



XXIV SNPTEE  
SEMINÁRIO NACIONAL DE PRODUÇÃO E  
TRANSMISSÃO DE ENERGIA ELÉTRICA  
22 a 25 de outubro de 2017

CB/GIA/13

Curitiba – PR

#### GRUPO – XI

##### GRUPO DE ESTUDOS DE IMPACTOS AMBIENTAIS - GIA

##### ABORDAGEM DE INTELIGÊNCIA COMPUTACIONAL APLICADA PARA MODELAGEM PREDITIVA DE EMISSÕES DE NOX E CO DE UMA TURBINA A GÁS DE UMA USINA TERMELÉTRICA DE CICLO COMBINADO

<b>Yamao, E.M(*)</b> LACTEC	<b>Pierezan, J.</b> LACTEC	<b>Gonçalves, J.P.S</b> LACTEC	<b>Gritti, M.C</b> LACTEC	<b>Ribas, L.G.T</b> LACTEC
<b>Chiesa, F.</b> UEGA	<b>Santos, V.M.L</b> UEGA	<b>Freitas, M.D</b> COPEL	<b>Orlandi, A.D.S</b> COPEL	<b>Coelho, L.D.S</b> PUCPR

#### RESUMO

O tratamento adequado das emissões gasosas provenientes de processos industriais é fundamental para a preservação do meio ambiente e de seus recursos fornecidos à sociedade. Isso faz com que o termo “responsabilidade socioambiental” seja um tema relevante e que deve ser tratado com seriedade em todas as áreas do conhecimento. Na produção de energia elétrica, os insumos nem sempre são renováveis e geram gases poluentes lançados no meio ambiente. Esta pesquisa apresenta a identificação de modelos caixa-preta preditivos com estrutura de modelo MISO (Multi-Inputs, Single-Output) de emissões dos gases poluentes Óxidos de Nitrogênio (NOx) e Monóxido de Carbono (CO) de uma turbina a gás natural. A pesquisa utiliza uma metodologia de associação de técnicas de Inteligência Computacional com dados reais coletados diretamente da turbina. Os resultados obtidos demonstram que os modelos identificados são capazes de abstrair o processo de combustão com valores de MAPE abaixo de 10% e proporcionam a estimativa antecipada das parcelas de NOx e CO.

#### PALAVRAS-CHAVE

Turbina a gás, NOx, CO, Identificação não-linear, Inteligência Computacional, Emissões.

#### 1.0 - INTRODUÇÃO

Em 2016 cerca de 32,33 % do gás natural ofertado ao mercado no Brasil foi consumido para a geração de energia em usinas termelétricas [1]. Desta forma, dominar o conhecimento dos processos de combustão é extremamente importante, pois através destes processos, pode-se definir parâmetros de operação, calcular o consumo de combustíveis e quantificar as emissões de gases poluentes em turbinas a gás.

(\*) Avenida Prefeito Lothário Meissner, n° 01 – CEP 80210170 Curitiba, PR – Brasil

Tel: (+55 41) 3361-6189 –Email: eduardo.yamao@lactec.org.br

Os gases de exaustão, proveniente de turbinas a gás *Heavy Duty*, possuem em sua composição o monóxido de carbono (CO) e os óxidos de nitrogênio (NOx) [2]. Os óxidos de nitrogênio presentes no processo de combustão das turbinas a gás são majoritariamente o óxido nítrico NO e o dióxido de nitrogênio NO<sub>2</sub>, comumente referidos por NOx que possuem três processos de formação sendo NOx térmico, NOx combustível e NOx imediato [3]. O NOx é um gás altamente poluente e tóxico, podendo causar danos à saúde [4] e [5]. Uma das tecnologias para reduzir as emissões de NOx tecnologia é o *dry-low emissions*, que consiste em manter a combustão em temperaturas abaixo de 1600K, impedindo a formação do NOx térmico. No entanto, o monóxido de carbono (CO), outro poluente resultante da combustão, aumenta sua formação em temperaturas mais baixas. O CO é um gás incolor, inodoro e tóxico formado quando a combustão é incompleta, ou seja, quando o oxigênio fornecido a combustão é insuficiente [6]. Devido a estes fatores, as emissões de NOx e CO são regulamentadas por lei no Brasil pelo CONAMA [7]. Logo, o desenvolvimento de métodos para predição dos gases de exaustão de turbinas a gás visa auxiliar na geração de esforços para que haja uma gestão ambiental de resíduos eficiente, responsável e rentável, sendo de suma importância para o setor de geração termelétrica.

