabela 6 – Média do consumo de energia elétrica por faixa de vazão.

Faixa de Vazão (ton./dia)	Média do Consumo Diário (kWh)
$FV_1 = 900$	218.844,610
$FV_2 = 1000$	238.497,766
$FV_3 = 1100$	251.631,434
$FV_4 = 1200$	253.401,549
$FV_5 = 1300$	258.986,989
$FV_6 = 1400$	273.634,013

**Fonte:** O autor.

Alguns experimentos foram realizados com o intuito de verificar o comportamento do *módulo de escalonamento*, bem como seu desempenho. Desta forma, utilizando os dados históricos da demanda mensal ( $V_T$ ) do ano de 2015 e o prazo de produção ( $P_L$ ) — entradas do *módulo de escalonamento*, foi possível analisar as possíveis saídas — melhores combinações entre  $Fv_q$  e  $d_q$  ( $0 < q \leq 6$ ) que minimizam o consumo de energia elétrica. Na Tabela 7 é possível analisar a relação entre o consumo de energia real (sem o uso do *módulo de escalonamento*) e o consumo de energia do modelo, que corresponde ao consumo de energia baseado na saída do *módulo de escalonamento*.

Tabela 7 – Resultado dos experimentos com o *módulo de escalonamento*.

Mês	Entrada		Saída						Dados	Consumo (kWh)
	$V_T$ (ton.)	$P_L$ (dia)	$d_1$ (dia)	$d_2$ (dia)	$d_3$ (dia)	$d_4$ (dia)	$d_5$ (dia)	$d_6$ (dia)		
Jan/2015	42300	31	0	0	1	0	8	22	Real	8584326,100
			0	0	0	0	11	20	Modelo	8321537,143
Fev/2015	37800	28	0	0	2	1	6	19	Real	7704125,600
			0	0	0	0	14	14	Modelo	7456694,034
Mar/2015	41700	31	0	0	1	4	6	20	Real	8422072,000
			0	0	0	0	17	14	Modelo	8233655,002
Abr/2015	36200	30	0	0	4	22	2	2	Real	8012592,300
			7	0	0	0	23	0	Modelo	7488613,027
Mai/2015	33800	31	0	3	28	0	0	0	Real	8091477,500
			16	0	0	1	14	0	Modelo	7380733,159
Jun/2015	33100	30	0	0	29	1	0	0	Real	7748951,400
			15	0	0	0	14	1	Modelo	7182121,013
Jul/2015	29800	28	0	10	18	0	0	0	Real	6818277,400
			16	0	0	2	10	0	Modelo	6598186,750
Ago/2015	31000	31	0	31	0	0	0	0	Real	8007659,800
			23	0	0	1	7	0	Modelo	7099736,501
Set/2015	30000	30	0	30	0	0	0	0	Real	7456212,000
			22	0	0	2	6	0	Modelo	6875306,451
Out/2015	36400	31	0	1	10	16	4	0	Real	7839480,300
			10	0	0	0	20	1	Modelo	7641819,901
Nov/2015	35100	30	0	5	12	0	13	0	Real	7812515,500
			10	0	0	0	19	1	Modelo	7382832,911
Dez/2015	33000	31	0	14	15	1	1	0	Real	7814866,600
			18	0	0	1	12	0	Modelo	7300448,400

**Fonte:** O autor.

É possível observar que o planejamento da produção baseado no *módulo de escalonamento* foi mais eficiente. No ano de 2015 a indústria teria economizado 5,67% no consumo de energia elétrica, caso tivesse aplicado o planeja-

mento da produção oriundo do *framework*, que equivale a uma economia de R\$1.712.279,106 no ano.

O *módulo de escalonamento* da vazão trouxe melhores resultados sem a necessidade de investimento, possibilitando os seguintes pontos de melhoria:

- Redução do custo com energia elétrica;
- Dados de apoio à decisão no processo de planejamento da produção;
- Possibilidade de programação da manutenção preventiva.

### 5.2.5 Predição

O *módulo de predição* é formado basicamente por quatro modelos de predição:

1. O modelo de predição do consumo de energia de curto prazo, STLF, capaz de prever o consumo de energia para o dia seguinte. Esse modelo foi baseado em aprendizado profundo, por meio da técnica GRU com configuração de uma camada e 30 neurônios (explicação apresentada na Seção 6.2).
2. O modelo de predição do consumo de energia de médio prazo, MTLF, capaz de prever o consumo diário de energia para os próximos 30 dias. Esse modelo foi baseado em aprendizado de máquina, técnica de XGBoost, com configuração de profundidade máxima de 3 e 50 árvores (explicação apresentada na Seção 6.3). Foi também responsável pelo monitoramento da predição do consumo de energia mensal e pela análise do indicador de desempenho energético.
3. O modelo de predição da vazão de produção diária para 30 dias consegue prever a vazão de produção, por dia, para os 30 dias seguintes. Esse modelo foi baseado em aprendizado de máquina, a técnica de SVR, com configuração do valor de C igual a 0,5 e a função de ativação RBF (explicação apresentada na Seção 6.4).
4. O modelo de predição do IDE mensal é capaz de oferecer informações para auxiliar a tomada de decisão na produção, pois é possível realizar uma comparação do IDE predito com o valor do IDE estabelecido como

referência. O modelo de predição do IDE é alimentado pelos dados oriundos dos três modelos de predição (modelo STLF, modelo MTLF e modelo da vazão de produção mensal).

### **5.2.6 API REST**

O *framework* implantado na indústria de resinas termoplásticas expõe uma API na qual implementa algumas requisições. Os *endpoints* expostos pela API, suas descrições, JSON *schema*, bem como os verbos HTTP são apresentados na Tabela 8.

Tabela 8 – *Endpoints expostos pela API do framework.*

Módulo	Endpoint	Verbos HTTP	JSON <i>schema</i>	Descrição
Controle de acesso	/framework/login	POST	{cod_user: 'user', senha: 'pass'}	Retorna 'sucesso' se as credenciais estiverem corretas.
	/framework/users	GET	?type==[all,admin,viewer]	Retorna os usuários correspondentes ao tipo escolhido.
	/framework/users/ {cod_user}	GET	-	Retorna o usuário solicitado. Precisa ser enviado, apenas, o código do usuário.
	/framework/users	POST	{cod_user: 'user', name: 'name', password: 'pass', matricula: 'matric', #opcional email: 'email@email.com', access_level: 'admin'ou 'viewer'} {password: 'pass'};	Criação de um novo no processo. É necessário o envio de algumas credenciais obrigatórias (código do usuário, nome, senha, e-mail, nível de acesso) e uma credencial não obrigatória (matrícula).
	/framework/users/ {cod_user}	PUT	{matricula: 'matricula'}, {access_level: 'access_level'}, {email: 'email'}	Edita as informações de um usuário existente no sistema.
	/framework/users/{cod_user}	DELETE	DELETE	Deleta um usuário existente no sistema. Basta enviar o código do usuário.
	Configuração	/framework/conf	GET	-
/framework/conf		PUT	{EventsList: 'Novo evento'} ou {Range: {max: 1, min: 0}}	Atualiza, edita e cria novas configurações.
Medição	/framework/meas ?gte=='dd/mm/AAAA'&lte =='dd/mm/AAAA	GET	-	Retorna todas as medições de energia existentes no BD em um período definido.
	/framework/meas ?mostrecent_meas	GET	-	Retorna a medição mais recente do BD.
	/framework/meas	POST	[[{date: 'dd/mm/AAAA', consumo: 1000.0, vazaopoli: 100.0, vazaospoli: 100.0}, {...}, ]	Envia uma lista de medições para o BD.
	/framework/meas/graph	POST	{years: [2015,...2017]}	Retorna os valores do indicador de desempenho por faixa de vazão por ano.
	/framework/meas	PUT	{date: 'dd/mm/AAAA', evet: ['parada', 'quebra']}	Insera um evento associado a uma determinada data.
Predição	/framework/preds ?gte=='dd/mm/AAAA'&lte =='dd/mm/AAAA	GET	-	Retorna todas as predições de consumo de energia existentes no BD entre a data definida
	/framework/preds ?today_pred	GET	-	Retorna a predição realizada para o dia atual.
	/framework/preds	POST	{month: 7; year: 2020}	Retorna a predição e o valor atual do indicador de desempenho do mês atual.

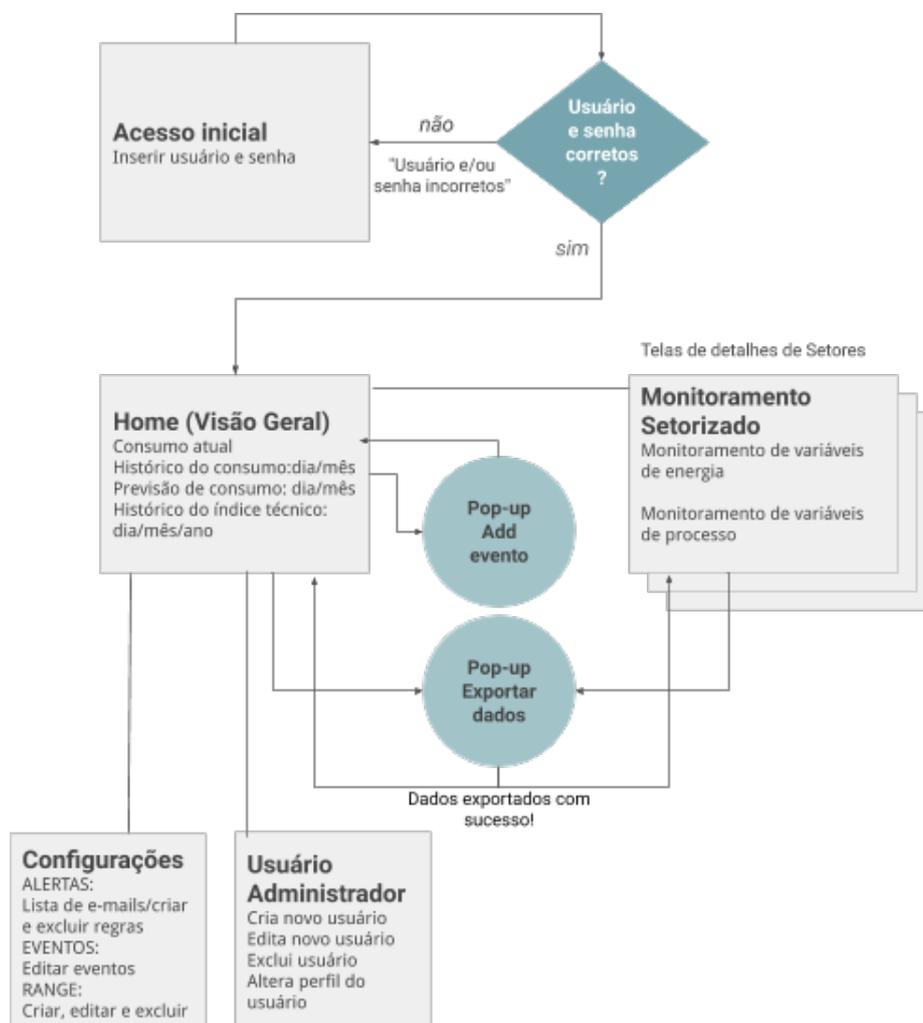
Fonte: O autor.

### 5.2.7 Interface de aplicação - funcionalidades e telas

Para contemplar os requisitos pontuados na Seção 4.2 e facilitar a implementação da *interface de aplicação*, foi elaborado um fluxo de interação que pode ser

visto na Figura 24.

Figura 24 – Fluxo de interação de telas.



Fonte: O autor.

Como é possível observar, o fluxo é dividido em dois perfis de usuários: o perfil do usuário administrador e o perfil do usuário não administrador. Desta forma, o sistema identifica o usuário segundo o *login* e senha, e o encaminha para a tela da visão geral, sendo a *home* do *framework*.

Os dados relativos à produção e ao consumo de energia da planta industrial

completa são apresentados na tela inicial, dividida em três partes. A primeira apresenta valores do consumo de energia real do dia anterior e o consumo de energia previsto para o dia que ainda não foi finalizado — o dia atual. A segunda parte é uma representação gráfica do consumo de energia. A terceira parte está relacionada com a representação gráfica do indicador de desempenho energético, faixas de vazão selecionadas como relevantes.

Ainda na tela da visão geral é importante destacar a funcionalidade de exibir pontos anômalos, justificados pelos eventos que ocorreram na indústria, representados pelo balão de alerta rosa. Este balão é clicável e, no *pop-up* seguinte, o usuário poderá inserir no sistema o motivo que ocasionou esta anormalidade.

No *menu* superior o usuário poderá selecionar outros conjuntos de sistemas industriais. Cada tela específica deve apresentar dados associados a um conjunto de equipamentos para facilitar a análise.

A *interface de aplicação* deste *framework* é formada basicamente por quatro telas: (1) *login*, (2) visão geral (dados de consumo de energia geral e indicador de desempenho energético), (3) visão por área (dados de variáveis elétricas e variáveis de processo) e (4) configuração (definição dos *set point* para os alertas).

Para acessar a *interface de aplicação* o usuário deve entrar na página de *login* e inserir o nome e a senha (Figura 25a). A primeira informação que a *interface de aplicação* disponibiliza para ele é o consumo real do dia anterior. Além disso, será apresentada a predição do consumo para o dia atual (Figura 25b).

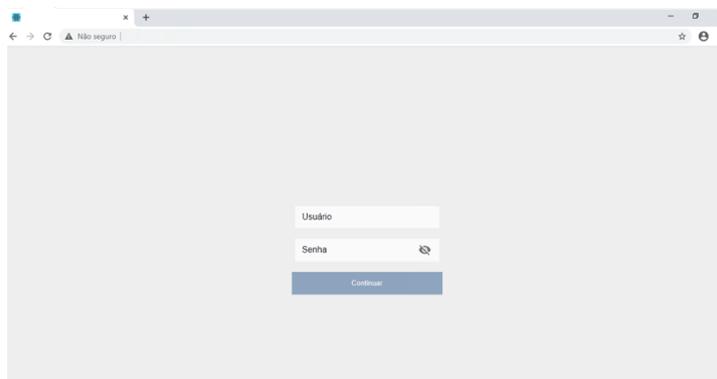
A Figura 25c expõe representado o gráfico com o consumo de energia real (curva verde) e prevista (curva azul). As curvas podem ser visualizadas simultaneamente ou uma de cada vez, basta selecionar o botão da legenda (localizado no lado direito), para habilitá-lo ou não. Objetivando a realização de consultas, compartilhamentos e análises dos dados apresentados no gráfico, é possível baixar um arquivo no formato csv com esses dados — basta clicar no botão cinza que apresenta o símbolo de *download* (localizado no lado superior direito).

Uma das funcionalidades da análise simultânea das curvas real e prevista é permitir ao usuário a comparação entre os valores de consumo de energia associados ao mesmo dia nas duas curvas. Desta forma, como o modelo de IA

utilizado apresenta uma precisão aceitável, é esperado que os dados de consumo previsto sejam próximos aos dados do consumo real. Caso o resultado seja diferente do esperado, é possível identificar alguma anomalia no sistema elétrico, que irá apontar para um possível evento na planta. Assim, foi criada uma funcionalidade nesta tela, que permite ao usuário inserir, em um ponto específico, o evento ocorrido (por exemplo: parada, alteração da vazão, equipamento ineficiente, dentre outros).

A inserção do evento pode ser realizada de forma automática ou manual. A inserção automática acontece com apenas o evento de manutenção preventiva, dado que temos um histórico desses dados. Já a inserção do evento manual (Figura 25d) é realizada de forma simples: basta clicar no ponto da curva, selecionar o evento correspondente e a duração do evento. Em seguida, será apresentado, no lado direito da curva, um contador com o número total de eventos que ocorreram no mês correspondente.

Figura 25 – Representação das telas (a) *login*, (b) visão geral — consumo de energia, (c) visão geral — gráfico do consumo de energia, e (d) visão geral — representação dos eventos.



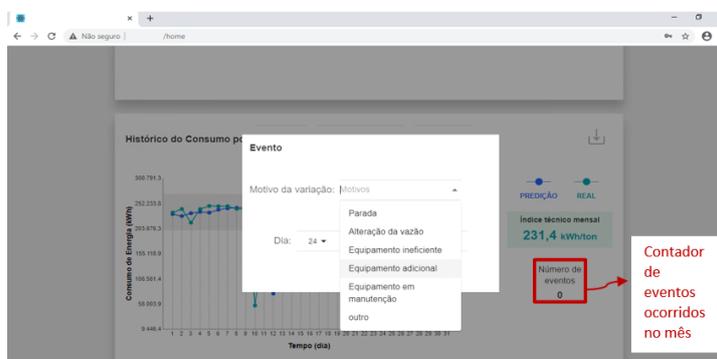
(a)



(b)



(c)



(d)

Fonte: O autor.

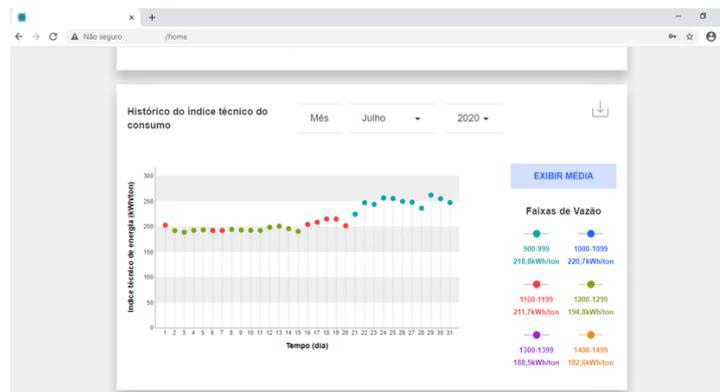
---

Outra análise possível de ser realizada por meio da curva da predição do consumo de energia é identificar se o comportamento da curva corresponde ao planejamento da indústria. Assim, um indicador de tendência foi criado para informar se a curva da predição está com o comportamento desejado. A predição do indicador de desempenho energético mensal foi selecionada como indicador de tendência. Esse indicador é atualizado diariamente, permitindo verificar o impacto de uma determinada ação nos processos que tenha afetado o resultado dessa análise do desempenho, sendo possível realizar correções no processo antes que o mês seja finalizado.

