



Programa de Pós-Graduação em Engenharia de Teleinformática (PPGETI)  
Centro de Tecnologia (CT)  
Universidade Federal do Ceará (UFC)

## **SEMINÁRIO DE AUTOAVALIAÇÃO**

Dezembro, 2024



## **APRESENTAÇÃO**

Como parte das ações de autoavaliação do PPGETI, a Coordenação do Programa promoveu, nos dias 11 e 12 de dezembro de 2024, um seminário que contou com a participação de dois avaliadores externos.

Durante o evento, discentes e docentes do PPGETI apresentaram os resultados de suas pesquisas em sessões orais e de pôsteres. Além disso, os avaliadores realizaram reuniões separadas com o colegiado, os discentes e a coordenação, possibilitando um diálogo amplo sobre o Programa.

A seguir, apresentamos a programação e fotos do seminário e os resumos e slides dos trabalhos apresentados.



# **SEMINÁRIO DE AUTOAVALIAÇÃO DO PPGETI/UFC**

11 e 12 de dezembro de 2024

---

[WWW.PPGETI.UFC.BR](http://WWW.PPGETI.UFC.BR)

## Dia 1 - 11/12/2024 (Quarta-feira)

### **Manhã**

9h - 9:30h: Apresentação do PPGETI  
(Auditório do LESC)

9:30h - 12h: Encontro com discentes:  
apresentações de pôsteres  
(Sede do DETI, térreo)

### **Tarde**

14h - 16:30h Encontro com discentes:  
apresentações no formato pitch  
(Auditório do LESC)

## Dia 2 - 12/12/2024 (Quinta-feira)

### **Manhã**

9h - 12h: Visita às salas de aulas e laboratórios do  
PPGETI

### **Tarde**

14h - 15h: Reunião dos avaliadores com  
discentes (Auditório do LESC)

15h - 17h: Reunião dos avaliadores com a  
Coordenação (Auditório do LESC)







**SEMINÁRIO DE AUTOAVALIAÇÃO  
DO PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE TELEINFORMÁTICA DA  
UNIVERSIDADE FEDERAL DO CEARÁ**

**LIVRO DE RESUMOS**

**Dezembro, 2024**

## **ERNESTO GURGEL VALENTE**

**Título do trabalho:** Data Quality to Federated Learning Performance Improvement

**Resumo do trabalho:**

Massive data generation through Internet of Things (IoT) devices affects the demand for data analysis to discover helpful information without biases. In this scenario, the challenge is to select high-quality data for training Artificial Intelligence (AI) algorithms, particularly in Federated Learning (FL) environments. FL applications include IoT devices that collaborate to train AI models without sharing sensitive data. Several applications that handle sensitive data, such as those in the healthcare sector, financial services industry, and governments, are suitable for FL. Therefore, selecting quality data is critical, as low-quality data may contain errors, be irrelevant, hinder training, lead to incorrect conclusions, or delay training. This study addresses these problems by selecting data quality in FL and centralized environments, speeding training up, and reducing computational costs. The main contributions of this study include providing a data quality analysis algorithm at the edge, reducing the computational cost of training AI models, reducing unnecessary data processing, and accelerating the convergence of AI models. The results showed a performance improvement with minimal loss of accuracy and significant gains in time efficiency. In Independent and Identically Distributed (iid) and Non-Independent and Identically Distributed (non-iid) scenarios, execution time reductions of up to 56.49% and 54.48%, respectively, were observed with minimal accuracy overhead.

**Nome do orientador:** Julio Cesar Santos dos Anjos

**IGOR ROCHA DE SOUSA**

**Título do trabalho:** Síntese e Análise de Estabilidade de Controladores PID de Ordem Fracionária: Teoria e Aplicações

**Resumo do trabalho:**

Esta pesquisa tem como principal contribuição o desenvolvimento de novas técnicas para síntese de controladores proporcional-integral-derivativo (PID) de ordem fracionária, bem como a análise da estabilidade em malha fechada do controlador resultante. Para a análise de estabilidade, este trabalho apresenta uma nova estrutura voltada para sistemas de controle de ordem fracionária com equação característica de malha fechada na forma de trinômios que difere daquela empregada atualmente na literatura. Ao contrário do método usual, que promove uma mudança de variável para fornecer apenas soluções numéricas, a abordagem proposta utiliza a equação de Lambert-Tsallis para fornecer soluções analíticas para a equação característica. Além disso, é possível definir o critério de estabilidade do sistema de forma analítica, permitindo que o projetista defina os parâmetros do controlador que satisfaçam as condições de estabilidade do sistema. Como exemplo, as condições de estabilidade para um benchmark da literatura são apresentadas analiticamente e confirmadas a posteriori por um método numérico. Por fim, é apresentado um conjunto de sistemas de controle composto por controladores e plantas de ordem inteira e fracionária, adequado para análise pelo método proposto.

**Nome do orientador:** Guilherme de Alencar Barreto

**YURI SALES RIBEIRO**

**Título do trabalho:** Channel Estimation for Beamforming Design in IRS-assisted MIMO Communications

**Resumo do trabalho:**

We study methods to perform channel estimation aligned with the joint active and passive beamforming design in an intelligent reflecting surface (IRS)-assisted multiple input multiple output (MIMO) networks. For this purpose, we explore the Kronecker structure of the involved channels to factorize each channel in horizontal and vertical channel components. After the factorized channels are estimated, we apply different strategies to active and passive beamforming designs, and each strategy requires different channel estimations to solve the beamforming optimization problem. Simulation results showed that the methods that explore the Kronecker structure can significantly enhance the spectral efficiency compared to the benchmark model due to the processing done to obtain the factorized channel components, which reduces the noise from the channel estimation step with less computational complexity.

**Nome do orientador:** André Lima Férrer de Almeida

## **AMARILTON LOPES MAGALHÃES**

**Título do trabalho:** Closed-Form Receivers for MIMO Communications Assisted by Hybrid Reconfigurable Surfaces

**Resumo do trabalho:**

Recent research has focused on advanced architectures for reconfigurable intelligent surfaces (RIS) that incorporate sensing capabilities. A notable development is the hybrid simultaneously sensing and reflecting RIS (HRIS), which integrates both sensing and reflecting meta-atoms. This design endows HRIS with signal processing abilities to tackle the channel estimation challenge. This work develops a closed-form semi-blind receiver pair for HRIS-assisted multiple-input multiple-output wireless communications, leveraging HRIS for joint symbol detection and channel estimation under a tensor space-time coding. By transmitting information symbols instead of pilots during the CE stage, our data-aided method reduces overall decoding delay while estimating symbols at low computational cost. Simulation results show competitive performance in terms of normalized mean square error and symbol error rates compared to existing solutions, highlighting the effectiveness of enabling semi-blind estimation at both the HRIS and BS. Furthermore, data estimation directly at the HRIS opens new opportunities and use cases for HRIS/RIS-assisted communications.

**Nome do orientador:** André Lima Férrer de Almeida

**JONATHAN RODRIGUES DA SILVA**

**Título do trabalho:** Detectores de Fótons para Comunicações Quânticas

**Resumo do trabalho:**

Sistemas de comunicações quânticas em redes ópticas, em particular distribuição quântica de chaves com variáveis discretas e teleportação quântica, requerem a utilização de detectores de fótons únicos. Estes equipamentos, ao absorverem um fóton, fornecem como saída um pulso elétrico com nível TTL, capaz de ser processado por sistemas computacionais comuns. Os detectores de fótons atuais utilizam fios quânticos de supercondutor ou fotodiodos de avalanche, APDs. O primeiro tipo é mais eficiente e possui menor ruído, entretanto requer refrigeração com hélio líquido e tem maior custo. Por outro lado, o detector baseado em APDs é menos eficiente e mais ruidoso, entretanto pode ser resfriado por um elemento Peltier e é mais barato. Nesta direção, a presente tese tem dois objetivos: 1) a construção e caracterização de um detector de fótons simples, barato e eficiente, para a janela de 1550 nm, baseado em fotodiodo de avalanche. 2) Investigar a utilização do detector de fótons construído como contador de fótons, através do processamento digital do sinal de avalanche obtido.

**Nome do orientador:** Rubens Viana Ramos

**ANTONIO REGILANE LIMA PAIVA**

**Título do trabalho:** Mitigando o Impacto do Envelhecimento do Canal em Sistemas MIMO Distribuídos com Filtros de Kalman

**Resumo do trabalho:**

O envelhecimento do canal pode degradar o desempenho das redes além da quinta geração, sendo mais pronunciado em sistemas de múltiplas entradas e múltiplas saídas massivas distribuídas em ondas milimétricas devido a três fatores principais: atrasos de propagação e processamento por pré-codificação centralizada, alta mobilidade em comunicação assistida para veículos terrestres e aéreos, e alto desvio Doppler. Nesta pesquisa é realizado um estudo de análise e mitigação do envelhecimento do canal utilizando três métodos matemáticos: modelo geométrico estocástico de canal, processo autorregressivo de ordem P e filtro de Kalman não linear.

**Nome do orientador:** Walter da Cruz Freitas Junior

## **MATHEUS GOMES CORDEIRO**

**Título do trabalho:** Cálculo eficiente da função de onda  $\psi(x)$  usando a matriz de coeficientes de Hermite em Python

**Resumo do trabalho:**

Com a aceleração do desenvolvimento de hardware quântico a cada ano, a demanda pela implementação de ferramentas de Simulação de Computação Quântica rápidas e precisas cresceu com igual intensidade devido às dificuldades de acesso ao hardware quântico real. Neste contexto, este trabalho visa alcançar uma vantagem temporal na computação da função de onda de um Oscilador Harmônico Quântico por meio de uma estratégia híbrida, parcialmente baseada no cálculo eficiente e preciso do polinômio de Hermite usando uma matriz de coeficientes combinada com o uso de um otimizador de compilação Just-In-Time (JIT) do Python.

**Nome do orientador:** Hilma Helena Macedo de Vasconcelos

## **RAUL VICTOR DE OLIVEIRA PAIVA**

**Título do trabalho:** Tensor Decomposition-Based Machine Learning Approach for Epilepsy Seizure Detection Using Electroencephalography Signals

**Resumo do trabalho:**

Epilepsy is a chronic neurological disorder that affects a significant portion of the psychiatric population and can have life-threatening consequences. It presents a major public health challenge, placing considerable financial strain on affected families and healthcare systems. This highlights the critical role neurologists play in diagnosing epilepsy, particularly through the analysis of Electroencephalography (EEG) signals. EEG data can be represented as a tensor, capturing dimensions such as amplitude, time, channels, and patients. This multi-dimensional structure leads to high storage demands and significant computational costs when training reliable machine learning models. In this case, tensor decomposition models, such as Parallel Factor Analysis (PARAFAC) and Tucker decomposition, are useful for compressing data while preserving essential information, enabling efficient training of machine learning models in terms of accuracy and processing time.

**Nome do orientador:** Tarcisio Ferreira Maciel

## **WELLINGTON DANTAS DE ALMEIDA**

**Título do trabalho:** Uma Nova Abordagem de Rede Neural com Opção de Rejeição para Equalização e Detecção de Erros

**Resumo do trabalho:**

A comunicação eficiente de dados representa um desafio em sistemas de transmissão e recepção de dados sem fio, especialmente em cenários com interferência intersimbólica e ruído no canal de comunicação, que degradam a qualidade das informações recebidas. Dois métodos são comumente empregados para abordar os problemas de interferência e ruído: (i) métodos de equalização para compensar distorções de sinal e (ii) métodos de detecção de erro para identificar pacotes de dados corrompidos. No entanto, esses métodos têm limitações: métodos de equalização baseados em rede neural categorizam todos os padrões, mesmo em cenários incertos, comprometendo o desempenho, e algoritmos de detecção de erro são propensos a falhas, especialmente em cenários de altos níveis de ruído. Neste artigo, propomos uma rede neural com opção de rejeição, que simultaneamente fornece benefícios para equalização e detecção de erro. Nossa abordagem oferece vantagens sobre os métodos convencionais ao classificar sinais com base em seus níveis de confiança. A técnica de opção de rejeição introduzida neste trabalho melhora o desempenho da rede neural ao evitar classificações com alto risco de erro. Primeiro, analisamos nossa proposta usando três redes neurais convencionais para equalização de canal. Os resultados indicam que nossa proposta melhora as métricas de desempenho. Depois disso, analisamos nossa proposta com um algoritmo de última geração, analisando curvas de taxa de erro de bit para vários canais de comunicação. Finalmente, apresentamos os resultados de nossa proposta, comparando-os com métodos de detecção de erro estabelecidos e com dados reais de simulações de hardware. Destacamos que nossa proposta pode detectar erros sem sobrecarga de dados adicional e supera outras técnicas em cenários de alto nível de ruído.

**Nome do orientador:** Ajalmar Rêgo da Rocha Neto

## **JOAQUIM OSTERWALD FROTA MOURA FILHO**

**Título do trabalho:** Modelagem e Desenvolvimento de Algoritmos de Aprendizado de Máquina em Redes de Petri Coloridas para o Diagnóstico de Falha de Execução em Manipuladores Robóticos

### **Resumo do trabalho:**

A pesquisa desenvolvida visa aprimorar a previsão e o diagnóstico de falhas de execução em manipuladores robóticos, utilizando uma abordagem gráfica e interpretativa baseada em Redes de Petri Coloridas (CPN). As CPN oferecem uma vantagem significativa por sua capacidade de modelar sistemas complexos de eventos discretos com uma representação visual que facilita a compreensão detalhada dos processos. Implementando algoritmos como K-Nearest Neighbors, Regressão Logística e Naive Bayes em CPN, a pesquisa proporciona maior transparência no diagnóstico de falhas, permitindo um monitoramento mais preciso e um entendimento mais claro das etapas do processo de execução dos manipuladores robóticos. A flexibilidade das implementações permite sua adaptação para qualquer conjunto de dados numéricos, tornando essa metodologia uma ferramenta poderosa para pesquisadores e profissionais interessados em modelagem de sistemas discretos e na aplicação de algoritmos de aprendizado de máquina com maior visibilidade e interpretabilidade. A validação dos modelos foi realizada em cenários de robótica e IoT, mostrando que as implementações em CPN atingem resultados comparáveis aos modelos tradicionais em Python, com o diferencial de serem mais interpretativas. Além de facilitar a detecção de falhas e a visualização dos padrões de erro, essa abordagem oferece um sistema modular e adaptável a diversos conjuntos de dados. No futuro, a pesquisa pretende expandir o uso de CPN para novas aplicações em sistemas complexos, promovendo avanços na confiabilidade e no controle de sistemas industriais e comerciais.

**Nome do orientador:** Giovanni Cordeiro Barroso

## **RODRIGO DE SOUZA XAVIER**

**Título do trabalho:** Detecção e estimativa de precipitação a partir de gravações de áudio

**Resumo do trabalho:**

Dados meteorológicos de superfície são escassos em muitas partes do globo, dificultando o monitoramento climático e gerenciamento eficaz de desastres. Na bacia amazônica, isso ocorre devido ao seu isolamento e impossibilidade de obtenção de dados em alta resolução temporal. Métodos inovadores de estimativa de precipitação são, portanto, necessários para preencher essa lacuna. Aqui, apresentamos uma abordagem para estimar a precipitação com base em medições sonoras. Identificamos a melhor faixa de frequência para estimar a ocorrência e a intensidade da precipitação, treinamos modelos de classificação e regressão com dados sonoros e pluviométricos coletados durante 9 meses em áreas de floresta tropical secundária e virgem na Amazônia central. Ao treinar um classificador/modelo de regressão Random Forest com base em valores do espectro de potência, foi possível identificar e estimar satisfatoriamente as taxas de precipitação horária em dois ambientes de vegetação distintos e 30 km distantes do local de treinamento. O método proposto é uma abordagem promissora para o monitoramento climático futuro em áreas tropicais remotas.

**Nome do orientador:** Tarcísio Ferreira Maciel

## **RAFAEL PEREIRA EUFRÁZIO**

**Título do trabalho:** Redução de dimensionalidade utilizando transporte ótimo por meio da distância de Gromov-Wasserstein

### **Resumo do trabalho:**

Propomos um novo método de redução de dimensionalidade baseado na teoria do transporte ótimo, utilizando a distância de Gromov-Wasserstein (GW). A motivação para este trabalho é a análise de relações entre objetos em alta dimensionalidade, que frequentemente exige técnicas que gerem representações mais manejáveis. Entre os métodos de redução de dimensionalidade, destaca-se o Escalonamento Multidimensional (MDS), uma abordagem que preserva distâncias entre pares de pontos ao projetá-los em um espaço de menor dimensão. O novo método, denominado Gromov-Wasserstein Multidimensional Scaling (GW-MDS), propõe uma visão probabilística para o MDS, empregando a distância GW como critério de otimização. Essa abordagem visa superar limitações do MDS tradicional, que não considera relações locais entre pontos. No GW-MDS, as similaridades entre os dados de alta dimensionalidade são preservadas, utilizando o gradiente descendente para encontrar uma configuração ótima em baixa dimensionalidade. A metodologia é dividida em duas etapas principais: (1) inicialização dos pontos na representação de baixa dimensionalidade e (2) otimização alternada entre o cálculo do plano de transporte e a atualização das coordenadas projetadas. Nos experimentos, o GW-MDS é comparado a métodos como PCA e MDS tradicional. Os resultados mostram que o GW-MDS supera essas abordagens em termos de preservação das distâncias intrínsecas e robustez ao lidar com dados complexos. Testes realizados em dados sintéticos e realistas, como MNIST e Faces, demonstram que o GW-MDS mantém melhor a topologia dos dados originais, sugerindo seu potencial para tarefas avançadas em aprendizado de máquina e análise de dados.

**Nome do orientador:** Charles Casimiro Cavalcante

## **LUCAS DE PAULA DAMASCENO**

**Título do trabalho:** Modelos estatísticos multimodais para detecção de fake news

**Resumo do trabalho:**

A pesquisa aborda o desenvolvimento de métodos avançados para a análise de dados multivariados e aprendizado multimodal, com foco na detecção de desinformação (fake news) durante eventos de alto impacto, como desastres naturais e crises políticas. A pesquisa é fundamentada na Independent Vector Analysis (IVA), uma técnica avançada de modelagem estatística que expande as capacidades do Independent Component Analysis (ICA). Enquanto o ICA é amplamente utilizado para separar sinais independentes em um único conjunto de dados, o IVA generaliza essa abordagem, permitindo a análise conjunta de múltiplos conjuntos de dados simultaneamente. Essa técnica é especialmente poderosa em cenários onde há necessidade de explorar interações e associações complexas entre diferentes dados de múltiplas fontes. Inicialmente, foi proposta uma técnica de estimação de densidade multivariada baseada no princípio da máxima entropia. Essa abordagem foi aplicada à fusão de dados multimodais para superar os desafios associados à desinformação em redes sociais, combinando representações pré-treinadas de aprendizado de máquinas com métodos de separação cega de fontes para aumentar a precisão e a interpretabilidade dos modelos de detecção de desinformação (fake news).

**Nome do orientador:** Charles Casimiro Cavalcante

## **CARLOS ALEX MARTINS OLIVEIRA**

**Título do trabalho:** Contribuições da Educometira para a Avaliação do Sucesso Acadêmico no Curso de Engenharia Elétrica da Ufc

### **Resumo do trabalho:**

A Avaliação Educacional contribui para o estudo das problemáticas existentes nas instituições de ensino superior brasileiras, tais como a retenção e a evasão dos estudantes de graduação. Esta pesquisa teve como objetivo identificar as causas de insucesso e quais aspectos carecem de mais atenção para melhorar o rendimento dos estudantes do curso de graduação em Engenharia Elétrica do Centro de Tecnologia (CT) da Universidade Federal do Ceará (UFC). Desse modo, foi possível oferecer subsídios para a administração superior da UFC formular estratégias para melhorar os indicadores de desempenho dos estudantes do curso de graduação em Engenharia Elétrica do CT. Como metodologia, este estudo adota a pesquisa de natureza aplicada, com abordagem quantitativa e descritiva. Para tanto, foi empregada a análise descritiva em uma amostra de 38 disciplinas obrigatórias do curso de Engenharia Elétrica da UFC do CT da UFC em uma série temporal de 2015.1 a 2022.2. Como resultado, esta pesquisa identificou as disciplinas que mais contribuem para o insucesso dos discentes do curso de graduação em Engenharia Elétrica do Centro de Tecnologia (CT) da Universidade Federal do Ceará (UFC). Portanto, a pesquisa mostrou que as disciplinas com insucesso dos semestres iniciais favorecem a retenção e a evasão no curso de graduação em Engenharia Elétrica do CT, já que essas disciplinas são pré-requisitos para as disciplinas dos semestres subsequentes.

**Nome do orientador:** João Cesar Moura Mota

## **FELIPE JUCÁ DOS SANTOS**

**Título do trabalho:** Sensoriamento de Vibração de Abelhas Sem Ferrão: Um Estudo Exploratório

### **Resumo do trabalho:**

O objetivo deste trabalho é identificar anomalias nos padrões acústicos de comportamento dentro do ninho de colônias da abelhas sem ferrão *Scaptotrigona aff. depilis*, conhecida popularmente como abelha Canudo, submetidas a uma invasão por outra espécie de abelha. Para a coleta dos dados, foi desenvolvido um hardware que utiliza um sensor piezoelétrico controlado por um microcontrolador Arduino. O sensor foi posicionado internamente na caixa racional, na parede oposta ao orifício de entrada das abelhas. A coleta de dados ocorreu no período da manhã, no Meliponário da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), Ceará, com duração de uma hora e uma taxa de aproximadamente 100 leituras por segundo. A espécie invasora utilizada foi a abelha marmelada (*Frieseomelitta varia*). Observamos variações na amplitude e na frequência do sinal durante a invasão, devido ao deslocamento de um grande número de operárias da colônia para a entrada da caixa racional, ou seja, para o lado oposto onde o sensor estava fixado. Os achados deste trabalho podem ser úteis aos meliponicultores, permitindo-lhes reconhecer precocemente os padrões de perturbação de uma colônia sob invasão e realizar intervenções imediatas.

**Nome do orientador:** Danielo G. Gomes

## **FELIPE PINTO MARINHO**

**Título do trabalho:** Novas propostas para aceleração do treinamento de Máquinas de Vetores de Suporte por Mínimos Quadrados

### **Resumo do trabalho:**

Modelos de aprendizado de máquina podem ser considerados o cerne por trás do grande avanço da Inteligência Artificial no cotidiano da sociedade atual, indo de aplicações em áreas tão diversas como na predição de manutenções preventivas em uma máquina até a análise de sentimentos em bases não relacionais, como textos, imagens e vídeos. Dentro deste escopo, destaca-se o modelo de Máquina de Vetores de Suporte (SVM), principalmente pela robustez da performance preditiva e pelo elegante formalismo matemático envolvido em sua concepção. Entretanto, o problema de otimização resultante do ajuste do modelo é quadrático e de alto custo computacional, o que pode ser problemático em aplicações de Big Data, por exemplo. Neste sentido, o modelo de Máquinas de Vetores de Suporte por Mínimos Quadrados (LSSVM) considera restrições de igualdade no problema de otimização do SVM, obtendo, com isso, um sistema linear KKT que simplifica de forma considerável o processo de treinamento. Apesar do ganho em simplicidade na formulação matemática, uma desvantagem inerente a tal metodologia é a ausência de esparsidade da solução ótima, ou seja, todas as observações de treino são consideradas vetores de suporte, impactando no tempo de processamento da etapa de predição. Assim, propõe-se quatro novas metodologias para acelerar o procedimento de treinamento de modelos LSSVM's, sendo uma resultante do uso de regularização LASSO no problema primal do modelo e solução via algoritmo Método das Direções Alternadas de Multiplicadores (ADMM) acelerado via Nesterov, outra abordagem envolve a solução via algoritmo de Levenberg-Marquardt com poda inversa iterativa, e duas propostas envolvendo direções de descida para a solução do problema dual do modelo.

**Nome do orientador:** Ajalmar Rêgo da Rocha Neto

## **LUCAS FREITAS CAMPOS**

**Título do trabalho:** Análise de estabilidade de sistemas fracionários lineares invariantes no tempo utilizando a função Lambert-Tsallis

**Resumo do trabalho:**

Sistemas Lineares de Ordem Fracionária Invariantes no Tempo (SLOFIT) são um caso geral de sistemas convencionais. Nesse sistema, utilizam-se derivadas e integrais de ordem fracionária, baseadas nas derivadas de Riemann-Liouville, Caputo, Grünwald-Letnikov e integrais generalizadas. Sistemas fracionários permitem descrever a dinâmica de sistemas complexos de forma mais completa, pois são capazes de modelar sua memória e efeitos de longo alcance. A análise de estabilidade de SLOFIT é importante no projeto de sistemas de controle, modelagem e compreensão da dinâmica. Pode-se adotar o uso no domínio do tempo ou da frequência, por meio da transformada de Laplace. No domínio da frequência, é possível obter a análise por meio dos polos da função de transferência do sistema (e zeros da função) e verificar os critérios de estabilidade, baseados na localização das raízes em relação ao plano complexo. Em sistemas fracionários, as equações originadas são de natureza complexa em termos de resolução. A fim de obter soluções analíticas mais práticas, este trabalho faz uso da função Lambert-Tsallis. A função  $W_q$  de Lambert-Tsallis é uma generalização da função  $W$  de Lambert. Ela surge da teoria desenvolvida pelo físico Tsallis em mecânica estatística não extensiva. A função  $W_q$  possui aplicações em engenharia, física e matemática. Este projeto tem por objetivo estudar e analisar a aplicabilidade dessa função para determinar polos de funções de transferência de natureza fracionária.

**Nome do orientador:** Kléber Zuza Nóbrega

**ANTÔNIO FRANCISCO AGUIAR**

**Título do trabalho:** Uma Proposta de QPU Fotônica para Qubits de Estados Coerentes

**Resumo do trabalho:**

Este trabalho apresenta uma proposta de QPU fotônica versátil para qubits de estados coerentes usando dispositivos baseados em óptica linear capaz de implementar, probabilisticamente, as funções lógicas (AND, OR, C-NOT, C2-NOT e C-SWAP) com uma eficiência de até  $1/4$ .

**Nome do orientador:** João Batista Rosa Silva

## **DAVID NASCIMENTO COELHO**

**Título do trabalho:** Classificação de dados de streaming por meio de modelos de kernel baseados em protótipos

**Resumo do trabalho:**

O processamento de grandes volumes de dados de streaming por meio de algoritmos de aprendizado de máquina apresenta vários desafios, como pouco tempo para treinar os modelos, restrições de memória de hardware e deriva de conceito. Neste trabalho, mostra-se que os classificadores kernel baseados em protótipos projetados por procedimentos de esparsificação, como o método de dependência linear aproximada (ALD), oferecem uma compensação adequada entre a precisão e a complexidade do tamanho dos classificadores de vizinhos mais próximos kernelizados. A abordagem proposta seleciona automaticamente amostras relevantes do streaming de dados de treinamento para formar um dicionário esparsificado de protótipos, que são então usados em métricas de distância kernelizadas para classificar as amostras que chegam em tempo real. Além disso, o método proposto é totalmente adaptável, no sentido de que atualiza e remove protótipos do dicionário, permitindo que ele aprenda continuamente em ambientes não estacionários. Os resultados obtidos em um conjunto abrangente de simulações de computador envolvendo conjuntos de dados de streaming artificiais e reais indicam que o algoritmo proposto pode criar modelos com baixa complexidade e taxas de erro de classificação competitivas em comparação com o estado da arte.

**Nome do orientador:** Guilherme de Alencar Barreto

## **ARTUR RODRIGUES ROCHA NETO**

**Título do trabalho:** Auxílio ao diagnóstico do autismo a partir de características de parcelas do cérebro humano representadas como nuvens de pontos

**Resumo do trabalho:**

O autismo é uma condição de saúde caracterizada por déficit na comunicação social e comportamento. Devido à existência de múltiplos subtipos, a versão atual do Manual Diagnóstico e Estatístico de Transtornos Mentais (DSM-5) unificou algumas condições que possuíam designação própria nas versões anteriores, como o Transtorno Autista e a Síndrome de Asperger, em uma única categoria chamada Transtorno do Espectro Autista (TEA). Devido a multiplicidade de condições, o diagnóstico do TEA é principalmente baseado em avaliações neuropsicológicas e escalas de classificação clínica, que medem alterações sociais e comportamentais do indivíduo. Contudo, a heterogeneidade do funcionamento social e cognitivo presentes no TEA tem sido associada a alterações neuroanatômicas e, neste caso, análises automáticas podem quantificar estas alterações. Embora muitos trabalhos venham sendo apresentados nesta direção, por não serem ainda conclusivos e aceitos para um diagnóstico definitivo, há espaço para novas investigações. Assim, apoiados em pesquisas recentes, investigam-se neste trabalho as características de representações em 3D (nuvens de pontos) dos diferentes segmentos do cérebro humano. As características de diferentes regiões do cérebro (denominadas parcelas) são obtidas após o processamento de imagens de ressonância magnética estrutural (RM) com a orientação de mapas anatômicos. Utilizando-se base de RM com mais de 1200 exames rotulados para pessoas autistas e não-autistas, múltiplas características das parcelas estão sendo avaliadas por meio de diferentes algoritmos de aprendizado de máquina com o propósito de auxiliar no diagnóstico do autismo a partir de exames de imagem. Embora ainda não haja um resultado conclusivo, a investigação tem se mostrado promissora e têm-se expectativa contribuições efetivas neste domínio.

**Nome do orientador:** José Marques Soares

## **RAPHAEL GOMES PINHEIRO**

**Título do trabalho:** Entropia da curvatura multiescala e agregação de descritores no reconhecimento de folhas de plantas

### **Resumo do trabalho:**

A classificação automática de folhas de plantas é uma tarefa desafiadora e de grande interesse para botânicos, além de ser crucial para a proteção ambiental e ecológica. Este estudo depende de atributos morfológicos da folha, incluindo forma e textura. Recentemente, tem-se observado a fusão de atributos para potencializar o reconhecimento de plantas através da imagem de suas folhas. Este trabalho apresenta um descritor de forma para o reconhecimento de folhas de plantas baseado na entropia multiescala da curvatura. A metodologia utiliza a entropia diferencial das funções de distribuição de probabilidade das curvaturas para obter uma representação multiescala do contorno da forma. Além disso, o descritor combina a entropia multiescala da curvatura com a energia de dobramento e características de textura, aprimorando a extração de assinaturas de forma e detalhes sutis de textura em imagens de folhas. O descritor de textura integra estatísticas do Local Binary Pattern (LBP) e da Matriz de Coocorrência em Níveis de Cinza (GLCM). Comparações foram realizadas entre o descritor agregado proposto e características extraídas de redes neurais convolucionais (CNNs), utilizando Random Forest em três bases públicas: Flavia, Swedish e PlantScan. Os resultados das métricas F1-score e Acurácia, superiores a 97,9%, validam a estratégia de agregação, demonstrando

**Nome do orientador:** Fátima Nelsizeuma Sombra de Medeiros

**MICHEL GONZAGA**

**Título do trabalho:** On the applications of the Cramér-Rao lower bound for target localization in ISAC networks

**Resumo do trabalho:**

Interest in joint communication and sensing (JCAS), also known as integrated communication and sensing (ISAC), has significantly increased due to promising applications envisioned for 6G, which allow for both communication and radar sensing to be performed at the same network. Two important sensing tasks are target detection and target localization. In the former, as the name suggests, we are interested in determining whether there is one or more targets within a region of interest. In the latter, we are interested in localizing the targets within a given region of interest, which can be done, for example, by exploiting the angle-of-arrival and angle-of-departure associated with each of the targets, as well as the target velocity obtained from the Doppler frequency. In the context of target localization, the Cramér-Rao lower bound (CRLB) has proven to be a useful tool to reflect the overall performance of the system. It can also be helpful for resource allocation, such as transmit power and time resources. In this seminar, I provide a short overview of the applications of CRLB in ISAC and perspectives for the next steps of my research.

**Nome do orientador:** Walter Freitas

## **EZEQUIAS MARCIO SILVA DE SANTANA JUNIOR**

**Título do trabalho:** Otimização de tecnologias emergentes em redes 6G

**Resumo do trabalho:**

A temática de pesquisa aqui apresentada consiste no estudo de estratégias de otimização aplicadas a problemas de comunicações sem-fio, visando o suporte para a sexta geração (sixth generation, 6G) de sistemas de comunicação. Tais problemas originam do emprego de novas tecnologias como a arquitetura cell-free (CF) ou MIMO distribuído para implementação de sistemas integrados de comunicação e sensoriamento (ISAC). O projeto de pesquisa visa estabelecer uma análise comparativa de desempenho das tecnologias abordadas a fim de identificar o quão bem as mesmas podem suprir os requisitos dos sistemas de próxima geração. Neste contexto, foram desenvolvidos os seguintes estudos: 1) Comunicação por uplink de sistemas CF com suporte a sistemas ISAC, no qual o desempenho do sistema foi avaliado em termos da relação sinal-interferência-mais-ruído (SINR) para comunicação, mostrando como os ecos do sensoriamento afetam o desempenho do sistema; 2) Extração e análise de parâmetros de propagação de larga escala obtidos por meio de medições de canal de rádio, onde a investigação da correlação cruzada entre os parâmetros obtidos e a comparação dos mesmos com os valores existentes na literatura foi abordada. Este último estudo foi realizado no contexto de estágio de doutorado sanduíche, realizado na Ericsson Research AB, em Luleå, Norbotten, Suécia.

**Nome do orientador:** Yuri Carvalho Barbosa Silva

## **FILIFE PEREIRA DE FARIAS**

**Título do trabalho:** Probabilistic modelling and control of dynamical systems

**Resumo do trabalho:**

Dynamical systems offer a robust mathematical framework to analyze, predict, and understand the behavior of systems governed by differential equations or iterative mappings. These systems span diverse fields, including classical mechanics, electrical circuits, fluid dynamics, climate science, finance, ecology, neuroscience, and epidemiology. However, the governing equations of such phenomena often remain unchanged or even unidentified. In these cases, probability theory provides a crucial tool for addressing uncertainties in modeling dynamical systems. This work investigates dynamical systems subject to random perturbations, a critical source of uncertainty that captures the influence of external factors on the system's evolution. Specifically, we focus on Wiener process perturbations, characterized by Gaussian-distributed randomness. This approach offers several advantages, including the representation of the probability density function of the system's evolution as a Gaussian process. Such properties facilitate model identification and calibration using real-world data and enable analytical solutions for optimal control strategies. For systems governed by affine dynamics, the control law can be explicitly derived, providing a precise functional form for system inputs. Ongoing research extends this framework by incorporating parameter perturbations, adding further flexibility to the analysis and broadening its applicability to complex real-world scenarios. These developments pave the way for enhanced modeling, prediction, and control of dynamical systems under uncertainty.

**Nome do orientador:** Michela Mulas

## **BRÍGIDA FARIAS CARDOSO OLIVEIRA**

**Título do trabalho:** Uso de wavelets e aprendizado de máquina para a detecção de disfonias na voz

### **Resumo do trabalho:**

A identificação de distúrbios vocais apresenta desafios significativos. Alterações na qualidade, altura ou volume da voz podem indicar diversas patologias, contudo o diagnóstico preciso é complexo. A avaliação vocal, frequentemente subjetiva, depende da experiência do profissional e é influenciada por fatores como ruídos ambientais e a semelhança de sintomas entre diferentes doenças. A classificação automática de vozes, utilizando ferramentas computacionais, pode auxiliar na superação desses desafios, fornecendo um diagnóstico mais objetivo e eficiente. Este trabalho investiga o uso de escalogramas gerados pelas wavelets Morlet, Bump e Chapéu Mexicano Complexo e o uso de AutoML (Aprendizado de Máquina Automatizado) na classificação de sinais de voz normais e sinais de voz com disfonia, considerando os gêneros masculino e feminino e uma combinação de ambos. A metodologia proposta para caracterização e classificação de vozes normais e anormais considera a criação de escalogramas dos sinais de voz formados por vogais sustentadas para utilizá-los como entradas nas CNNs (VGG16, ResNet50, Xception, InceptionV3, entre outras) para a extração de características a serem utilizadas na classificação utilizando a biblioteca de AutoML Pycaret. Conduzimos experimentos em duas bases de dados públicas de origem portuguesa e alemã, Advanced Voice Function Assessment Database (AVFAD) e Saarbrücken Voice Database (SVD), respectivamente. Os resultados obtidos revelaram que a acurácia depende da complexidade da base utilizada, para a base AVFAD, em que todas as vozes vieram de pessoas maiores de 18 anos, foi possível alcançar valores de acurácia, F1 e área sob a curva acima dos 85%, mas na base SVD, em que há amostras de vozes de crianças e idosos também, a acurácia já cai para ficar em torno de 70 a 80%. Além disso, num modo geral, os resultados obtidos a partir dos escalogramas das wavelet Morlet obtiveram uma acurácia um pouco melhor que os obtidos pelos da Bump e pelos da Chapéu Mexicano Complexo. Dentre os classificadores que a Pycaret rodou para realizar a classificação, o que alcançou os melhores resultados na maioria das vezes foi o Extra Trees Classifier.

**Nome do orientador:** Fátima Nelsizeuma Sombra de Medeiros

## **RAPHAEL VICTOR BARROS CAMPOS**

**Título do trabalho:** Sensor acústico piezoelétrico de temperatura de fibras de cristal de  $\text{LiNbO}_3$  operando em radiofrequências

### **Resumo do trabalho:**

Este estudo se concentra no crescimento e caracterização de fibras piezoelétricas cristalinas de  $\text{LiNbO}_3$  (LNO) puxadas pela técnica Laser Heated Pedestal Growth (LHPG). As propriedades elétricas das fibras foram investigadas usando um analisador de impedância, que produziu valores para frequência de ressonância, frequência antirressonância e ângulo de fase. Posteriormente, cálculos baseados em modos de ressonância de espessura determinaram constantes elásticas e fatores de acoplamento. A precisão do método de ressonância foi validada por meio de simulações numéricas utilizando o software COMSOL, demonstrando uma concordância próxima entre os resultados experimentais e simulados. Além disso, foi realizado o sensoriamento de temperatura, submetendo as fibras a uma ampla faixa de temperatura de 30 °C a 236 °C para avaliar sua sensibilidade a variações de temperatura. Os fatores de acoplamento de  $K=0,37$  para LNO-1 e  $K=0,35$  para LNO-2 demonstraram o desempenho eficiente das fibras cristalinas. Além disso, as simulações numéricas correlacionaram-se fortemente entre os dados simulados e experimentais. A análise de sensibilidade revelou o potencial das fibras LNO para aplicações de sensores de temperatura, exibindo uma sensibilidade de  $-87 \text{ Hz } ^\circ\text{C}^{-1}$ . Essas descobertas ressaltam a promessa das fibras piezoelétricas LNO em tecnologias avançadas de detecção.

**Nome do orientador:** Antonio Sergio Bezerra Sombra

## **JOSÉ EDILSON SILVA FILHO**

**Título do trabalho:** Trustful Communication in Nanosatellite Constellations Using Blockchain and Multiagent Systems

### **Resumo do trabalho:**

A literatura enfatiza os esforços contínuos das comunidades científica e industrial para aumentar a eficiência do gerenciamento de constelações de satélites e nanossatélites. Alguns dos trabalhos mais inovadores exploram a realização de tarefas específicas ou na manutenção das formações orbitais desejadas por meio da colaboração, mesmo sem comunicação direta. O consenso é obtido por meio da troca de informações entre satélites vizinhos e estações na terra, permitindo que eles ajustem e sincronizem suas órbitas. O projeto de tese proposto propõe um protocolo baseado em blockchain para autenticar as comunicações espaciais combinado com técnicas de sistemas multiagentes. Isso se torna particularmente crucial em constelações de satélites, em que a integridade e a autenticação dos dados são fundamentais. A tecnologia blockchain oferece uma abordagem criptografada e descentralizada para registrar transações ou comunicações entre satélites, garantindo a autenticidade e a segurança dos dados, por sua vez interpretar constelações de satélites como sistemas multiagentes pode aumentar a eficiência e eficácia na automação de rotinas em missões espaciais, monitoramento climático e telecomunicações.

**Nome do orientador:** Jarbas Aryel Nunes da Silveira

**ELENE FIRMEZA OHATA**

**Título do trabalho:** Estimation of Bone Mineral Density using Machine Learning and SHapley Additive exPlanations

**Resumo do trabalho:**

Osteoporosis is a worldwide health issue marked by decreased bone density and degradation of bone tissue, which raises the risk of fractures. Early diagnosis of low bone mineral density (BMD) is crucial in reducing risks by providing appropriate treatment or prevention methods. However, the most common method of measuring BMD is the Dual-energy x-ray absorptiometry, which might not be affordable or accessible to many patients. This study proposes using machine learning methods to predict BMD through anthropometric measurements, anamnesis, age, and sex. A dataset containing 905 patients with their corresponding features and BMD values was also introduced. Different regression algorithms were evaluated, and the model predictions were interpreted using SHapley Additive exPlanations. The approach demonstrated good performance, with an average mean absolute error and mean absolute percentage error of 0.0771 g/cm<sup>2</sup> and 6.34%, respectively. As a result, this proposed method can potentially become a tool for healthcare professionals to predict BMD in a cost-effective and accessible manner.

**Nome do orientador:** Pedro Pedrosa Rebouças Filho

**BIANCA SOUSA SOARES**

**Título do trabalho:** Redes Neurais embarcadas para a classificação da Spodoptera frugiperda

**Resumo do trabalho:**

A Spodoptera frugiperda é uma das principais pragas da agricultura mundial. Seu monitoramento comumente requer inspeção visual e contagem manual de indivíduos. Avanços em visão computacional, aprendizado de máquina e internet das coisas oferecem meios para alcançar um monitoramento rápido e preciso. Neste contexto, investigamos o uso de redes neurais convolucionais pré-treinadas para extrair características relevantes de imagens desses insetos capturadas em armadilhas. Os modelos de extração, MobileNet e DenseNet201, foram aliados à MLP e alcançaram acurácia de classificação de 0,89 e 0,94, respectivamente, embarcados em um dispositivo Raspberry Pi. Os resultados mostram que, embora a DenseNet201 ofereça maior precisão, a MobileNet é mais eficiente em processamento e possui menor tempo de execução. Portanto, a MobileNet desponta como alternativa viável para identificação da Spodoptera frugiperda em campo com dispositivos com restrição computacional. Dessa forma, este trabalho contribui para o monitoramento automático e preciso de pragas em plantações.

**Nome do orientador:** Atslands Rego da Rocha



# Uma Proposta de QPU Fotônica para Qubits de Estados Coerentes

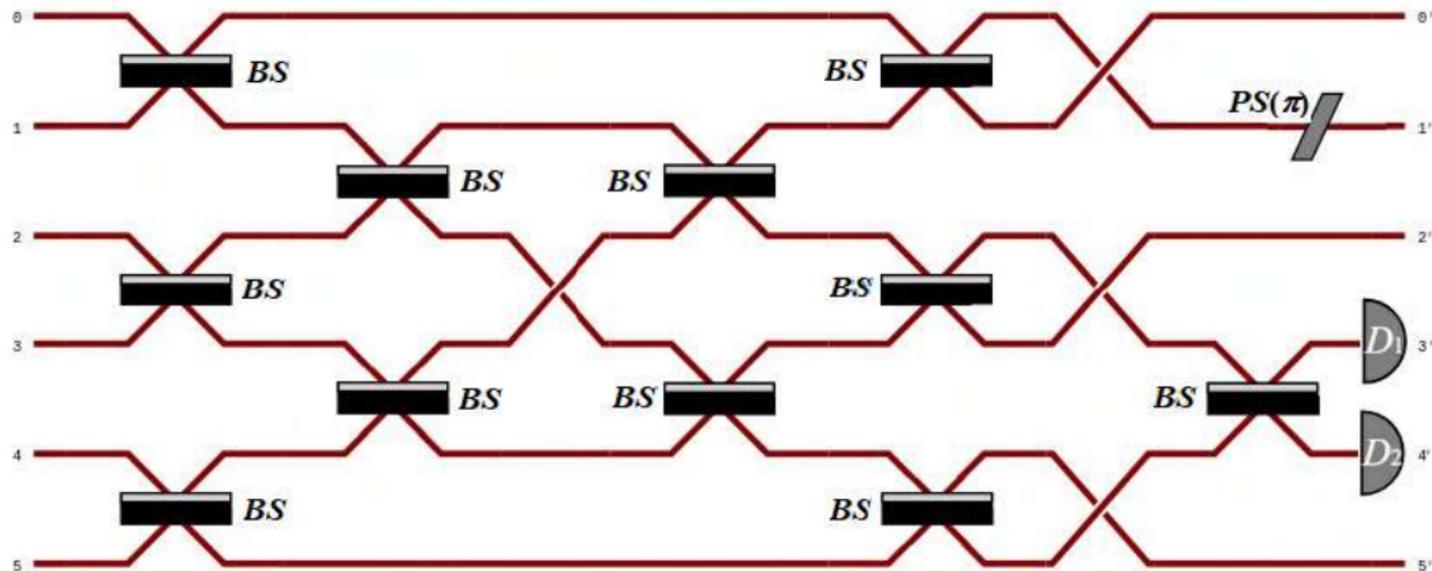
Antonio F. Aguiar

João Batista R. Silva

Dispositivos e Sistemas Quânticos / Eletromagnetismo Aplicado



- Fotônica integrada e computação quântica com qubits fotônicos proporcionaram avanços significativos das plataformas dedicadas ao processamento quântico de informação (*QIP*).
- Em fotônica integrada os fótons e suas características fundamentais, como baixa suscetibilidade a decoerência, são usados para processar informação quântica com baixo ruído.
- O ruído e a decoerência não são os principais obstáculos no desenvolvimento de computação quântica fotônica.



