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

PREVISÃO DE EMISSÕES DE NOX DE UMA USINA TERMELÉTRICA À CARVÃO POR MEIO DE REDES NEURAIS ARTIFICIAIS

por

Leonardo Paini Pavlak

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. Paini Pavlak, Leonardo PREVISÃO DE EMISSÕES DE NOX DE UMA USINA TERMELÉTRICA À CARVÃO POR MEIO DE REDES NEURAIS ARTIFICIAIS / Leonardo Paini Pavlak. -- 2019. 25 f. Orientador: Paulo Smith Schneider. Coorientadora: Natália de Assis Brasil Weber. Trabalho de conclusão de curso (Graduação) --Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Curso de Engenharia Mecânica, Porto Alegre, BR-RS, 2019. 1. Redes Neurais Artificiais. 2. NOx. 3. Análise de Sensibilidade. 4. Usina Termelétrica. I. Smith Schneider, Paulo, orient. II. de Assis Brasil Weber, Natália, coorient. III. Título. Leonardo Paini Pavlak

PREVISÃO DE EMISSÕES DE NOX DE UMA USINA TERMELÉTRICA À CARVÃO POR MEIO DE REDES NEURAIS ARTIFICIAIS

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 Coorientadora: M.^a Natália de Assis Brasil Weber

Comissão de Avaliação:

Prof. Dr. Bardo Ernst Josef Bodmann

Prof. Dr. Guilherme Henrique Fiorot

Prof^a. Dra. Letícia Jenisch Rodrigues

Porto Alegre, dezembro de 2019

AGRADECIMENTOS

Aos meus pais, que me deram amor, educação e sempre me apoiaram em todas as etapas da minha vida.

Ao meu irmão, que sempre foi um exemplo para mim.

Ao meu orientador, Paulo Schneider, pela confiança depositada em mim e pelo incentivo que possibilitou a realização deste trabalho.

À minha coorientadora, Natália Weber, pela paciência, ensinamentos e suporte durante este aprendizado.

Aos meus amigos, que tornaram essa caminhada muito mais prazerosa.

"Far better an approximate answer to the right question, which is often vague, than an exact answer to the wrong question, which can always be made precise."

John W. Tukey

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL ESCOLA DE ENGENHARIA - CURSO DE ENGENHARIA MECÂNICA TRABALHO DE CONCLUSÃO DE CURSO – 2019/2

PREVISÃO DE EMISSÕES DE NOx DE UMA USINA TERMELÉTRICA À CARVÃO POR MEIO DE REDES NEURAIS ARTIFICIAIS

Paini Pavlak, Leonardo

leonardo.ppavlak@hotmail.com

Resumo. O monitoramento de emissões de NOx em usinas termelétricas à base de carvão é uma exigência dos órgãos de controle e fiscalização ambientais, e geralmente realizado por sensores físicos. As técnicas baseadas em machine learning se mostraram eficientes na previsão deste tipo de emissão e apresentam-se como uma alternativa para esse acompanhamento. O presente trabalho trouxe o desenvolvimento de uma rede neural artificial a partir de parâmetros relacionados ao moinho de carvão pulverizado e de alimentação da fornalha da Usina Termelétrica de Pecém para a previsão de emissão de NOx durante o processo de queima. A análise do Erro Percentual Absoluto Médio (MAPE) mostrou um erro de 2,67% entre os valores de NOx previstos e os valores medidos. O coeficiente de determinação R^2 da dispersão dos valores medidos "versus" os valores previstos ficou em 0,93. Uma análise de sensibilidade indicou o comportamento do NOx previsto a partir da variação individual de cada parâmetro de entrada. O modelo regido por dados se mostrou eficaz na solução do problema proposto.

Palavras-chave: redes neurais artificiais, NOx, sensibilidade, usina termelétrica.

Abstract. The tracking of NOx emissions in coal-fired power plants is required by the environmental regulatory agencies and usually done through the use of physical detectors. Machine learning based techniques has shown to be efficient predicting this kind of emission and appears as an alternative for this tracking. The present work presented the development of an artificial neural network from parameters related to the pulverized coal mill and the furnace feeder of the Pecém thermal power plant to predict the emission of NOx during the burning process. The analysis of the Mean Absolute Percentage Error (MAPE) showed an error of 2,67% between the predicted values of NOx and the measured ones. The determination coefficient R^2 of the scatter diagram of measured values versus predicted values was 0,93. A sensitivity analysis indicated the behavior of the predicted NOx through the individual variation of each input parameter. The data-driven model has shown to be effective in the solution of the proposed problem.

Keywords: artificial neural networks, NOx, sensitivity, thermal power plant.

1. INTRODUÇÃO

A geração de energia elétrica a partir da queima de carvão compreende aproximadamente 38% da geração mundial. Por mais que essa fonte de energia esteja aos poucos sendo substituída por fontes renováveis nos Estados Unidos e em grande parte dos países da Europa, sua utilização continua aumentando consideravelmente em países asiáticos, como China e Índia, ocasionando num aumento mundial total de 3% entre 2017 e 2018 (IEA, 2019).

