

GRUPO DE ESTUDO DE GERAÇÃO TÉRMICA - GGT

MONITORAMENTO DE MOTORES A COMBUSTÃO ATRAVÉS DE DIGITAL TWIN PARA APOIO A TOMADA DE DECISÃO OPERACIONAL

**KLEYTON PONTES COTTA(1);BRUNO DEON(1);ROBSON FELIPE VIANA DA SILVA(1);CAMILLA BARROS BATISTA(1);GABRIELA TEIXEIRA JUSTINO(1);GABRIELA CARVALHO FREITAS(1);FLÁVIO LEITE LOUÇÃO JUNIOR(1);ATHOS DOS SANTOS BARBOSA(1);ANGELO MARCELINO CORDEIRO(1);ALEX MORETTI DE MORAIS(2);ISAAC EMMANUEL AZEVEDO DE MEDEIROS(2);RODRIGO JOSÉ SILVA DE ALMEIDA(2);CARLOS ANTONIO ALVES DE ARAÚJO JUNIOR(2)
RADIX ENGENHARIA E DESENVOLVIMENTO DE SOFTWARE S/A(1);EPASA(2)**

RESUMO

A disponibilidade, a confiabilidade e o desempenho das máquinas geradoras de uma Usina Termelétrica (UTE) são questões críticas para maximizar os resultados econômicos do negócio e para garantir o atendimento à demanda do setor elétrico. Portanto, foi desenvolvido uma ferramenta computacional que permita prever tendências e desvios operacionais de forma automatizada e confiável, baseada em modelos de digitalização de plantas industriais (Digital Twin), para motores de geração termelétrica e seus subsistemas. Os modelos representam as condições e parâmetros mecânicos, térmicos e elétricos de cada equipamento em condições operativas normais e a ferramenta gera alertas quando ocorrem desvios em relação ao modelo base.

PALAVRAS-CHAVE

Digital Twin, Monitoramento, Vida Útil Remanescente, Inteligência Artificial.

1.0 INTRODUÇÃO

A disponibilidade, a confiabilidade e o desempenho das máquinas geradoras de uma Usina Termelétrica (UTE) são questões críticas para maximizar os resultados econômicos do negócio e para garantir o atendimento à demanda do setor elétrico. O desafio de garantir alta disponibilidade, confiabilidade e desempenho estão associados tanto aos processos de operação quanto de manutenção.

Atualmente, não se dispõe de ferramenta computacional que permita prever tendências e desvios operacionais de forma automatizada e confiável, baseada em modelos de digitalização de plantas industriais, para motores de geração termelétrica, ou outras grandes máquinas geradoras, conforme constatado através de uma pesquisa bibliográfica, estudo de anterioridade do projeto e consulta a outros bancos de dados como o do INPI. As ferramentas disponíveis têm sido desenvolvidas pelos próprios fabricantes dos equipamentos, tem alto custo de implantação e sustentação, e não permitem a sua fácil replicação para equipamentos de outros fabricantes com baixo custo, além disso, estas ferramentas costumam apresentar cenários mais genéricos de operação, podendo apresentar resultados com menor grau de precisão em alguns casos.

No horizonte atual, em que as técnicas de inteligência artificial (IA) se mostram cada vez mais assertivas e viáveis, surge a possibilidade de usar essas técnicas de IA para construir uma ferramenta de apoio a tomada de decisão em motores de termelétricas, independente do fabricante e com a perspectiva de uso por outros tipos de equipamentos críticos.

Com o avanço tecnológico, existem diversos sensores capazes de identificar variações em medidas contínuas, com sensibilidade centena de vezes maior que a humana, o que permite explorar o sensoriamento e a análise computacional para prever tendências e desvios operacionais com maior assertividade, através da criação de um índice de saúde dos sistemas, subsistemas e equipamentos. Além disso, o avanço da IA permite codificar o conhecimento humano tácito em forma de algoritmos e de regras lógicas para automatizar a detecção de eventos e até mesmo a decisão de uma ação.

O trabalho pertence a um projeto de pesquisa e desenvolvimento (P&D) da Aneel, onde consiste em desenvolver uma ferramenta construída sobre um conjunto de modelos de IA para predição e indicação em tempo real de tendências e desvios operacionais nas unidades geradoras da usina. A ferramenta utiliza uma abordagem de *digital*

twin para cada equipamento, combinando dados históricos e suas correlações com modelos de engenharia. Os modelos representam as condições e parâmetros mecânicos, térmicos e elétricos de cada equipamento em condições operativas normais e a ferramenta gera alertas quando ocorrem desvios em relação ao modelo base.