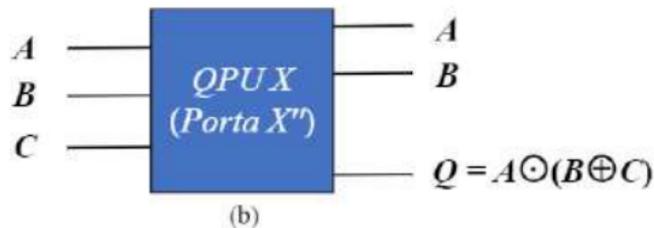
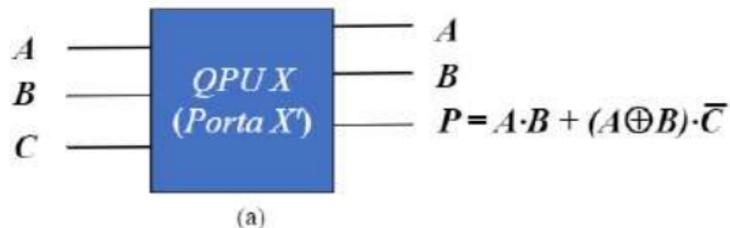
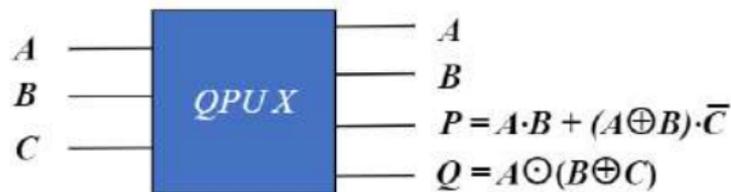
- $|A\rangle_0 = N_A(a_0|-\alpha\rangle + a_1|\alpha\rangle)$

- $|C\rangle_4 = N_C(c_0|-\alpha\rangle + c_1|\alpha\rangle)$

$$|B\rangle_1 = N_B(b_0|-\alpha\rangle + b_1|\alpha\rangle)$$

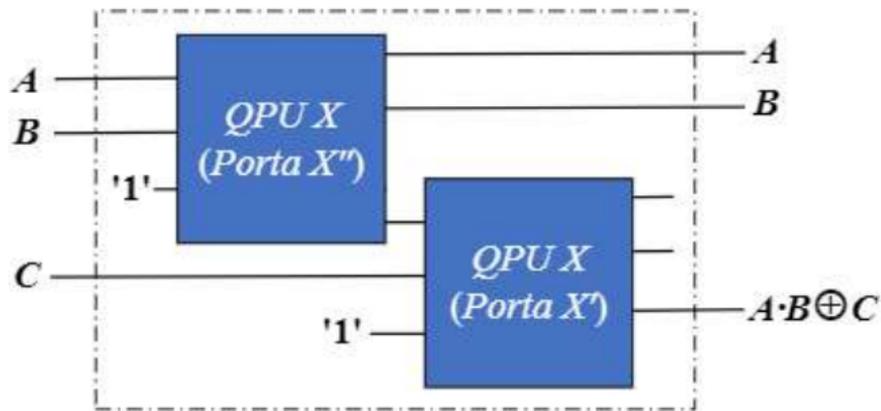
$$|\varphi\rangle_{235} = N(|-\alpha\rangle + |\alpha\rangle)$$

A partir da QPU  $X$  obtem-se duas portas 3x3, conforme mostrado a seguir:



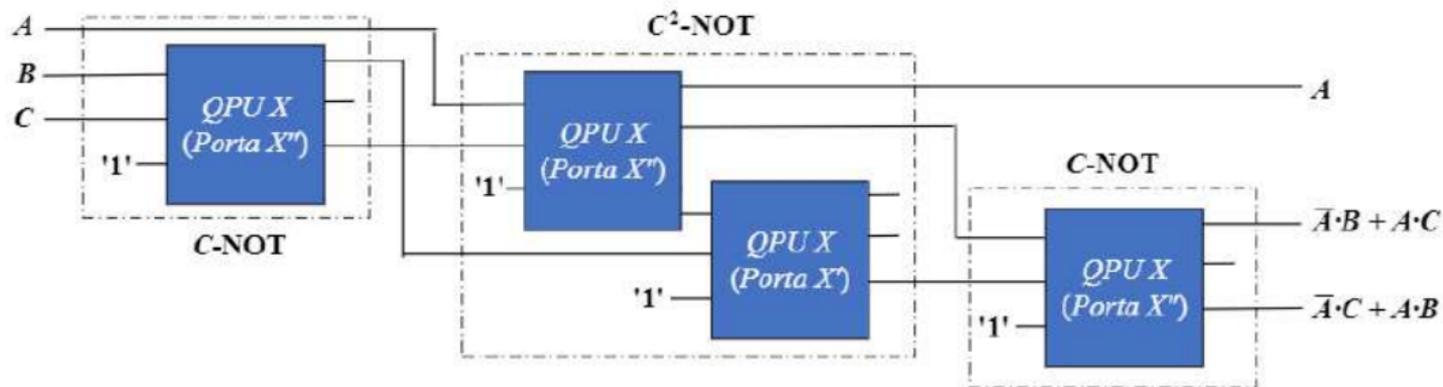
<b>QPU X</b>	<b>P</b>	<b>Q</b>
$C = 0$	$A + B$	$A \odot B$
$C = 1$	$A \cdot B$	$A \oplus B$

Pode-se obter a porta Toffoli ( $C^2$ -NOT) a partir das portas  $X'$  e  $X''$  conforme mostrado logo abaixo.



A porta Toffoli pode ter uma eficiência de até  $1/16$ .

Porta Fredkin (C-SWAP) a partir de uma porta  $C^2$ -NOT e duas C-NOT's.



A porta Fredkin pode ter uma probabilidade de sucesso de até  $1/256$ .



- Foi apresentada uma proposta de *QPU* fotônica (*QPU X*) usando dispositivos baseados em óptica linear factível para qubits de estados coerentes.
- Foi possível obter funções lógicas importantes, como *AND*, *OR*, *C-NOT*, *C<sup>2</sup>-NOT* e *C-SWAP*, de forma probabilística.
- A porta Toffoli (*C<sup>2</sup>-NOT*) e a porta Fredkin (*C-SWAP*) foram obtidas a partir das portas *X'* e *X''* propostas, demonstrando a versatilidade e potencial do sistema proposto.
- Portanto, a combinação de óptica linear e estados coerentes mostra-se promissora para superar desafios e alcançar resultados confiáveis no processamento de informação quântica.

Grupo de Óptica e  
Informação Quântica



UNIVERSIDADE  
FEDERAL DO CEARÁ





Universidade Federal do Ceará  
Programa de Pós-Graduação em  
Engenharia de Teleinformática



# Detectores de Fótons para Comunicações Quânticas

Jonathan Rodrigues da Silva

Rubens Viana Ramos

Dispositivos e Sistemas Quânticos / Eletromagnetismo Aplicado



## *Comunicações Quânticas e a Necessidade de Detectores de Fótons Únicos*

*O que são sistemas de comunicações quânticas?*

- *Transmissão de informações com segurança baseada em princípios quânticos.*

*Objetivos dos Detectores de Fótons Únicos:*

- *Detectam fótons individuais e produzem pulsos elétricos (nível TTL).*

*Detectores Atuais:*

- *Supercondutores: Inviabilidade prática devido ao alto custo e complexidade de refrigeração.*
- *APDs (fotodiodo de avalanche) : Alta taxa de ruído e menor eficiência.*



## *Limitações dos Detectores Atuais e Proposta do Projeto*

### **Objetivos:**

- 1. Construir e caracterizar um detector eficiente e barato para 1550 nm, baseado em APDs.*
- 2. Explorar o uso do detector como contador de fótons, processando os sinais de avalanche digitalmente.*

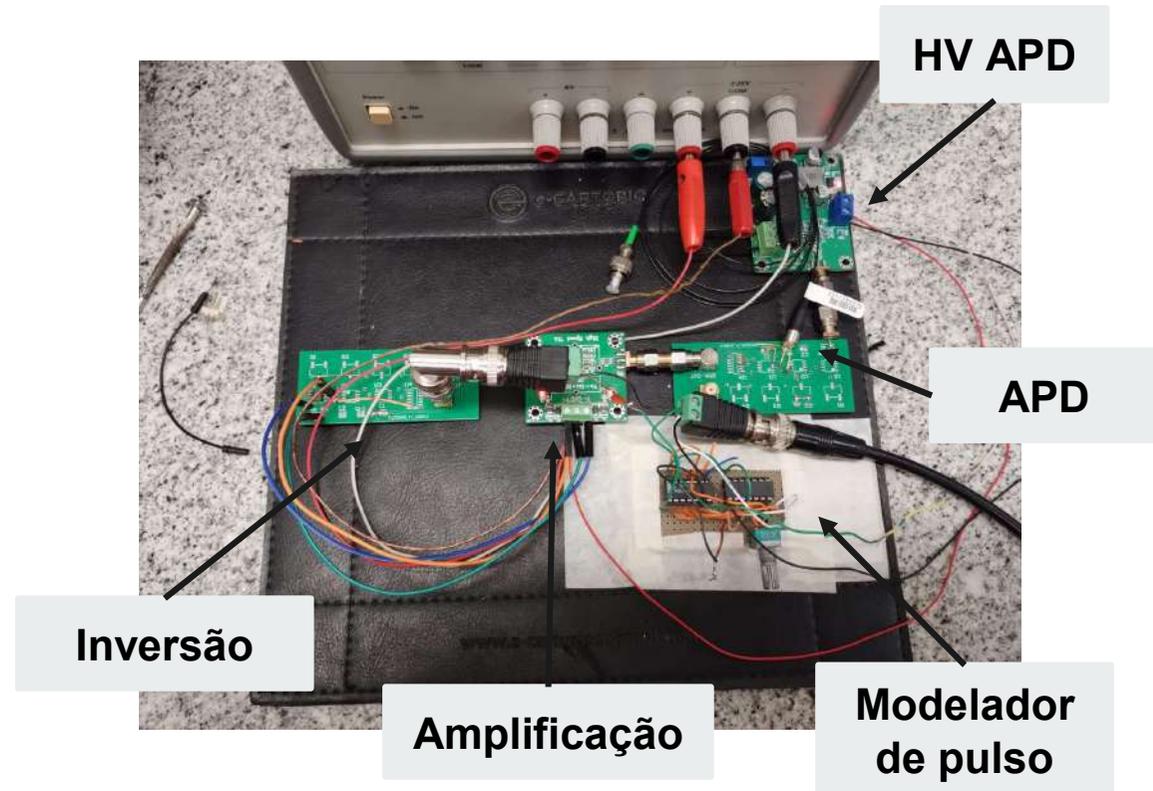
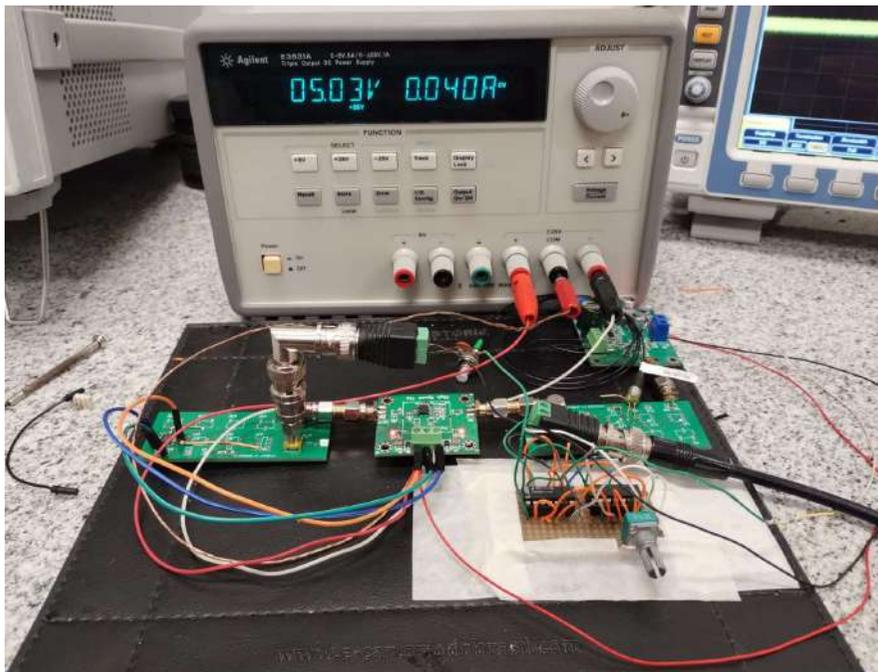
### **Impacto Esperado:**

- Democratização de sistemas de comunicações quânticas com soluções mais acessíveis.*
- Avanço na contagem precisa de fótons para redes ópticas quânticas e outras aplicações.*

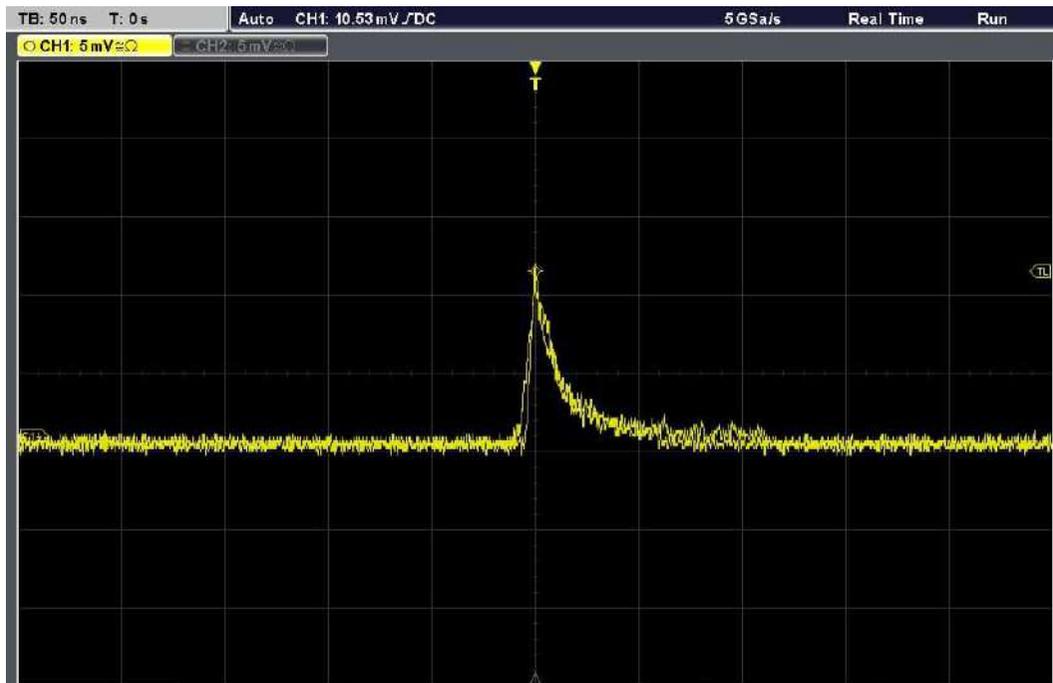
## Concretização dos Objetivos

### Desenvolvimento do Detector de Fótons:

- Escolha e teste de APDs adequados para a janela de 1550 nm.



## Desenvolvimento do Detector de Fótons



APD



Amplificação



## *Desenvolvimento do Detector de Fótons*



**Modelador  
de pulso**



## Concretização dos Objetivos

### *Caracterização do Detector:*

- *Testes de eficiência e ruído.*

### *Processamento Digital do Sinal:*

- *Algoritmos para identificar eventos de avalanche.*

### *Validação em Aplicações Quânticas:*

- *Testar o detector construído em sistemas ópticos de distribuição quântica de chaves*



Universidade Federal do Ceará  
Programa de Pós-Graduação em  
Engenharia de Teleinformática



OBRIGADO



# Estudo de Sistemas Lineares Invariantes no Tempo de Ordem Fracionária usando a Função de Lambert-Tsallis

Lucas Freitas Campos

Dr. Kleber Zuza Nobrega

Eletromagnetismo Aplicado



- **Sistemas Lineares Invariantes no Tempo de Ordem Fracionária (SLITOF)** representam uma generalização de SLITs descritos através de polinômios de ordem inteira;
- **Grande demanda em diversas áreas de conhecimento;**
- **Análise analítica de SLITOFs:**
  - Cálculo de pólos de polinômios fracionários;
  - Discriminação de ESTABILIDADE-INSTABILIDADE;
  - Uso da Função de Lambert-Tsallis no âmbito de sistemas de controle.



- Estudo de SLITOFs ;
  - Agregam características de memória em SLITs;
  - **Adiciona** ao menos **um grau de liberdade a mais** para análise;
- Cálculo de pólos (estabilidade) é feito numericamente **sem agregar qualquer analiticidade entre parâmetros de sistema;**
- Aplicação da **Função de Lambert-Tsallis** no âmbito de sistemas de controle;
  - Descrição analítica das raízes de um trinômio de **ordem genérica;**
  - **Introduz relações entre parâmetros do sistema** ( $K_p, K_i$  e  $K_d$ ) e a estabilidade do mesmo;
- **Quebra de paradigma** nas técnicas utilizadas atualmente.



- A função é Lambert-Tsallis é solução da equação ;

$$x \left( 1 + \frac{x}{r} \right)^r = z, x = W_r(z)$$

- Sistemas de Controle descritos por equações trinômias;

$$a_n s^n + a_m s^m + a_0 = 0$$

$$\forall n, m \in \mathbb{Q}^*, m < n, a_0, a_n, a_m \neq 0$$

- Características do estudo.
  - Descrição analítica dos resultados;
  - Trinômios de qualquer ordem;
  - Determinação analítica de discriminantes;



- [1] **Sousa, I. R.; Nobrega, K. Z.; Barreto, G. A.** An analytical approach to the stability conditions of a new class of fractional-order control systems by the Lambert-Tsallis function. *IEEE Transactions on Automatic Control*, 2024.
- [2] **Guedes, V. F.; Nobrega, K. Z.; Ramos, R. V.** Analytical solution of the space charge limited current using Lambert–Tsallis  $W_q$  function. *IEEE Transactions on Electron Devices*, v. 69, n. 10, p. 5787-5791, 2022.
- [3] **Silva, George Barbosa da.** A função  $W_q$  de Lambert-Tsallis e suas aplicações. 2021. 52 f. Tese (Doutorado em Engenharia de Teleinformática) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2021.
- [4] **Petráš, Ivo.** Fractional-order nonlinear systems: modeling, analysis and simulation. Springer Science & Business Media, 2011.



# Cálculo eficiente da função de onda $\psi_n(x)$ usando a matriz de coeficientes de Hermite em Python

Matheus Gomes Cordeiro

Hilma Helena Macedo de Vasconcelos

Eletromagnetismo Aplicado / Dispositivos e Sistemas Quânticos



- **A Dificuldade de Acesso a Hardware Quântico:** O acesso limitado a *hardware* quântico real aumenta a demanda por ferramentas de simulação eficientes e precisas.
- **A Função de Onda:** A representação da função de onda do Oscilador Harmônico Quântico com polinômios de Hermite enfrenta desafios computacionais, pois é necessário garantir precisão e eficiência para simulações quânticas rápidas e precisas.

$$\psi_n(x) = \mathcal{N}_n H_n(x) e^{-x^2/2} \quad (1)$$

**Fonte:** Do livro [1]



- **Complexidade no Cálculo da Função de Onda:** A função de onda do oscilador harmônico quântico é expressa em termos de polinômios de Hermite. A eficiência computacional é crucial para simulações precisas, especialmente em estados de alta energia.
- **Restrições das Implementações Tradicionais:** A computação de polinômios de Hermite em Python, usando métodos convencionais como a fórmula de Rodrigues, enfrenta desafios em aplicações que exigem alta precisão e eficiência.

$$H_n(x) = (-1)^n e^{x^2} \frac{d^n}{dx^n} e^{-x^2} \quad (2)$$

**Fonte:** Do livro [2]



- Algoritmo Híbrido Utilizando a Biblioteca Numba do Python [3, 4]:

**if**  $i \leq 60$  **then**

$$\psi_i(x) = \{ \mathbf{C}_{60}^s[i] \cdot \mathbf{x}^p \} e^{-x^2/2}$$

**else**

$$\psi_{i+1}(x) = \left( \sqrt{\frac{2}{i+1}} \right) x \psi_i(x) - \left( \sqrt{\frac{i}{i+1}} \right) \psi_{i-1}(x)$$

**end if**

- **Pacote Fast Wave:** Este algoritmo e suas versões estão incluídos em um pacote Python, com módulos Numba e Cython, que pode ser instalado facilmente com:

```
> pip install fast-wave
```

- **QuTip Pull Request:** Parte do código desse pacote foi integrada, ao QuTiP, uma Toolbox de Física Quântica em Python de grande visibilidade.



Figura 1: Quantum Toolbox in Python [5]



-  Schleich, W. P. (2001). *Quantum optics in phase space*. Wiley-VCH. ISBN: 352729435X (9783527294350)
-  Olver, F. W. J., & Maximon, L. C. (2010). *NIST Handbook of Mathematical Functions*. Cambridge University Press. ISBN: 0521192250 (9780521192255)
-  Cordeiro, M., Bezerra, I. P., & Vasconcelos, H. H. M. (2024). *Efficient computation of the wave function  $\psi_n(x)$  using Hermite coefficient matrix in Python*. In 7<sup>o</sup> Workshop Escola de Computação e Informação Quântica (7<sup>a</sup> WECIQ) (pp. 56-60). CEFET/RJ.
-  Pérez-Jordá, J. M. (2017). *On the recursive solution of the quantum harmonic oscillator*. European Journal of Physics, 39(1), 015402. <https://doi.org/10.1088/1361-6404/aa9584>
-  Unitary Fund. (2024, novembro 29). *2022 QuTiP Student Presentations (GSoC Projects)*[Vídeo]. Youtube. <https://www.youtube.com/watch?v=cCzohbNxweM>



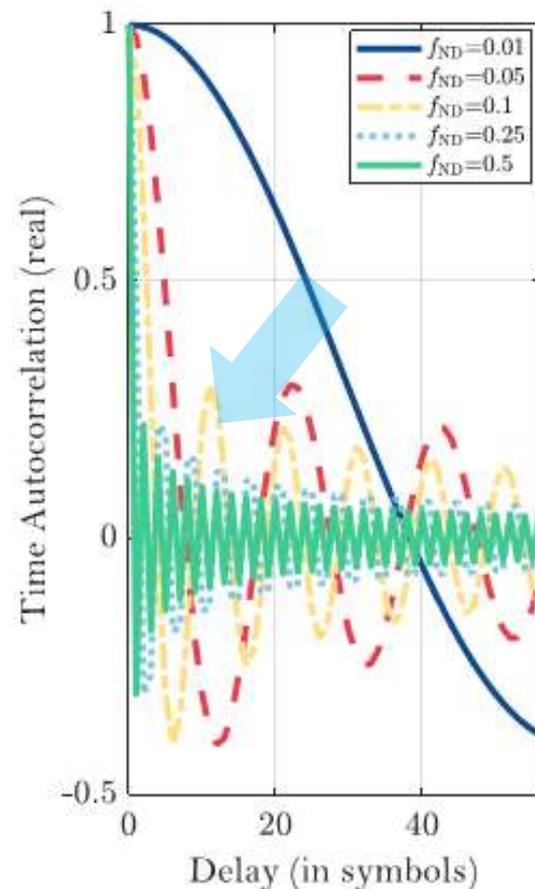
# Mitigando o Impacto do Envelhecimento do Canal em Sistemas MIMO Distribuídos com Filtragem de Kalman

A. Regilane L. P.

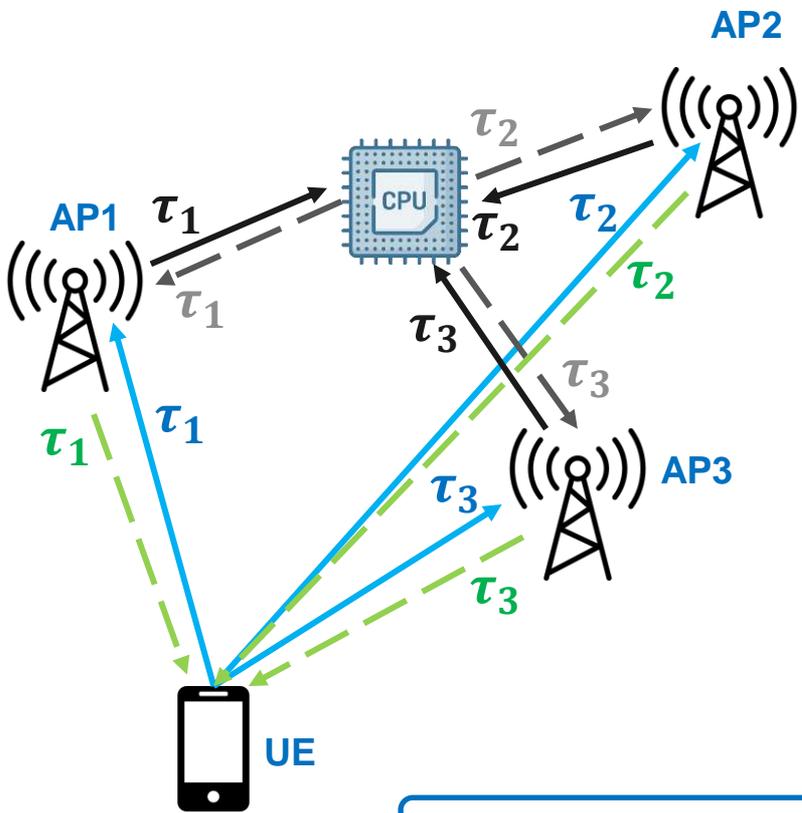
Walter C. Freitas Jr

SISTEMAS E REDES DE COMUNICAÇÕES/ SINAIS E SISTEMAS

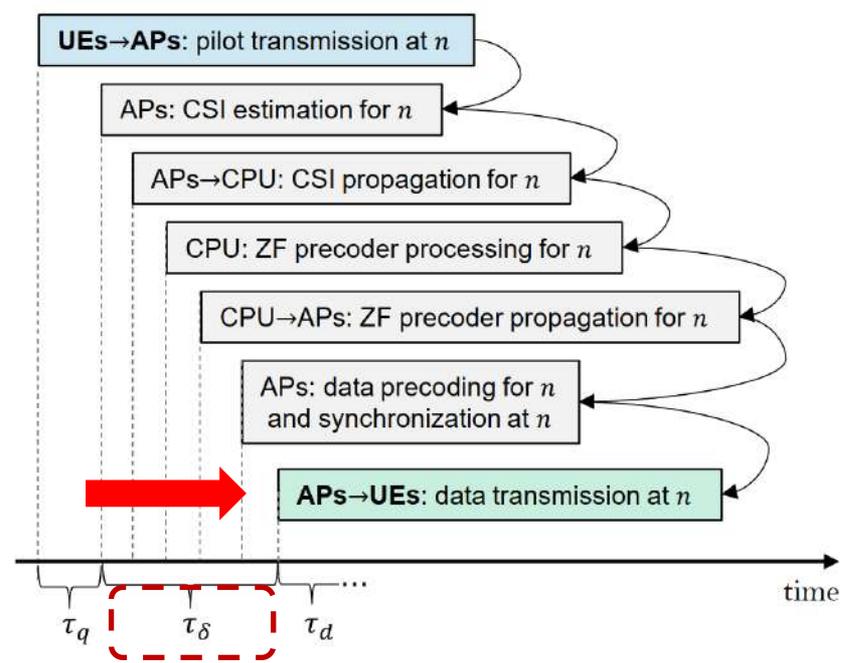
- O **envelhecimento do canal** pode degradar o desempenho das redes 5G/6G;
- Em sistemas de **mMIMO** distribuídas de **ondas milimétricas**;
- Três fatores principais:
  1. **atrasos** de propagação e processamento por pré-codificação centralizada,
  2. **alta mobilidade** em comunicação assistida para veículos terrestres e aéreos,
  3. **alto desvio Doppler**.
- Nesta pesquisa é realizado um estudo de análise e **mitigação do envelhecimento do canal**
- métodos matemáticos: **GBSM**, **AR** de ordem  $P$  e filtro de **Kalman** não linear .



# Descrição do problema: Envelhecimento do Canal

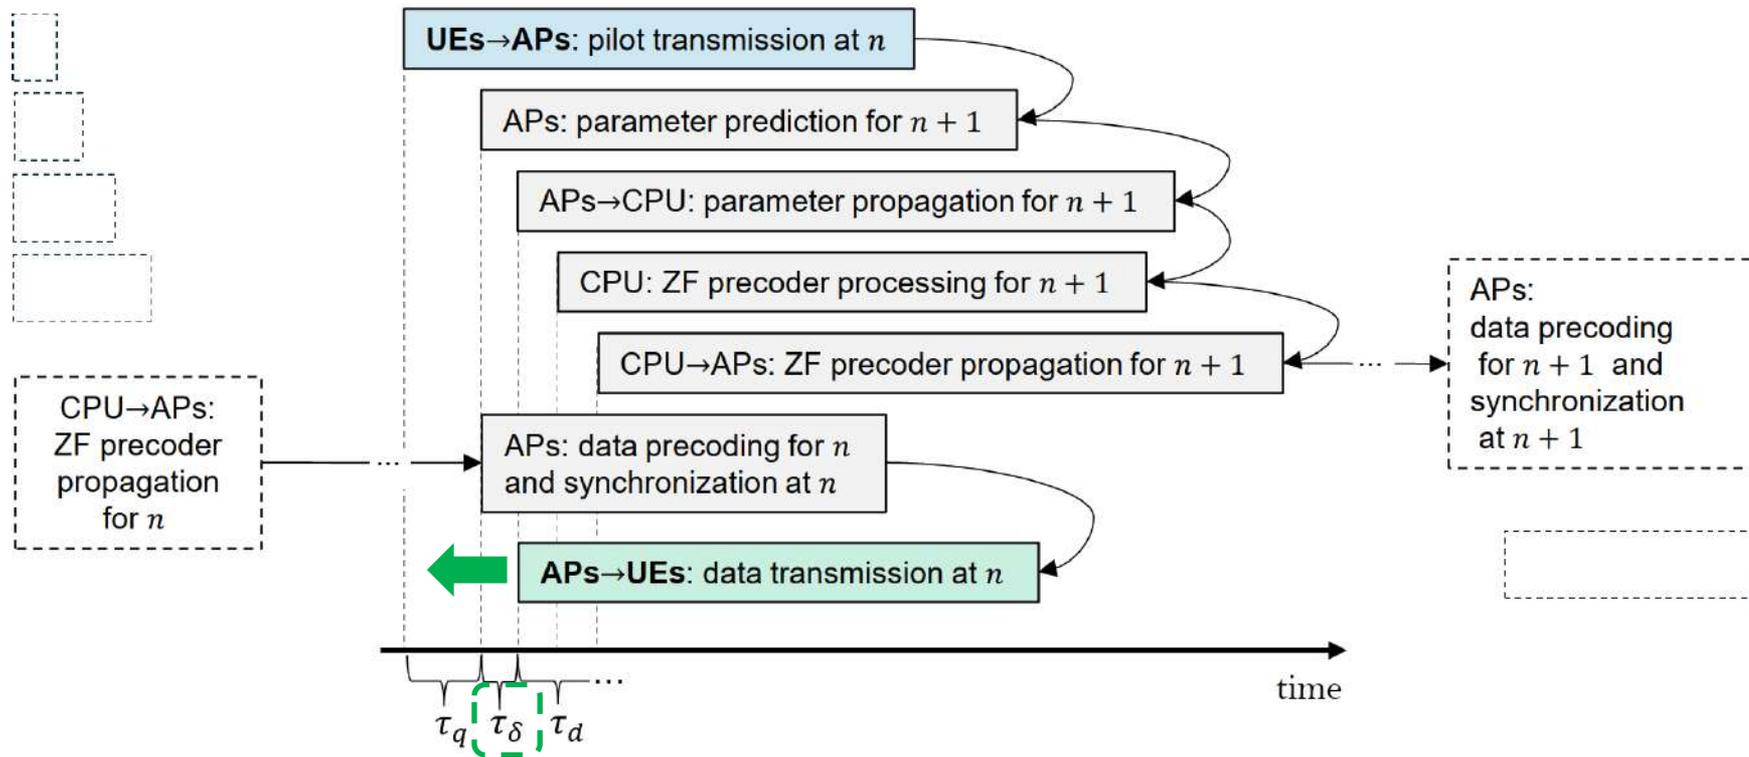


## Convencional



$$\tau_t = \tau_1 + \tau_1 + \tau_1 + \tau_1 + \tau_3 + \tau_3 + \tau_2 + \tau_3 + \tau_2 + \tau_2 + \tau_3 + \tau_2$$

## Proposto

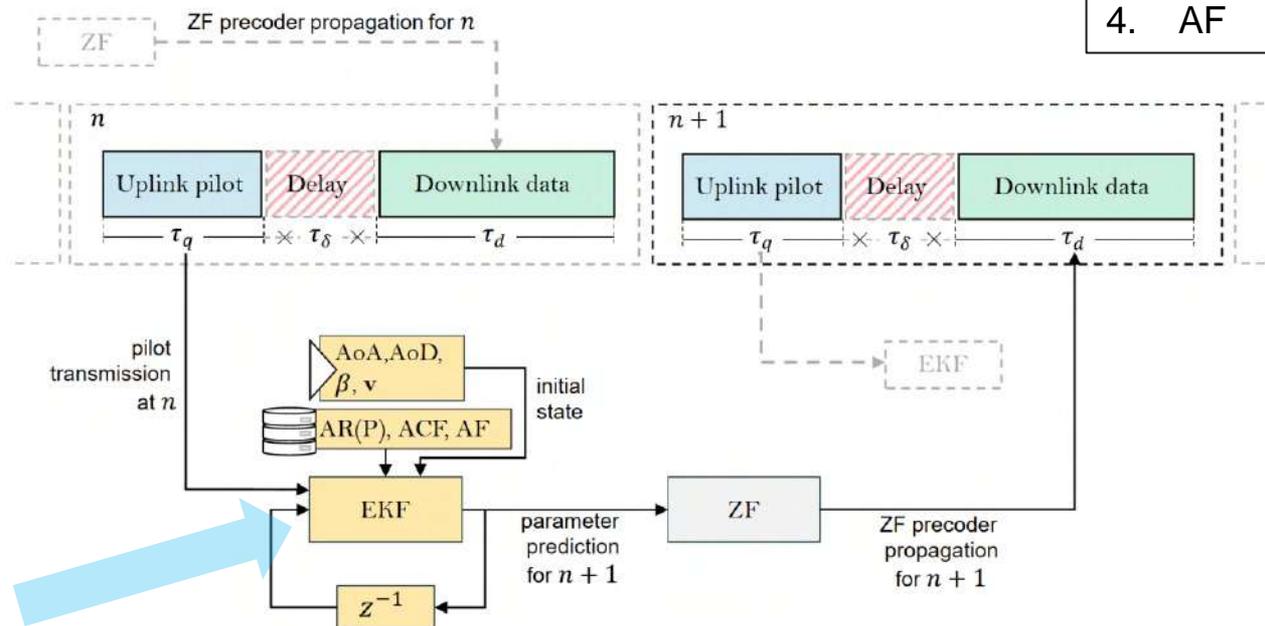


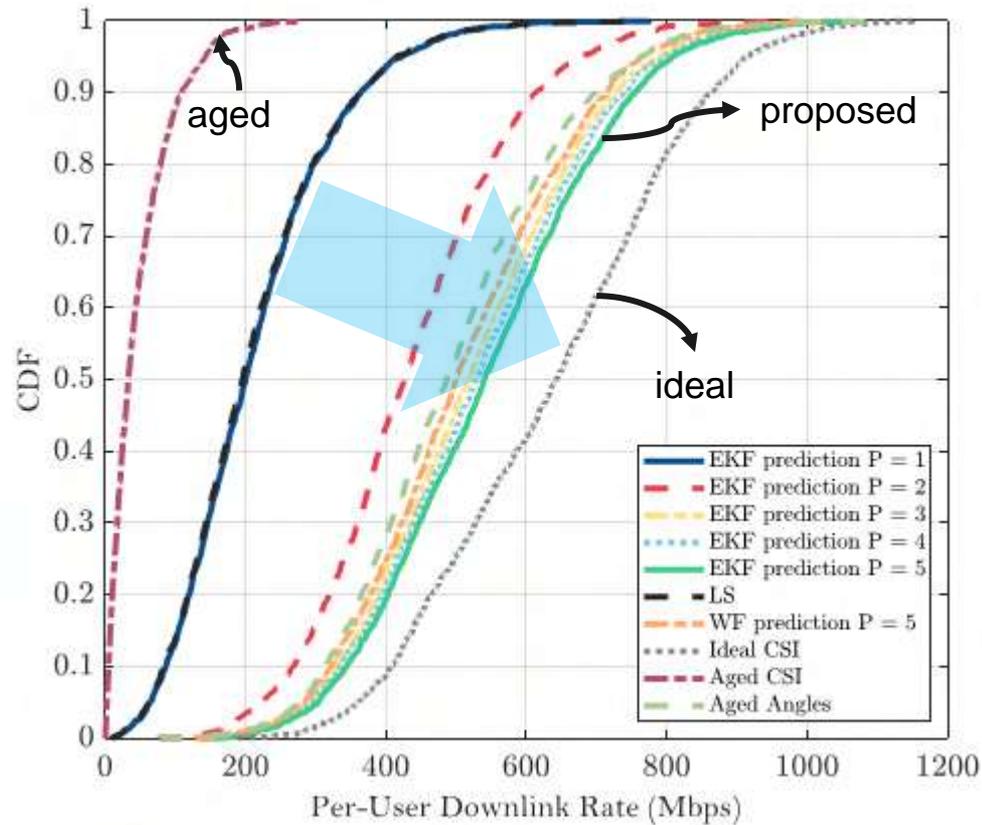
# Descrição do problema: Proposta



## Input

1. AoA, AoD, L
2. Velocity,
3. ACF
4. AF







- Analisar a influência da **LoS**;
- Analisar a influência da **diretividade do canal**;
- Cenário com **UAVs**;



# Auxílio ao diagnóstico do autismo a partir de características de parcelas do cérebro humano representadas como nuvens de pontos

Artur Rodrigues Rocha Neto

José Marques Soares

Sinais e Sistemas / Visão Computacional 3D



O DSM-5 define TEA a partir da unificação de outras condições que anteriormente possuíam designação própria (i.e Transtorno Autista e a Síndrome de Asperger)

## Transtorno do Espectro Autista

Comportamento restrito e de natureza repetitiva

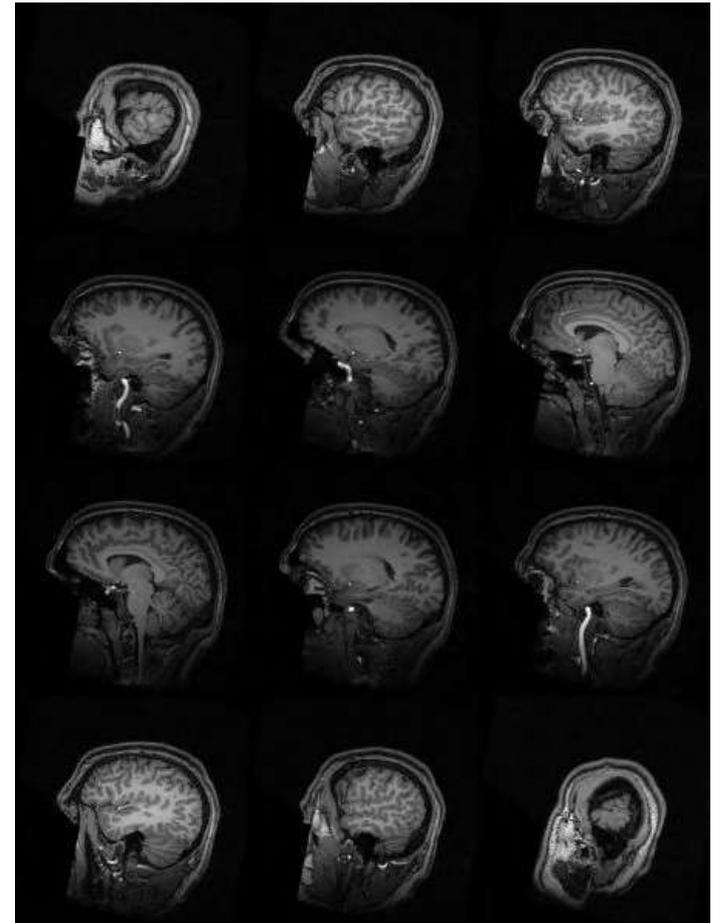
Alterações qualitativas no comportamento e nas interações sociais

Etiologia multifatorial



- Baseado em avaliações neuropsicológicas e escalas de classificação clínica
- Objetivo das testagens: medir alterações sociais e comportamentais do indivíduo
- Processo longo, custoso e, muitas vezes, emocionalmente impactante à pessoa

- Heterogeneidade do funcionamento social e cognitivo presentes no TEA tem sido associada a alterações neuroanatômicas
- Estudos recentes apontam para um potencial **suporte ao diagnóstico** via análise por imagens
- Imagens de Ressonância Magnética Estrutural (RM) como objeto de análise





- Apesar dos resultados promissores, os trabalhos atuais (por não serem ainda conclusivos e aceitos para um diagnóstico definitivo) abrem espaço para novas investigações em outros domínios
- A análise da estrutura cerebral a partir de uma **estrutura tridimensional conectada** permite um estudo da superfície da massa encefálica com mais detalhe e profundidade



1. Análise em massa de base de dados de *benchmark* da literatura: mais de 3k amostras balanceadas de RMs de pessoa com TEA e neurotípicas
2. Estudo de técnicas de análise de superfície amparadas na teoria das Variedades e em Geometria Riemanniana para representação do cérebro em termos descritivos
3. Propor uma técnica robusta de suporte ao diagnóstico de TEA baseada na análise de RMs
4. Propor um atlas composto de parcelas do cérebro que possuem maior capacidade de diferenciação entre um cérebro com TEA e um neurotípico



Obrigado (-:



# Uso de wavelets e aprendizado de máquina para a detecção de disfonias na voz

Brígida Farias Cardoso Oliveira

Fatima N. S. de Medeiros

Processamento de Sinais e Imagens / Sinais e Sistemas



- A análise de disfonias na voz tem um papel significativo no diagnóstico de diversas doenças. A literatura relata esses distúrbios como qualquer alteração na qualidade, altura ou amplitude que divergem das vozes de grupos etários, sexuais e sociais semelhantes [1].
- Razões para identificar padrões anormais de voz:
  - Tratamento precoce da doença e a redução do impacto na capacidade de comunicação do indivíduo.
  - Avaliação da saúde vocal.
  - Melhora da Fala e Comunicação, etc
- Desafios:
  - A identificação de padrões patológicos na voz humana é subjetiva e depende normalmente da experiência do especialista [2].
  - A perceção do distúrbio é geralmente baseada numa análise acústica que é suscetível ao ruído, interferindo no diagnóstico.
  - Além disso, diferentes patologias podem coexistir com sintomas semelhantes, o que dificulta a análise perceptiva, bem como a análise por videolaringoscopia e luz estroboscópica [3].

## Metodologia

1. Geração dos escalogramas dos áudios das bases AVFAD e SVD utilizando as wavelets Morlet, Bump e Chapéu Mexicano Complexo;
2. Extração das características dos escalogramas pela rede neural convolucional (CNN) escolhida;
3. Classificação utilizando diversos classificadores utilizando a biblioteca de AutoML Pycaret.





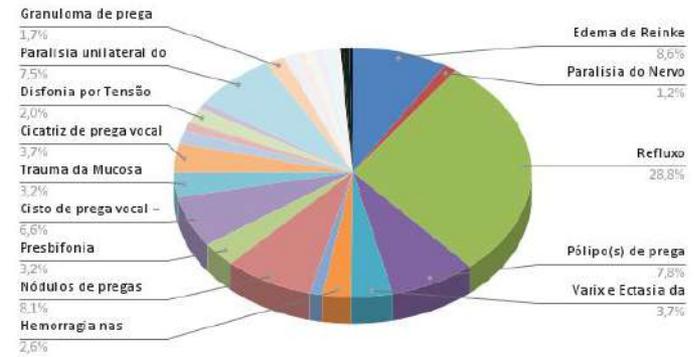
## Metodologia

- Classificadores implementados pela Pycaret:
  - Extra Trees Classifier
  - Extreme Gradient Boosting
  - Random Forest Classifier
  - Light Gradient Boosting Machine
  - Logistic Regression
  - Gradient Boosting Classifier
  - Ada Boost Classifier
  - SVM - Linear Kernel
  - Linear Discriminant Analysis
  - Naive Bayes
  - K Neighbors Classifier
  - Ridge Classifier
  - Decision Tree Classifier
  - Dummy Classifier
  - Quadratic Discriminant Analysis

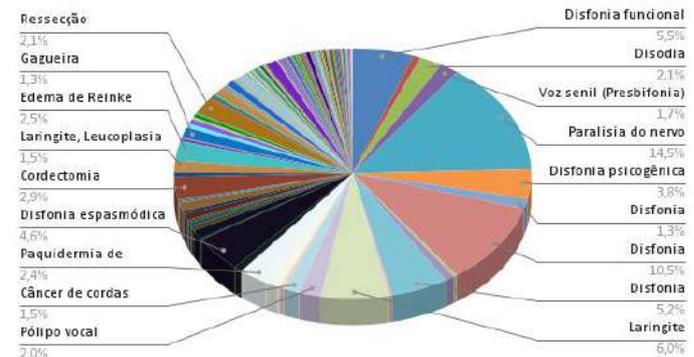
## Bases

- AVFAD:
  - Contém 363 vozes saudáveis (253 do sexo feminino e 110 do sexo masculino) e 346 vozes anormais (247 do sexo feminino e 99 do sexo masculino);
  - Amostras foram gravadas a 48kHz com uma resolução de 16 bits.
- SVD:
  - Contém 687 vozes saudáveis
    - 428 do sexo feminino
    - 259 do sexo masculino
  - 1354 vozes anormais
    - 727 do sexo feminino
    - 627 do sexo masculino
  - Amostras foram gravadas a 50 kHz com uma resolução de 16 bits.

