

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA - CURSO DE ENGENHARIA MECÂNICA  
TRABALHO DE CONCLUSÃO DE CURSO

PREVISÃO DA EFICIÊNCIA DE GERAÇÃO DE VAPOR POR MEIO DE REDES  
NEURAS ARTIFICIAIS COM DIFERENTES ACOPLAMENTOS

por

Felipe Brunetto Büttendender

Monografia apresentada ao Departamento de Engenharia Mecânica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como parte dos requisitos para obtenção do diploma de Engenheiro Mecânico.

Porto Alegre, maio de 2021.

## CIP - Catalogação na Publicação

Brunetto Büttenbender, Felipe  
Previsão da eficiência de geração de vapor por meio  
de redes neurais artificiais com diferentes  
acoplamentos / Felipe Brunetto Büttenbender. -- 2021.  
25 f.  
Orientador: Paulo Smith Schneider.

Trabalho de conclusão de curso (Graduação) --  
Universidade Federal do Rio Grande do Sul, Escola de  
Engenharia, Curso de Engenharia Mecânica, Porto  
Alegre, BR-RS, 2021.

1. redes neurais artificiais. 2. eficiência. 3.  
machine learning. 4. gerador de vapor. 5. usina  
termelétrica. I. Smith Schneider, Paulo, orient. II.  
Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os  
dados fornecidos pelo(a) autor(a).

Felipe Brunetto Büttenbender

PREVISÃO DA EFICIÊNCIA DE GERAÇÃO DE VAPOR POR MEIO DE REDES  
NEURAS ARTIFICIAIS COM DIFERENTES ACOPLAMENTOS

ESTA MONOGRAFIA FOI JULGADA ADEQUADA COMO PARTE DOS  
REQUISITOS PARA A OBTENÇÃO DO TÍTULO DE  
**ENGENHEIRO MECÂNICO**  
APROVADA EM SUA FORMA FINAL PELA BANCA EXAMINADORA DO  
CURSO DE ENGENHARIA MECÂNICA

Prof. Mário Roland Sobczyk Sobrinho  
Coordenador do Curso de Engenharia Mecânica

Área de Concentração: Energia e Fenômenos de Transporte

Orientador: Prof. Dr. Paulo Smith Schneider

Comissão de Avaliação:

Prof. Cirilo Seppi Bresolin

Prof. Felipe Roman Centeno

Prof. Julian David Hunt

Porto Alegre, maio de 2021.

## AGRADECIMENTOS

Agradeço primeiramente aos meus pais Eliane e Luiz por incentivarem a busca contínua por conhecimento, por tornarem toda essa caminhada possível e por serem meu porto seguro. Nunca me imaginaria realizando este sonho sem o seu apoio e sem tudo o que fizeram e fazem por mim. Agradeço ainda por ensinarem valores essenciais para minha vida e por serem exemplo de força, dedicação, determinação e ética.

À minha irmã Mariana por sempre me motivar a ser o melhor exemplo, por me mostrar o quão importante é ter pensamento coletivo e por todas as trocas de experiência que são fundamentais para mim.

Agradeço à Taciele pelo amor e carinho demonstrado todos os dias e pelos conselhos nos momentos difíceis e de angústia que enfrentei durante o último ano. Ter uma companhia como você na minha vida é um privilégio.

Ao Tiago e à família Schroer por compartilharem boa parte desta caminhada. Agradeço pela amizade, pelo suporte mesmo na ausência de laços sanguíneos e pelo exemplo de simplicidade e de humildade.

À Universidade Federal do Rio Grande do Sul e aos meus professores e colegas de aula, por compartilharem conhecimento e garantirem a qualidade do ensino superior público.

Por fim, agradeço à OTMZA Assessoria em Engenharia por permitir uma vivência empresarial em um ambiente de teste e de empoderamento dos membros. Estendo meu agradecimento a todos os meus colegas durante esta experiência inesquecível, vocês são referências que me motivam a buscar desenvolvimento contínuo.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA - CURSO DE ENGENHARIA MECÂNICA  
TRABALHO DE CONCLUSÃO DE CURSO – 2021

**PREVISÃO DA EFICIÊNCIA DE GERAÇÃO DE VAPOR POR MEIO  
DE REDES NEURAIS ARTIFICIAIS COM DIFERENTES  
ACOPLAMENTOS**

**Brunetto Büntenbender, Felipe Brunetto Büntenbender**  
felipebrunettob@gmail.com

***Resumo.** Usinas termelétricas têm alta participação na matriz de geração de energia global e já integram a demanda de base do Sistema Elétrico Brasileiro. Modelos e estratégias de simulação voltadas à melhoria da eficiência das usinas e de seus sistemas são importantes para garantir o bom desempenho aliado ao controle de emissões. O presente trabalho investiga diferentes formas de simular a eficiência do subsistema real de moagem e de geração de vapor com Redes Neurais Artificiais (RNAs). O subsistema completo é simulado por RNAs com variações do número de moinhos em conjunto com o gerador de vapor. Essas soluções são comparadas à alternativa de RNAs individuais para cada moinho e para o gerador de vapor, posteriormente acopladas por meio de suas entradas e saídas. Os resultados dessas duas estratégias de simulação são comparados pelas métricas de erros RMSE e  $R^2$ . A simulação com redes separadas e posteriormente acopladas aumenta o RMSE de 1,244 para 2,210 em relação às redes únicas, e diminui o  $R^2$  de 0,861 para 0,557. Desempenhos levemente superiores são observados com o emprego de Máquinas de Vetor de Suporte e Random Forest, mas igualmente com perda de acurácia. Estes resultados apontam para a necessidade de melhor a estratégia de acoplamento de modelos individuais baseados em dados para alcançar bons resultados.*

***Palavras-chave:** redes neurais artificiais, eficiência, acoplamento, gerador de vapor, usina termelétrica*

***Título em inglês***

***Abstract.** Thermal power plants have a high global energy generation market share and they already are part of the brazilian electric system basic demand. Models and simulation aimed at improving the efficiency of the plants and their systems are important to ensure good performance combined with execution control. The present work investigates different ways to simulate the efficiency of the real grinding and steam generation subsystem with Artificial Neural Networks (ANNs). The complete subsystem is simulated by RNAs with variations in the number of mills in conjunction with the steam generator. These solutions are compared to the alternative using individual RNAs for each mill and for the steam generator, later coupled through their inputs and outputs. The results of these two simulation strategies are compared by the error metrics RMSE and  $R^2$ . The simulation with separate and subsequently coupled networks increases the RMSE from 1,244 to 2,210 in relation to the single networks, and decreases the  $R^2$  from 0,861 to 0,557. Slightly better performances are observed with the use of Support Vector Machines and Random Forest, but also with loss of accuracy. These results point to the need to improve the strategy of coupling individual models based on data to achieve good results.*

***Keywords:** artificial neural nets, efficiency, coupling, steam generator, thermal power plant*

## SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>1</b>
<b>2. MODELOS DE REGRESSÃO .....</b>	<b>2</b>
<b>2.1. REDES NEURAIS ARTIFICIAIS .....</b>	<b>2</b>
<b>2.2. ÁRVORES DE DECISÃO.....</b>	<b>3</b>
<b>2.3. MÁQUINAS DE VETOR DE SUPORTE .....</b>	<b>3</b>
<b>2.3. MÉTRICAS DE AVALIAÇÃO DE MODELOS DE REGRESSÃO .....</b>	<b>4</b>
<b>3. ESTUDO DE CASO .....</b>	<b>5</b>
<b>4. METODOLOGIA.....</b>	<b>6</b>
<b>4.1. PRÉ-PROCESSAMENTO DOS DADOS.....</b>	<b>7</b>
<b>4.2. TREINAMENTO DOS MODELOS E DEFINIÇÃO DE PARÂMETROS.....</b>	<b>8</b>
<b>4.3. COMPARAÇÃO E AVALIAÇÃO DOS MODELOS .....</b>	<b>9</b>
<b>5. RESULTADOS .....</b>	<b>9</b>
<b>5.1. PRÉ-PROCESSAMENTO DOS DADOS.....</b>	<b>10</b>
<b>5.2. DEFINIÇÃO DE HIPERPARÂMETROS.....</b>	<b>10</b>
<b>5.3. DESEMPENHO DOS MODELOS DE REDES NEURAIS .....</b>	<b>11</b>
<b>5.4. COMPARAÇÃO ENTRE MODELOS DE REGRESSÃO.....</b>	<b>14</b>
<b>6. CONCLUSÃO.....</b>	<b>14</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>15</b>

## 1. INTRODUÇÃO

Termelétricas alimentadas com combustíveis fósseis representaram 76% da geração de energia elétrica mundial em 2018 (IeA, 2018) e 15%, no Brasil (ANEEL, 2018). O carvão é o combustível responsável por 38% dessa produção no âmbito mundial, mas apenas 2,3% no Brasil, segundo as mesmas fontes

Lawson (2017) destaca que a demanda de base do Sistema Elétrico Brasileiro, mesmo que de maneira secundária, já conta com a inclusão de termelétricas por conta da queda gradativa da capacidade de regularização dos reservatórios nacionais que suprem as hidrelétricas. O autor também salienta que este tipo de geração dependente da queima de recursos naturais eleva o custo da energia brasileira e causa impactos ambientais, visto que especialmente usinas abastecidas com óleo diesel e com carvão emitem elevados níveis de gases de efeito estufa. Portanto, é evidente um interesse mundial e nacional numa operação eficiente de usinas termelétricas.