Será possível realizar o monitoramento diário do indicador de desempenho energético por faixa de vazão. Após algumas análises da melhor forma de representar essa informação, o gráfico de dispersão foi escolhido. Na Figura 26a é possível verificar, de forma simples e clara, o indicador de desempenho associado a cada dia. Também é possível identificar a faixa de vazão predominante e qual faixa não apareceu em um determinado mês, dado que cada cor representa uma faixa de vazão, além de ser possível identificar o indicador de desempenho energético. Essas informações auxiliam os gestores e funcionários da indústria a ter um maior controle da produção, e conseqüentemente do desempenho energético.

Na Figura 26b é possível verificar outra forma de visualizar os dados do indicador de desempenho energético. O gráfico em barra em tons de azul representa o monitoramento anual da média do indicador de desempenho de energia elétrica por faixa de vazão a cada ano. E, dependendo das necessidades da indústria, esses dados possibilitam identificar um indicador para ser usado como referência para os indicadores de desempenho energético dos próximos anos. O que se deseja é uma redução no valor da média do indicador com o passar dos anos.

Figura 26 – Representação da tela de visão geral (a) do gráfico do indicador de desempenho energético, e (b) do gráfico da média do indicador de desempenho energético.



(a)



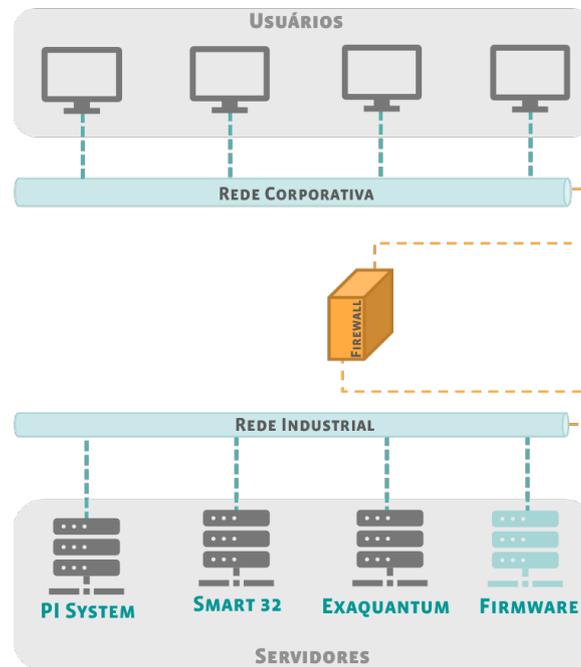
(b)

Fonte: O autor.

### 5.2.8 Infraestrutura

A infraestrutura para a implantação do *framework* na indústria de resinas termoplásticas demandou a aquisição de um servidor físico com as seguintes configurações: processador i7, memória *Random Access Memory* (RAM), tamanho 8 Gb e *Solid-State Drive* (SSD) de 256 Gb, *Hard Disk* (HD) de 500 Gb, além de uma infraestrutura de rede para que o *framework* pudesse funcionar corretamente na indústria (Figura 27).

Figura 27 – Infraestrutura de rede no estudo de caso.



Fonte: O autor.

Pelo acesso remoto ao servidor da indústria, foi possível instalar as bibliotecas e os sistemas necessários para o funcionamento do *framework*. A seguir, a descrição de algumas instalações realizadas:

- Para estruturar o *backend* foi necessário instalar: o mini conda 3 (CONDA, 2017); o mongo 4.4 (MONGODB, 2020); além de algumas bibliotecas (*keras* (PYPI, 2019b), *bcrypt* (PYPI, 2020a), *scipy* (SCIPY, 2008), *tensorflow* (TENSORFLOW, 2019), *falcon* (PYPI, 2019a), *pandas* (PANDAS, 2020), *numpy* (PYPI, 2020d), *pymongo* (PYPI, 2020e), *talos* (PYPI, 2020f), *scikit-learn* (LEARN, 2007), *gevent* (PYPI, 2020b), *xgboost* (PYPI, 2020g), *grpcio* (PYPI, 2020c), *zipp* (PYPI, 2020h)).
- Para o *front-end* foi necessária a instalação do D3.js (D3.JS, 2011), axios (AXIOS, 2014), date-fns (AXIOS, 2014) e react-csv (REACT-CSV, 2018).

- 
- Para que outros elementos de uma rede possam se conectar aos serviços do servidor (acesso à página *web* e consulta ao *back-end*) no qual o *framework* está instalado, é necessário que algumas portas sejam abertas.
  - Para acessar o BD das variáveis elétricas, foi necessária a instalação do DB Browser SQLite 3.12 (SQLITE, 2020).
  - Instalação do ZABBIX (ZABBIX, 2020) para monitorar o comportamento do *framework*, por meio do monitoramento de algumas variáveis — consumo de memória, tempo de processamento, uso de *hardware*, espaço em disco, uso de memória por processo, se o *back-end* e *front-end* estão ativos, dentre outros.

### 5.3 CONSIDERAÇÕES FINAIS

Após a realização dos diferentes experimentos para validar o funcionamento de cada módulo implementado no *framework*, bem como a interação entre eles, foi verificado que o *framework* oferece: melhorias no planejamento de produção; economia de energia elétrica; melhor gerenciamento e monitoramento dos recursos; indicação de substituição de equipamento; melhoria no processo.

Além dos experimentos, o *framework* foi implantado na indústria de resinas termoplásticas. Após sua implantação, foi possível validar e analisar suas funcionalidades através de estudos com especialistas e usuários do *framework* no estudo de caso. Seguem, abaixo, algumas das considerações ressaltadas:

- Após a inserção das medições setorizadas foi possível ter um controle ainda mais preciso do que cada setor consome, facilitando as manobras de economia de energia.
- A análise dos dados da previsão do consumo de energia possibilitou realizar ações para evitar que um comportamento indesejado pudesse acontecer. O indicador de desempenho energético previsto, mostra o impacto de cada ação no desempenho energético, com a curva de previsão.
- O monitoramento do indicador de desempenho por faixa de vazão, bem como as funcionalidades do *framework* contribuirão para o sistema de ge-

renciamento de energia. Desta forma, estarão cooperando com a certificação da ISO 50001, almejada pela indústria.

## 6 ANÁLISE DE MODELOS DE PREDIÇÃO

A base do *módulo de predição*, componente do *módulo de suporte à análise de dados*, e do *framework*, para gerenciamento de energia elétrica, é constituída pelos três modelos de predição desenvolvidos nesta pesquisa. Estes modelos utilizaram técnicas de IA. Por meio de análises comparativas das diferentes técnicas de aprendizado de máquina e aprendizado profundo — já bem definidas na literatura —, foram obtidos modelos precisos.

A etapa da pesquisa descrita neste capítulo é dedicada à análise de desempenho dos modelos de aprendizado profundo e aprendizado de máquina para a STLF (Seção 6.2) e para a MTLF (Seção 6.3) no nível da demanda, além de apresentar o modelo de predição para o indicador de desempenho energético (Seção 6.4). Os modelos foram desenvolvidos utilizando dados reais de variáveis elétricas e variáveis de processos oriundos de uma indústria de resinas termoplásticas que faz uso de energia-intensiva.

### 6.1 MATERIAL E MÉTODO

#### 6.1.1 Conjunto de Dados

Os dados utilizados neste estudo foram oriundos de uma indústria de resinas termoplásticas (a mesma indústria em que o estudo de caso do *framework* foi aplicado). Atualmente, para auxiliar o gerenciamento do desempenho energético, esta indústria faz a predição diária de energia, calculada manualmente pelos seus funcionários.

Os três conjuntos de dados disponibilizados para a realização do estudo descrito na Seção 5.1.1 foram: (1) o conjunto de dados do consumo de energia elétrica diário referente à toda planta industrial (conjunto de dados ENERGIA, ver Figura 20a, bem como os dados relacionados a duas etapas do processo de

produção, (2) o conjunto de dados da vazão de produção diária, referente ao processo de POLI (conjunto de dados PRODUÇÃO\_POLI, ver Figura 20b) e (3) o conjunto de dados da vazão de produção diária do processo de SSPOLI (conjunto de dados PRODUÇÃO\_SSPOLI, ver Figura 20c). Cada conjunto de dados apresenta um histórico de cinco anos, de 1 de janeiro de 2015 até 31 de dezembro de 2019. Desta forma, cada conjunto de dados representa 1.826 amostras. Na Figura 20 é possível visualizar a representação gráfica das três séries temporais referentes aos conjuntos de dados usados na pesquisa.

Para identificar o impacto das variações dos dados de vazão de produção diária no consumo total de energia da planta, foi realizada a análise de correlação de *Pearson* (HOLCOMB, 2016). Após a análise, foi possível afirmar haver uma correlação positiva moderada entre o conjunto de dados ENERGIA e os dois conjuntos de dados de vazão de produção (conjunto de dados PRODUÇÃO\_POLI e conjunto de dados PRODUÇÃO\_SSPOLI). O coeficiente de correlação entre o conjunto de dados ENERGIA e o conjunto de dados PRODUÇÃO\_POLI foi de 0,71, enquanto a relação entre o conjunto de dados ENERGIA e o conjunto de dados PRODUÇÃO\_SSPOLI foi de 0,75. Assim, foi tomada a decisão de incluir todas as três séries temporais (ENERGIA, PRODUÇÃO\_POLI, PRODUÇÃO\_SSPOLI) como entrada para os modelos de predição do consumo de energia elétrica STLF, MTLF e o modelo de predição da vazão de produção.

### 6.1.2 Pré-processamento dos dados

Valores ausentes e erros de medição podem levar a resultados imprevisíveis. Para evitar removê-los, os dados anômalos foram preenchidos com dados imputados e depois normalizados. Para o primeiro, os dados ausentes foram substituídos pela média dos dados dos sete dias anteriores, de acordo com (PEPPANEN et al., 2016; DEMIRHAN; RENWICK, 2018; ANDIOJAYA; DEMIRHAN, 2019). Em seguida, os dados foram normalizados para que todas as entradas do modelo tivessem pesos iguais e a função de ativação de *sigmoid* pudesse ser aplicada nos modelos de aprendizado profundo e aprendizado de máquina ( (AZADEH; GHADERI; SOHRABKHANI, 2008; BERRIEL et al., 2017; KUO; HUANG, 2018)). A normalização

reduziu o intervalo de dados das séries temporais para valores  $[0, 1]$ . A função *MinMaxScaler* da biblioteca *Sklearn* (LEARN, 2007) foi utilizada, neste estudo, para normalizar os dados, com base na Equação 6.1, na qual  $X'_i$  representa o dado normalizado,  $X_i$  representa o dado real,  $\min(x)$  e  $\max(x)$  representam os valores mínimos e máximos do conjunto de dados, respectivamente.

$$X'_i = \frac{X_i - \min(x)}{\max(x) - \min(x)} \quad (6.1)$$

### 6.1.3 Métricas de avaliação

Para avaliar quantitativamente os modelos de predição do consumo de energia STLF, MTLF e o modelo de predição da vazão de produção, três métricas de regressão foram utilizadas: RMSE, MAPE e MAE.

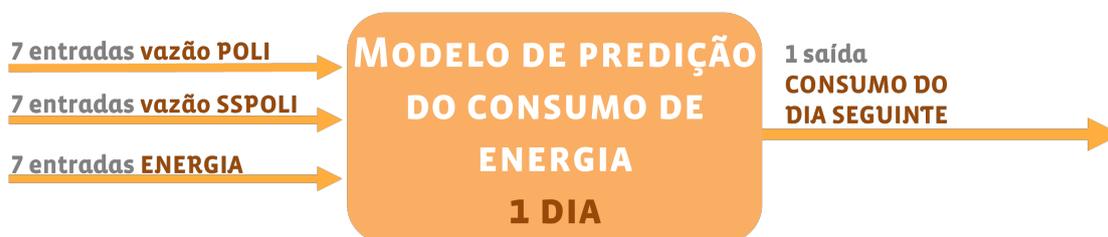
## 6.2 PREDIÇÃO DO CONSUMO DE ENERGIA DE CURTO PRAZO

Devido às características não lineares dos três conjuntos de dados usados nesta pesquisa, além da necessidade de precisão e tempo de execução reduzido para os modelos, e aos resultados promissores obtidos em outros trabalhos que usaram aprendizado profundo (BERRIEL et al., 2017; KONG et al., 2017; LAGO; RIDDER; SCHUTTER, 2018; GÜNGÖR; AKŞANLI; AYDOĞAN, 2019), três técnicas de aprendizado profundo foram selecionadas para STLF: RNN simples, LSTM e GRU. Além dessas técnicas, duas técnicas diferentes de aprendizado de máquina foram selecionadas para fins de comparação - SVR e *Random Forest*. Estas foram selecionadas porque são comumente aplicadas em trabalhos relacionados no STLF para consumo de energia do lado da demanda (RYU; NOH; KIM, 2017; CHEN et al., 2018).

Todos os modelos propostos utilizam dados de três séries temporais (ver Figura 20) como entrada: (i) consumo de energia elétrica diário, (ii) vazão de produção de POLI e (iii) vazão de produção de SSPOLI, e têm uma única saída, o valor da predição do consumo de energia. Para cada entrada, o modelo

usa dados dos sete dias anteriores. Desta forma, são utilizadas, no total, 21 entradas para os modelos STLF (Figura 28).

Figura 28 – Configuração do modelo STLF.



Fonte: O autor.

### 6.2.1 Configuração do modelo de aprendizado profundo

Para determinar a configuração mais adequada para cada modelo de aprendizado profundo, foi utilizado o método *grid search*. O objetivo é encontrar os respectivos hiperparâmetros (SAMSUDIN; SHABRI; SAAD, 2010; KAVAKLIOGLU, 2011; BERGSTRA; BENGIO, 2012; YOON et al., 2017; LIAO; CHANG; CHANG, 2020). O *grid search* é amplamente utilizado porque é rápido de implementar, trivial para paralelizar e intuitivamente permite que todo o espaço de busca seja explorado (YOUNG et al., 2015; KHALID; JAVAID, 2020).

Para realizar o *grid search*, os dados foram separados em um conjunto de treinamento que consiste em 80% do conjunto de dados original (de 1 de janeiro de 2015 a 30 de dezembro de 2018) e um conjunto de teste, compreendendo 20% do conjunto de dados original (a partir de 31 de dezembro 2018 a 31 de dezembro de 2019), aplicando o *percentage split*. Os hiperparâmetros avaliados pelo *grid search* para técnicas de aprendizado profundo foram (i) o número de camadas e (ii) o número de neurônios em cada camada (RETRIEVED, 2019) (Tabela 9).

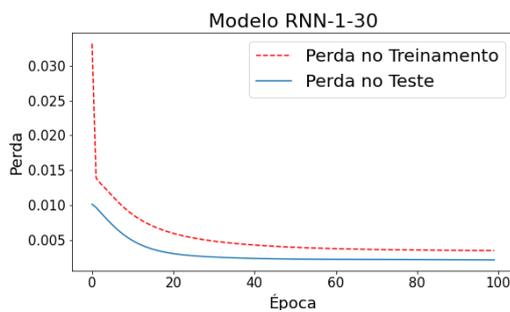
A Figura 29 apresenta a convergência da perda durante a etapa de treinamento e a etapa de teste dos modelos baseados em aprendizado profundo. Verifica-se que os modelos não estão superdimensionados e convergem após cerca de 40 épocas para o conjunto de treino (estabilização da perda). Além disso, não apresentaram *over-fitting*.

Tabela 9 – Parâmetros e níveis utilizados no *grid search*.

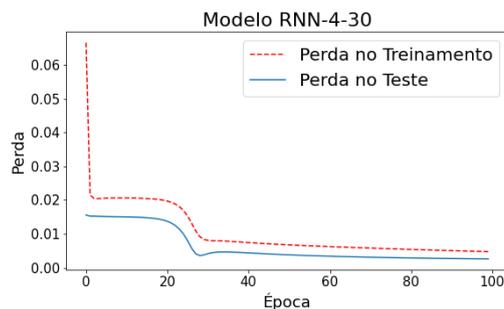
Parâmetros	Níveis
Número de neurônios	De 10 até 90, incrementos de 20
Número de camadas	De 1 até 4, incrementos de 1

Fonte: O autor.

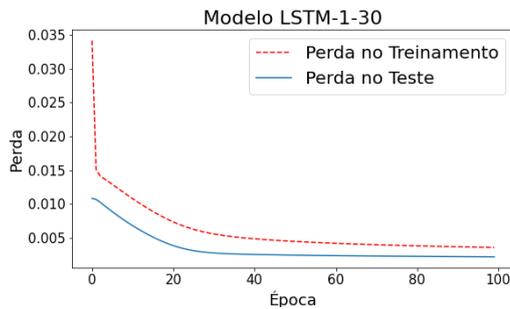
Figura 29 – Resultados da análise da convergência para os modelos de aprendizado profundo baseados em (a) RNN-1-30, (b) RNN-4-30, (c) LSTM-1-30, e (d) GRU-1-30.