O aumento da utilização de fontes de energia baseadas na queima de combustíveis fósseis reforça a necessidade de um controle rígido de emissões de poluentes provenientes destas fontes, como os óxidos de nitrogênio (NOx), óxidos de enxofre (SOx), dióxido de carbono (CO₂) e material particulado (MP) (GAFFNEY; MARLEY, 2009). Em virtude disso, a utilização de técnicas baseadas em *machine learning*, como as Redes Neurais Artificiais (RNA), tem sido foco de diversos estudos, mostrando-se útil para a previsão de parâmetros em sistemas complexos e de difícil modelagem física, como é o caso de geradores de vapor de usinas termelétricas.

1.1. Revisão Bibliográfica

Uma vez que o monitoramento e controle de emissões de poluentes em usinas termelétricas à base de carvão tem uma importância tão significativa, métodos de previsão dessas emissões a partir de redes neurais artificiais têm se mostrado uma solução eficaz. Mankar et al., (2014) mencionam o alto custo dos instrumentos de medição de poluentes, propondo a utilização de uma RNA combinada com um método meta-heurístico de recozimento simulado para a previsão de NOx de uma usina termelétrica de carvão, obtendo resultados satisfatórios em comparação com CFD.

Ermel et al., (2017) propuseram a utilização de modelo de dimensão zero para calcular a formação de NOx de uma usina termelétrica sob diferentes condições de entrada, apresentando desvios relativos altos, mas dentro da magnitude das medições deste parâmetro, indicando que o método pode ser utilizado como uma guia preliminar para entender o comportamente da fornalha.

Com o intuito de reduzir a taxa de emissão de NOx e otimizar a operação de uma usina de energia alimentada por carvão, Tuttle et al., (2019) propouseram o modelamento de uma rede neural online com otimização por enxame de partículas. Após a implementação da rede, chegaram a uma redução de 22,5% na emissão desse poluente, comprovando a eficácia do método.

1.2. Objetivos

O presente trabalho tem como objetivo o desenvolvimento de uma Rede Neural Artificial (RNA) capaz de fazer a previsão da emissão de NOx proveniente da fornalha da Usina Termelétrica (UTE) de Pecém.

2. FUNDAMENTAÇÃO TEÓRICA

2.1.Visão geral do NOx

Os óxidos de nitrogênio, conhecidos como NOx, são uma generalização para os compostos químicos formados por nitrogênio e oxigênio: NO, NO₂, N₂O, N₂O₄, entre outras. Estes óxidos causam diversos problemas quando presentes nas camadas mais baixas da atmosfera, como a formação de ozônio (potencial causador de doenças respiratórias em seres humanos) quando há o contato do NO com o oxigênio, formação do ácido nítrico (HNO₃) através do contato do NO₂ com a água, causando as chamadas "chuvas ácidas", com grande potencial corrosivo em construções, pontes, plantas e esculturas. Além disso, ao se misturar com hidrocarbonetos presentes na atmosfera,

o NO₂ contribui para a formação dos nevoeiros de fumaça, problema recorrente em grandes cidades (BAUKAL JR., 1998).

Em virtude desse alto potencial poluente do NOx, limites para sua emissão em usinas termelétricas à base de óleo combustível são estabelecidos pelo CONAMA¹ (Conselho Nacional do Meio Ambiente) na Resolução N°382/2007, apresentados na Tabela 1.

Tabela 1: Limites para emissões de NOx por unidades de geração de calor a partir da combustão externa de óleo combustível.

Potência térmica nominal (MW)	NOx (como o NO ₂) $[mg/m_N^2]$		
MW < 10	1600		
$10 \le MW \le 70$	1000		
MW > 70	1000		
Fonte: CONSELHO NACIONAL DO MEIO AMBIENTE (2006)			

De acordo com Turns (2013), a formação do NO pode ser descrita por três tipos bem definidos, chamados de NO-Térmico (ou de Zeldovich), NO-Imediato e NO de Combustível. Martins e Ferreira (2011) expressam a taxa de formação do NO-Térmico de acordo com a Eq. (1)

$$\frac{\partial R_{NO-T\acute{e}rmico}}{\partial t} = \frac{6 \times 10^{16} exp\left(\frac{-69090}{T_{fg}}\right) \left[C_{N_2}\right]_{eq} \left[\sqrt{C_{O_2}}\right]_{eq}}{\sqrt{T_{fg}}} \tag{1}$$

onde $[C_{N_2}]_{eq}$ é a concentração molar de nitrogênio em moles/cm³ na condição de equilíbrio, T_{fg} é a temperatura homogênea da fornalha e $[\sqrt{C_{O_2}}]_{eq}$ é a concentração molar do oxigênio, também na condição de equilíbrio, em moles/cm³.

Segundo Ermel (2017), a taxa de formação do NO de combustível é definida pela Eq. (2)

$$\frac{\partial R_{NO-HCN}}{\partial t} = 10^{10} C_{HCN} C_{O_2}^b exp\left(\frac{-33713}{T_{fg}}\right)$$
(2)

onde b = 0 quando $C_{O_2} > 0,018$ e b = 1 quando $C_{O_2} < 0,0025$.