Com o advento da Internet das Coisas e do sensoriamento de equipamentos, surgiram diversos softwares para otimização e controle de processos, como é o caso do Predix Operations Performance Management<sup>1</sup> e do Siemens Energy<sup>2</sup>. Estes softwares atuam como um *digital twin*, uma denominação para ferramentas que mapeiam um ativo físico através de sensores a fim de modelar uma réplica digital que, através do uso de modelos baseados na física envolvida no processo ou no aprendizado de máquina dos dados obtidos, pode ser utilizada na simulação de cenários de processo mais eficientes (PATWAL, 2020). Ferramentas *digital twin* ainda possibilitam a verificação do estado atual de operação de cada componente modelado, algo essencial em eventuais modificações consideráveis nos ativos. Isso exige, entretanto, a aplicação da ferramenta individualmente em cada componente ou sistema desejado.

Zhang et. al. (2002) e Shin et. al. (2009) utilizaram algoritmo genético e modelo de caixa cinza, respectivamente, para encontrar coeficientes no equacionamento resultante da física envolvida nos moinhos de carvão verticais isolados do gerador de vapor. Estas abordagens permitiram a modelagem computacional da temperatura de saída do carvão e da pressão diferencial no sistema de moagem para todas as faixas de operação.

Rocha (2019) modelou a Usina Térmica de Pecém com redes neurais artificiais para a previsão e otimização da operação levando em conta a eficiência do gerador de vapor e a emissão de NO<sub>x</sub>. Sua modelagem uniu os sistemas de moagem e de geração de vapor em um volume de controle único e apresentou MSE e MAE de 0,7572 e 0,6206, respectivamente na previsão da eficiência. Já no estudo de Vieira (2020) para a mesma usina, modelos substitutos foram elaborados com software comercial e com redes neurais artificiais para simular a eficiência do sistema de geração de vapor. O comportamento dos modelos foi analisado com ferramentas estatísticas como Projeto de Experimentos e Modelo de Superfície de Resposta para identificar as influências dos parâmetros controláveis. O trabalho desenvolvido resultou em um sistema de apoio à decisão da operação que permite atingir novas condições seguras, estáveis e mais eficientes.

O presente trabalho tem como objetivo o desenvolvimento e a avaliação do desempenho de estratégias de montagem e acoplamento de modelos de simulação dos sistemas de moagem e de geração de vapor com redes neurais artificiais visando a previsão de sua eficiência, aplicado ao caso real da Usina Termelétrica de Pecém.

---

<sup>1</sup> <https://www.ge.com/digital/iiot-platform>

<sup>2</sup> <https://www.siemens-energy.com/global/en.html>

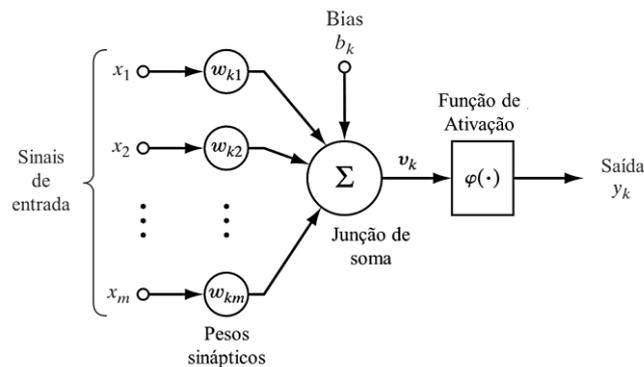
## 2. MODELOS DE REGRESSÃO

Modelos de regressão são utilizados na previsão de respostas dada uma ou mais variáveis de entrada. Em sua forma mais simples se tratam de uma regressão linear, ou então de uma regressão linear múltipla. Entretanto, modelos de *machine learning* mostram-se bastante eficazes quando uma grande quantidade de dados disponíveis está associada a comportamentos não lineares (JAMES, 2017). Alguns dos métodos empregados nesse trabalho são apresentados nas próximas seções.

### 2.1. Redes neurais artificiais

Uma rede neural artificial consiste em um sistema de processamento paralelo de informações que é baseado no funcionamento de um cérebro. Ele se assemelha a este órgão animal principalmente por aprender através de um processo de treinamento as características de uma função de interesse e por então armazenar esse conhecimento através de pesos  $w_{ki}$ , que emulam a força de conexão dos neurônios (HAYKIN, 2009). A Figura 1 representa um neurônio artificial e os principais componentes do seu funcionamento. Contudo, na prática, utilizam-se *Multi Layer Perceptrons*, que se tratam de redes com múltiplos neurônios em camadas interconectadas entre si pelos sinais de entrada  $x_i$  e de saída  $y_i$ .

Figura 1 – Representação de um neurônio artificial



Fonte: Adaptado de HAYKIN, 2009.

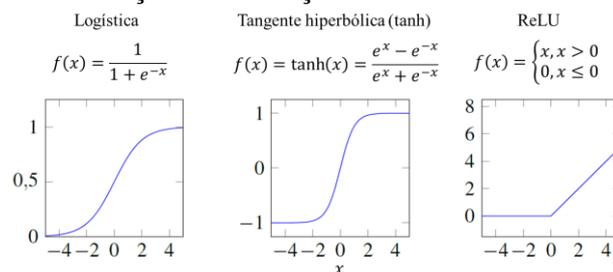
O funcionamento matemático de um neurônio  $k$  até a saída  $y_k$  é dado pelas equações 1 e 2

$$v_k = \sum_{i=1}^m x_i w_{ki} + b_k \quad (1)$$

$$y_k = \varphi(v_k) \quad (2)$$

A função de ativação  $\varphi(\cdot)$  determina o comportamento da saída e, segundo Weber et al (2019), são responsáveis por introduzir propriedades não lineares à rede. Na Figura 2 são ilustradas as funções de ativação usuais em redes neurais artificiais.

Figura 2 – Funções de ativação de redes neurais artificiais

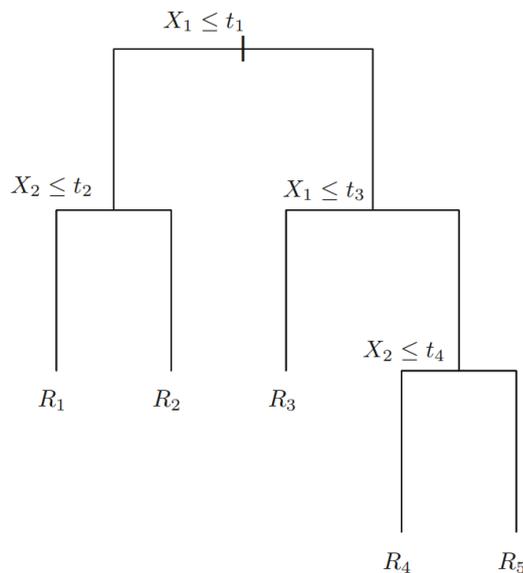


O processo de treinamento e determinação dos pesos das redes neurais artificiais é realizado através da minimização de erros em comparação a um conjunto de dados experimentais. Este processo utiliza um algoritmo de *backpropagation*, que se baseia no método do gradiente descendente e, assim como o nome sugere, é computado no sentido inverso do fluxo de informação da rede (de frente para trás).

