



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ  
Av Treze de Maio 2081 - Bairro Benfica - CEP 60040-531 - Fortaleza - CE - [www.ifce.edu.br](http://www.ifce.edu.br)

## ANEXO

Processo: 23256.014991/2025-78

Interessado: Antonio Wendell de Oliveira Rodrigues



### ANEXO I - DISTRIBUIÇÃO DE VAGAS E TEMAS DE PESQUISA (REPUBLICADO)

CÓDIGO	TEMA	NÚMERO DE VAGAS
CA 01	Sistema Inteligente de Geração de Alertas Proativos para Apoio à Permanência Estudantil com Base em Análise Preditiva de Dados Educacionais	1
IA 01	Análise do impacto de ataques de bit-flip em redes neurais profundas	1
IA 02	Modelos Inteligentes para Otimização Energética: Uma Abordagem com Aprendizado de Máquina	1
IA 03	Deep Learning Theory	2
IA 04	Inteligência Artificial Explicável com Raciocínio Automatizado	1
IA 05	Extensão de Modelos Generativos (VAEs, DDPMs) para Tarefas de Geração de Dados Sintéticos	1
IA 06	Visão computacional em Tecnologias assistivas	3
IA 07	Aprendizado de Maquinas: Modelos Leves e/ou com Capacidade de Rejeição	2
IA 08	Detecção de Falhas em Máquinas Elétricas de Indução Trifásicas	1
IA 09	Detecção de Falhas Baseada em Visão Computacional	2
PDI 01	Detecção de Anomalias em Máquinas Rotativas via Análise de Sinais e Aprendizagem Profunda	2

PDI 02	Aprendizado Profundo para Análise e Classificação de Imagens Médicas em Diagnóstico e Tratamento.	4
RCSD 01	Monitoramento Inteligente de Segurança de Redes	1
RCSD 02	Segurança de Redes Orientada por Inteligência Artificial	2
RCSD 03	Técnicas e Ferramentas para o Gerenciamento de Redes Blockchain	2
RCSD 04	Monitoramento Multimodal com Machine Learning para Predição do Abandono em Colmeias Abelhas Africanizadas no Semiárido Cearense	2
TOTAL DE VAGAS		28
VAGAS RESERVADAS PARA PRETOS, PARDOS E INDÍGENAS		6
VAGAS RESERVADAS PARA PESSOAS COM DEFICIÊNCIA		3
VAGAS PARA AMPLA CONCORRÊNCIA		19

### **Linha de pesquisa: computação aplicada (CA)**

CÓDIGO	CA 01
Tema	Sistema Inteligente de Geração de Alertas Proativos para Apoio à Permanência Estudantil com Base em Análise Preditiva de Dados Educacionais
Resumo	Este projeto propõe o desenvolvimento de um sistema inteligente que utiliza técnicas de inteligência artificial para analisar dados educacionais e gerar alertas automáticos de cuidado com alunos em risco. O objetivo é identificar, de forma proativa, situações como risco de evasão, baixo desempenho acadêmico ou vulnerabilidade socioemocional, permitindo que a equipe escolar tome ações preventivas e personalizadas para apoiar a permanência e o sucesso estudantil.
Vagas	01
Proponente	Prof. Dr. Corneli Gomes Furtado Júnior
Projeto	Este projeto propõe o desenvolvimento de um sistema inteligente que utiliza técnicas de inteligência artificial para analisar dados educacionais e gerar alertas automáticos de cuidado com alunos em risco. O objetivo é identificar, de forma proativa, situações como risco de evasão, baixo desempenho acadêmico ou vulnerabilidade socioemocional, permitindo que a equipe escolar tome ações preventivas e personalizadas para apoiar a permanência e o sucesso estudantil.

Referências	
-------------	--

### Linha de pesquisa: inteligência artificial (IA)

CÓDIGO	IA 01
Tema	Análise do impacto de ataques de bit-flip em redes neurais profundas
Resumo	<p>Este tema de pesquisa investiga a vulnerabilidade de modelos de redes neurais a ataques de bit-flip, que consistem na alteração intencional de bits na memória onde os pesos do modelo estão armazenados. Essas perturbações podem comprometer a precisão das inferências, provocando erros de classificação ou até falhas completas no sistema. O estudo busca avaliar os efeitos desses ataques em diferentes arquiteturas de redes neurais, identificando quais camadas e tipos de pesos são mais sensíveis às falhas. Espera-se que os resultados contribuam para o desenvolvimento de mecanismos de detecção e mitigação, fortalecendo a confiabilidade e a segurança de sistemas baseados em inteligência artificial.</p>
Vagas	01
Proponente	Prof. Dr. Otávio Alcântara de Lima Júnior
Projeto	<p>Este projeto propõe o desenvolvimento de modelos eficientes para prever vulnerabilidades a bit-flips em redes neurais profundas. Esses modelos serão construídos a partir da avaliação da confiabilidade estatística dos parâmetros, com base em experimentos de injeção de falhas. O objetivo é prever e ranquear a vulnerabilidade de todos os parâmetros da rede, além de explorar algoritmos de busca avançados para identificar um conjunto mínimo de bit-flips capaz de neutralizar o funcionamento de uma rede neural profunda.</p>
Referências	<p>Anıl Bayram Gogebakan, E. Magliano, Alessio Carpegna, Annachiara Ruospo, A. Savino, and S. D. Carlo, "SpikingJET: Enhancing Fault Injection for Fully and Convolutional Spiking Neural Networks," arXiv (Cornell University), pp. 1–7, Jul. 2024;</p> <p>Y. Zhang, H. Itsuji, T. Uezono, T. Toba, and M. Hashimoto, "Vulnerability Estimation of DNN Model Parameters with Few Fault Injections," IEICE Trans. Fundam. Electron. Commun. Comput. Sci., vol. E106-A, no. 3, pp. 523–530, 2023.;</p> <p>M. Dumont, J.-M. Dutertre, A.-P. Mirbaha, A. Tria, and H. L. Hector, "A Closer Look at Evaluating the Bit-Flip Attack Against Deep Neural Networks," in 2022 IEEE International Workshop on Information Forensics and Security (WIFS), 2022.;</p> <p>G. Yu et al., "A Survey on Failure Analysis and Fault Injection in AI Systems," ACM Transactions on Software Engineering and Methodology, May 2025.</p>