2.2. Queimadores Low-NOx

Diferentes soluções foram criadas e aperfeiçoadas ao longo do tempo para reduzir a emissão de NOx. O controle dessas emissões, na maioria das vezes, é realizado diretamente no processo de combustão. Para o caso de geradores de vapor de carvão pulverizado, utilizam-se principalmente os chamados queimadores *Low-NOx*, como mostrados na Figura 1.

¹ Utilizados os limites de emissões referentes a fontes fixas movidas à óleo combustível, uma vez o CONAMA não estabelece limites para fontes fixas movidas à carvão (EPE, 2007).



Fonte: TOLMASQUIM, 2016

Estes queimadores são capazes de reduzir a formação do NOx a partir do controle da mistura ar e combustível. O operador do equipamento tem a possibilidade de fazer este ajuste, uma vez que o equipamento é composto por um injetor de ar e combustível, e mais dois injetores de ar. Dessa forma, trabalha-se com regiões sub-estequiométricas na zona de estagiamento e excesso de O_2 na zona final de combustão (COOPER, 2002).

2.3. Redes Neurais Artificiais

Uma rede neural é um modelo regido por dados composto por um conjunto de neurônios artificiais distribuídos em camadas e com função de processar dados (ARMSTRONG, 2018). Uma RNA em sua forma mais simples, consiste em três camadas distintas de processamento: camada de entrada, camadas escondidas e as camadas de saída. Os três elementos principais de um neurônio são mostrados na Figura 2, sendo eles as sinapses, funções de soma e funções de ativação, segundo Haykin *et al.*, (2009).



Figura 2: Representação de um Neurônio Artificial.

Fonte: Adaptado de HAYKIN, 2009

O funcionamento matemático de um neurônio é dado pelas Eq. (3) e Eq. (4)

$$u_k = \sum_{m}^{j} w_{kj} x_j \tag{3}$$

$$y_k = \varphi(u_k + b_k) \tag{4}$$

onde x_j representa os parâmetros de entrada e w_{kj} os pesos das funções sinápticas dos neurônios. Ao multiplicar estes parâmetros, têm-se a saída da combinação linear dos sinais de entrada, representada

por u_k ; b_k é um *bias*, φ é a função de ativação e y_k é o sinal de saída do neurônio. Cabe ressaltar que o *bias b_k* tem uma função de aplicar uma transformação afim na saída u_k , como mostra a Eq. (5)

$$v_k = u_k + b_k \tag{5}$$

As funções de ativação possuem o papel de definir o comportamento da saída de cada neurônio em uma RNA. Esta saída, por sua vez, é utilizada como entrada para o próximo neurônio e assim por diante, até que uma solução aceitável para o problema seja encontrada (ARMSTRONG, 2018). As funções de ativação são elementos básicos da arquitetura de RNAs, uma vez que são responsáveis pela introdução de propriedades não lineares à rede. Sem essas funções, as ativações de cada nó da rede seria feita de maneira linear e demandaria mais tempo para processar as informações necessária para resolver os problemas (WEBER et al., 2019).

2.4. Análises de Incertezas

É necessário entender os erros atrelados às previsões feitas por RNAs para avaliar seu desempenho. Algumas das métricas mais comuns utilizadas para analisar essas incertezas são o MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*), MAPE (*Mean Absolute Percentage Error*) e o R² (coeficiente de determinação).

O MAE é uma das medidas estatísticas mais utilizadas para a análise dos erros de RNAs, e é definido pela Eq. (6)

$$MAE = \frac{1}{n} \sum_{i=1}^{n} (|X_{medido} - X_{previsto}|)$$
(6)

onde X_{medido} é o valor medido da variável em questão, e $X_{previsto}$ é o valor previsto pela RNA. Uma das vantagens dessa métrica é o fato de possuir a mesma unidade de medida da variável que está sendo estudada. Contudo, por ser um erro absoluto, não indica a direção do erro (MISHRA, 2018).

O RMSE, por sua vez, pode ser entendido como um "desvio padrão" das previsões da RNA, e é dado pela Eq. (7)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (X_{medido} - X_{previsto})^2}$$
(7)

Este erro também possui unidade igual da variável em questão, e indica o quão longe do valor medido geralmente encontram-se as previsões da RNA (ZUMEL; MOUNT, 2014). O MAPE é dado pela Eq. (8)

$$MAPE = \frac{100\%}{n} \sum_{i=1}^{n} \left(\left| \frac{X_{medido} - X_{previsto}}{X_{medido}} \right| \right)$$
(8)

Este erro indica a média percentual dos erros ponto a ponto. É uma boa métrica a ser analisada quando atrelada à um histograma de erros. Por fim, o coeficiente de determinação R² é uma medida bastante usual em análises estatísticas, por mais que nem sempre o seu significado seja tão claro, dado pela Eq. (9)

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (X_{real} - \bar{X}_{previsto})^{2}}{\sum_{i=1}^{n} (X_{real})^{2}}$$
(9)

É uma métrica adimensional que varia entre 0 e 1, sendo que quanto mais próximo de 1, melhor o modelo de ajusta à amostra (SCHNEIDER, 2018).