Na literatura, previsões de NOx e CO normalmente são realizadas utilizando modelos matemáticos encontrados por princípios físicos e simulação computacional. Uma destas abordagens é utilizar a teoria de Cadeias de Reatores Químicos (CRQ) com *softwares* de simulação como o CHEMIKIN [8] em conjunto com softwares de fluidodinâmica computacional (CFD) [9]. A simulação da combustão envolve a resolução de muitas equações diferenciais parciais advindas das leis físico-químicas do sistema como conservação de massa global, momento, cinética química etc., no entanto, isto exige um alto custo computacional. A simulação por CRQ consiste em utilizar modelos matemáticos de componentes idealizados de um processo químico contínuo como o Reator Perfeitamente Agitado (RPA) e o Reator de Escoamento Uniforme (REU). A ênfase da modelagem e simulação do processo da combustão é dado a cinética química sendo a fluidodinâmica do sistema simplificada [10]. Além de utilizar softwares de simulação que possuem *solvers* contendo o equacionamento, é necessário conhecimento de parâmetros específicos do sistema, os quais nem sempre estão disponíveis. Em identificação de sistemas esta diretriz pode ser classificada com uma modelagem do tipo caixa branca, ou seja, o modelo matemático é baseado majoritariamente nas leis físicas que regem o processo. Outra abordagem é a modelagem caixa preta que utiliza dados adquiridos diretamente da entradas e saídas do processo para encontrar modelos matemáticos que os relacione sem seguir obrigatoriamente as leis da física. Embora os modelos encontrados por esta abordagem não possam explicar as características físicas do sistema, eles conseguem representar a dinâmica da planta de forma precisa e satisfatória. A identificação de sistemas utilizando inteligência computacional é do tipo caixa preta e suas técnicas já foram utilizadas para prever emissões de turbinas a gás como máquinas de vetores suporte [11] e redes neuro-fuzzy [12] apresentando bons resultados.

A justificativa em utilizar técnicas de inteligência computacional está no fato de que a teoria clássica de identificação de sistemas é baseada em modelos lineares de entrada e saída (SISO, *single input single output*) e requerem que o sinal de entrada seja pré-determinado com a característica de excitação persistente para a estimação dos parâmetros do modelo [13]. No entanto, os fenômenos que ocorrem em uma turbina a gás são complexos (alta não linearidade), envolvendo muitas variáveis (MIMO, *Multiple Inputs Multiple Output*) e não é possível realizar testes controlados com entradas que possuem a característica de excitação persistente na turbina. Logo, o uso das técnicas de inteligência computacional é justificado, pois conseguem lidar com estas características e limitações. Além disso, a teoria por trás das técnicas de inteligência computacional como redes neurais, lógica nebulosa e otimização meta-heurística no contexto da identificação de sistemas também já está bem desenvolvida [14]. Sendo assim, o objetivo de utilizar tais técnicas era encontrar modelos matemáticos não lineares do tipo MISO (*Multiple Inputs Single Output*) que fossem capazes de reproduzir a dinâmica do sistema com o intuito de prever as emissões de NOx e CO. A metodologia utilizada para realizar a identificação consistiu em duas etapas principais. A primeira buscou-se encontrar as entradas mais correlacionadas com o comportamento do NOx e CO utilizando algoritmos para extração de padrões como regressão sequencial com mínimos quadrados ortogonal (*Forward Regression Orthogonal Least Squares*, FROLS) [14] e análise de componentes principais (*Principal Component Analysis*, PCA) [13]. O objetivo desta etapa era manter a dimensionalidade dos modelos baixa (menor número de entradas) e embora não explicitamente, tentar encontrar relações de causalidade entre as entradas selecionadas pelos algoritmos e as saídas, com base em conhecimentos prévios sobre a turbina. A segunda etapa consistiu em aplicar as técnicas de inteligência computacional para encontrar os modelos matemáticos que relacionassem as emissões de NOx e CO com as entradas selecionadas. Nesta etapa aplicou-se redes neurais como a RBF (RNA de função de base radial), redes neuro-fuzzy e otimização multiobjetivo. A qualidade dos modelos foi mensurada utilizando critérios de seleção como o MAPE (Erro absoluto médio percentual) e validação cruzada.

O trabalho está organizado da seguinte maneira. Na seção 2 é apresentada uma breve explicação sobre o comportamento da turbina e sua disposição física. Na seção 3 as técnicas de inteligência computacional são apresentadas de forma simplificada. Nas seções 4 e 5 os resultados e a conclusão são expostos respectivamente.

## 2.0 - DESCRIÇÃO FÍSICA DA TURBINA A GÁS UTILIZADA

A turbina a gás utilizada para estudo neste trabalho é do tipo *Heavy Duty* com baixa emissão de poluentes (*Dry low emissions*) e faz parte de uma usina termoeletrica composta por duas turbinas a gás e uma a vapor em ciclo combinado. Ela pode produzir 160MW de potência a 37% de eficiência em ciclo simples e 240MW com eficiência de 54% a ciclo combinado. Ela pode ser representada de forma simplificada por um compressor, câmara de combustão e turbina como mostrado na .