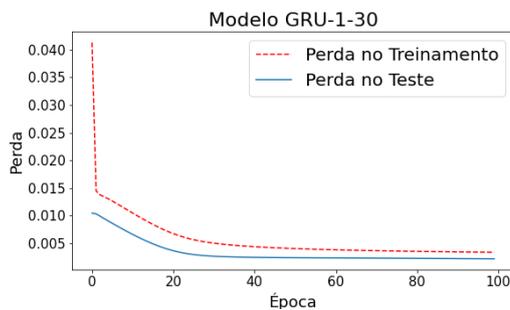
(a)



(b)



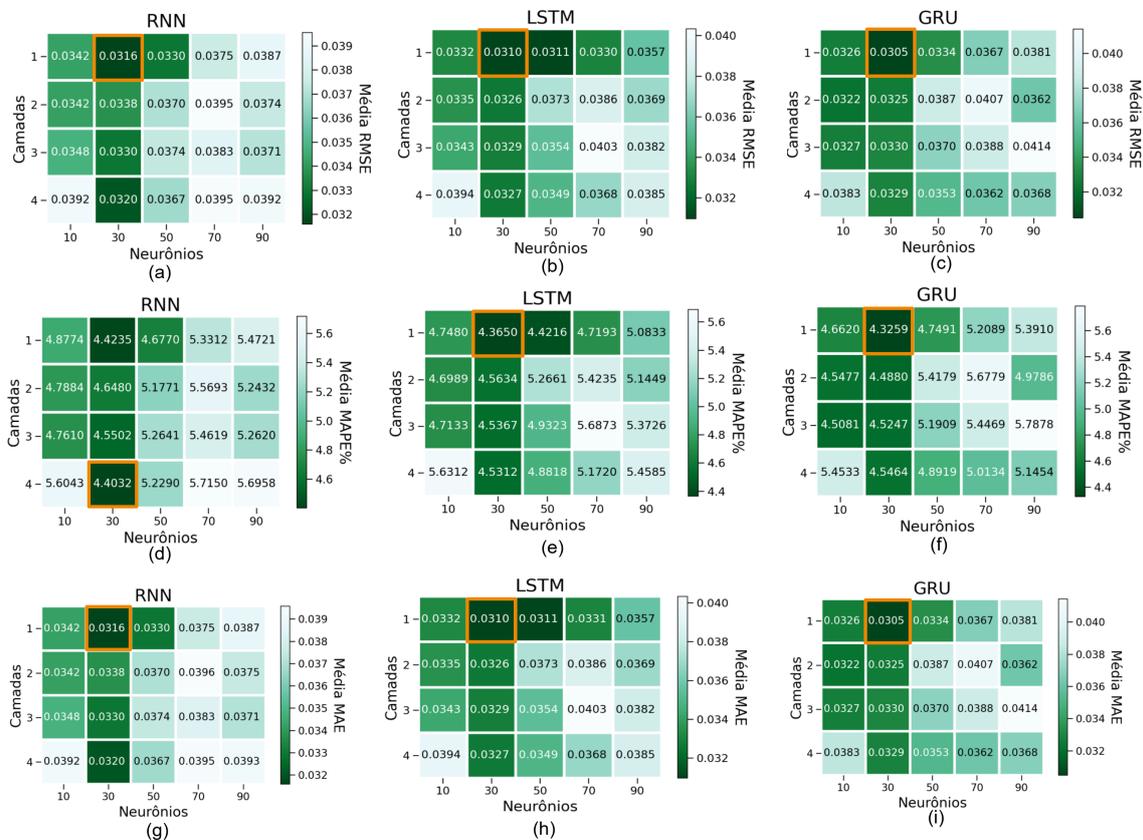
(c)



Para modelos de aprendizado profundo, os seguintes parâmetros foram fixados: 100 épocas com base na Figura 29, um tamanho de lote de 16, *sigmoid* (HAN; MORAGA, 1995), como a função de ativação, MSE, como a função de perda e um método para otimização estocástica (Adam) como otimizador. Esses parâmetros foram escolhidos empiricamente. Devido à natureza estocástica do processo de otimização, o *grid search* foi realizado 30 vezes, e as médias do RMSE, MAPE e MAE foram calculadas.

As Figuras 30a - 30i apresentam os resultados normalizados do *grid search* para o modelo STLF baseado nas técnicas de aprendizado profundo — RNN (Figuras 30a, 30d e 30g), LSTM (Figuras 30b, 30e e 30h) e GRU (Figuras 30c, 30f e 30i). A configuração com uma camada e 30 neurônios gerou os melhores modelos — RNN-1-30, LSTM-1-30 e GRU-1-30 — para todas as técnicas de aprendizado profundo, exceto em uma instância, em que a média do MAPE apresentou o melhor resultado para RNN, com uma configuração de quatro camadas e 30 neurônios (ver Figura 30d), ou seja, RNN-4-30. Essas quatro configurações de modelo serão usadas na avaliação com os modelos *baselines*.

Figura 30 – Resultado do *grid search* para o modelo STLF baseado em técnicas de aprendizado profundo.



Fonte: O autor.

### 6.2.1.1 Configuração do modelo de aprendizado de máquina

Semelhante aos modelos de aprendizado profundo, também foi aplicado o *grid search* para encontrar os melhores hiperparâmetros dos modelos de aprendizado de máquina, usando o mesmo procedimento de divisão do conjunto de dados. Os hiperparâmetros usados variam de acordo com a técnica utilizada (Tabela 10). Para SVR, o parâmetro de regularização  $C$  e o tipo de *kernel* foram usados (RETRIEVED, 2018), enquanto no *Random Forest* foram utilizados a profundidade máxima das árvores e o número de árvores.

As Figuras 31a - 31f apresentam os resultados do *grid search* para o modelo

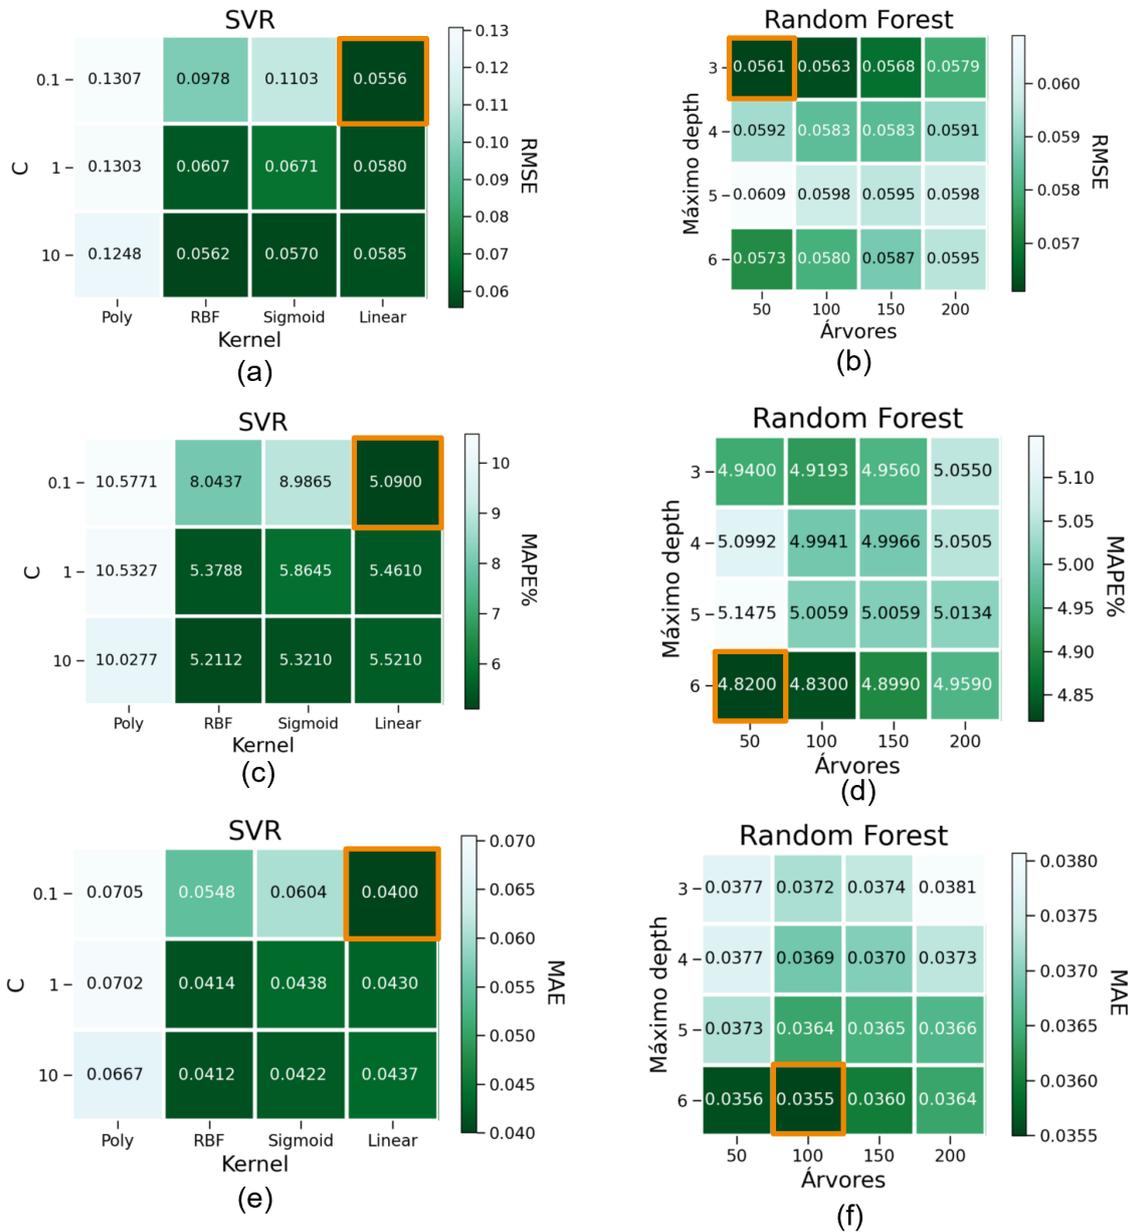
Tabela 10 – Parâmetros e níveis utilizados no *grid search*.

Técnicas	Parâmetros	Níveis
SVR	Número C	0,1, 1 e 10
SVR	Tipo de <i>kernel</i>	Polinomial, RBF, <i>sigmoid</i> e linear
<i>Random Forest</i>	Número máx. de <i>depth</i>	De 3 até 6, incrementos de 1
<i>Random Forest</i>	Número de árvores	De 50 até 200, incrementos de 50

**Fonte:** O autor.

STLF baseado em técnicas de aprendizado de máquina. Para SVR (Figuras 31a, 31c e 31e), a melhor configuração nas três métricas usadas — RMSE, MAPE e MAE — é representada por SVR-0.1-linear, cujo valor C é 0.1 e usa o *kernel* linear. Para *Random Forest*, os modelos configurados com (a) profundidade máxima de três e com 50 árvores (*Random Forest-3-50*), (b) profundidade máxima de seis e com 50 árvores (*Random Forest-6-50*), e (c) profundidade máxima de seis e com 100 árvores (*Random Forest-6-100*) geraram os melhores resultados para RMSE, MAPE e MAE, respectivamente. Essas quatro configurações de modelo serão usadas em nossa avaliação com os modelos definidos como *baselines*.

Figura 31 – Resultado do *grid search* para o modelo STLF baseado em técnicas de aprendizado de máquina.



Fonte: O autor.

### 6.2.2 Baselines

Dois *baselines* adicionais foram selecionados para fins de comparação. O primeiro é a técnica manual usada pela indústria de resinas termoplásticas. O segundo é um modelo ARIMA, selecionado devido ao seu uso em predição de energia e, em particular, em trabalhos relacionados (RYU; NOH; KIM, 2017) e ainda por ser uma técnica clássica de predição.

A técnica manual utilizada pela indústria de resinas termoplásticas se baseia em um cálculo simples, de acordo com a Equação 6.2, em que o consumo de energia de um determinado dia  $C_{previsto}$  corresponde à relação entre a vazão de produção planejada ( $F_{planejado}$ ) e o indicador de desempenho energético ( $n_{anterior}$ ) com base na medição dos dados coletados no dia anterior.

$$C_{previsto} = F_{planejado} * n_{anterior} \quad (6.2)$$

A escolha do modelo ARIMA para este estudo foi baseada na natureza das séries temporais do conjunto de dados. A Equação 6.3 (PUSHP, 2010) representa a expressão matemática para a parte autorregressiva.

$$x(t) = \sum_{i=1}^p \alpha_i x(t-i) \quad (6.3)$$

onde:  $t$  é o índice representado por um número inteiro;  $x(t)$  é o valor estimado;  $p$  é o número de termos autorregressivos; e  $\alpha$  é o polinômio relacionado ao operador autorregressivo de ordem  $p$ .

A Equação 6.4 (PUSHP, 2010) reflete a dependência dos valores da série temporal sobre os erros das estimativas anteriores, ou seja, os erros da predição são levados em consideração ao estimar o próximo valor na série temporal.

$$x(t) = \sum_{i=1}^q \beta_i \varepsilon(t-i) \quad (6.4)$$

onde:  $q$  é o número de termos de média móvel;  $\beta$  é o polinômio relacionado ao operador de média móvel da ordem  $q$ ; e  $\varepsilon$  é a diferença entre os valores estimados e reais de  $x(t)$ .

A Equação 6.5 (PUSHP, 2010) é uma combinação das Equações 6.3 e 6.4, representa o modelo ARIMA  $(p, q)$  usado como referência para este estudo.

$$x(t) = \sum_{i=1}^p \alpha_i x(t-i) - \sum_{i=1}^q \beta_i \varepsilon(t-i) \quad (6.5)$$

Após a análise empírica, o modelo ARIMA selecionado apresentou a ordem da autorregressiva  $(p = 1)$ , o grau de diferenciação  $(d = 0)$ , e a ordem da média móvel  $(q = 1)$ .

### 6.2.3 Resultados modelo de predição do consumo de energia de curto prazo

A Tabela 11 apresenta os valores do RMSE, MAPE e MAE para os quatro modelos de aprendizado profundo (RNN-1-30, RNN-4-30, LSTM-1-30 e GRU-1-30), para os quatro modelos de aprendizado de máquina (SVR-0.1-linear, *Random Forest-3-50*, *Random Forest-6-50* e *Random Forest-3-100*) identificados como as melhores configurações pelo método de *grid search*, bem como para os modelos *baselines* — manual e ARIMA.

Com base na métrica RMSE, os modelos de aprendizado profundo superaram os modelos de aprendizado de máquina e os *baselines* manual e ARIMA. Esse comportamento pode ser explicado pela capacidade dos modelos de aprendizado profundo de obter *insights* fora do domínio dos dados de treinamento. O modelo GRU apresentou o melhor desempenho dentre todos os modelos testados, além de reduzir a complexidade inerente aos demais modelos de aprendizado profundo; os modelos baseados em RNN simples apresentaram os piores desempenhos. No entanto, com base nas métricas MAPE e MAE, o modelo ARIMA superou os modelos de aprendizado profundo, os de aprendizado de máquina e a abordagem manual *baselines*.

A Tabela 12 apresenta as médias do tempo de inferência e seus respectivos desvios-padrão para os quatro modelos de aprendizado profundo (RNN-1-30, RNN-4-30, LSTM-1-30 e GRU-1-30), para os quatro modelos de aprendizado de

Tabela 11 – Resultados das métricas dos melhores modelos de aprendizado profundo.

Modelos	RMSE	MAPE (%)	MAE
ARIMA	0,0471	3,52	0,0249
RNN-1-30	0,0316	4,42	0,0316
RNN-4-30	0,0320	4,40	0,0320
LSTM-1-30	0,0310	4,37	0,0310
GRU-1-30	0,0305	4,33	0,0305
SVR-0.1-linear	0,0556	5,09	0,0400
<i>Random Forest-3-50</i>	0,0561	4,94	0,0377
<i>Random Forest-6-50</i>	0,0573	4,82	0,0356
<i>Random Forest-6-100</i>	0,0580	4,83	0,0355
Manual	0,4119	51,61	0,4039

Fonte: O autor.

máquina (SVR-0.1-linear, *Random Forest-3-50*, *Random Forest-6-50* e *Random Forest-6-100*), bem como para os *baselines* (manual e ARIMA).

Tabela 12 – Média do tempo de inferência para os modelos.

Modelos	Média do tempo de inferência (s)
<b>ARIMA</b>	56,3565 ± 0,6802
<b>RNN-1-30</b>	0,3896 ± 0,1289
<b>RNN-4-30</b>	0,5939 ± 0,2070
<b>LSTM-1-30</b>	0,6751 ± 0,2480
<b>GRU-1-30</b>	0,7058 ± 0,2866
<b>SVR-0.1-linear</b>	0,0014 ± 0,0004
<b><i>Random Forest-3-50</i></b>	0,0043 ± 0,0004
<b><i>Random Forest-6-50</i></b>	0,0046 ± 0,0001
<b><i>Random Forest-6-100</i></b>	0,0080 ± 0,0012

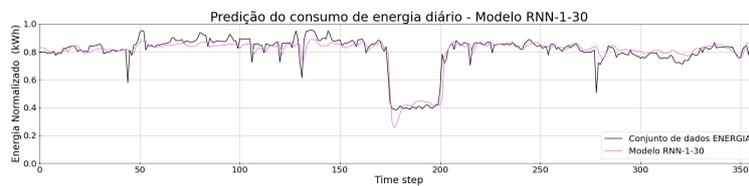
**Fonte:** O autor.

Os modelos de aprendizado profundo e aprendizado de máquina tiveram melhores desempenhos, apresentando como média do tempo de inferência valores de 0,8 e 0,0085, respectivamente, com desvios-padrão insignificantes. O *Random Forest-3-50* é o modelo com o menor tempo médio de inferência dentre aqueles comparados. O modelo ARIMA é o modelo de pior desempenho, quando comparado aos modelos de aprendizado de máquina e aprendizado profundo. Apesar de alcançar bons resultados de RMSE, MAPE e MAE, o tempo de inferência do modelo ARIMA é muito maior do que os dos modelos de aprendizado profundo, o que constitui uma limitação significativa para uso prático, visto que o *framework* deverá permitir que os dados das previsões sejam apresentados para o usuário em tempo real, não interferindo na funcionalidade da aplicação.

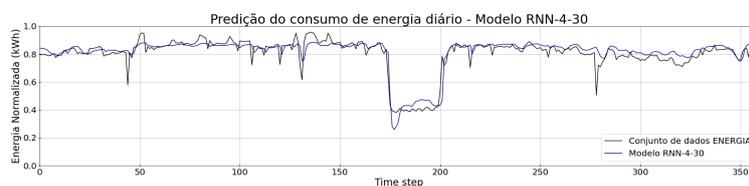
As Figuras 32, 33 e 34 ilustram as previsões de carga diária para os modelos de aprendizado profundo, aprendizado de máquina e os *baselines* — manual e ARIMA — comparados com os dados reais. Isso mostra claramente que os modelos de aprendizado profundo propostos (Figuras 32a e 32d) são muito semelhantes aos dados verdadeiros, em comparação com a técnica manual usada

na indústria de resinas termoplásticas (Figura 34b).

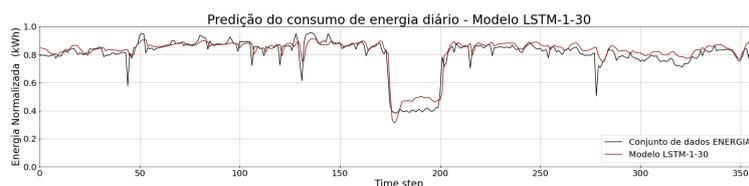
Figura 32 – Predição do consumo de energia usando (a) o modelo RNN-1-30, (b) o modelo RNN-4-30, (c) o modelo LSTM-1-30, e (d) o modelo GRU-1-30.