3. ESTUDO DE CASO

A Usina Termelétrica Pecém opera em duas faixas de potência, 240 MW e 360 MW, as quais são selecionadas dependendo da demanda energética definida pelo ONS, Operador Nacional do Sistema Elétrico (REICHERT et al., 2019). Ela opera através da queima de carvão pulverizado proveniente de quatro moinhos de carvão, sendo que apenas 3 deles operam simultaneamente, enquanto um moinho sempre permanece desativado. A queima ocorre em uma fornalha com queimadores do tipo "*Low-NOx*".

Os parâmetros controláveis do moinho são a temperatura, pressão e vazão de ar primário, responsáveis pela remoção da umidade do carvão e transporte deste carvão pulverizado, além da velocidade do classificador dinâmico dos moinhos, responsável pelo controle da granulometria do carvão transportado para o queimador da fornalha. A vazão de carvão pulverizado é uma consequência dos parâmetros anteriores.

O conjunto bruto de dados² utilizado neste trabalho é proveniente do sistema supervisório da Usina de Pecém durante o período entre 01 de janeiro de 2018 a 27 de maio de 2019, com intervalo de aquisição de 30 minutos, totalizando 24578 aquisições. A Figura 3 mostra um esquema da planta, bem como os parâmetros de entrada e saída selecionados a partir deste conjunto.

Figura 3: Desenho esquemático do conjunto de moinhos e do gerador de vapor da UTE Pecém e seus parâmetros de entrada e saída selecionados.



² Cordialmente disponibilizado pela Bárbara Pacheco da Rocha, bolsista de iniciação científica do LETA-UFRGS e participante do projeto PECEM.

Os parâmetros de entrada, utilizados posteriormente para a criação da RNA, foram listados na legenda da Figura 3, e o parâmetro de saída (NOx) foi representado na saída do gerador de vapor.

Duas simplificações referentes aos moinhos foram adotadas a fim de obter dados que traduzem o comportamento do sistema: 1^a – a Vazão de Ar Primário (V1) é o resultado da soma das vazões dos três moinhos; 2^a - A Temperatura de Ar Primário (T1), a Pressão do Coletor de Ar Primário (P1) e a Velocidade do Classificador Dinâmico dos Moinhos (ω) são o resultado da média dos três moinhos.

4. METODOLOGIA

O presente trabalho utilizou métodos estatísticos e um modelo orientado a dados (Redes Neurais Artificiais) para estimar a emissão de NOx na fornalha da Usina Termelétrica de Pecém a partir de parâmetros dos moinhos de carvão e do gerador de vapor. O fluxograma da Figura 4 apresenta de maneira esquemática a forma como foi desenvolvida a metodologia do trabalho.



Figura 4: Fluxograma da metodologia.

Cada passo do fluxograma da Figura 4 foi detalhado nas subseções seguintes.

4.1. Pré-processamento dos dados

A análise proposta foi precedida por um pré-processamento dos dados brutos provenientes dos sistemas de medição da UTE Pecém. Este passo compreende as etapas de seleção dos dados que estão na faixa de operação determinada e remoção de números nulos, negativos e *outliers*, como mostra a Figura 5.



Figura 5: Fluxograma de pré-processamento dos dados.

A partir do conjunto bruto de dados, foi selecionada primeiramente a faixa de geração de energia entre 340 MW e 365 MW, que caracteriza uma faixa de operação usual da UTE Pecém.

Em seguida, foram removidos os instantes de medição em que um ou mais parâmetros apresentaram valores nulos ou negativos, que indicam problemas ou inconsistências de medição dos sensores naquele instante de tempo. Por fim, foi aplicado o Método de Tukey (*boxplot*) (SEO, 2006) para remoção de pontos discrepantes (*outliers*).

4.2. Análise estatística dos dados

Utilizou-se a correlação de Pearson para entender de que forma os parâmetros de entrada estavam correlacionados entre si e com o parâmetro de saída (NOx). A partir deles, foram selecionados os parâmetros de entrada utilizados na formação de duas redes distintas: RNA_a e RNA_b, onde os subíndices "a" e "b" correspondem ao total de parâmetros de entrada de cada rede.

Foi definido que a primeira rede (RNA_a) seria formada por todos os parâmetros disponíveis, independentemente dos coeficientes de correlação encontrados. A segunda (RNA_b) foi formada apenas pelos parâmetros que tivessem correlação maior que 0,10, removendo assim as correlações muito baixas.

4.3. Seleção da arquitetura da rede

Os passos para construção das RNAs e definição de suas arquiteturas finais foram esquematizados no fluxograma da Figura 6.



Figura 6: Fluxograma de desenvolvimento das RNAs.

A seleção da arquitetura de rede mais adequada para o problema proposto foi feita a partir de tentativas e erros, onde foram variados os seguintes hiperparâmetros: número de camadas, número de neurônios e tipo de função de ativação. A Tabela 2 mostra os hiperparâmetros que foram variados na seleção da arquitetura de rede mais adequada.

de Camadas	N° de Neurônios	Funções de Ativação
1	10	
2	32	ReLU Sigmoide
3	64	Sigilioide Tangente Hiperbólica
4	128	rangeme mperoonea

Tabela 2: Hiperparâmetros utilizados para a seleção da melhor arquitetura da rede. N° de Camadas | N° de Neurônios | Funcões de Ativação

A arquitetura de rede selecionada foi a que apresentou menores resultados para MAE e RMSE durante as etapas de treinamento e validação.