CÓDIGO	IA 02
Tema	Modelos Inteligentes para Otimização Energética: Uma Abordagem com Aprendizado de Máquina
Resumo	Diversos processos industriais, com seus parâmetros e propriedades, podem ser modelados por meio de problemas de classificação de padrões ou de regressão, em abordagens estáticas ou dinâmicas, resultando em soluções eficazes para diferentes aplicações. Nesse contexto, a aplicação de técnicas de aprendizado de máquina em plantas industriais surge como uma estratégia promissora para otimizar o rendimento da produção, reduzir o consumo de energia elétrica e mitigar impactos ambientais, preservando, ao mesmo tempo, a qualidade do produto final.
Vagas	01
Proponentes	Prof. Dr. José Daniel de Alencar Santos
Projeto	Aplicação de técnicas de aprendizado de máquina para otimização do consumo de energia elétrica em processos de usinagem na manufatura de componentes mecânicos.
Referências	<ul style="list-style-type: none"> <li>- KHAN, PATHAN LAYEEQUZZAMA; BHIVSANE, S. V., Experimental Analysis and Investigation of Machining Parameters in Finish Hard Turning of AISI 4340 Steel. Procedia Manufacturing, [s.l.], v. 20, p.265-270, 2018. Elsevier BV.</li> <li>- LABONDRE, RAJSHEKHAR; KRISHNA, PRASAD; MOHANKUMAR, G. C.. An Experimental Investigation on Machinability Studies of Steels by Face Turning. Procedia Materials Science, [s.l.], v. 6, p.1386-1395, 2014. Elsevier BV.</li> <li>- BISHOP, CHRISTOPHER M., NASSER M. NASRABADI. Pattern Recognition and Machine Learning. Vol. 4. No. 4. New York: Springer, 2006.</li> </ul>

CÓDIGO	IA 03
Tema	Deep Learning Theory

Resumo	<p>Deep learning theory aims to uncover the fundamental principles that explain why modern neural networks work so well in practice. While deep models have achieved breakthroughs across domains such as natural language processing, vision, and scientific discovery, much remains unknown about their generalization capabilities, expressivity, robustness, and inductive biases. A deeper theoretical understanding is essential not only for clarifying the limits of current methods, but also for guiding the design of next-generation architectures that are more reliable, interpretable, and principled.</p> <p>Here, we will focus on the generalization capabilities of modern neural networks, including large languages models (LLMs), graph neural networks, and topological deep learning.</p> <p>Ideally, candidates are expected to be familiar with machine learning, proficient in English (reading), have good coding skills (Python preferable), and be interested in learning topics in Applied Math.</p>
Vagas	02
Proponentes	Prof. Dr. Amauri Souza
Projeto 1	Generalization in Large Language Models (LLMs): Investigate how scaling laws, inductive biases, and optimization dynamics shape the ability of LLMs to generalize beyond training data.
Projeto 2	Generalization in Topological & Geometric Deep Learning (TGDL): Explore the representational limits and robustness of TGDL models, analyzing how topological and geometric priors influence generalization across complex structured data.
Referências	<p>P. Reizinger et. al, Position: Understanding LLMs Requires More Than Statistical Generalization. ICML, 2024.</p> <p>C. Zhang et. al, Understanding deep learning requires rethinking generalization. ICLR, 2017.</p> <p>T. Papamarkou et. al. Position: Topological Deep Learning is the New Frontier for Relational Learning. ICML, 2024.</p> <p>S. Jegelka. Theory of Graph Neural Networks: Representation and Learning. ArXiv e-prints, 2022.</p>

CÓDIGO	IA 04
Tema	Inteligência Artificial Explicável com Raciocínio Automatizado

Resumo	Os avanços recentes em aprendizado de máquina permitiram resolver problemas em uma grande variedade de domínios. Aplicações em domínios críticos, como medicina, direito e finanças, motivam a capacidade de obter explicações corretas para as previsões realizadas. Como consequência, pesquisas sobre inteligência artificial explicável têm sido incentivadas e várias técnicas para explicar modelos de aprendizado de máquina têm surgido. Infelizmente, a maioria dos trabalhos sobre a obtenção de explicações é baseada em abordagens heurísticas e não possuem garantias de corretude. Isso agrava o problema da confiança em sistemas que usam aprendizado de máquina, pois com explicações incorretas os usuários podem perder a confiança no sistema. Por conta dessas adversidades, abordagens baseadas em lógica e raciocínio automatizado foram propostas recentemente com a finalidade de computar explicações comprovadamente corretas.
Vagas	01
Proponente	Prof. Dr. Thiago Alves Rocha
Projeto	Este projeto aborda o desenvolvimento de métodos de raciocínio automatizado capazes de fornecer explicações para redes neurais e outros modelos de aprendizado de máquina.
Referências	<p>RIBEIRO, M. T.; SINGH, S.; GUESTRIN, C. <b>“Why should I trust you?”: Explaining the predictions of any classifier.</b> In: 22nd ACM SIGKDD, 2016.</p> <p>IGNATIEV, A.; NARODYTSKA, N.; MARQUES-SILVA, J. <b>Abduction-based explanations for machine learning models.</b> In: 33rd AAAI, 2019.</p> <p>MARQUES-SILVA, J. <b>CPAIOR 2021 Master Class: Formal Reasoning Methods in Machine Learning Explainability.</b> YouTube, 17 de outubro de 2021. Disponível em: <a href="https://www.youtube.com/watch?v=VifLJPWkZU4">https://www.youtube.com/watch?v=VifLJPWkZU4</a></p> <p>WU, M., WU, H., BARRETT, C. <b>Verix: Towards verified explainability of deep neural networks.</b> In: 37th NeurIPS, 2023.</p>