Contagem de patologias (base AVFAD)



Contagem de patologias (base SVD)





## MobileNet V3 Small

- Resultados de todos classificadores do Pycaret para ambos os sexos vogal a:

Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
Linear Discriminant Analysis	0,8379	0,9137	0,8379	0,8467	0,837	0,6766	0,6847	1,323
Extra Trees Classifier	0,833	0,8963	0,833	0,8394	0,8325	0,6669	0,6726	1,362
Random Forest Classifier	0,8329	0,896	0,8329	0,8412	0,8322	0,667	0,6744	1,373
Extreme Gradient Boosting	0,8251	0,8889	0,8251	0,8289	0,8248	0,6507	0,6541	4,712
Naive Bayes	0,8228	0,8339	0,8228	0,8298	0,8221	0,6459	0,6525	1,289
K Neighbors Classifier	0,8224	0,8606	0,8224	0,8307	0,8217	0,6456	0,6532	1,97
Light Gradient Boosting Machine	0,8176	0,8864	0,8176	0,8247	0,8167	0,6363	0,6426	98,395
Gradient Boosting Classifier	0,8126	0,8884	0,8126	0,8229	0,8114	0,6264	0,6355	8,733
SVM - Linear Kernel	0,8099	0,8881	0,8099	0,8207	0,8088	0,6204	0,6305	1,226
Ridge Classifier	0,8097	0,8786	0,8097	0,8165	0,8088	0,6199	0,6262	1,266
Logistic Regression	0,7998	0,8993	0,7998	0,8067	0,7991	0,6001	0,6065	1,847
Ada Boost Classifier	0,7897	0,8766	0,7897	0,793	0,7893	0,5795	0,5826	2,814
Decision Tree Classifier	0,7315	0,7322	0,7315	0,7432	0,7282	0,4633	0,4744	1,399
Dummy Classifier	0,5114	0,5	0,5114	0,2616	0,3461	0	0	1,447
Quadratic Discriminant Analysis	0,4984	0,5133	0,4984	0,4983	0,4953	-0,0047	-0,0045	1,346

## VGG16

- Morlet

SVD										
Grupo	Vogal	Model	Accuracy	AUC	Recall	Precision	F1	Kappa	MCC	TT (Sec)
Mulher	a	Extra Trees Classifier	0.7599	0.8367	0.7599	0.7575	0.7522	0.4585	0.4669	1.919
	i	Light Gradient Boosting Machine	0.7382	0.7864	0.7382	0.7314	0.7277	0.4042	0.4121	187.154
	u	Gradient Boosting Classifier	0,7184	0,7401	0,7184	0,7111	0,7077	0,3662	0,3729	6,204
	aiu	Light Gradient Boosting Machine	0.7258	0.7881	0.7258	0.7198	0.7196	0.3923	0.3963	218.823
Homem	a	Light Gradient Boosting Machine	0.7556	0.8201	0.7556	0.745	0.7386	0.3522	0.3679	154.516
	i	Extra Trees Classifier	0.7535	0.7983	0.7535	0.7444	0.7038	0.2346	0.292	1.779
	u	Logistic Regression	0.7442	0.7845	0.7442	0.7411	0.7394	0.3615	0.3664	1.81
	aiu	Light Gradient Boosting Machine	0.7339	0.7834	0.7339	0.7167	0.7162	0.3014	0.3134	210.256
Ambos	a	Extreme Gradient Boosting	0.739	0.7951	0.739	0.7311	0.729	0.3852	0.3935	10.688
	i	Extreme Gradient Boosting	0.7058	0.7401	0.7058	0.6973	0.6942	0.3155	0.3245	11.542
	u	Extreme Gradient Boosting	0.706	0.7393	0.706	0.692	0.6923	0.2951	0.3021	8.425
	aiu	Extreme Gradient Boosting	0.7212	0.7752	0.7212	0.7109	0.7113	0.3421	0.3481	25.676

## VGG16

- Morlet

AVFAD										
Grupo	Vogal	Model	Accuracy	AUC	Recall	Precision	F1	Kappa	MCC	TT (Sec)
Mulher	a	Random Forest Classifier	0.8308	0.8654	0.8308	0.8487	0.8279	0.663	0.6793	1.139
	i	Extra Trees Classifier	0.8743	0.8828	0.8743	0.8829	0.8733	0.7481	0.7567	1.156
	u	Logistic Regression	0.8712	0.9254	0.8712	0.8749	0.8701	0.7423	0.746	1.35
	aiu	Gradient Boosting Classifier	0.8554	0.897	0.8554	0.8618	0.8546	0.7109	0.7172	8.765
Homem	a	Extra Trees Classifier	0.8114	0.8683	0.8114	0.8224	0.8095	0.6213	0.6324	0.984
	i	Logistic Regression	0.8015	0.8744	0.8015	0.8248	0.7965	0.6066	0.6265	1.143
	u	Extra Trees Classifier	0.7909	0.8162	0.7909	0.8148	0.785	0.5828	0.6038	1.45
	aiu	Linear Discriminant Analysis	0.8029	0.8512	0.8029	0.8116	0.8022	0.6067	0.614	1.297
Ambos	a	Extra Trees Classifier	0.8431	0.894	0.8431	0.8535	0.8423	0.6874	0.6967	1.488
	i	Extra Trees Classifier	0.8288	0.8658	0.8288	0.8339	0.828	0.6577	0.6627	1.853
	u	Extra Trees Classifier	0.8228	0.8784	0.8228	0.8324	0.8217	0.6461	0.6553	1.549
	aiu	Extra Trees Classifier	0.8113	0.8631	0.8113	0.8185	0.8107	0.6239	0.6302	1.48



## VGG16

- Bump

SVD										
Grupo	Vogal	Model	Accuracy	AUC	Recall	Precision	F1	Kappa	MCC	TT (Sec)
Mulher	a	Light Gradient Boosting Machine	0.7231	0.7848	0.7231	0.7208	0.7146	0.3855	0.395	148.209
	i	Extreme Gradient Boosting	0.7244	0.7601	0.7244	0.7212	0.7179	0.3876	0.3941	5.291
	u	Linear Discriminant Analysis	0.7152	0.7514	0.7152	0.7113	0.7106	0.3754	0.3785	1.368
	aiu	Light Gradient Boosting Machine	0.7335	0.7942	0.7335	0.7273	0.7265	0.4038	0.4087	216.88
Homem	a	Extra Trees Classifier	0.7535	0.7874	0.7535	0.7393	0.7199	0.291	0.3265	1.321
	i	Random Forest Classifier	0.7271	0.7671	0.7271	0.687	0.6457	0.1004	0.1576	1.379
	u	Logistic Regression	0.7236	0.7637	0.7236	0.7165	0.7134	0.3072	0.3144	1.647
	aiu	Light Gradient Boosting Machine	0.7513	0.7895	0.7513	0.7343	0.7309	0.3206	0.3373	206.871
Ambos	a	Light Gradient Boosting Machine	0.7443	0.7964	0.7443	0.7382	0.7344	0.3979	0.4077	201.747
	i	Extreme Gradient Boosting	0.7181	0.775	0.7181	0.7073	0.7067	0.3316	0.3392	7.322
	u	Extra Trees Classifier	0.6868	0.7053	0.6868	0.6705	0.633	0.1708	0.2122	1.39
	aiu	Light Gradient Boosting Machine	0.711	0.7681	0.711	0.6977	0.6968	0.306	0.315	245.71

## VGG16

- Bump

AVFAD										
Grupo	Vogal	Model	Accuracy	AUC	Recall	Precision	F1	Kappa	MCC	TT (Sec)
Mulher	a	Extra Trees Classifier	0.8561	0.8929	0.8561	0.8647	0.8553	0.7128	0.7207	1.24
	i	Extra Trees Classifier	0.8279	0.8654	0.8279	0.8372	0.8273	0.6572	0.6651	1.127
	u	Linear Discriminant Analysis	0.8237	0.864	0.8237	0.8453	0.8201	0.6482	0.6678	1.151
	aiu	Light Gradient Boosting Machine	0.8387	0.8956	0.8387	0.8467	0.8379	0.6781	0.6856	187.148
Homem	a	Gradient Boosting Classifier	0.8045	0.8503	0.8045	0.828	0.801	0.6051	0.6267	2.626
	i	Linear Discriminant Analysis	0.7273	0.7771	0.7273	0.7643	0.7209	0.4608	0.4908	0.946
	u	K Neighbors Classifier	0.7568	0.789	0.7568	0.7817	0.754	0.5114	0.5324	1.038
	aiu	Random Forest Classifier	0.7652	0.835	0.7652	0.7835	0.7623	0.5328	0.5488	1.15
Ambos	a	Extreme Gradient Boosting	0.8551	0.9188	0.8551	0.8579	0.8547	0.7099	0.7128	3.159
	i	Extreme Gradient Boosting	0.8479	0.8688	0.8479	0.8583	0.8467	0.6964	0.7061	3.151
	u	Extra Trees Classifier	0.7966	0.8408	0.7966	0.803	0.7956	0.5943	0.5999	1.184
	aiu	Gradient Boosting Classifier	0.8238	0.8796	0.8238	0.8292	0.8234	0.6485	0.6532	12.433

## VGG16

- Chapéu Mexicano Complexo

SVD										
Grupo	Vogal	Model	Accuracy	AUC	Recall	Precision	F1	Kappa	MCC	TT (Sec)
Mulher	a	Extra Trees Classifier	0.7369	0.8035	0.7369	0.734	0.7259	0.4031	0.4154	1.23
	i	Gradient Boosting Classifier	0.706	0.75	0.706	0.7007	0.6964	0.341	0.3497	7.301
	u	Linear Discriminant Analysis	0.6829	0.6854	0.6829	0.6813	0.6798	0.3159	0.3184	1.903
	aiu	Extreme Gradient Boosting	0.7036	0.7654	0.7036	0.6962	0.6966	0.3375	0.3413	16.61
Homem	a	Extra Trees Classifier	0.7476	0.7934	0.7476	0.7327	0.7268	0.3426	0.3591	1.306
	i	Extreme Gradient Boosting	0.7151	0.7147	0.7151	0.6967	0.6892	0.2214	0.2428	3.746
	u	Extra Trees Classifier	0.7322	0.7537	0.7322	0.736	0.6699	0.1827	0.2558	1.193
	aiu	Light Gradient Boosting Machine	0.7292	0.7637	0.7292	0.7057	0.7015	0.2481	0.2679	200.449
Ambos	a	Gradient Boosting Classifier	0.7348	0.7867	0.7348	0.7247	0.724	0.379	0.3854	18.909
	i	Extreme Gradient Boosting	0.7417	0.7762	0.7417	0.734	0.7285	0.3767	0.3896	8.329
	u	Light Gradient Boosting Machine	0.6947	0.7158	0.6947	0.6758	0.6665	0.2324	0.2506	189.371
	aiu	Light Gradient Boosting Machine	0.7183	0.7684	0.7183	0.706	0.7056	0.3273	0.3352	295.395

## VGG16

- Chapéu Mexicano Complexo

AVFAD										
Grupo	Vogal	Model	Accuracy	AUC	Recall	Precision	F1	Kappa	MCC	TT (Sec)
Mulher	a	Random Forest Classifier	0.8489	0.8865	0.8489	0.8553	0.8484	0.6978	0.7041	1.321
	i	Linear Discriminant Analysis	0.8243	0.8776	0.8243	0.8407	0.8218	0.6495	0.6649	1.51
	u	Random Forest Classifier	0.8229	0.8529	0.8229	0.8371	0.8195	0.6432	0.6581	1.614
	aiu	Gradient Boosting Classifier	0.8256	0.8842	0.8256	0.8318	0.825	0.6517	0.6576	8.788
Homem	a	Linear Discriminant Analysis	0.7856	0.8567	0.7856	0.8105	0.7802	0.5735	0.5945	1.404
	i	Extreme Gradient Boosting	0.7735	0.8503	0.7735	0.8082	0.7673	0.5513	0.5796	3.312
	u	Linear Discriminant Analysis	0.7917	0.809	0.7917	0.8168	0.7863	0.5867	0.6066	1.499
	aiu	Linear Discriminant Analysis	0.7995	0.8776	0.7995	0.809	0.7986	0.6007	0.6085	1.194
Ambos	a	Linear Discriminant Analysis	0.8329	0.8631	0.8329	0.8388	0.8324	0.6659	0.6715	1.155
	i	Random Forest Classifier	0.8202	0.8601	0.8202	0.8264	0.819	0.6402	0.6463	1.736
	u	Random Forest Classifier	0.8101	0.8396	0.8101	0.8215	0.8082	0.6208	0.6316	1.571
	aiu	Extreme Gradient Boosting	0.828	0.8793	0.828	0.8338	0.8277	0.6569	0.662	12.513



1. S. Hegde, S. Shetty, S. Rai and T. Dodderi, "A survey on machine learning approaches for automatic detection of voice disorders", *Journal of Voice*, vol. 33, no. 6, pp. 947.e11-947.e33, 2019.
2. H. Wu, J. Soraghan, A. Lowit and G. Di Caterina, "Convolutional neural networks for pathological voice detection", 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 1-4, July 2018.
3. E. S. Fonseca, R. C. Guido, S. B. Junior, H. Dezani, R. R. Gati and D. C. M. Pereira, "Acoustic investigation of speech pathologies based on the discriminative paraconsistent machine (DPM)", *Biomedical Signal Processing and Control*, vol. 55, 2020.
4. M. Chaiani, S. A. Selouani and M. Boudraa, "Voice Disorder Detection Using Enhanced Auditory Perception-Scaled Spectrograms," 2022 45th International Conference on Telecommunications and Signal Processing (TSP), Prague, Czech Republic, 2022, pp. 49-54.
5. Cantürk, İ., Günay, O. Investigation of Scalograms with a Deep Feature Fusion Approach for Detection of Parkinson's Disease. *Cogn Comput* 16, 1198–1209 (2024).
6. Mounira Chaiani, Sid Ahmed Selouani, Malika Boudraa, Mohammed Sidi Yakoub, Voice disorder classification using speech enhancement and deep learning models, *Biocybernetics and Biomedical Engineering*, Volume 42, Issue 2, 2022, Pages 463-480.
7. Farhad Javanmardi, Sudarsana Reddy Kadiri, Paavo Alku,
8. A comparison of data augmentation methods in voice pathology detection,
9. *Computer Speech & Language*, Volume 83, 2024.



Universidade Federal do Ceará  
Programa de Pós-Graduação em  
Engenharia de Teleinformática



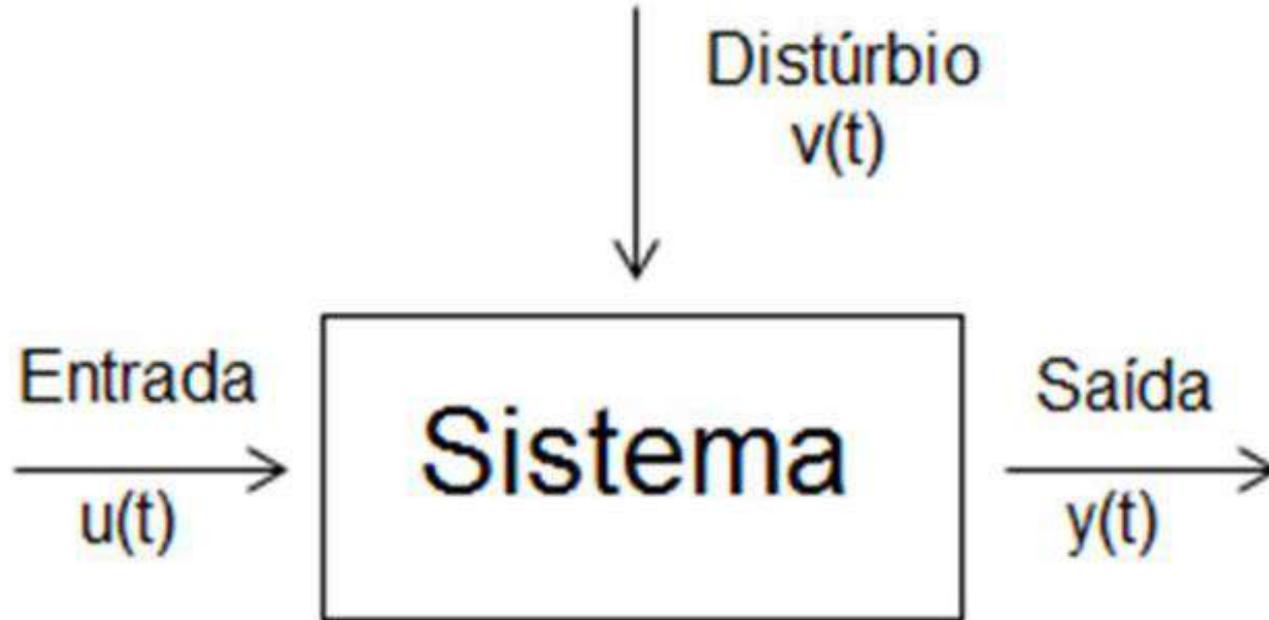
# **CONTRIBUIÇÕES DA EDUCOMETRIA PARA A AVALIAÇÃO DO SUCESSO ACADÊMICO NO CURSO DE ENGENHARIA ELÉTRICA DA UFC.**

**CARLOS ALEX MARTINS OLIVEIRA**

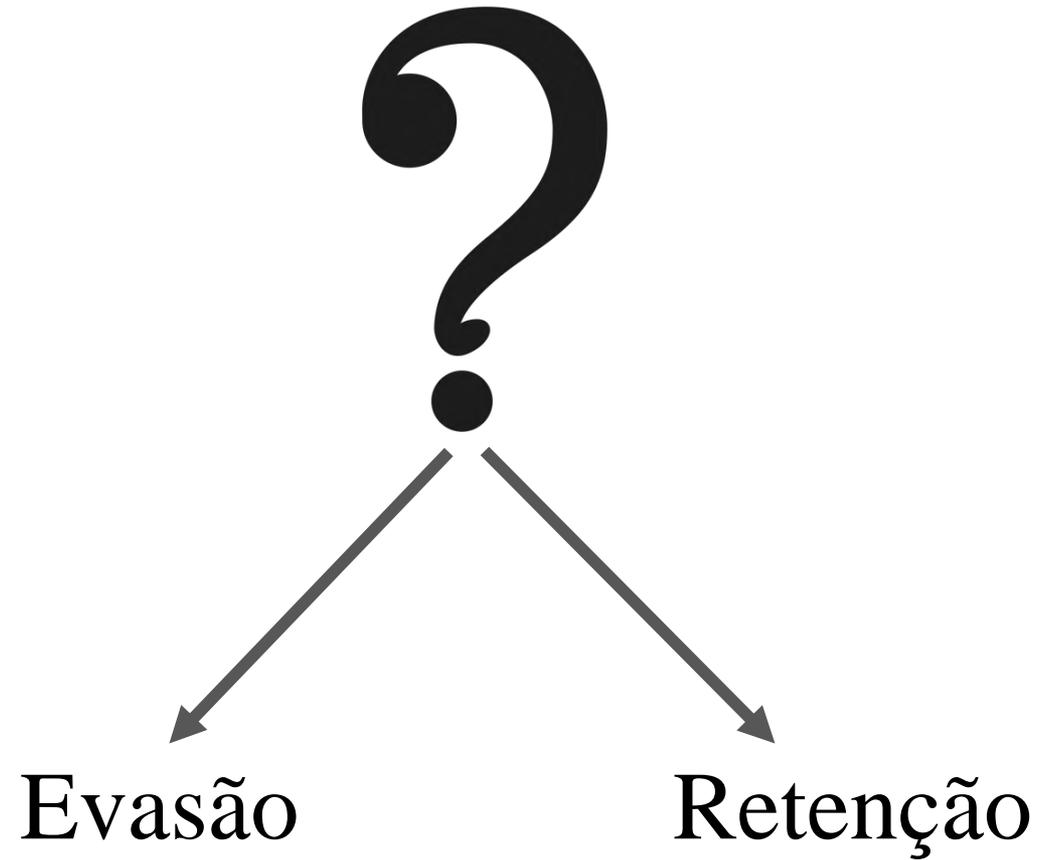
**PROFESSOR DR JOÃO CESAR MOURA MOTA**

**RECONHECIMENTO DE PADRÕES E SISTEMAS DINÂMICOS / SINAIS E SISTEMAS**

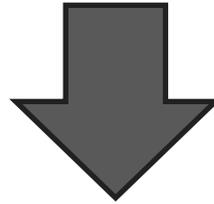
# Processo de Diplomação do Discente



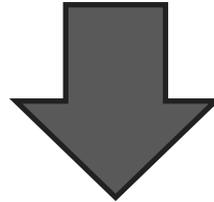
Situação dos alunos que ingressaram na UFC por turma de entrada SISU - Coleta dos dados em Mar/2022							
ENGENHARIA ELÉTRICA / BACHARELADO							
Turma SISU >	2015	2016	2017	2018	2019	2020	2021
Trancado	0 (0%)	0 (0%)	0 (0%)	0 (0%)	0 (0%)	0 (0%)	1(1,03%)
Concluído	34 (34%)	15 (14,85%)	3 (2,97%)	0 (0%)	0 (0%)	0 (0%)	0 (0%)
Cancelado	52 (52%)	45 (44,55%)	42 (41,58%)	33 (33,33%)	22 (22,68%)	23 (23%)	2 (2,06%)
Ativo	13 (13%)	41 (40,59%)	55 (54,46%)	65 (65,66%)	74 (76,29%)	75 (75%)	94 (96,91%)
N/A	1 (1%)	0 (0%)	1 (0,99%)	1 (1,01%)	1 (1,03%)	2 (2%)	0 (0%)
<b>TOTAL</b>	<b>100 (100%)</b>	<b>101 (100%)</b>	<b>101 (100%)</b>	<b>99 (100%)</b>	<b>97 (100%)</b>	<b>100 (100%)</b>	<b>97 (100%)</b>
ENGENHARIAS CT/UFC FORTALEZA							
Turma SISU >	2015	2016	2017	2018	2019	2020	2021
Trancado	0 (0%)	0 (0%)	0 (0%)	2 (0,3%)	0 (0%)	3 (0,42%)	3 (0,45%)
Concluído	234 (33,38%)	153 (21,67%)	35% (5,06%)	6 (0,89%)	1 (0,15%)	0 (0%)	0 (0%)
Cancelado	350 (49,93%)	317 (44,9%)	279 (40,32%)	259 (38,31%)	206 (30,98%)	158 (22,25%)	14 (2,09%)
Ativo	115 (16,41%)	232 (32,86%)	369 (53,32%)	404 (59,76%)	450 (67,67%)	540 (76,06%)	14 (2,09%)
N/A	2 (0,29%)	4 (0,57%)	9 (1,3%)	5 (0,74%)	8 (1,2%)	9 (1,27%)	647 (96,57%)
<b>TOTAL</b>	<b>701 (100%)</b>	<b>706 (100%)</b>	<b>692 (100%)</b>	<b>676 (100%)</b>	<b>665 (100%)</b>	<b>710 (100%)</b>	<b>670 (100%)</b>
<b>Resp. Semestre</b>	<b>15° Sem</b>	<b>13° Sem</b>	<b>11° Sem</b>	<b>9° Sem</b>	<b>7° Sem</b>	<b>5° Sem</b>	<b>3° Sem</b>



**UNIVERSIDADE FEDERAL DO CEARÁ (UFC)**



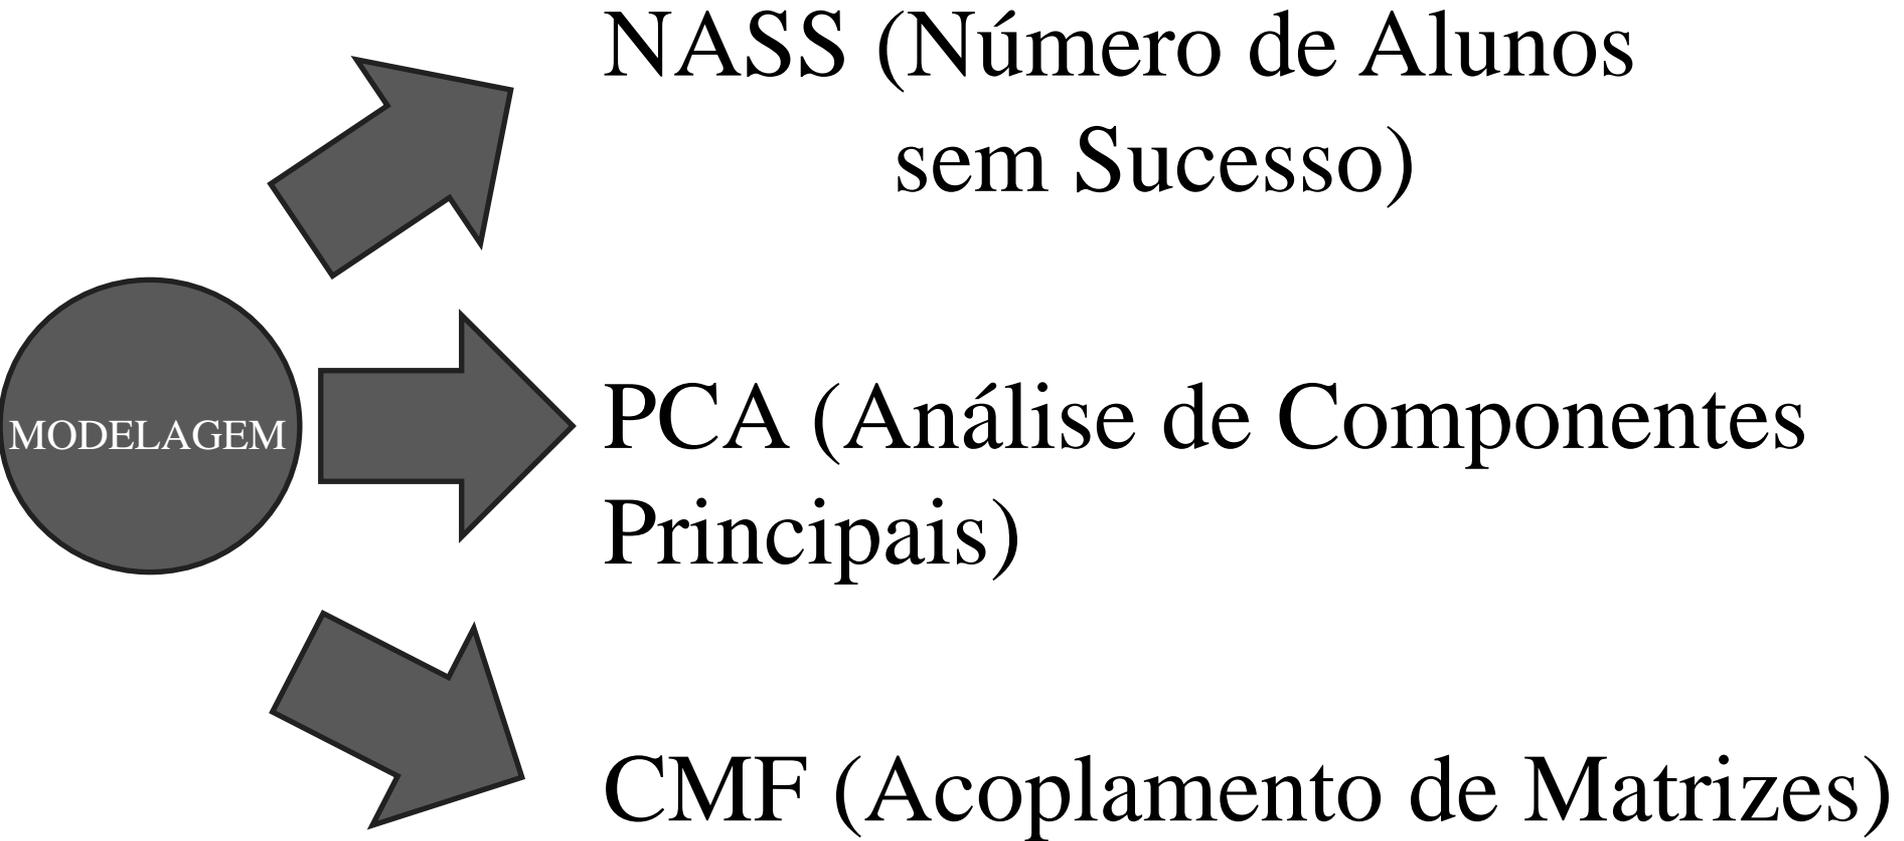
**CENTRO DE TECNOLOGIA (CT)**



**ENGENHARIA ELÉTRICA (EE)**



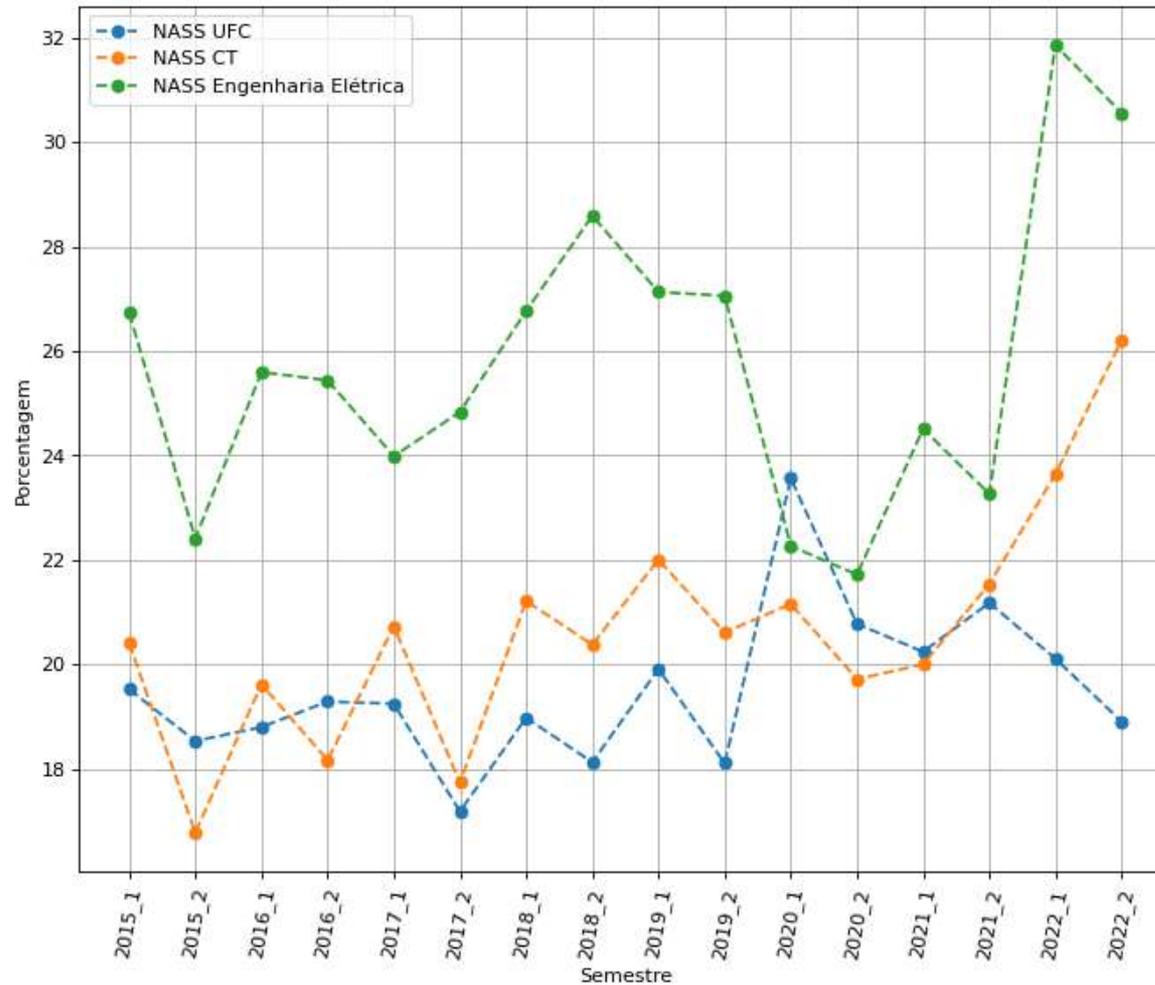
- Avaliação educacional
- Educometria
- A formação de Engenheiros no Brasil



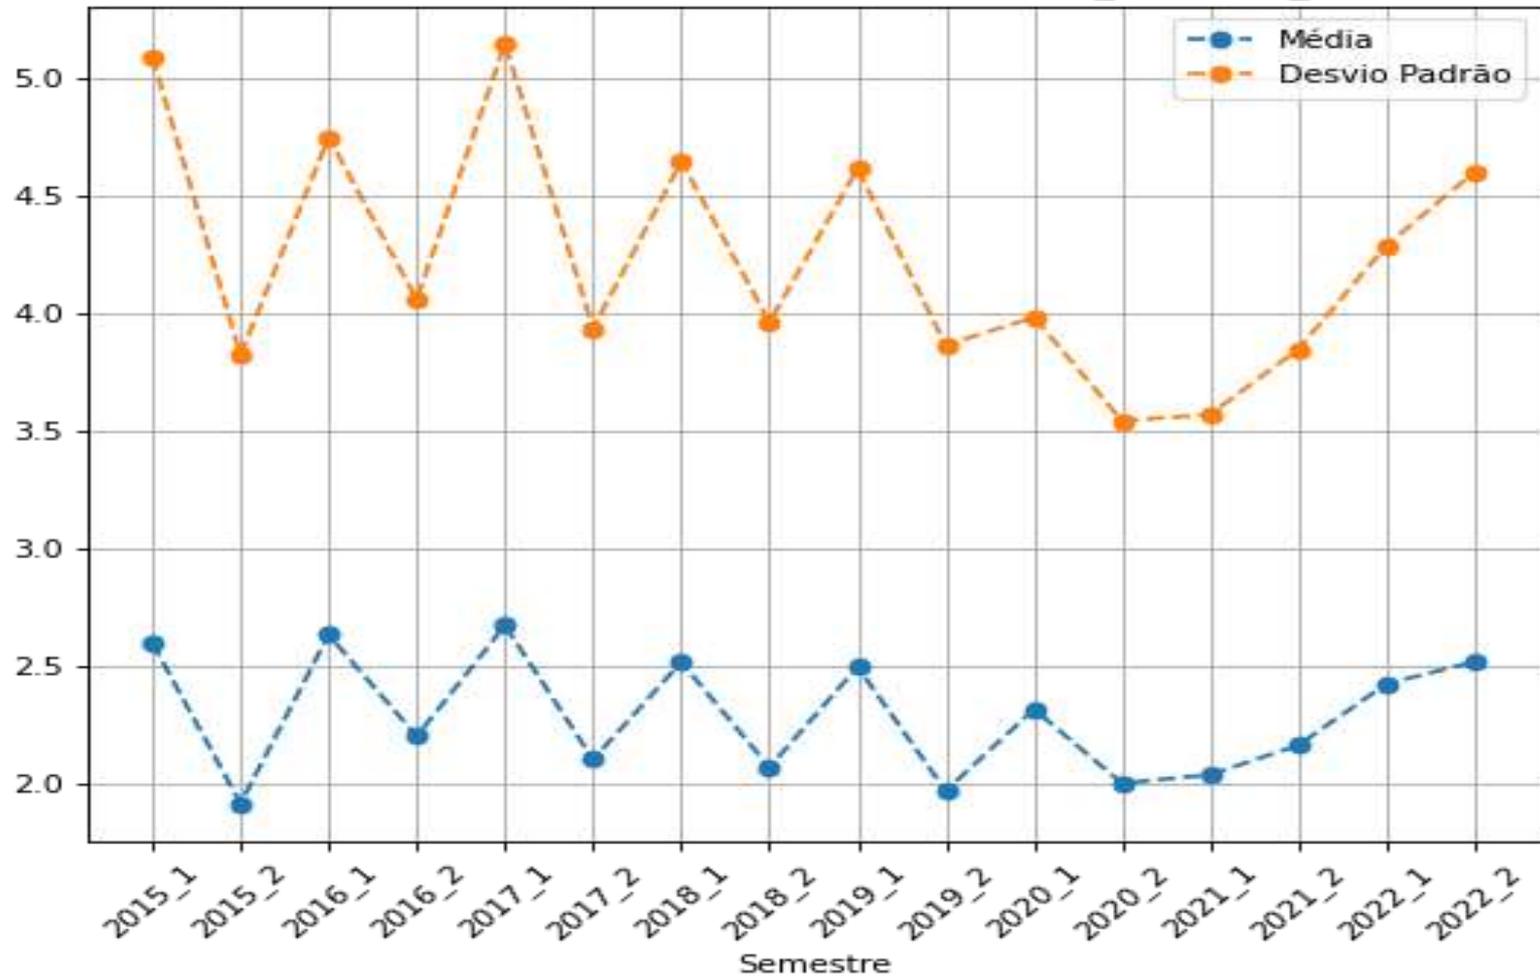


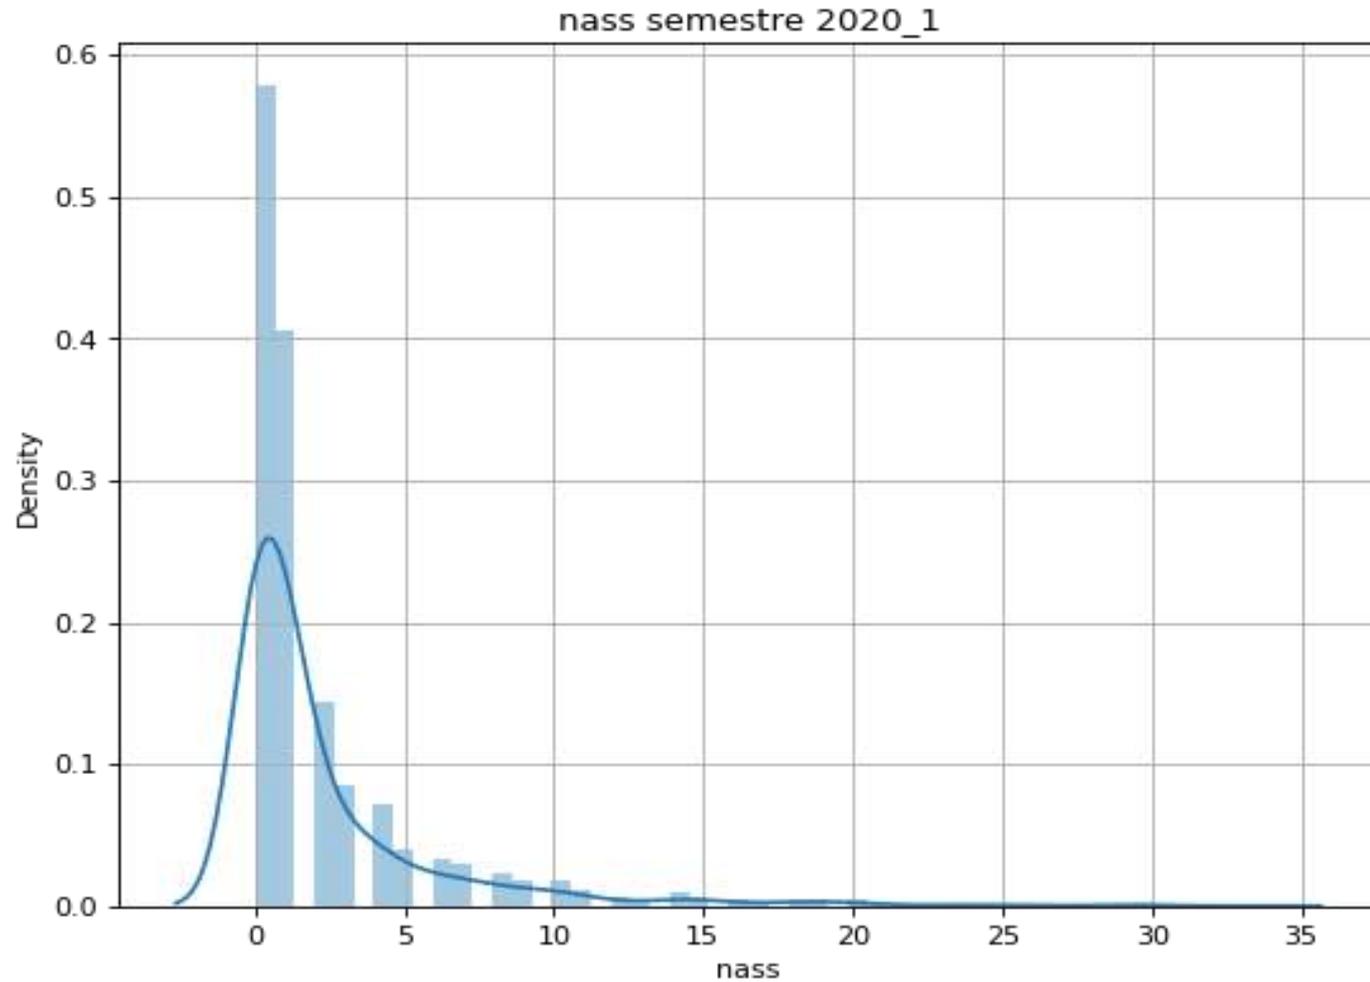
*NASS: Alunos com Reprovação por Nota (ARPN) + Alunos com Reprovação por Falta (ARPF)  
+ Alunos com Trancamento (AT) + Alunos com supressão (SUP).*

# RESULTADOS NASS

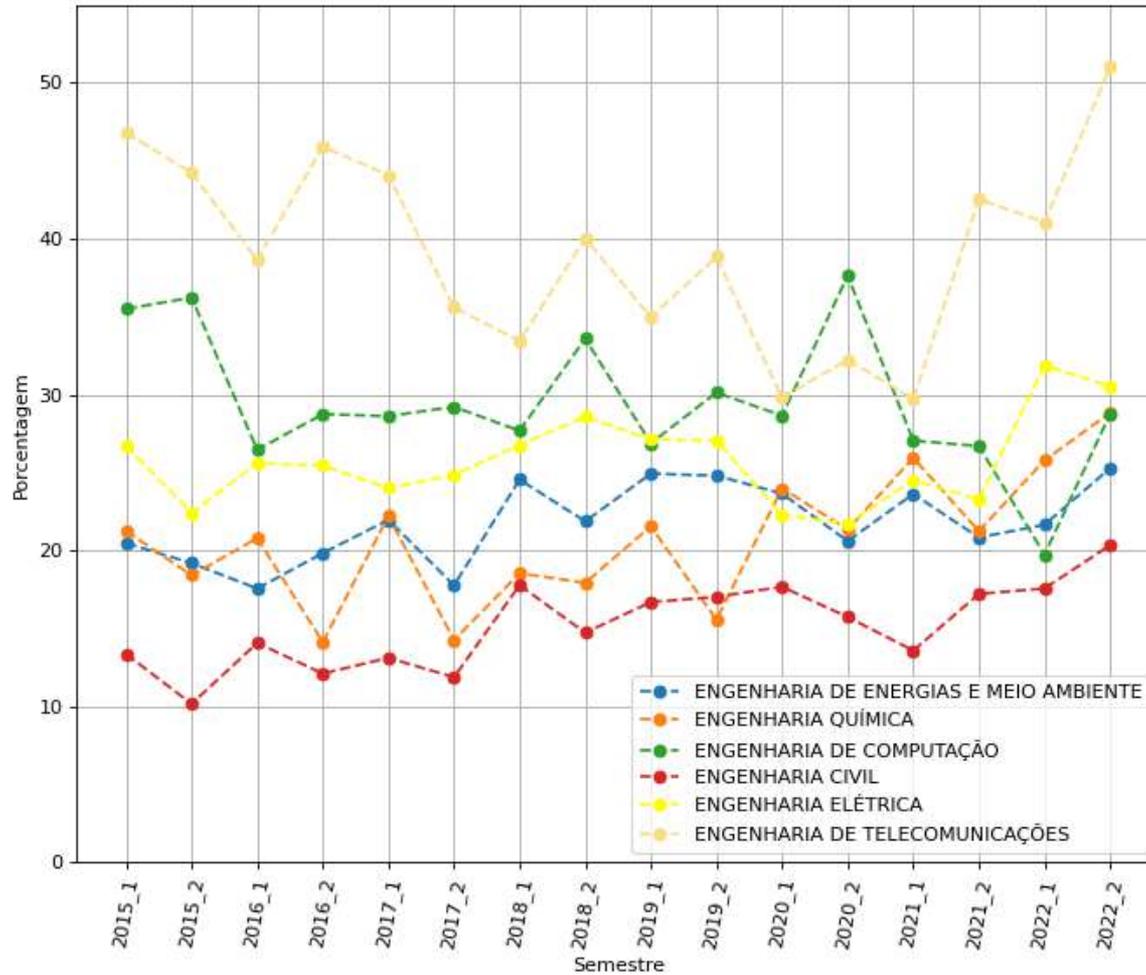


# RESULTADOS NASS

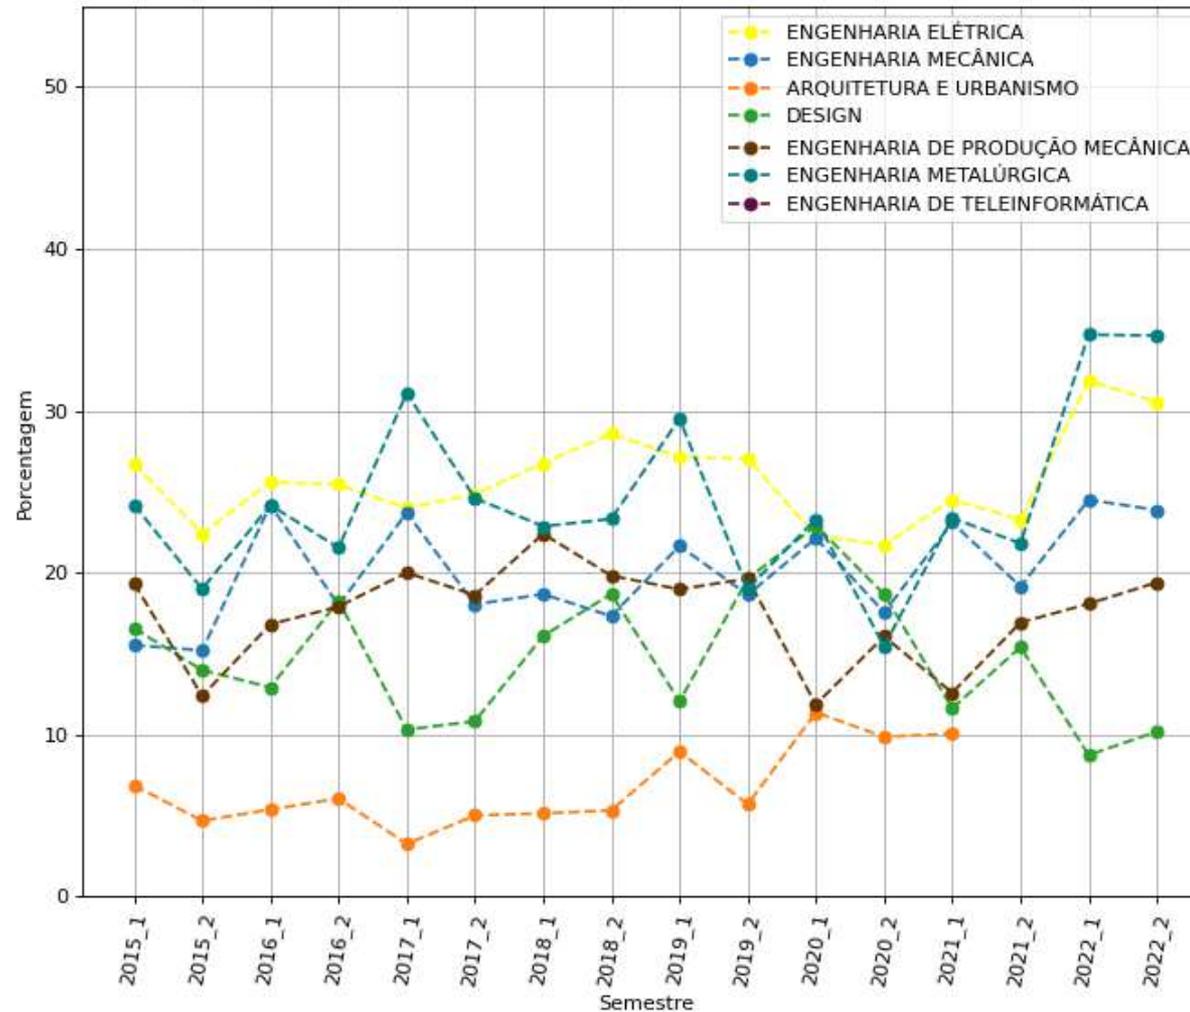




# RESULTADOS NASS



# RESULTADOS NASS

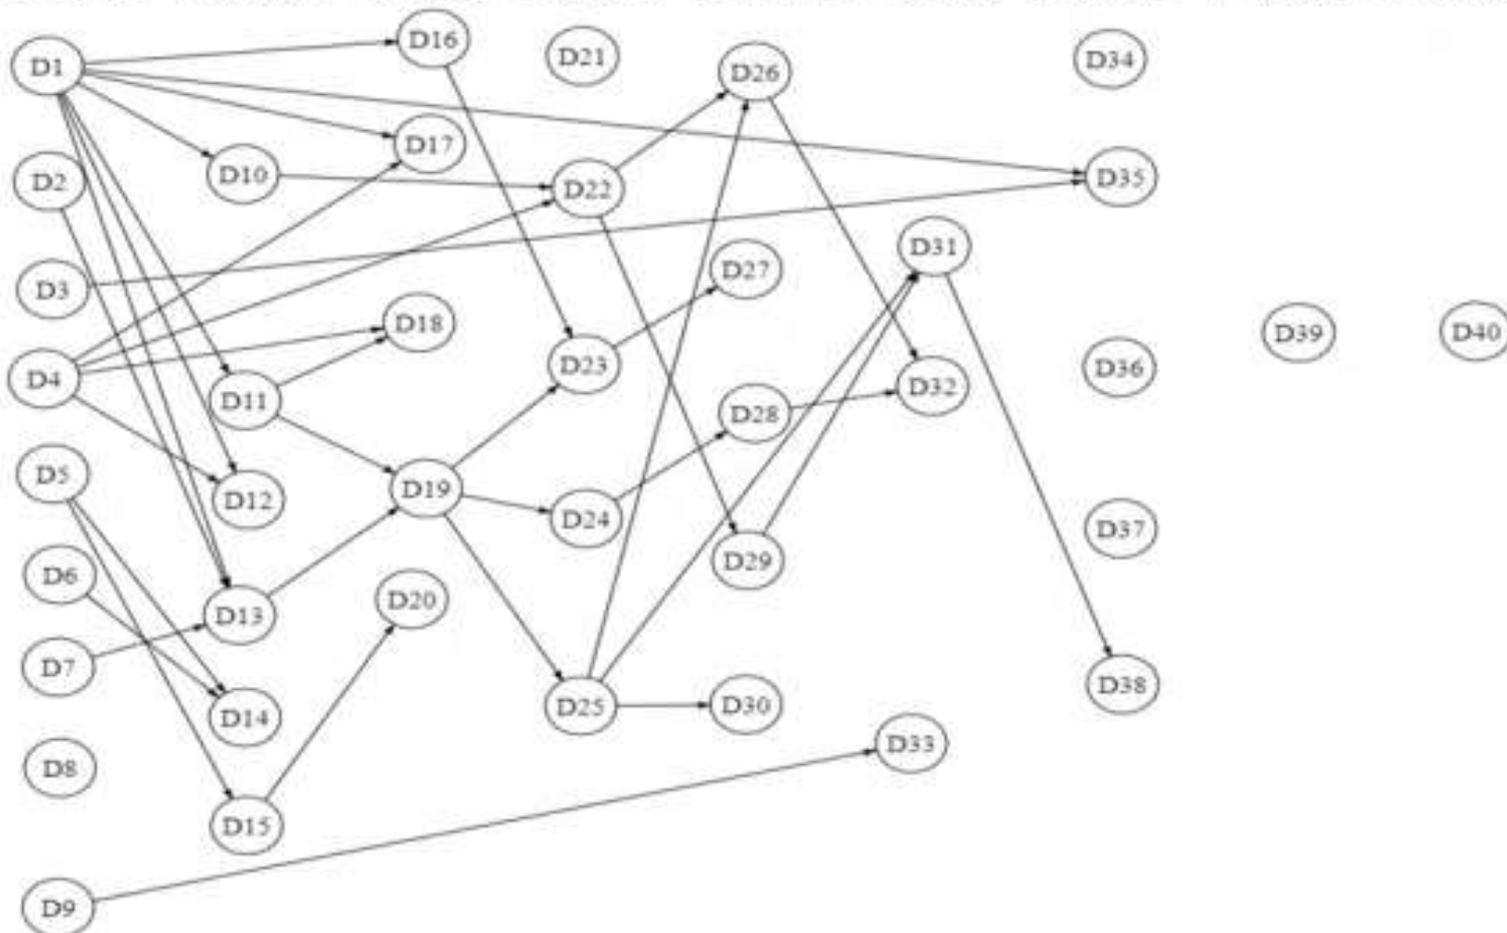


	<b>Disciplina</b>	<b>NASS</b>	<b>Total de Alunos</b>	<b>Percentual de insucesso</b>
1	ELETROMAGNETISMO APLICADO - ENGENHARIA ELÉTRICA	37	48	77
2	FUNDAMENTOS DE CÁLCULO PARA ENGENHARIA - ENGENHARIA ELÉTRICA	25	46	54
3	FUNDAMENTOS DE CÁLCULO PARA ENGENHARIA - ENGENHARIA ELÉTRICA	23	50	46
4	FÍSICA FUNDAMENTAL - ENGENHARIA ELÉTRICA	23	48	48
5	INTRODUÇÃO A ENGENHARIA - ENGENHARIA ELÉTRICA	19	112	17
6	ENGENHARIA ECONÔMICA - ENGENHARIA ELÉTRICA	16	54	30
7	FÍSICA FUNDAMENTAL - ENGENHARIA ELÉTRICA	15	46	33
8	MÉTODOS NUMÉRICOS APLICADOS A ENGENHARIA ELÉTRICA - ENGENHARIA ELÉTRICA	13	18	72
9	PROGRAMAÇÃO COMPUTACIONAL PARA ENGENHARIA - ENGENHARIA ELÉTRICA	13	49	27
10	ENGENHARIA ECONÔMICA - ENGENHARIA ELÉTRICA	12	48	25
11	PROGRAMAÇÃO COMPUTACIONAL PARA ENGENHARIA - ENGENHARIA ELÉTRICA	12	52	23
12	MECÂNICA DOS MATERIAIS - ENGENHARIA ELÉTRICA	12	41	29
13	CÁLCULO VETORIAL APLICADO - ENGENHARIA ELÉTRICA	11	20	55
14	QUÍMICA GERAL PARA ENGENHARIA - ENGENHARIA ELÉTRICA	10	19	53
15	QUÍMICA GERAL PARA ENGENHARIA - ENGENHARIA ELÉTRICA	10	19	53
16	ENGENHARIA DOS MATERIAIS - ENGENHARIA ELÉTRICA	10	24	42
17	QUÍMICA GERAL PARA ENGENHARIA - ENGENHARIA ELÉTRICA	9	20	45