4.4. Análise da performance da RNA

A análise da performance das redes foi feita a partir de uma comparação entre os valores previstos e os valores medidos da parcela de dados separada para teste, como definido na Figura 6, comparados com o auxílio das medidas estatísticas MAPE, MAE, RMSE e R². A comparação entre os resultados dos erros entre RNA_a e RNA_b, definiu a rede mais adequada para previsão de NOx, selecionando a que apresentou os menores erros, denominada RNA final.

4.5. Comparação com regressão linear múltipla

Foram utilizados os mesmos parâmetros empregados para criar a RNA final para montar uma regressão linear múltipla (RLM), cuja forma geral segue a Eq. (10)

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \tag{10}$$

onde y é o valor previsto de NOx, x_j são os parâmetros de entrada da regressão e β_j os coeficientes de regressão (QUININO et al., 1991). A construção da RLM empregou o mesmo conjunto de dados anteriormente utilizado para o treinamento da RNA.

4.6. Análise de sensibilidade

O procedimento de análise de sensibilidade da RNA final foi empregado para verificar o impacto de cada parâmetro de entrada no valor de NOx previsto pela rede, bem como a presença de correlações não lineares entre cada entrada e o modelo de previsão de NOx, como sugerido por Elangasinghe et al., (2014). Esta análise buscou verificar as tendências de comportamento da variável de saída. Para cada parâmetro de entrada, foram realizados 50 incrementos uniformes entre os seus valores mínimos e máximos, enquanto os demais parâmetros foram fixados em seus respectivos valores médios.

5. RESULTADOS

Os resultados obtidos através da aplicação da metodologia proposta foram divididos em subseções idênticas às da metodologia.

5.1. Pré-processamento dos dados

Após a aplicação de todas as etapas de pré-processamento, o conjunto final ficou com 7012 dados distribuídos num período de aproximadamente 1 ano e 5 meses. A Tabela 3 mostra informações de cada parâmetro deste conjunto final.

Parâmetro	Mínimo	Máximo	Média
NOx [mg/m _N ³]	220,29	436,72	323,22
Temperatura de Ar Primário [°C]	312,54	359,42	335,30
Temperatura de Ar Secundário [°C]	334,06	385,64	359,33
Pressão do Coletor de Ar Primário [bar]	75,42	94,26	83,97
Pressão do Coletor de Ar Secundário [bar]	14,60	23,97	18,39
Vazão de Ar Primário [kg/s]	71,31	84,40	77,51
Vazão de Ar Secundário [kg/s]	221,78	273,30	247,40
Vazão de Ar de Sobre queima [kg/s]	6,75	16,55	10,52
Vazão de Carvão Pulverizado [t/h]	129,31	148,58	139,16
Velocidade do Classificador Dinâmico [rpm]	49,71	95,11	70,29

Tabela 3 - Valores mínimos, máximos e média do conjunto de dados final utilizado.

5.2. Análise estatística dos dados

O cálculo das correlações de Pearson entre todas as variáveis selecionadas gerou os coeficientes mostrados na Tabela 4. Para melhor visualização, os elementos acima da diagonal principal foram removidos, uma vez que se trata de uma matriz simétrica.

	NOx [mg/m ₃]	Temperatura de Ar Primário [°C]	Vazão de Carvão Pulverizado [t/h]	Vazão de Ar de Sobre Queima [kg/s]	Vazão de Ar Primário [kg/s]	Vel. do Classificador Dinâmico [rpm]	Vazão de Ar Secundário [kg/s]	Pressão do Coletor de Ar Secundário [bar]	Pressão do Coletor de Ar Primário [bar]	Temperatura de Ar Secundário [°C]
NOx [mg/m _N ³]	1									
Temperatura de Ar Primário [°C]	0.53	1								
Vazão de Carvão Pulverizado [t/h]	-0.02	0.05	1							
Vazão de Ar de Sobre Queima [kg/s]	0.21	0.39	-0.33	1						
Vazão de Ar Primário [kg/s]	0.11	0.18	0.66	-0.17	1					
Vel. do Classificador Dinâmico [rpm]	-0.27	-0.25	-0.06	-0.16	-0.22	1				
Vazão de Ar Secundário [kg/s]	0.64	0.25	-0.27	0.16	-0.33	-0.17	1			
Pressão do Coletor de Ar Secundário [bar]	0.10	0.20	0.00	0.25	-0.06	-0.14	0.19	1		
Pressão do Coletor de Ar Primário [bar]	-0.18	-0.26	0.56	-0.23	0.39	0.09	-0.40	-0.07	1	
Temperatura de Ar Secundário [°C]	0.59	0.94	-0.08	0.44	0.03	-0.21	0.40	0.21	-0.35	1

Tabela 4: Coeficientes de Correlação de Pearson do Conjunto de Dados Final.