## 2.2. Árvores de decisão

Trata-se de um o método de classificação e regressão em que o espaço de análise das variáveis de entrada é dividido em regiões binárias que não se sobrepõem. A construção deste modelo de regressão se dá através do conjunto de treinamento em que cada nó da árvore tem sua variável  $X_i$  e ponto de divisão  $t_i$  escolhidos dentre as possibilidades com base no menor erro quadrático da previsão na ramificação em construção (JAMES, 2017). A Figura 3 ilustra uma árvore de decisão.

Figura 3 – Representação esquemática de uma árvore de decisão



Fonte: JAMES, 2017.

As variáveis de entrada  $X_i$  são verificadas nos condicionais seguindo a ordem hierárquica da árvore até a sua base para obter a resposta de previsão  $R_i$ . Cada resposta  $R_i$  é denominada de terminal e é obtida através da média da variável a ser prevista para o conjunto de treinamento que foi selecionado pelas condições.

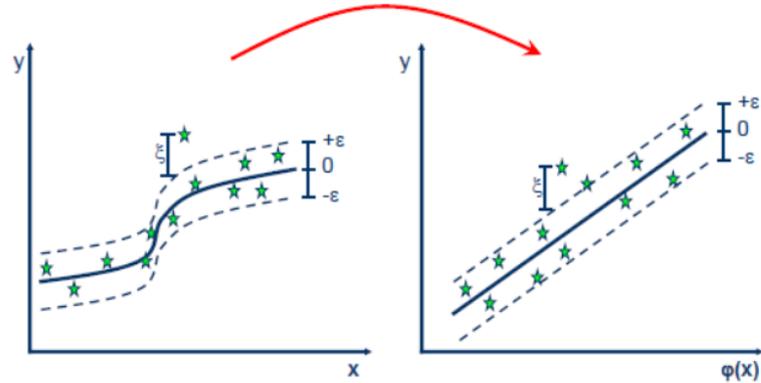
O método *RandomForest* combina um número  $N$  de árvores de decisão de modo a utilizar o resultado médio de cada uma como previsão final. Para elaborar  $N$  árvores se faz necessária a criação de  $N$  amostras novas através da técnica de reamostragem denominada *bootstrapping*, que consiste em gerar amostras aleatórias a partir da original, preservando a sua dimensão.

## 2.3. Máquinas de vetor de suporte

Máquinas de vetor de suporte (SVM, do inglês) são usuais em problemas de classificação binária e se destinam a determinar um hiperplano, de forma que os limites entre duas classes sejam melhor representados, buscando maximizar a distância perpendicular deste plano às observações, chamada de margem (JAMES, 2017). Na utilização dessa ferramenta para regressão, almeja-se o inverso da classificação. Neste caso deseja-se que o hiperplano seja tal

que o máximo de pontos esteja incluído nesta margem delimitada por  $\epsilon$ , assim como ilustra a Figura 4, para melhor representar a variável a ser prevista.

Figura 4 – Representação de uma SVM não linear



Fonte: Página do Dr. Saed Sayad<sup>3</sup>.

Algoritmos de SVM aplicados à regressão podem utilizar outros tipos de função além da linear, como polinômios, funções de base radial e sigmóides. Estas funções, denominadas de *kernel*, transformam os dados de maneira a aumentar a dimensão do espaço de análise. A Figura 4 ainda ilustra a presença de pontos fora da margem a uma distância  $\xi$ . Estes são inerentes aos problemas de regressão e, nos algoritmos aplicados, são penalizados pelo hiperparâmetro  $C$ , ou seja, quanto maior  $C$ , maior a penalização de pontos não abrangidos pela margem (YUAN et al., 2021).

### 2.3. Métricas de avaliação de modelos de regressão

As métricas de avaliação de desempenho de modelos de regressão comumente utilizadas são o MAE (*Mean Absolute Error*), o MAPE (*Mean Absolute Percentage Error*), o RMSE (*Root Mean Squared Error*) e o  $R^2$  (coeficiente de determinação). Estas métricas são elaboradas na comparação da previsão do modelo supervisionado  $\hat{y}_i$  com a variável medida  $y_i$  e são utilizadas tanto nas etapas de treinamento, de escolha de parâmetros e de validação.

O MAE pode ser determinado através da Equação 3.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Apresenta-se através do MAE a magnitude média dos erros do modelo. Como apresenta a escala e a unidade da variável analisada, não pode ser utilizada na comparação de modelos de variáveis distintas. Portanto, utiliza-se o MAPE, determinado pela Equação 4.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

O RMSE pode ser determinado através da Equação 5.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

<sup>3</sup> Disponível em: < [https://www.saedsayad.com/support\\_vector\\_machine\\_reg.htm](https://www.saedsayad.com/support_vector_machine_reg.htm) >

Essa métrica é usual por estar na mesma unidade da variável analisada e, devido à potência de elevação dos erros, por penalizar previsões com grande diferença da variável medida (PACHECO, 2019). Quando analisado em comparação ao MAE, é possível observar se há uma grande variância no erro médio.

O coeficiente de determinação é uma métrica bastante comum para estes métodos, em análises conjuntas ao RMSE e é representado pela Equação 6.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

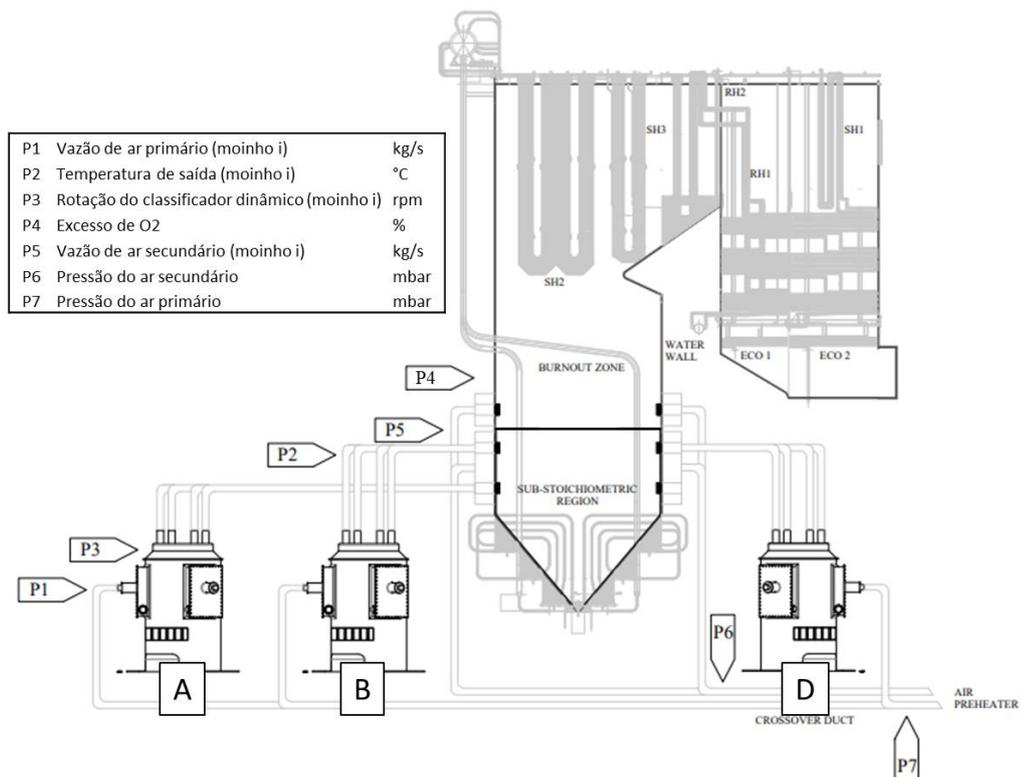
Assim como relata James (2017), a métrica  $R^2$  mede a proporção da variabilidade do fenômeno que pode ser representada pelo modelo. Ele ressalta que, apesar da dificuldade de se delimitar o que seria um bom  $R^2$ , em fenômenos físicos essa métrica deve ser muito próxima de 1.

### 3. ESTUDO DE CASO

O objeto de estudo é um dos sistemas de geração de vapor da Usina Termelétrica de Pecém localizada no Ceará. A planta possui dois geradores de vapor subcríticos abastecidos a carvão que compõem uma capacidade de geração de vapor de 360 MW cada (VIEIRA, 2020).

O sistema analisado opera com um gerador de vapor e três moinhos de carvão simultâneos. A Figura 5 apresenta o objeto de estudo, bem como os parâmetros de entrada controláveis considerados nas análises.