# Estrutura Curricular



1º e 2º Semestres    3º Semestre    4º Semestre    5º Semestre    6º Semestre    7º Semestre    8º Semestre    9º Semestre    10º Semestre





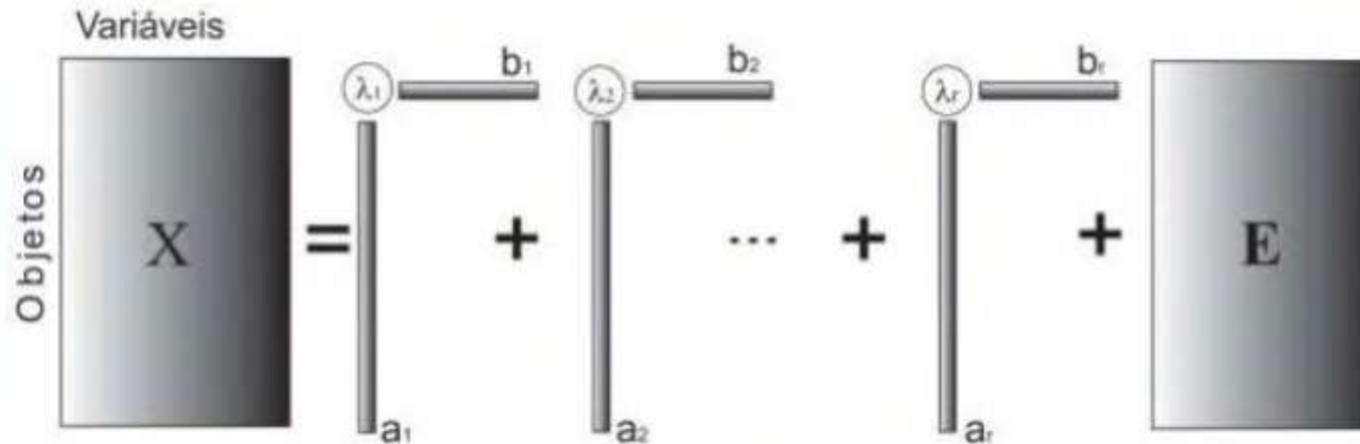
## Série Temporal – 2015 a 2022

Matriz de Aprovados  
( $X_{38 \times 8}$ )

Matriz de Relacionamento Curricular  
( $Y_{38 \times 38}$ )

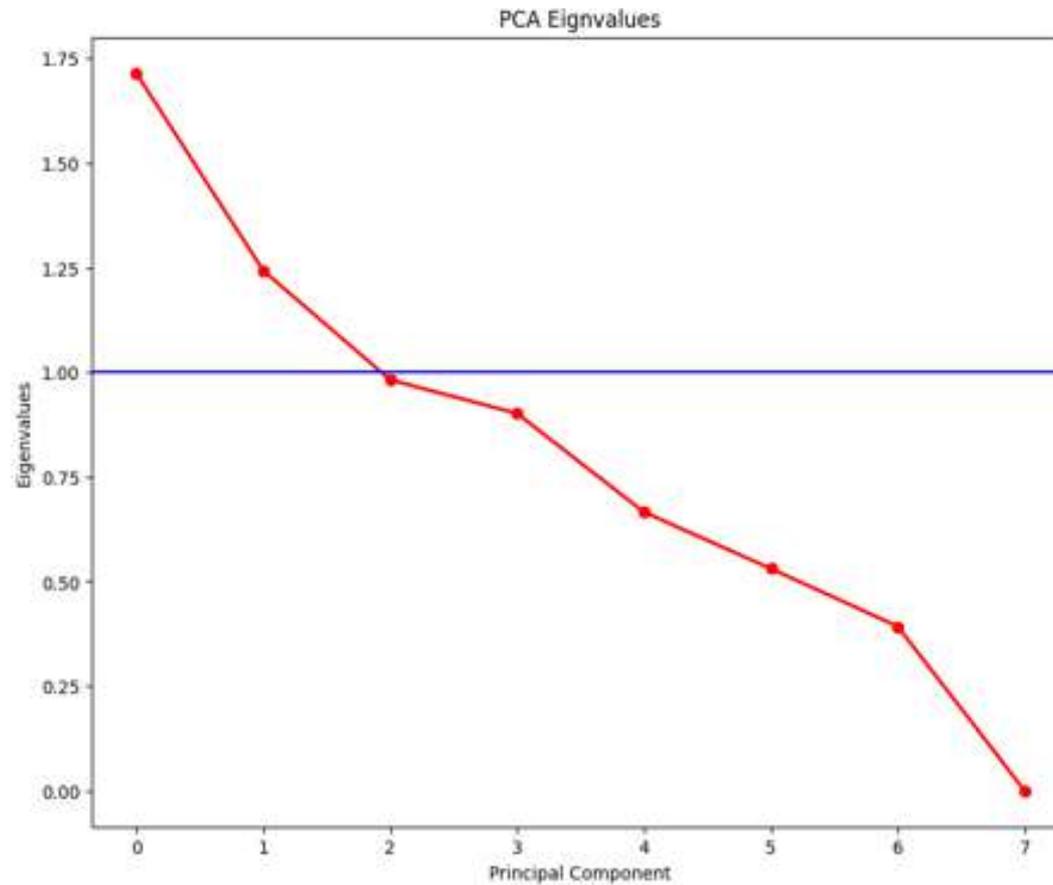
$$x_{ij} = \sum_{r=1}^R \lambda_r a_{ir} b_{jr} + e_{ij} \quad (13)$$

Figura 3: Representação esquemática de decomposição dos dados no PCA



Fonte: Autor (2023)

Gráfico 3 – Autovalores da variável ano



# RESULTADOS PCA

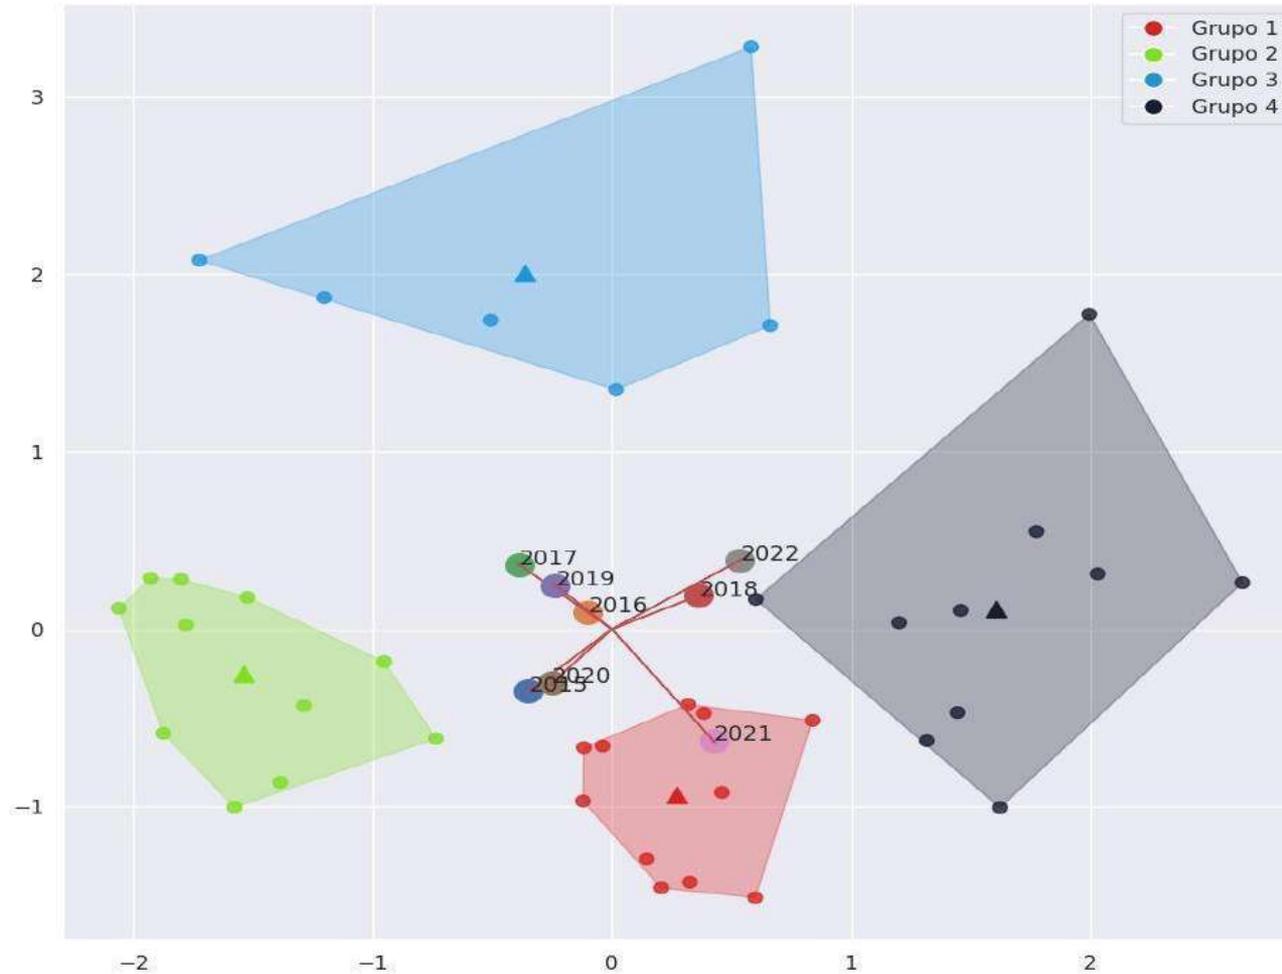
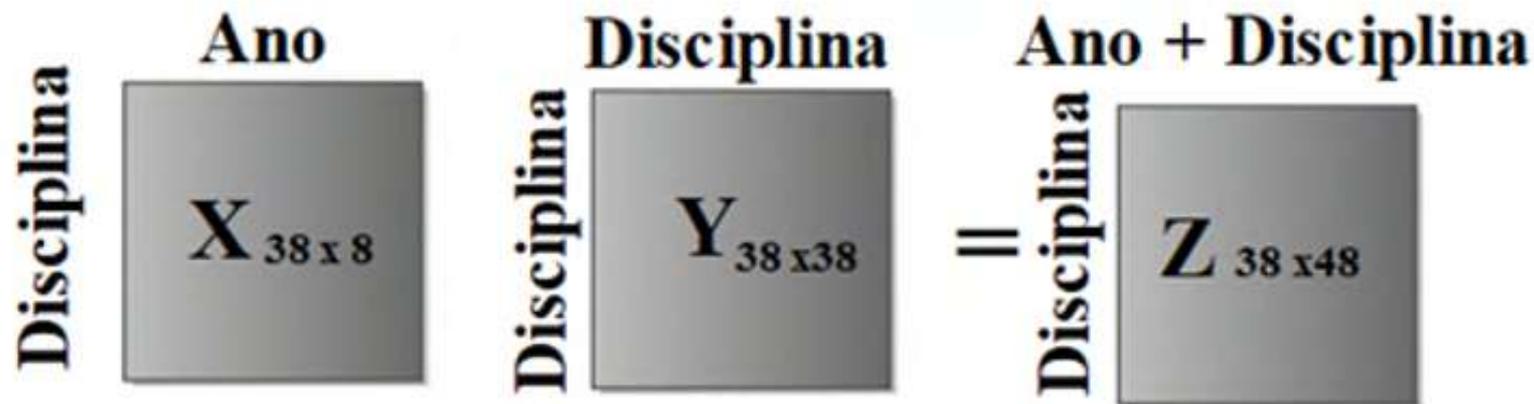
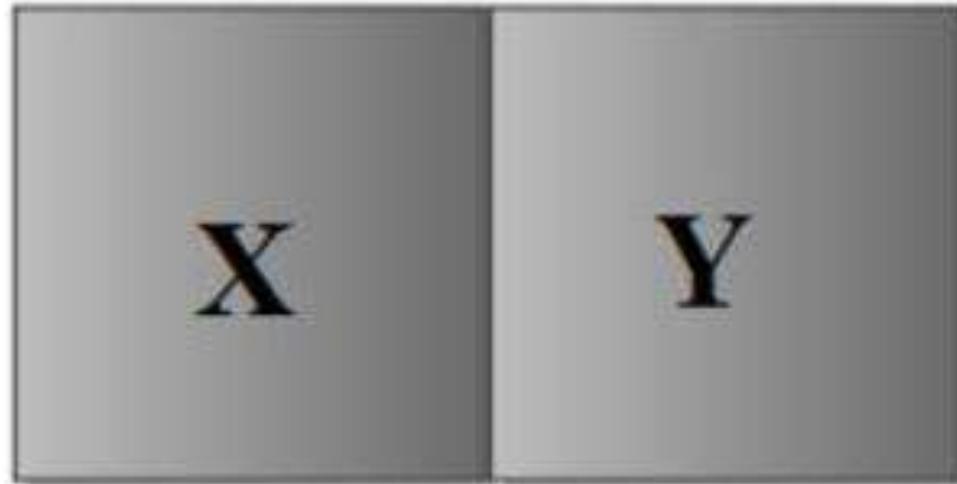


Figura 4 – Acoplamento das Matrizes X e Y



Fonte: Autor (2024).

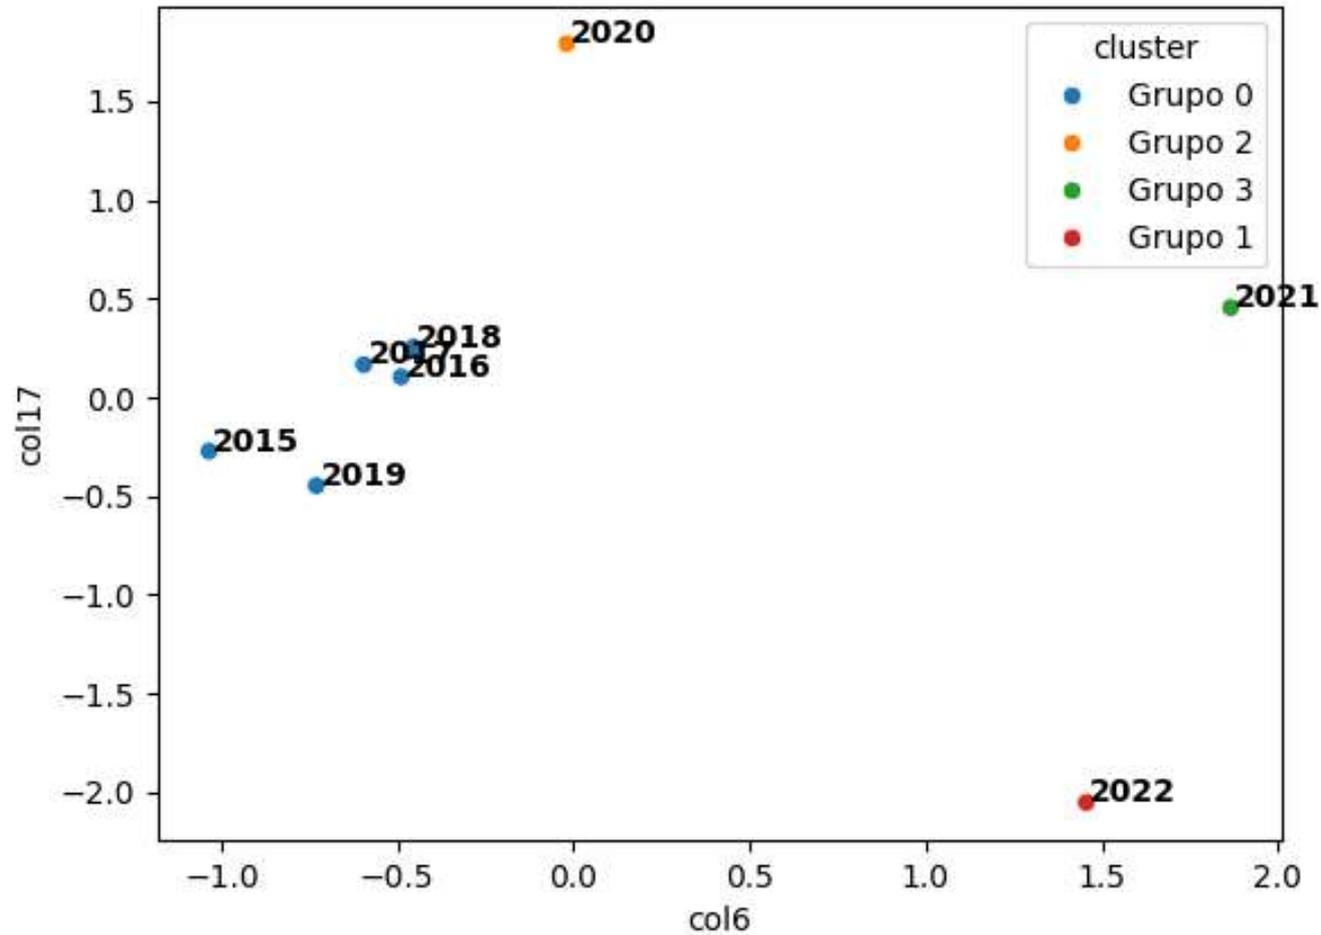
Figura 5– Acoplamento das Matrizes X e Y (CMF)

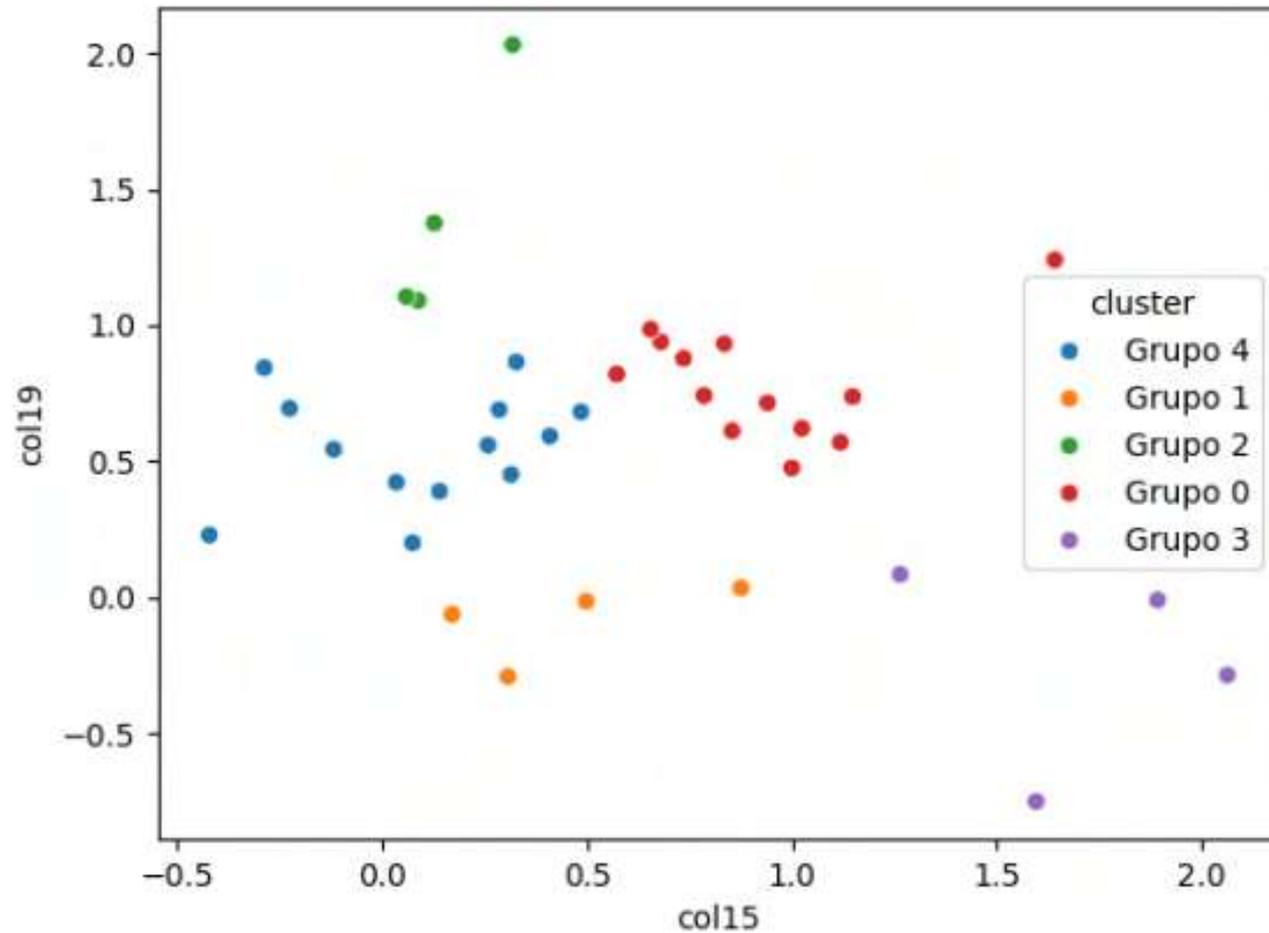


Fonte: Autor (2023)



$$f(U, V, W) = \|X - UV^T\|^2 + \|Y - UW^T\|^2$$







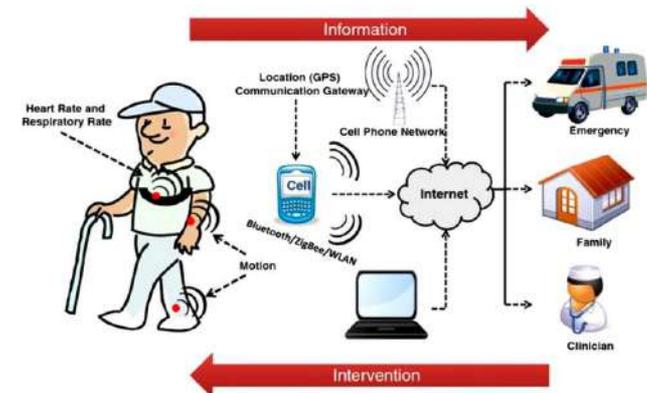
# Classificação de dados de streaming por meio de modelos de kernel baseados em protótipos

David Nascimento Coelho

Guilherme de Alencar Barreto

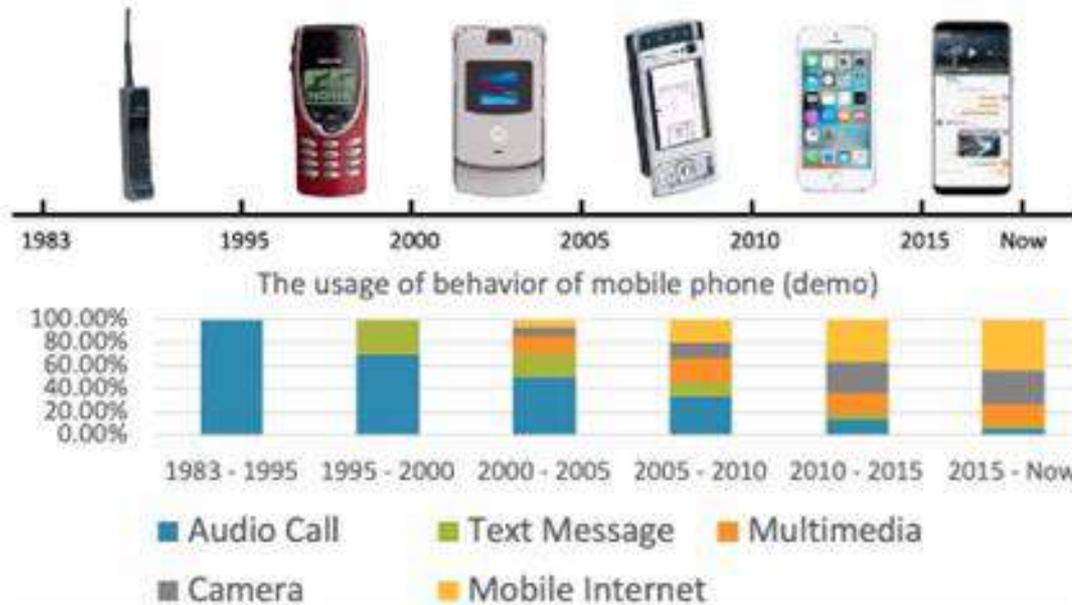
Sistemas e Redes de Comunicações / Sinais e Sistemas

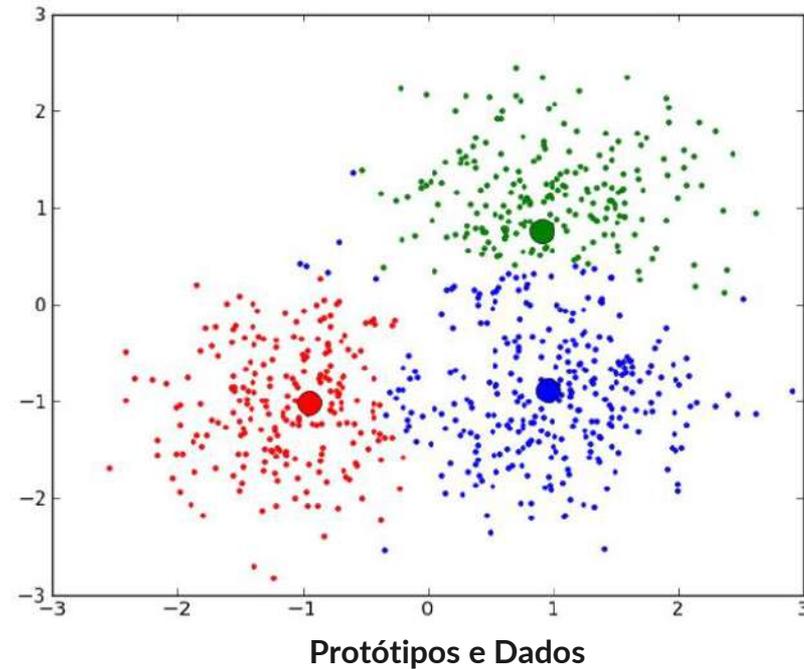
- Muitas aplicações atuais não possuem um banco de dados “estático”, visto que os dados são gerados em forma de fluxo contínuo (streaming)



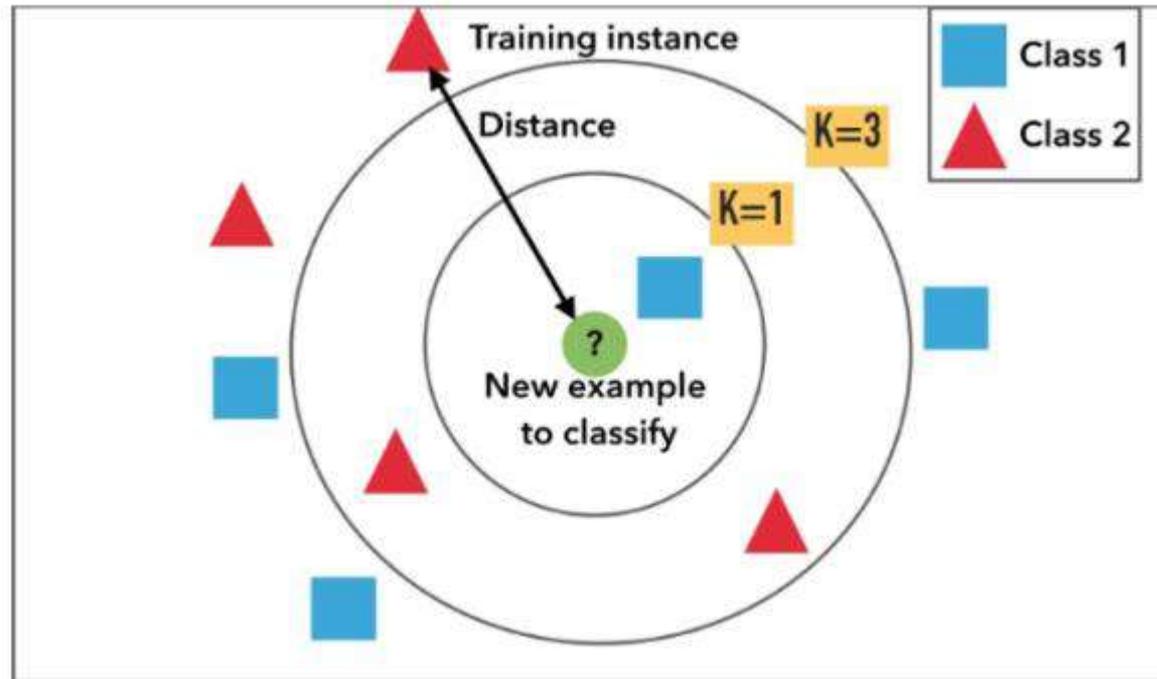


- Pouco tempo para treinar modelos
- Restrições de memória e hardware
- Mudança/Deriva de conceito (*Concept Drift*)



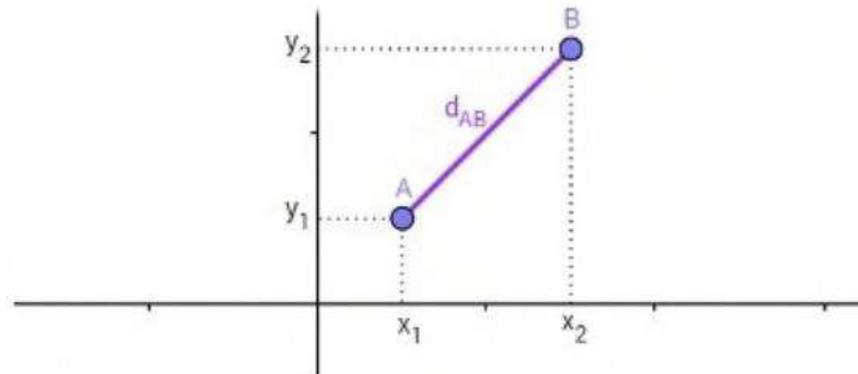


- Baseados em distâncias



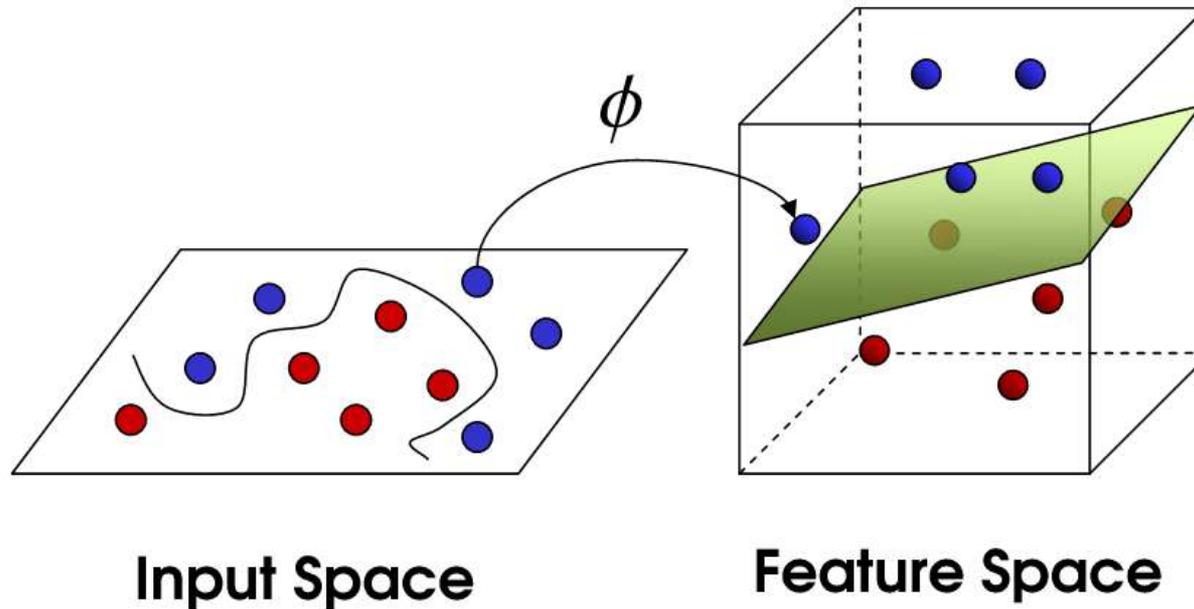


- Baseados em distâncias



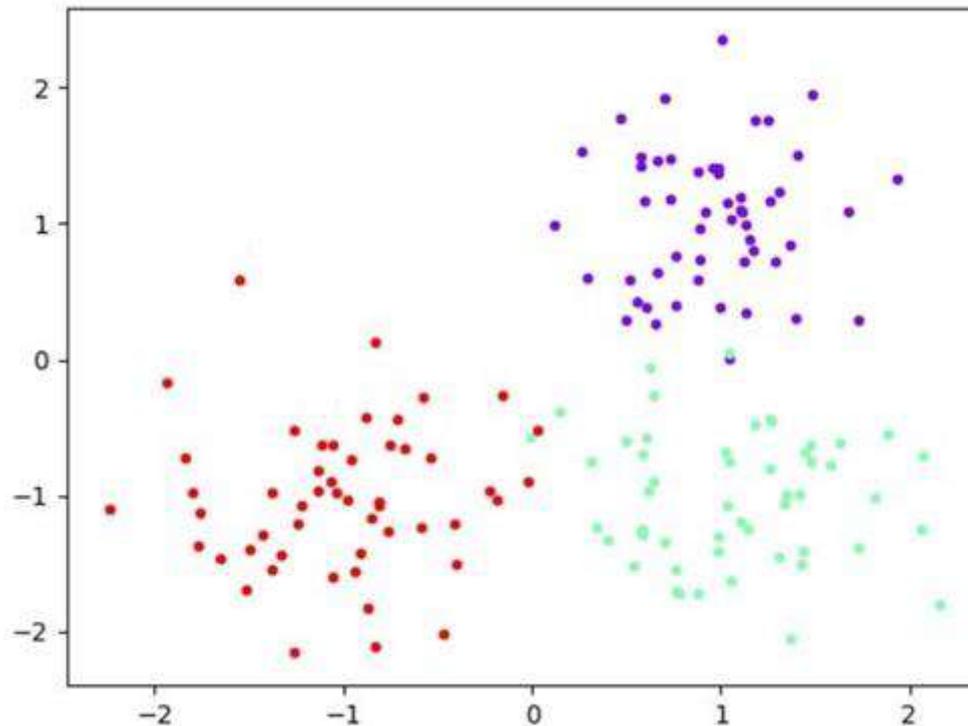
$$d_{AB} = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

- Truque de kernel

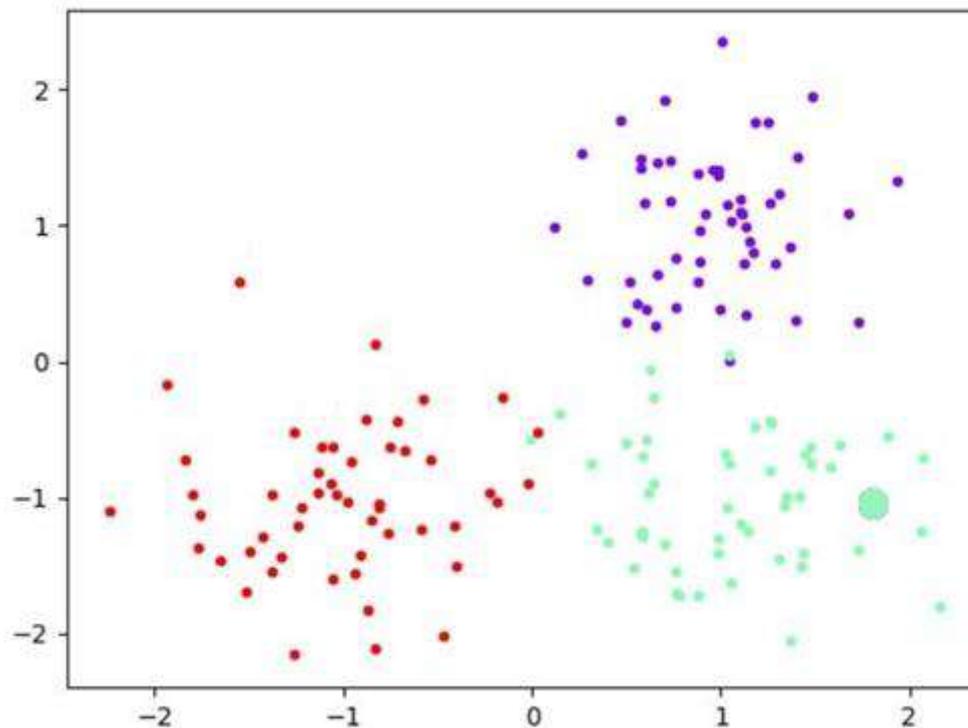




- Definição automática do número de protótipos: modelos esparsos

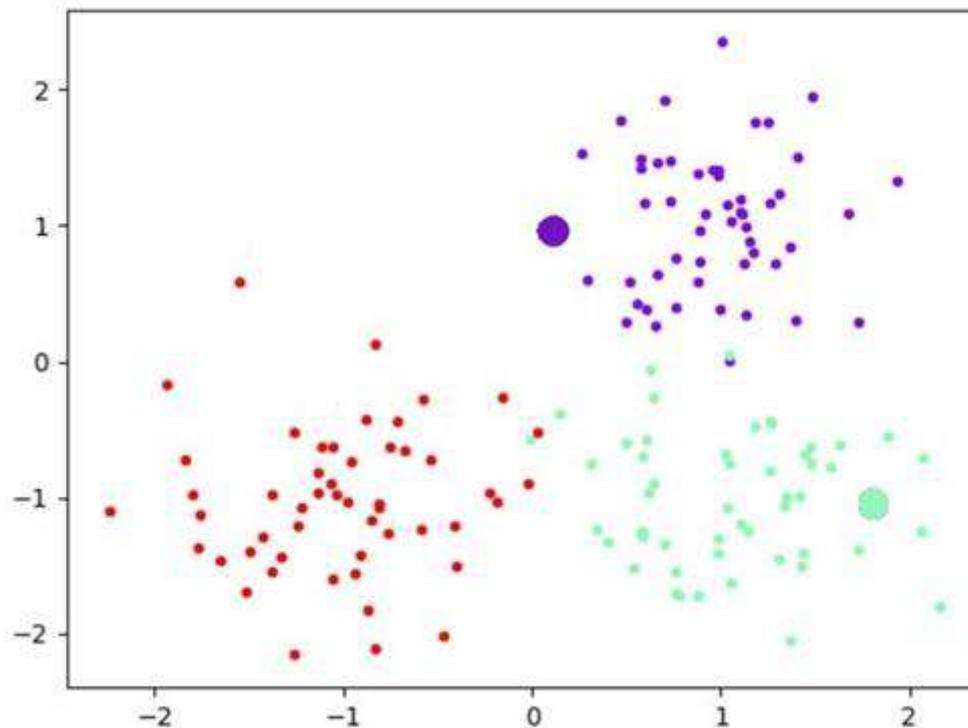


- Definição automática do número de protótipos: modelos esparsos

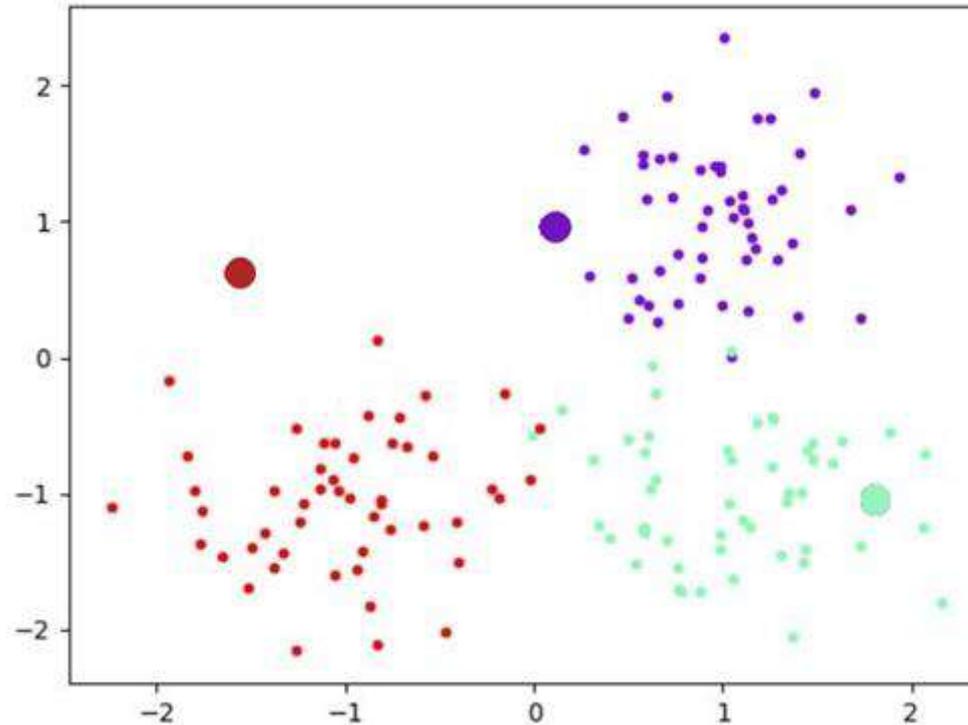




- Definição automática do número de protótipos: modelos esparsos

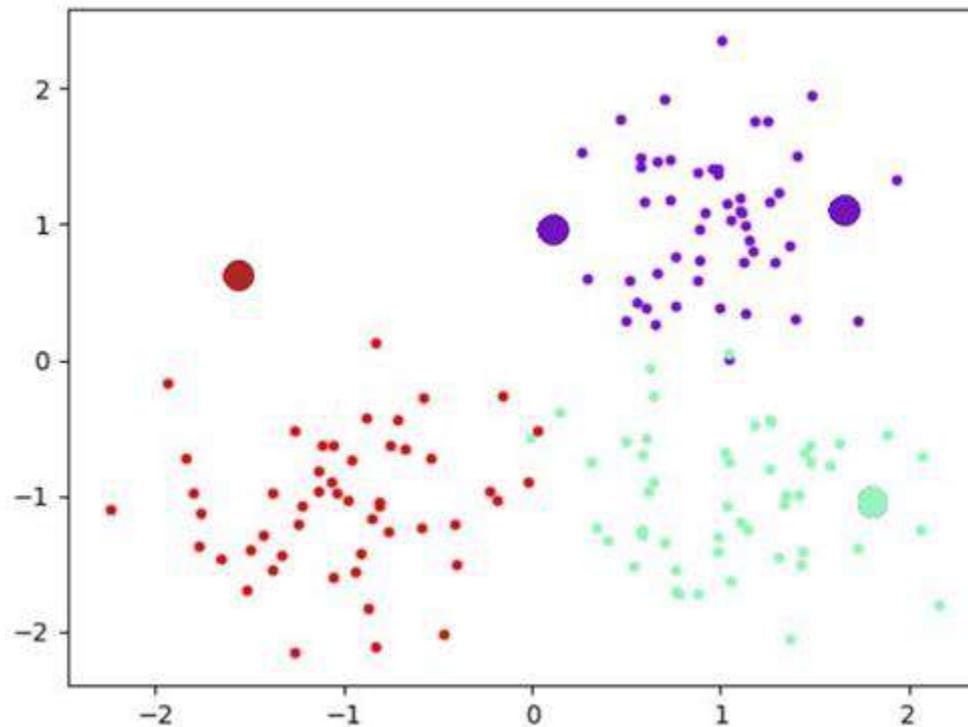


- Definição automática do número de protótipos: modelos esparsos

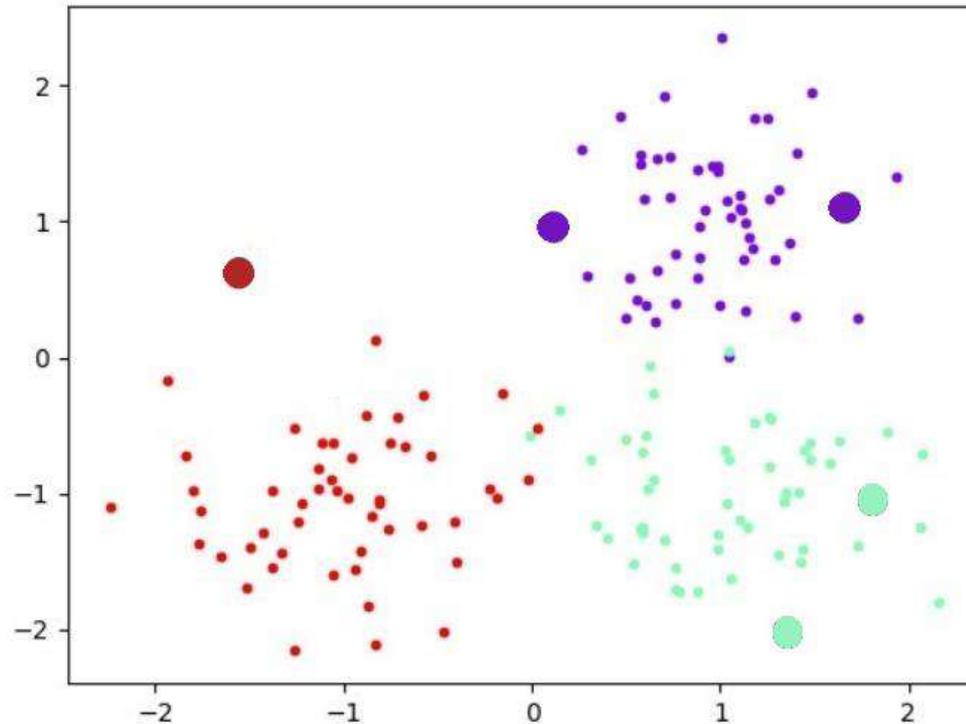




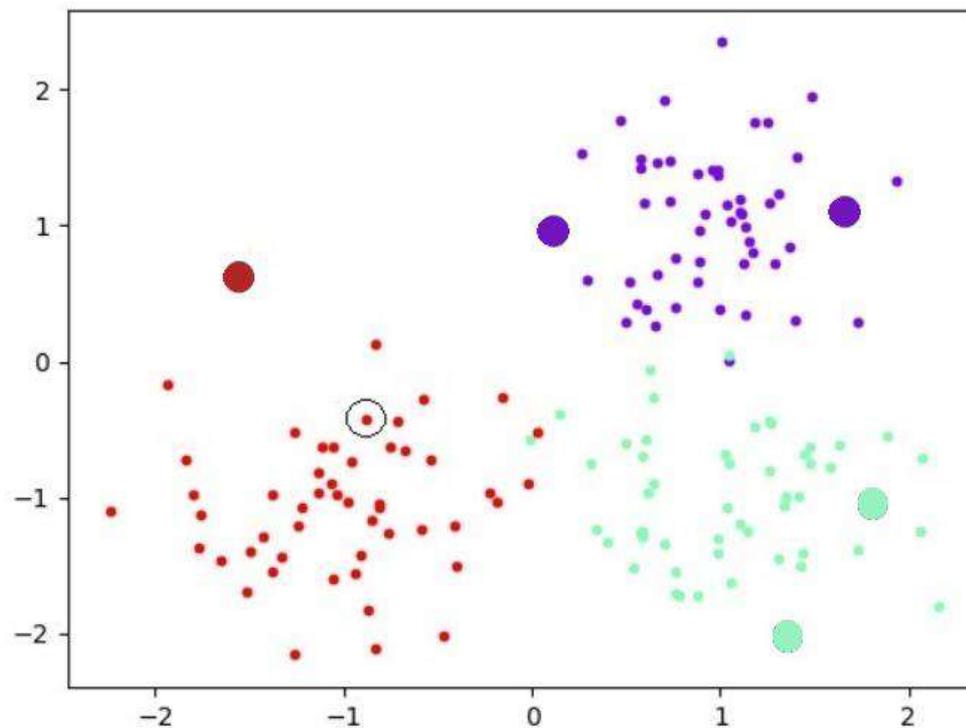
- Definição automática do número de protótipos: modelos esparsos