A modelagem destes equipamentos, via *digital twin*, foi composta por uma longa jornada de desenvolvimento até que se atingisse um resultado que correspondesse às usinas estudadas neste trabalho. Como maneira de se testar a abordagem, a construção dos algoritmos começou pelos sistemas mais críticos, neste caso, os motores geradores. Após os primeiros avanços, a abordagem foi expandida até os demais níveis para os seguintes subsistemas: resfriamento, exaustão, óleo e combustível/ignição, resultando na criação do gêmeo digital da planta.

2.0 REVISÃO BIBLIOGRÁFICAS

2.1 – Usina Termelétrica

Neste artigo estudamos o processo de geração de energia de uma termelétrica, no qual envolve a operação de duas usinas idênticas. Juntas possuem capacidade instalada de 342 megawatts, o que representa energia suficiente para atender uma população de cerca de 980 mil habitantes. A estrutura da UTE é composta por motores Diesel como equipamentos principais e subsistemas atrelados a estes, garantindo sua manutenção e funcionamento, contém geradores para conversão da energia cinética gerada pelos motores em energia elétrica.

Cada UTE conta com 19 Motores MAN/STX do tipo 18V32/40 com capacidade de gerar 8,76 MW e 1 Motor MAN/STX do tipo 9L32/40 com capacidade de gerar 4,38 MW. Os motores com a designação V32/40 são motores sobrealimentados, não reversíveis, de 4 tempos, em V, com 18 cilindros e 320 mm de diâmetro de cilindro e 400 mm de curso do pistão e com rotação de 720 rpm. Os motores com a designação 9L32/40 são motores sobrealimentados, não reversíveis, de 4 tempos, em L, com 9 cilindros e 320 mm de diâmetro de cilindro e 400 mm de curso do pistão e com rotação de 720 rpm. O consumo específico é de 212 kg/MWh, contudo este valor varia, principalmente, de acordo com o poder calorífico do combustível utilizado.

De modo simplificado os subsistemas presentes na UTE são:

- **Sistema de Admissão de Ar:** o ar é filtrado, comprimido no turbocompressor e resfriado através da troca térmica com água dos radiadores para, então, ser admitido no motor;
- **Sistema de Admissão de Combustível:** o combustível é aquecido através da troca de calor com o vapor e filtrado para ser alimentado no motor. O óleo combustível-HFO por apresentar alta viscosidade é preciso ser aquecido antes de ser alimentado no motor, porém o óleo diesel-LFO não precisa ser aquecido, pois a sua viscosidade é baixa o suficiente;
- **Sistema de Exaustão:** a queima do combustível com o ar nos motores gera gases de exaustão. Os gases de exaustão passam pelas turbinas dos turbocompressores e trocam calor com a água nas caldeiras de recuperação para geração de vapor. Em seguida, são encaminhados para exaustão nas Chaminés;
- **Sistema de Geração Vapor e Condensado:** o vapor é gerado da troca térmica da água com os gases de exaustão dos motores nas caldeiras de recuperação. Esse vapor gerado é utilizado para aquecimento do combustível. Vale salientar que as caldeiras de recuperação só podem ser acionadas quando há geração. Quando não há geração, são acionadas as caldeiras auxiliares que apresentam queimador de óleo diesel e gás natural;
- **Sistema de Lubrificação:** o óleo de lubrificação armazenado no cárter dos motores irá promover a lubrificação de todas as partes móveis do motor que entram em contato uma com as outras;
- **Sistema de Arrefecimento:** a água utilizada no processo promove o resfriamento do motor e suas partes (bicos injetores e sistema de ar de admissão). Essa água é oriunda dos radiadores e resfriam trocadores de calor dos demais sistemas.

2.1 – Digital Twin

O conceito de *digital twin* é bastante amplo e vem sendo utilizado de forma difusa e até superficialmente em alguns trabalhos recentes. Um *digital twin* se refere ao equivalente digital de um equipamento, sistema ou planta, que é composto por modelos e dados que correlacionam três estruturas de informação: engenharia do equipamento; histórico do equipamento; condições e variáveis em tempo real.