Figura 5 – Parâmetros controláveis utilizados na modelagem do sistema



Fonte: Adaptado de VIEIRA, 2020.

Assim como empregado por Vieira (2020) na sua dissertação, o presente estudo utilizou os parâmetros controláveis pelo operador da usina que não geram prejuízo para a operação e são utilizados no sistema supervisorio em tempo real elaborado.

A legenda sinaliza que a vazão de ar primário, a temperatura de saída da mistura de ar e carvão pulverizado e a rotação do classificador dinâmico são específicas de cada moinho, bem como a vazão de ar secundário, de mesma origem que o ar primário, mas que entra nas faixas de queimadores abastecidos por unidades de moagem distintas. O restante é único para todos os moinhos ou referente ao gerador de vapor.

O sistema de moagem possui a função de fornecer carvão pulverizado em uma dada granulometria, seco e em uma temperatura adequada na fornalha. Segundo Zhang et. al (2002) moinhos verticais possuem como variáveis de saída a pressão diferencial no moinho, a temperatura de saída da mistura carvão e ar e a energia consumida pelo moinho. A pressão diferencial no moinho é influenciada pela pressão do ar primário, pela massa de carvão no moinho e pela vazão de carvão pulverizado na saída dele. Já a temperatura de saída da mistura é dependente da temperatura de entrada e da vazão do ar primário, além da vazão mássica de entrada de carvão no moinho.

A variável de saída estudada é a eficiência do sistema de geração de vapor, que representa a quantidade de energia aproveitada em relação ao total de energia disponível. Neste sistema ela é calculada pelo método direto, em que se compara o fluxo de calor de saída com o de entrada, como representado pela Equação 7 (CHETAN E BHAVESH, 2013).

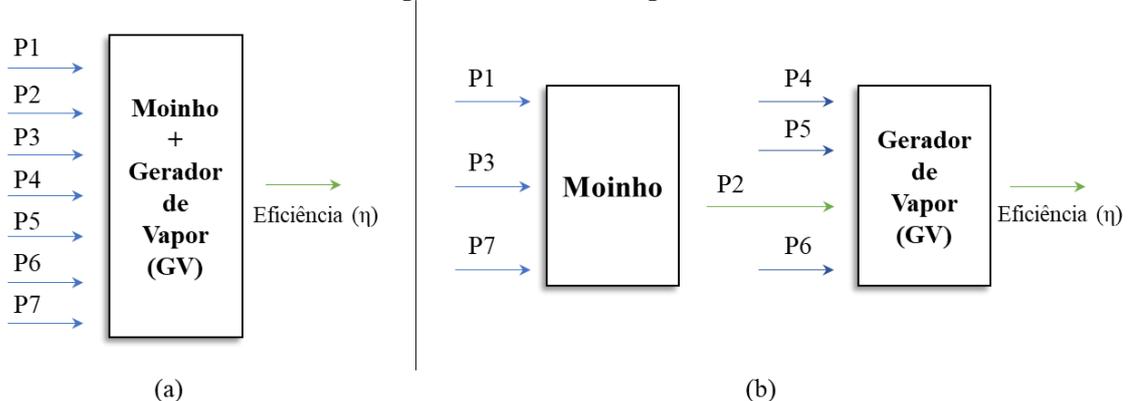
$$\eta = \frac{\dot{Q}_S}{\dot{Q}_E} = \frac{\dot{m}_v(h_v - h_{H2O})}{\dot{m}_c PCI} \quad (7)$$

As perdas energéticas no processo de geração de vapor que reduzem essa eficiência segundo Justí (2019) estão relacionadas principalmente aos gases de combustão, à umidade do combustível, às cinzas, à combustão parcial, às purgas e ao fluxo de calor pelas fronteiras dos equipamentos.

#### 4. METODOLOGIA

As duas formas apresentadas na Figura 6 foram propostas para a elaboração e avaliação de um modelo de regressão da eficiência de unidade geradora de vapor da Usina Térmica de Pecém.

Figura 6 – Representação do processo de geração de vapor analisado. (a) modelagem com volume de controle único. (b) modelagem com volumes de controle separados e posteriormente acoplados



Na modelagem com volume de controle único, o sistema de moagem está unido ao modelo de eficiência da unidade geradora de vapor. Todas as variáveis controláveis consideradas são utilizadas como entradas neste caso, gerando como saída a eficiência.

Na modelagem com volumes de controle separados, considerou-se a unidade de moagem como um sistema anterior e separado do gerador de vapor. As variáveis de entrada do sistema de moagem geram como saída a temperatura da mistura de ar e carvão pulverizado que é utilizada como entrada no modelo da eficiência do gerador de vapor.

O presente trabalho verifica também a combinação de modelagens das colunas da Tabela 1.

Tabela 1 – Tipos de modelagens realizadas filtrando os moinhos em conjunto com o gerador de vapor

<b>Filtro de parâmetros dos moinhos</b>	<b>Volume de Controle (VC)</b>
moinho A + GV (A)	único
moinho B + GV (B)	separado
moinho D + GV (D)	
média dos moinhos + GV (média)	
moinho A, B e D + GV (A, B e D)	

Foram geradas dez alternativas de combinações entre as colunas da tabela. A primeira coluna apresenta a filtragem dos dados de cada moinho, ou seja, qual subsistema de moagem é modelado. Utilizou-se parâmetros exclusivos a cada um dos moinhos A, B ou D, parâmetros médios entre os três moinhos e parâmetros provenientes uma união de todos os moinhos.

O conjunto de dados é proveniente do sistema supervisor da Usina de Pecém com medições realizadas entre 01 de agosto de 2018 e 01 de fevereiro de 2020, com intervalo de aquisição de trinta minutos, totalizando 26353 amostras. Este conjunto foi pré-processado em Python para eliminar dados espúrios para então treinar e testar os modelos preditivos.

#### 4.1. Pré-processamento dos dados

A etapa de pré-processamento realiza a remoção dos dados nulos e dos *outliers* e a normalização dos dados. Ela torna os dados próprios para o uso nos modelos de regressão, visto que eles podem ser prejudicados pela presença de outliers

Como a análise realizada busca prever a eficiência do gerador de vapor em uma operação estável, optou-se pela remoção de dados fora dos limites inferiores  $L_i$  e superiores  $L_s$  dos diagramas de caixa das variáveis. Estes diagramas são elaborados a partir do primeiro e terceiro quartil da amostra e, seus limites podem ser obtidos através das equações 8 e 9.

$$L_i = Q_1 - 1,5(Q_3 - Q_1) \quad (8)$$

$$L_s = Q_3 + 1,5(Q_3 - Q_1) \quad (9)$$

em que  $Q_1$  e  $Q_3$  são, respectivamente, o primeiro e terceiro quartis.

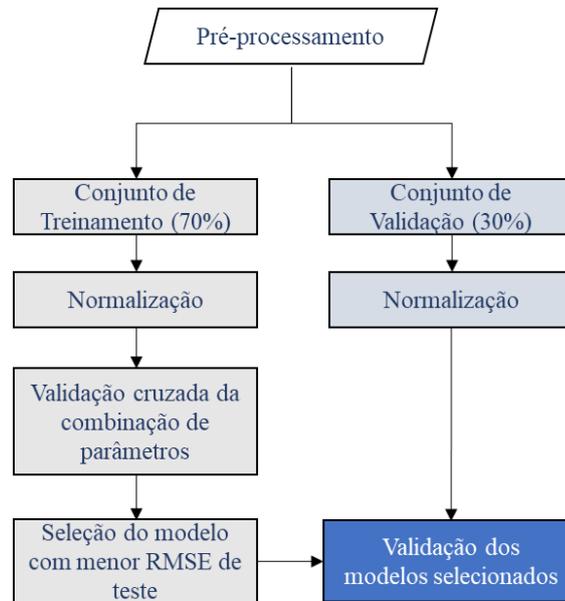
A normalização, essencial aos algoritmos utilizados segundo o *User Guide* da biblioteca *Scikit-Learn*<sup>4</sup>, é utilizada para que o modelo perceba todas as variáveis da mesma maneira, ignorando a variação de escala entre as grandezas. Utilizou-se o algoritmo *StandardScaler*, que transforma as variáveis da base de dados no seu escore padronizado. Esta etapa foi realizada nos conjuntos de treinamento e de validação em separado.