- Definição automática do número de protótipos: modelos esparsos

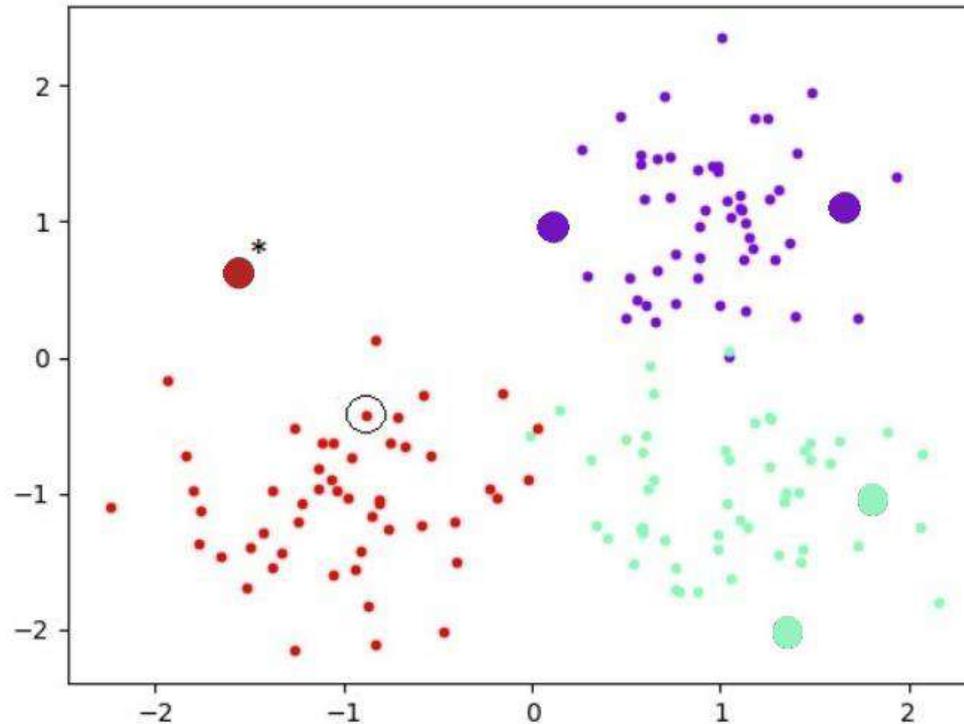


- Atualização dos pesos dos protótipos

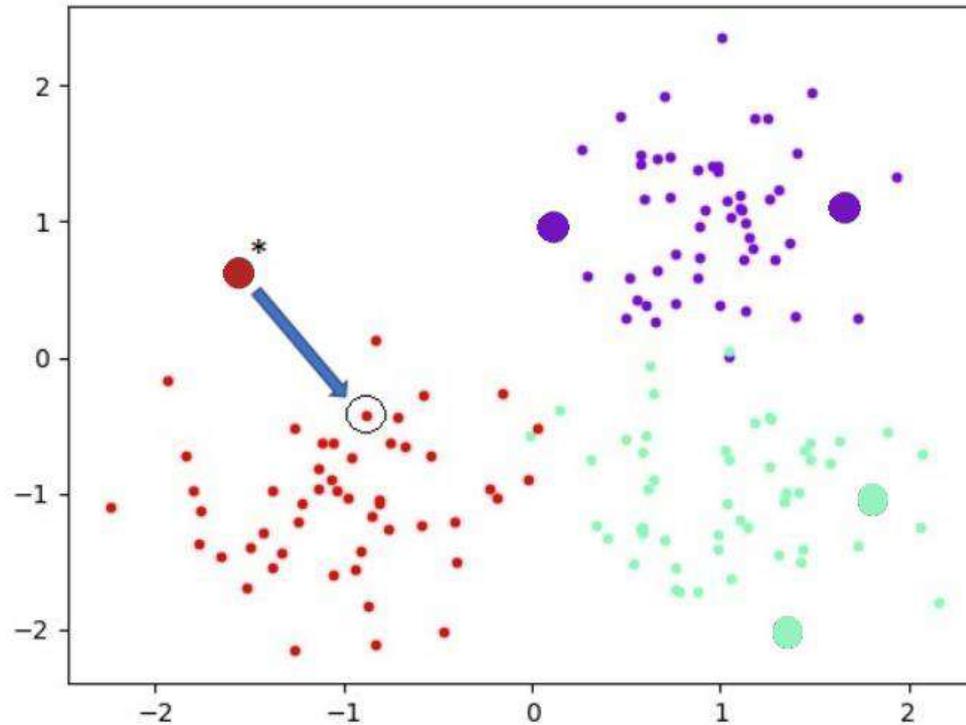




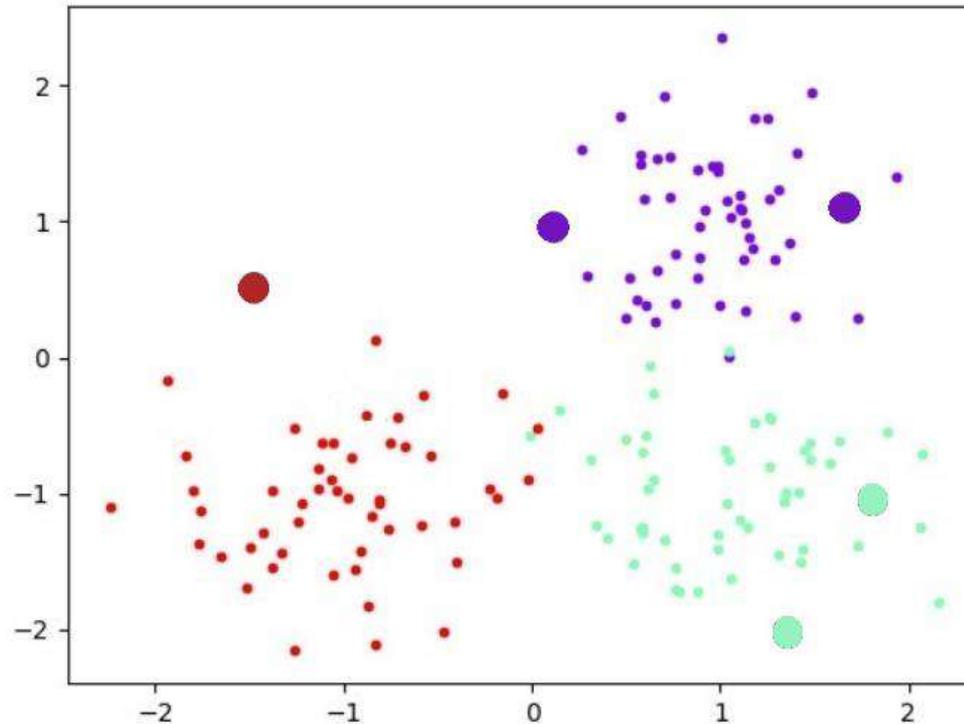
- Atualização dos pesos dos protótipos



- Atualização dos pesos dos protótipos

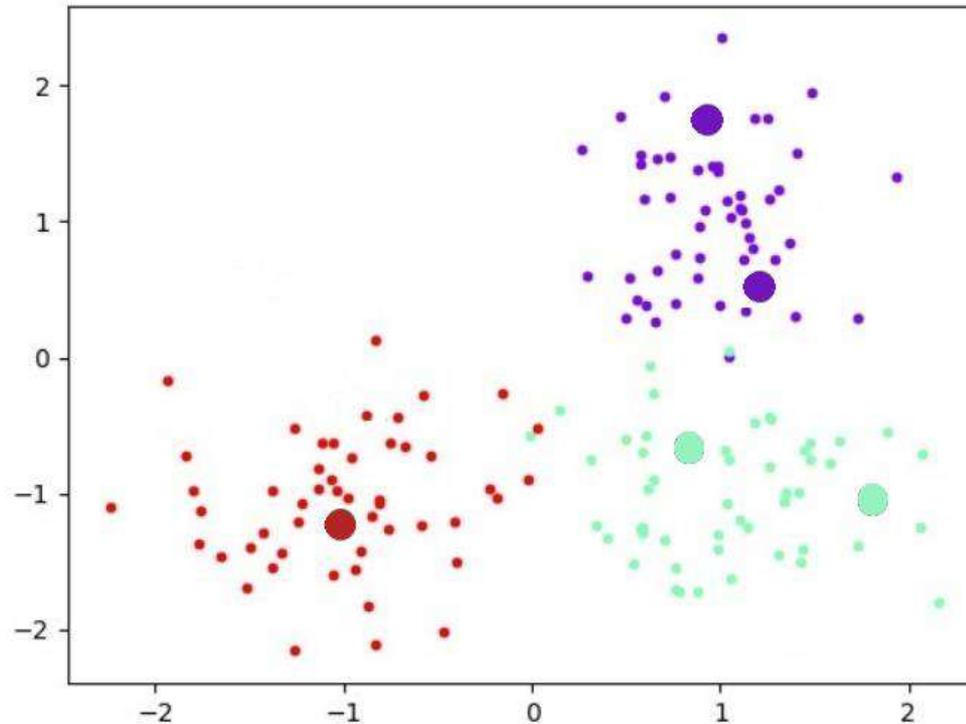


- Atualização dos pesos dos protótipos

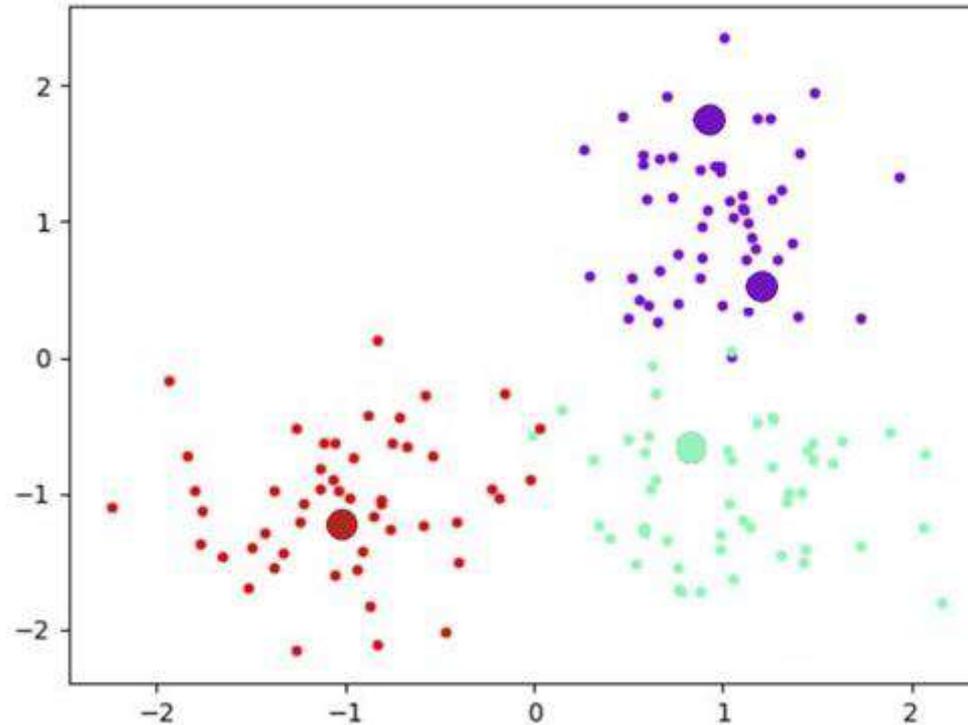




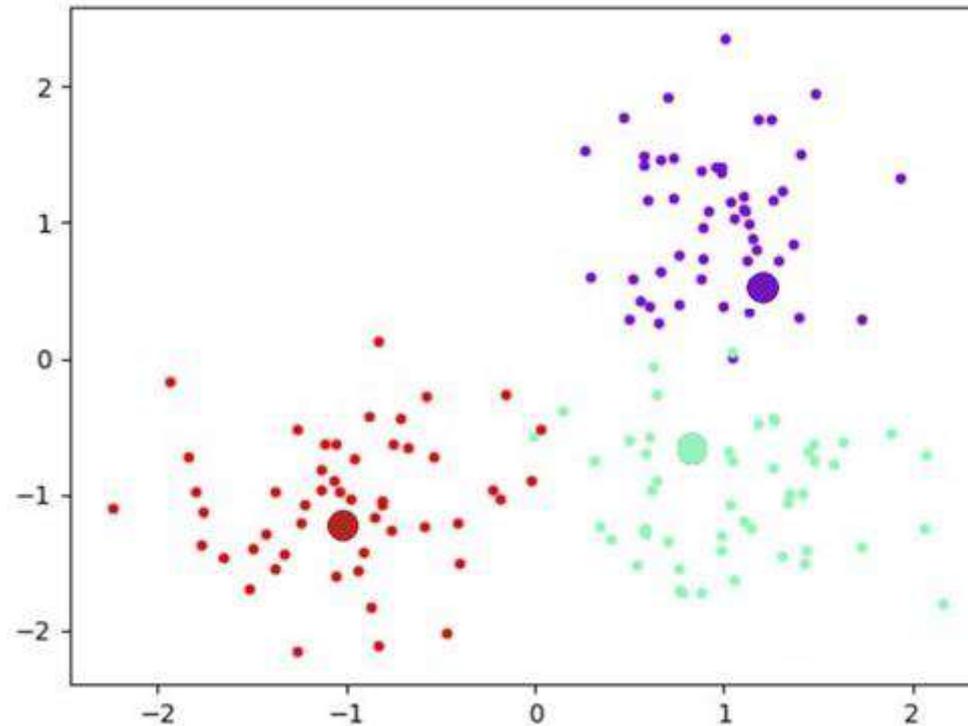
- Atualização dos pesos dos protótipos



- Remoção de protótipos



- Remoção de protótipos





- Estudo comparativo: Algoritmos aplicados à fluxo contínuo de dados

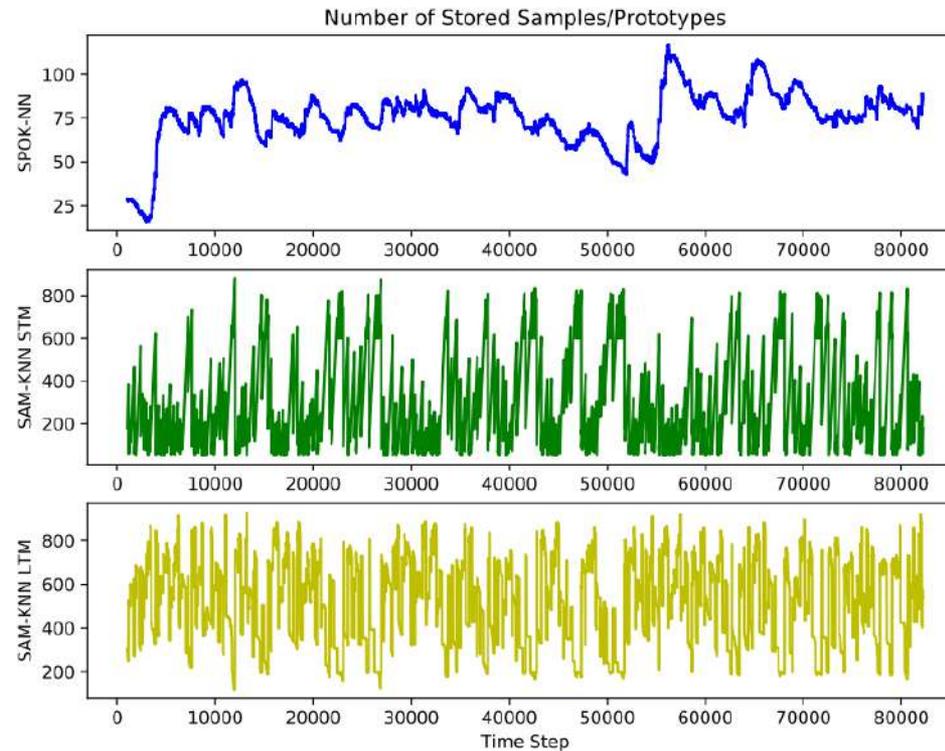
<b>Data Set</b>	<b>L++.NSE</b>	<b>DACC</b>	<b>LVGB</b>	<b>KNN<sub>s</sub></b>	<b>KNN<sub>W<sub>A</sub></sub></b>	<b>SAM</b>	<b>SPOK</b>
Coverttype	0.1500	0.1005	0.0907	0.0421	0.0676	0.0480	0.1167
Electricity	0.2724	0.1687	0.1678	0.2861	0.2613	0.1752	0.2582
Outdoor	0.5780	0.3565	0.3997	0.1398	0.1630	0.1125	0.1909
Poker Hand	0.2214	0.2097	0.1365	0.1708	0.2794	0.1845	0.2689
Rialto	0.4036	0.2893	0.3964	0.2274	0.2496	0.1858	0.3817
Weather	0.2288	0.2678	0.2189	0.2153	0.2311	0.2174	0.2590



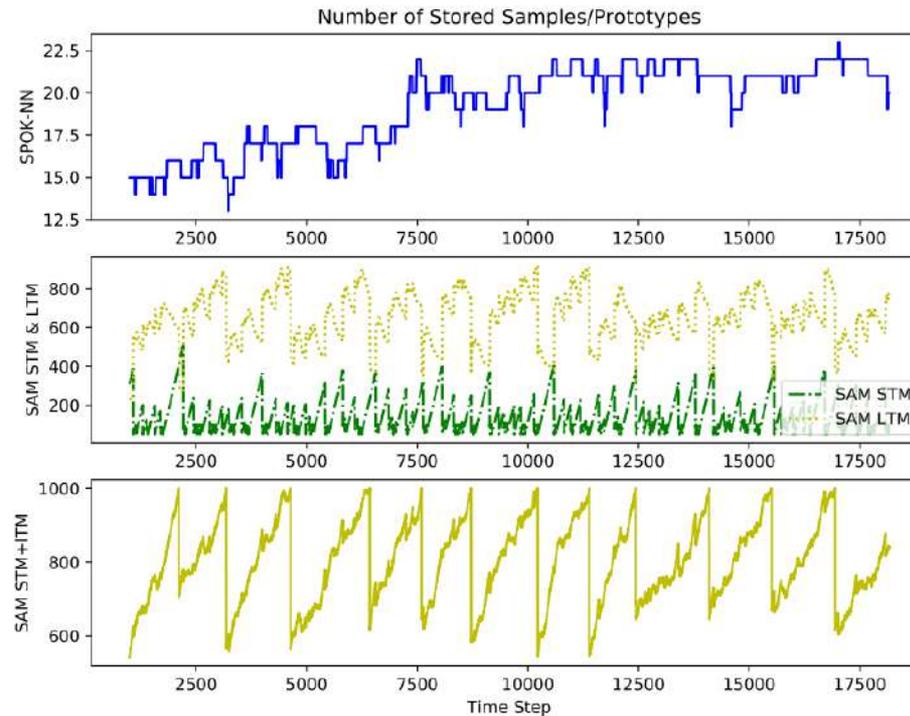
- Estudo comparativo: Algoritmos aplicados à fluxo contínuo de dados

Data set	SPOK-NN		Best Result		Worst Result	
	#Prot.	Error	Algorithm	Error	Algorithm	Error
CoverType	1000	0.1167	KNN <sub>s</sub>	0.0421	L++.NSE	0.1500
Electricity	1000	0.2582	LVGB	0.1678	KNN <sub>s</sub>	0.2861
Outdoor	192	0.1909	SAM-KNN	0.1125	L++.NSE	0.5780
Poker Hand	24	0.2689	LVGB	0.1365	PAW-KNN	0.2794
Rialto	89	0.3817	SAM-KNN	0.1858	L++.NSE	0.4036
Weather	20	0.2590	KNN <sub>s</sub>	0.2153	DACC	0.2678

- Estudo comparativo: Algoritmos aplicados à fluxo contínuo de dados



- Estudo comparativo: Algoritmos aplicados à fluxo contínuo de dados





- Estudo comparativo: Algoritmos aplicados à fluxo contínuo de dados

<b>Data Set</b>	<b>With Update</b>		<b>Without Update</b>	
	<b>Error</b>	<b>#Prot</b>	<b>Error</b>	<b>#Prot</b>
Moving Squares	0.0429	8	0.2239	19
RBF Int	0.0171	19	0.0517	18
Chessboard	0.1487	78	0.1923	164
Electricity	0.2582	1000	0.3443	860
Outdoor	0.1909	192	0.1741	615
Rialto	0.3817	89	0.4567	1000
Weather	0.2590	20	0.3670	11



- Comparação entre métodos de esparsidade, atualização e remoção de protótipos.
- Comparação entre funções de kernel
- Construção, a partir dos protótipos, de modelos mais complexos de classificação
- Adaptação do modelo SPOK para regressão



[david.coelho@sobral.ufc.br](mailto:david.coelho@sobral.ufc.br)



Universidade Federal do Ceará  
Programa de Pós-Graduação em  
Engenharia de Teleinformática



# Estimation of Bone Mineral Density using Machine Learning and SHapley Additive exPlanations

Elene Firmeza Ohata

Orientador: Pedro Pedrosa Rebouças Filho

Coorientadora: Atslands Rego da Rocha

Área: Sinais e Sistemas



- Osteoporosis is a disease that affects bones. Globally, more than 500 million people suffers from the disease [1].
- Early detection of bone mineral density (BMD) can facilitate early treatment or prevention measures [2].
- Various methods are available for measuring BMD, including the dual energy X-ray absorptiometry (DXA) technique [1].
- Machine Learning offers versatile and affordable methods for estimating BMD.



- Evaluate different BMD prediction methods using accessible attributes;
- Present a new BMD prediction dataset encompassing diverse body measurements and lifestyle habits;
- Analyze if ML models trained solely on one gender outperform those trained on the entire database;
- Interpret and analyze attribute impact on the model output to support algorithm.

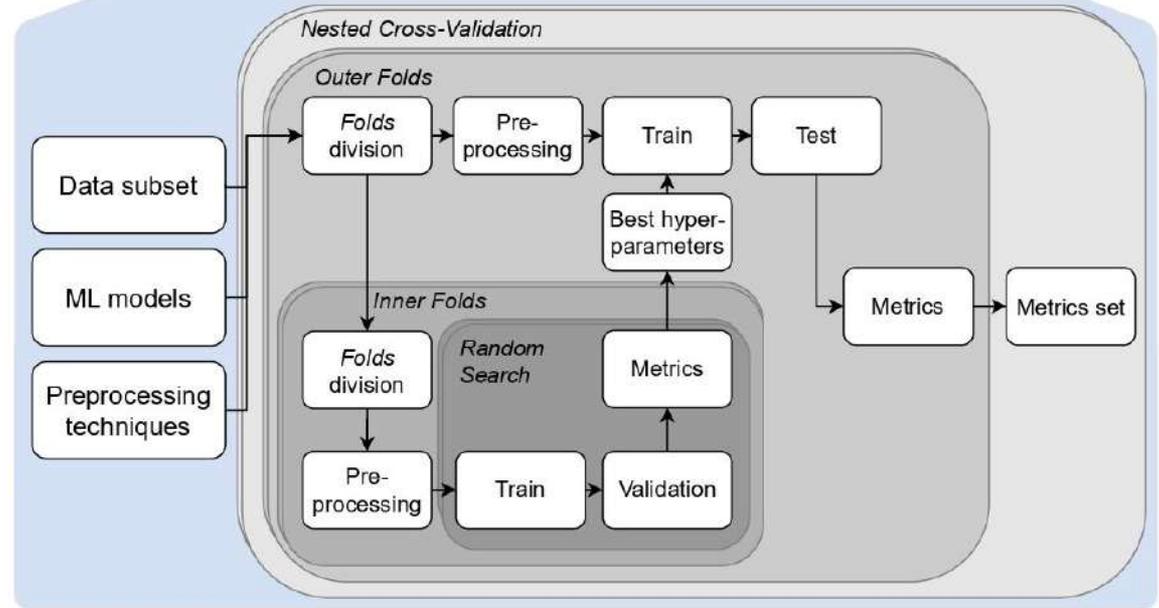
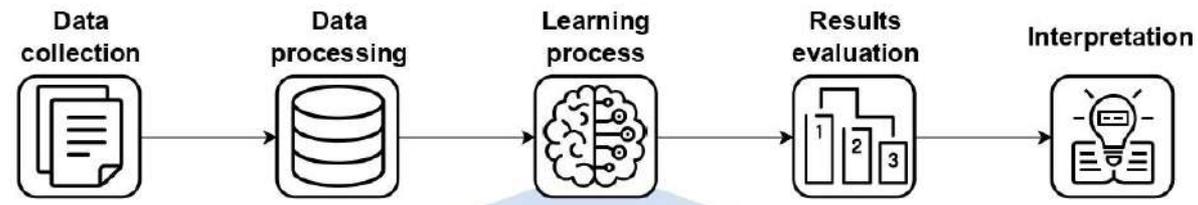


Fig 1. Flowchart of the proposed approach.

Table I. Means and standard deviations (in parentheses) of the evaluation metrics for the different model and preprocessing combinations in E1-A.

Preprocessing	Model	MAE (g/cm <sup>2</sup> )	RMSE (g/cm <sup>2</sup> )	MAPE (%)	ME (g/cm <sup>2</sup> )	R <sup>2</sup>
None	LR	0.0786 (0.0077)	0.0988 (0.0102)	6.49 (0.66)	0.2863 (0.0489)	0.4645 (0.0719)
None	EN	0.0784 (0.0075)	0.0986 (0.0099)	6.47 (0.65)	0.2856 (0.0478)	0.4665 (0.0698)
None	DT	0.0849 (0.0113)	0.1054 (0.0130)	7.00 (0.97)	0.2983 (0.0566)	0.3879 (0.1133)
None	MLP	0.0790 (0.0071)	0.0995 (0.0097)	6.53 (0.62)	0.2885 (0.0419)	0.4571 (0.0652)
None	k-NN	0.0790 (0.0074)	0.0986 (0.0097)	6.55 (0.63)	0.2736 (0.0458)	0.4659 (0.0712)
None	SVM_Lin	0.0934 (0.0212)	0.1186 (0.0287)	7.66 (1.77)	0.3477 (0.1283)	0.2101 (0.3328)
None	SVM_RBF	0.0776 (0.0068)	0.0990 (0.0117)	<b>6.39 (0.60)</b>	0.3071 (0.1033)	0.4609 (0.1004)
None	SVM_Pol	0.0805 (0.0071)	0.1018 (0.0091)	6.66 (0.62)	0.3000 (0.0453)	0.4270 (0.1031)
None	SVM_Sig	0.0821 (0.0112)	0.1037 (0.0130)	6.78 (0.93)	0.3028 (0.0478)	0.4033 (0.1383)
None	RF	0.0794 (0.0090)	0.0988 (0.0104)	6.55 (0.77)	0.2808 (0.0374)	0.4618 (0.0895)
None	XGBoost	0.0789 (0.0090)	0.0978 (0.0107)	6.50 (0.75)	0.2641 (0.0434)	0.4739 (0.0799)
MinMax	LR	0.0786 (0.0077)	0.0988 (0.0102)	6.49 (0.66)	0.2863 (0.0489)	0.4645 (0.0719)
MinMax	EN	0.0789 (0.0080)	0.0991 (0.0104)	6.51 (0.68)	0.2867 (0.0402)	0.4613 (0.0756)
MinMax	DT	0.0854 (0.0116)	0.1061 (0.0131)	7.04 (0.99)	0.2757 (0.0375)	0.3778 (0.1240)
MinMax	MLP	0.0793 (0.0080)	0.0997 (0.0107)	6.53 (0.67)	0.3001 (0.0650)	0.4545 (0.0808)
MinMax	k-NN	0.0819 (0.0078)	0.1022 (0.0090)	6.78 (0.67)	0.2880 (0.0382)	0.4284 (0.0526)
MinMax	SVM_Lin	0.0787 (0.0078)	0.0987 (0.0100)	6.49 (0.66)	0.2772 (0.0357)	0.4656 (0.0686)
MinMax	SVM_RBF	<b>0.0774 (0.0077)</b>	<b>0.0974 (0.0095)</b>	<b>6.39 (0.66)</b>	<b>0.2842 (0.0475)</b>	<b>0.4794 (0.0643)</b>
MinMax	SVM_Pol	0.0793 (0.0082)	0.1007 (0.0120)	6.54 (0.76)	0.3068 (0.1125)	0.4391 (0.1201)
MinMax	SVM_Sig	0.0788 (0.0076)	0.0988 (0.0098)	6.49 (0.65)	0.2766 (0.0373)	0.4644 (0.0664)
MinMax	RF	0.0784 (0.0090)	0.0981 (0.0110)	6.47 (0.77)	0.2704 (0.0466)	0.4713 (0.0865)
MinMax	XGBoost	0.0785 (0.0081)	0.0976 (0.0104)	6.47 (0.67)	<b>0.2634 (0.0425)</b>	0.4767 (0.0761)
Standardization	LR	0.0786 (0.0077)	0.0988 (0.0102)	6.49 (0.66)	0.2863 (0.0489)	0.4645 (0.0719)
Standardization	EN	0.0783 (0.0078)	0.0983 (0.0099)	6.46 (0.67)	0.2806 (0.0382)	0.4697 (0.0677)
Standardization	DT	0.0845 (0.0113)	0.1054 (0.0131)	6.98 (0.97)	0.2970 (0.0591)	0.3871 (0.1199)
Standardization	MLP	0.0802 (0.0082)	0.1000 (0.0105)	6.61 (0.70)	0.2904 (0.0503)	0.4510 (0.0752)
Standardization	k-NN	0.0794 (0.0078)	0.0992 (0.0095)	6.58 (0.67)	0.2834 (0.0414)	0.4615 (0.0610)
Standardization	SVM_Lin	0.0786 (0.0077)	0.0987 (0.0102)	6.48 (0.66)	0.2790 (0.0482)	0.4665 (0.0685)
Standardization	SVM_RBF	0.0786 (0.0077)	0.0984 (0.0095)	6.49 (0.65)	0.2799 (0.0415)	0.4688 (0.0672)
Standardization	SVM_Pol	0.0912 (0.0072)	0.1161 (0.0105)	7.52 (0.69)	0.3392 (0.0666)	0.2567 (0.1205)
Standardization	SVM_Sig	0.0781 (0.0075)	0.0981 (0.0097)	6.44 (0.64)	0.2750 (0.0405)	0.4720 (0.0647)
Standardization	RF	0.0782 (0.0079)	0.0976 (0.0098)	6.45 (0.69)	0.2794 (0.0362)	0.4753 (0.0814)
Standardization	XGBoost	0.0789 (0.0084)	0.0983 (0.0105)	6.51 (0.71)	0.2669 (0.0418)	0.4688 (0.0769)

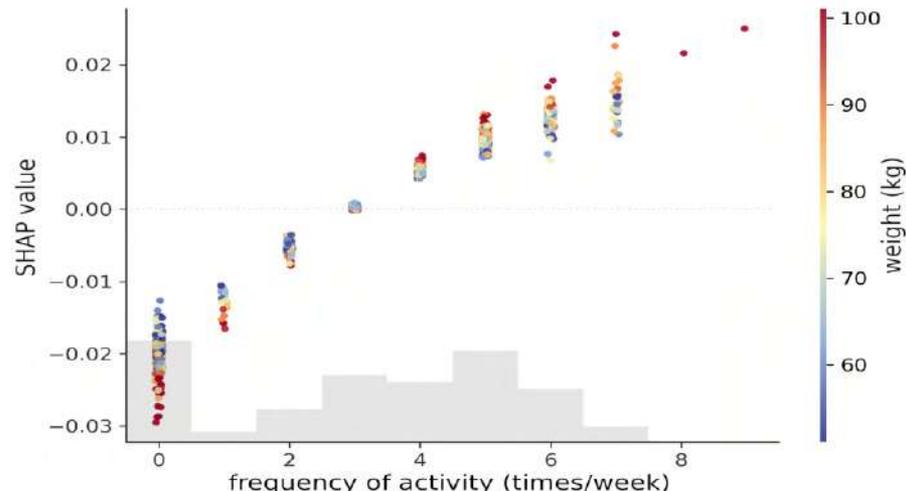


Fig 2. Behavior of SHAP values according to the relationship between frequency of activity and weight.

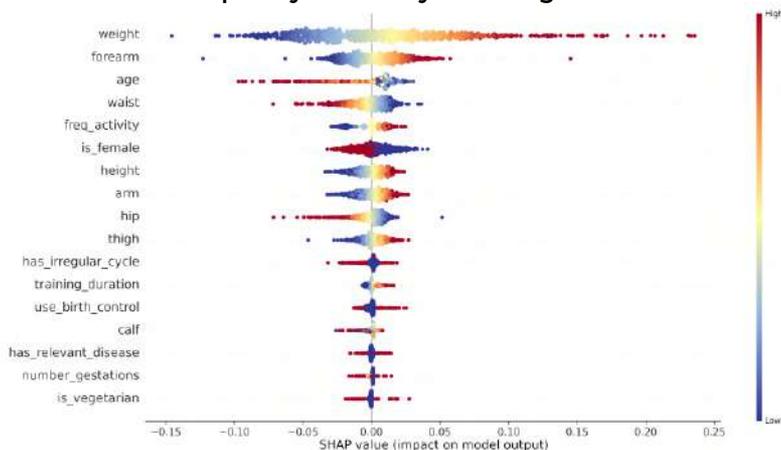
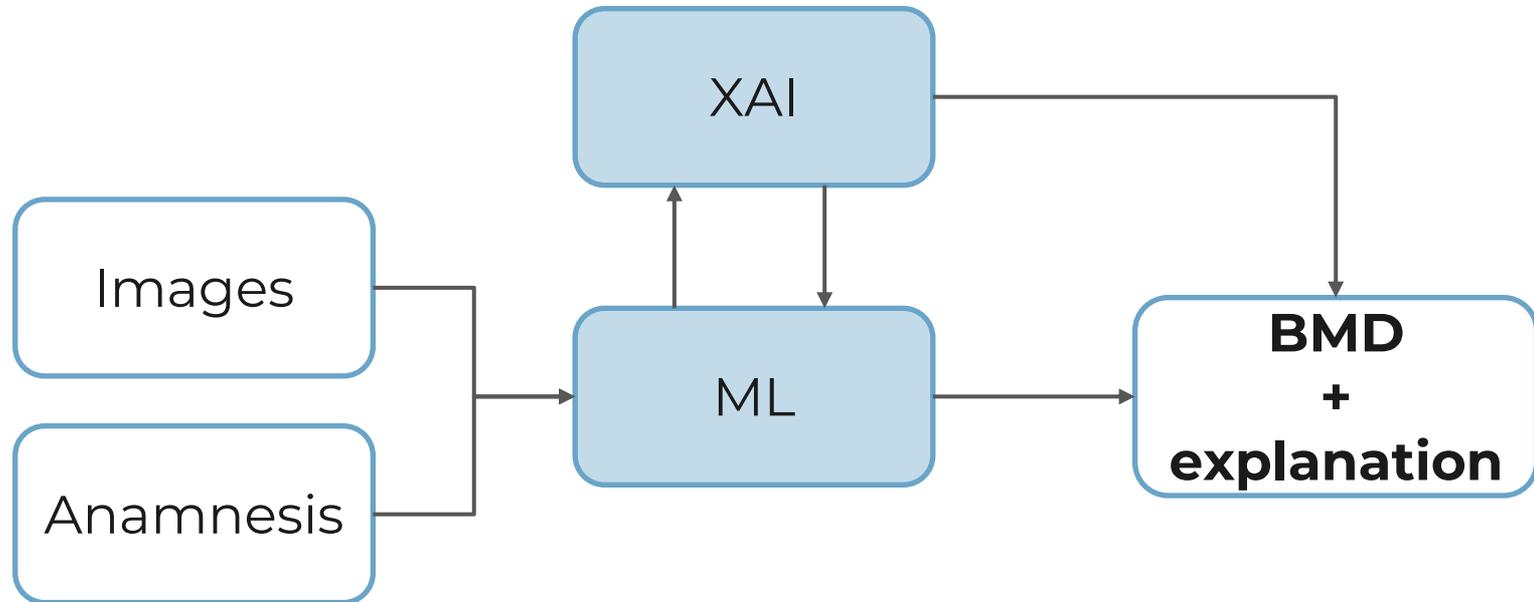


Fig 3. Behavior of SHAP values according to attribute values.





Universidade Federal do Ceará  
Programa de Pós-Graduação em  
Engenharia de Teleinformática



# Data Quality to Federated Learning Performance Improvement

Ernesto Gurgel Valente Neto

Advisor: Julio César Santos dos Anjos

Co-advisor: Solon A. Peixoto Jr.

Field of Study:

PATTERN RECOGNITION AND DYNAMIC SYSTEMS / SIGNALS AND SYSTEMS

The main challenges:

- Large volumes of data from devices with **low computational and energy capacity**.
- **Heterogeneous and non-IID** nature of the data.
- Difficulty in **scalability** and **integration**.
- High cost for algorithm **convergence**.
- Communication **bottlenecks** and **device limitations**.

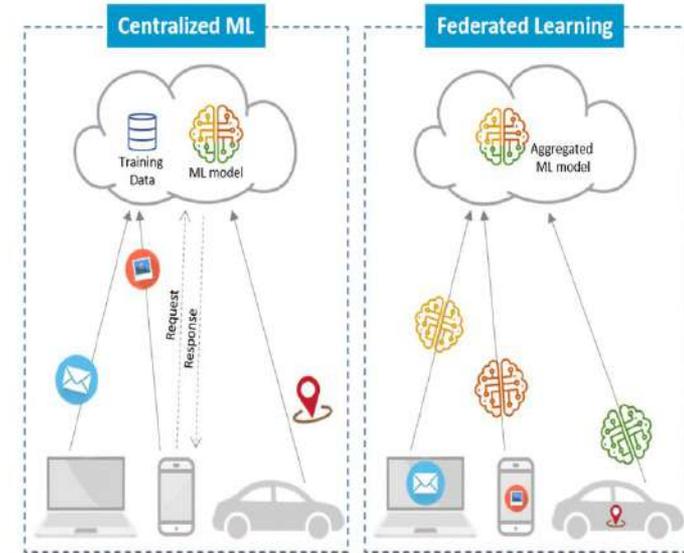


Figure 1: AI Learning Strategies

[D. van Tilborg et al. 2024] [C. Chakraborty et al. 2023] [M. F. Criado al. 2022] [J.C.S. Dos Anjos et al. 2023] [S. Chintala et al. (2024)] [A. Imteaj et al. (2022)] [T. Gafni et al. (2022)]

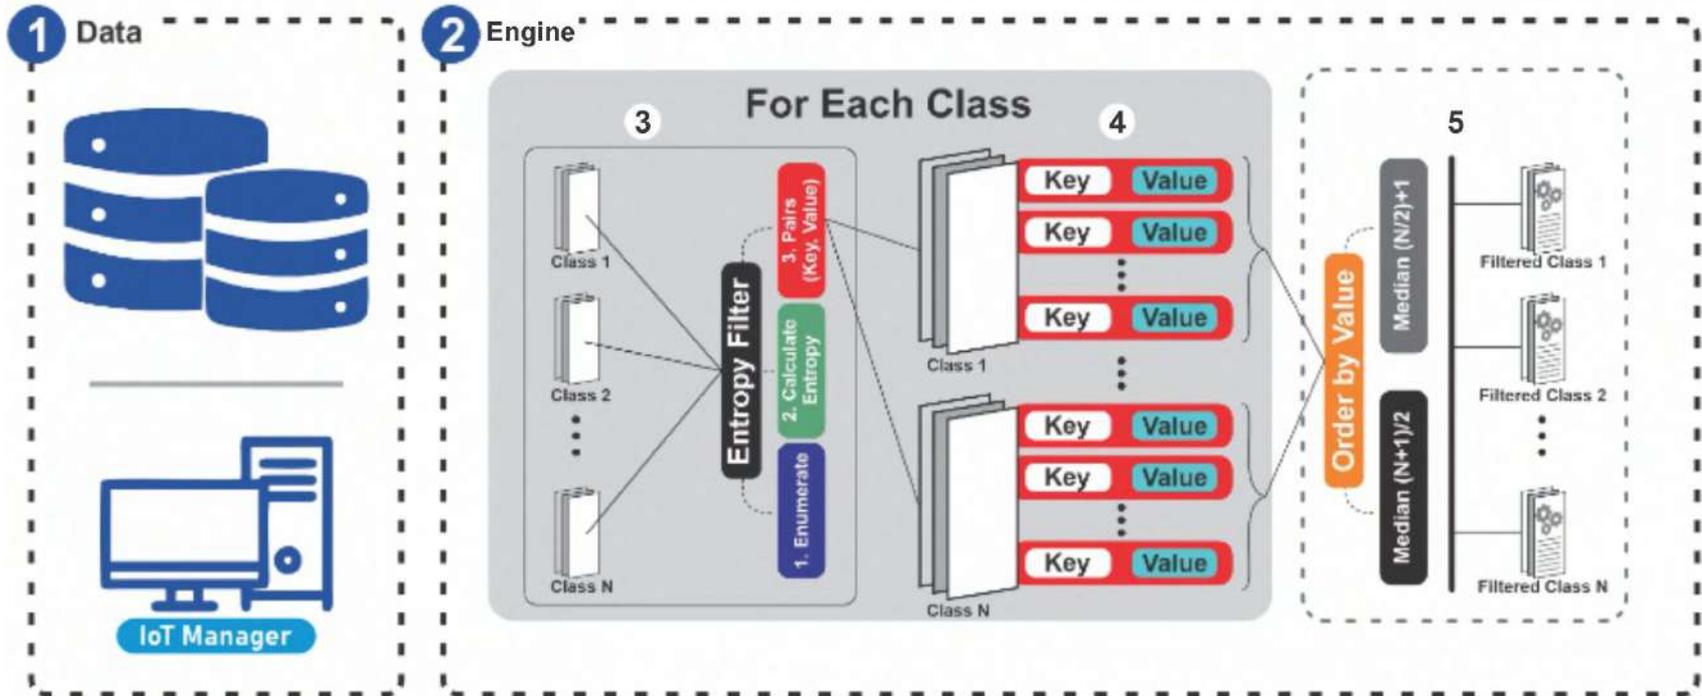


Figure 2: Embedded Model - **Entropy-Based Selection (EnBaSe)**

Tabela: Results for Scenario iid for centralized learning.