O modelo de *digital twin* é utilizado para monitoramento e predição de falha, assim como a identificação destas para sistemas complexos (1). O método se baseia na comparação dos dados da máquina real com a máquina virtual, validados pelos dados históricos. O método também utiliza de padrões de serviços que fornecem variáveis para análise baseada nos modelos fenomenológicos.

Digital twin é uma réplica digital de uma entidade física, um modelo virtual baseado em atributos digitais (2). Quanto mais altamente instrumentado for um dispositivo, mais precisamente seu gêmeo digital representará seu

desempenho histórico real, levando a uma melhor análise e simulação de seu desempenho no futuro. A Figura 1 mostra a arquitetura de um *digital twin*.

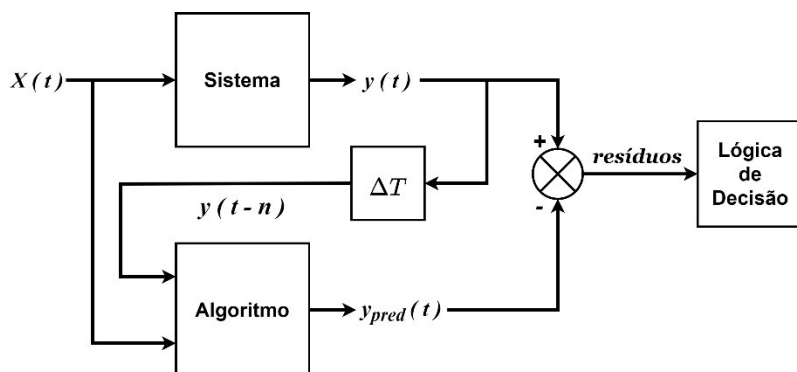


FIGURA 1 - Arquitetura de um *digital twin*.

- **Sistema:** é o equipamento, ou parte do equipamento, retratado como um sistema estático não-linear, isto é, que sua saída pode ser modelada através das entradas no instante de tempo atual.
- ΔT : atraso unitário, implementado através de um buffer que armazena a resposta do sistema no passado.
- **Algoritmo:** utiliza um modelo treinado por algum algoritmo operando em série-paralelo com o sistema, recebendo as mesmas entradas e os valores da variável alvo do passado.
- **Lógica Decisão:** responsável por aplicar as lógicas de decisão em cima dos resíduos (erro entre a variável predita e a real) e sua tendência, bem como onde estão implementados os limiares de decisão.

2.1 – Gradient Boosting

Muitos algoritmos produzem modelos mais simples, mas a precisão normalmente também tem um desempenho inferior ao desejável (3). Portanto, é possível construir uma combinação linear dos modelos retornados por este algoritmo mais simples. Esta técnica é chamada de *boosting*, no qual tenta aproveitar a união de mais de um algoritmo mais simples para obter respostas diferentes. Assim, é possível gerar um modelo mestre mais preciso, baseado nas respostas combinadas de diferentes modelos mais simples e diferentes amostras de entrada (4).

O algoritmo usado neste trabalho foi *gradiente boosting*, no qual executa uma descida gradiente em uma função potencial. Mas alguns problemas aparecem no algoritmo que usa gradiente descendente, então a função potencial deve ser escolhida com cuidado, dependendo do que você deseja minimizar (4).

A Figura 2 mostra como é a iteração do *gradiente boosting*. Um primeiro modelo é criado com uma aproximação simples. Dessa aproximação, temos o resíduo, que é a distância entre o que foi previsto e o valor real. Um próximo modelo é criado e ajustado em cima do resíduo gerado pelo modelo anterior. Em seguida, um novo resíduo é calculado com esse segundo modelo. Essas iterações são repetidas por um determinado número de vezes, buscando minimizar o resíduo gerado pelos modelos, ou seja, até que a distância entre o previsto e o valor real seja o menor possível. O modelo final é a soma dos ajustes de todos os modelos.

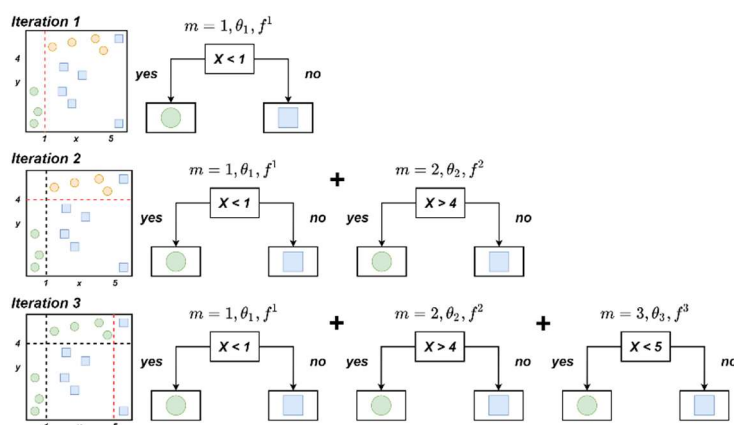


FIGURA 2 - Um exemplo da iteração do algoritmo de *gradiente boosting* adaptado de (5).