CÓDIGO	IA 05
Tema	Extensão de Modelos Generativos (VAEs, DDPMs) para Tarefas de Geração de Dados Sintéticos

Resumo	Modelos generativos profundos, como Variational Autoencoders (VAEs) e Denoising Diffusion Probabilistic Models (DDPMs), têm se destacado por sua capacidade de modelar distribuições complexas de dados e gerar amostras realistas. Neste projeto, investigaremos estratégias para estender essas arquiteturas a diferentes domínios de dados sintéticos, contemplando cenários estruturados, visuais e temporais. Pretende-se explorar abordagens que combinem eficiência computacional, interpretabilidade e robustez estatística, avaliando o impacto da geração de dados sintéticos em tarefas como balanceamento de bases, simulação de cenários de difícil coleta e preservação da privacidade.
Vagas	01
Proponente	Prof. Dr. Saulo Anderson Freitas de Oliveira
Projeto 1	O projeto visa implementar e adaptar modelos VAEs e DDPMs para a geração de dados sintéticos em múltiplos domínios, com ênfase em:  Ajustes arquiteturais para lidar com dados multimodais.  Avaliação da qualidade dos dados sintéticos por métricas estatísticas e de aprendizado de máquina.  Estudo da aplicabilidade em cenários de baixa disponibilidade de dados e em contextos que demandam privacidade.  Comparação empírica entre os métodos propostos e abordagens clássicas de oversampling e data augmentation.
Referências	GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep Learning. MIT Press, 2016.  HO, Jonathan et al. Denoising diffusion probabilistic models. Advances in Neural Information Processing Systems, v. 33, p. 6840-6851, 2020.  KINGMA, Diederik P.; WELLING, Max. Auto-encoding variational bayes. arXiv preprint arXiv:1312.6114, 2013.  LI, Zhong et al. Diffusion Models for Tabular Data: Challenges, Current Progress, and Future Directions. arXiv preprint arXiv:2502.17119, 2025.

CÓDIGO	IA 06
Tema	Visão computacional em Tecnologias assistivas

Resumo	<p>As Tecnologias Assistivas (TA) podem ser compreendidas como dispositivos pessoais que oferecem suporte para que pessoas com deficiência realizem atividades de forma independente. Entre os desafios enfrentados por deficientes visuais, a mobilidade é um dos mais estudados, por estar diretamente ligada à autonomia em ambientes internos e externos. Nesse contexto, o uso de imagens capturadas por câmeras vestíveis ou instaladas no ambiente surge como recurso para orientação. Uma aplicação relevante é auxiliar deficientes visuais ou idosos a caminharem com maior segurança, evitando colisões com obstáculos e mantendo trajetos seguros.</p> <p>Alguns conjuntos de dados já estão disponíveis com imagens rotuladas para navegação e desvio de obstáculos. Ainda assim, persistem desafios em computação, como a geração artificial de dados para ampliar os cenários de treinamento, a melhoria da precisão dos modelos em ambientes reais e a redução do custo computacional para possibilitar sua execução em dispositivos embarcados de baixo consumo. Esses avanços podem resultar em soluções mais eficientes e acessíveis para apoiar a mobilidade de deficientes visuais e idosos.</p>
Vagas	03
Proponente	Prof. Dr. Elias Teodoro da Silva Junior, orientador; Prof. Dr. Otávio Alcântara de Lima Júnior, coorientador
Projeto 1	Uso de imagens para auxílio a deficientes visuais no desvio de obstáculos.
Projeto 2	Detecção de quedas em ambiente residencial.
Projeto 3	Uso de imagens para navegação de robôs terrestres.
Referências	<p>Cai, Qilie; Wang, Qiang; Zhang, Yuhong; He, Zhibo. Lwdnet-A Lightweight Water-Obstacles Detection Network for Unmanned Surface Vehicles. <i>Robotics and Autonomous Systems</i>, Volume 166, 2023, 104453, ISSN 0921-8890, <a href="https://doi.org/10.1016/j.robot.2023.104453">https://doi.org/10.1016/j.robot.2023.104453</a></p> <p>D. Medeiros, T. Araujo, E. SILVA Jr, and G. Ramalho, "Using images to avoid collisions and bypass obstacles in indoor environments," in Anais Estendidos da XXXIV Conference on Graphics, Patterns and Images (SIBGRAPI). Porto Alegre, RS, Brasil: SBC, 2021, pp. 158–161.</p> <p>BREVE, F.; FISCHER, C. N. Visually impaired aid using convolutional neural networks, transfer learning, and particle competition and cooperation. In: 2020 International Joint Conference on Neural Networks (IJCNN). IEEE, 2020.</p> <p>CORDEIRO, N. H.; PEDRINO, E. C. An architecture for collision risk prediction for visually impaired people. In: 2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). IEEE, 2018.</p> <p>RIQUELME, Fabián et al. Ehomeseniors dataset: An infrared thermal sensor dataset for automatic fall detection research. <i>Sensors (Switzerland)</i>, [s. l.], v. 19, n. 20, p. 1–16, 2019.</p>