Dataset	Balancing	Dataset Role	Accuracy (%)	Sensitivity (%)	Loss	Avg. Time (s)
MNIST	All Data	Training	≈ 99.5	≈ 99.5	≈ 0.038	≈ 73
		Validation	≈ 98.9	≈ 98.9	≈ 0.049	
	EnBaSe	<b>Training</b>	≈ <b>99.2</b>	≈ <b>99.2</b>	≈ <b>0.069</b>	≈ <b>32</b>
		<b>Validation</b>	≈ <b>98.6</b>	≈ <b>98.6</b>	≈ <b>0.050</b>	
Fashion-MNIST	All Data	Training	≈ 92.1	≈ 92.1	≈ 0.278	≈ 17
		Validation	≈ 90.7	≈ 90.7	≈ 0.253	
	EnBaSe	<b>Training</b>	≈ <b>92.4</b>	≈ <b>92.4</b>	≈ <b>0.262</b>	≈ <b>10</b>
		<b>Validation</b>	≈ <b>91.0</b>	≈ <b>91.0</b>	≈ <b>0.246</b>	
CIFAR-10	All Data	Training	≈ 90.9	≈ 90.9	≈ 0.395	≈ 1019
		Validation	≈ 86.4	≈ 86.4	≈ 0.403	
	EnBaSe	<b>Training</b>	≈ <b>89.2</b>	≈ <b>89.2</b>	≈ <b>0.441</b>	≈ <b>501</b>
		<b>Validation</b>	≈ <b>82.0</b>	≈ <b>82.0</b>	≈ <b>0.558</b>	
CIFAR-100	All Data	Training	≈ 79.3	≈ 79.3	≈ 0.952	≈ 16393
		Validation	≈ 72.2	≈ 72.3	≈ 1.151	
	EnBaSe	<b>Training</b>	≈ <b>77.7</b>	≈ <b>77.7</b>	≈ <b>0.952</b>	≈ <b>8778</b>
		<b>Validation</b>	≈ <b>68.1</b>	≈ <b>68.1</b>	≈ <b>1.151</b>	

Tabela: Results for non-iid scenario with federated learning.

Dataset	Balancing	Global Alg.	Precision (%)	Sensitivity (%)	F1-Score (%)	Accuracy (%)	Avg. Time (s)
<b>MNIST</b>	All Data	FedAvg	≈ 74.4	≈ 74.5	≈ 71.8	≈ 85.7	≈ 1096
	<b>EnBaSe</b>	<b>FedAvg</b>	≈ <b>65.9</b>	≈ <b>66.4</b>	≈ <b>62.7</b>	≈ 78.9	≈ <b>586</b>
	All Data	FedProx	≈ 69.3	≈ 71.4	≈ 67.5	≈ 81.7	≈ 1180
	<b>EnBaSe</b>	<b>FedProx</b>	≈ <b>69.3</b>	≈ <b>68.9</b>	≈ <b>66.0</b>	≈ <b>81.2</b>	≈ <b>629</b>
<b>Fashion</b>	All Data	FedAvg	≈ 56.7	≈ 52.8	≈ 47.4	≈ 62.2	≈ 1084
	<b>EnBaSe</b>	<b>FedAvg</b>	≈ <b>53.7</b>	≈ <b>49.7</b>	≈ <b>45.4</b>	≈ <b>58.8</b>	≈ <b>556</b>
	All Data	FedProx	≈ 60.3	≈ 57.0	≈ 52.3	≈ 66.4	≈ 1125
	<b>EnBaSe</b>	<b>FedProx</b>	≈ <b>55.7</b>	≈ <b>52.3</b>	≈ <b>47.5</b>	≈ <b>60.8</b>	≈ <b>601</b>
<b>CIFAR-10</b>	All Data	FedAvg	≈ 47.4	≈ 71.7	≈ 33.9	≈ 42.4	≈ 14941
	<b>EnBaSe</b>	<b>FedAvg</b>	≈ <b>43.8</b>	≈ <b>38.3</b>	≈ <b>32.7</b>	≈ <b>40.3</b>	≈ <b>8259</b>
	All Data	FedProx	≈ 46.1	≈ 38.7	≈ 32.3	≈ 39.5	≈ 15662
	<b>EnBaSe</b>	<b>FedProx</b>	≈ <b>45.0</b>	≈ <b>38.1</b>	≈ <b>32.2</b>	≈ <b>39.9</b>	≈ <b>8413</b>
<b>CIFAR-100</b>	All Data	FedAvg	≈ 47.8	≈ 41.2	≈ 34.8	≈ 43.2	≈ 15214
	<b>EnBaSe</b>	<b>FedAvg</b>	≈ <b>44.3</b>	≈ <b>38.6</b>	≈ <b>32.8</b>	≈ <b>41.6</b>	≈ <b>8132</b>
	All Data	FedProx	≈ 55.4	≈ 55.9	≈ 51.9	≈ 63.0	≈ 18020
	<b>EnBaSe</b>	<b>FedProx</b>	≈ <b>48.0</b>	≈ <b>46.4</b>	≈ <b>43.0</b>	≈ <b>53.5</b>	≈ <b>8202</b>



The main conclusions of the research are:

- An algorithm for **centralized** and **decentralized** learning in **deep learning**.
- **Reduction in computational cost** and **acceleration of convergence** time.
- Data selection completed in an **average of 3 seconds**, with a **3% accuracy loss**.
- **Reduction** in computing and energy costs.
- The model significantly **accelerates the convergence** of neural networks.

Future Works:

- Validate the proposal on **larger datasets** and **cases**.
- Analyze the possibility of creating a new **layer in Deep Learning Networks**.



- D. van Tilborg, H. Brinkmann, E. Criscuolo, L. Rossen, R. Özçelik, & F. Grisoni (2024). "Deep learning for low-data drug discovery: hurdles and opportunities", *Current Opinion in Structural Biology*, 86:102818. Elsevier.
- C. Chakraborty, M. Bhattacharya, S. Pal, & S.-S. Lee (2023). "From machine learning to deep learning: An advances of the recent data-driven paradigm shift in medicine and healthcare", *Current Research in Biotechnology*, 100164. Elsevier.
- M. F. Criado, F. E. Casado, R. Iglesias, C. V. Regueiro, and S. Barro, "Non-iid data and continual learning processes in federated learning: A long road ahead," *Information Fusion*, vol. 88, pp. 263–280, 2022.
- J.C.S. Dos Anjos, K.J. Matteussi, F.C. Orlandi, J.L.V. Barbosa, J.S. Silva, L.F. Bittencourt, & C.F.R. Geyer (2023). "A survey on collaborative learning for intelligent autonomous systems", *ACM Computing Surveys*, 56(4):1–37. ACM New York, NY.
- M.M. Bassiouni, R.K. Chakraborty, K.M. Sallam, & O.K. Hussain (2024). "Deep learning approaches to identify order status in a complex supply chain", *Expert Systems with Applications*, 250:123947. Elsevier.
- S. Chintala, "IoT and AI synergy: Remote patient monitoring for improved healthcare," in 2024 4th International Conference on Innovative Practices in Technology and Management (ICIPTM). IEEE, 2024, pp. 1–6.
- A. Imteaj, U. Thakker, S. Wang, J. Li & M. H. Amini (2022). "A Survey on Federated Learning for Resource-Constrained IoT Devices", *IEEE Internet of Things Journal*, 9(1):1–24. DOI: 10.1109/JIOT.2021.3095077.
- T. Gafni, N. Shlezinger, K. Cohen, Y. C. Eldar & H. V. Poor (2022). "Federated learning: A signal processing perspective", *IEEE Signal Processing Magazine*, 39(3):14–41. DOI: 10.1109/MSP.2021.3125282.



Universidade Federal do Ceará  
Programa de Pós-Graduação em  
Engenharia de Teleinformática



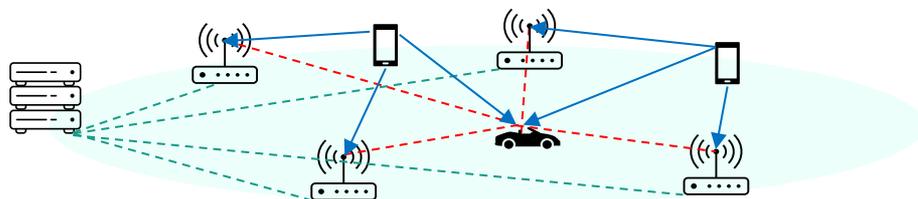
# Otimização de tecnologias emergentes em redes 6G

Ezequias M. S. de Santana Jr.

Orientador: Yuri Carvalho Barbosa Silva

Sistemas e Redes de Comunicações / Sinais e Sistemas

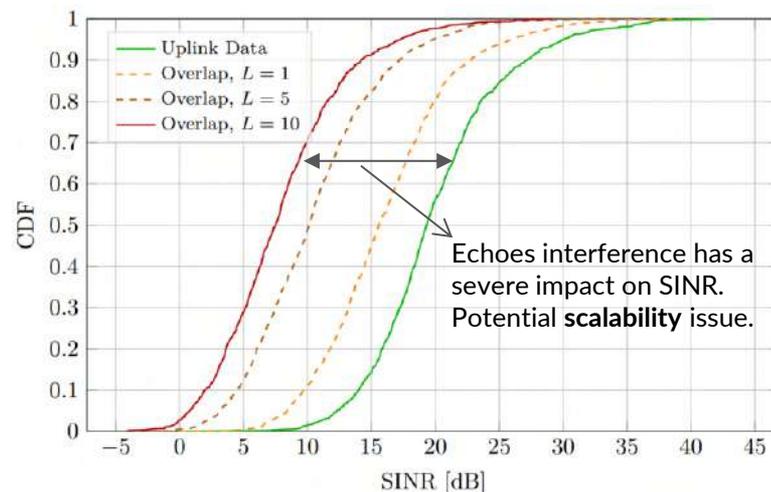
- **Cell-free** systems consider densely deployed APs over a certain geographic area
  - Benefit from the macro-diversity gains; Centralized architecture (C-RAN)
- **ISAC** is accomplished by the design of systems that enable the joint operation of wireless communication and remote sensing applications
  - Optimize and share the system infrastructure, resources and signals between **communication** and **sensing**



**Fig. 1** Depiction of a CF JCAS scenario. Here Uplink sensing is being performed by UEs sending Pilot Signals that are being reflected at the target and received at several APs.

**Scalability problem** → **Efficient power allocation.**

- **Next steps:** Power allocation for spectral efficiency optimization considering sensing constraints



**Fig. 2** CDF of the SINR of the received signal for the uplink data period and overlapping period when varying the number of targets  $L$  for an RCS of 10dB.

- Wireless communications technologies are evolving towards 6G
  - Large bandwidth, 3D beamforming, larger antenna arrays
- Measurement methods are crucial for **channel model parametrization**, providing reliability and modeling accuracy for statistical channel models
  - Generating **accurate** wideband channel impulse responses



Fig. 3: Experiment scenario. Here, 46 Tx devices transmit to a BS. Channel samples were logged and analyzed, extracting LSPs.

Observed positive correlated values in the measurements, specially for **NLOS UEs**. **Higher values** in comparison with 3GPP.

- **Next steps:** Comparison with parametrized channel models using extracted LSPs

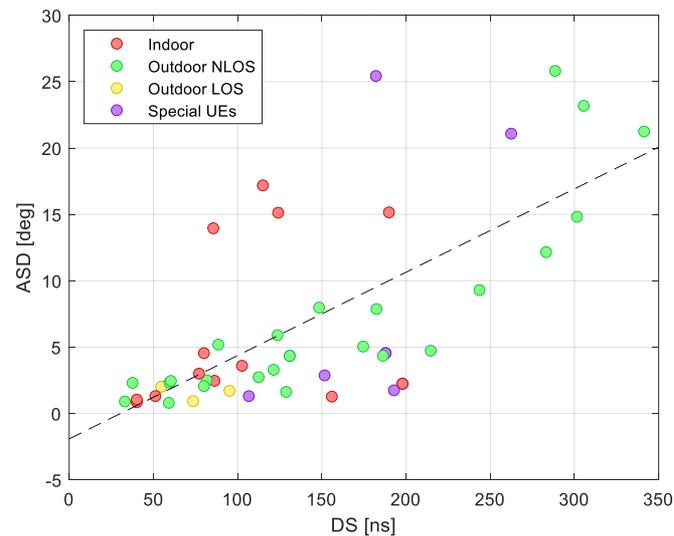


Fig. 4 Scatter plot: Delay Spread vs Azimuth Spread of Departure. The measured LSPs presented a positive cross correlation between parameters.

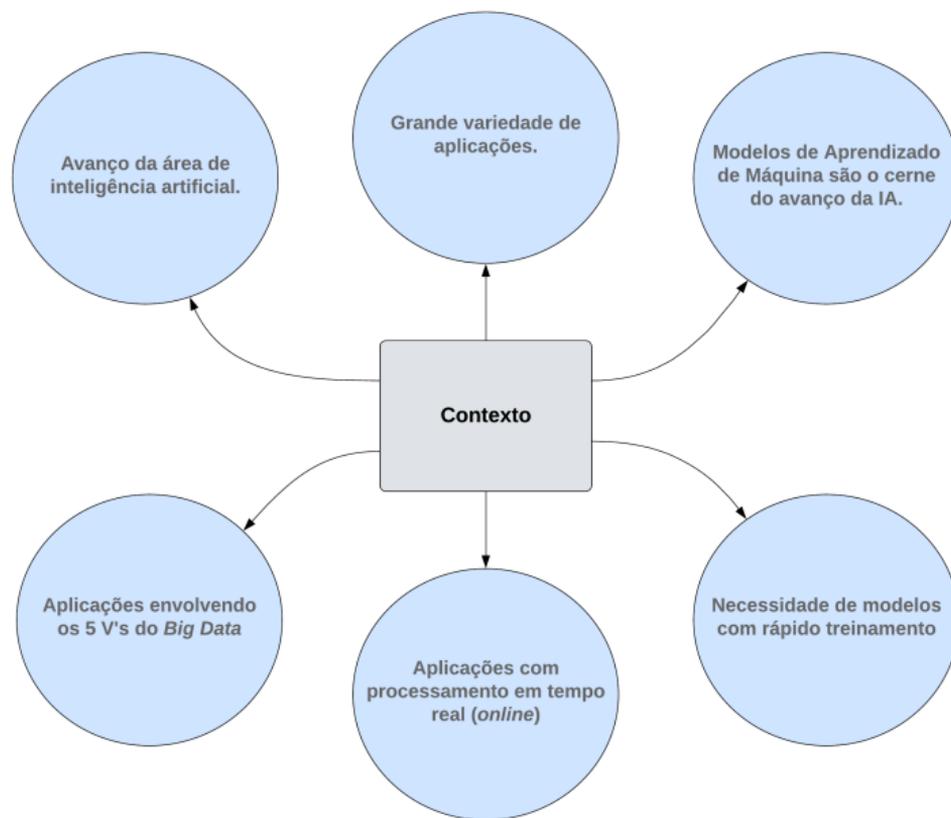


# Novas propostas para aceleração do treinamento de Máquinas de Vetores de Suporte por Mínimos Quadrados

Felipe Pinto Marinho

Ajalmar Rêgo da Rocha Neto

Sinais e Sistemas / Reconhecimento de Padrões e Sistemas Dinâmicos



SVM	<p>O tempo para realização do treinamento cresce exponencialmente com o aumento do número de registros da base, principalmente, devido ao uso da matriz de kernel.</p> 	<p>Robustez da performance preditiva e elegante formalismo matemático</p> 
LSSVM	<p>O tempo para realização do treinamento cresce exponencialmente com o aumento do número de registros da base, principalmente, devido ao uso da matriz de kernel.</p> 	<p>Perda da esparsidade no vetor ótimo de multiplicadores de Lagrange do problema Dual.</p> 

**Legenda:**  Vantagens  Desvantagens

## LSSVM\_ADMM

$$\min_{\alpha} \frac{1}{2} \|\mathbf{A}\alpha - \mathbf{b}\|^2$$

$$s. t. |\beta|_1 \leq \tau$$

$$\mathbf{A}\alpha = \mathbf{b}$$

$$\mathbf{A} = \mathbf{P}^T$$

$$\mathbf{b} = [\tau\mathbf{I} + \mathbf{P}\mathbf{P}^T]^{-1}\mathbf{y}$$

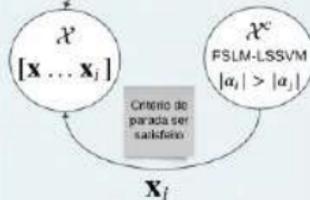
ADMM

$\alpha^*$  esparsos

## FSLM\_LSSVM Inverse

DBSCAN

PUREZA



## TCSMO-LSSVM

Seleção do par de multiplicadores

$$i = \operatorname{argmax} |\mathbf{G}_1(\alpha^k)|$$

$$j = \operatorname{argmax}_{i \neq j} \frac{(\mathbf{G}_i(\alpha^k) - \mathbf{G}_j(\alpha^k))^2}{2(|\bar{K}_i| + |\bar{K}_j| - |\bar{K}_{ij}| - |\bar{K}_{ji}|)}$$

$$\alpha^{k+1} = \alpha^k + \rho_k \mathbf{z}^k$$

$$\mathbf{z}_k = \begin{cases} \mathbf{d}_k + \delta_{k-1} \mathbf{z}_{k-1} + \delta_{k-2} \mathbf{z}_{k-2}, & k \geq 1 \\ 0, & k = -1, 0 \end{cases}$$

## SCG-LSSVM

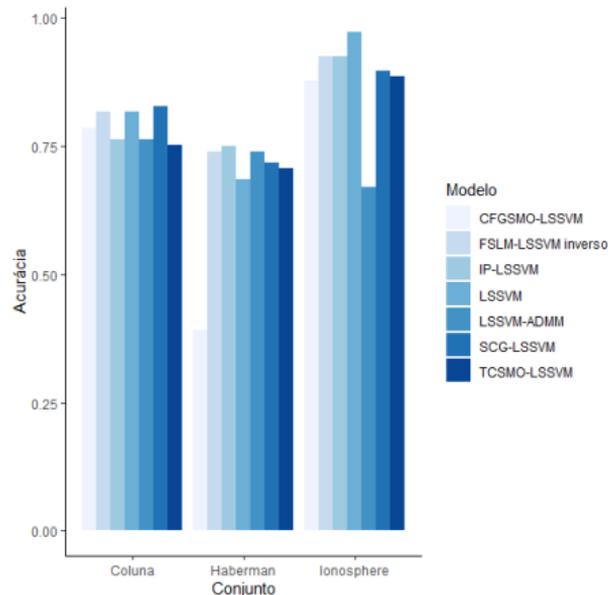
Seleção do par de multiplicadores

$$i = \operatorname{argmax} |\mathbf{G}_1(\alpha^k)|$$

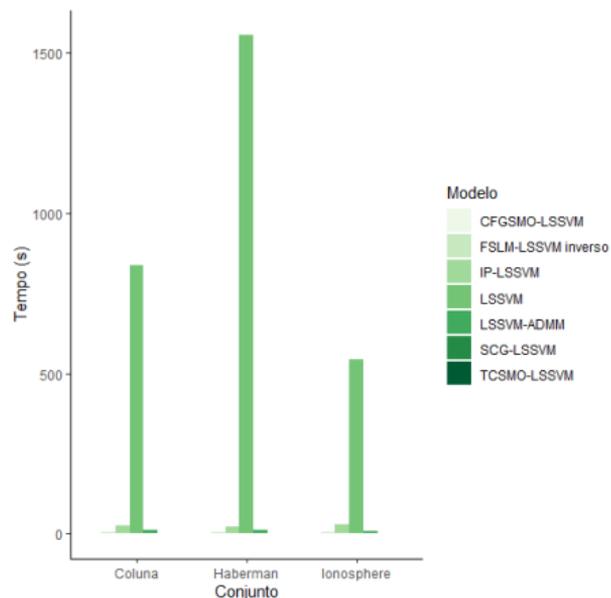
$$j = \operatorname{argmax}_{i \neq j} \frac{(\mathbf{G}_i(\alpha^k) - \mathbf{G}_j(\alpha^k))^2}{2(|\bar{K}_i| + |\bar{K}_j| - |\bar{K}_{ij}| - |\bar{K}_{ji}|)}$$

$$\alpha^{k+1} = \alpha^k + \rho_k \mathbf{z}^k$$

$$\mathbf{z}^k = \theta_k \mathbf{g}^k + \beta_k (\alpha^k - \alpha^{k-1})$$



(a) Acurácia Média



(b) Tempos Médios (s)



- Obter resultados para outros conjuntos de dados de *benckmarking*;
- Avaliar a convergência do LSSVM-ADMM;
- Refinar a proposta FSLM-LSSVM inverso;
- Desenvolver os artigos relacionados a cada proposta.

# On stochastic differential equations and some applications

Filipe P. de Farias  
filipepfarias@alu.ufc.br

Department of Teleinformatics Engineering  
Federal University of Ceará

Supervisor: Prof. Dr. Michela Mulas  
Signals and Systems / Pattern recognition and dynamical systems

November 29, 2024

UFC 



UNIVERSIDADE  
FEDERAL DO CEARÁ

## What are stochastic differential equations (SDEs)?

SDEs extend the theory of (ordinary) differential equations (DE) to include a source of randomness<sup>1</sup>.

---

<sup>1</sup>Øksendal, B. (2010). *Stochastic differential equations: An introduction with applications*. Springer Berlin Heidelberg.

## What are stochastic differential equations (SDEs)?

SDEs extend the theory of (ordinary) differential equations (DE) to include a source of randomness<sup>1</sup>.

> DEs model a system's dynamics and depend on system's states, inputs, parameters, and time

$$\frac{dx(t)}{dt} = f(x(t), u(t), \theta, t)$$

---

<sup>1</sup>Øksendal, B. (2010). *Stochastic differential equations: An introduction with applications*. Springer Berlin Heidelberg.

## What are stochastic differential equations (SDEs)?

SDEs extend the theory of (ordinary) differential equations (DE) to include a source of randomness<sup>1</sup>.

- > DEs model a system's dynamics and depend on system's states, inputs, parameters, and time

$$\frac{dx(t)}{dt} = f(x(t), u(t), \theta, t) \implies \frac{dx(t)}{dt} = f_s(x(t), u(t), \eta(t), \theta, t).$$

---

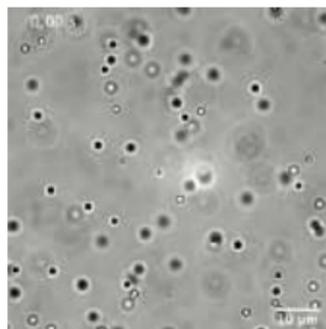
<sup>1</sup>Øksendal, B. (2010). *Stochastic differential equations: An introduction with applications*. Springer Berlin Heidelberg.

## What are stochastic differential equations (SDEs)?

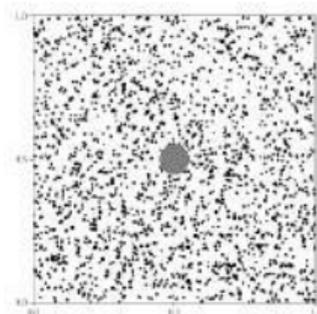
SDEs extend the theory of (ordinary) differential equations (DE) to include a source of randomness<sup>1</sup>.

> DEs model a system's dynamics and depend on system's states, inputs, parameters, and time

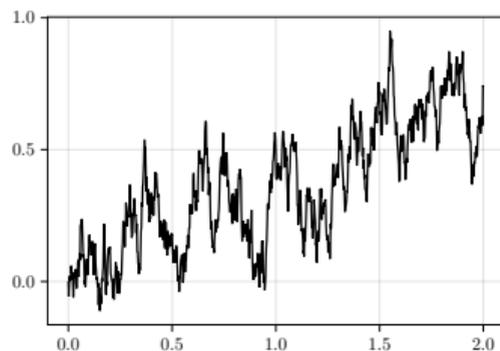
$$\frac{dx(t)}{dt} = f(x(t), u(t), \theta, t) \implies \frac{dx(t)}{dt} = f_s(x(t), u(t), \eta(t), \theta, t).$$



Brownian motion on a microscope<sup>2</sup>.



Simulated Brownian motion.



Simulated Brownian motion.

<sup>1</sup>Øksendal, B. (2010). *Stochastic differential equations: An introduction with applications*. Springer Berlin Heidelberg.

<sup>2</sup>Miyazaki, M., Yamazaki, Y., & Hasegawa, Y. (2022). Analysis of brownian motion by elementary school students. *The Physics Teacher*, 60(6), 478–483. <https://doi.org/10.1119/5.0059810>

## How SDEs are solved?

The solution of an ordinary DE is obtained through deterministic initial-value problem

$$\dot{x}(t) = f(x(t), u(t), \theta, t) \implies x(t) = c + \int_0^t f(x(s), u(s), \theta, s) ds, \quad x(0) = c$$

> In the Riemannian sense the integral would be defined as the limit, where  $\Delta t_i = t_i - t_{i-1}$

$$\lim_{\Delta t \rightarrow 0} \sum_{i=1}^n f(x(t_i), u(t_i), \theta, t_i) \Delta t_i$$

When  $f$  is a stochastic processes, the convergence in mean-square sense is analysed<sup>1</sup>.

> If  $dW(t) \triangleq W(t + dt) - W(t)$  with  $dt \rightarrow 0$  is a Wiener process ( $dW(t) \sim \mathcal{N}(0, \sqrt{dt})$ ).  
For example

$$\int_{t_0}^t W(s) dW(s) = W(t)^2 - W(t_0)^2 - (t - t_0)/2.$$

<sup>1</sup>Øksendal, B. (2010). *Stochastic differential equations: An introduction with applications*. Springer Berlin Heidelberg.

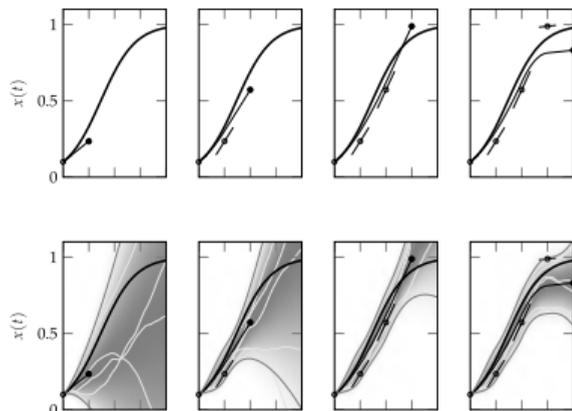
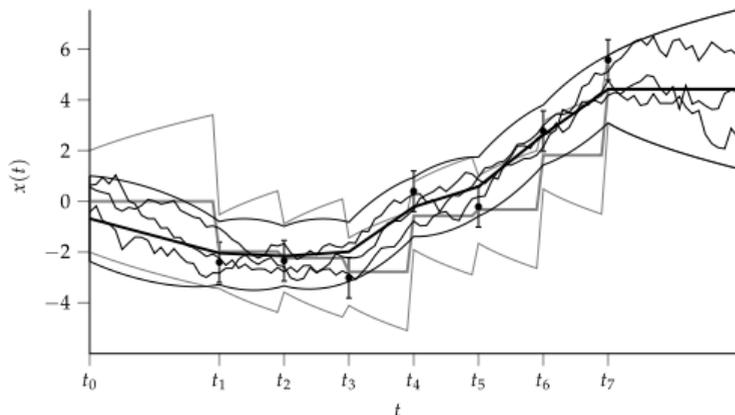
## Some (not so common) applications

### Probabilistic numerics<sup>2</sup>

For stochastic (i.e. in time) processes, the representation of the Gaussian process regression as an SDE reduces the complexity from  $\mathcal{O}(N^3)$  to  $\mathcal{O}(N)$  using the well-known Kalman filter algorithm<sup>1</sup>.

(left) By the Wiener-Khinchin theorem we represent covariance functions as state-space models.

(right) Gaussian process can model uncertainty over DE and their solutions.



<sup>1</sup>Sarkka, S., Solin, A., & Hartikainen, J. (2013). Spatiotemporal learning via infinite-dimensional bayesian filtering and smoothing: A look at gaussian process regression through kalman filtering. *IEEE Signal Processing Magazine*, 30(4), 51–61.

<sup>2</sup>Hennig, P., Osborne, M., & Kersting, H. (2022). *Probabilistic numerics*. Cambridge University Press, p. 51, 293.

## Some (not so common) applications

### 'Violations' of the second law of thermodynamics

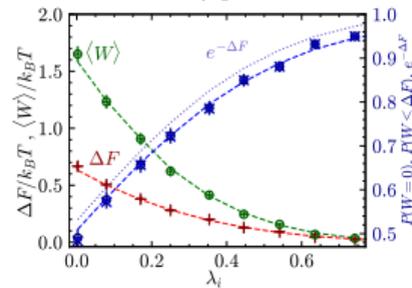
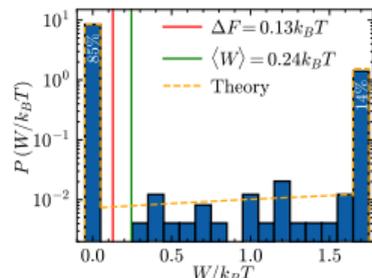
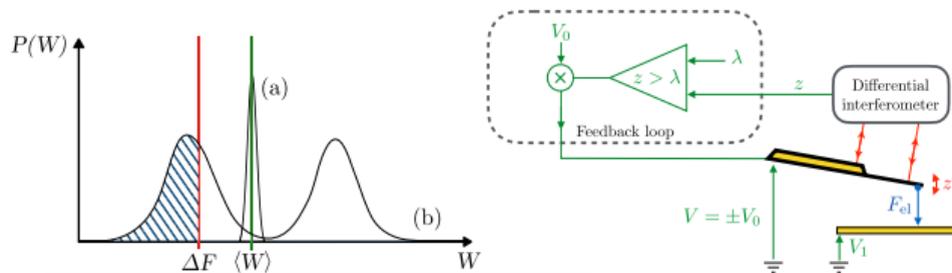
SDEs can model dynamical systems under the thermodynamic limit (Langevin dynamics).

- > The 2nd law of thermodynamics states

$$W - \Delta F = \Delta S \geq 0.$$

- > But fluctuation theorem<sup>1</sup> states that

$$\langle e^{-\beta W/k_B T} \rangle = e^{-\Delta F/k_B T}.$$



<sup>1</sup>Jarzynski, C. (1997). Nonequilibrium equality for free energy differences. *Phys. Rev. Lett.*, 78, 2690–2693

<sup>2</sup>Barros, N., Ciliberto, S., & Bellon, L. (2024). Probabilistic work extraction on a classical oscillator beyond the second law. *Phys. Rev. Lett.*, 133, 057101



Universidade Federal do Ceará  
Programa de Pós-Graduação em  
Engenharia de Teleinformática



UFC70

# Síntese e análise de estabilidade de controladores PID de ordem fracionária

Igor Rocha de Sousa

Guilherme de Alencar Barreto  
Kleber Zuza Nóbrega

Reconhecimento de padrões e sistemas dinâmicos / Sinais e sistemas

# □ Cálculo de ordem inteira

$$\frac{d}{dt}f(t) \quad , \quad \frac{d^2}{dt^2}f(t) \quad , \quad \frac{d^3}{dt^3}f(t) \quad , \quad \dots$$

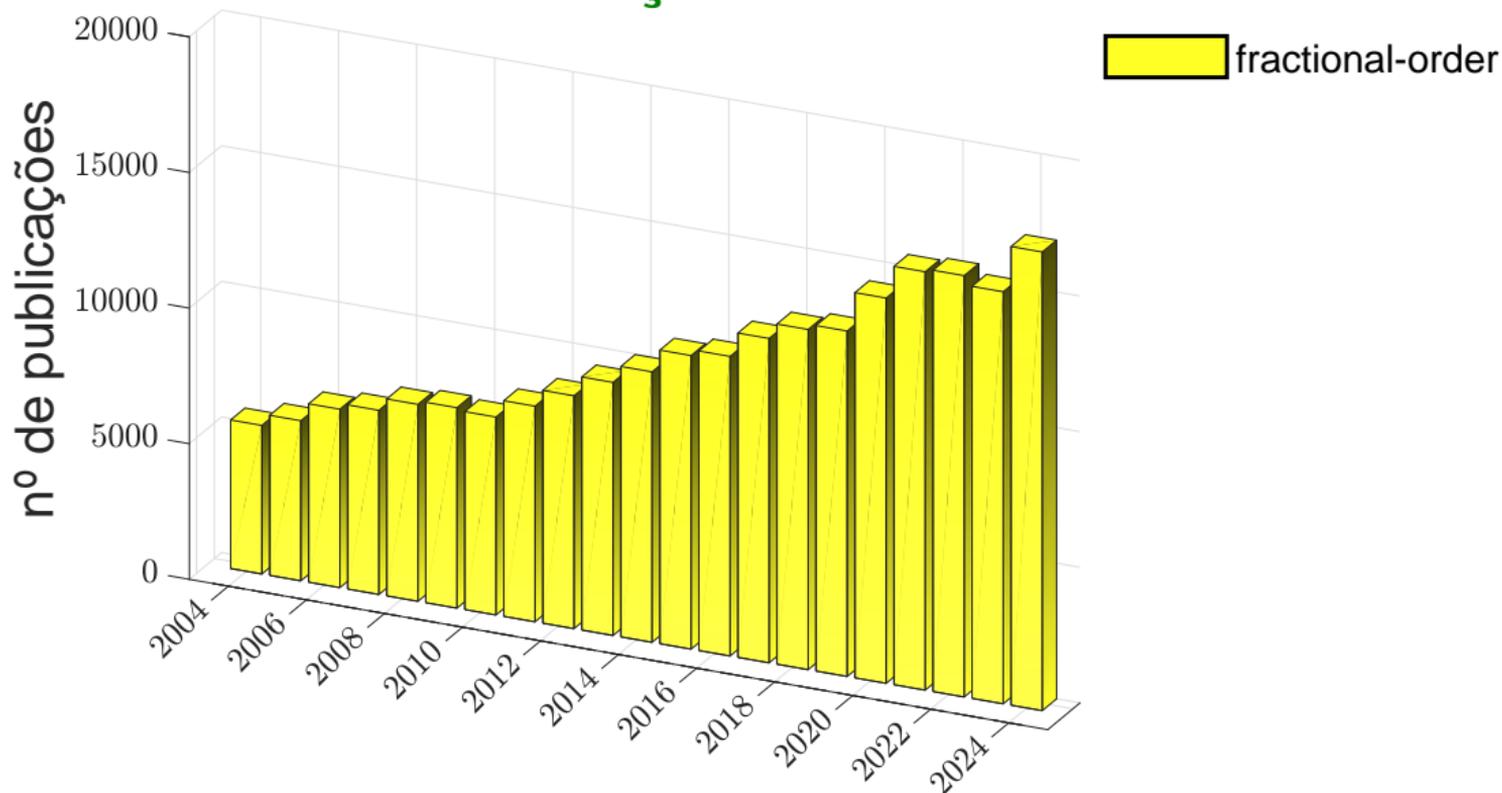
## □ Cálculo de ordem inteira

$$\frac{d}{dt}f(t) \quad , \quad \frac{d^2}{dt^2}f(t) \quad , \quad \frac{d^3}{dt^3}f(t) \quad , \quad \dots$$

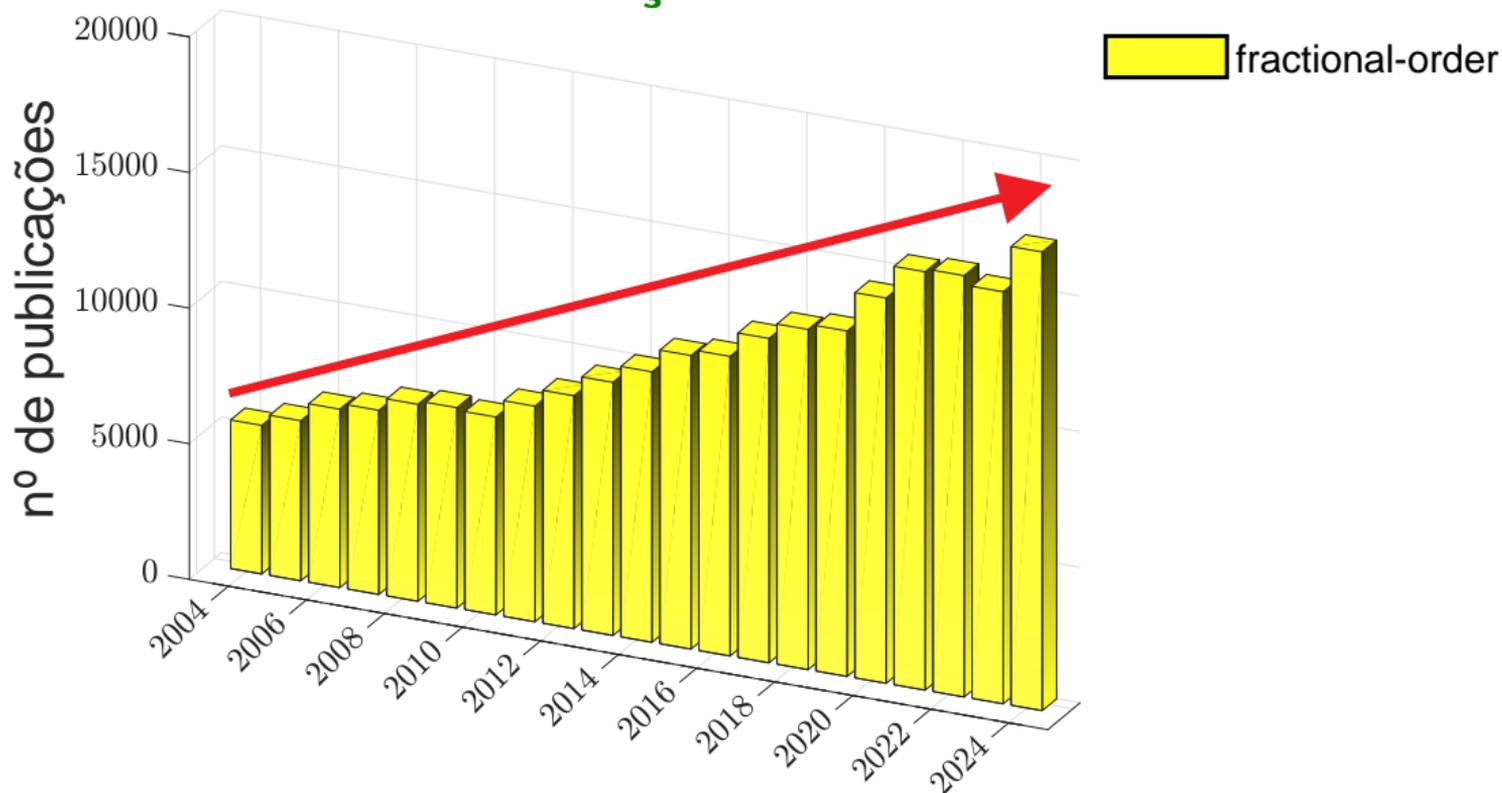
## □ Cálculo de ordem fracionária

$$\frac{d^{1.23}}{dt^{1.23}}f(t)$$

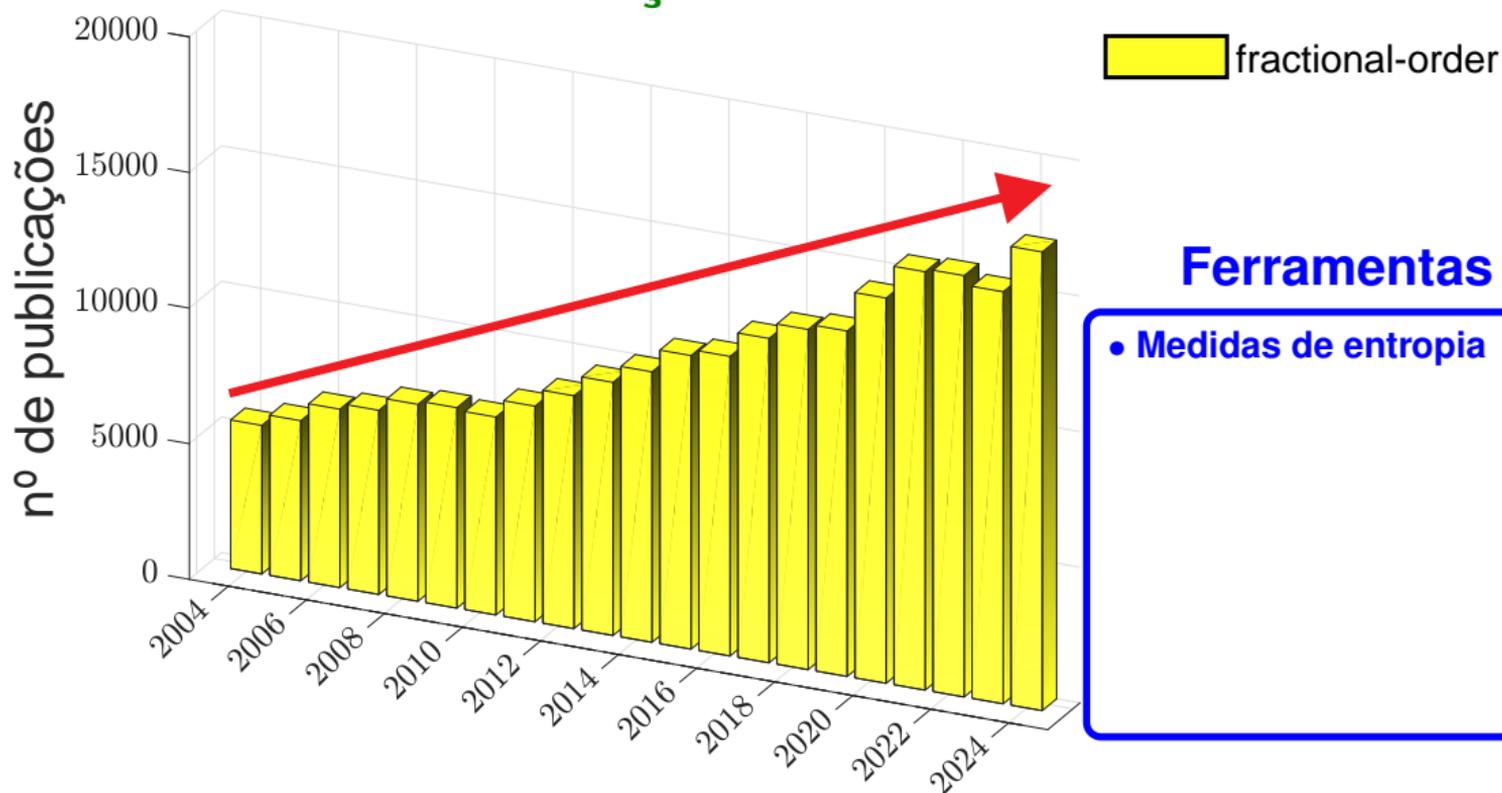
## Publicações na Elsevier



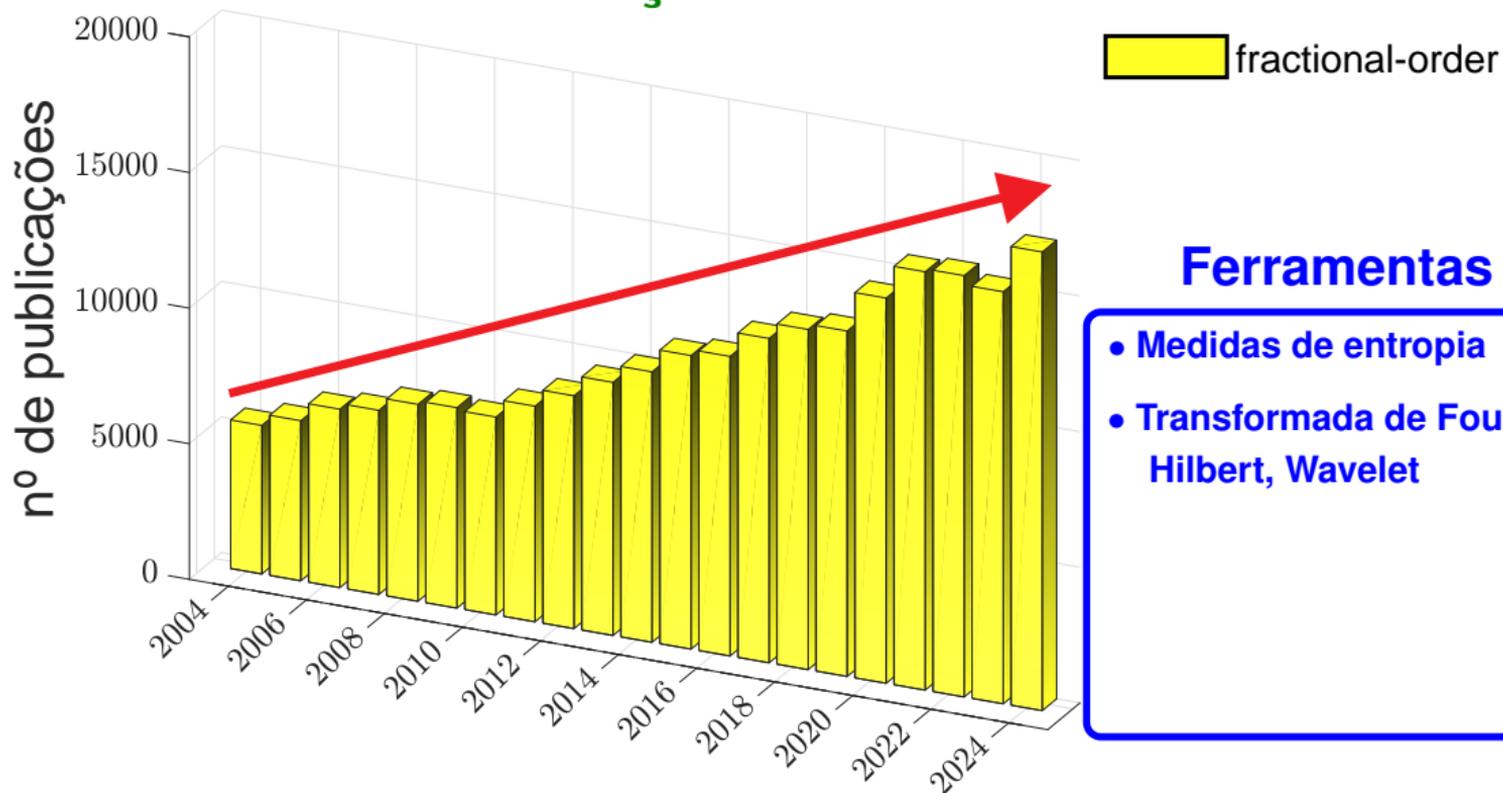
## Publicações na Elsevier



## Publicações na Elsevier



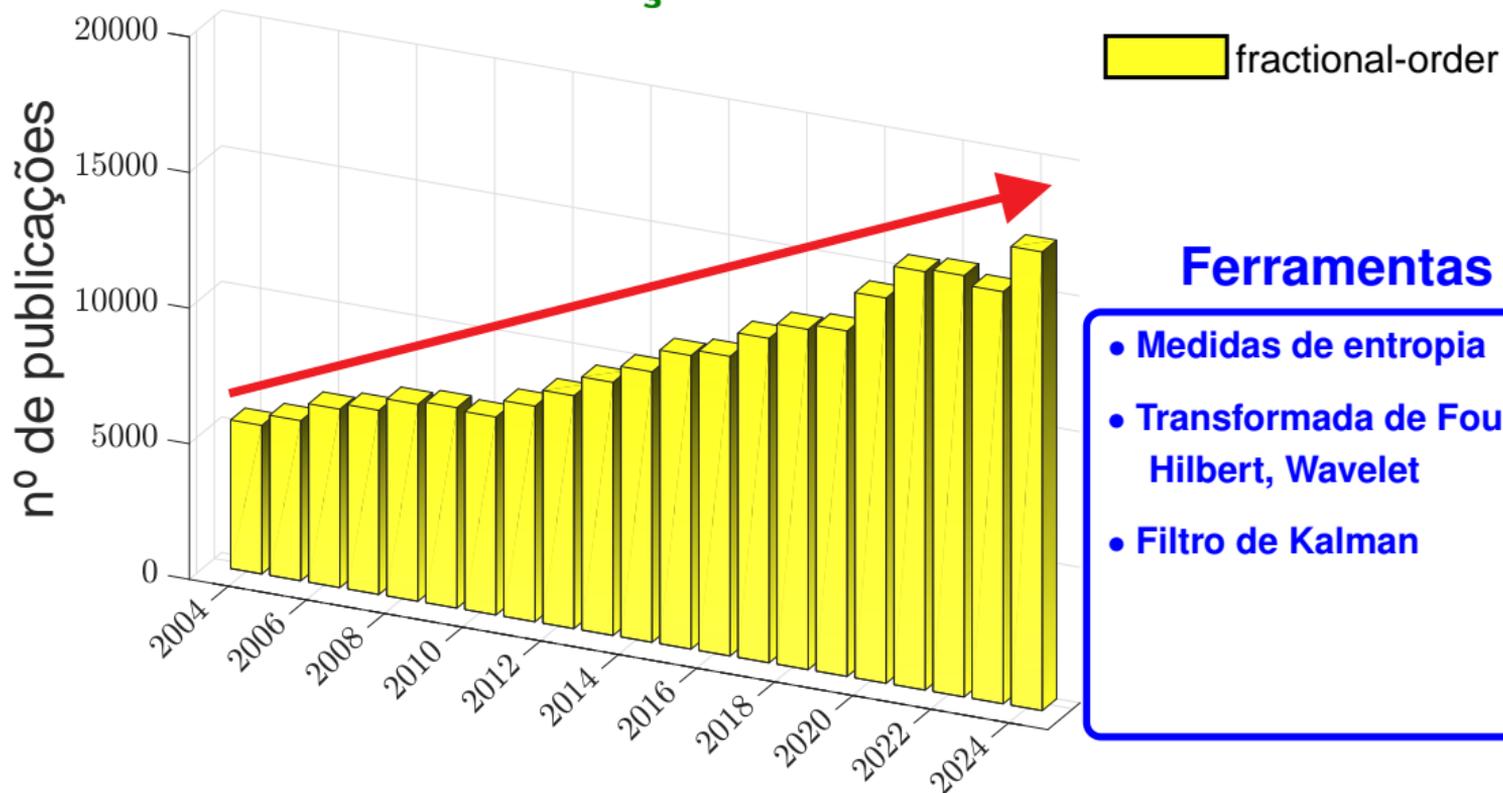
## Publicações na Elsevier



### Ferramentas

- Medidas de entropia
- Transformada de Fourier, Hilbert, Wavelet

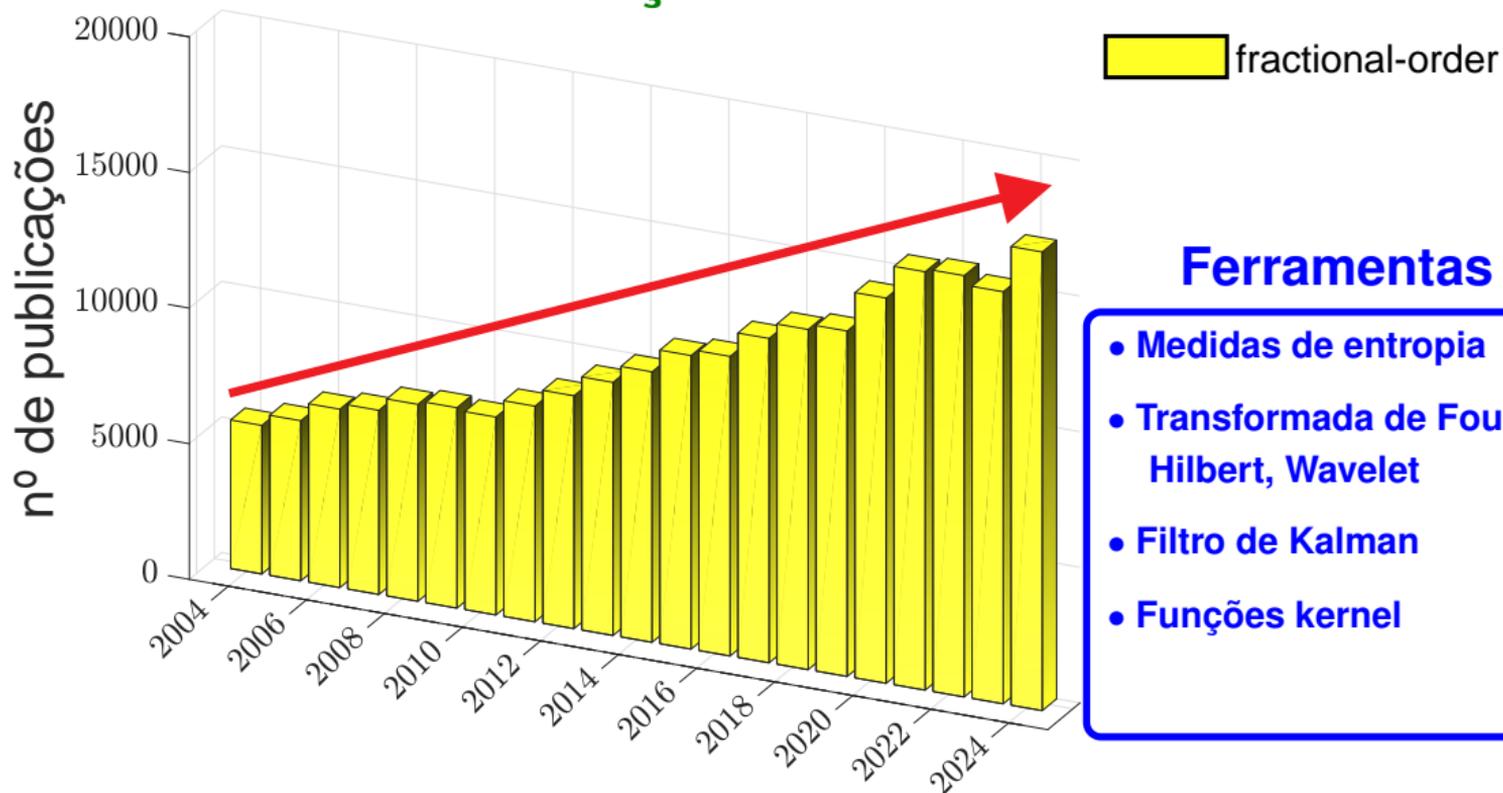
## Publicações na Elsevier



### Ferramentas

- Medidas de entropia
- Transformada de Fourier, Hilbert, Wavelet
- Filtro de Kalman