<sup>4</sup> [https://scikit-learn.org/stable/user\\_guide.html](https://scikit-learn.org/stable/user_guide.html)

## 4.2. Treinamento dos modelos e definição de parâmetros

O treinamento dos modelos e a definição dos parâmetros que os compõem seguiu o fluxograma apresentado na Figura 7, implementados com a biblioteca Python *Scikit-Learn* e *Seaborn*<sup>5</sup>.

Figura 7 – Fluxograma de treinamento, seleção de parâmetros e validação dos modelos



Os conjuntos de dados pré-processados são primeiramente separados de maneira aleatória com uma proporção de 70% para o treinamento e 30% para a validação. O conjunto de treinamento é utilizado na técnica de validação cruzada, que consiste na separação destes dados em amostras embaralhadas que são utilizadas para o treinamento e para o teste dos modelos. Todos os testes utilizaram uma validação cruzada de 3 conjuntos, ou seja, a cada treinamento da rede, um terço do conjunto foi utilizado somente para comparação e determinação do desempenho da rede.

A validação cruzada permite obter um desempenho prévio do modelo através da avaliação de métricas no próprio conjunto de treinamento. Foi empregado um algoritmo de busca exaustiva denominado *GridSearchCV*, que gera a validação cruzada de uma combinação de hiperparâmetros apresentada a ele. Os modelos que obtiveram menor RMSE médio de teste no algoritmo foram selecionados. Esta combinação resultou em 60 redes neurais artificiais diferentes e utilizou os hiperparâmetros apresentados na Tabela 2.

Tabela 2 –Hiperparâmetros testados nas redes neurais artificiais

Número de Camadas	Quantidade de Neurônios	Função de Ativação
1	8	tanh
2	32	ReLU
	64	logística
	128	

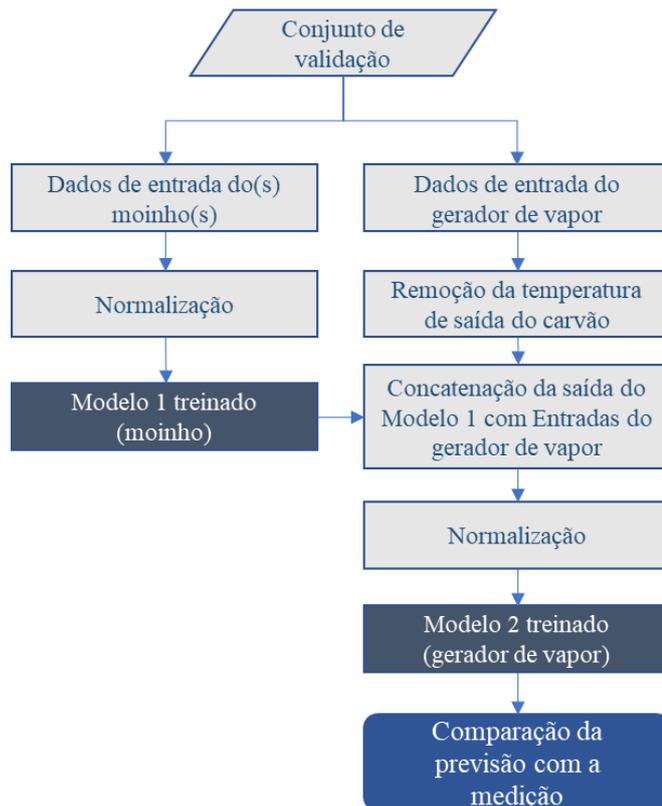
<sup>5</sup> <https://seaborn.pydata.org/>

Outros modelos de regressão foram treinados no conjunto de parâmetros dos moinhos com melhor desempenho dentre as redes neurais para fins de comparação. O treinamento seguiu a mesma metodologia apresentada e utilizou os hiperparâmetros apresentados no Apêndice 1. Ao todo foram avaliados 48 modelos diferentes de SVM e 6 de *Random Forest*.

### 4.3. Comparação e avaliação dos modelos

A comparação dos modelos se deu: 1) entre tipos de modelagem de volume de controle; 2) entre filtros de seleção de parâmetros dos moinhos e; 3) entre modelos de regressão. Todos os modelos definidos durante a validação cruzada foram submetidos ao conjunto de validação previamente separado a fim de verificar o MAE, RMSE e  $R^2$ . A modelagem em volumes de controle separados e posteriormente acoplados teve seu desempenho avaliado após a previsão do conjunto conectado, assim como indica a Figura 8. Esta abordagem difere do volume de controle único, que respeita o fluxograma indicado na Figura 7.

Figura 8 – Fluxograma do acoplamento e da avaliação de desempenho de modelos de regressão em série



Cabe ressaltar a necessidade da normalização do conjunto de entrada do modelo 2 após a substituição da temperatura de saída do carvão pela saída do modelo 1.

## 5. RESULTADOS

Os resultados apresentados estão divididos seguindo as etapas da metodologia de elaboração e avaliação dos modelos. Na descrição dos resultados de desempenho procura-se comparar os modelos criados com ambos os métodos de modelagem do sistema de geração de vapor da unidade de Pecém, a fim de identificar o melhor método para a previsão da eficiência.

## 5.1. Pré-processamento dos dados

Após as etapas de pré-processamento de dados realizadas no conjunto original recebido, foram obtidos quatro conjuntos de dados com características apresentadas na Tabela 3.

Tabela 3 – Descrição dos dados de entrada resultantes do pré-processamento de dados

		moinho A	moinho B	moinho D	média dos moinhos
vazão de ar primário [kg/s]	mín.	20,20	20,12	19,53	20,06
	média	23,44	23,07	23,12	23,18
	máx.	27,34	26,38	26,62	26,71
pressão no coletor de ar primário [mbar]	mín.	66,40	67,19	66,00	63,46
	média	75,57	75,65	76,07	75,66
	máx.	87,72	87,48	90,48	89,60
rotação do classificador [rpm]	mín.	88,71	84,93	88,43	87,07
	média	101,79	94,75	101,94	99,60
	máx.	113,34	104,52	112,61	106,36
temperatura de saída do carvão [°C]	mín.	66,62	67,75	65,26	66,97
	média	76,48	76,80	75,31	76,20
	máx.	85,41	84,98	84,30	83,08
vazão de ar secundário [kg/s]	mín.	35,80	36,54	33,60	35,21
	média	62,46	61,89	62,66	62,45
	máx.	78,79	80,27	78,82	77,46
pressão no coletor de ar secundário [mbar]	mín.	8,05	8,18	6,58	6,90
	média	15,23	15,21	15,21	15,11
	máx.	24,06	24,06	24,06	24,19
excesso de O <sub>2</sub> [%]	mín.	0,29	0,30	0,27	0,37
	média	2,48	2,45	2,41	2,51
	máx.	4,75	4,73	4,71	4,84
número de observações		12229	11504	11532	11088

Observa-se que a maioria dos parâmetros de entrada possui características semelhantes para os diferentes conjuntos. A exceção é a rotação do classificador, que é menor no moinho B e, por consequência, na média dos moinhos. Nota-se um menor número resultante de observações para a média dois moinhos, por se tratar de um conjunto da intersecção das operações dos três moinhos, ou seja, alguns períodos da operação em que o moinho C substituiu outro moinho foram excluídos.

## 5.2. Definição de hiperparâmetros

Na Tabela 4 são apresentados os conjuntos de parâmetros com o menor RMSE médio de teste na validação cruzada. Os resultados completos da matriz de validação cruzada são exemplificados no Apêndice 2 através dos dados da modelagem de todos os moinhos com o gerador de vapor em volume de controle único.

Tabela 4 – Combinação de hiperparâmetros de menor RMSE médio de teste para as diferentes configurações de modelagem de RNA

rede	arquitetura da rede	função de ativação
moinho A + GV (A)	{ 128, 128 }	tanh
moinho B + GV (B)	{ 128, 64 }	tanh
moinho D + GV (D)	{ 128, 128 }	tanh
moinho A, B e D + GV (A, B e D)	{ 64, 128 }	logística
média dos moinhos + GV (média)	{ 128, 64 }	logística
moinho A	{ 64, 128 }	ReLU
GV (A)	{ 64, 64 }	tanh
moinho B	{ 64, 128 }	ReLU
GV (B)	{ 64, 128 }	tanh
moinho D	{ 32, 64 }	ReLU
GV (D)	{ 128, 64 }	tanh
média dos moinhos	{ 64, 64 }	ReLU
GV (média)	{ 128, 128 }	tanh
GV (A, B e D)	{ 128, 32 }	logística

A quantidade de neurônios por camada oculta da rede neural é apresentada na coluna de arquitetura da rede. Pode ser observada a ausência de um padrão de arquitetura e que, em grande parte, não utiliza a quantidade máxima de neurônios testada (128 por camada).