CÓDIGO	IA 07
Tema	Aprendizado de Máquinas: Modelos Leves e/ou com Capacidade de Rejeição
Resumo	Esse tema envolve tanto a computação suave/leve (soft computing) quanto a redução do tamanho dos modelos com o intuito de aprimorar seu desempenho. De um lado, busca-se desenvolver métodos que tornem os modelos mais compactos, possibilitando sua execução em plataformas de recursos limitados (como dispositivos embarcados e móveis), com menor consumo de memória, processamento e energia, garantindo ainda respostas rápidas — aspecto crítico em aplicações de tempo real. De outro, pretende-se incorporar técnicas de rejeição, que permitem ao modelo abster-se de decisões em situações de baixa confiança, transferindo o processo para classificadores mais complexos ou para especialistas humanos. Essa combinação de eficiência e segurança visa aumentar a confiabilidade e a disponibilidade dos sistemas, especialmente em aplicações sensíveis como diagnósticos médicos.
Vagas	02
Proponente	Prof. Dr. Ajalmar Rego da Rocha Neto
Projeto 1	Redução do tamanho dos modelos de aprendizagem de máquinas: busca-se desenvolver técnicas que permitam comprimir ou simplificar modelos sem perda significativa de desempenho. Essa redução é essencial para aplicação em plataformas de recursos limitados, como dispositivos embarcados (ex.: Arduíno) ou sistemas móveis. Modelos menores demandam menos memória e processamento, possibilitando respostas mais rápidas, fator crítico em aplicações de tempo real. Além disso, contribuem para menor consumo de energia e maior viabilidade de implantação em larga escala.
Projeto 2	Aprimoramento do desempenho dos modelos com técnicas de rejeição: o foco é incorporar mecanismos que permitam ao modelo optar por não tomar uma decisão quando o nível de confiança for baixo. Essa abordagem evita decisões equivocadas em sistemas de apoio, transferindo o processo para métodos mais adequados ou especialistas humanos. A rejeição funciona como uma camada adicional de segurança, aumentando a confiabilidade do sistema em cenários críticos, como diagnósticos médicos. Também abre espaço para modelos híbridos, onde classificadores simples delegam casos incertos para modelos mais complexos.

Referências	<p>DIAS, MADSON L. D. ; MAIA, ATILLA N. ; DA ROCHA NETO, AJALMAR R. ; GOMES, JOAO P . P . Parsimonious Minimal Learning Machine via Multiresponse Sparse Regression. International Journal of Neural Systems, v. 30, p. 1-16, 2020.</p> <p>MATIAS, ALAN L. ; NETO, AJALMAR R. ROCHA . OnARTMAP: A Fuzzy ARTMAP-based Architecture. NEURAL NETWORKS, v. 98, p. 236-250, 2017.</p> <p>DIAS, M. L. D. ; SOUSA, L. S. ; Rocha Neto, Ajalmar R. ; FREIRE, A. L.Fixed-Size Extreme Learning Machines Through Simulated Annealing. NEURAL PROCESSING LETTERS, v. 1, p. 1-17, 2017.</p> <p>CHOW, C. On optimum recognition error and reject tradeoff. IEEE Transactions on Information Theory,, v. 16, n. 1, p. 41–46, jan 1970.</p>
-------------	--

CÓDIGO	IA 08
Tema	Detecção de Falhas em Máquinas Elétricas de Indução Trifásicas
Resumo	As máquinas de indução trifásicas são amplamente utilizadas na indústria como motores, ao ponto de serem consideradas como “cavalo vapor” da indústria. Sua aplicação também é comum como geradores, sendo amplamente utilizados em geração eólica de grande porte. Sua robustez e simplicidade construtiva são os principais atributos responsáveis por esta reputação. Entretanto, quando esta máquina é submetida a condições operacionais ou ambientais severas, pode ser conduzida a falhas prematuras e inesperadas, o que pode causar impactos econômicos importantes. A detecção destas falhas vem sendo costumeiramente realizada por pessoal e instrumentação especializada, principalmente em equipamentos considerados de alto custo. Entretanto, com o desenvolvimento de técnicas de inteligência computacional, a detecção prematura de falhas, baseada na análise de sinais de vibração, corrente e/ou temperatura, vem se apresentando como uma opção atrativa, inclusive para equipamentos de baixo custo. Dessa forma, propõe-se o desenvolvimento de pesquisa aplicada para a detecção combinada de falhas por curto-círcuito, abertura de barras rotóricas e/ou falhas em rolamentos. Para tal, há a possibilidade da utilização de uma bancada de testes ou o desenvolvimento de simulações computacionais para gerar os sinais dos quais serão extraídos os atributos para o treinamento dos classificadores. No caso de simulação computacional, pode-se lançar mão de modelos dinâmicos lineares ou a aplicação de elementos finitos para levar em consideração os efeitos dos harmônicos espaciais. Além disso, outra oportunidade é a implementação dos algoritmos de detecção de falhas em hardware específico para aplicação industrial.
Vagas	01

Proponente	Prof. Dr. Cláudio Marques de Sá Medeiros
Projeto 1	Detecção de falhas em rolamentos utilizando sinais de vibração e redes convolucionais
Referências	<p>VIEIRA, RENAN G. ; MEDEIROS, CLAUDIO M. S. ; SILVA, ELIAS T. . Classification and sensitivity analysis to detect fault in induction motors using an MLP network. In: 2016 International Joint Conference on Neural Networks (IJCNN), 2016, Vancouver. 2016 International Joint Conference on Neural Networks (IJCNN). p. 796-802.</p> <p>VIEIRA, RENAN GOMES ; CUNHA, REBECA GUERREIRO C. ; MEDEIROS, CLAUDIO MARQUES SA ; SILVA, ELIAS TEODORO . Embedding a Neural Classifier to Detect Faults in a Three-Phase Induction Motor. In: 2016 VI Brazilian Symposium on Computing Systems Engineering (SBESC), 2016, João Pessoa. 2016 VI Brazilian Symposium on Computing Systems Engineering (SBESC). p. 136.</p> <p>NASCIMENTO, N. M. M. E. ; REBOUCAS FILHO, P. P. ; MEDEIROS, C. M. S. . A reliable approach for detection of incipient faults of short-circuits in induction generators using machine learning. COMPUTERS &amp; ELECTRICAL ENGINEERING , v. 71, p. 440-451, 2018.</p>