A primeira coluna da matriz mostra as correlações entre o NOx e cada variável de entrada. O parâmetro com maior correlação positiva com o NOx é a Vazão de Ar Secundário, seguido da Temperatura de Ar Secundário e Temperatura de Ar Primário, indicando uma provável alta influência desses parâmetros nos resultados das redes neurais.

A partir dos coeficientes de Pearson, selecionaram-se os parâmetros com correlação com NOx acima de 0,10 para formar a RNA₇ (7 parâmetros de entrada, omitindo-se pressão do coletor de ar secundário e vazão de carvão pulverizado). Por sua vez, outra rede foi criada a partir de todos os 9 parâmetros, sendo denominada RNA₉.

5.3. Seleção da arquitetura da rede

As RNAs utilizadas são do tipo *multilayer feed-forward perceptron* (GULLI; PAL, 2017) com mecanismo de *backpropagation* e otimizador tipo *Adam* (DIEDERIK; BA, 2014). Foram realizadas as seleções das arquiteturas das redes aplicando-se o método de tentativa e erro a partir da variação do número de camadas, número de neurônios e função de ativação. A Figura 7 mostra a arquitetura final das redes RNA₇ e RNA₉.



As duas redes apresentaram os menores valores de MAE e RMSE quando foram construídas com 3 camadas com respectivamente 64-64-1 neurônios, função de ativação ReLU na primeira camada e sigmoide na segunda.

5.4. Análise da performance da RNA

A avaliação da performance da RNA foi feita através da comparação entre os valores medidos do conjunto de teste e os valores previstos pelas próprias RNAs. A Figura 8 mostra os diagramas de dispersão da previsão de emissões de NOx pela RNA₇ e RNA₉ em relação aos valores medidos dessa emissão.



Figura 8 - Diagramas de dispersão entre valores medidos de NOx e valores previstos pela a) RNA₉ e b) RNA₇.

Foi observado um aumento na dispersão dos resultados ao remover os parâmetros de entrada Vazão de Carvão Pulverizado e Pressão do Coletor de Ar Secundário. Este aumento na dispersão foi refletido numa redução do R² de 0,9283 no diagrama da RNA₉ para 0,9009 no diagrama da RNA₇. Na Tabela 5 foram mostrados os impactos da remoção de parâmetros da rede no aumento do restante dos erros.

Tabela J. Ellos da KINA9 e KINA7					
	RNA ₉	RNA7	Unidade		
Número de parâmetros de entrada	9	7	-		
MAPE	2,67	3,05	%		
MAE	8,45	9,67	$[mg/m_N^3]$		
RMSE	11,26	13,3	$[mg/m_N^3]$		
R ²	0.93	0.90	-		

Tabela 5: Erros da RNA9 e RNA7.

Pela comparação dos erros, a rede considerada mais adequada para aplicação na previsão do NOx foi a RNA9, sendo assim definida para compor a RNA final.

5.5. Comparação com regressão linear múltipla

Foi realizada uma regressão linear múltipla (RLM) com os mesmos 9 parâmetros de entrada utilizados na RNA final. A função da RLM foi dada pela Eq. (11)

$$y_{prev} = -1304,20536 + 0,06074457 \times T1 - 0,27069364 \times \omega - 1,38071807 \times VC + 0,05555817 \times V3 + 5,04596132 \times V1 + 2,83019306 \times V2 - 1,71349987 \times P2 + 1,02295181 \times P1 + 1,86977658 \times T2$$
(11)

onde y_{prev} é o valor de NOx previsto pela RLM, e as outras variáveis seguem a nomenclatura da legenda da Figura 3. O diagrama de dispersão entre os valores medidos de NOx e os valores previstos pela RLM é mostrado na Figura 9.



Figura 9 - Diagrama de dispersão entre valores medidos de NOx e valores previstos pela RLM.

Observou-se um R² de 0,6558 para a dispersão dos resultados da RLM, o que é consideravelmente menor do que o encontrado pela RNA final. Esta diferença na dispersão pode ser vista também através dos histogramas dos erros, apresentados na Figura 10.



Figura 10 - Histograma dos erros nas previsões da a) RNA final e b) RLM.

A distribuição dos erros provenientes da RNA final assemelha-se a uma distribuição normal, com baixo desvio padrão, ao contrário do observado para a RLM. Os resultados dos erros para a RNA final e RLM são apresentados na Tabela 6.

	RNA final	RLM	Unidade
Número de parâmetros de entrada	9	9	-
MAPE	2,67	6,19	%
MAE	8,45	19,61	[mg/m _N ³]
RMSE	11,26	24,12	[mg/m _N ³]
R ²	0,93	0,66	-

	Tabela 6 -	Performance	da RNA	final e	RLM
--	------------	-------------	--------	---------	-----

Pode-se observar uma diferença entre os erros da RNA final e os erros da RLM, sugerindo que a utilização de redes neurais, para este caso, foi mais adequada para a previsão do NOx do que a regressão linear múltipla.

O gráfico da Figura 11 mostra um comparativo entre os valores medidos de NOx e os valores previstos pela RNA₉.



É possível notar que a RNA₉ é capaz de reproduzir em sua resposta as tendências de variação do NOx ao longo do tempo.