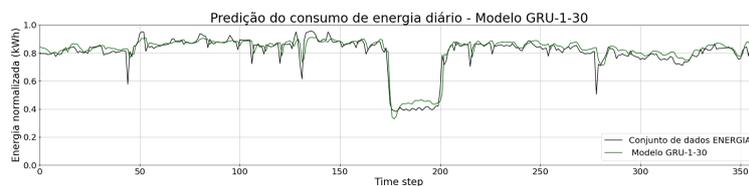
(a)



(b)



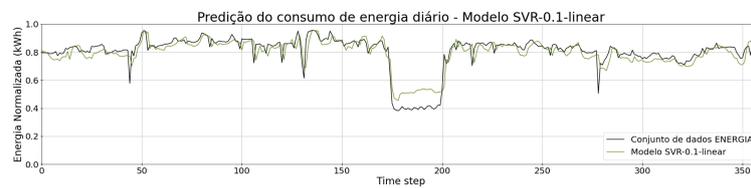
(c)



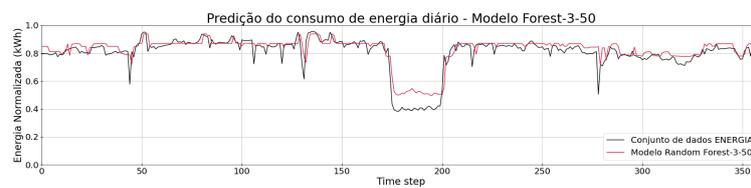
(d)

Fonte: O autor.

Figura 33 – Predição do consumo de energia usando (a) o modelo SVR-0.1-linear, (b) o modelo *Random Forest-3-50*, (c) o modelo *Random Forest-6-50*, e (d) o modelo *Random Forest-6-100*.



(a)



(b)



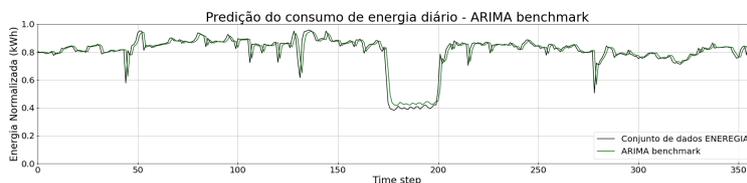
(c)



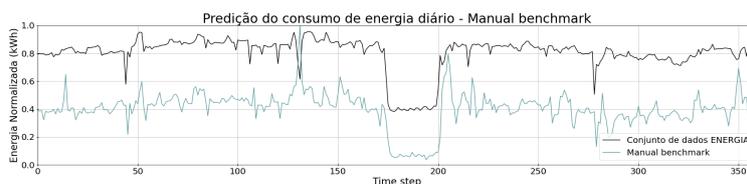
(d)

Fonte: O autor.

Figura 34 – Predição do consumo de energia usando (a) o modelo manual e (b) o modelo ARIMA.



(a)



(b)

Fonte: O autor.

### 6.2.3.1 Teste estatístico Diebold-Mariano

A Tabela 11 apresentada no início da Seção 6.2.3 sugere que GRU-1-30 e ARIMA obtiveram os melhores resultados para as métricas RMSE, MAPE e MAE, respectivamente. Como os valores do RMSE, MAPE e MAE são muito semelhantes, o teste estatístico DM (DIEBOLD, 2015) foi aplicado para confirmar os resultados. A Tabela 13 apresenta os resultados obtidos.

Tabela 13 – Resultados do teste estatístico DM.

	ARIMA	RNN-1-30	RNN-4-30	LSTM-1-30	GRU-1-30	SVR-0.1-linear	Random Forest-3-50	Random Forest-6-50	Random Forest-6-100
Manual	51,38	51,55	51,27	50,79	51,30	51,06	50,20	49,76	49,70
ARIMA	-	-0,54	-0,83	-1,46	0,45	-2,96	-3,36	-2,95	-3,18
RNN-1-30	-	-	-1,39	-1,34	1,99	-2,43	-2,76	-2,41	-2,56
RNN-4-30	-	-	-	-0,99	3,04	-2,07	-2,57	-2,25	-2,40
LSTM-1-30	-	-	-	-	6,56	-1,96	-2,81	-2,37	-2,54
GRU-1-30	-	-	-	-	-	-3,87	-4,47	-3,61	-3,71
SVR-0.1-linear	-	-	-	-	-	-	-0,24	-0,78	-1,08
Random Forest-3-50	-	-	-	-	-	-	-	-0,76	-1,15
Random Forest-6-50	-	-	-	-	-	-	-	-	-1,83

Fonte: O autor.

Como referência, o resultado do teste estatístico DM é igual a zero, quando

as técnicas testadas são iguais; valores negativos indicam que a técnica à esquerda obtém melhor desempenho; e os valores positivos indicam que a técnica à esquerda apresenta pior desempenho. Se os valores absolutos do resultado do teste estatístico DM forem altos, as técnicas testadas têm valores de predição significativamente diferentes. A primeira linha da Tabela 13 compara o modelo do cálculo manual utilizado pela indústria com todos os outros modelos.

Pode-se perceber que a técnica manual utilizada na indústria de resinas termoplásticas apresenta o pior desempenho, quando comparada com todos os modelos analisados. Os altos valores estatísticos obtidos para esta técnica confirmam que ela é sub-ótima para STLF neste caso. O único modelo que superou o modelo ARIMA foi o GRU-1-30. Todos os modelos de aprendizado profundo superam os modelos de aprendizado de máquina. No entanto, a variação nos valores do teste estatístico DM não é tão significativa.

Embora os valores dos resultados do teste estatístico DM para modelos de aprendizado profundo sejam semelhantes, o modelo GRU-1-30 obteve os melhores índices de predição, quando comparado a todos os modelos testados. Assim, as hipóteses iniciais sobre os resultados do *grid search* são confirmadas. Desta forma, o modelo STLF utilizado no *módulo de predição* foi baseado no modelo GRU-1-30.

### 6.3 PREDIÇÃO DO CONSUMO DE ENERGIA DE MÉDIO PRAZO

O modelo de predição de consumo de energia elétrica MTLF foi definido com o intuito de ser integrado ao *módulo de predição* do *framework* para gerenciamento de energia elétrica. Desta forma, foram utilizadas seis diferentes técnicas para definir os modelos, sendo três baseadas em aprendizado profundo — RNN, LSTM e GRU — e as outras, baseadas em aprendizado de máquina — SVR, *Random Forest* e XGBoost. Para definição dos modelos, foram utilizados os três conjuntos de dados disponibilizados pela indústria de resinas termoplásticas: ENERGIA, PRODUÇÃO\_POLI, PRODUÇÃO\_SSPOLI.

As entradas e saídas dos modelos de predição do consumo de energia elétrica MTLF são caracterizadas por apresentar 21 entradas e 30 saídas. As entradas

do modelo são representadas por dados de variáveis elétricas (7 entradas de dados de consumo de energia diário de dias anteriores) e dados de variáveis de processo (7 entradas de vazão de produção diária referentes ao processo de POLI e 7 variáveis referentes ao processo de SSPOLI) (Figura 35).

Seguindo a mesma metodologia utilizada para análise do desempenho dos modelos de predição do consumo de energia elétrica STLF (Seção 6.2), o *grid search* foi aplicado para os modelos MTLF. Desta forma, foi definido que 80% do conjunto de dados originais seriam utilizados na etapa de treinamento e os dados restantes na etapa de teste.

Figura 35 – Configuração do modelo MTLF.



Fonte: O autor.

### 6.3.1 Configuração do modelo de aprendizado profundo

Na Tabela 14 são apresentados os hiperparâmetros avaliados no *grid search* das configurações que fizeram uso das técnicas de aprendizado profundo.

Tabela 14 – Parâmetros e níveis utilizados no *grid search*.

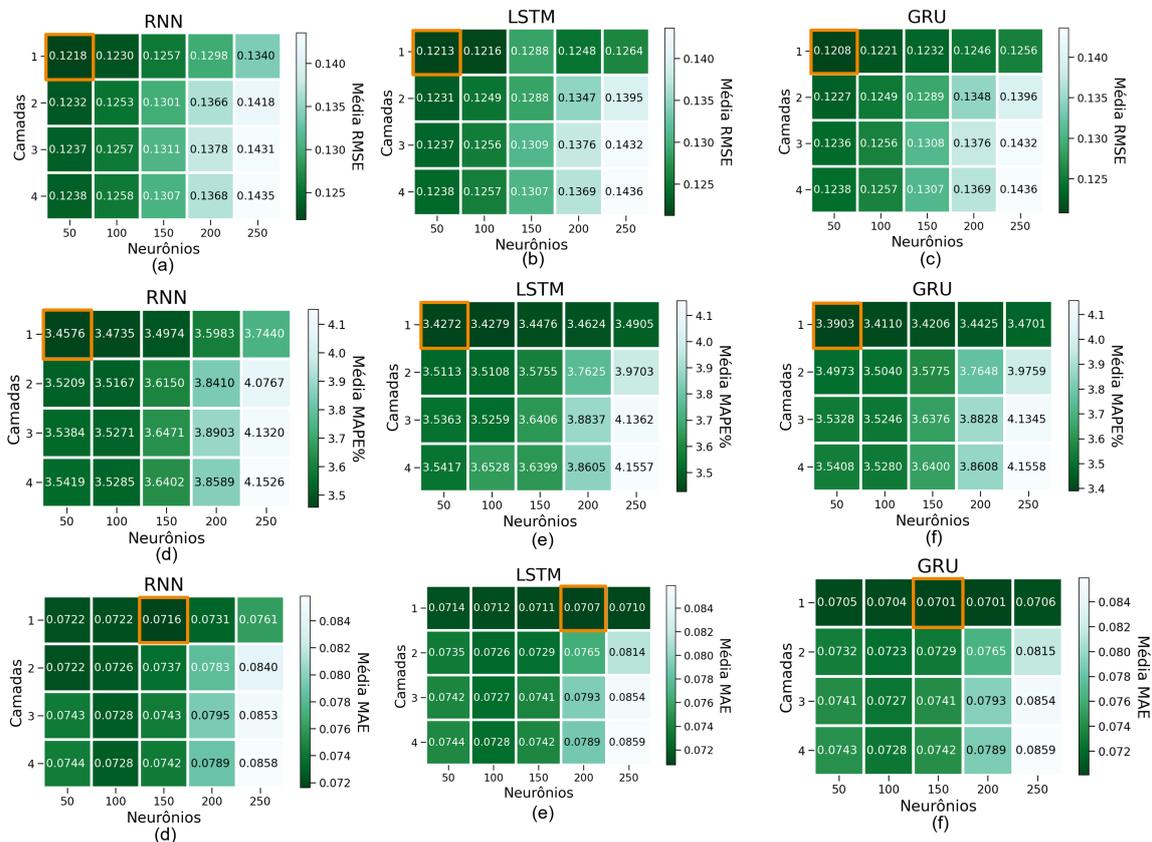
Parâmetros	Níveis
Número de neurônios	De 50 até 250, incrementos de 50
Número de camadas	De 1 até 4, incrementos de 1

Fonte: O autor.

Como o processo de otimização dos modelos de aprendizado profundo tem uma natureza estocástica, novamente o *grid search* foi realizado 30 vezes. Assim,

nas Figuras 36a - 36i é possível analisar a média dos resultados normalizados do *grid search* para o modelo MTLF baseados nas técnicas de aprendizado profundo — RNN (Figuras 36a, 36d e 36g), LSTM (Figuras 36b, 36e e 36h) e GRU (Figuras 36c, 36f e 36i). A configuração com uma camada e 50 neurônios gerou os melhores modelos quando analisamos as métricas RMSE e MAPE — RNN-1-50, LSTM-1-50 e GRU-1-50 — para todas as técnicas de aprendizado profundo. Analisando a métrica MAE as configurações que apresentaram os melhores resultados foram: RNN-1-150, LSTM-1-200 e GRU-1-150. Essas seis configurações de modelo serão usadas na avaliação com do melhor modelo.

Figura 36 – Resultado do *grid search* para o modelo MTLF baseado em técnicas de aprendizado profundo.



Fonte: O autor.

### 6.3.2 Configuração do modelo de aprendizado de máquina

Na Tabela 15 são apresentados os hiperparâmetros avaliados no *grid search* das configurações que fizeram uso das técnicas de aprendizado de máquina. Como é possível observar, os hiperparâmetros usados variam de acordo com a técnica aplicada. Para SVR, o parâmetro de regularização C e o tipo de *kernel* foram usados, enquanto, para o *Random Forest* e o *XGBoost*, foram utilizados a profundidade máxima das árvores e o número de árvores.

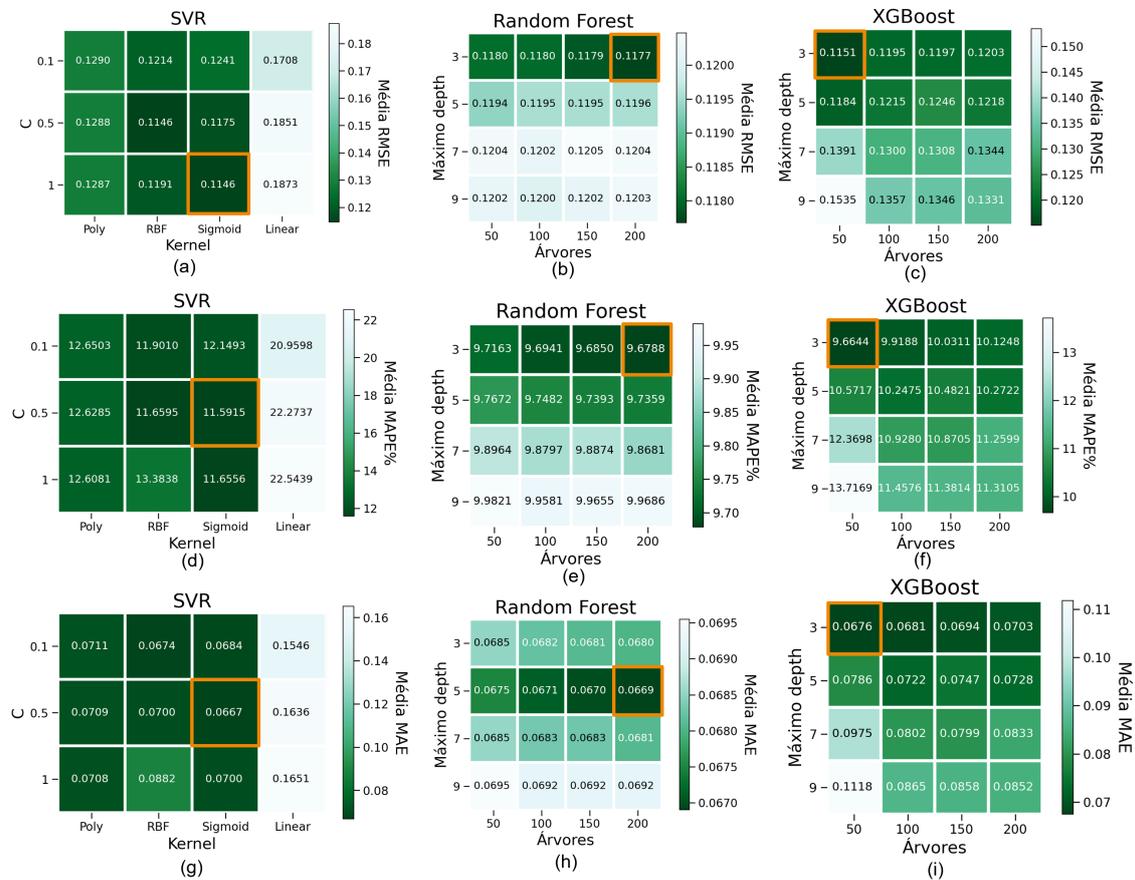
Tabela 15 – Parâmetros e níveis utilizados no *grid search*.

Técnicas	Parâmetros	Níveis
SVR	Número C	0,1, 0,5 e 1
SVR	Tipo de <i>kernel</i>	Polinomial, RBF, <i>sigmoid</i> e linear
<i>Random Forest</i>	Número máx. de <i>depth</i>	De 3 até 9, incrementos de 2
<i>Random Forest</i>	Número de árvores	De 50 até 200, incrementos de 50
<i>XGBoost</i>	Número máx. de <i>depth</i>	De 3 até 9, incrementos de 2
<i>XGBoost</i>	Número de árvores	De 50 até 200, incrementos de 50

**Fonte:** O autor.

As Figuras 37a - 37i apresentam os resultados do *grid search* para o modelo MTLF baseado em técnicas de aprendizado de máquina. Para SVR (Figuras 37a, 37c e 37e), a melhor configuração nas métricas MAPE e MAE é representada por SVR-0.5-sigmoid. Já para a métrica RMSE a melhor configuração é representada pelo modelo SVR-1-sigmoid. Para *Random Forest*, os modelos configurados com *Random Forest-3-200* e *Random Forest-5-200* apresentaram os melhores desempenhos. Já para o *XGBoost* a configuração com profundidade igual a três e número de árvores igual a 50 (*XGBoost-3-50*) foi a que apresentou o melhor desempenho para todas as três métricas analisadas.

Figura 37 – Resultado do *grid search* para o modelo MTLF baseado em técnicas de aprendizado de máquina.



Fonte: O autor.

### 6.3.3 Resultados do modelo de previsão do consumo de energia de médio prazo

A Tabela 16 apresenta os resultados referentes às métricas analisadas — RMSE, MAPE e MAE — para a melhor configuração de cada um dos onze modelos, seis deles baseados em aprendizado profundo e os outros cinco baseados em aprendizado de máquina.

Tabela 16 – Resultado das melhores configurações do MTLF.

Modelo	RMSE	MAPE(%)	MAE
RNN-1-50	0,1218	3,4576	0,0722
RNN-1-150	0,1257	3,4974	0,0716
LSTM-1-50	0,1213	3,4272	0,0714
LSTM-1-200	0,1248	3,4624	0,0707
GRU-1-50	0,1208	3,3903	0,0705
GRU-1-150	0,1232	3,4206	0,0701
SVR-0.5- <i>sigmoid</i>	0,1175	11,5915	0,0667
SVR-1- <i>sigmoid</i>	0,1146	11,6556	0,0700
<i>Random Forest</i> -3-200	0,1177	9,6788	0,0680
<i>Random Forest</i> -5-200	0,1195	9,7359	0,0669
XGBoost-3-50	0,1151	9,6644	0,0675

**Fonte:** O autor.

Com base nas três métricas e analisando os modelos oriundos das técnicas de aprendizado profundo, o modelo GRU-1-50 apresentou o melhor desempenho em relação às outras duas técnicas (RNN e LSTM). Já o modelo RNN-1-150 apresentou os piores resultados para RMSE e MAPE.