2.1 – Rede Neurais

Redes neurais artificiais são um modelo computacional composto por interconexões chamadas de neurônios, representa uma analogia às redes neurais biológicas e tem como principal função simular computacionalmente o funcionamento destas, onde cada neurônio gera a entrada para o outro. Basicamente, os neurônios são agrupados, constituindo assim uma rede neuronal cuja complexidade estrutural é variável, dependendo da arquitetura utilizada. Dessa forma, tarefas dos mais diversos graus de complexidade podem ser executadas por uma rede neural.

A origem deste modelo foi através dos trabalhos de (6) que tentaram modelar um neurônio artificial. Em seguida, o *perceptron*, um modelo simples de neurônio artificial para classificação binária, capaz de expressar classes linearmente separáveis, foi criado por (7). A Figura 3 mostra o modelo de um neurônio, que forma a base para o projeto de redes neurais artificiais.

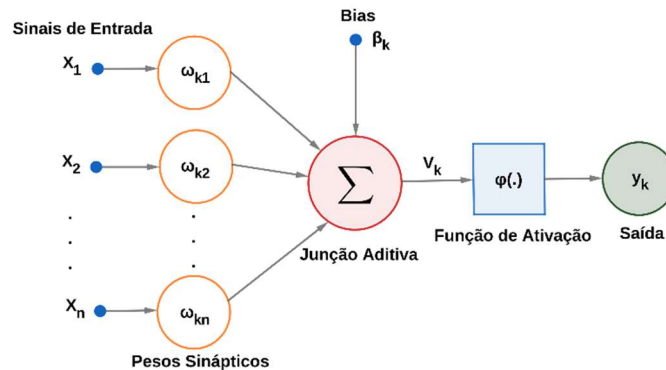


FIGURA 3 - Representação de um Neurônio.

A Figura 4 apresenta a estrutura básica de um *perceptron* de múltiplas camadas (MLP), dado que a capacidade computacional de um neurônio é limitada foi pensado que um conjunto de neurônios artificiais interligados em forma de uma rede é capaz de resolver problemas de alta complexidade. Os *perceptrons* de múltiplas camadas foram aplicados com sucesso para solucionar diversos tipos de problemas, através de seu treinamento de forma supervisionada utilizando-se de retropropagação do erro (8).




FIGURA 4 - Arquitetura de um *perceptron* de múltiplas camadas.

3.0 METODOLOGIA

A abordagem utilizada na solução do projeto é separada em três etapas, sendo o primeiro o pré-processamento, seguido da análise de dados, modelagem e a validação dos experimentos. Em outras palavras, a primeira etapa trata os dados brutos para que possam ser realizadas as análises das variáveis no momento de operação, desta forma facilita a identificação de outlier para remoção. A segunda etapa faz as análises mais refinadas, identificando padrões e simplificando a massa de dados, formando então a base de dados com as condições saudáveis de operação. Por fim, a última apresenta a abordagem de apoio à decisão para criação do índice de saúde com diversos experimentos usando modelos de *machine learning*. A Figura 5 apresenta o esquema da abordagem.




FIGURA 5 - Diagrama das Etapas de Desenvolvimento dos Modelos.

Utilizando a abordagem citada anteriormente, foram desenvolvidos 4 modelos de índice de saúde para cada unidade geradora para os seguintes subsistemas: resfriamento (TC), exaustão (HT), consumo (FA) e óleo (LO). Totalizando 160 modelos a serem executados durante o processo, formando assim, o índice de saúde geral (HI) da UGD. O índice geral é calculado através da média ponderada dos índices dos subsistemas.