5.6. Análise de Sensibilidade da RNA Final

Foi realizada a análise de sensibilidade da RNA final, buscando tendências no comportamento do NOx ao variarmos um parâmetro de entrada por vez entre os valores máximos e mínimos da Tabela 3. Os demais parâmetros foram fixados em seus valores médios. A Figura 12 mostra as análises de sensibilidade da RNA final para 8 dos 9 parâmetros de entrada. O gráfico para o parâmetro "Velocidade do Classificador Dinâmico dos Moinhos" pode ser visto na Figura A1 do Apêndice.



Figura 12 – Análises de sensibilidade da RNA final.

A vazão e temperatura do ar secundário exercem uma influência no sentido de aumentar a geração de NOx, como mostrado pelas Figura 12-b e d. Esse comportamento já foi indicado pelos coeficientes de correlação de Pearson, com valores de 0,59 e 0,64, respectivamente. A temperatura e vazão do ar primário (Figura 12-a e c) não apresentam muita influência no comportamento do NOx. Isso pode estar relacionado ao fato deste ser um ar de entrada no moinho de carvão, utilizado para a secagem e transporte do carvão pulverizado. Na saída do moinho, a mistura de ar primário com carvão pulverizado fica abaixo dos 100°C, bastante inferior quando comparada com a temperatura do ar secundário.

A vazão de carvão pulverizado (Figura 12-h) sugere uma relação quadrática com o comportamento do NOx, o que pode explicar o baixo coeficiente de correlação de Pearson (que indica correlações lineares entre as variáveis), mas influência positiva na redução dos erros da RNA. Observa-se que a vazão de ar de sobre queima (Figura 12-g) exerce pouca influência na variação do NOx, estando de acordo com os princípios de funcionamento de queimadores do tipo *Low-NOx*, nos quais o controle da emissão do NOx ocorre antes do injetor de ar de sobre queima.

Por fim, os parâmetros pressão do coletor de ar primário (Figura 12-e) e pressão do coletor de ar secundário (Figura 12-f) sugerem uma relação inversamente proporcional com a variável de saída.

6. CONCLUSÃO

O presente trabalho buscou desenvolver e verificar a eficácia de uma Rede Neural Artificial construída em Python para a previsão de NOx emitido pela fornalha da Usina Termelétrica de Pecém, utilizando apenas parâmetros anteriores à queima do combustível na fornalha, com exceção da vazão de ar de sobre queima. O conjunto de dados utilizado para treinamento e validação da rede foi proveniente de sistemas de medição dos moinhos de carvão e pontos na entrada da fornalha, anteriores aos queimadores.

Este estudo mostrou que, a partir de uma seleção e tratamento de dados de entrada relacionados a moinhos de carvão e ajuste dos hiperparâmetros da rede, é possível utilizar RNAs para prever emissões de NOx de fornalhas de usinas termelétricas com precisão, com MAPE na faixa dos 2,67% e R² por volta de 0,93. Estes resultados mostram uma possibilidade de utilização de redes neurais na substituição temporária de sensores físicos de NOx neste tipo de usina, auxiliando manutenções do sistema de medição.

As análises de sensibilidade possibilitaram um entendimento do comportamento do NOx em função da variação dos parâmetros de entrada, mostrando-se uma ferramenta importante para validação do meta-modelo com o comportamento físico do sistema.

Futuros trabalhos poderiam buscar a aplicação de um algoritmo para otimização (algoritmo genético, por exemplo) dos hiperparâmetros utilizados na construção das RNAs, com o intuito de reduzir ainda mais os erros das previsões. Além disso, outra sugestão é adaptar a rede criada neste trabalhado para realizar um monitoramento online da emissão de NOx da usina, com uma melhoria contínua do treinamento da rede a partir dos dados novos que ela receber.

REFERÊNCIAS BIBLIOGRÁFICAS

ARMSTRONG, J. J. Machine Learning Techniques Applied to Steam Generator Modelling. 2018. Universidade Federal Do Rio Grande Do Sul, [s. 1.], 2018.

BAUKAL JR., C. E. **Oxygen-Enhanced Combustion**. Boca Raton, Florida: CRC Press LLC, 1998. v. 1

CONSELHO NACIONAL DO MEIO AMBIENTE. Resolução nº 382/2006Brasil, 2006. p. 37. Disponível em: http://www.mma.gov.br/port/conama/res/res06/res38206.pdf>

COOPER, C. D. Air Pollution Control: A Design Approach. Prospect Heights. Prospect Heights, IL: Waveland, 2002.

DIEDERIK, K.; BA, J. L. ADAM: A Method for Stochastic Optimization. **AIP Conference Proceedings**, [s. 1.], v. 1631, p. 58–62, 2014.

ELANGASINGHE, M. A. et al. Development of an ANN–based air pollution forecasting system with explicit knowledge through sensitivity analysis. **Atmospheric Pollution Research**, [s. l.], v. 5, n. 4, p. 696–708, 2014.

EPE. **Plano Nacional de Energia 2030: Geração Termelétrica - Carvão MineralMinistério das Minas e Energia – MME**. [s.l: s.n.]. Disponível em: <http://www.mme.gov.br/documents/10584/177708/06.+Carvão/d9adc479-379a-436d-9a4f-255625edcdee?version=1.0>.