Analisando a métrica MAPE, todos os modelos de aprendizado profundo apresentaram melhores resultados, quando comparados com os modelos de aprendizado de máquina. Já a análise das métricas RMSE e MAE mostram que os modelos de aprendizado profundo apresentaram piores resultados para todas as configurações, quando comparados com as configurações dos modelos de aprendizado de máquina.

Através da análise tradicional, foi observado que para cada métrica analisada, há uma configuração diferente para o melhor resultado. Objetivando obter uma outra análise comparativa entre os diferentes modelos, o procedimento MCS foi aplicado, baseado em testes de equivalência e aplicação de regra de eliminação. Neste procedimento não há necessidade de definição de um modelo

*benchmark* (HANSEN; LUNDE; NASON, 2011). Os resultados do procedimento aplicado incluíram as configurações: RNN-1-50, LSTM-1-50, GRU-1-50, SVR-0,5-*sigmoid*, SVR-1-*sigmoid* e XGBoost. Os resultados obtidos excluíram as configurações: RNN-1-150, LSTM-1-200 e GRU-1-150 (Tabela 17).

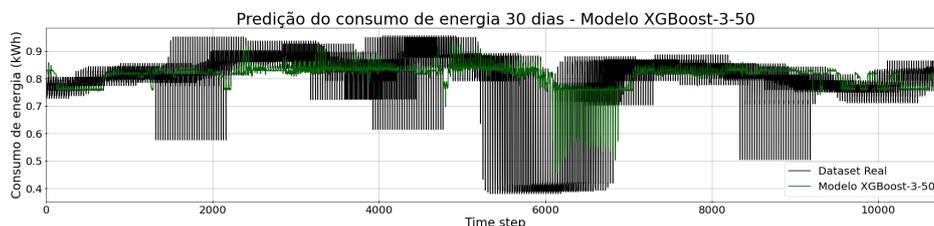
Tabela 17 – Resultados do MCS do MTLF.

Modelo	P-valor
LSTM-1-200	0,011
RNN-1-150	0,063
GRU-1-150	0,064
RNN-1-50	0,168
LSTM-1-50	0,170
GRU-1-50	0,175
<i>Random Forest-5-200</i>	0,365
<i>SVR-0.5-sigmoid</i>	0,403
<i>Random Forest-3-200</i>	0,795
<i>SVR-1-sigmoid</i>	0,795
XGBoost-3-50	1,000

**Fonte:** O autor.

Pela seleção do modelo tradicional, analisando as métricas separadamente, os modelos SVR-1-*sigmoid*, GRU-1-50 e SVR-0,5-*sigmoid* apresentaram os melhores desempenhos dentre as métricas analisadas RMSE, MAPE e MAE, respectivamente. Mas, após a aplicação do MCS, a configuração que apresentou o p-valor igual a um foi o modelo XGBoost-3-50. Na Figura 38 é possível comparar a curva dos valores reais e a curva de predição do consumo diário do modelo XGBoost-3-50. Devido ao seu melhor desempenho, a configuração XGBoost-3-50 será utilizada no *módulo de predição* do *framework* para gerenciamento de energia elétrica, a fim de prever o consumo de energia elétrica de médio prazo (30 dias posteriores).

Figura 38 – Predição do modelo que apresentou o melhor desempenho XGBoost-3-50.



Fonte: O autor.

#### 6.4 PREDIÇÃO DA VAZÃO DE PRODUÇÃO DE MÉDIO PRAZO

Assim como o modelo de predição do consumo diário de energia de médio prazo, apresentado na seção anterior, o modelo de predição da vazão diária POLI precisou ser implementado para compor o *módulo de predição do framework* de gerenciamento de energia elétrica. Para isso, foram selecionadas seis técnicas de IA (RNN, LSTM, GRU, SVR, *Random Forest* e XGBoost), por serem utilizadas em modelos de predição em diferentes contextos de aplicação.

Com o objetivo de identificar a configuração que apresentava a melhor precisão na predição da vazão diária de produção, foram utilizados três conjuntos de dados diferentes — ENERGIA, PRODUÇÃO\_POLI e PRODUÇÃO\_SSPOLI. As entradas dos modelos foram representadas por 21 amostras, sete de cada conjunto diferente de dados, e a saída foi representada pelos valores preditos da vazão de produção diária de 30 dias futuros (Figura 39).

Figura 39 – Configuração do modelo da predição da vazão de produção de 30 dias.



Fonte: O autor.

A metodologia de *grid search* foi utilizada para avaliação dos resultados, bem como as métricas RMSE, MAPE e MAE. Devido à natureza estocástica das técnicas de IA utilizadas, executou-se o *grid search* 30 vezes. Foi definido que 80% de cada conjunto de dados seriam utilizados para treinamento dos modelos com cada configuração e os 20% restantes foram utilizados para teste.

#### 6.4.1 Configuração do modelo de aprendizado profundo

A Tabela 18 apresenta os hiperparâmetros avaliados no *grid search* das configurações que fizeram uso das técnicas de aprendizado profundo.

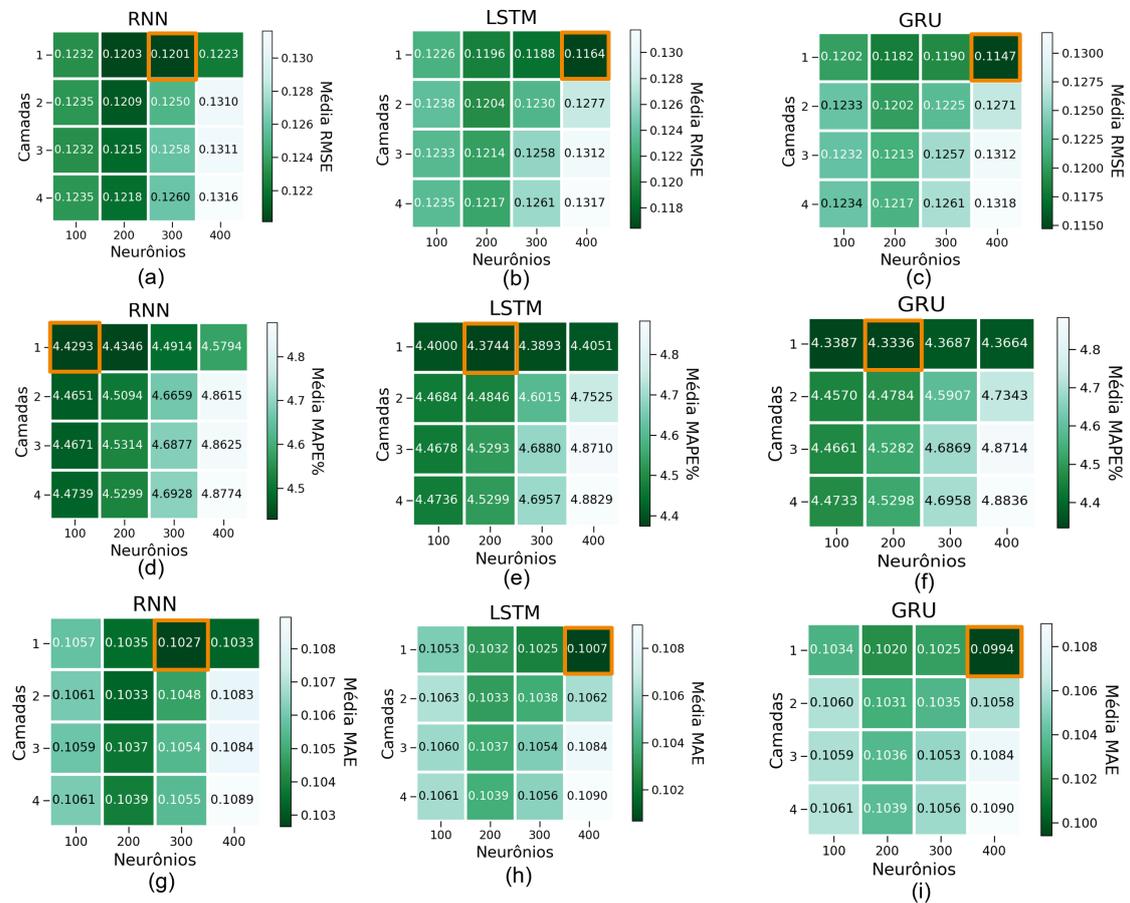
Tabela 18 – Parâmetros e níveis utilizados no *grid search*.

Parâmetros	Níveis
Número de neurônios	De 100 até 400, incrementos de 100
Número de camadas	De 1 até 4, incrementos de 1

**Fonte:** O autor.

Nas Figuras 40a - 40i, é possível observar os *heatmaps* com os resultados obtidos com a aplicação do *grid search* para as técnicas de aprendizado profundo. Analisando as três métricas — RMSE, MAPE e MAE — as configurações que apresentaram os melhores desempenhos foram: RNN-1-300, RNN-1-100, LSTM-1-400, LSTM-1-200, GRU-1-400 e GRU-1-200.

Figura 40 – Resultado do *grid search* para o modelo de predição da vazão de produção baseado em técnicas de aprendizado profundo.



Fonte: O autor.

#### 6.4.2 Configuração do modelo de aprendizado de máquina

A Tabela 19 apresenta os hiperparâmetros avaliados no *grid search* das configurações que fizeram uso das técnicas de aprendizado de máquina. Como é possível observar, os hiperparâmetros usados variam de acordo com a técnica utilizada. Para SVR, o parâmetro de regularização  $C$  e o tipo de *kernel* foram usados. Já para o *Random Forest* e XGBoost, foram utilizados a profundidade máxima das árvores e o número de árvores.

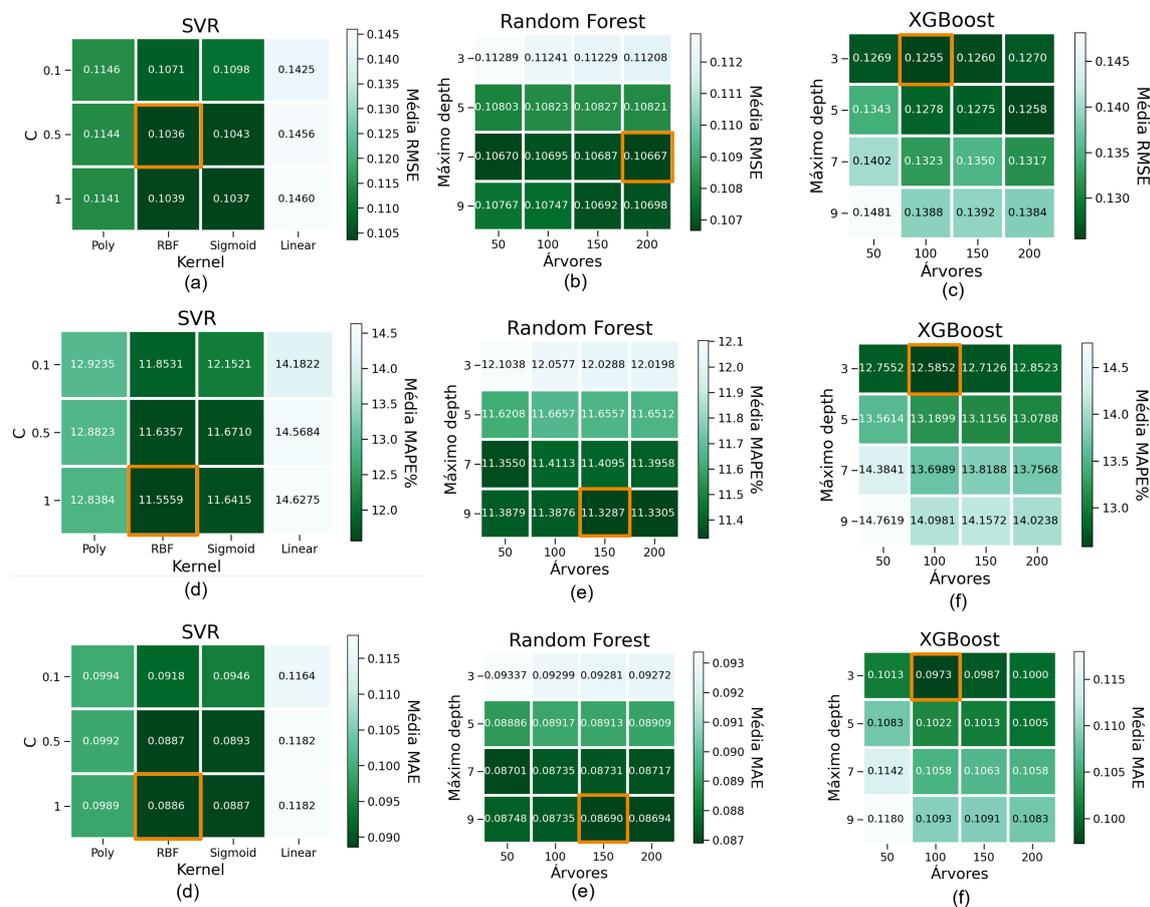
Tabela 19 – Parâmetros e níveis utilizados no *grid search*.

Técnicas	Parâmetros	Níveis
SVR	Número C	0,1, 0,5 e 1
SVR	Tipo de <i>kernel</i>	Polinomial, RBF, <i>sigmoid</i> e linear
<i>Random Forest</i>	Número máx. de <i>depth</i>	De 3 até 9, incrementos de 2
<i>Random Forest</i>	Número de árvores	De 50 até 200, incrementos de 50
XGBoost	Número máx. de <i>depth</i>	De 3 até 9, incrementos de 2
XGBoost	Número de árvores	De 50 até 200, incrementos de 50

**Fonte:** O autor.

As Figuras 41a - 41i apresentam os resultados do *grid search* para RMSE, MAPE e MAE, respectivamente. O XGBoost-3-100 (profundidade máxima igual a três e número de árvores igual a 100) foi a configuração que apresentou os maiores valores das métricas RMSE e MAPE, comparada com todas as demais configurações. O SVR-0.5-rbf apresentou o melhor resultado de RMSE, dentre todos os modelos analisados. Já a configuração SVR-1-rbf apresentou o melhor resultado dentre todos os modelos quando a métrica analisada era o MAE. O GRU-1-200 apresentou o menor valor de MAPE.

Figura 41 – Resultado do *grid search* para o modelo de predição da vazão de produção baseado em técnicas de aprendizado de máquina.



Fonte: O autor.

### 6.4.3 Resultados do modelo de predição da vazão de produção para 30 dias

A Tabela 20 apresenta os resultados referentes às métricas analisadas — RMSE, MAPE e MAE — para a melhor configuração de cada um dos sete modelos: três deles baseados em aprendizado profundo e os outros quatro baseados em aprendizado de máquina.

O procedimento MCS também foi aplicado para análise e obtenção dos conjuntos formados pelos melhores modelos e piores modelos em um certo nível de

Tabela 20 – Resultados das métricas das melhores configurações.

Modelo	RMSE	MAPE(%)	MAE
RNN-1-100	0,1232	4,4293	0,1057
RNN-1-300	0,1201	4,4914	0,1027
LSTM-1-200	0,1196	4,3744	0,1032
LSTM-1-400	0,1164	4,4051	0,1007
GRU-1-200	0,1182	4,3336	0,1020
GRU-1-400	0,1147	4,3664	0,0994
SVR-0.5-RBF	0,1036	11,6357	0,0887
SVR-1-RBF	0,1039	11,5559	0,0886
<i>Random Forest-7-200</i>	0,1067	11,3958	0,0872
<i>Random Forest-9-150</i>	0,1070	11,3287	0,0869
XGBoost-3-100	0,1255	12,5852	0,0973

**Fonte:** O autor.

confiança (HANSEN; LUNDE; NASON, 2011). As configurações presentes no conjunto dos melhores resultados incluíram: SVR-0,5-RBF, SVR-1-RBF, *Random Forest-7-200* e *Random Forest-9-150*. Já as configurações que o MCS inseriu no conjunto dos piores modelos foram: RNN-1-100, RNN-1-300, LSTM-1-200, LSTM-1-400, GRU-1-200, GRU-1-400 e XGBoost-3-100 (Tabela 21).

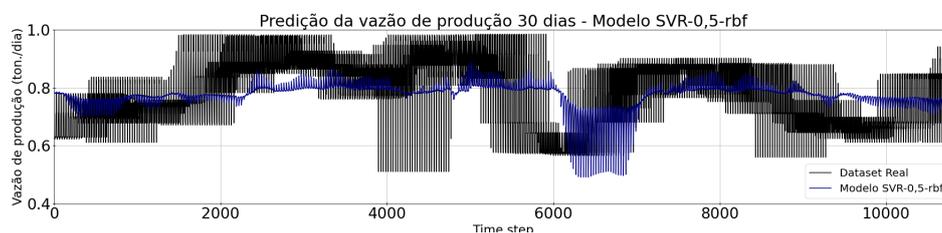
Pela seleção do modelo tradicional, analisando as métricas separadamente, os modelos SVR-0,5-RBF, GRU-1-200 e SVR-1-RBF, apresentaram os melhores desempenhos dentre as métricas analisadas RMSE, MAPE e MAE, respectivamente. Mas, após a aplicação do MCS, a configuração que apresentou o p-valor igual a um foi o modelo SVR-0,5-RBF. Na Figura 42 é possível comparar a curva dos valores reais e a curva de predição da vazão do modelo SVR-0,5-RBF. Devido ao seu melhor desempenho, a configuração SVR-0,5-RBF é utilizada no *módulo de predição* do *framework* para gerenciamento de energia elétrica a fim de ser integrado a análise da predição do indicador de desempenho energético mensal.

Tabela 21 – Resultados do MCS.

Modelo	P-valor
RNN-1-100	0,000
RNN-1-300	0,000
LSTM-1-200	0,000
LSTM-1-400	0,000
GRU-1-200	0,000
GRU-1-400	0,000
XGBoost-3-100	0,003
<i>Random Forest-7-200</i>	0,746
<i>Random Forest-9-150</i>	0,746
SVR-1-RBF	0,809
SVR-0.5-RBF	1,000

**Fonte:** O autor.

Figura 42 – Predição do modelo SVR-0,5-RBF para vazão de produção de 30 dias.



**Fonte:** O autor.

## 6.5 CONSIDERAÇÕES FINAIS

As análises realizadas com os diferentes modelos de predição de consumo de energia para um dia e para 30 dias sugerem uma melhoria significativa na precisão do STLF e MTLF para essa indústria de alto consumo de energia. O que pode ser utilizado para um gerenciamento de energia mais preciso, a fim de atender às demandas de produção, melhorar o fluxo de caixa, reduzir o impacto

---

ambiental e mitigar os riscos associados às ineficiências de energia. Resultados de modelos precisos podem ser utilizados para otimização antecipada e remediação. Por exemplo, a detecção de anomalias pode ser utilizada para identificar possível degradação da máquina ou falha de cargas anômalas em diferentes estágios do processo de fabricação. Isso permitiria a manutenção preditiva e evitaria paralisações da produção.