CÓDIGO	IA 09
Tema	Detecção de Falhas Baseada em Visão Computacional
Resumo	As técnicas de inteligência computacional vêm ganhando destaque na solução de problemas relacionados à detecção de falhas baseada em imagens. A aplicação desta filosofia pode provocar um impacto positivo relevante na agilidade e redução de custos de manutenção preditiva e corretiva em parques de geração eólica e fotovoltaica. No caso de parques eólicos, a análise preliminar de falhas em pás pode ser realizada de forma remota por detectores neurais, por exemplo, sobre imagens fotográficas realizadas pelo pessoal técnico dos próprios parques eólicos, dispensando a presença de técnico especializado, o qual se deslocará ao objeto de investigação apenas em caso de sugestão do detector. Já no caso de usinas fotovoltaicas de médio e grande porte, a utilização de drones equipados com câmeras e a aplicação posterior de algoritmos de detecção de falhas sobre imagens termográficas pode tornar o processo de correção de falhas ágil, reduzindo as perdas e aumentando a disponibilidade de geração.
Vagas	02
Proponentes	Prof. Dr. Cláudio Marques de Sá Medeiros

Projeto 1	Detecção de falhas em pás eólicas utilizando redes neurais artificiais.
Projeto 2	Detecção de falhas em usinas fotovoltaicas a partir de imagens termográficas e redes neurais artificiais.
Referências	<p>Pereira, M. L, DESENVOLVIMENTO DE UM SISTEMA DE MONITORAMENTO E DETECÇÃO DE FALHAS PARA MICROGERAÇÃO FOTOVOLTAICA, Dissertação de mestrado, PPGER, 2018.</p> <p>Tomazzoli, C.; Scannapieco S. e Cristani, M. Internet of Things and artificial intelligence enable energy efficiency, Journal of Ambient Intelligence and Humanized Computing, Springer, 2020.</p>

#### **Linha de pesquisa: processamento de sinais e imagens (PDI)**

CÓDIGO	PDI 01
Tema	Detecção de Anomalias em Máquinas Rotativas via Análise de Sinais e Aprendizagem Profunda

Resumo	<p>A manutenção preditiva evoluiu com a Indústria 4.0, tornando-se crucial para a confiabilidade de ativos rotativos, como bombas centrífugas, esteiras transportadoras e aerogeradores, para citar os mais comuns em diversos setores industriais. A Tese "Deep Learning-Based Anomaly Detection System for Centrifugal Pumps: Enhancing Predictive Maintenance in the Offshore Industry", que demonstrou a eficácia do emprego de autoencoders para esta finalidade. Sabe-se que Autoencoders Variacionais (VAE) são valiosos para a síntese de dados (gerar imagens, texto e dados de séries temporais, como os de IoT ou sinais biológicos), a detecção de anomalias (identificar desvios nos dados que se afastam da distribuição aprendida), na educação de ruído (reconstruir dados corrompidos ou remover informações indesejadas) e no aumento de dados (expandir conjuntos de dados para treinar outros algoritmos de IA, especialmente para séries temporais).</p> <p>Esta pesquisa propõe avaliar e expandir este conceito, investigando um sistema híbrido que integra redes neurais profundas com técnicas de inteligência computacional para não apenas detectar, mas também classificar e interpretar anomalias em tempo real. Este projeto, portanto, visa propor e validar uma abordagem em um sistema de monitoramento de condição em uma planta industrial em escala de laboratório. O sistema utilizará, para a validação, uma arquitetura de Internet Industrial das Coisas (IIoT) para aquisição de dados multisensoriais (vibração, temperatura e corrente) de bombas centrífugas. Será investigado um modelo de detecção de anomalias baseado em VAEs, cujas saídas poderão ser interpretadas por um sistema de inferência fuzzy para fornecer uma métrica de criticidade compreensível ao operador. Será realizada a aquisição de um conjunto de dados representativo dos estados normal e de falha (ex.: cavitação, desbalanceamento, rolamento avariado). Os sinais brutos serão pré-processados (filtragem, normalização, extração de features no domínio da frequência). Será avaliado se um modelo VAE pode ser treinado para reconstruir o perfil de operação normal. Anomalias poderão ser detectadas quando a taxa de erro de reconstrução ultrapassar um limiar estatístico. Este erro poderá ser mapeado como entrada para um sistema fuzzy, que, com base no conhecimento de especialista, gerará um índice de saúde da bomba (ex.: "Normal", "Atenção", "Crítico").</p>
Vagas	2
Proponente	Prof. Dr. Geraldo Ramalho
Projeto 1	Investigação de Autoencodes Variacionais no monitoramento de condição e na detecção de sinais representativos de anomalias em bombas centrífugas em laboratório, por meio de aprendizado supervisionado e/ou não supervisionado.
Projeto 2	Investigação de Autoencodes Variacionais na filtragem e/ou síntese de sinais de anomalias em bombas centrífugas em laboratório, por meio do refinamento ou transferência a partir de modelos de aprendizagem profunda previamente treinados.

Referências	<p>BLAAUW, ANE DYVEKE ANDENES; HOVDE, TORSTEIN HELTNE. Deep Learning-Based Anomaly Detection System for Centrifugal Pumps: Enhancing Predictive Maintenance in the Offshore Industry, 2023. Acesso em 11/08/2025. Disponível em: <a href="https://hdl.handle.net/11250/3093891">https://hdl.handle.net/11250/3093891</a></p> <p>XINGCHEN LIU, QICAI ZHOU, JIONG ZHAO, HEHONG SHEN, XIAOLEI XIONG. Fault Diagnosis of Rotating Machinery under Noisy Environment Conditions Based on a 1-D Convolutional Autoencoder and 1-D Convolutional Neural Network. Sensors 2019, 19(4), 972; <a href="https://doi.org/10.3390/s19040972">https://doi.org/10.3390/s19040972</a></p> <p>ZHENGJIE WANG, XING YANG, TONGJIE LI, LEI SHE, XUANCHEN GUO, FAN YANG. Intelligent Fault Diagnosis for Rotating Machinery via Transfer Learning and Attention Mechanisms: A Lightweight and Adaptive Approach. Actuators 2025, 14(9), 415; <a href="https://doi.org/10.3390/act14090415">https://doi.org/10.3390/act14090415</a></p> <p>ZHANG S, SU L, GU J, et al. Rotating machinery fault detection and diagnosis based on deep domain adaptation: A survey. Chinese Journal of Aeronautics, 2023, 36(1): 45-74. <a href="https://doi.org/10.1016/j.cja.2021.10.006">https://doi.org/10.1016/j.cja.2021.10.006</a></p> <p>HUANG, R., XIA, J., ZHANG, B., CHEN, Z., LI, W. Compound Fault Diagnosis for Rotating Machinery: State-of-the-Art, Challenges, and Opportunities. Journal of Dynamics, Monitoring and Diagnostics, 2(1), 2023. 13-29. <a href="https://doi.org/10.37965/jdmd.2023.152">https://doi.org/10.37965/jdmd.2023.152</a></p> <p>RUPA DEVI B, SUSEELA G, RANJITH KUMAR PAINAM, THAMMISETTY SWETHA, SURYANARAYANA, REDDY MADHAVI K. Intelligent Fault Diagnosis in Industrial Machinery: Leveraging AI with LSTM Autoencoder for Enhanced Fault Detection. Journal of Machine and Computing 4(4), 2024.</p>
-------------	--