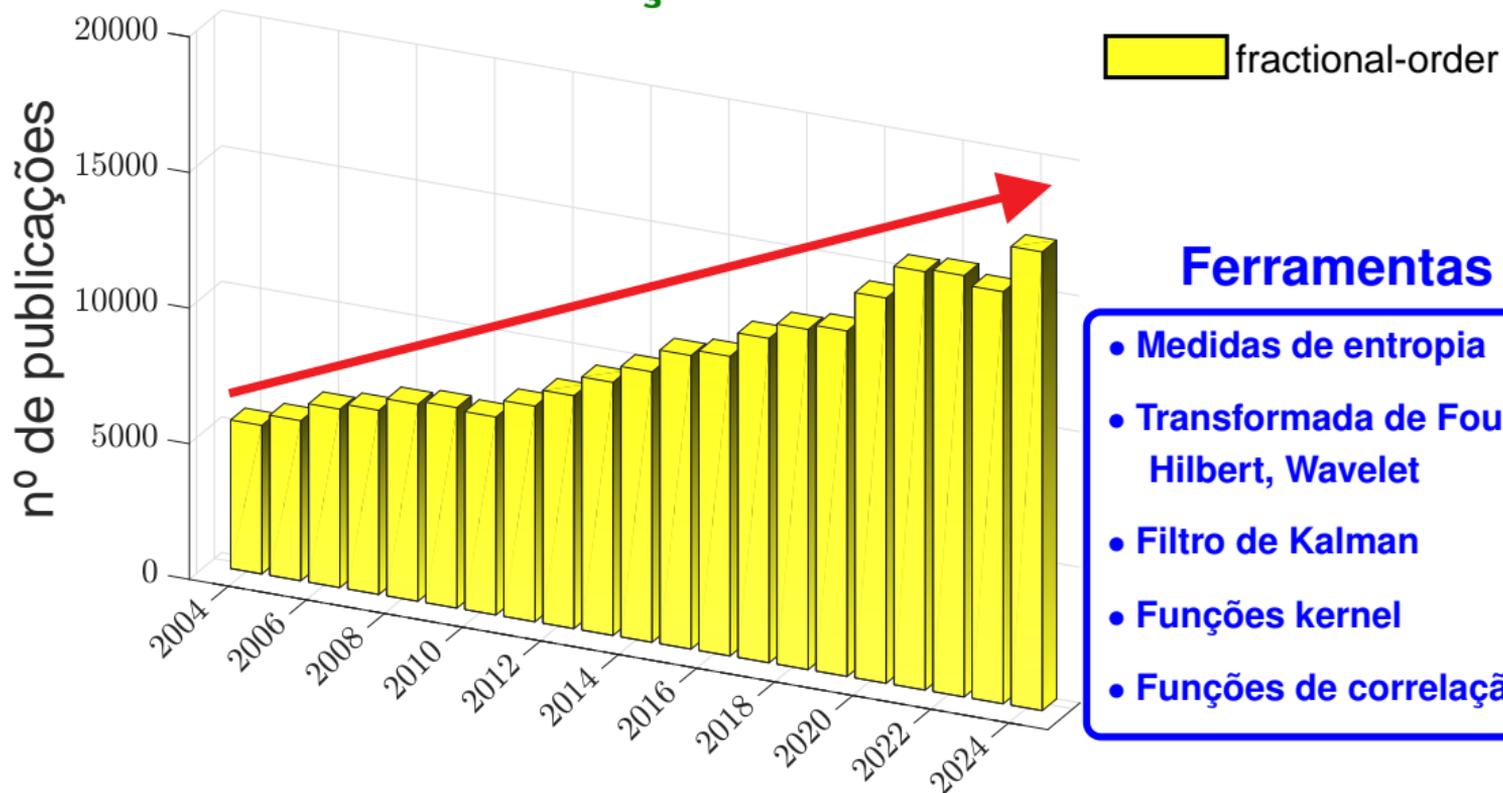
## Publicações na Elsevier



### Ferramentas

- Medidas de entropia
- Transformada de Fourier, Hilbert, Wavelet
- Filtro de Kalman
- Funções kernel

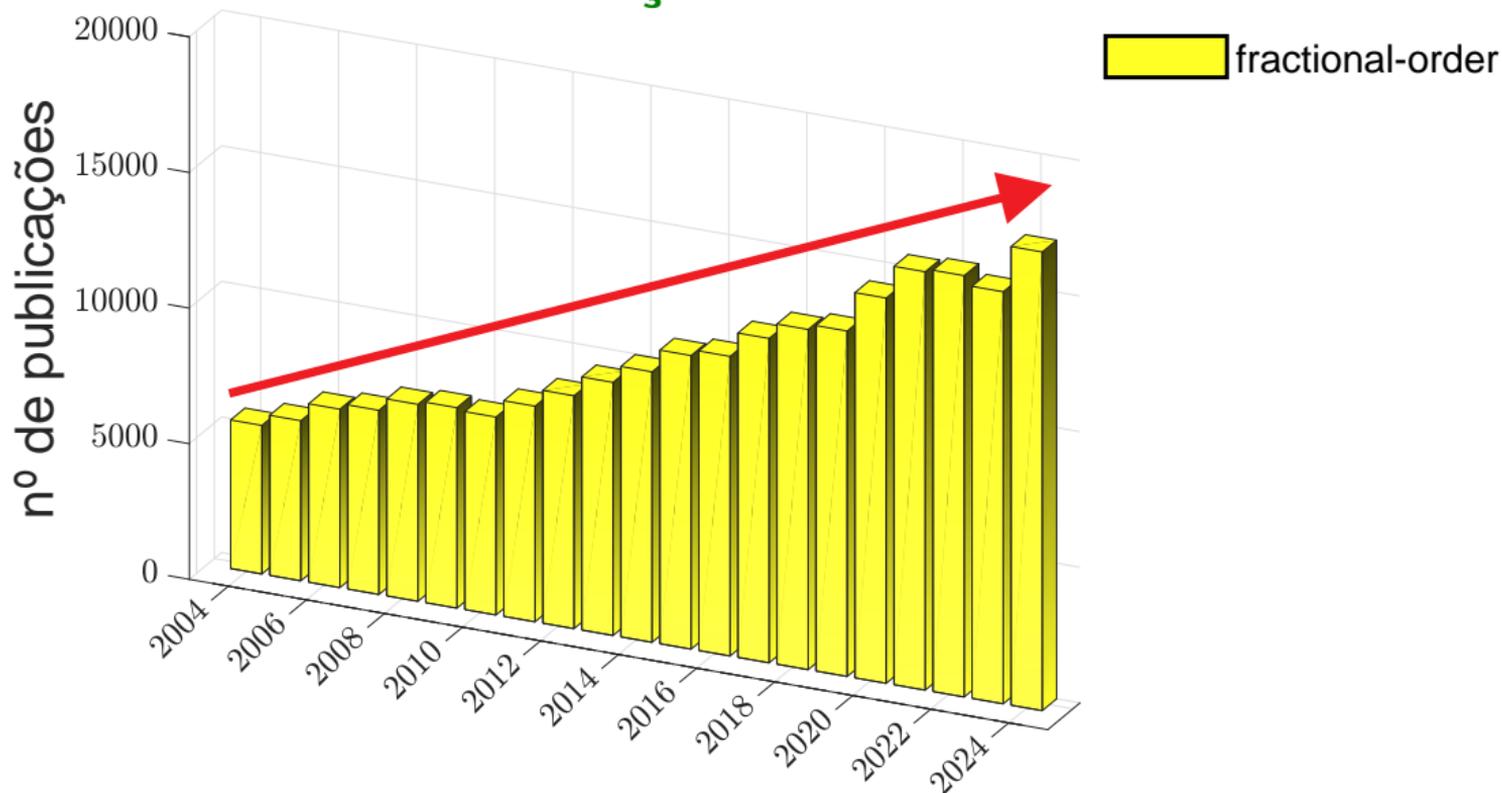
## Publicações na Elsevier



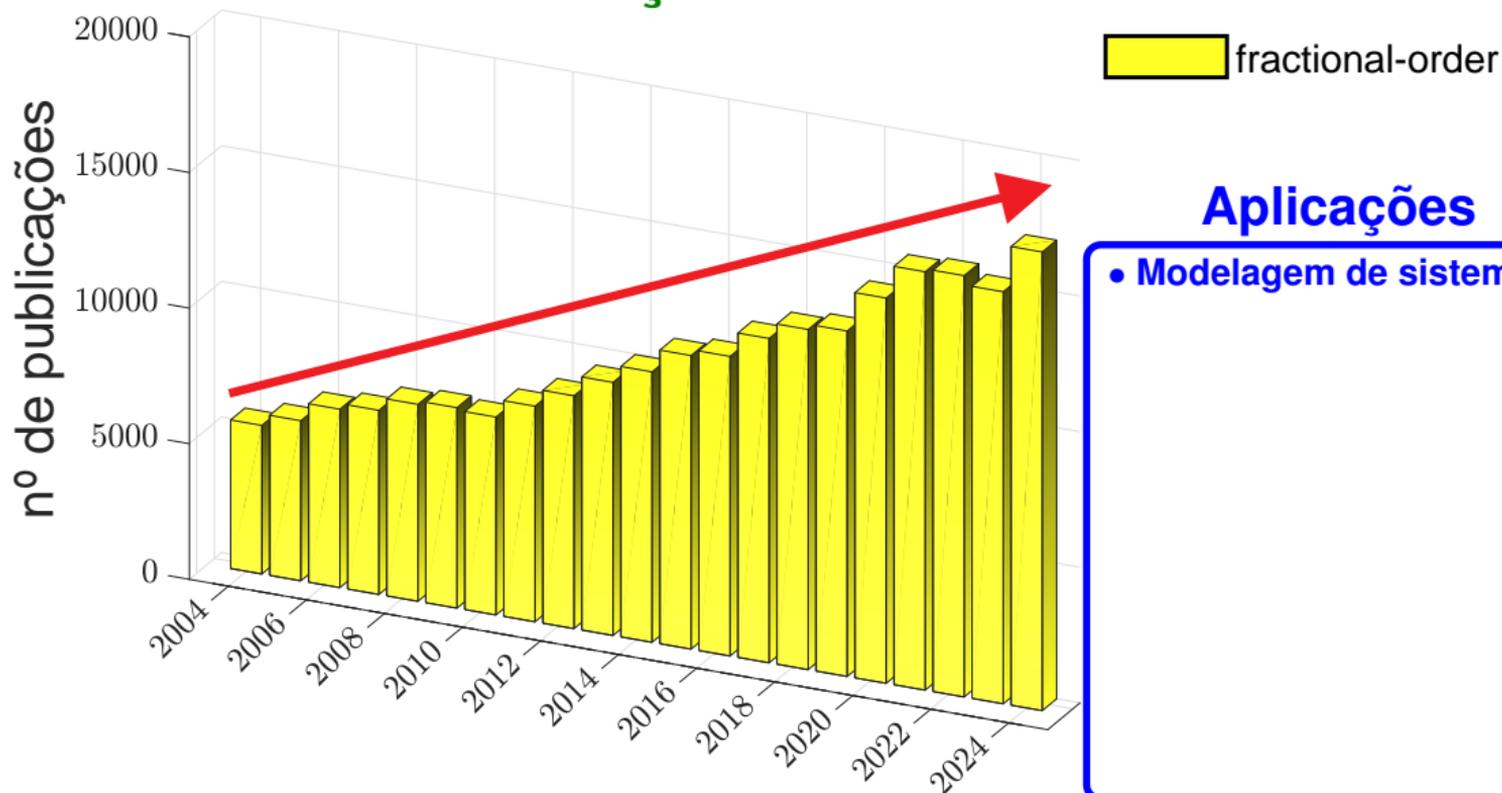
### Ferramentas

- Medidas de entropia
- Transformada de Fourier, Hilbert, Wavelet
- Filtro de Kalman
- Funções kernel
- Funções de correlação

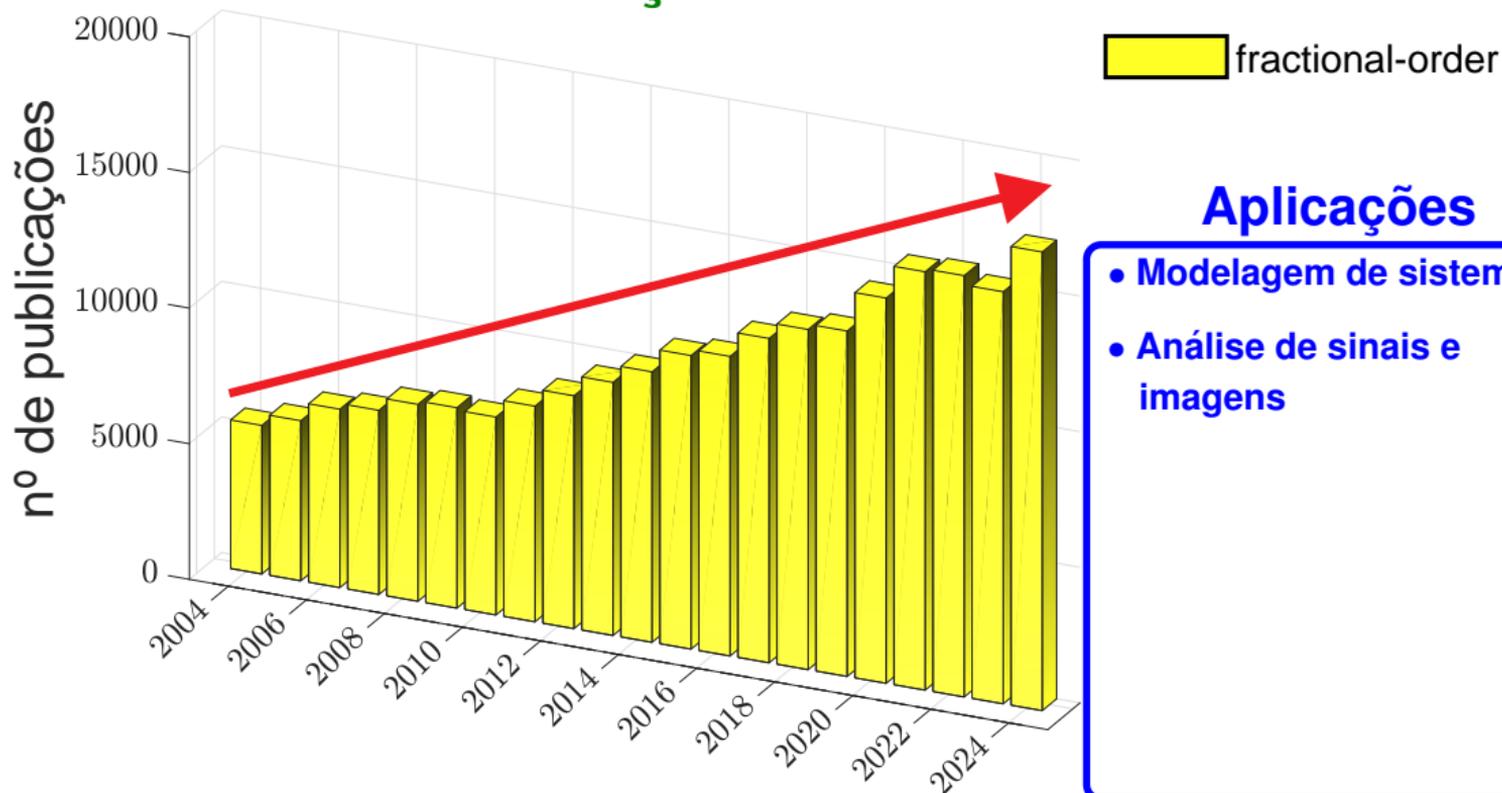
## Publicações na Elsevier



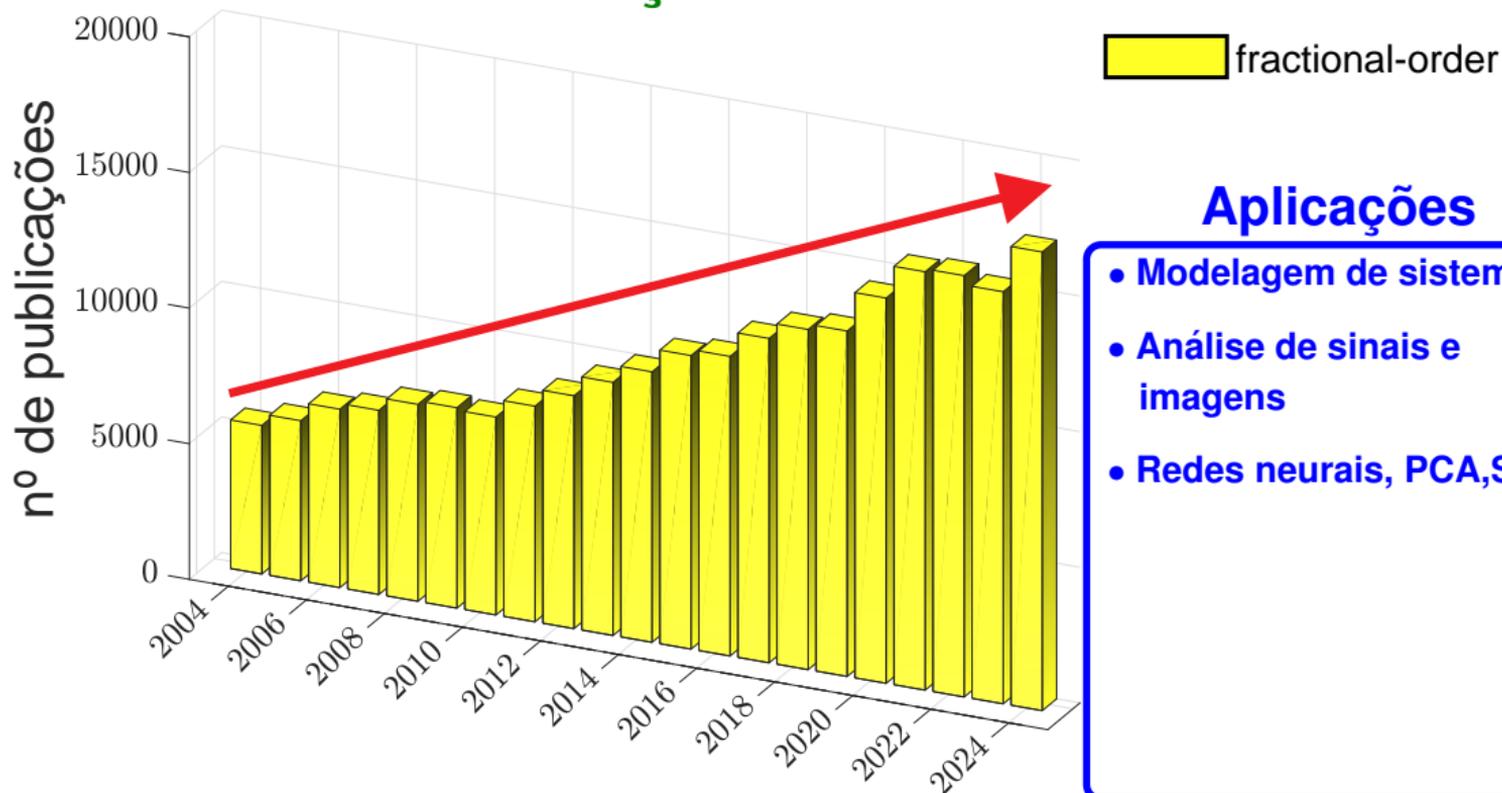
## Publicações na Elsevier



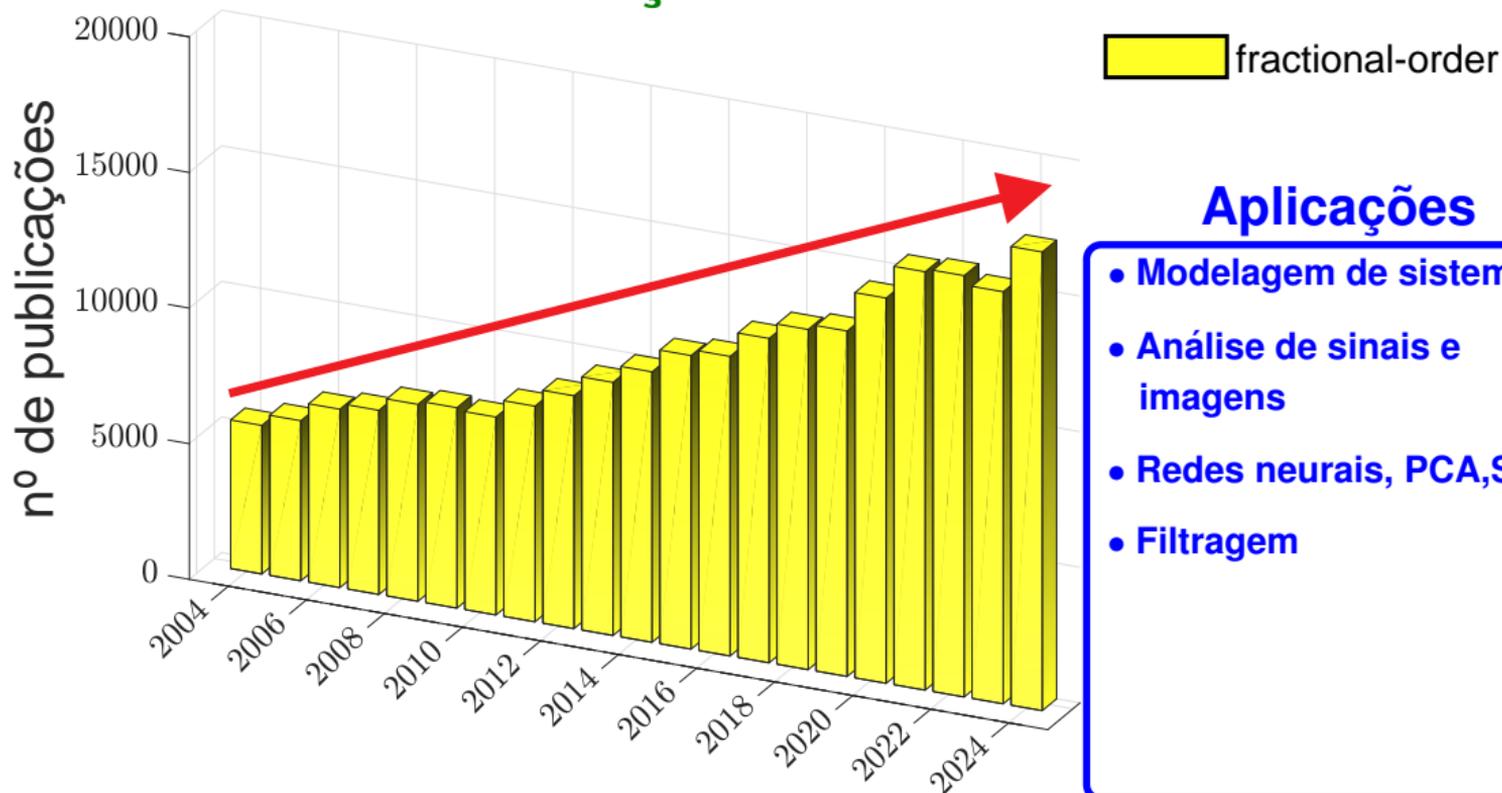
## Publicações na Elsevier



## Publicações na Elsevier



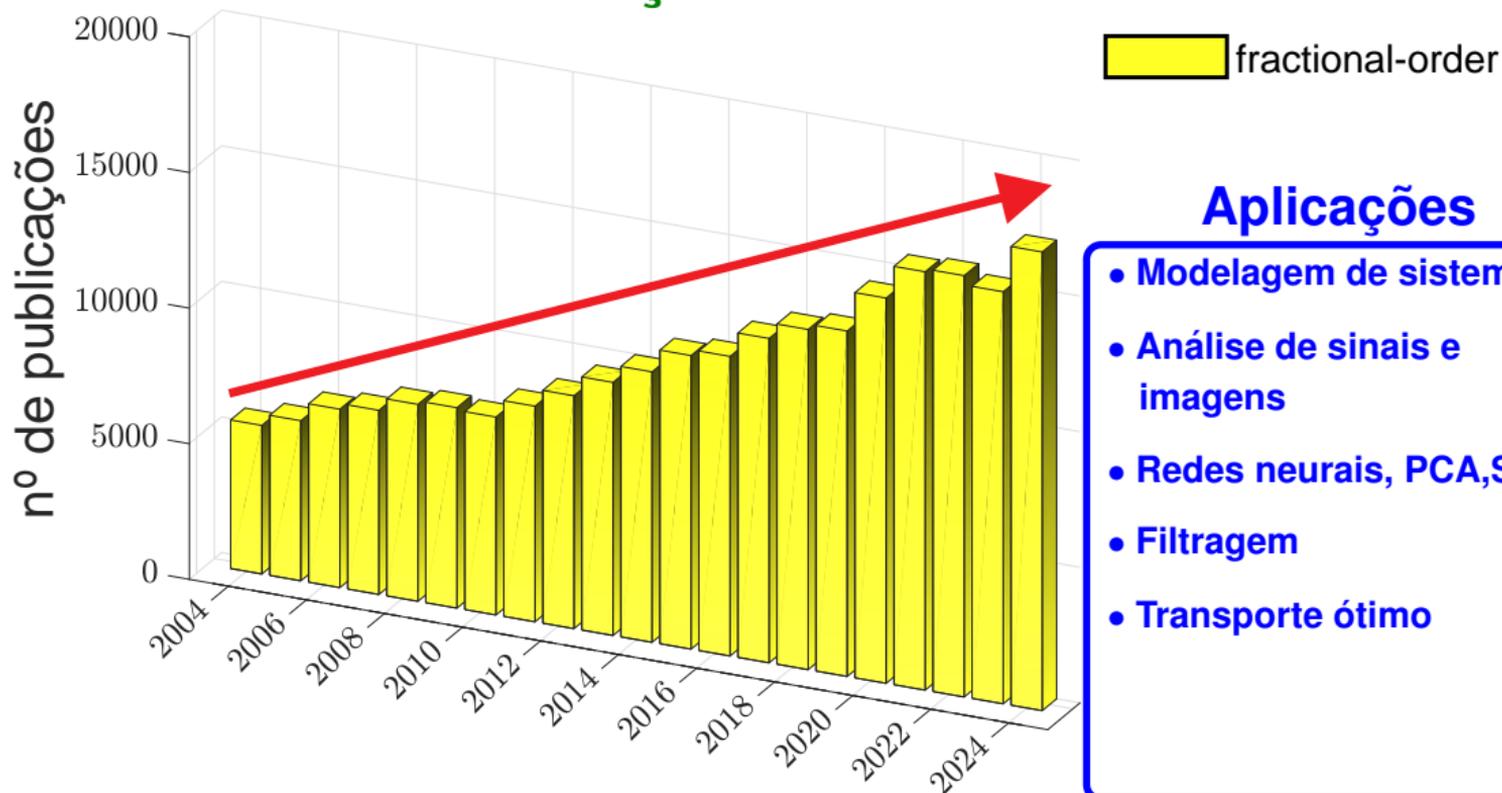
## Publicações na Elsevier



### Aplicações

- Modelagem de sistemas
- Análise de sinais e imagens
- Redes neurais, PCA, SVM
- Filtragem

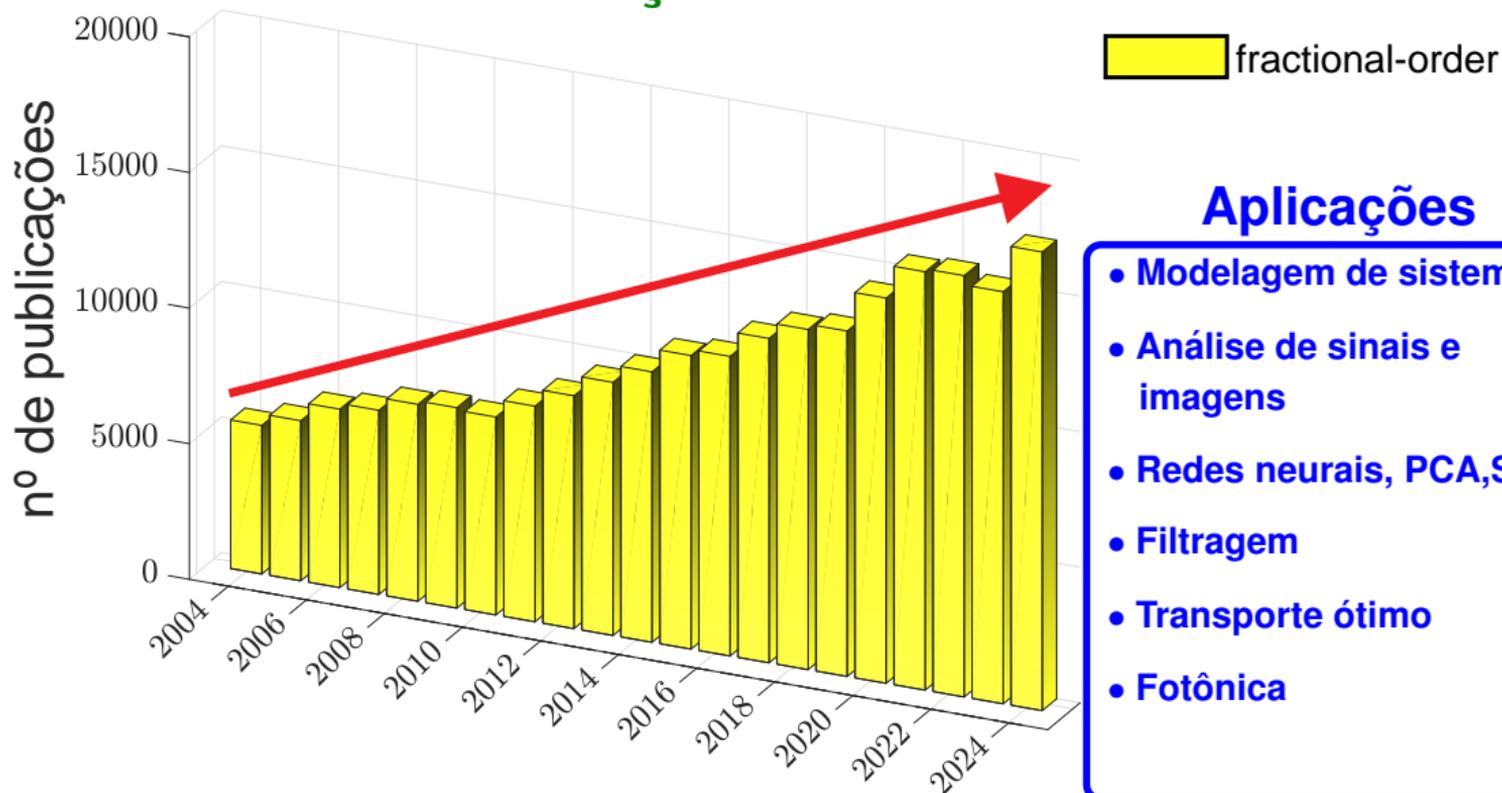
## Publicações na Elsevier



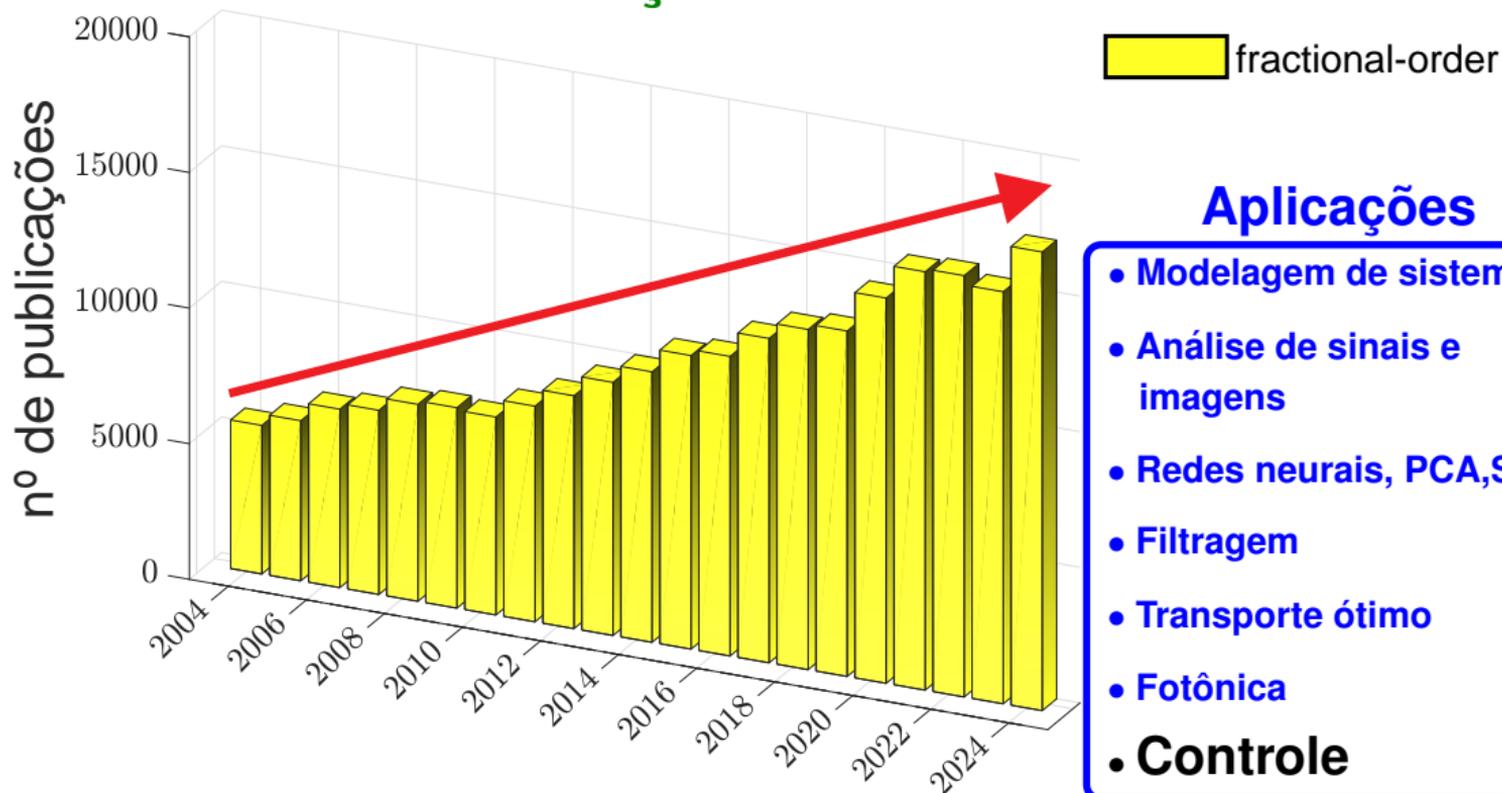
### Aplicações

- Modelagem de sistemas
- Análise de sinais e imagens
- Redes neurais, PCA, SVM
- Filtragem
- Transporte ótimo

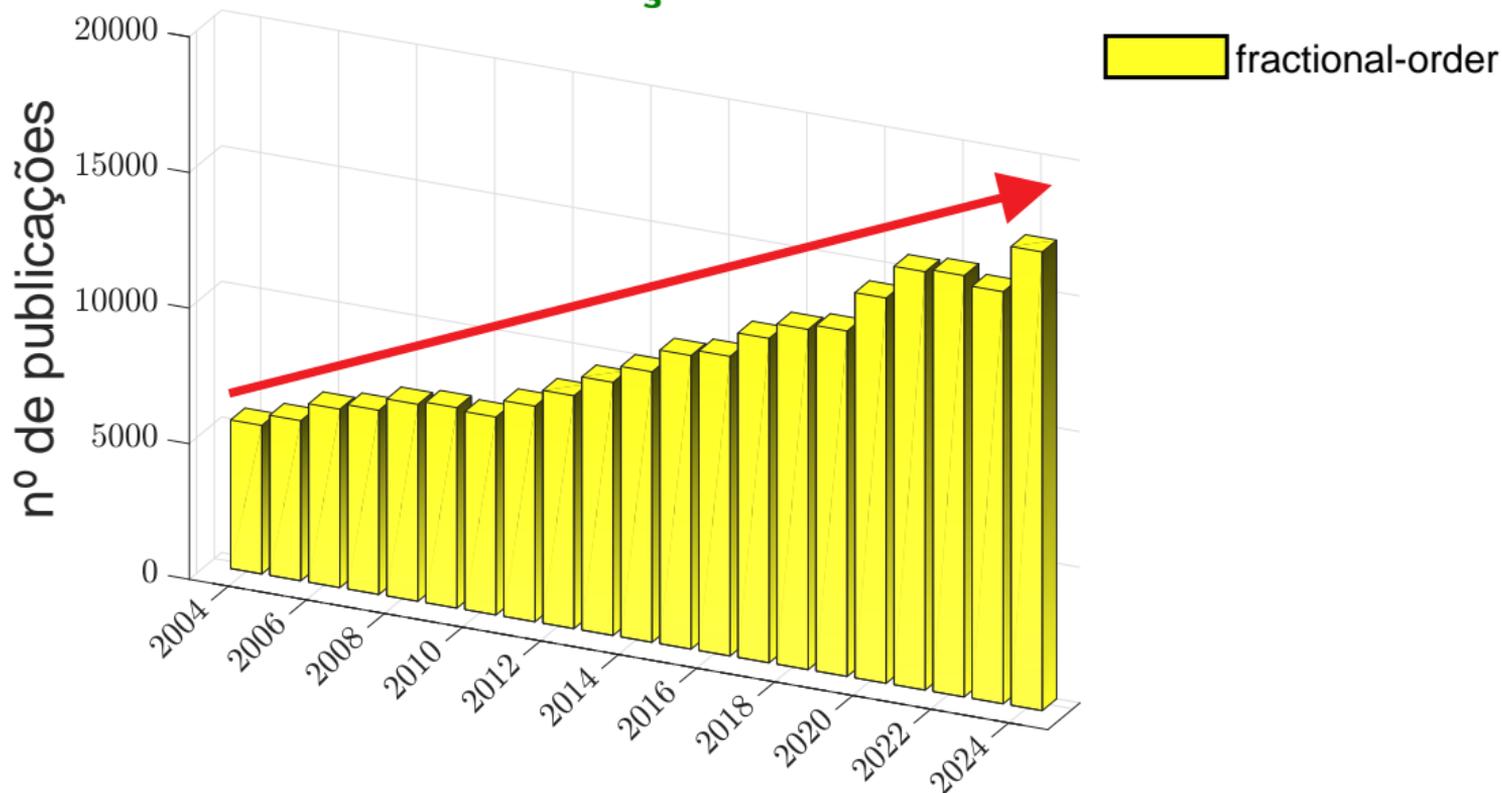
## Publicações na Elsevier



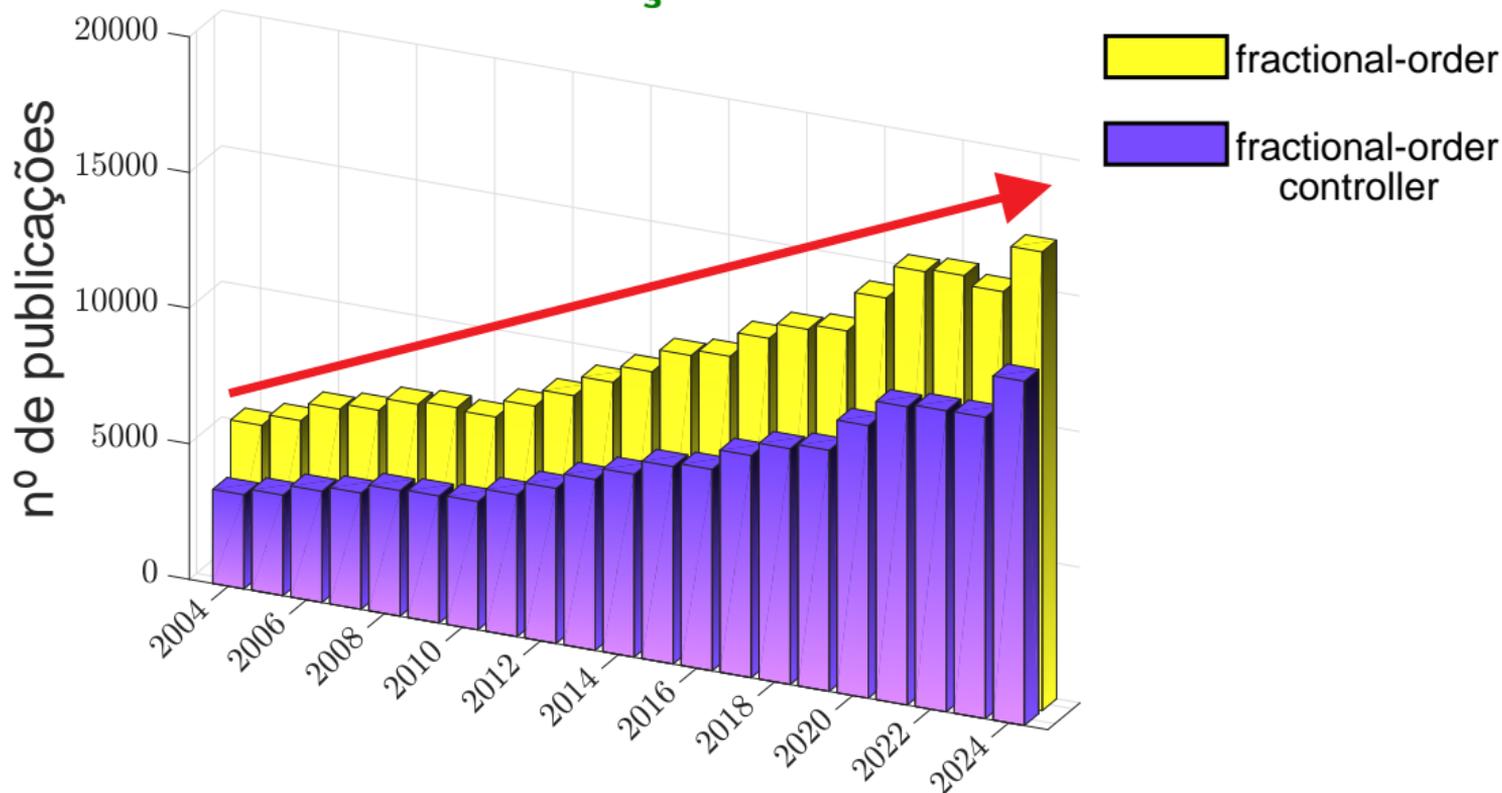
## Publicações na Elsevier



## Publicações na Elsevier



## Publicações na Elsevier



# Controlador PID (Proporcional-Integrativo-Derivativo)

$$C(s) = K_p + \frac{K_i}{s} + K_d s$$

## ❑ Controlador PID (Proporcional-Integrativo-Derivativo)

$$C(s) = K_p + \frac{K_i}{s} + K_d s$$

## ❑ Controlador PID fracionário

$$C(s) = K_p + \frac{K_i}{s^\lambda} + K_d s^\mu$$

## ❑ Controlador PID (Proporcional-Integrativo-Derivativo)

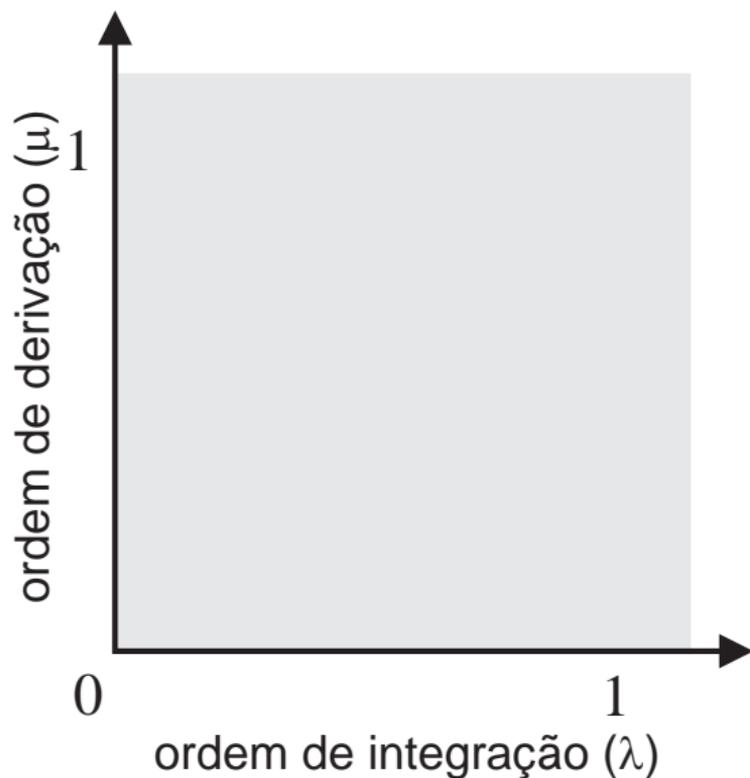
$$C(s) = Kp + \frac{K_i}{s} + K_d s$$

## ❑ Controlador PID fracionário

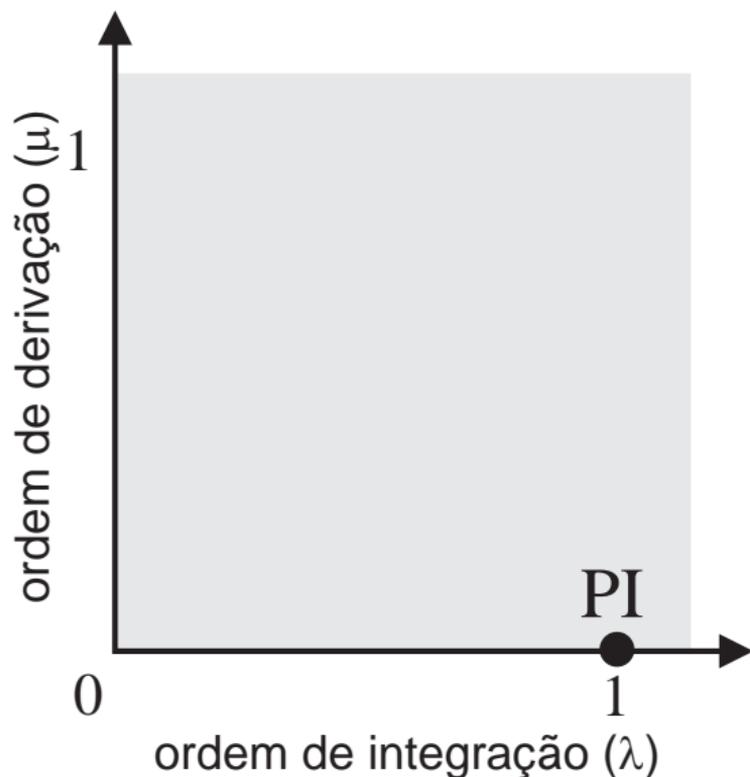
$$C(s) = Kp + \frac{K_i}{s^\lambda} + K_d s^\mu$$