Após os experimentos realizados, foi possível verificar as configurações que apresentaram os modelos mais precisos para o contexto da indústria de resinas termoplásticas. Os modelos implementados no módulo de predição do *framework* foram baseados na técnica de aprendizado profundo com a configuração de GRU-1-30 para realizar a predição de energia diária do dia seguinte; aprendizado de máquina com a configuração de XGBoost-3-50, para realizar a predição de energia dos 30 dias futuros, e a configuração SVR-0,5-RBF, para realizar a predição da vazão de produção de 30 dias.

O estudo do modelo de predição da vazão diária de produção, juntamente com o modelo de predição do consumo diário de energia elétrica para 30 dias subsidiará a base para o modelo de predição do indicador de desempenho energético mensal. Uma vez que, o cálculo da predição do IDE é dado pela relação entre o consumo de energia elétrico diário ( $C$ ) e a vazão de produção diária ( $F$ ), conforme apresentado na Equação 5.1. Desta forma, com o valor da predição do IDE é possível validar o comportamento da produção da indústria juntamente com o consumo de energia elétrica, através da comparação do valor do IDE referência, estabelecido pela indústria. Caso a análise do IDE previsto não corresponda com o esperado é possível realizar ações para reparar o resultado indesejado de maneira proativa.

## 7 CONCLUSÃO

Além das considerações finais propriamente ditas, por meio de uma breve explanação sobre o que foi alcançado, este capítulo tece alguns comentários sobre as dificuldades enfrentadas, bem como oferece sugestões para trabalhos futuros. Apresenta também as publicações e submissões diretamente ligadas ao tema da tese e trabalhos correlatos.

### 7.1 CONSIDERAÇÕES FINAIS

A pesquisa que embasou a realização desta tese é uma das primeiras a efetuar a comparação da eficácia dos modelos de aprendizado profundo e aprendizado de máquina para a predição de carga de curto prazo para indústrias de alto consumo de energia. Esses modelos foram comparados por meio de um estudo de caso com o modelo de predição manual utilizado na indústria de resinas termoplásticas e o modelo que utiliza uma técnica clássica de predição de série temporal, o ARIMA. Ao contrário dos trabalhos relacionados, foram utilizados dados reais de cinco anos (2015–2019), incluindo dados de consumo de energia elétrica da planta industrial e dados da vazão de produção referentes a duas etapas do processo de produção, em que há uma correlação com os dados de consumo de energia. O uso de dados de produção contribuiu significativamente para melhorar a precisão do STLF, reduzindo o RMSE.

O STLF preciso pode ser usado em uma variedade de processos de manufatura para alcançar eficiência de energia e também como entrada para auxiliar em gestão operacional, incluindo gerenciamento de energia (por exemplo, armazenamento de calor e resfriamento), detecção de anomalias, manutenção preventiva de máquinas e manutenção corretiva e gerenciamento do uso de máquinas, dentre outros. A redução do tempo ocioso das máquinas é vantajosa para essas indústrias.

A escassez de pesquisas sobre este tópico, a manufatura com alto consumo de energia, abre muitos caminhos e perspectivas para pesquisas futuras. Conforme a IoT Industrial amadurece, um volume significativamente maior de dados de série temporal estará disponível para refinar ainda mais a precisão dos modelos, como também estender o uso de aprendizado profundo, além da predição para a atuação.

Esta pesquisa destaca o potencial de técnicas de IA na predição do consumo de energia no contexto industrial e mostra como um modelo de predição preciso terá um impacto na análise do indicador do desempenho energético. A adoção do aprendizado profundo, como tecnologias de ciência de dados, requer a superação de desafios humanos, organizacionais e tecnológicos. Mas, terá um impacto bastante positivo, como subsídio para uma indústria mais competitiva.

O estudo do escalonamento da produção possibilitou selecionar as melhores combinações entre faixas de vazão da produção disponíveis na indústria e períodos de produção. A melhor combinação está diretamente relacionada com a obtenção do menor consumo de energia elétrica. Foi verificado também que, dependendo do volume e prazo de produção, algumas faixas de vazão não são selecionadas.

Com o estudo de caso realizado na indústria de resinas termoplásticas, foi constatado que a eficiência energética poderá ter ganhos com uma programação de produção, sem a necessidade de investimento. Caso a indústria tivesse aplicado o estudo durante o período de cinco anos (2015 – 2019) teria obtido uma economia de 9,74%, oriunda apenas do módulo de escalonamento que auxilia a programação da produção de quantas toneladas precisarão ser produzidas diariamente. O módulo de escalonamento implementado no *framework* indicará quantos dias e quais as faixas de vazão diárias devem ser utilizadas para um dado volume de produção, respeitando um tempo de produção especificado.

A viabilidade técnica e econômica de tecnologias permite que a indústria de resinas termoplásticas realize estudos prévios para verificar se determinado equipamento oferecerá ganhos para a indústria. No estudo de caso foi verificado que o inversor que estava sendo subutilizado em um processo geraria uma economia

---

mensal de R\$9.877,64, caso fosse integrado a outro processo industrial. Além disso, o tempo de retorno de investimento (*Payback*) é de cinco meses. O estudo de viabilidade subsidia melhorias de processos visando o aumento da eficiência da produção.

Diante das características do *framework* para gerenciamento de energia elétrica e do que ele oferece, sua implantação em indústrias de resinas termoplásticas auxiliará na manutenção e obtenção da certificação pela ISO 50001. Isso porque proporciona um melhor gerenciamento e monitoramento dos recursos, dos processos e da produção. O *framework* auxiliará a tomada de decisão dos gerentes visando a eficiência energética: identificar equipamentos que podem ser alocados em outros processos, para torná-los mais eficientes (troca ou inclusão de equipamentos); detectar os equipamentos que estão desgastados e precisam ser substituídos; sugerir diferentes configurações de produção; alterar *layout* da planta industrial; transformar dados em informação para gerar conhecimento e reduzir o risco de falhas.

## 7.2 LIMITAÇÕES DA PESQUISA

Esta tese se inclui no âmbito industrial. Logo, uma das principais limitações encontradas foi o acesso aos dados (variáveis elétricas e variáveis de processo), pois, dificilmente as indústrias disponibilizam dados reais para a comunidade científica. Assim, em boa parte das plataformas com repositórios com conjunto de dados *open source* (por exemplo: repositório de aprendizado de máquina da Universidade da Califórnia em Irvine (UCI) (DUA; GRAFF, 2017)), ou há inexistência desse tipo de dados, ou ainda, quando existem, não são dados suficientes.

Foi observada uma carência de trabalhos científicos incluindo predição do consumo de energia no contexto industrial. Os poucos trabalhos encontrados foram realizados sob a óptica da concessionária.

Falta de informações mais detalhadas sobre o processo de produção fabril em que o estudo de caso foi aplicado, bem como o não fornecimento de outras variáveis que possam impactar o processo produtivo, como insumo e produto, foram outras dificuldades observadas.

Para a implementação do *framework* para gerenciamento de energia elétrica na indústria, desenvolvido nesta tese, foi essencial o trabalho em parceria com a indústria de resinas termoplásticas e sua validação como um estudo de caso. Mas, devido às limitações técnicas oriundas do contexto da pandemia, nos anos de 2020 e 2021, houve atraso em algumas atividades, bem como a necessidade de alterações de tarefas.

### 7.3 SUGESTÕES PARA TRABALHOS FUTUROS

Esta tese pode subsidiar o desenvolvimento de pesquisas futuras. Assim, foram delineados os seguintes pontos específicos que podem complementar o trabalho realizado nesta tese:

- Implantar o *framework* em outras indústrias de resina termoplásticas e até mesmo em indústrias com outros perfís;
- Realizar o monitoramento individualizado em mais áreas da indústria e verificar o impacto no gerenciamento do desempenho energético;
- Realizar acompanhamento com a indústria, para analisar o impacto do uso do *framework*;
- Utilizar mais variáveis de produção na definição da eficiência das faixas de vazão;
- Utilizar novas técnicas de IA e técnicas de otimização para aprimorar os módulos de predição e de escalonamento, respectivamente.

### 7.4 CONTRIBUIÇÕES TÉCNICAS

É possível destacar como principais contribuições técnicas:

- Desenvolvimento de um *framework* de gerenciamento de energia elétrica industrial de apoio à decisão. Provê aos gestores uma visão mais específica e completa dos dados de diferentes naturezas (variáveis elétricas e variáveis de processo).

- 
- *Framework* capaz de interagir com diferentes sistemas industriais, permitindo a geração de informação útil aos gestores.
  - Definição de uma metodologia para facilitar a aplicação do *framework* em indústrias com diferentes perfis. Desta forma será possível a customização do *framework* considerando as características de cada indústria.
  - Utilização de diferentes estratégias — representadas pelos módulos de previsão, escalonamento e viabilidade — para aumentar a produtividade e reduzir o consumo de energia elétrica industrial.
  - Valorização de modelos de previsão de energia elétrica com precisão elevada, através da aplicação de uma metodologia de análise comparativa de diferentes configurações de modelos de previsão utilizando técnicas de IA.

## 7.5 CONTRIBUIÇÕES CIENTÍFICAS

Para documentar as pesquisas realizadas e contribuir com a comunidade científica, seis trabalhos foram publicados. Um deles foi extraído diretamente dos estudos realizados para esta tese e os outros cinco, em área correlata.

### 7.5.1 Publicações associadas à tese de Doutorado

- Short-term firm-level energy-consumption forecasting for energy-intensive manufacturing: a comparison of machine learning and deep learning models. *Algorithms*, 2020 (RIBEIRO et al., 2020).

### 7.5.2 Publicações de artigos em área correlata

- Short- and Very Short-Term Firm-Level Load Forecasting for Warehouses: A Comparison of Machine Learning and Deep Learning Models. *Energies*, 2022 (RIBEIRO et al., 2022).
- The internet of things: definitions, key concepts, and reference architectures. *The Cloud-to-Thing Continuum*, 2020 (LYNN et al., 2020).

- Comparative analysis of current transducers for development of smart plug through rank order centroid method. *IEEE Latin America Transactions*, 2020 (RIBEIRO et al., 2020).
- Comparative analysis of abstraction layer performance of IoT devices management platforms. *IEEE International Conference on Internet of Things: Systems, Management and Security (IoTSMS2019)* (RIBEIRO et al., 2019).
- IMMS: IoT management and monitoring system. *IEEE Symposium on Computers and Communications (ISCC2018)* (MONTE et al., 2018).

## REFERÊNCIAS

- ABIPLAST. *Perfil 2019*. 2019. Disponível em: <[http://www.abiplast.org.br/wp-content/uploads/2020/09/Perfil\\_2019\\_web\\_abiplast.pdf](http://www.abiplast.org.br/wp-content/uploads/2020/09/Perfil_2019_web_abiplast.pdf)>. Acesso em: 11-01-2022.
- ABNT. Nbr iso - 50006: Sistemas de gerenciamento de energia - medição do desempenho energético com base na energia e indicadores de desempenho energético - princípios e orientações gerais. 2016.
- ABNT. Iso 50001: sistemas de gestão de energia – requisitos com orientações para uso. 2018.
- AID. *Revisão tarifária da Celpe (PE) é aprovada*. 2021. Disponível em: <<https://www.aneel.gov.br>>. Acesso em: 24-05-2011.
- AL-MUSAYLH, M. S.; DEO, R. C.; ADAMOWSKI, J. F.; LI, Y. Short-term electricity demand forecasting with mars, svr and arima models using aggregated demand data in queensland, australia. *Advanced Engineering Informatics*, Elsevier, v. 35, p. 1–16, 2018.
- ANDIOJAYA, A.; DEMIRHAN, H. A bagging algorithm for the imputation of missing values in time series. *Expert Systems with Applications*, Elsevier, v. 129, p. 10–26, 2019.
- AXIOS. *GitHub axios*. 2014. Disponível em: <<https://github.com/axios/axios>>. Acesso em: 12-11-2020.
- AXIOS. *GitHub date-fns*. 2014. Disponível em: <<https://github.com/date-fns/date-fns>>. Acesso em: 12-11-2020.
- AZADEH, A.; GHADERI, S.; SOHRABKHANI, S. Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors. *Energy Conversion and management*, Elsevier, v. 49, n. 8, p. 2272–2278, 2008.
- BENGIO, Y.; SIMARD, P.; FRASCONI, P. Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, IEEE, v. 5, n. 2, p. 157–166, 1994.
- BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, v. 13, n. Feb, p. 281–305, 2012.

- BERRIEL, R. F.; LOPES, A. T.; RODRIGUES, A.; VAREJAO, F. M.; OLIVEIRA-SANTOS, T. Monthly energy consumption forecast: A deep learning approach. In: IEEE. *2017 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2017. p. 4283–4290.
- BREBNER, P. C. Is your cloud elastic enough?: Performance modelling the elasticity of infrastructure as a service (iaas) cloud applications. In: ACM. *Proceedings of the 3rd ACM/SPEC International Conference on Performance Engineering*. [S.l.], 2012. p. 263–266.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001.
- CAGNO, E.; WORRELL, E.; TRIANNI, A.; PUGLIESE, G. A novel approach for barriers to industrial energy efficiency. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 19, p. 290–308, 2013.
- CAPELLI, A. Energia elétrica: qualidade e eficiência para aplicações industriais. *São Paulo: Érica*, 2013.
- CARUANA, R.; KARAMPATZIAKIS, N.; YESSINALINA, A. An empirical evaluation of supervised learning in high dimensions. In: *Proceedings of the 25th international conference on Machine learning*. [S.l.: s.n.], 2008. p. 96–103.
- CEPERIC, E.; CEPERIC, V.; BARIC, A. A strategy for short-term load forecasting by support vector regression machines. *IEEE Transactions on Power Systems*, IEEE, v. 28, n. 4, p. 4356–4364, 2013.
- CHEN, C.; LIU, Y.; KUMAR, M.; QIN, J. Energy consumption modelling using deep learning technique—a case study of eaf. *Procedia CIRP*, Elsevier, v. 72, p. 1063–1068, 2018.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. [S.l.: s.n.], 2016. p. 785–794.
- CHEN, X.; LI, C.; TANG, Y.; LI, L.; XIAO, Q. A framework for energy monitoring of machining workshops based on iot. *Procedia CIRP*, Elsevier, v. 72, p. 1386–1391, 2018.
- CHEN, Y.; TAN, H. Short-term prediction of electric demand in building sector via hybrid support vector regression. *Applied energy*, Elsevier, v. 204, p. 1363–1374, 2017.
- CHEN, Y.; XU, P.; CHU, Y.; LI, W.; WU, Y.; NI, L.; BAO, Y.; WANG, K. Short-term electrical load forecasting using the support vector regression (svr)

model to calculate the demand response baseline for office buildings. *Applied Energy*, Elsevier, v. 195, p. 659–670, 2017.

CHUNG, J.; GULCEHRE, C.; CHO, K.; BENGIO, Y. Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*, 2014.

CONDA. *Installing on Linux*. 2017. Disponível em: <<https://docs.continuum.io/projects/conda/en/latest/user-guide/install/linux.html>>. Acesso em: 10-10-2020.

CORALINA, C. *Cora Coralina vintém de cobre meias confissões de Aninha*. 1 edição digital. ed. [S.l.]: Global editora, 2012. 121 p.

CUTLER, D. R.; JR, T. C. E.; BEARD, K. H.; CUTLER, A.; HESS, K. T.; GIBSON, J.; LAWLER, J. J. Random forests for classification in ecology. *Ecology*, Wiley Online Library, v. 88, n. 11, p. 2783–2792, 2007.

D3.JS. *Data-Driven documents*. 2011. Disponível em: <<https://d3js.org/>>. Acesso em: 12-11-2020.

DAUT, M. A. M.; HASSAN, M. Y.; ABDULLAH, H.; RAHMAN, H. A.; ABDULLAH, M. P.; HUSSIN, F. Building electrical energy consumption forecasting analysis using conventional and artificial intelligence methods: A review. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 70, p. 1108–1118, 2017.

DEBNATH, K. B.; MOURSHED, M. Forecasting methods in energy planning models. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 88, p. 297–325, 2018.

DEMCHENKO, Y.; GROSSO, P.; LAAT, C. D.; MEMBREY, P. Addressing big data issues in scientific data infrastructure. In: IEEE. *2013 International conference on collaboration technologies and systems (CTS)*. [S.l.], 2013. p. 48–55.

DEMCHENKO, Y.; LAAT, C. D.; MEMBREY, P. Defining architecture components of the big data ecosystem. In: IEEE. *2014 International conference on collaboration technologies and systems (CTS)*. [S.l.], 2014. p. 104–112.

DEMIRHAN, H.; RENWICK, Z. Missing value imputation for short to mid-term horizontal solar irradiance data. *Applied Energy*, Elsevier, v. 225, p. 998–1012, 2018.

DIEBOLD, F.; MARIANO, R. Comparing predictive accuracy. *Journal of Business and Economic Statistics*, v. 13. 1995.

- DIEBOLD, F. X. Comparing predictive accuracy, twenty years later: A personal perspective on the use and abuse of diebold–mariano tests. *Journal of Business & Economic Statistics*, Taylor & Francis, v. 33, n. 1, p. 1–1, 2015.
- DONG, X.; QIAN, L.; HUANG, L. Short-term load forecasting in smart grid: A combined cnn and k-means clustering approach. In: IEEE. *2017 IEEE International Conference on Big Data and Smart Computing (BigComp)*. [S.l.], 2017. p. 119–125.
- DRUCKER, H.; BURGESS, C. J.; KAUFMAN, L.; SMOLA, A. J.; VAPNIK, V. Support vector regression machines. In: *Advances in neural information processing systems*. [S.l.: s.n.], 1997. p. 155–161.
- DUA, D.; GRAFF, C. *UCI Machine Learning Repository*. 2017. Disponível em: <<http://archive.ics.uci.edu/ml>>.
- DURAN, E.; ARAVENA, C.; AGUILAR, R. Analysis and decomposition of energy consumption in the chilean industry. *Energy Policy*, Elsevier, v. 86, p. 552–561, 2015.
- EIA. *International Energy Outlook 2016, with Projections to 2040*. [S.l.]: Government Printing Office, 2016.
- EIA. *International Energy Outlook 2019*. 2019. <<https://www.eia.gov/outlooks/ieo/>>, urlaccessdate = 24-04-2020.
- EPE. *Anuário estatístico de energia 2020*. 2020. Disponível em: <<https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-160/topico-168/EPEFactSheetAnuario.pdf>>. Acesso em: 16-11-2020.
- ESIGHT ENERGY. *eSight Energy Monitoring and Targeting/Energy Management System*. 2019. Disponível em: <<http://www.esightenergy.com/>>. Acesso em: 09-08-2019.
- EVANGELISTA, V. Modelagem e simulação do processo industrial de polimerização em estado sólido do poli (tereftalato de etileno) e do nylon 66. *Rio de Janeiro: COPPE da Universidade Federal do Rio de Janeiro*, 2010.
- EYADA, M. M.; SABER, W.; GENIDY, M. M. E.; AMER, F. Performance evaluation of iot data management using mongodb versus mysql databases in different cloud environments. *IEEE Access*, IEEE, v. 8, p. 110656–110668, 2020.