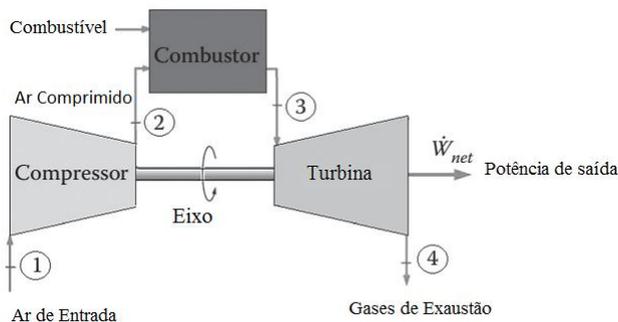


Figura 1 - Modelo físico simplificado de uma turbina a gás [15].

O compressor da turbina é do tipo axial e possui 16 estágios (conjuntos de palhetas) montados sobre um único eixo, garantindo para regimes diferentes pressões e vazões constantes. O ar entra no compressor pelo sistema de admissão em forma de sino que possui alta eficiência aerodinâmica. Na entrada de ar, o compressor possui palhetas diretoras variáveis (*Inlet Guide Vane – IGV*) que controlam a vazão de entrada de ar impedindo perdas. Além disso, existem sangrias de ar comprimido, no sexto, décimo e décimo terceiro estágio que são utilizados na turbina para resfriamento. O ar sai do compressor e entra na descarga do compressor que então internamente direciona ao conjunto de 16 combustores. Os combustores são câmaras cilíndricas, onde a queima é realizada no bocal de entrada. Os combustores para baixa emissões de poluente utilizam um mecanismo de pré-mistura antes da ignição, fazendo assim com que a temperatura da queima seja mais baixa. Na saída dos combustores, os gases quentes são direcionados para a palhetas da turbina pela peça de transição. A expansão dos gases faz a turbina girar aplicando torque ao eixo e os gases residuais saem pelo sistema de exaustão. Mais considerações como modelagem e funcionamento sobre a turbina a gás utilizada e turbinas a gás em geral podem ser encontradas em [16].

## 3.0 - TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL

O ramo da inteligência computacional é uma subárea da inteligência artificial onde um computador aprende determinados padrões e comportamentos através da análise de dados. Geralmente as técnicas utilizadas em inteligência computacional são baseadas em fenômenos naturais como a seleção natural. Elas são aplicadas para resolver problemas complexos onde a modelagem matemática tradicional se torna complicada na análise, pois os problemas podem possuir várias incertezas, possuir comportamento aleatório (estocásticos) ou pela dificuldade de colocar o comportamento do sistema em termos matemáticos precisos. As técnicas buscam utilizar maneiras semelhantes ao raciocínio humano, ou seja, conhecimento inexato e que geram decisões que se adaptam. Neste trabalho as principais técnicas utilizadas foram as redes neurais artificiais, a lógica fuzzy e a otimização meta-heurística. Nas próximas seções é apresentado de maneira simplificada o funcionamento de cada uma delas [17].

### 3.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Podem ser utilizadas para problemas de classificação, regressão e agrupamento de dados. A

Comentado [EMY1]: Falta referência

estrutura fundamental de uma rede neural é o neurônio. O neurônio em uma rede neural é um modelo matemático que busca imitar a função de um neurônio biológico. Em um neurônio biológico as informações recebidas são um somatório de entradas captadas pelos dendritos, ponderadas pelos pesos sinápticos e aplicadas a uma transformação linear ou não linear. O resultado desta transformação (saída) é transmitido pelos axônios. Na Figura 2 uma representação do neurônio biológico e seu modelo matemático são mostrados, em que  $x_n$  são as entradas,  $\theta_m$  os pesos sinápticos,  $f(\cdot)$  é a função de mapeamento ou ativação e  $y$  a saída [18].

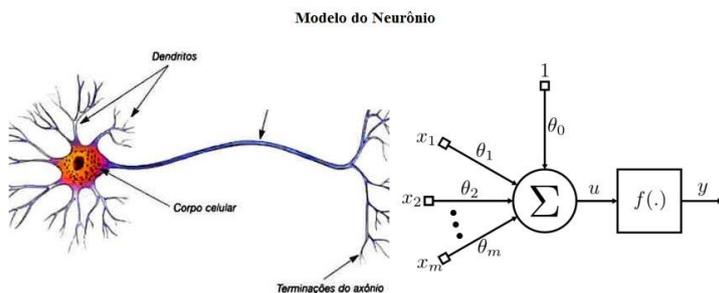


Figura 2 - Neurônio biológico e modelo matemático [18].