3.1 – Modelagem Digital Twin

O uso do modelo de *digital twin* é de grande importância para esta abordagem, sendo o responsável por determinar o índice de saúde de cada unidade geradora. O Modelo de *digital twin* usa o resultado dos dados após uma manutenção e alimentam um algoritmo aplicado ao método de regressão. O uso dos dados nessas condições garante que o algoritmo tenha como referência valores em estado ótimo de operação para então traçar a previsão do comportamento. A partir dessa previsão, através do desvio do valor esperado, os dados serão avaliados e um índice da condição da máquina será estipulado. A Figura 6 apresenta o diagrama dessa abordagem.

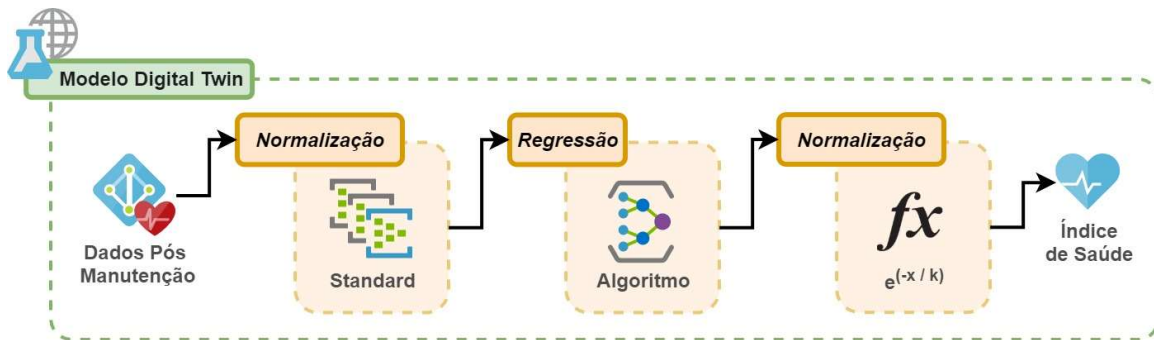


FIGURA 6 - Diagrama da Abordagem para o Modelo *Digital Twin*.

Os modelos de *digital twin* foram definidos com o propósito de identificar o índice de saúde nos componentes dos subsistemas dos motores. O erro entre as regressões e as variáveis reais sugere divergências de comportamento, que podem refletir falhas. Um detalhe importante é que o erro é normalizado por uma função exponencial descrita pela Equação (1),

$$f(x) = e^{\left(\frac{-x}{k}\right)} \quad (1)$$

que é assintótica em zero, e onde x é o erro absoluto e k é usado como parâmetro de calibração.

4.0 RESULTADOS E DISCUSSÕES

Nesta seção vamos apresentar os resultados obtidos para identificação dos desvios operacionais. Os modelos de *Digital Twin* foram testados no motor 15 e serão replicados nos demais motores. Para suavizar os resultados, foi aplicada uma média móvel de 240 minutos.

Os algoritmos de machine learning treinados foram Regressão Linear (LR), Gradient Boosting Regressor (GBR) e Multilayer Perceptron (MLP). Os algoritmos do GBR tiveram seus hiperparâmetros avaliados, a taxa de aprendizado, número de estimadores e profundidade máxima, foram variados, respectivamente em (0,05, 0,10, 0,15), (50, 100, 150) e (2,3,4). Da mesma forma para o MLP, o número de camadas ocultas testadas foram 1,2,3 e para o solver foram o estocástico gradiente descendente e Adam. Os melhores algoritmos foram escolhidos com base em seu erro quadrático médio (MSE), como pode ser visto nos resultados na Tabela 1.

TABELA 1 - Resultados dos Modelos de Regressão para os Subsistemas.

	LR		GBR		MLP	
	MSE (%)	R2	MSE (%)	R2	MSE (%)	R2
Resfriamento	1.820	0.870	0.647	0.939	0.535	0.944
Exaustão	0.540	0.953	0.019	0.998	0.339	0.975
Óleo	0.082	0.923	0.061	0.934	0.749	0.638
Consumo	3.415	0.736	2.477	0.668	3.915	0.702

Por último, foram utilizadas métricas de classificação para uma validação extra. Os verdadeiros positivos (TP) foram definidos em regiões em torno de erros elevados com manutenções presentes. Essas regiões foram baseadas na duração do terceiro quartil das campanhas. Falsos negativos (FN), consistiam em manutenções sem erros elevados nas proximidades. Os falsos positivos (FP) são erros elevados sem manutenções principais e, por último, os negativos verdadeiros (TN) são as regiões restantes. Que são ilustrados na Figura 7.