CÓDIGO	PDI 02
Tema	Aprendizado Profundo para Análise e Classificação de Imagens Médicas em Diagnóstico e Tratamento.
Resumo	A análise de imagens médicas desempenha um papel fundamental na prática da medicina moderna, permitindo que os profissionais de saúde visualizem estruturas internas do corpo, identifiquem anormalidades, e façam diagnósticos precisos. Essas imagens, provenientes de diversas modalidades, como radiografia, tomografia, ressonância magnética e microscopia, oferecem informações valiosas para a compreensão e o tratamento de doenças. No entanto, à medida que a quantidade de dados gerados por exames médicos aumenta exponencialmente, a necessidade de métodos eficazes de análise e interpretação também cresce. A aplicação de técnicas de Aprendizado Profundo (Deep Learning) nesse contexto representa um avanço significativo, permitindo o desenvolvimento de sistemas inteligentes capazes de automatizar a interpretação de imagens médicas, melhorar a precisão diagnóstica e agilizar o processo de tomada de decisões clínicas. Esta linha busca contribuir para esse campo em constante evolução, explorando o potencial das tecnologias de Aprendizado Profundo para aprimorar a prática da Engenharia Biomédica.
Vagas	04

Proponente	Prof. Dr. Pedro Pedrosa
Projeto	Inteligência Artificial Explicável (XAI) aplicado ao Aprendizado Profundo para Análise e Classificação de Imagens Médicas em Diagnóstico e Tratamento.
Referências	<p>[1] E. F. Ohata et al., Automatic detection of COVID-19 infection using chest X-ray images through transfer learning, in IEEE/CAA Journal of Automatica Sinica, vol. 8, no. 1, pp. 239-248, January 2021, <a href="https://doi.org/10.1109/JAS.2020.1003393">https://doi.org/10.1109/JAS.2020.1003393</a>.</p> <p>[2] C. M. J. M. Dourado, S. P. P. da Silva, R. V. M. da Nobrega, P. P. Rebouças Filho, K. Muhammad and V. H. C. de Albuquerque, "An Open IoHT-Based Deep Learning Framework for Online Medical Image Recognition," in IEEE Journal on Selected Areas in Communications, vol. 39, no. 2, pp. 541-548, Feb. 2021, <a href="https://doi.org/10.1109/J SAC.2020.3020598">https://doi.org/10.1109/J SAC.2020.3020598</a>.</p> <p>[3] Yongzhao Xu, Luís F.F. Souza, Iágson C.L. Silva, Adriell G. Marques, Francisco H.S. Silva, Virgínia X. Nunes, Tao Han, Chuanyu Jia, Victor Hugo C. de Albuquerque, Pedro P. Rebouças Filho. A soft computing automatic based in deep learning with use of fine-tuning for pulmonary segmentation in computed tomography images, Applied Soft Computing, Volume 112, 2021, 107810, ISSN 1568-4946, <a href="https://doi.org/10.1016/j.asoc.2021.107810">https://doi.org/10.1016/j.asoc.2021.107810</a>.</p> <p>[4] Y. Xu et al., Deep Learning-Enhanced Internet of Medical Things to Analyze Brain CT Scans of Hemorrhagic Stroke Patients: A New Approach, in IEEE Sensors Journal, vol. 21, no. 22, pp. 24941-24951, 15 Nov. 15, 2021, <a href="https://doi.org/10.1109/JSEN.2020.3032897">https://doi.org/10.1109/JSEN.2020.3032897</a>.</p> <p>[5] Marcus A.G. Santos, Roberto Munoz, Rodrigo Olivares, Pedro P. Rebouças Filho, Javier Del Ser, Victor Hugo C. de Albuquerque. Online heart monitoring systems on the internet of health things environments: A survey, a reference model and an outlook, Information Fusion, Volume 53, 2020, Pages 222-239, ISSN 1566-2535, <a href="https://doi.org/10.1016/j.inffus.2019.06.004">https://doi.org/10.1016/j.inffus.2019.06.004</a>.</p> <p>[6] Róger M. Sarmento, Francisco F.X. Vasconcelos, Pedro P. Rebouças Filho, Victor Hugo C. de Albuquerque. An IoT platform for the analysis of brain CT images based on Parzen analysis, Future Generation Computer Systems, Volume 105, 2020, Pages 135-147, ISSN 0167-739X, <a href="https://doi.org/10.1016/j.future.2019.11.033">https://doi.org/10.1016/j.future.2019.11.033</a>.</p>