As RNAs são formadas por camadas de neurônios interligadas umas às outras, sendo elas a camada de entrada, camadas ocultas e camadas de saída. Elas podem ser classificadas de diversas maneiras, principalmente pelo fluxo de sinal e pelo tipo de função de ativação utilizado na rede. O fluxo de sinal da rede define se a rede é *feedforward*, onde o sinal “flui” apenas da entrada para a saída, ou se a rede é recorrente (*feedback*), onde o sinal flui tanto da entrada para a saída quanto vice-versa. Redes recorrentes são dinâmicas (dependem dos valores das entradas e saídas atuais e passadas do sistema) e redes *feedforward* são estáticas (dependem apenas dos valores atuais das entradas).

As funções de ativação também são importantes no comportamento da rede. Redes *multilayer perceptron* (MLP) majoritariamente utilizam funções sigmóides e tangente hiperbólicas para modelarem comportamentos não lineares. Redes de função de base radial utilizam funções como a Gaussiana, que podem ser caracterizadas por dois parâmetros, o centro (média na Gaussiana) e o raio (variância ou desvio padrão na Gaussiana).

### 3.2 Sistemas nebulosos e lógica fuzzy

A lógica Fuzzy ou lógica nebulosa é uma teoria para lidar com incertezas, diferente da teoria da probabilidade e da lógica binária. A lógica Fuzzy lida com incertezas no conceito de “meias verdades”, onde algo pode ser completamente falso ou verdadeiro, mas também possui valores intermediários. Um exemplo entre como a probabilidade e lógica Fuzzy diferem para considerar incertezas é dado abaixo:

- Probabilidade – “Grau de crença” ou o quão se acredita que algo irá ocorrer.  
Se  $P(A) = 80\%$ , logo se acredita que a cada 10 ocorrências de um experimento, onde o espaço amostral possui A como um evento, 8 vezes o evento A ocorrerá.
- Lógica Fuzzy – “Grau de verdade” ou o quão verdadeiro é algo.  
Dado a afirmação, “X é uma pessoa alta”, considerando que X possui 1.70m, o quão verdadeiro é esta afirmação.

No exemplo de lógica fuzzy, a incerteza não está na altura de X (já que ela é conhecida), mas no significado linguístico de “alto”. Sendo assim, percebe-se que a lógica fuzzy trata-se de como modelar conceitos vagos e não incertezas como na teoria da probabilidade. Como apresentado, a teoria nebulosa lida com conceitos onde seus significados não são totalmente definidos, ou seja, fazem parte de conjuntos nebulosos.

As duas definições importantes da lógica nebulosa são:

- Variável linguística – Conceito a ser tratado pela lógica Fuzzy. Ex: Temperatura

Comentado [EMY2]: Faltou a referência desse paragrafo

Comentado [JPSG3R2]: Resolvido

Comentado [EMY4]: Faltou a referência

Comentado [JPSG5R4]: resolvido

Termos primários – caracterizam o conceito. Ex: Frio e Muito Quente  
 Universo de discurso – Intervalo a ser estudado Ex: 10° a 40°

- Regras Nebulosas – As regras nebulosas são a base de decisão da lógica Fuzzy.

Representam regras para inferir sobre o fenômeno estudado. O conjunto de regras forma a base de conhecimento. Exemplo, “**Se** a temperatura está alta e continua aumentando, **então** ligue um pouco o refrigerador”. As regras nebulosas podem ser construídas pelo conhecimento de um especialista sobre o sistema ou por algoritmos que as criam automaticamente utilizando dados.

A modelagem Fuzzy é definida em três etapas a Fuzzyficação, a Inferência e a Defuzzyficação. A Fuzzyficação consiste em transformar valores numéricos em valores “linguísticos” por funções de pertinência. Existem várias funções de pertinência como triangular, *singleton*, trapezoidal entre outras. A Inferência consiste no mecanismo que define quais regras do banco de regras foram ativadas utilizando da teoria de conjuntos nebulosos. A Defuzzyficação transforma os valores gerados pela inferência em valores numéricos reais novamente, por exemplo utilizando a fórmula do centro de massa. A Figura 3 sumariza os processos de Fuzzyficação, Inferência e Defuzzyficação e apresenta a estrutura de um modelo Fuzzy, conhecido por modelo de Mamdani [19]. Para aplicações da lógica Fuzzy a modelagem de sistema e um tratamento matemático mais rigoroso o leitor é direcionado a [20].