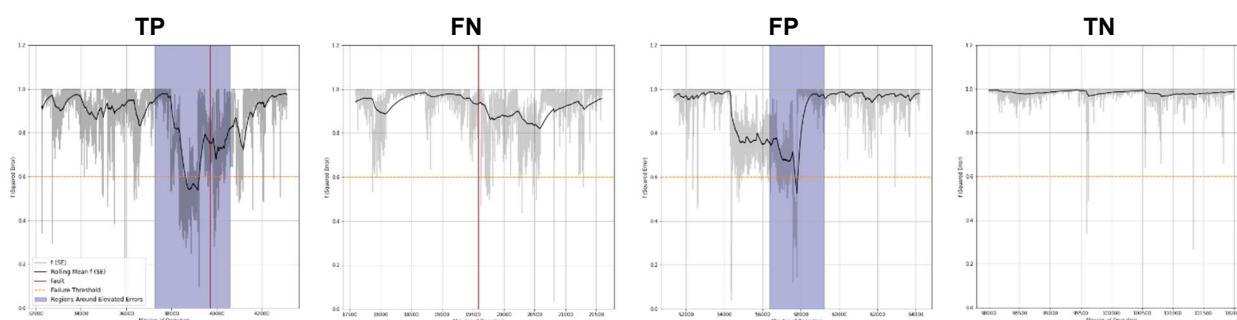


FIGURA 7 - Exemplo da Classificação para Avaliar o Modelo de Digital Twin.

Uma vez que a precisão é geralmente alta devido ao elevado número de TN (o motor gasta mais tempo em operação ótima), a principal métrica avaliada foi o F1-Score, sendo assim, os resultados são mostrados na Tabela 2.

TABELA 2- Resultados dos Modelos por Período para os Subsistemas.

Modelos	F1	Recall	Precision	Acurácia
Resfriamento (LR)	0.50	0.33	1.00	0.98
Resfriamento (GBR)	0.60	0.50	0.75	0.98
Resfriamento (MLP)	0.50	0.33	1.00	0.98
Exaustão (LR)	0.22	0.20	0.25	0.95
Exaustão (GBR)	0.89	1.00	0.80	0.99
Exaustão (MLP)	0.18	0.20	0.17	0.94
Óleo (LR)	0.75	0.75	0.75	0.99
Óleo (GBR)	0.86	0.75	1.00	0.99
Óleo (MLP)	0.55	0.75	0.43	0.98
Consumo (LR)	0.40	0.38	0.43	0.94
Consumo (GBR)	0.50	0.38	0.75	0.96
Consumo (MLP)	0.29	0.25	0.33	0.94

A partir das análises os modelos usando o algoritmo de GBR obtiveram os melhores resultados. Sendo assim, foi escolhido para replicar a abordagem para os demais motores e subsistemas.

Como pode ser visto na Figura 8, o modelo se comportou bem, indicando uma queda no índice de saúde dos determinados subsistemas anteriores as falhas, marcadas pelas linhas verticais. Foi determinado o limiar de 0.75 para gerar um alerta quando o índice de saúde geral (HI) o atingir. Nota-se que mesmo quando o HI não é acionado em uma determinada falha, o subsistema ligado a essa condição pode apresentar uma mudança no seu índice, sendo assim, pode ser usado também como informação para o apoio a tomada de decisão.




FIGURA 8 - Resultado do Modelo para um Determinado Período.

5.0 CONCLUSÕES

Este artigo apresentou o resultado de uma pesquisa para prever tendências e desvios operacionais de forma automatizada e confiável, baseada em modelos de *digital twin* para motores de geração termelétrica e seus subsistemas. A arquitetura lida com modelos de *machine learning* para execução em tempo real.

Os alertas e insights que atualmente são gerados pela ferramenta, permitem ao operador realizar manobras operacionais para evitar tendências indesejadas e/ou gerar ações de manutenção para aquele equipamento/subsistema, de acordo com o seu índice de saúde. Os modelos e lógicas gerados no projeto são automatizados no sistema de controle da usina para que a equipe de operação obtenha os resultados em tempo real e com grau de confiança necessário para realização das ações correspondentes.

Podemos considerar que uma das contribuições deste artigo é a implementação dos modelos de *digital twin* para identificar os desvios operacionais utilizando a arquitetura presente para execução dos modelos de ML em tempo real, que pode ser aplicada a qualquer setor industrial que utilize supervisórios do tipo SCADA, podendo também ser adaptada, expandida e evoluída para outras tecnologias de geração como: outras Termelétricas (de qualquer combustível), pequenas centrais hidrelétricas, eólicas e termonucleares. Vale ressaltar a contribuição na operação, tanto na parte de manutenção dos equipamentos, como na criação de novos conhecimentos e informações relevantes das unidades geradoras no processo de geração de energia através do índice de saúde.