### **Linha de pesquisa: redes de computadores e sistemas distribuídos (RCSD)**

CÓDIGO	RCSD 01
Tema	Monitoramento Inteligente de Segurança de Redes

Resumo	Trata-se de desenvolver e validar metodologias baseadas em inteligência artificial (IA) para identificar, modelar e mitigar ataques de engenharia social, considerando-se tanto a dimensão humana quanto a técnica. O objetivo é formular uma estrutura científica que abranja: (i) coleta e curadoria de dados relevantes (por exemplo, comunicações, comportamentos humanos, perfis de risco), (ii) aplicação de algoritmos de aprendizagem de máquina e técnicas de processamento de linguagem natural para detecção precoce e preditiva de tentativas de manipulação (como phishing, pretexting, deepfakes), (iii) avaliação experimental da eficácia dessas soluções (por meio de métricas como taxa de detecção, falso-positivo, tempo de resposta, impacto humano) e (iv) proposição de contramedidas adaptativas, explicáveis e éticas — integrando considerações de usabilidade, privacidade, viés algorítmico e responsabilização.
Vagas	1
Proponente	Prof. Dr. Antonio Wendell de Oliveira Rodrigues
Projeto	Proposicao de Solucoes de Analise de Engenharia Social com IA
Referências	

CÓDIGO	RCSD 02
Tema	Segurança de Redes Orientada por Inteligência Artificial
Resumo	Aplicação de técnicas avançadas de Inteligência Artificial e Aprendizado de Máquina para enfrentar os desafios contemporâneos críticos em segurança de redes de computadores. O foco principal está no desenvolvimento de sistemas inteligentes capazes de detectar ameaças sofisticadas e de dia-zero, mesmo quando ocultas em tráfego criptografado, e na criação de mecanismos de segurança para arquiteturas modernas como SD-WAN. Um pilar fundamental desta temática é a superação do paradigma de caixa preta da IA por meio da Inteligência Artificial Explicável (XAI), garantindo que as decisões automatizadas sejam transparentes, auditáveis e acionáveis por analistas de segurança. A pesquisa envolve a modelagem de comportamento de rede, a análise de metadados de fluxo, o desenvolvimento de modelos de deep learning (supervisionados e não supervisionados) e a integração dessas soluções em ambientes de rede definidos por software (SDNs), com o objetivo final de criar sistemas de defesa proativos, adaptativos e inteligentes.
Vagas	02
Proponente	Prof. Dr. Reinaldo Bezerra Braga
Projeto 1	Detecção de Ameaças e Explicabilidade de Decisões de Segurança em Ambientes SD-WAN Utilizando Técnicas de Inteligência Artificial Explicável
Projeto 2	Detecção Não Supervisionada de Ameaças Avançadas em Tráfego Criptografado TLS 1.3

Referências	<p>LUNDBERG, S. M.; LEE, S.-I. A Unified Approach to Interpreting Model Predictions. <i>Advances in Neural Information Processing Systems (NeurIPS)</i>, 2017.</p> <p>MOLNAR, C. <i>Interpretable Machine Learning: A Guide for Making Black Box Models Explainable</i>. 2nd ed., 2022.</p> <p>RIBEIRO, M. T.; SINGH, S.; GUESTRIN, C. "Why Should I Trust You?": Explaining the Predictions of Any Classifier. <i>Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)</i>, 2016.</p> <p>ACETO, G.; CUONZO, D.; PERSICO, V.; PESCIONE, A. Toward Effective Mobile Encrypted Traffic Classification through Deep Learning. <i>Neurocomputing</i>, v. 409, p. 306-315, 2020.</p> <p>BUCUR, D. I.; et al. Explainable AI for Network Security: A Survey. <i>IEEE Access</i>, v. 9, p. 113379-113396, 2021.</p> <p>DORLEVSKY, M.; et al. TSF: A Transparent-Secure Framework for Software-Defined Networks. <i>IEEE Transactions on Dependable and Secure Computing</i>, 2022.</p> <p>LI, W.; et al. Towards A Deep Learning-Driven Intrusion Detection Approach for IoT Networks. <i>IEEE Internet of Things Journal</i>, 2021.</p> <p>LOPEZ-MARTIN, M.; CARRO, B.; SANCHEZ-ESGUEVILLAS, A.; LLORENTE, J. Network Traffic Anomaly Detection with Gated Recurrent Units and Attention Mechanism. <i>Computer Communications</i>, v. 175, p. 12-22, 2021.</p> <p>SHEN, M.; WEI, Y.; ZHU, L.; WANG, M. Classification of Encrypted Traffic with Second-Order Markov Chains and Application Attribute Bigrams. <i>IEEE Transactions on Information Forensics and Security</i>, v. 16, p. 536-551, 2021.</p> <p>YANG, H.; et al. A Multi-Task Learning Model for Encrypted Traffic Classification and Malicious Traffic Detection. <i>IEEE Transactions on Network and Service Management</i>, 2022.</p> <p>ZHAO, S.; LI, W.; ZIA, T.; ZOMAYA, A. Y. A Deep Learning-Based Approach for Anomaly Detection in Encrypted Network Traffic. <i>IEEE Transactions on Information Forensics and Security</i>, 2023.</p> <p>ZIMMERMANN, T.; et al. Towards Evaluating the Robustness of Deep Intrusion Detection Models in Adversarial Environments. <i>Computers &amp; Security</i>, v. 112, 2022.</p>
-------------	---

CÓDIGO	RCSD 03
Tema	Técnicas e Ferramentas para o Gerenciamento de Redes Blockchain