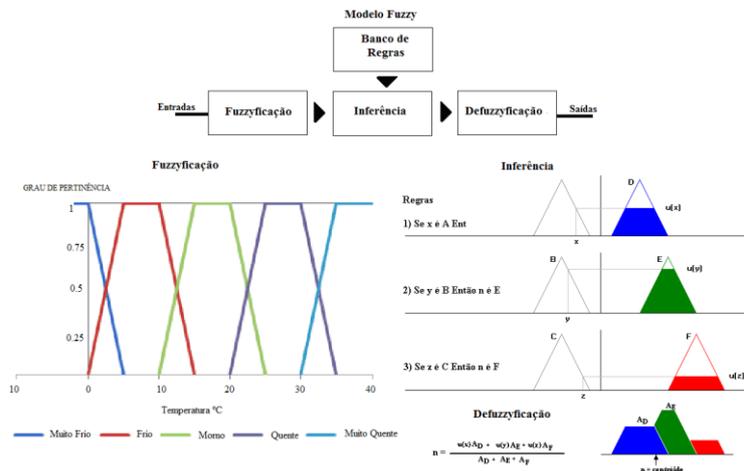


Figura 3 – Fuzzyficação, Inferência e Defuzzyficação.

#### 4.0 - RESULTADOS

Nesta seção são apresentadas as técnicas de identificação aplicadas ao problema, bem como seus respectivos parâmetros, a configuração experimental e os modelos caixa-preta obtidos no processo.

##### 4.1 Parametrização da identificação

Os modelos caixa-preta obtidos na presente pesquisa podem ser definidos como *Multi-Input Single-Output* (MISO) preditivos e não auto regressivos, uma vez que os valores estimados não dependem de seus próprios valores estimados anteriormente e o atraso mínimo permitido para as entradas é 60 (um minuto). Os regressores são re-amostrados a cada cinco segundos e o número máximo de atrasos permitido para as entradas é igual a 20. Portanto, as amostras das entradas consideradas para os modelos variam de  $k-60$  até  $k-160$ .

As entradas dos modelos foram selecionadas de acordo com o algoritmo de regressão sequencial com mínimos quadrados ortogonal (FROLS). Os FROLS é uma técnica utilizada em regressão linear e não linear capaz de selecionar os regressores (entradas) que mais influenciam a saída. A ideia do FROLS é transformar um conjunto de dados de entradas em uma base ortogonal, ou seja, o produto interno entre dois vetores diferentes da base é igual zero. Se dois regressores são ortogonais, eles não possuem correlação (interdependência nula), logo o algoritmo descarta regressores redundantes automaticamente.

Além disso o algoritmo conta com critérios de parada que dão maior peso de importância a modelos de ordem reduzida. Desta maneira, mantém-se a parcimônia (baixa dimensionalidade) e maior capacidade de generalização do modelo, evitando *overfitting* [14].

**Comentado [EMY6]:** referência

Para a avaliação dos resultados foram empregados o Erro Médio Quadrado (MSE – *Mean Squared Error*) e o Erro Percentual Absoluto Médio (MAPE – *Mean Absolute Percentual Error*), bem como o tempo de treinamento das técnicas. Vale observar que a máquina usada para as simulações estava sendo usada para outras tarefas durante o processo e as configurações da mesma são processador Intel Core i7 2.93GHz, 10GB de RAM, 1333MHz e sistema operacional 64 bits.

**Comentado [JPSG7R6]:** resolvido

#### 4.2 Parametrização das técnicas

Na presente pesquisa foram empregadas as Redes Neurais Artificiais (RNA) Perceptron Multicamadas (MLP – *Multi-Layer Perceptron*) com função de ativação tangente sigmoide e treinamento por meio do algoritmo Levenberg-Marquardt (LM) [21], Mínimos Quadrados (MQ) e uma rede neural nebulosa Fuzzy clusterizada usando Fuzzy *c-means* [22] e com pesos treinados por meio da pseudo-inversa de Moore-Penrose [23]. As redes MLP e Fuzzy foram configuradas com cinco neurônios, sendo que foram executadas 100 iterações com  $\mu = 1e-3$  para o algoritmo LM e 50 iterações com critério de parada  $1e-3$  para a rede Fuzzy. O treinamento e validação das técnicas foi realizado utilizando 90% dos dados para treinamento e 10 % para validação (A partir da amostra 13500).

**Comentado [EMY8]:** Encontrei esse termo com acento e sem no artigo. Verificar e padronizar.

**Comentado [JPSG9R8]:** Resolvido

#### 4.3 Modelos caixa-preta obtidos

A **Erro! Fonte de referência não encontrada.** é o comportamento da potência fornecida pela turbina. Analisando a **Erro! Fonte de referência não encontrada.** e as Figuras Figura 5 e Figura 6, percebe-se a influência da potência nas emissões, especialmente que as emissões possuem os maiores valores na faixa de maior potência.