Os próximos passos deste trabalho se referem a melhoria na fase de validação dos resultados, no qual pode ser estudado a utilização de algoritmos de otimização, como por exemplo, algoritmo genético, para encontrar os melhores parâmetros para cada subsistemas. Verificar outras variáveis para serem utilizadas no modelo, no qual sejam menos sensíveis a erro de medição para evitar alguns falsos negativos. Outro ponto para melhoria, é aplicação de um estudo para identificar a influência do índice de saúde de um subsistema no índice de saúde geral.

Os autores agradecem à Centrais Elétricas da Paraíba (EPASA) pelo apoio financeiro ao Projeto PD-07236-0010-2020 - Digital Twin de Apoio à Tomada de Decisão Operacional de Usina Termelétrica a Motores de Combustão, desenvolvido no âmbito do programa de Pesquisa e Desenvolvimento da Agência Nacional de Energia Elétrica (P&D ANEEL), que foi executado pela empresa de engenharia Radix Engenharia e Software S/A.

6.0 REFERÊNCIAS BIBLIOGRÁFICAS

- (1) TAO, F., ZHANG, H., LIU, A., AND NEE, A. Y. Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics*, 15(4):2405–2415, 2018.
- (2) CIMINO, C., NEGRI, E., AND FUMAGALLI, L. Review of digital twin applications in manufacturing. *Computers in Industry*, 113:103130, 2019.
- (3) DUFFY, N. AND HELMBOLD, D. Boosting methods for regression. *Machine Learning*, 47(2):153–200, 2002.

- (4) ZEMEL, R. S. AND PITASSI, T. A gradiente-based boosting algorithm for regression problems. *Advances in neural information processing systems*, pp. 696–702, 2001.
- (5) ZHANG, Z., MAYER, G., DAUVILLIERS, Y., PLAZZI, G., PIZZA, F., FRONCZEK, R., SANTAMARIA, J., PARTINEN, M., OVEREEM, S., PERAITA-ADRADOS, R., ET AL. Exploring the clinical features of narcolepsy type 1 versus narcolepsy type 2 from european narcolepsy network database with machine learning. *Scientific reports*, 8(1):1–11, 2018.
- (6) MCCULLOCH, W. S., PITTS, W., 1943, “A logical calculus of the ideas immanent in nervous activity”, *The Bulletin of Mathematical Biophysics*, v. 5, n. 4, pp. 115–133. ISSN: 00074985. doi: 10.1007/BF02478259.
- (7) ROSENBLATT, F., 1958, “The perceptron: A probabilistic model for information storage and organization in the brain”, *Psychological Review*, v. 65, n. 6, pp. 386–408. ISSN: 0033295X. doi: 10.1037/h0042519.
- (8) HAYKIN, S., 2008, *Redes neurais: princípios e prática*. Bookman Editora. ISBN:9788573077186. doi: 8573077182.

DADOS BIOGRÁFICOS



Mestre em Engenharia de Sistemas e Computação pela UFRJ (2018), graduado em Ciências da Computação pela UFRJ (2014) e Design Gráfico pela UNESA (2008). Atuou como designer gráfico e desenvolvedor full stack desde 2009. Foi pesquisador bolsista no IPEA, atuando diretamente no design, modelagem e nas ferramentas de análises de dados. Professor de algoritmos, Machine Learning e Data Mining na pós-graduação no Instituto Infnet. Atualmente é líder técnico de ciência de dados no grupo de P&D da Radix, desenvolvendo atividades e projetos de inovação com inteligência artificial, criando soluções para diversos setores da indústria.

(2) BRUNO DEON, é atualmente aluno de mestrado do Programa de Pós-Graduação em Engenharia Química da UFSC, onde também recebeu bacharel em Engenharia Química (2019). Nos últimos dois anos, sua experiência profissional foi focada na ciência de dados, onde a partir da utilização de algoritmos de inteligência artificial desenvolveu ferramentas para o auxílio à tomada de decisão e predição de falhas no setor industrial.