- FEINBERG, E. A.; GENETHLIOU, D. Load forecasting. In: *Applied mathematics for restructured electric power systems*. [S.l.]: Springer, 2005. p. 269–285.
- FOSSA, A.; SGARBI, F. Guia para aplicação da norma abnt nbr iso 50001 gestão de energia. *International Copper Association (ICA)*, 2017.
- GAHM, C.; DENZ, F.; DIRR, M.; TUMA, A. Energy-efficient scheduling in manufacturing companies: A review and research framework. *European Journal of Operational Research*, Elsevier, v. 248, n. 3, p. 744–757, 2016.
- GENSLER, A.; HENZE, J.; SICK, B.; RAABE, N. Deep learning for solar power forecasting—an approach using autoencoder and lstm neural networks. In: IEEE. *2016 IEEE international conference on systems, man, and cybernetics (SMC)*. [S.l.], 2016. p. 002858–002865.
- Gers, F. A.; Schmidhuber, J.; Cummins, F. Learning to forget: continual prediction with lstm. In: *1999 Ninth International Conference on Artificial Neural Networks ICANN 99. (Conf. Publ. No. 470)*. [S.l.: s.n.], 1999. v. 2, p. 850–855 vol.2. ISSN 0537-9989.
- GESTAL. *Plataforma Smart Energy*. 2019. Disponível em: <<http://gestal.com/produtos/smart-energy/>>. Acesso em: 10-11-2020.
- GESTAL. *Smart 32*. 2019. Disponível em: <<http://www.gestal.com/produtos/smart-32>>. Acesso em: 11-11-2020.
- GIBSON, I. H. Variable-speed drives as flow control elements. *ISA Transactions*, Elsevier, v. 33, n. 2, p. 165–169, 1994.
- GOLKARNARENJI, G.; NAEBE, M.; BADI, K.; MILANI, A. S.; JAZAR, R. N.; KHAYYAM, H. Support vector regression modelling and optimization of energy consumption in carbon fiber production line. *Computers & Chemical Engineering*, Elsevier, v. 109, p. 276–288, 2018.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. et al. *Deep Learning*. [Sl]. [S.l.]: MIT press, 2016.
- GOZGOR, G.; LAU, C. K. M.; LU, Z. Energy consumption and economic growth: New evidence from the oecd countries. *Energy*, Elsevier, v. 153, p. 27–34, 2018.
- GROLINGER, K.; L'HEUREUX, A.; CAPRETZ, M. A.; SEEWALD, L. Energy forecasting for event venues: Big data and prediction accuracy. *Energy and buildings*, Elsevier, v. 112, p. 222–233, 2016.

- GÜNGÖR, O.; AKŞANLI, B.; AYDOĞAN, R. Algorithm selection and combining multiple learners for residential energy prediction. *Future Generation Computer Systems*, Elsevier, v. 99, p. 391–400, 2019.
- HADERA, H.; LABRIK, R.; MÄNTYSAARI, J.; SAND, G.; HARJUNKOSKI, I.; ENGELL, S. Integration of energy-cost optimization and production scheduling using multiparametric programming. In: *Computer aided chemical engineering*. [S.l.]: Elsevier, 2016. v. 38, p. 559–564.
- HAN, J.; MORAGA, C. The influence of the sigmoid function parameters on the speed of backpropagation learning. In: MIRA, J.; SANDOVAL, F. (Ed.). *From Natural to Artificial Neural Computation*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1995. p. 195–201. ISBN 978-3-540-49288-7.
- HANSEN, P. R.; LUNDE, A.; NASON, J. M. The model confidence set. *Econometrica*, Wiley Online Library, v. 79, n. 2, p. 453–497, 2011.
- HE, F.; ZHOU, J.; FENG, Z.-k.; LIU, G.; YANG, Y. A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with bayesian optimization algorithm. *Applied energy*, Elsevier, v. 237, p. 103–116, 2019.
- HERRMANN, C.; THIEDE, S. Process chain simulation to foster energy efficiency in manufacturing. *CIRP journal of manufacturing science and technology*, Elsevier, v. 1, n. 4, p. 221–229, 2009.
- HOBBY, J. D.; TUCCI, G. H. Analysis of the residential, commercial and industrial electricity consumption. In: IEEE. *2011 IEEE PES Innovative Smart Grid Technologies*. [S.l.], 2011. p. 1–7.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT Press, v. 9, n. 8, p. 1735–1780, 1997.
- HOLCOMB, Z. C. *Fundamentals of descriptive statistics*. [S.l.]: Routledge, 2016.
- HSIEH, T.-J.; HSIAO, H.-F.; YEH, W.-C. Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm. *Applied soft computing*, Elsevier, v. 11, n. 2, p. 2510–2525, 2011.
- HU, H.; WESTHUYSEN, A. J. van der; CHU, P.; FUJISAKI-MANOME, A. Predicting lake erie wave heights using xgboost and lstm. *Ocean Modelling*, Elsevier, p. 101832, 2021.

HUANG, Z.; YANG, C.; ZHOU, X.; YANG, S. Energy consumption forecasting for the nonferrous metallurgy industry using hybrid support vector regression with an adaptive state transition algorithm. *Cognitive Computation*, Springer, p. 1–12, 2019.

JOZEFOWICZ, R.; ZAREMBA, W.; SUTSKEVER, I. An empirical exploration of recurrent network architectures. In: *International conference on machine learning*. [S.l.: s.n.], 2015. p. 2342–2350.

KAVAKLIOGLU, K. Modeling and prediction of turkey's electricity consumption using support vector regression. *Applied Energy*, Elsevier, v. 88, n. 1, p. 368–375, 2011.

KHALID, R.; JAVAID, N. A survey on hyperparameters optimization algorithms of forecasting models in smart grid. *Sustainable Cities and Society*, Elsevier, p. 102275, 2020.

KOLOMVATSOS, K.; PAPADOPOULOU, P.; ANAGNOSTOPOULOS, C.; HADJIEFTHYMIADES, S. A spatio-temporal data imputation model for supporting analytics at the edge. In: SPRINGER. *Conference on e-Business, e-Services and e-Society*. [S.l.], 2019. p. 138–150.

KONG, W.; DONG, Z. Y.; JIA, Y.; HILL, D. J.; XU, Y.; ZHANG, Y. Short-term residential load forecasting based on lstm recurrent neural network. *IEEE Transactions on Smart Grid*, IEEE, v. 10, n. 1, p. 841–851, 2017.

KOSMADAKIS, G. Estimating the potential of industrial (high-temperature) heat pumps for exploiting waste heat in eu industries. *Applied Thermal Engineering*, Elsevier, v. 156, p. 287–298, 2019.

KUAN, L.; YAN, Z.; XIN, W.; YAN, C.; XIANGKUN, P.; WENXUE, S.; ZHE, J.; YONG, Z.; NAN, X.; XIN, Z. Short-term electricity load forecasting method based on multilayered self-normalizing gru network. In: IEEE. *2017 IEEE Conference on Energy Internet and Energy System Integration (EI2)*. [S.l.], 2017. p. 1–5.

KUO, P.-H.; HUANG, C.-J. A high precision artificial neural networks model for short-term energy load forecasting. *Energies*, Multidisciplinary Digital Publishing Institute, v. 11, n. 1, p. 213, 2018.

LAGO, J.; RIDDER, F. D.; SCHUTTER, B. D. Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Applied Energy*, Elsevier, v. 221, p. 386–405, 2018.

LAHOUAR, A.; SLAMA, J. B. H. Day-ahead load forecast using random forest and expert input selection. *Energy Conversion and Management*, Elsevier, v. 103, p. 1040–1051, 2015.

LEARN, S. *Machine Learning in Python*. 2007. Disponível em: <<https://scikit-learn.org/stable/index.html>>. Acesso em: 12-11-2020.

LI, C.; TAO, Y.; AO, W.; YANG, S.; BAI, Y. Improving forecasting accuracy of daily enterprise electricity consumption using a random forest based on ensemble empirical mode decomposition. *Energy*, Elsevier, v. 165, p. 1220–1227, 2018.

LI, P.; ZHANG, J.-S. A new hybrid method for china's energy supply security forecasting based on arima and xgboost. *Energies*, Multidisciplinary Digital Publishing Institute, v. 11, n. 7, p. 1687, 2018.

LI, Q.; ZHANG, L.; XIANG, F. Short-term load forecasting: A case study in chongqing factories. In: IEEE. *2019 6th International Conference on Information Science and Control Engineering (ICISCE)*. [S.l.], 2019. p. 892–897.

LIAO, J.-M.; CHANG, M.-J.; CHANG, L.-M. Prediction of air-conditioning energy consumption in r&d building using multiple machine learning techniques. *Energies*, Multidisciplinary Digital Publishing Institute, v. 13, n. 7, p. 1847, 2020.

LIAO, X.; CAO, N.; LI, M.; KANG, X. Research on short-term load forecasting using xgboost based on similar days. In: IEEE. *2019 International conference on intelligent transportation, big data & smart city (ICITBS)*. [S.l.], 2019. p. 675–678.

LIAW, A.; WIENER, M. et al. Classification and regression by randomforest. *R news*, v. 2, n. 3, p. 18–22, 2002.

LIU, T.; TAN, Z.; XU, C.; CHEN, H.; LI, Z. Study on deep reinforcement learning techniques for building energy consumption forecasting. *Energy and Buildings*, Elsevier, v. 208, p. 109675, 2020.

LYNN, T.; ENDO, P. T.; RIBEIRO, A. M. N.; BARBOSA, G. B.; ROSATI, P. The internet of things: Definitions, key concepts, and reference architectures. *The Cloud-to-Thing Continuum*, Palgrave Macmillan, Cham, p. 1, 2020.

MACDONALD, W. A. New advances in poly (ethylene terephthalate) polymerization and degradation. *Polymer International*, Wiley Online Library, v. 51, n. 10, p. 923–930, 2002.

- MARIANO, R. S.; PREVE, D. Statistical tests for multiple forecast comparison. *Journal of econometrics*, Elsevier, v. 169, n. 1, p. 123–130, 2012.
- MASSE, M. *REST API Design Rulebook: Designing Consistent RESTful Web Service Interfaces*. [S.l.]: "O'Reilly Media, Inc.", 2011.
- MAWSON, V. J.; HUGHES, B. R. Deep learning techniques for energy forecasting and condition monitoring in the manufacturing sector. *Energy and Buildings*, Elsevier, p. 109966, 2020.
- MONGODB. *Release Notes for MongoDB 4.4*. 2020. Disponível em: <<https://docs.mongodb.com/>>. Acesso em: 12-11-2020.
- MONTE, J. V. L. do; FRAGA, V. M. da S.; RIBEIRO, A. M. N. C.; SADOK, D.; KELNER, J. Imms: Iot management and monitoring system. In: IEEE. *2018 IEEE Symposium on Computers and Communications (ISCC)*. [S.l.], 2018. p. 422–425.
- MÜLLER, K.-R.; SMOLA, A. J.; RÄTSCH, G.; SCHÖLKOPF, B.; KOHLMORGEN, J.; VAPNIK, V. Predicting time series with support vector machines. In: SPRINGER. *International Conference on Artificial Neural Networks*. [S.l.], 1997. p. 999–1004.
- NANSEN. *Plataforma SanPlat*. 2019. Disponível em: <<http://nansen.com.br/solucoes/>>. Acesso em: 09-08-2019.
- NASON, G. P. Stationary and non-stationary time series. *Statistics in Volcanology. Special Publications of IAVCEI*, Geological Society London, England, v. 1, p. 000–000, 2006.
- NUNES, E.; SANTOS, L. *Termoplásticos: estruturas, propriedades e aplicações*. [S.l.]: Érica, 2015.
- OLANREWAJU, O. A. Predicting industrial sector's energy consumption: Application of support vector machine. In: IEEE. *2019 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*. [S.l.], 2019. p. 1597–1600.
- OSI-SOFT. *PI System*. 1980. Disponível em: <<https://www.osisoft.pt/pi-system/>>. Acesso em: 11-11-2020.
- PANDAS. *Pandas V.1.0.5 documentation*. 2020. Disponível em: <<https://pandas.pydata.org/>>. Acesso em: 12-11-2020.
- PATEL, R.; PATEL, M. R.; PATEL, R. V. A review: Introduction and understanding of load forecasting. *Journal of Applied Science and Computations (JASC)*, v. 4, n. 4, p. 1449–1457, 2019.

- PATTERSON, M. G. What is energy efficiency?: Concepts, indicators and methodological issues. *Energy policy*, Elsevier, v. 24, n. 5, p. 377–390, 1996.
- PEPPANEN, J.; ZHANG, X.; GRIJALVA, S.; RENO, M. J. Handling bad or missing smart meter data through advanced data imputation. In: IEEE. *2016 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*. [S.l.], 2016. p. 1–5.
- PETRI, I.; LI, H.; REZGUI, Y.; CHUNFENG, Y.; YUCE, B.; JAYAN, B. A modular optimisation model for reducing energy consumption in large scale building facilities. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 38, p. 990–1002, 2014.
- PLASTIVIDA. *Manual do programa Pellet Zero - OCS - Indústria*. 2020. Disponível em: <[http://www.porummarlimpo.org.br/assets/docs/Manual\\_Programa\\_Pellet\\_Zero\\_OCS.pdf](http://www.porummarlimpo.org.br/assets/docs/Manual_Programa_Pellet_Zero_OCS.pdf)>. Acesso em: 01-01-2022.
- PUSHP, S. Merging two arima models for energy optimization in wsn. *arXiv preprint arXiv:1006.5436*, 2010.
- PYPI. *Falcon 2.0.0*. 2019. Disponível em: <<https://pypi.org/project/falcon/>>. Acesso em: 12-11-2020.
- PYPI. *Keras 2.3.0*. 2019. Disponível em: <<https://pypi.org/project/Keras/2.3.0/>>. Acesso em: 15-01-2020.
- PYPI. *Bcrypt 3.2.0*. 2020. Disponível em: <<https://pypi.org/project/bcrypt/>>. Acesso em: 17-11-2020.
- PYPI. *Gevent 20.6.2*. 2020. Disponível em: <<https://pypi.org/project/gevent/#downloads>>. Acesso em: 12-11-2020.
- PYPI. *Grpcio 1.30.0*. 2020. Disponível em: <<https://pypi.org/project/grpcio/>>. Acesso em: 12-11-2020.
- PYPI. *Numpy 1.19.0*. 2020. Disponível em: <<https://pypi.org/project/numpy/>>. Acesso em: 12-11-2020.
- PYPI. *PyMongo 3.10.1*. 2020. Disponível em: <<https://pypi.org/project/pymongo/>>. Acesso em: 12-11-2020.
- PYPI. *Talos 0.6.6*. 2020. Disponível em: <<https://pypi.org/project/talos/>>. Acesso em: 12-11-2020.
- PYPI. *Xgboost 1.2.0*. 2020. Disponível em: <<https://pypi.org/project/xgboost/>>. Acesso em: 12-11-2020.

---

PYPI. *Zip* 3.1.0. 2020. Disponível em: <<https://pypi.org/project/zip/>>. Acesso em: 12-11-2020.

PYPI. *PuLP* 2.5.1. 2021. Disponível em: <<https://pypi.org/project/PuLP/>>. Acesso em: 28-09-2021.

QIU, X.; REN, Y.; SUGANTHAN, P. N.; AMARATUNGA, G. A. Empirical mode decomposition based ensemble deep learning for load demand time series forecasting. *Applied Soft Computing*, Elsevier, v. 54, p. 246–255, 2017.

RAPTIS, T. P.; PASSARELLA, A.; CONTI, M. Data management in industry 4.0: State of the art and open challenges. *IEEE Access*, IEEE, v. 7, p. 97052–97093, 2019.

REACT-CSV. *GitHub react-csv*. 2018. Disponível em: <<https://github.com/react-csv/react-csv>>. Acesso em: 12-11-2020.

RETRIEVED, M. T. D. S. *Support vector machines (SVM) – An overview*. 2018. Disponível em: <<https://towardsdatascience.com/neural-networks-parameters-hyperparameters-and-optimization-strategies-3f0842fac0a5>>. Acesso em: 02-12-2020.

RETRIEVED, M. T. D. S. *Neural networks: Parameters, hyperparameters and optimization strategies*. 2019. Disponível em: <<https://towardsdatascience.com/neural-networks-parameters-hyperparameters-and-optimization-strategies-3f0842fac0a5>>. Acesso em: 02-12-2020.

RIBEIRO, A. M. N.; CARMO, P. R. X. do; RODRIGUES, I. R.; SADOK, D.; LYNN, T.; ENDO, P. T. Short-term firm-level energy-consumption forecasting for energy-intensive manufacturing: A comparison of machine learning and deep learning models. *Algorithms*, Multidisciplinary Digital Publishing Institute, v. 13, n. 11, p. 274, 2020.

RIBEIRO, A. M. N.; CARMO, P. R. X. do; ROSATI, P.; ENDO, P.; LYNN, T. Short- and very short-term firm-level load forecasting for warehouses: A comparison of machine learning and deep learning models. *Energies*, Multidisciplinary Digital Publishing Institute, v. 15, n. 3, p. 750, 2022.

RIBEIRO, A. M. N. C.; CARMO, P. R. X. do; MONTE, J. V. L. do; SADOK, D.; ENDO, P. T.; KELNER, J. Comparative analysis of abstraction layer performance of iot devices management platforms. In: IEEE. *2019 Sixth International Conference on Internet of Things: Systems, Management and Security (IOTSMS)*. [S.l.], 2019. p. 35–42.