O comportamento do NOx e do CO encontrados pelas técnicas são apresentados nas Figuras Figura 5 e Figura 6. Analisando os dados da Tabela 1 e Tabela 2 observa-se que todas as técnicas apresentaram MSE e MAPE baixos. No entanto, as técnicas com os menores índices de desempenho também apresentam maior tempo de treinamento. Cada técnica utilizada consegue capturar informações diferentes dos dados. Sendo assim, optou-se por combinar os resultados para se obter uma estimativa melhor e mais robusta através de uma combinação linear pela pseudo-inversa. O MSE e MAPE para o NOx e CO da combinação linear também são apresentadas na Tabela 1 e Tabela 2. Para o CO, a combinação linear apresentou um MAPE um pouco maior, no entanto, isso é devido ao comportamento variável dos dados medidos. O tempo de treinamento da combinação linear é próximo ao do mínimos quadrados.

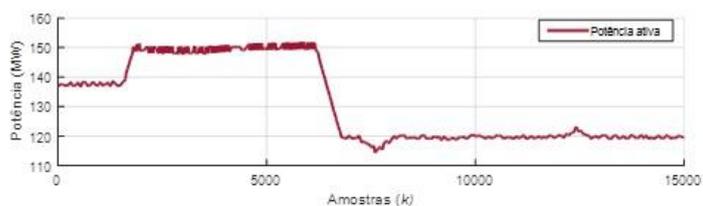


Figura 4 - Gráfico de potência ativa proveniente de uma turbina a gás.

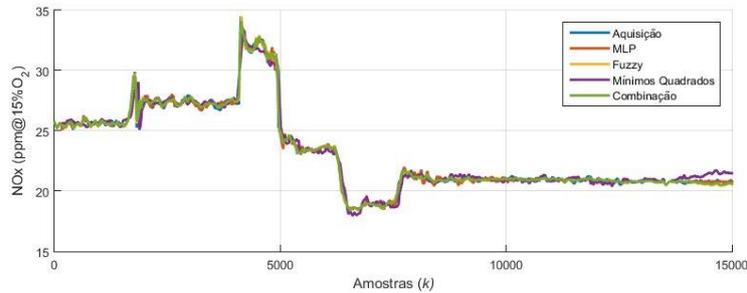


Figura 5 - Comportamento NOX medido (Aquisição) e previsto.

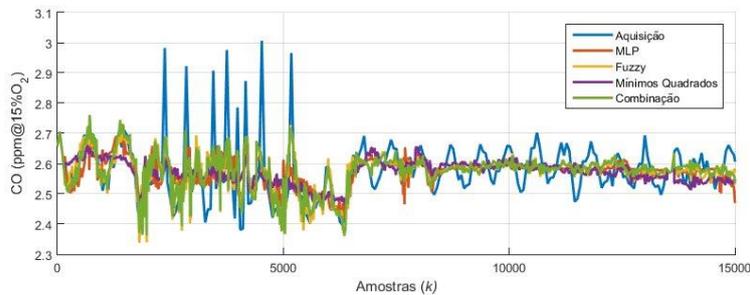


Figura 6 - Comportamento CO medido (Aquisição) e previsto.

Tabela 1 - Resultados NOX.

NOX		Treinamento		Validação		Tempo de treinamento (s)
		MSE	MAPE	MSE	MAPE	
Técnicas	MLP	0,053784	0,645617	0,007186	0,344745	75,655
	Fuzzy	0,023957	0,423909	0,034220	0,740898	45,271
	Mínimos Quadrados	0,223066	1,228305	0,331057	2,541021	0,0310
	Combinação	<b>0,021322</b>	<b>0,418856</b>			

Tabela 2 - Resultados CO.

CO		Treinamento		Validação		Tempo de treinamento (s)
		MSE	MAPE	MSE	MAPE	
Técnicas	MLP	0,005041	2,010646	0,002783	1,624286	75,695
	Fuzzy	0,004051	1,721883	0,002176	1,470618	44,148
	Mínimos Quadrados	0,006034	2,138376	0,004146	2,032666	0,0160
	Combinação	<b>0,003623</b>	<b>1,674294</b>			

## 5.0 - CONCLUSÃO

O trabalho demonstrou a capacidade das técnicas de inteligência computacional em mapear comportamentos complexos e poderem ser usadas para previsão e simulações computacionais das

emissões de NOx e CO de uma turbina a gás *Heavy Duty*. Demonstrou-se ainda que é possível combiná-las para se obter resultados mais robustos e satisfatórios mesmo na presença de ruídos e outros fenômenos aleatórios nos dados. O futuro da pesquisa buscará tornar o sistema adaptativo buscando acrescentar mudanças que acontecem na dinâmica do sistema a estimação. Isto pode ser feito implementando algoritmos de estimação recursiva como o filtro de Kalman ou o estimador de mínimos quadrados recursivos para estimar os pesos da combinação linear das técnicas *online*.