Os hiperparâmetros selecionados pelos algoritmos SVM e Random Forest são apresentados no Apêndice 3.

### 5.3. Desempenho dos modelos de redes neurais

As redes selecionadas através do algoritmo *GridSearchCV* e submetidas ao conjunto de validação tem a performance apresentada na Tabela 5. As colunas “VC separado” referem-se ao desempenho do acoplamento dos modelos.

Tabela 5 – Desempenho da previsão da eficiência dos arranjos VC separado (acoplamento de RNAs) e de VC único modelados com redes neurais artificiais - comparação com o conjunto de validação

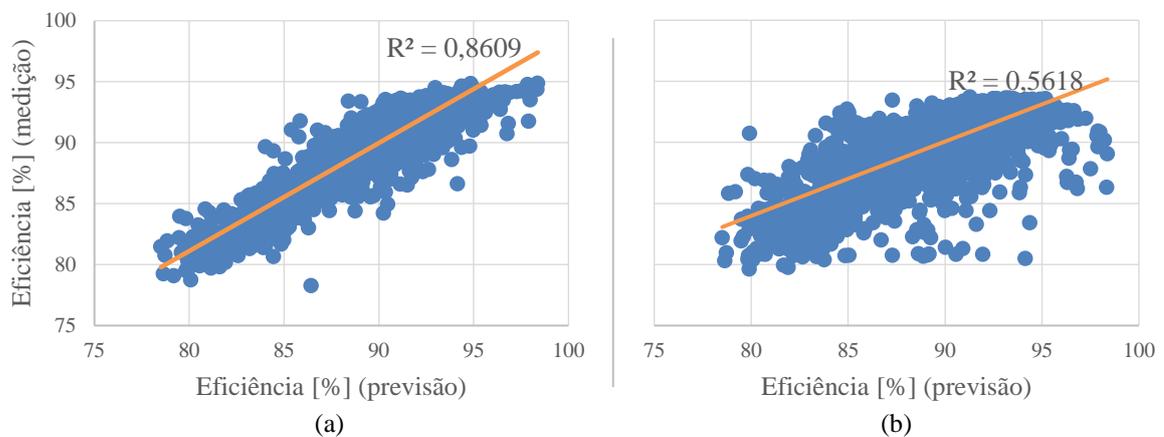
	RMSE		MAE		R <sup>2</sup>	
	VC separado	VC único	VC separado	VC único	VC separado	VC único
moinho A + GV (A)	2,352	1,411	1,773	1,016	0,572	0,846
moinho B + GV (B)	2,404	1,505	1,776	1,091	0,496	0,802
moinho D + GV (D)	2,122	1,261	1,588	0,931	0,591	0,856
média dos moinhos + GV (média)	2,210	1,244	1,606	0,937	0,557	0,861
moinho A, B e D + GV (A, B e D)	2,507	1,201	1,862	0,878	0,427	0,868

A modelagem de todos os moinhos em um único volume de controle, compreendendo os moinhos e o gerador de vapor (moinho A, B e D + GV) exibe a melhor performance entre os arranjos propostos. Este comportamento deve-se à utilização de um maior número de variáveis de entrada e, portanto, da melhor descrição da variação da eficiência. Apesar do melhor desempenho em volume de controle único, o menor desempenho é visualizado na interligação

de modelos de todos os moinhos com o modelo do gerador de vapor, visto que há um maior número de redes interligadas e, por conseguinte, uma maior propagação de erros.

Além disso, é observada uma deterioração significativa do desempenho na modelagem em volume de controle separado e posteriormente acoplado, com MAE e RMSE maiores e um  $R^2$  consideravelmente menor. Selecionou-se o modelo que utiliza os parâmetros médios moinhos (média dos moinhos + GV (média)) para a comparação detalhada das duas metodologias de volume de controle, pois este possui o melhor desempenho com volumes de controle separados. A Figura 9 ilustra a diferença entre as abordagens utilizadas através da comparação do valor previsto e medido para a eficiência.

Figura 9 – Eficiência medida versus eficiência prevista no conjunto de validação dos dados de média dos moinhos. (a) modelagem em volume de controle único. (b) modelagem em volume de controle separado



Observa-se que 86,1% do comportamento da eficiência é representado pelo modelo com volume de controle único e 55,7% com volumes de controle separados. Os gráficos também elucidam que as previsões na nova abordagem são consideravelmente mais dispersas para o domínio analisado.

A razão da deterioração do desempenho nessa modelagem é apresentada na Tabela 6, através da comparação dos resultados de desempenho das redes utilizadas no moinho e no gerador de vapor com aquela utilizada no volume de controle único.

Tabela 6 – Resultados de desempenho das RNA em comparação ao conjunto de validação para a modelagem do sistema com as médias dos moinhos

Rede	MAPE	$R^2$
Rede 1 - média dos moinhos	1,99%	0,316
Rede 2 - GV (entradas médias)	1,76%	0,585
média dos moinhos + GV (média) - VC separado	3,63%	0,557
média dos moinhos + GV (média) - VC único	1,04%	0,861

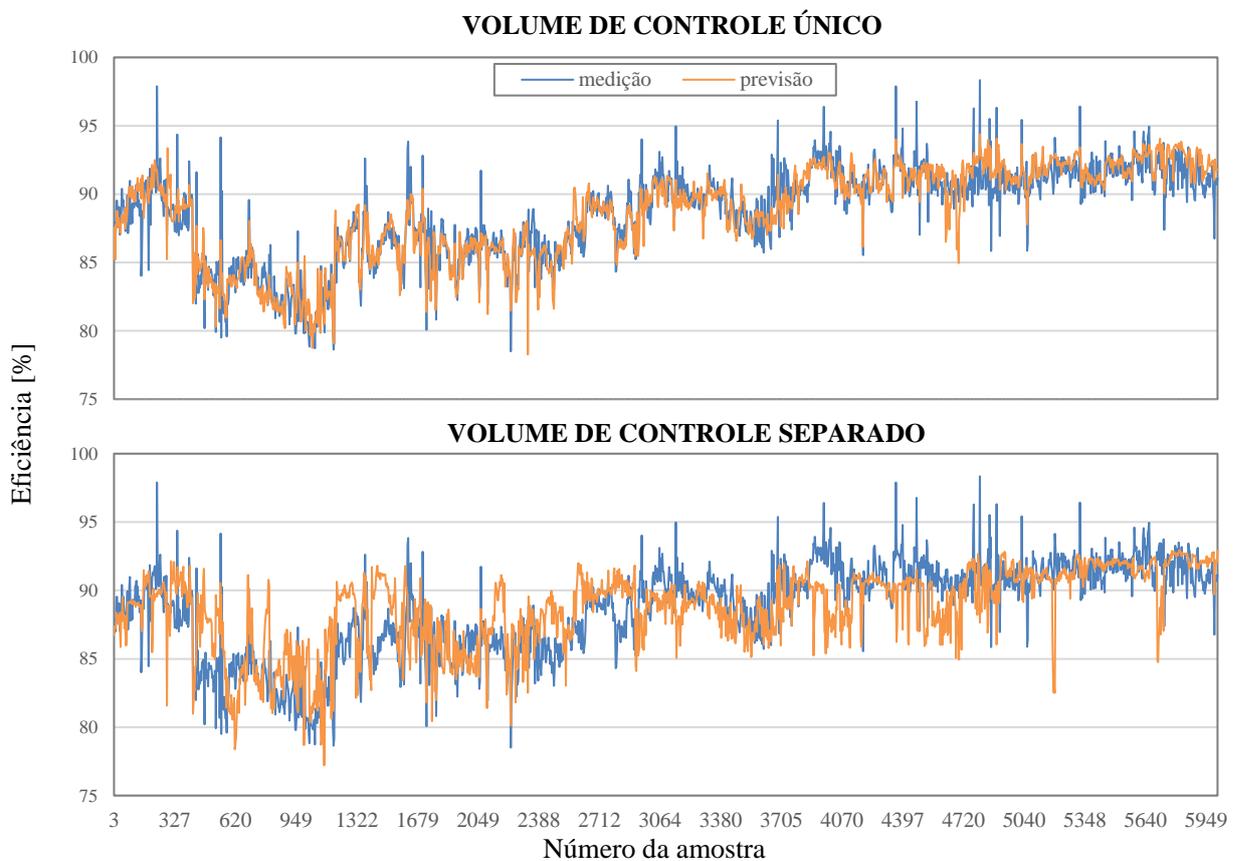
Como existe um erro associado à previsão da temperatura na Rede 1, este erro é propagado à previsão da eficiência pela Rede 2. A ausência de variáveis de entrada como a vazão mássica de carvão na entrada do moinho e a temperatura do ar primário pode explicar o baixo  $R^2$  averiguado na Rede 1.