Resumo	Nos últimos anos, Blockchain ter sido apresentada como uma tecnologia disruptiva. Sua definição, embora seja expressa de modo bastante fragmentado na literatura atual, considera aspectos como ledgers descentralizados, redes peer-to-peer, transações confiáveis e seguras entre outros termos. Vários tipos de aplicações suportadas por redes Blockchain tem sido reportadas nos últimos anos. Aplicações essas que vão desde as consagradas criptomoedas até sistemas nas áreas de educação e saúde. Contudo, a infraestrutura descentralizada das redes Blockchain introduz grandes desafios para sua adoção nos negócios atualmente. A necessidade de lidar com questões de escalabilidade, carência de padrões universais, complexos sistemas de consenso, entre outros, requer a atuação de profissionais altamente especializados para lidar com esses desafios. Nesse sentido, esse projeto visa estudar, propor e validar métodos, técnicas e ferramentas para o suporte ao gerenciamento de redes Blockchain. O objetivo maior dessa pesquisa é fornecer ferramentas que permitam que essa tecnologia seja adotada mais facilmente pelas organizações, minorando os investimentos necessários para implantar redes de Blockchain complexas.
Vagas	02
Proponente	Prof. Dr. Cidcley Teixeira de Souza
Projeto 1	Utilizando Modelos em Tempo de Execução no Gerenciamento de Blockchains Permissionadas
Projeto 2	Desenvolvimento Orientado a Modelos em Interoperabilidade de Blockchains
Referências	<p>1. Frizzo-Barkera, J., Chow-Whitea, P. A., Adamsa, P. R., Mentankoa, J., Hab D., Greenc, S. (2020).Blockchain as a disruptive technology for business: A systematic review. International Journal of Information Management. Volume 51, April 2020, 102029. <a href="https://doi.org/10.1016/j.ijinfomgt.2019.10.014">https://doi.org/10.1016/j.ijinfomgt.2019.10.014</a>.</p> <p>2. Kasireddy, P. (2017). Blockchains don't scale. Not today, at least. But there's hope. Retrieved December 10, 2020, from Hacker Noon website:<a href="https://hackernoon.com/blockchains-dont-scale-not-today-at-least-but-there-s-hope-2cb43946551a">https://hackernoon.com/blockchains-dont-scale-not-today-at-least-but-there-s-hope-2cb43946551a</a>.</p> <p>3. Zalan, T. (2018). Born global on blockchain. Review of International Business and Strategy, 28(1), 19–34. <a href="https://doi.org/10.1108/RIBS-08-2017-0069">https://doi.org/10.1108/RIBS-08-2017-0069</a>.</p> <p>4. Hughes, L., Dwivedi, Y. K., Misra, S. K., Rana, N. P., Raghavan, V., Akella, V. (2019). Blockchain research, practice and policy: Applications, benefits, limitations, emerging research themes and research agenda. International Journal of Information Management, 49, 114–129. <a href="https://doi.org/10.1016/j.ijinfomgt.2019.02.005">https://doi.org/10.1016/j.ijinfomgt.2019.02.005</a>.</p>

CÓDIGO	RCSD 04
Tema	Monitoramento Multimodal com Machine Learning para Predição do Abandono em Colmeias Abelhas Africanizadas no Semiárido Cearense

Resumo	O abandono de uma colônia é um fenômeno crítico na apicultura, caracterizado pela saída completa das abelhas do ninho sem retorno, causando perdas significativas para os apicultores do semiárido cearense. Esse projeto visa investigar, por meio de técnicas avançadas de aprendizado de máquina, quais fatores ambientais e comportamentais (sensoriados dentro e fora das colmeias) podem antecipar a iminência do abandono. Além de variáveis tradicionais (temperatura, umidade, peso, clima e inspeções in loco), este projeto amplia a abordagem para incluir dados multimídia obtidos por sensores de áudio, vídeo e vibração, buscando capturar sinais sutis de estresse ou alteração no comportamento coletivo da colônia. As técnicas de aprendizado de máquina a serem exploradas incluem: deep learning: uso de CNNs e modelos baseados em espectrogramas para análise de padrões de zumbido e atividade sonora; Visão computacional para vídeo: aplicação de CNNs e modelos baseados em Transformers para detecção de fluxo de entrada e saída de abelhas e comportamentos atípicos; Análise de séries temporais e vibração: uso de LSTMs, GRUs e modelos híbridos CNN-LSTM para detecção de alterações rítmicas e microvibrações associadas ao estado da colônia; Modelos multimodais: integração de múltiplas fontes de dados (sensores ambientais, inspeções, áudio, vídeo e vibração) em arquiteturas de aprendizado profundo para aprimorar a acurácia da previsão de risco de abandono. O projeto busca não apenas prever precocemente o abandono, mas também contribuir para a criação de sistemas de apoio à decisão para apicultores, com alertas em tempo real.
Vagas	02
Proponente	Prof. Dr. Antonio Rafael Braga
Projeto	Aplicação de técnicas de aprendizado de máquina para predição do bem-estar de colônias de abelhas no sertão central com dados de inspeções in-loco e sensoriamento remoto
Referências	<p>YILDIZ, Berkant İsmail; ESKIOĞLU, Kemal; KARABAĞ, Kemal. Developing a machine learning prediction model for honey production. <i>Mediterranean Agricultural Sciences</i>, v. 37, n. 2, p. 105-110, 2024.</p> <p>Rafael Braga, Antonio; Arruda Fontenele, Tiago; Guimarães Al-Alam, Wagner; de Carvalho Silva, Jefferson. Prototyping a system for detection and notification of damage or theft in beehives. <i>Ecological Informatics</i>, v. 75, p. 102015, <a href="https://doi.org/10.1016/j.ecoinf.2023.102015">https://doi.org/10.1016/j.ecoinf.2023.102015</a>, 2023.</p> <p>Rafael Braga, Antonio; G. Gomes, Danielo ; Rogers, Richard ; E. Hassler, Edgar ; M. Freitas, Breno ; A. Cazier, Joseph . A method for mining combined data from in-hive sensors, weather and apiary inspections to forecast the health status of honey bee colonies. <i>Computers And Electronics In Agriculture</i>, v. 169, p. 105161, 2020.</p>



Documento assinado eletronicamente por **Saulo Anderson Freitas de Oliveira, Professor do Ensino Básico, Técnico e Tecnológico**, em 21/11/2025, às 05:27, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade do documento pode ser conferida no site  
[https://sei.ifce.edu.br/sei/controlador\\_externo.php?  
acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ifce.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0) informando o código verificador **8155890** e o código CRC **BCC24EBC**.

---

23256.014991/2025-78

8155890v4