#### 6.0 - REFERÊNCIAS

- (1) MINISTÉRIO DE MINAS E ENERGIA. Boletim gás natural. Dezembro de 2016. [http://www.mme.gov.br/documents/1138769/1732803/Boletim\\_Gas\\_Natural\\_nr\\_118\\_DEZ\\_16.pdf/bc508598-e8dd-4bfb-abda-400d0fd10e02](http://www.mme.gov.br/documents/1138769/1732803/Boletim_Gas_Natural_nr_118_DEZ_16.pdf/bc508598-e8dd-4bfb-abda-400d0fd10e02) Acessado em: 17/02/2017 – 17:05h
- (2) LIEUWEN, T. C., & YANG, V. (2013). Gas turbine emissions. Cambridge, United Kingdom.
- (3) MAFRA, M. R. (2000). Estudo da influência do número de rotação na formação de NOx em uma câmara de combustão cilíndrica. São Paulo, Brasil.
- (4) CASTANAS, E., & CAMPA, M. (2007). Human health effects of air pollution. Heraklion, Grécia.
- (5) HWANG, B.-F., JAAKKOLA, J. J., LEE, Y.-L., LIN, Y.-C., & GUO, Y.-L. L. (2006). Relation between air pollution and allergic rhinitis in Taiwanese schoolchildren .
- (6) RAUB, J. (s.d.). Inter-Organization program for the sound management of chemicals – Carbon monoxide.
- (7) LIVRO CONAMA (2012). Ministério do meio ambiente. Governo do Brasil.
- (8) PARK, J., NGUYEN, T. H., JOUNG, D., & LEE, M. C. (2013). Prediction of NOx and CO emissions from and industrial lean premixed gas turbine combustor using reactor network model.
- (9) Hao, N. T., & Jungkyu, P. (2013). CRN application to predict the NOx emissions for industrial gas chamber. Seoul, Korea.
- (10) JUNIOR, A. R. (2012). Modelagem da combustão de gás natural em um queimador industrial utilizando cadeia de reatores químicos. Dissertação de mestrado. Porto Alegre, Brasil.
- (11) IDZWAN, S. B., PHING, C. C., & KIONG, T. S. (2014). Prediction Of NOx using support vector for gas turbine emissions at Putrajaya power station. Kajang, Malaysia.
- (12) OH, S.-K., PEDRYCZ, W., & PARK, H.-S. (2007). Fuzzy relation-based neural networks and their hybrid identification.
- (13) TANGIRALA, A. K. (2014). Principles of system identification: theory and practice.
- (14) NEIL, O. (2001). Nonlinear system identification from classical approaches to neural networks and fuzzy models.
- (15) ASGARI, H. & CHEN, X. (2015). Gas turbines modeling, simulation and control: using artificial neural networks.
- (16) BOYCE, M. P. (2012). Gas turbine engineering handbook.
- (17) SIDDIQUE, N. & ADELI, H. (2013). Computational intelligence: synergies of fuzzy Logic, neural networks and evolutionary computing.
- (18) HU, Y. H., & HWANG, J. N. (2001). Handbook of neural networks signal processing.
- (19) MAMDANI, E. H. (1974). Application of fuzzy algorithm for control of simple dynamic plant. .
- (20) ROSS, T. J. (2007). Fuzzy logic: with engineering Applications.
- (21) MARQUARDT, DONALD (1963). An algorithm for least-squares estimation of nonlinear parameters. SIAM Journal on Applied Mathematics.
- (22) BEZDEK, JAMES C. (1981). Pattern recognition with fuzzy objective function algorithms.

(23) MOORE, E. H. (1920). On the reciprocal of the general algebraic matrix. Bulletin of the american mathematical society.

## 7.0 - DADOS BIBLIOGRÁFICOS



**Autor de Contato:** Eduardo Massashi Yamao  
**Local e ano de nascimento:** Curitiba, 1985  
**Local e ano de graduação / pós-graduação:** Curitiba, 2009/2016  
**Experiência profissional:** Mestrado em Engenharia Elétrica pela UFPR. Experiência de 6 anos como Pesquisador nos Institutos Lactec atuando nas áreas de simulação, treinamento, Usinas Hidrelétricas, Termelétricas e Eólicas.