O ruído da saída da Rede 1 é especialmente prejudicial para a abordagem em dois volumes de controle, pois há um menor número de parâmetros de entrada para a Rede 2 em comparação

com a modelagem em volume de controle único. Além disso a temperatura de saída do carvão pulverizado nos moinhos influencia a variável de estudo, visto que uma temperatura mais elevada do combustível reduz o gasto da energia empregada pelos queimadores para a combustão no gerador de vapor. Esta influência também é verificada em um coeficiente de correlação de Pearson de 0,41 entre a eficiência e a temperatura de saída média do carvão nos moinhos, apresentado juntamente com os demais coeficientes no Apêndice 4.

O contraste de performance entre as modelagens de análise é apresentado também na Figura 10 através do comparativo do comportamento da previsão e da medição de eficiência do gerador de vapor para as diferentes amostras do conjunto de validação.

Figura 10 – Valores previstos e medidos de eficiência em cada amostra do conjunto de validação para as modelagens e volume de controle separado e volume de controle único



Apesar de a modelagem em volume de controle único ser capaz de representar a tendência de variação da eficiência ao longo das amostras de validação, este comportamento não é notado na modelagem em volumes de controle separado. Algumas zonas de distorção de valores notadas principalmente entre as amostras 949 e 1679, e entre as amostras 3705 e 4070 explicitam que há um ruído proveniente de alguma variável que não estava presente na outra modelagem. Esse tipo de comportamento é considerado prejudicial para um sistema de supervisão e de otimização da eficiência de operação do conjunto gerador de vapor, visto que picos inexistentes de eficiência são apresentados apesar de não serem observados nas medições. A análise de resíduos para esta comparação é apresentada no Apêndice 5.

#### 5.4. Comparação entre modelos de regressão

Os outros modelos de regressão submetidos ao conjunto de dados com variáveis médias dos moinhos apresentaram resultados dispostos na Tabela 7.

Tabela 7 - Desempenho da previsão da eficiência dos arranjos VC separado (acoplamento de RNAs) e de VC único modelados com redes neurais artificiais, regressão linear múltipla, *Random Forest* e *Support Vector Machine Regressor* - comparação ao conjunto de validação

	RMSE		MAE		R <sup>2</sup>	
	VC separado	VC único	VC separado	VC único	VC separado	VC único
Redes Neurais Artificiais	2,210	1,244	1,606	0,937	0,557	0,861
Regressão Linear Múltipla	2,517	1,649	1,928	1,251	0,426	0,754
Random Forest	2,081	1,022	1,507	0,722	0,607	0,905
Support Vector Machine (SVM)	2,281	1,120	1,625	0,828	0,528	0,886

As redes neurais artificiais têm seu uso justificado perante à regressão linear múltipla e ao SVM. Entretanto, o algoritmo *Random Forest* apresentou um RMSE até 5,8% menor do que às RNAs. Verificou-se uma melhora de desempenho com o algoritmo *Random Forest* para ambas as modelagens, mas o desempenho para a abordagem com volumes de controles separados ainda não é satisfatório a ponto de validar sua utilização na previsão da eficiência.

#### 6. CONCLUSÃO

Este trabalho analisou dados reais e controláveis da Usina Térmica de Pecém com duas abordagens de representação do sistema moinhos de carvão e gerador de vapor, uma que inclui o sistema completo (volume de controle único) e outra acoplado (volumes de controles separados para os moinhos e o gerador). Averiguou-se que a abordagem de volume de controle único produziu modelos com menor erro, comparativamente à opção de volumes de controles separados para os moinhos e para o gerador de vapor, posteriormente acoplados em série. Portanto, um *digital twin* que modele estes dois subsistemas da geração de vapor separadamente deve envolver outras estratégias de acoplamento.

Ao comparar uma abordagem com volume de controle único à nova modelagem proposta neste trabalho, verificou-se que modelos com redes neurais artificiais propagaram erros significativos e prejudiciais. Para o conjunto de dados com variáveis médias dos moinhos o RMSE aumentou de 1,244 para 2,210, e o R<sup>2</sup> reduziu consideravelmente, de 0,861 para 0,557.

Comprovou-se ainda que os modelos de regressão *Random Forest* e SVM também não representam satisfatoriamente a eficiência do gerador de vapor quando modelados em volumes de controle separados, apesar de o *Random Forest* apresentar RMSE até 5,8% menores que às redes neurais em volumes de controle único.

De maneira geral, espera-se uma deterioração do desempenho com modelos de regressão conectados. Entretanto, pode ser estudada a inclusão de variáveis não controláveis nos modelos, como a vazão de entrada de carvão nos moinhos, a pressão diferencial no moinho, a temperatura de saída dos gases, entre outros. Mesmo que não possam ser alteradas na rotina de operação, essas variáveis podem ser de grande valor para descrever os fenômenos que ocorrem no sistema de moagem e de geração de vapor, principalmente por conta da pequena quantidade de entradas dos modelos com volume de controle separado neste estudo. A utilização de redes neurais artificiais recorrentes em um estudo futuro pode incluir na análise uma variável temporal dos dados para o sistema. Este tipo de abordagem permitirá avaliar tendências históricas e o impacto

de eventos específicos na eficiência do gerador de vapor. Sendo assim, efeitos da manutenção de um equipamento e da degradação de componentes do sistema na eficiência poderiam ser percebidos pelo modelo para resultar em um melhor desempenho.

## REFERÊNCIAS BIBLIOGRÁFICAS

ANEEL. **ANEEL. BIG - Banco de Informações de Geração**. 2019. Disponível em: <<https://www.aneel.gov.br/dados/geracao>>

CHETAN, T.; BHAVESH, P. K. Efficiency with different GCV of coal and efficiency improvement, International Journal of Innovative Research in Science, Engineering and Technology, vol. 2, p. 1518-1527, 2013.

HAYKIN, S. **Neural networks and learning machines**. 3<sup>a</sup>. ed.: Pearson Prentice Hall, 2009.

IEA. **Data and Statistics**. 2018. Disponível em: <<https://www.iea.org/data-and-statistics?country=WORLD&fuel=Energy%20supply&indicator=ElecGenByFuel>>

JAMES, G.; HASTIE, T.; TIBSHIRANI, D. W. R. **An Introduction to Statistical Learning with Applications in R**. 7<sup>a</sup> ed. Springer, 2017.

JUSTI, R. S. **Ferramenta Computacional para Cálculo de Rendimento Térmico de Geradores de Vapor**. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

LAWSON, A.; PEREIRA, G. **Termelétricas e seu papel na matriz energética brasileira**. Caderno Opinião, FGV Energia. Fevereiro, 2017. Disponível em: <<http://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/20398/Coluna%20Opinio%20Fevereiro%20-%20Termeletricas%20%20Andre%20e%20Guilherme.pdf?sequence=1&isAllowed=y>>

PATWAL, A. **The Power Interview: What is a Digital Twin?**. Aaron Larson. POWER, 2020.

PAVLAK, L. P. **Previsão de Emissões de NOx de uma Usina Termelétrica à Carvão Por Meio de Redes Neurais Artificiais**. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

ROCHA, B. P. **Efficiency and NOx Emissions Optimization by Genetic Algorithm of a Coal-Fired Steam Generator Modeled with Artificial Neural Networks**. Monografia (Trabalho de Conclusão do Curso em Engenharia de Energia) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

SCIKIT LEARN. **Scikitlearn User Guide**. Disponível em: <<https://sklearn.org>>

SHIN, H. B.; LI, X. I; JEONG, I. Y., PARK, J. M., LEE, S. **Modeling and Parameter Identification of Coal Mill**. Journal of Power Electronics, vol. 9. p. 700-707. Coréia do Sul, 2009.