- RIBEIRO, A. M. N. C.; SADOK, D. F. H.; BRITO, M. E. da C.; CAVALCANTI, Á. de A.; ENDO, P. T.; KELNER, J. Comparative analysis of current transducers for development of smart plug through rank order centroid method. *IEEE Latin America Transactions*, IEEE, v. 18, n. 01, p. 147–155, 2020.
- RYU, S.; NOH, J.; KIM, H. Deep neural network based demand side short term load forecasting. *Energies*, Multidisciplinary Digital Publishing Institute, v. 10, n. 1, p. 3, 2017.
- SAMSUDIN, R.; SHABRI, A.; SAAD, P. A comparison of time series forecasting using support vector machine and artificial neural network model. *Journal of applied sciences*, v. 10, n. 11, p. 950–958, 2010.
- SAPANKEVYCH, N. I.; SANKAR, R. Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, IEEE, v. 4, n. 2, p. 24–38, 2009.
- SARKER, R. A.; NEWTON, C. S. *Optimization modelling: a practical approach*. [S.l.]: CRC press, 2007.
- SCHMIDT, C.; LI, W.; THIEDE, S.; KORNFELD, B.; KARA, S.; HERRMANN, C. Implementing key performance indicators for energy efficiency in manufacturing. *Procedia Cirp*, Elsevier, v. 57, p. 758–763, 2016.
- SCIPY. *SciPy 1.2.1 Release Notes*. 2008. Disponível em: <<https://www.scipy.org/>>. Acesso em: 17-11-2020.
- SDG9. *Build resilient infrastructure, promote inclusive and sustainable industrialization and foster innovation*. [S.l.]: United Nations, 2020.
- SEICA. *Seica Industrial Monitoring*. 2019. Disponível em: <<https://www.seica.com>>. Acesso em: 09-08-2019.
- SEN, P.; ROY, M.; PAL, P. Application of arima for forecasting energy consumption and ghg emission: A case study of an indian pig iron manufacturing organization. *Energy*, Elsevier, v. 116, p. 1031–1038, 2016.
- SHEN, Y.; ZHANG, T.; WANG, Y.; WANG, H.; JIANG, X. Microthings: A generic iot architecture for flexible data aggregation and scalable service cooperation. *IEEE Communications Magazine*, IEEE, v. 55, n. 9, p. 86–93, 2017.
- SHI, H.; XU, M.; LI, R. Deep learning for household load forecasting—a novel pooling deep rnn. *IEEE Transactions on Smart Grid*, IEEE, v. 9, n. 5, p. 5271–5280, 2017.

- SHROUF, F.; MIRAGLIOTTA, G. Energy management based on internet of things: practices and framework for adoption in production management. *Journal of Cleaner Production*, Elsevier, v. 100, p. 235–246, 2015.
- SILVA, C. J. da. Predição de séries temporais no contexto de smart grids. Universidade Federal de Minas Gerais, 2016.
- SIMON, H. *Neural networks: a comprehensive foundation*. [S.l.]: Prentice hall, 1999.
- SIMPSON, A. R.; MARCHI, A. Evaluating the approximation of the affinity laws and improving the efficiency estimate for variable speed pumps. *Journal of Hydraulic Engineering*, American Society of Civil Engineers, v. 139, n. 12, p. 1314–1317, 2013.
- SINGH, S.; HUSSAIN, S.; BAZAZ, M. A. Short term load forecasting using artificial neural network. In: IEEE. *2017 Fourth International Conference on Image Information Processing (ICIIP)*. [S.l.], 2017. p. 1–5.
- SOLA, A. V. H.; MOTA, C. Melhoria da eficiência energética em sistemas motrizes industriais. *Production, São Paulo, vl*, SciELO Brasil, v. 25, 2015.
- SQLITE. *Version 3.12.0 released*. 2020. Disponível em: <<https://sqlitebrowser.org/>>. Acesso em: 12-11-2020.
- SUN, X.; ANSARI, N. Edgeiot: Mobile edge computing for the internet of things. *IEEE Communications Magazine*, IEEE, v. 54, n. 12, p. 22–29, 2016.
- SUNDARAKANI, B.; SOUZA, R. D.; GOH, M.; WAGNER, S. M.; MANIKANDAN, S. Modeling carbon footprints across the supply chain. *International Journal of Production Economics*, Elsevier, v. 128, n. 1, p. 43–50, 2010.
- SUNDERMEYER, M.; SCHLÜTER, R.; NEY, H. Lstm neural networks for language modeling. In: *Thirteenth annual conference of the international speech communication association*. [S.l.: s.n.], 2012.
- TENSORFLOW. *GitHub TensorFlow v.1.14*. 2019. Disponível em: <<https://www.tensorflow.org/>>. Acesso em: 12-11-2020.
- VAPNIK, V. The nature of statistical learning theory (p. 189). *New York: Springer-Verlag. doi*, v. 10, p. 978–1, 1995.
- VERMAAK, J.; BOTHA, E. Recurrent neural networks for short-term load forecasting. *IEEE Transactions on Power Systems*, IEEE, v. 13, n. 1, p. 126–132, 1998.

- 
- VIKHOREV, K.; GREENOUGH, R.; BROWN, N. An advanced energy management framework to promote energy awareness. *Journal of Cleaner Production*, Elsevier, v. 43, p. 103–112, 2013.
- WANG, X.; ZHAO, T.; LIU, H.; HE, R. Power consumption predicting and anomaly detection based on long short-term memory neural network. In: IEEE. *2019 IEEE 4th International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*. [S.l.], 2019. p. 487–491.
- WANG, Y.; LIU, M.; BAO, Z. Deep learning neural network for power system fault diagnosis. In: IEEE. *2016 35th Chinese control conference (CCC)*. [S.l.], 2016. p. 6678–6683.
- WANG, Y.; LIU, M.; BAO, Z.; ZHANG, S. Short-term load forecasting with multi-source data using gated recurrent unit neural networks. *Energies*, Multidisciplinary Digital Publishing Institute, v. 11, n. 5, p. 1138, 2018.
- WEI, N.; LI, C.; PENG, X.; ZENG, F.; LU, X. Conventional models and artificial intelligence-based models for energy consumption forecasting: A review. *Journal of Petroleum Science and Engineering*, Elsevier, v. 181, p. 106187, 2019.
- WHINFIELD, J. R. Chemistry of ‘terylene’. *Nature*, Nature Publishing Group, v. 158, n. 4026, p. 930–931, 1946.
- WHITE, H. A reality check for data snooping. *Econometrica*, Wiley Online Library, v. 68, n. 5, p. 1097–1126, 2000.
- WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Climate research*, v. 30, n. 1, p. 79–82, 2005.
- WU, W.; LIAO, W.; MIAO, J.; DU, G. Using gated recurrent unit network to forecast short-term load considering impact of electricity price. *Energy Procedia*, Elsevier, v. 158, p. 3369–3374, 2019.
- XYPOLYTOU, E.; MEISEL, M.; SAUTER, T. Short-term electricity consumption forecast with artificial neural networks—a case study of office buildings. In: IEEE. *2017 IEEE Manchester PowerTech*. [S.l.], 2017. p. 1–6.
- YEOM, K.-R.; CHOI, H.-S. Prediction of manufacturing plant’s electric power using machine learning. In: IEEE. *2018 Tenth International Conference on Ubiquitous and Future Networks (ICUFN)*. [S.l.], 2018. p. 814–816.

- 
- YOKOGAWA. *Exaquantum*. 2000. Disponível em: <<https://www.yokogawa.com/solutions/products-platforms/solution-based-software/data-historian/data-historian-exaquantum/>>. Acesso em: 11-11-2020.
- YOON, H.; KIM, Y.; HA, K.; LEE, S.-H.; KIM, G.-P. Comparative evaluation of ann-and svm-time series models for predicting freshwater-saltwater interface fluctuations. *Water*, Multidisciplinary Digital Publishing Institute, v. 9, n. 5, p. 323, 2017.
- YOUNG, S. R.; ROSE, D. C.; KARNOWSKI, T. P.; LIM, S.-H.; PATTON, R. M. Optimizing deep learning hyper-parameters through an evolutionary algorithm. In: *Proceedings of the Workshop on Machine Learning in High-Performance Computing Environments*. [S.l.: s.n.], 2015. p. 1–5.
- YU, Y.; SI, X.; HU, C.; ZHANG, J. A review of recurrent neural networks: Lstm cells and network architectures. *Neural computation*, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info . . . , v. 31, n. 7, p. 1235–1270, 2019.
- YUAN, C.; LIU, S.; FANG, Z. Comparison of china’s primary energy consumption forecasting by using arima (the autoregressive integrated moving average) model and gm (1, 1) model. *Energy*, Elsevier, v. 100, p. 384–390, 2016.
- ZABBIX. *Zabbix documentation 5.0 LTS*. 2020. Disponível em: <<https://www.zabbix.com/>>. Acesso em: 12-11-2020.
- ZAMPOU, E.; PLITSOS, S.; KARAGIANNAKI, A.; MOURTOS, I. Towards a framework for energy-aware information systems in manufacturing. *Computers in Industry*, Elsevier, v. 65, n. 3, p. 419–433, 2014.
- ZHENG, H.; YUAN, J.; CHEN, L. Short-term load forecasting using emd-lstm neural networks with a xgboost algorithm for feature importance evaluation. *Energies*, Multidisciplinary Digital Publishing Institute, v. 10, n. 8, p. 1168, 2017.
- ZHU, K.; GENG, J.; WANG, K. A hybrid prediction model based on pattern sequence-based matching method and extreme gradient boosting for holiday load forecasting. *Electric Power Systems Research*, Elsevier, v. 190, p. 106841, 2021.

## APÊNDICE A – ENDPOINTS API REST

### A.1 CLASSE LOGIN

#### A.1.1 Verificação das credenciais do usuário

Para realizar o *login* é preciso verificar se as credenciais do usuário estão corretas. Desta forma, será necessária a realização de uma requisição POST no *endpoint* abaixo:

---

Synopsis:	POST </framework/login>
Precondition:	Accept: application/json
Postcondition:	Content-Type: application/json
Status code:	200 OK
	404 Not Found
	500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON com a seguinte formatação:

```
1    {
2        cod_user: 'codigo_usuario', #type: string, minLength: 5
3        password: 'senhauser'      #type: string, minLength: 6
4    }
```

### A.2 CLASSE USUÁRIO

#### A.2.1 Inserção de usuário

Para inserir um usuário deverá ser feita uma requisição POST no *endpoint* abaixo:

---

Synopsis:        POST </framework/users/>

Precondition:   Accept: application/json

Postcondition:  Content-Type: application/json

Status code:    200 OK

                  404 Not Found

                  500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON com a seguinte formatação:

```

      {
2         cod_user: 'user', #type: string, minLength: 5
          name: 'name', #type: string, minLength: 2
4         password: 'pass', #type: string, minLength: 6
          matricula: 'matric', #type: string, minLength: 5, opcional
6         email: 'email@gmail.com', #type: email
          acess_level: "admin" ou "viewer" #enum
8     }
```

### A.2.2 Busca de usuário

Para buscar usuários no BD deverá ser feita uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/users?type=\_\_\_\_\_>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

Onde *type* pode assumir três diferentes valores:

*type = viewer*, representa a busca de usuários que apenas visualizam as informações)

*type = admin*, representa a busca de usuários administradores,

*type = all*, representa a busca de todos os usuários.

Para buscar um usuário específico no BD deverá ser feita uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/users/{cod\_user}>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

Onde *cod\_user* está referenciando o código de usuário a ser encontrado.

### A.2.3 Edição de usuário

Para editar os dados referentes a um determinado usuário deverá ser feita uma requisição PUT no *endpoint* abaixo:

---

Synopsis: PUT </framework/users/{cod\_user}>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON que pode ter um ou mais campos, com a seguinte formatação:

```
2     {
3         cod_user: "user", #type: string, minLength: 5
4         name: "name", #type: string, minLength: 2
5         password: "pass", #type: string, minLength: 6
6         matricula: "matric", #type: string, minLength: 5, opcional
7         email: "email@email.com", #type: email
8         acess_level: "admin" ou "viewer" #enum
9     }
```

### A.2.4 Deletar usuário

Para deletar um usuário deverá ser feita uma requisição DELETE no *endpoint* abaixo:

---

Synopsis: DELETE </framework/users/{cod\_user}>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

### A.3 CLASSE MEDIÇÃO

#### A.3.1 Inserção de medição

Para inserir medição no BD, deverá ser realizada uma requisição JSON no *endpoint* abaixo:

---

Synopsis: POST </framework/meas>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

No corpo da requisição deverá ser enviado uma lista de documentos JSON com a seguinte formatação:

```

2     [
      {
4         date: "dd/mm/AAAA", #type: string, "pattern": r"
          (^([0-9]|[12][0-9]|3[01])/([0-9]|1[0-2])/\\d\\d\\d$)"
6         consumo: 1000, #type: number
          vazaoCP: 100, #type: number
          vazaoSSP: 100, #type: number
8     },
      {
10    }
    ]

```

### A.3.2 Busca de medição

Para realizar buscas de medições já inseridas no BD, deverá ser realizada uma requisição GET no *endpoint* abaixo:

---

Synopsis:        GET        </framework/meas?gte=dd/mm/AAAA&lte=dd/mm/AAAA>

Precondition:    Accept: application/json

Postcondition:   Content-Type: application/json

Status code:     200 OK

                  404 Not Found

                  500 Internal Server Error

---

Desta forma, serão retornadas todas as medições existentes no BD e que estão entre as datas *gte* e *lte*.

### A.3.3 Busca da medição mais recente

Para buscar a medição mais recente inserida no BD, deverá ser realizada uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/meas?mostrecent\_meas>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

#### A.3.4 Busca de datas sem medição

Para realizar uma consulta no BD de uma lista de medições que não apresentam datas, deverá ser realizada uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/meas?missing\_dates>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

#### A.3.5 Busca do índice de desempenho por ano

Para realizar consultas no BD dos índices de desempenho, deverá ser realizada uma requisição POST no *endpoint* abaixo:

Synopsis:        POST </framework/meas/graph>

Precondition:    Accept: application/json

Postcondition:   Content-Type: application/json

Status code:     200 OK

                  404 Not Found

                  500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON com a seguinte formatação:

```
1      {
3          years: [2015, ..., 2018]
      }
```

Desta forma serão retornados nessa requisição um documento com os valores dos índices por faixa de vazão pré-definida para cada ano em *years*.

### **A.3.6 Inserção de evento**

Para inserir um evento associado a uma medição, deverá ser realizada uma requisição PUT no *endpoint* abaixo:

---

Synopsis: PUT </framework/meas>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON com a seguinte formatação:

```
2    {
      date: "dd/mm/AAAA", #type: string, "pattern": r"
          ^(0?[1-9]|[12][0-9]|3[01])/(0?[1-9]|1[0-2])/\d\d\d\d$"
4    event: ["parada", "Falta de energia"]
    }
```

## A.4 CLASSE PREDIÇÃO

### A.4.1 Busca de Predição

Para realizar consultas das predições no BD, deverá ser realizada uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/preds?gte=dd/mm/AAAA&lte=dd/mm/AAAA>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

Desta forma, serão retornadas todas as predições existentes no BD e que estão entre as datas gte e lte.

#### **A.4.2 Busca da predição do dia atual**

Para buscar a predição para o dia de hoje no BD, deverá ser realizada uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/preds?today\_pred>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

---

### A.4.3 Busca da predição do índice de desempenho mensal do dia atual

Para realizar uma consulta no BD da predição e do valor atual do índice de desempenho mensal, deverá ser realizada uma requisição POST no *endpoint* abaixo:

---

Synopsis:	POST </framework/preds>
Precondition:	Accept: application/json
Postcondition:	Content-Type: application/json
Status code:	200 OK
	404 Not Found
	500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON com a seguinte formatação:

```
1
2     {
3         month: 7, #type number (1 - 12)
4         year: 2020 #type number
5     }
```

## A.5 CLASSE CONFIGURAÇÃO

### A.5.1 Busca de configuração

Para buscar as configurações atuais do sistema, deverá ser realizada uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/conf>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

### A.5.2 Edição da configuração

Para editar as configurações atuais do sistema, deverá ser realizada uma requisição PUT no *endpoint* abaixo:

---

Synopsis: PUT </framework/conf>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON com uma das seguintes formatações:

```
1      {
3      EventsList: "Novo evento"
      }
```

Nesse caso, o novo evento enviado será adicionar a lista de eventos possíveis nas configurações.

```
1      {
3      Range: {max: 1, min:0}
      }
```

Nesse caso, o *range* configurado substituirá o *range* antigo.

Outras configurações podem ser adicionadas através da requisição citada.

## A.6 CLASSE VIABILIDADE

### A.6.1 Busca de medição

Para realizar a busca de medições de viabilidade entre os *ranges* de datas previamente configuradas, deverá ser realizada uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/viability?gte==dd/mm/AAAA&lte==dd/mm/AAAA>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

### A.6.2 Busca do *payback*

Para buscar o valor *payback* em meses para os dados que estão no BD, deverá ser realizada uma requisição GET no *endpoint* abaixo:

---

Synopsis: GET </framework/viability?payback>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

### A.6.3 Inserção de medição

Para buscar e inserir uma medição na tabela de viabilidade do BD, deverá ser realizada uma requisição POST no *endpoint* abaixo:

---

Synopsis: GET </framework/viability>

Precondition: Accept: application/json

Postcondition: Content-Type: application/json

Status code: 200 OK

404 Not Found

500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON com a seguinte formatação:

```
1  
  {
```

---

```

3     date: "12/31/2011 19:20", #type: "string", "pattern": r"
        (^([0]{0,1}[1-9]|1[012])/([1-9]|([012][0-9])|(3[01]))/\d\d\d
        \d [012]{0,1}[0-9]:[0-6][0-9]$)"
        FI_C1_104: 200 #type number
5     FI_C2_104: 2020 #type number
        FI_C3_104: 2020 #type number
7     }

```

#### A.6.4 Cálculo de rotação

Para realizar o cálculo da rotação em *rpm* dado um valor  $Q$ , deverá ser realizada uma requisição POST no *endpoint* abaixo:

---

Synopsis:        POST </framework/viability/rpm>

Precondition:    Accept: application/json

Postcondition:   Content-Type: application/json

Status code:     200 OK

                  404 Not Found

                  500 Internal Server Error

---

No corpo da requisição deverá ser enviado um documento JSON com a seguinte formatação:

```

1     {
3     Q: 1 #type: number
        }

```