(3) ROBSON FELIPE VIANA DA SILVA, graduou-se em Engenharia Mecânica na UFF (2019) onde está cursando mestrado em Engenharia Mecânica com ênfase em transferência de massa e energia (2022). Seus interesses são estudos de manutenção preditiva e otimização de sistemas. Atua em projetos de P&D no setor de energia elétrica.

(4) CAMILLA BARROS BATISTA, graduou-se em Engenharia Química na UERJ (2017) onde está cursando o mestrado em Otimização de Processos desde 2021. Tem experiência na área de projetos de engenharia no setor de óleo e gás e em projetos de P&D da ANEEL. Seus principais interesses são estudos de novas tecnologias na área de geração, transmissão e distribuição de energia.

(5) GABRIELA TEIXEIRA JUSTINO, engenheira química com mestrado em Tecnologia de Processos Químicos e Bioquímicos. Possui experiência em otimização, análise de dados, modelagem matemática.

(6) GABRIELA CARVALHO FREITAS, graduada em Engenharia Química pela UFRJ (2020). Atua como cientista de dados na Radix Engenharia e Desenvolvimento de Software, onde desenvolve projetos utilizando inteligência artificial aplicada em soluções para problemas de engenharia.

(7) FLÁVIO LEITE LOUÇÃO JUNIOR, graduou-se em Engenharia Química pela UFRJ (2015) onde finalizou mestrado em Otimização de Processos no ano de 2016. Atua em projetos de P&D para o setor elétrico desde 2017 e atualmente gerencia um grupo voltada à formatação e execução de novos P&Ds no contexto da ANEEL. Seus principais interesses consistem no estudo da aplicação novas tecnologias e metodologias de gestão e execução de pesquisas para o desenvolvimento de melhorias e solução de problemas no setor elétrico como um todo.

(8) ATHOS DOS SANTOS BARBOSA, graduou-se em Engenharia de Controle e Automação no CEFET/RJ (2019). Tem experiência na área de desenvolvimento de software voltado para projetos de engenharia ligados ao setor de energia e sistemas PIMS, principalmente da OSIsoft.

(9) ANGELO MARCELINO CORDEIRO, graduou-se em Ciências e Tecnologia na UFRN (2019) onde está cursando o bacharelado em Engenharia de Computação. Seus interesses são nas áreas de ciência de dados, com ênfase em inteligência artificial e aprendizagem profunda. Atualmente, atua em projetos de P&D no setor de energia elétrica.

(10) ALEX MORETTI DE MORAIS, pós-graduando em Ciências de Dados e BigData pela PUC Minas e graduação pela USF (2008) e UFSCAR (1996). Possui 25 anos de experiência e especialização em tecnologia da informação, com ênfase em infraestrutura e datacenter T3, desses, 12 anos no setor elétrico. Atuou como Gestor Latam na Stefanini IT Solutions, Gestor de Serviços de TI na CPFL Energia e atualmente como Gestor de Infraestrutura Corporativa na EPASA.

(11) ISAAC EMMANUEL AZEVEDO DE MEDEIROS, graduado em Engenharia Elétrica pela UFPB. Atualmente, cursa Pós-Graduação em Ciência de Dados e Big Data pela Puc Minas e mestrado em Engenharia Elétrica pela UFPB. Desde 2019 atua na indústria, ocupou o cargo de Analista no ramo de Automação Industrial. Atualmente é Engenheiro Trainee da EPASA, atuando no departamento de engenharia e em projetos P&D nas áreas de Inovação.

(12) RODRIGO JOSÉ SILVA DE ALMEIDA, possui graduação em Automação Industrial pelo IFPB (2011) e graduação em Engenharia Elétrica pela UNINASSAU (2019). Atualmente está cursando Ciência de Dados e Big Data na PUC Minas. Trabalha na EPASA, desde 2010 e atualmente tem o cargo de especialista em usina termoeletrica II.

(13) CARLOS ANTONIO ALVES DE ARAÚJO JUNIOR, graduado em Engenharia Elétrica pela UFCG e Mestre em

Sistemas Eletrônicos e Automação pela UFPB. Tem experiência como Engenheiro de Controle e Automação, atuando em projetos de manutenção da automação e melhorias em plantas industriais. Atualmente trabalha na EPASA como Especialista em Termoelétrica II, onde realiza melhorias no processo de geração de energia elétrica, implantação de novos projetos (CAPEX), gestor técnico de projetos P&D Aneel, avaliação de parâmetros de proteção e contato com ONS referente a SGR, SIPER, RANOR e OTRS.