VIEIRA, L. W. **Standardization of steam generator operation in order to increase performance through process surrogate models**. Escola de Engenharia, Universidade Federal do Rio Grande do Sul. Porto Alegre, 2020

WEBER, N. D. A. B.; ARMSTRONG, J. J.; SCHNEIDER, P. S. **Machine Learning Approach To Simulate A Coal-Fired Steam Generator: Study Case Of Pecem**. COB-2019-0221, [s. l.], 2019.

YUAN, Z.; MENG, L.; GU, X.; BAI, Y.; CUI, H.; JIANG, C. **Predictions of NO<sub>x</sub> emissions for coal-fired power plants with stacked-generalization ensemble method**. Fuel vol. 289. China, 2021.

ZHANG, Y. G.; WU, H.; WANG, J.; OLUWANDE, G. ZHOU, X. X. **Coal Mill Modeling by Machine Learning Based on Onsite Measurements**. IEEE Transactions on Energy Conversions, Vol. 17. p. 549-555. 2002.

**APÊNDICE 1 - Hiperparâmetros do SVM e do *Random Forest* utilizados na validação cruzada**

Random Forest	SVM		
Número de Árvores, N	Função Kernel	Parâmetro $\epsilon$	Parâmetro C
10	Polinomial - Grau 3	0,75	10
50	Logística	0,5	50
100	Função Base Radial	0,1	100
200		0,01	200
400			
600			

**APÊNDICE 2 – Conjunto de dados gerados à partir do *GridSearchCV* - conjunto com variáveis médias e volume de controle único**

Função de ativação	Arquitetura da Rede	RMSE Teste (média)	RMSE Treino (média)
tanh	(8,)	-1,54616	-1,5232
tanh	(32,)	-1,51371	-1,49592
tanh	(64,)	-1,49578	-1,47975
tanh	(128,)	-1,50269	-1,48084
tanh	(8, 8)	-1,41309	-1,38128
tanh	(8, 32)	-1,53933	-1,52753
tanh	(8, 64)	-1,46742	-1,44094
tanh	(8, 128)	-1,50774	-1,46925
tanh	(32, 8)	-2,69475	-2,69567
tanh	(32, 32)	-1,32145	-1,26528
tanh	(32, 64)	-1,28976	-1,20482
tanh	(32, 128)	-1,63669	-1,60074
tanh	(64, 8)	-3,3672	-3,36724
tanh	(64, 32)	-1,27946	-1,19981
tanh	(64, 64)	-1,27303	-1,21124
tanh	(64, 128)	-1,29456	-1,22848
tanh	(128, 8)	-3,37083	-3,37003
tanh	(128, 32)	-2,69406	-2,67619
tanh	(128, 64)	-1,40505	-1,37473
tanh	(128, 128)	-1,31932	-1,2536
relu	(8,)	-1,55076	-1,53978
relu	(32,)	-1,45368	-1,3827
relu	(64,)	-1,40916	-1,32582
relu	(128,)	-1,40893	-1,32909
relu	(8, 8)	-1,54597	-1,52149
relu	(8, 32)	-1,48868	-1,46783
relu	(8, 64)	-1,51791	-1,46712
relu	(8, 128)	-1,52397	-1,48786
relu	(32, 8)	-1,44935	-1,41249
relu	(32, 32)	-1,38715	-1,29178
relu	(32, 64)	-1,406	-1,3352
relu	(32, 128)	-1,36832	-1,276
relu	(64, 8)	-1,37615	-1,29768
relu	(64, 32)	-1,34945	-1,24905
relu	(64, 64)	-1,32866	-1,25661
relu	(64, 128)	-1,36817	-1,27287
relu	(128, 8)	-1,38526	-1,31878
relu	(128, 32)	-1,40895	-1,32905
relu	(128, 64)	-1,35155	-1,2784
relu	(128, 128)	-1,32824	-1,25643
logistic	(8,)	-1,56173	-1,53801
logistic	(32,)	-1,49619	-1,47817

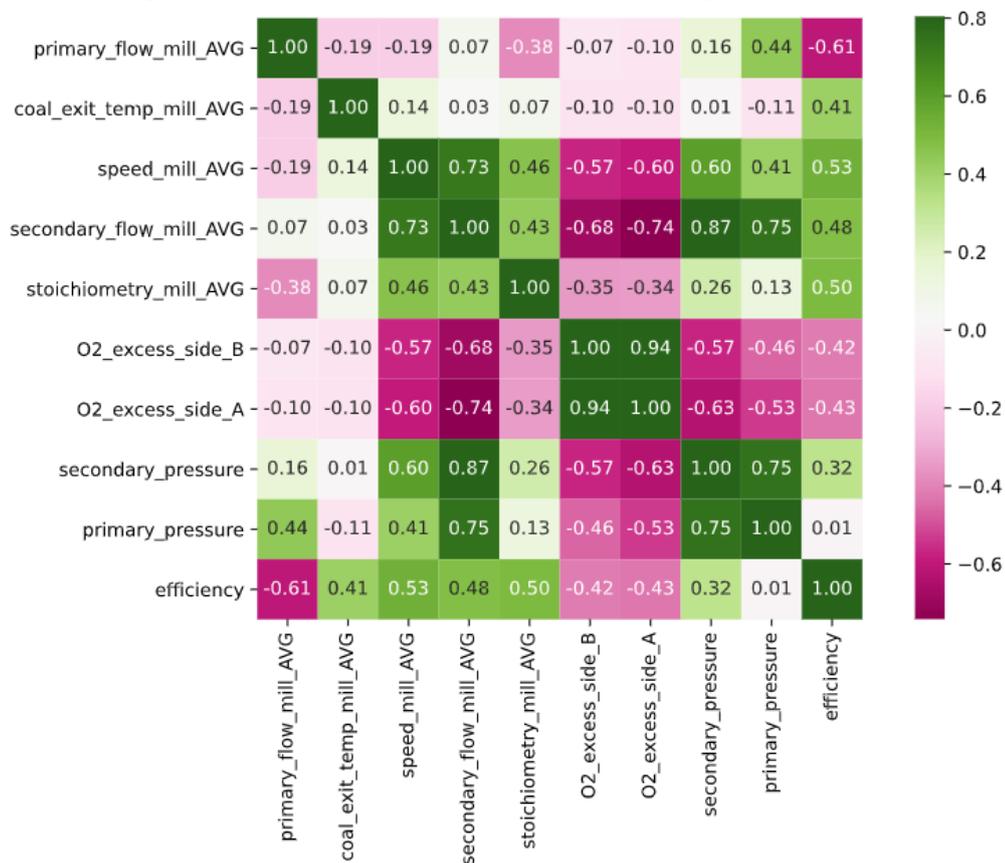
logistic	(64,)	-1,62358	-1,60676
logistic	(128,)	-1,67969	-1,67378
logistic	(8, 8)	-1,39155	-1,3634
logistic	(8, 32)	-1,40862	-1,37442
logistic	(8, 64)	-1,3914	-1,36194
logistic	(8, 128)	-1,4589	-1,4317
logistic	(32, 8)	-1,32909	-1,27687
logistic	(32, 32)	-1,30494	-1,24988
logistic	(32, 64)	-1,31737	-1,26733
logistic	(32, 128)	-1,34621	-1,29898
logistic	(64, 8)	-1,37073	-1,33399
logistic	(64, 32)	-1,28434	-1,21966
logistic	(64, 64)	-1,32345	-1,28247
logistic	(64, 128)	-1,29958	-1,23553
logistic	(128, 8)	-1,40825	-1,3502
logistic	(128, 32)	-1,29705	-1,221
logistic	(128, 64)	-1,26852	-1,19841
logistic	(128, 128)	-1,29584	-1,23073

### APÊNDICE 3 – Hiperparâmetros selecionados nos modelos SVM e Random Forest

análise	Random Forest	SVM
média dos moinhos + GV (média)	N = 200	Base radial; C=50 ; $\epsilon = 0,5$
média dos moinhos	N = 400	Base radial; C=200 ; $\epsilon = 0,75$
GV (média)	N = 400	Base radial; C=200 ; $\epsilon = 0,75$

### APÊNDICE 4 - Coeficientes de correlação de Pearson – variáveis médias dos moinhos

Figura A1 – Matriz de coeficientes de correlação de Pearson



## APÊNDICE 5 – Análise de resíduos das redes neurais artificiais

Figura A2 – Resíduos percentuais apresentados pelas redes neurais no conjunto de variáveis médias dos moinhos. (a) volume de controle único. (b) volume de controle separado