ERMEL, C.; PEREIRA, F. M. Integral prediction model of process parameters and pollutant formation for a coal-fired thermal power plant. **ENCIT2018-0178**, [s. l.], 2018.

GAFFNEY, J. S.; MARLEY, N. A. The impacts of combustion emissions on air quality and climate - From coal to biofuels and beyond. **Atmospheric Environment**, [s. l.], v. 43, n. 1, p. 23–36, 2009. Disponível em: http://dx.doi.org/10.1016/j.atmosenv.2008.09.016>

GULLI, A.; PAL, S. Deep Learning with Keras. [s.l.] : Packt Publishing Ltd, 2017.

HAAS REICHERT, H.; FONSECA, J.; SMITH SCHNEIDER, P. Evaluation of an Artificial Neural Network Model Compared With a Regression Model To Estimate the Steam Flow Generation of a Real Thermoelectric Power Plant Data. **ENCIT-2018-0207**, [s. 1.], 2018.

HAYKIN, S. Neural networks and learning machines. 3rd. ed. [s.l.] : Pearson Prentice Hall, 2009. v. 127

IEA. **Tracking Power**. 2019. Disponível em: https://www.iea.org/reports/tracking-power-2019. Acesso em: 7 dez. 2019.

MANKAR, M. S.; VYAWAHARE, A. M.; PACHBHAI, J. S. Nitrogen Oxides Emission Prediction in Coal Based Thermal Power Plant using Artificial Neural Network. **International Journal of Engineering Research & Technology (IJERT)**, [s. 1.], v. 2, n. 12, p. 16–21, 2013.

MARTINS, C. A.; FERREIRA, M. A. Considerações Sobre a Formação de NOx na Combustão. **VI** Congresso Nacional de Engenharia Mecânica - CONEM, [s. l.], n. x, 2010.

MISHRA, A. **Metrics to Evaluate your Machine Learning Algorithm**. 2018. Disponível em: https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234>. Acesso em: 7 dez. 2019.

QUININO, R. C.; REIS, E. A.; BESSEGATO, L. F. O Coeficiente de Determinação R² como Instrumento Didático para Avaliar a Utilidade de um Modelo de Regressão Linear Múltipla. [s.l: s.n.].

SCHNEIDER, B. do N. **Obtenção de Modelo para Torre Úmida de Resfriamento Operando em Regime Transitório Através de Rede Neural Artificial**. 2018. Universidade Federal Do Rio Grande Do Sul, [s. 1.], 2018.

SEO, S. A Review and Comparison of Methods for Detecting Outliers in Univariate Data Sets. 2006. University of Pittsburgh, [s. 1.], 2006. Disponível em: http://d-scholarship.pitt.edu/7948

TOLMASQUIM, M. T. Energia Termelétrica - Gás Natural, Biomassa, Carvão, Nuclear. [s.l: s.n.].

TURNS, S. R. Introdução à Combustão Conceitos e Aplicações. 3. ed. Porto Alegre: McGraw-Hill Book Co, 2013.

TUTTLE, J. F. et al. Sustainable NOx emission reduction at a coal-fired power station through the use of online neural network modeling and particle swarm optimization. **Control Engineering Practice**, [s. 1.], v. 93, n. May, p. 104167, 2019. Disponível em: https://doi.org/10.1016/j.conengprac.2019.104167>

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.

ZUMEL, N.; MOUNT, J. **Practical Data Science with R**. Shelter Island, NY: Manning Publications Co., 2014. v. 19 Disponível em: http://www.ncbi.nlm.nih.gov/pubmed/24896337

NOMENCLATURA

Parâmetros

NOx	Vazão mássica de NOx	$[mg\!/\!m_N{}^3]$
P1	Pressão do Coletor de Ar Primário	[bar]
P2	Pressão do Coletor de Ar Secundário	[bar]
Τ1	Temperatura de Ar Primário	[°C]
<i>T</i> 2	Temperatura de Ar Secundário	[°C]
V1	Vazão de Ar Primário	[kg/s]
V2	Vazão de Ar Secundário	[kg/s]
V3	Vazão de Ar de Sobre Queima	[kg/s]
VC	Vazão de Carvão Pulverizado	[t/h]

Símbolos gregos

Abreviaturas e acrômimos

ANEEL	Agência Nacional de Energia Elétrica
CO ₂	Dióxido de Carbono
CONAMA	Conselho Nacional do Meio Ambiente
HNO ₃	Ácido Nítrico
MAE	Erro Médio Absoluto (Mean Absolute Error)
MAPE	Erro Absoluto Médio Percentual (Mean Absolute Percentage Error)
MP	Material Particulado
NOx	Óxidos de Nitrogênio
ONS	Operador Nacional do Sistema Elétrico
O ₂	Oxigênio
R ²	Coeficiente de Determinação
RLM	Regressão Linear Múltipla
RMSE	Raiz do Erro Quadrático Médio (Root Mean Squared Error)
RNA	Rede Neural Artificial
UTE	Usina Termelétrica

APÊNDICE