<p><b>Autor 2:</b> Juliano Pierezan  <b>Local e ano de nascimento:</b> Videira-SC  <b>Local e ano de graduação / pós-graduação:</b> Curitiba</p> <p><b>Experiência profissional:</b> Graduado Engenharia de Controle e Automação (PUCPR) e mestre em Engenharia Elétrica pelo Programa de Pós-Graduação em Engenharia Elétrica (UFPR-PPGEE) por meio do qual também conduz seu doutorado e suas pesquisas na área de Inteligência Computacional.</p>	<p><b>Autor 3:</b> João Paulo Silva Gonçalves  <b>Local e ano de nascimento:</b> Loanda-PR, 1994  <b>Local e ano de graduação / pós-graduação:</b> Curitiba,2017  <b>Experiência profissional:</b> Graduando em Engenharia de Controle e Automação pela UTFPR. Trabalha como estagiário nos institutos Lactec (LEME) na área de identificação de sistemas.</p>
<p><b>Autor 4:</b> Luís Gustavo  <b>Local e ano de nascimento:</b> Ponta Grossa – PR/ 1989  <b>Local e ano de graduação / pós-graduação:</b> Curitiba-PR/2004  <b>Experiência profissional:</b> Engenheiro Eletricista – Ênfase Eletrônica e Telecomunicações pela UFPR. Pesquisador nos Institutos Lactec.</p>	<p><b>Autor 5:</b> Marcos Cesar Gritti  <b>Local e ano de nascimento:</b> Guarapuava-PR,1991  <b>Local e ano de graduação / pós-graduação:</b> Curitiba,2015  <b>Experiência profissional:</b> Graduado em Engenharia Mecatrônica PUC-PR. Pesquisador desde 2014, onde iniciou como estagiário nos Institutos Lactec. Hoje é aluno do Programa de Pós-Graduação em Engenharia Elétrica UFPR - PPGEE, e trabalha como bolsista nos Institutos Lactec (LEME).</p>
<p><b>Autor 6:</b> Flávio Chiesa  <b>Local e ano de nascimento:</b> Curitiba-PR, 1959  <b>Local e ano de graduação / pós-graduação:</b> Curitiba,1981/ Florianópolis,1994/ Curitiba,2002  <b>Experiência profissional:</b> Graduado em Engenharia Mecânica (UFPR), também possui pós-graduação em Engenharia de Produção pela UFSC e Mestrado em Engenharia Mecânica pelaPUC-PR. Já atuou em diversas áreas relacionadas a geração de energia e engenharia térmica. Desde 2007 é diretor técnico da Usina Termoeletrica de Araucária (UEGA) de 480MW a ciclo combinado.</p>	<p><b>Autor 7:</b> Victor Manuel Lopes Santos  <b>Local e ano de nascimento:</b> Cabo Verde, 1960  <b>Local e ano de graduação / pós-graduação:</b> Curitiba,1992  <b>Experiência profissional:</b> Graduado em Engenharia Elétrica, trabalha na coordenação e gerencia técnica da usina termoeletrica de Araucária (UEGA).</p>
<p><b>Autor 8:</b> André da Silva Orlandi  <b>Local e ano de nascimento:</b> Cambé-PR, 1986  <b>Local e ano de graduação / pós-graduação:</b> Curitiba, 2008/ Cuiitiba,2009  <b>Experiência profissional:</b> Graduado em Engenharia Elétrica pela UFSC. Atualmente é Engenheiro de Manutenção de Equipamentos Eletrônicos - Copel Geração e Transmissão S.A. em usinas de geração de energia.</p>	<p><b>Autor 9:</b> Marcos de Freitas  <b>Local e ano de nascimento:</b> Curitiba-PR,1974  <b>Local e ano de graduação / pós-graduação:</b> Curitiba,2008/  <b>Experiência profissional:</b> Possui MBA em Mercado Financeiro e graduação em Administração de Empresas - Faculdades Integradas do Brasil (2008). Atualmente é Supervisor de operação da Usina Termelétrica de Araucária da Companhia Paranaense de Energia - COPEL. Tem experiência na área de Administração, com ênfase em comportamento humano e gestão da qualidade. Professor contratado pelo CTGAS-ER, para ministrar módulo no curso de formação de operadores de Usinas Termelétricas da Petrobrás.</p>

**Autor 10:** Leandro dos Santos Coelho

**Local e ano de graduação / pós-graduação:**

Santa Maria, 1994 e 1999/ Florianópolis 1997 e 2000

**Experiência profissional:** Possui graduação em Informática pela Universidade Federal de Santa Maria (UFSM, 1994), graduação em Engenharia Elétrica (UFSM, 1999), mestrado em Ciências da Computação (UFSC, 1997) e doutorado em Engenharia Elétrica (UFSC, 2000). Atualmente, é professor titular da PUC-PR e professor adjunto na UFPR. Tem também atuado como consultor (PETROBRAS, ANEEL, COPEL, LACTEC), palestrante e ministrando treinamentos em inteligência computacional, identificação, otimização e algoritmos de controle avançado.