**mais graus de liberdade**

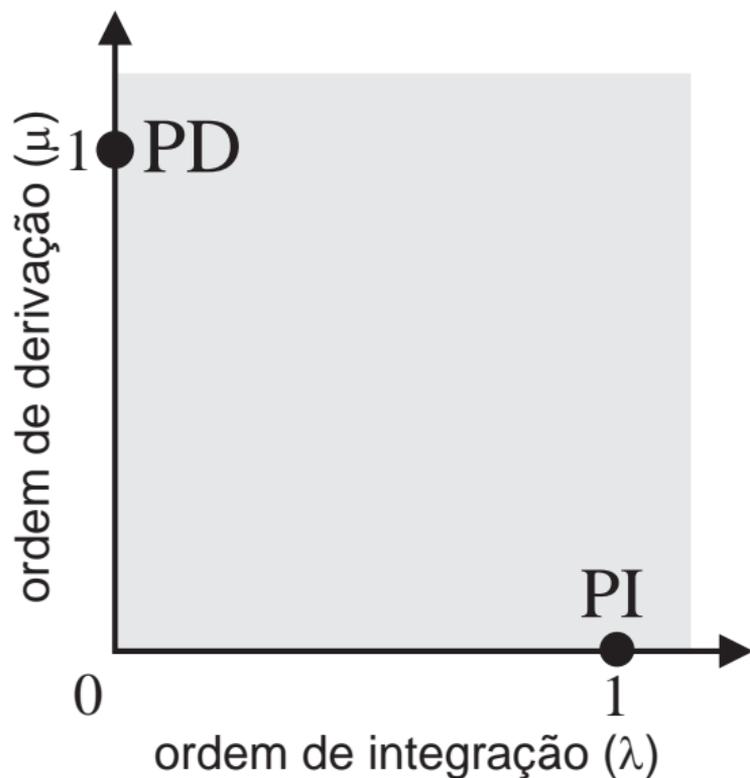
## Comparação entre controladores



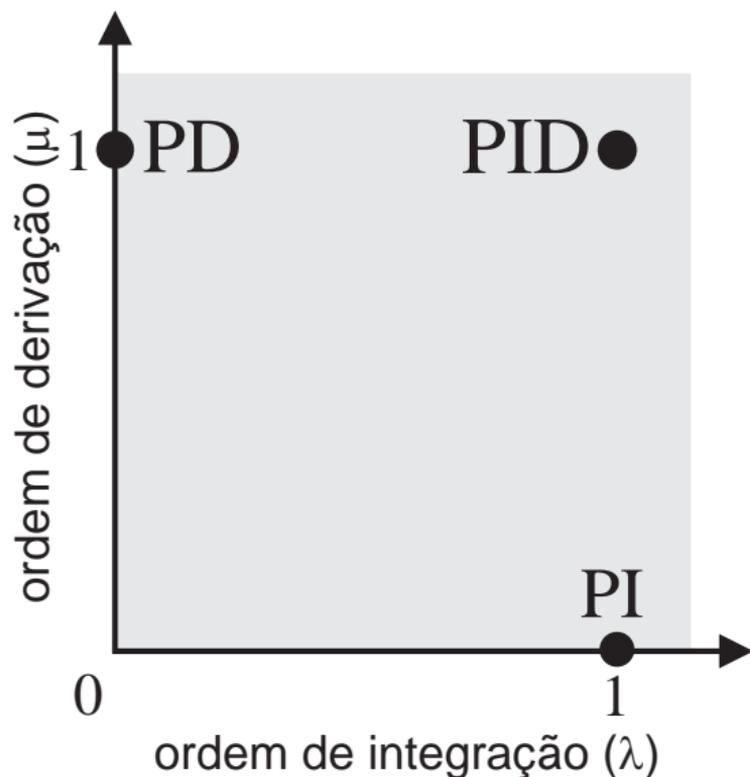
## Comparação entre controladores



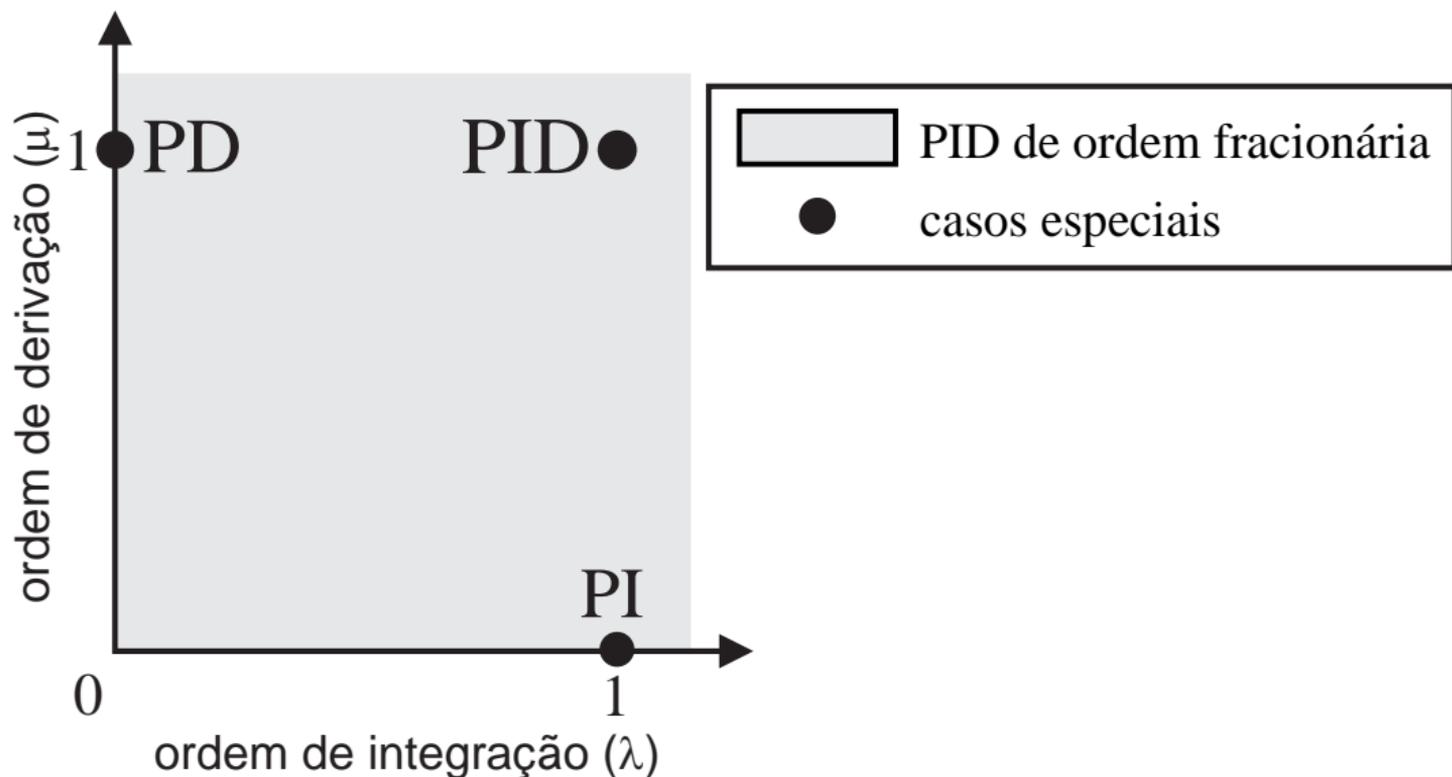
## Comparação entre controladores



## Comparação entre controladores



## Comparação entre controladores



## Definições de derivada fracionária

### Grunwald-Letnikov:

$${}_{t_0}\mathcal{D}_t^\alpha f(t) = \lim_{h \rightarrow 0} \frac{1}{h^\alpha} \sum_{j=0}^{\lceil t-t_0/h \rceil} (-1)^j \frac{\Gamma(\alpha + 1)}{j! \Gamma(\alpha - j + 1)} f(t - jh)$$

### Caputo:

$${}_{t_0}\mathcal{D}_t^\alpha f(t) = \frac{1}{\Gamma(n - \alpha)} \int_{t_0}^t \frac{d^n}{d\tau^n} f(\tau) (t - \tau)^{\alpha - n + 1} d\tau$$

# Desenvolvimento de um controlador $PI^\lambda D^\mu$ discreto otimizado e embarcado em incubadora neonatal

Igor R. Sousa

*Pós-Graduação em Eng. de Teleinformática(PPGETI)*

*Universidade Federal do Ceará (UFC)*

Campus do Pici, Centro de Tecnologia

igor.sousa@alu.ufc.br

Guilherme A. Barreto

*Pós-Graduação em Eng. de Teleinformática(PPGETI)*

*Universidade Federal do Ceará (UFC)*

Campus do Pici, Centro de Tecnologia

gbarreto@ufc.br



**DOI: 10.21528/CBIC2023-049**

**Melhor artigo do XVI Congresso Brasileiro de Inteligência Computacional (CBIC 2023). Salvador, Bahia**

# Neural fractional order PID controller embedded in an 8-bit microcontroller for neonatal incubator

Igor R. Sousa

*Graduate Program on Teleinformatics Engineering*

*Federal University of Ceara*

Fortaleza, Ceará

igor.sousa@alu.ufc.br

Guilherme A. Barreto

*Graduate Program on Teleinformatics Engineering*

*Federal University of Ceara*

Fortaleza, Ceará

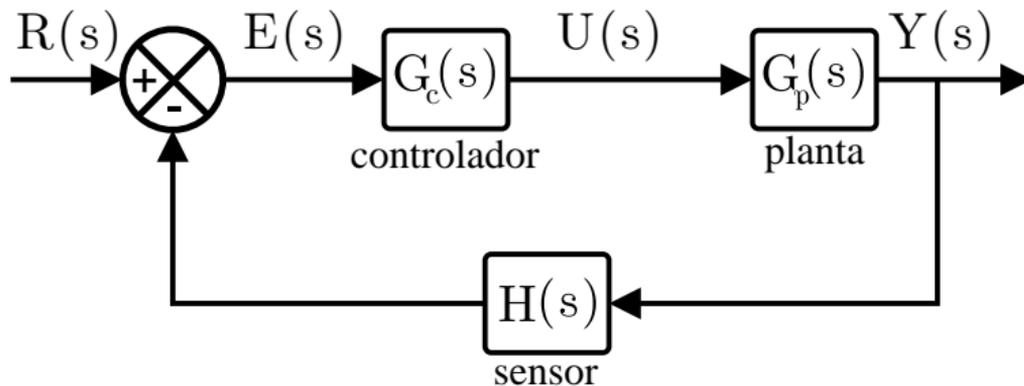
gbarreto@ufc.br



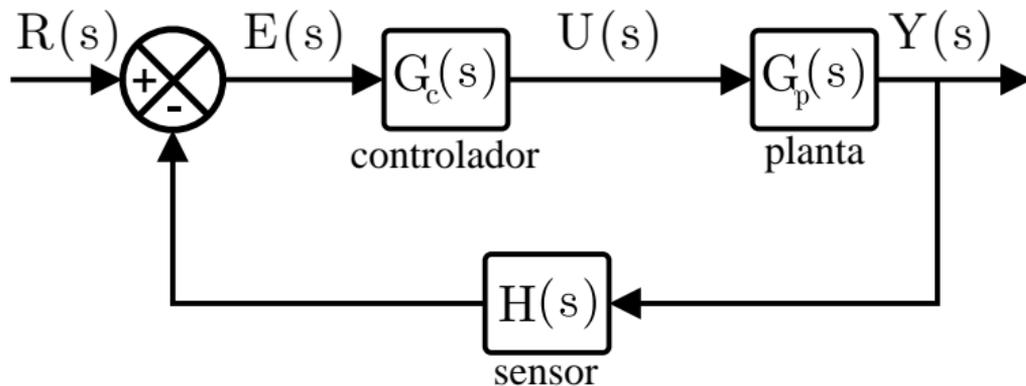
**DOI: 10.1109/IJCNN60899.2024.10651507**

**2024 World Congress on Computational Intelligence (WCCI).  
Yokohama, Japão**

## Sistema de controle em malha fechada

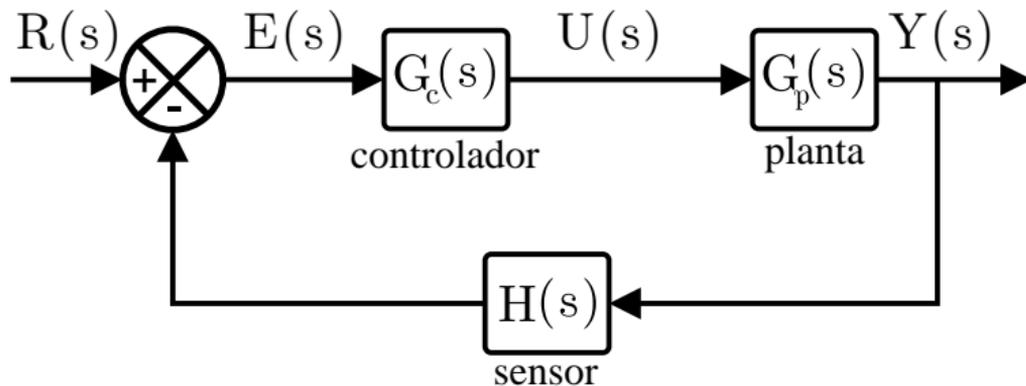


## Sistema de controle em malha fechada



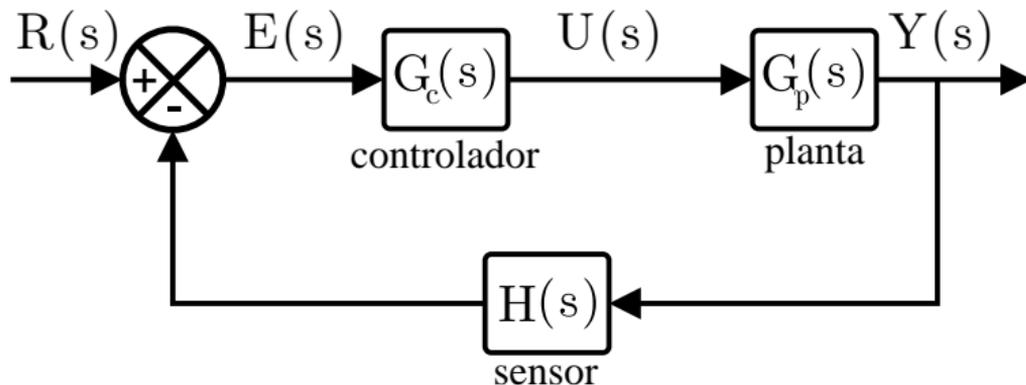
$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_1 s^\alpha + a_2 s^\beta + a_3 s^\gamma + \dots + a_z}$$

## Sistema de controle em malha fechada



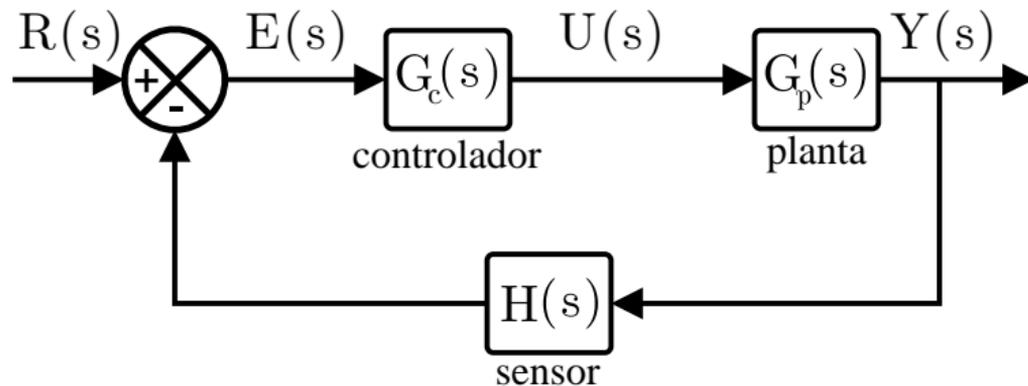
$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_1 s^\alpha + a_2 s^\beta + a_3 s^\gamma + \dots + a_z} Q(s)$$

## Sistema de controle em malha fechada



$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_1 s^\alpha + a_2 s^\beta + a_3 s^\gamma + \dots + a_z}$$

## Sistema de controle em malha fechada



~~solução analítica~~

$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_1 s^\alpha + a_2 s^\beta + a_3 s^\gamma + \dots + a_z}$$

# An analytical approach to the stability conditions of a new class of fractional-order control systems by the Lambert-Tsallis function

**IGOR R. SOUSA, (Graduate Student Member, IEEE),  
KLEBER Z. NÓBREGA, AND  
GUILHERME A. BARRETO, (Member, IEEE)**

Department of Teleinformatics Engineering, Federal University of Ceara, Fortaleza, Ceara, Brazil  
(e-mail: igor.sousa@alu.ufc.br, kznobrega@ufc.br, gbarreto@ufc.br)



This study has financial support from CAPES – Finance Code 001, CNPq (No. 313251/2023-1) and the Centro de Referência em Inteligência Artificial - CEREA, agreements 23067.055633/2021-19 (UFC) / 2020/09706-7 (FAPESP).

**DOI: 10.1109/ACCESS.2024.3503562**

$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_m s^m + a_n s^n + a_0}$$

$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_m s^m + a_n s^n + a_0}$$

$$s = \left[ \begin{array}{c} W_r(z) \\ r \frac{a_n}{a_m} \end{array} \right]^{\frac{1}{mr}}$$

$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_m s^m + a_n s^n + a_0}$$

$$s = \left[ \begin{array}{c} W_r(z) \\ r \frac{a_n}{a_m} \end{array} \right]^{\frac{1}{mr}} \quad z = r \frac{a_n}{a_m} \left( -\frac{a_0}{a_m} \right)^r$$

$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_m s^m + a_n s^n + a_0}$$

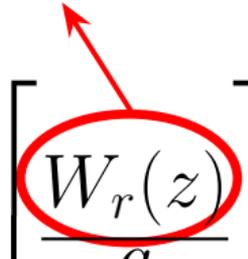
$$s = \left[ \begin{array}{c} W_r(z) \\ r \frac{a_n}{a_m} \end{array} \right]^{\frac{1}{mr}}$$

$$z = r \frac{a_n}{a_m} \left( -\frac{a_0}{a_m} \right)^r$$

$$r = \frac{n - m}{m}$$

$$G_{cl}(s) = \frac{b_1 s^\delta + b_2 s^\epsilon + b_3 s^\zeta + \dots + b_z}{a_m s^m + a_n s^n + a_0}$$

## Função de Lambert-Tsallis

$$s = \left[ \frac{W_r(z)}{r \frac{a_n}{a_m}} \right]^{\frac{1}{mr}}$$


$$z = r \frac{a_n}{a_m} \left( -\frac{a_0}{a_m} \right)^r$$

$$r = \frac{n - m}{m}$$

$$W_q(z) \cdot e_q^{W_q(z)} = z$$

$$W_q(z) \cdot e_q^{W_q(z)} = z$$

G. da Silva e R. Ramos, “**The Lambert–Tsallis  $W_q$  function,**”  
Physica A: Statistical Mechanics and its Applications, vol. 525, pp.  
164–170, 2019. DOI: 10.1016/j.physa.2019.03.046.

$$W_q(z) \cdot e_q^{W_q(z)} = z$$

$$e_q^z \equiv [1 + (1 - q)z]^{\frac{1}{1-q}}$$

G. da Silva e R. Ramos, **“The Lambert–Tsallis  $W_q$  function,”**  
Physica A: Statistical Mechanics and its Applications, vol. 525, pp.  
164–170, 2019. DOI: 10.1016/j.physa.2019.03.046.

$$W_q(z) \cdot e_q^{W_q(z)} = z$$

$$e_q^z \equiv [1 + (1 - q)z]^{1/(1-q)}$$

**exponencial de Tsallis**

G. da Silva e R. Ramos, “**The Lambert–Tsallis  $W_q$  function,**”  
Physica A: Statistical Mechanics and its Applications, vol. 525, pp.  
164–170, 2019. DOI: 10.1016/j.physa.2019.03.046.

## Casos elegíveis para análise com a função de Lambert-Tsallis

case	integer-order controller	fractional-order plant	$Q(s)$
1	$G_c(s) = K_p$	$G_p(s) = \frac{ds^\beta + c}{s^\alpha + a}$	$s^\alpha + bdK_p s^\beta + (a + bcK_p)$
2		$G_p(s) = \frac{c}{s^\beta + ds^\alpha + a}$	$s^\beta + ds^\alpha + (a + bcK_p)$
3		$G_p(s) = \frac{es^\alpha + c}{s^\beta + ds^\alpha + a}$	$s^\beta + (d + beK_p) s^\alpha + (a + bcK_p)$
4	$G_c(s) = K_p + \frac{K_i}{s}$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^{1+\alpha} + (a + bcK_p) s + bcK_i$

## Casos elegíveis para análise com a função de Lambert-Tsallis

2	$G_c(s) = K_p$	$G_p(s) = \frac{c}{s^\beta + ds^\alpha + a}$	$s^\beta + ds^\alpha + (a + bcK_p)$
3		$G_p(s) = \frac{es^\alpha + c}{s^\beta + ds^\alpha + a}$	$s^\beta + (d + beK_p)s^\alpha + (a + bcK_p)$
4	$G_c(s) = K_p + \frac{K_i}{s}$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^{1+\alpha} + (a + bcK_p)s + bcK_i$
5		$G_p(s) = \frac{c}{s^\alpha + a}$	$s^\alpha + bcK_d s + (a + bcK_p)$
6	$G_c(s) = K_p + K_d s$	$G_p(s) = \frac{c}{s + ds^\alpha + a}$	$ds^\alpha + (1 + bcK_d)s + (a + bcK_p)$

## Casos elegíveis para análise com a função de Lambert-Tsallis

4	$G_c(s) = K_p + \frac{K_i}{s}$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^{1+\alpha} + (a + bcK_p)s + bcK_i$
5	$G_c(s) = K_p + K_d s$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^\alpha + bcK_d s + (a + bcK_p)$
6		$G_p(s) = \frac{c}{s + ds^\alpha + a}$	$ds^\alpha + (1 + bcK_d)s + (a + bcK_p)$
	<b>fractional-order controller</b>	<b>integer-order plant</b>	<b><math>Q(s)</math></b>
7	$G_c(s) = K_p + \frac{K_i}{s^\lambda}$	$G_p(s) = \frac{c}{s^n + a}$	$s^{n+\lambda} + (a + bcK_p)s^\lambda + bcK_i$

## Casos elegíveis para análise com a função de Lambert-Tsallis

5	$G_c(s) = K_p + K_d s$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^\alpha + bcK_d s + (a + bcK_p)$
6		$G_p(s) = \frac{c}{s + ds^\alpha + a}$	$ds^\alpha + (1 + bcK_d) s + (a + bcK_p)$
	<b>fractional-order controller</b>	<b>integer-order plant</b>	<b><math>Q(s)</math></b>
7	$G_c(s) = K_p + \frac{K_i}{s^\lambda}$	$G_p(s) = \frac{c}{s^n + a}$	$s^{n+\lambda} + (a + bcK_p) s^\lambda + bcK_i$
8	$G_c(s) = K_p + K_d s^\mu$	$G_p(s) = \frac{c}{s^n + a}$	$s^n + bcK_d s^\mu + (a + bcK_p)$

## Casos elegíveis para análise com a função de Lambert-Tsallis

	fractional-order controller	integer-order plant	$Q(s)$
7	$G_c(s) = K_p + \frac{K_i}{s^\lambda}$	$G_p(s) = \frac{c}{s^n + a}$	$s^{n+\lambda} + (a + bcK_p) s^\lambda + bcK_i$
8	$G_c(s) = K_p + K_d s^\mu$	$G_p(s) = \frac{c}{s^n + a}$	$s^n + bcK_d s^\mu + (a + bcK_p)$
	fractional-order controller	fractional-order plant	$Q(s)$
9	$G_c(s) = K_p + \frac{K_i}{s^\lambda}$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^{\lambda+\alpha} + (a + bcK_p) s^\lambda + bcK_i$

## Casos elegíveis para análise com a função de Lambert-Tsallis

	$G_c(s) = K_p + \frac{K_d}{s^\lambda}$	$G_p(s) = \frac{c}{s^n + a}$	$s^n + (a + bcK_p)s + bcK_i$
8	$G_c(s) = K_p + K_d s^\mu$	$G_p(s) = \frac{c}{s^n + a}$	$s^n + bcK_d s^\mu + (a + bcK_p)$
	<b>fractional-order controller</b>	<b>fractional-order plant</b>	<b><math>Q(s)</math></b>
9	$G_c(s) = K_p + \frac{K_i}{s^\lambda}$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^{\lambda+\alpha} + (a + bcK_p)s^\lambda + bcK_i$
10	$G_c(s) = K_p + K_d s^\mu$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^\alpha + bcK_d s^\mu + (a + bcK_p)$

## Casos elegíveis para análise com a função de Lambert-Tsallis

8	$G_c(s) = K_p + K_d s^\mu$	$G_p(s) = \frac{c}{s^n + a}$	$s^n + bcK_d s^\mu + (a + bcK_p)$
	<b>fractional-order controller</b>	<b>fractional-order plant</b>	<b><math>Q(s)</math></b>
9	$G_c(s) = K_p + \frac{K_i}{s^\lambda}$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^{\lambda+\alpha} + (a + bcK_p) s^\lambda + bcK_i$
10	$G_c(s) = K_p + K_d s^\mu$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^\alpha + bcK_d s^\mu + (a + bcK_p)$
11	$G_c(s) = K_p + K_d s^\alpha$	$G_p(s) = \frac{c}{s^\beta + ds^\alpha + a}$	$s^\beta + (d + bcK_d) s^\alpha + (a + bcK_p)$

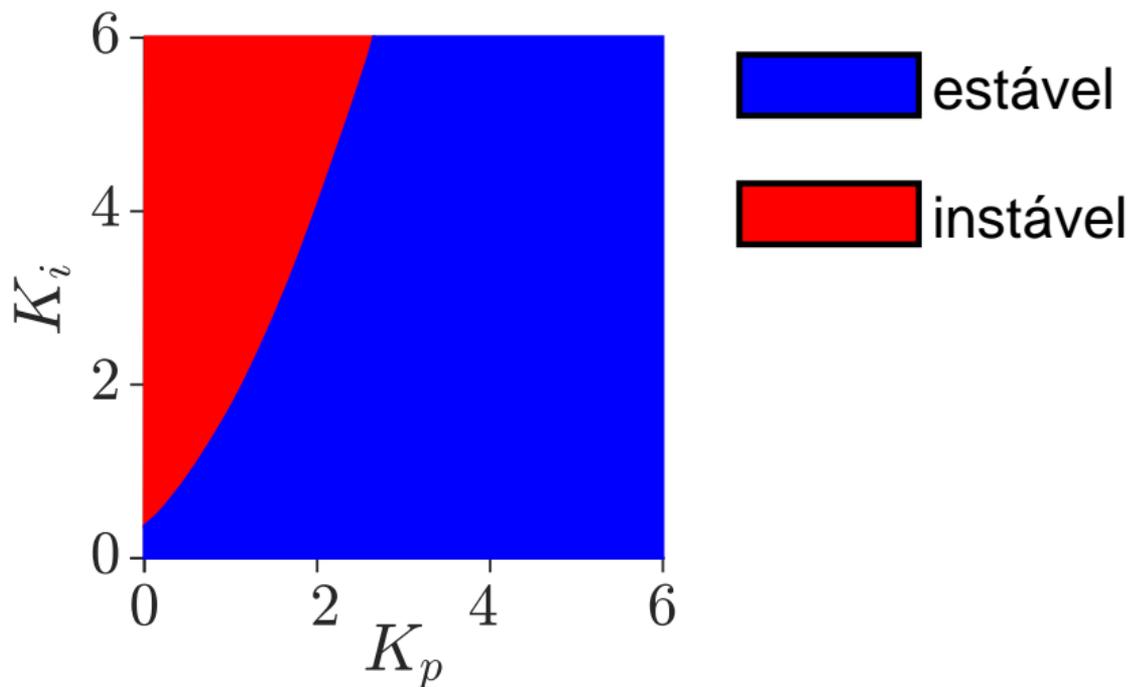
## Casos elegíveis para análise com a função de Lambert-Tsallis

	fractional-order controller	fractional-order plant	$Q(s)$
9	$G_c(s) = K_p + \frac{K_i}{s^\lambda}$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^{\lambda+\alpha} + (a + bcK_p) s^\lambda + bcK_i$
10	$G_c(s) = K_p + K_d s^\mu$	$G_p(s) = \frac{c}{s^\alpha + a}$	$s^\alpha + bcK_d s^\mu + (a + bcK_p)$
11	$G_c(s) = K_p + K_d s^\alpha$	$G_p(s) = \frac{c}{s^\beta + ds^\alpha + a}$	$s^\beta + (d + bcK_d) s^\alpha + (a + bcK_p)$
12	$G(s) = K_p + \frac{K_i}{s^\lambda} + K_d s^\alpha$	$G_p(s) = \frac{c}{s^\alpha + a}$	$(1 + bcK_d) s^{\lambda+\alpha} + (a + bcK_p) s^\lambda + bcK_i$

## Casos elegíveis para análise com a função de Lambert-Tsallis

10	$G_c(s) = K_p + K_d s^\mu$	$G_p(s) = \frac{1}{s^\alpha + a}$	$s^\alpha + bcK_d s^\mu + (a + bcK_p)$
11	$G_c(s) = K_p + K_d s^\alpha$	$G_p(s) = \frac{c}{s^\beta + ds^\alpha + a}$	$s^\beta + (d + bcK_d) s^\alpha + (a + bcK_p)$
12	$G(s) = K_p + \frac{K_i}{s^\lambda} + K_d s^\alpha$	$G_p(s) = \frac{c}{s^\alpha + a}$	$(1 + bcK_d) s^{\lambda+\alpha} + (a + bcK_p) s^\lambda + bcK_i$
13	$G_c(s) = \frac{ds^\alpha + c}{s^\alpha + a}$	$G_p(s) = \frac{e}{s^\alpha + f}$	$s^{2\alpha} + (a + bd + f) s^\alpha + (af + bce)$
14		$G_p(s) = \frac{es^\alpha + g}{s^\alpha + f}$	$(1 + bde) s^{2\alpha} + (a + f + bdg + bce) s^\alpha + (bcg + af)$

## Análise analítica da estabilidade



# Obrigado

contatos: igor.sousa@alu.ufc.br  
kznobrega@ufc.br  
gbarreto@ufc.br



UNIVERSIDADE  
FEDERAL  
DO CEARÁ





# Desenvolvimento e modelagem de algoritmos de aprendizado de máquina em redes de Petri coloridas para o diagnóstico de falha de execução em manipuladores robóticos

Joaquim Osterwald Frota Moura Filho

Orientador: Prof. Dr. Giovanni Cordeiro Barroso

Sinais e sistemas / Reconhecimento de padrões e sistemas dinâmicos



- Avanço da Indústria 4.0: Implementação de mecanismos de conectividade entre maquinários robóticos industriais.
- Flexibilidade e produção interconectada: Capacidade de monitorar e analisar dados operacionais em tempo real.
- Uso de aprendizado de máquina: Permite que dispositivos autônomos detectem e corrijam suas próprias falhas.



- Aprendizado de máquina pode ser difícil de interpretar e visualizar.
- Abstrações claras são essenciais para a manutenção em ambientes industriais.
- Aplicação de aprendizado de máquina em Redes de Petri Coloridas (RPC) com algoritmos como K-NN, Regressão Logística e Naive Bayes.
- Uso de técnicas explicáveis como SHAP e LIME para melhorar a transparência.

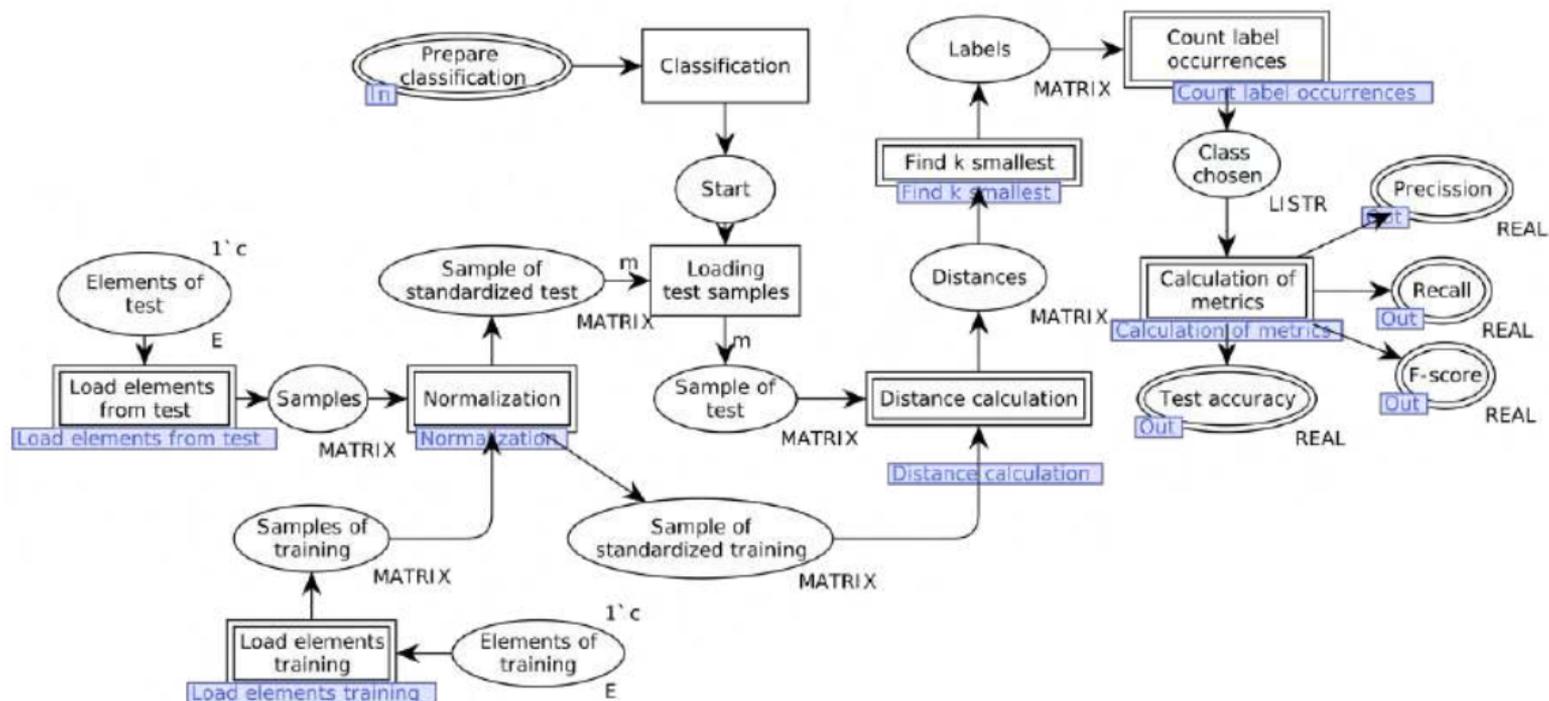


Figura 1: Estrutura do KNNHCPN para classificação

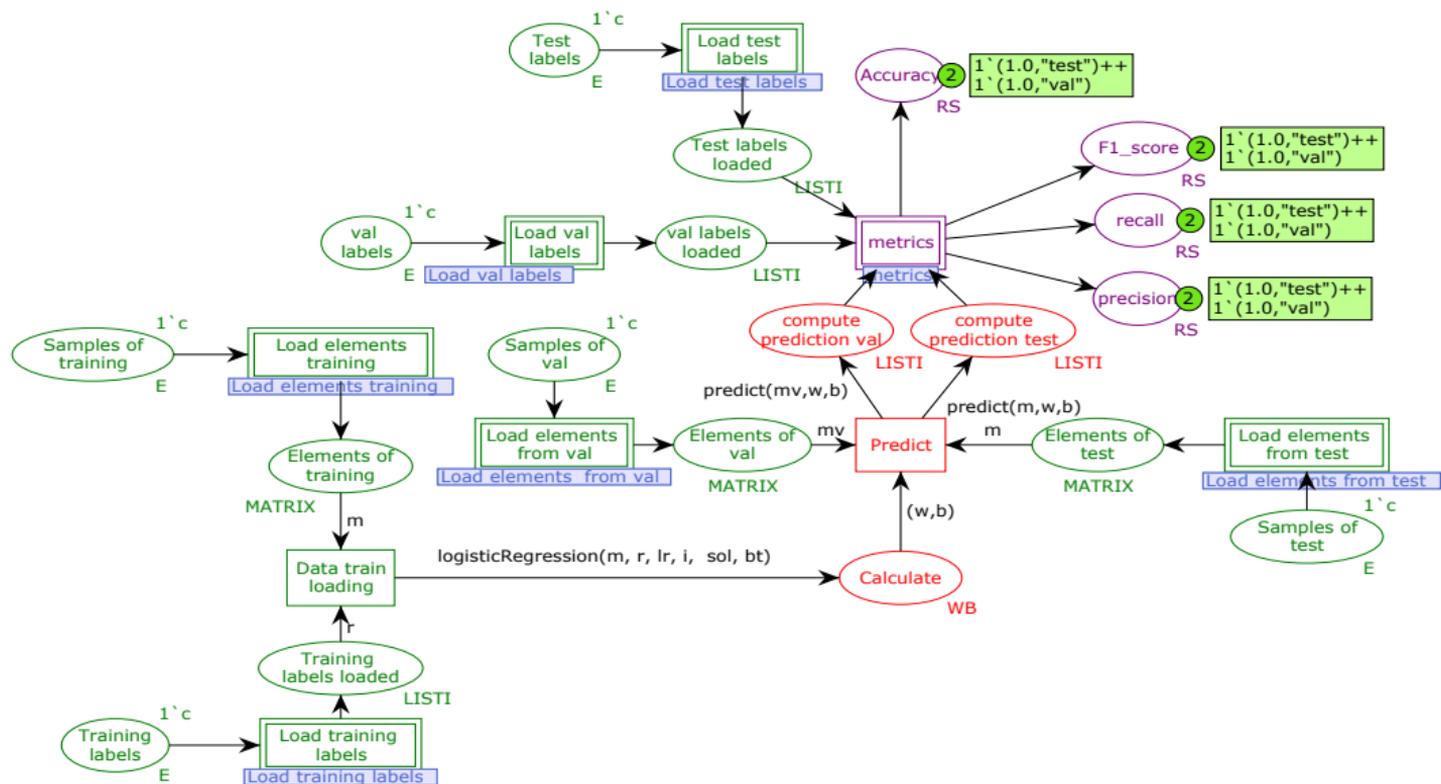


Figura 2: Estrutura do LRHCPN

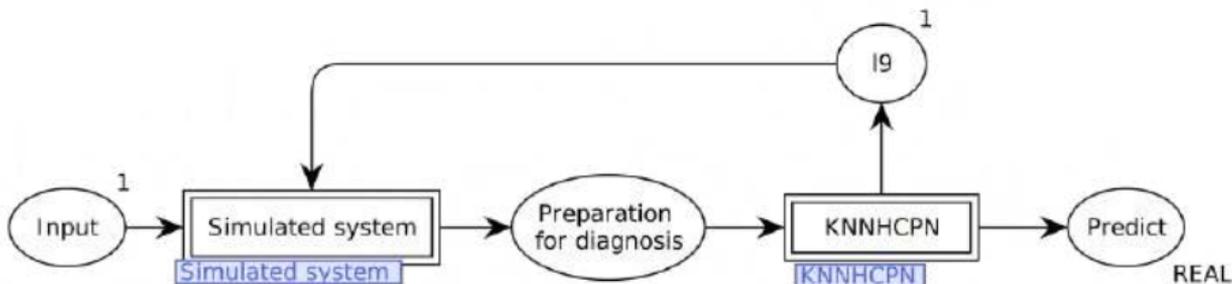


Figura 3: Modelo de um sistema supervisorio para detecção de falhas de execução em manipuladores roboticos

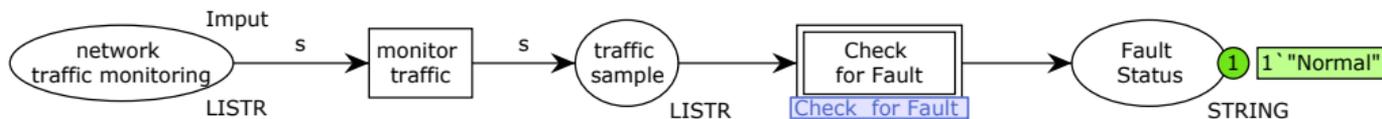


Figura 4: Modelo de um sistema supervisorio para detecção de anomalias no tráfego de rede de dispositivos IoT



- Implementar diversos algoritmos de aprendizado de máquina em RPC para prever e diagnosticar falhas de execução em manipuladores robóticos.
- Desenvolver um sistema de gêmeo digital baseado em RPC, integrando dados reais para diagnósticos precisos e estimativas mais confiáveis da vida útil do sistema.
- Promover uma integração de alto nível entre dispositivos e o modelo em RPC, permitindo o controle eficiente e o monitoramento contínuo de aplicações.
- Explorar algoritmos explicáveis para compreender e justificar as decisões do aprendizado de máquina na detecção de falhas em manipuladores robóticos.



-  Pinto, R., Cerquitelli, T. \*Robot fault detection and remaining life estimation for predictive maintenance\*. Procedia Computer Science, 2019, 151:709-716. DOI: 10.1016/j.procs.2019.04.094.
-  Dash, P., Naik, B., Nayak, J., Shanmuganathan, V. \*Deep belief network-based probabilistic generative model for detection of robotic manipulator failure execution\*. Soft Computing, 2021, 27. DOI: 10.1007/s00500-021-05572-0.
-  Baressi Šegota, S., Anđelić, N., Car, Z., Šercer, M. \*Neural Network-Based Model for Classification of Faults During Operation of a Robotic Manipulator\*. Tehnicki Vjesnik, 2021, 28:1380-1387. DOI: 10.17559/TV-20201112163731.



# Efficient Multivariate Data Fusion for Misinformation Detection During High Impact Events

Lucas Damasceno

Charles Casimiro Cavalcante

PROCESSAMENTO DE SINAIS E IMAGENS / SINAIS E SISTEMAS

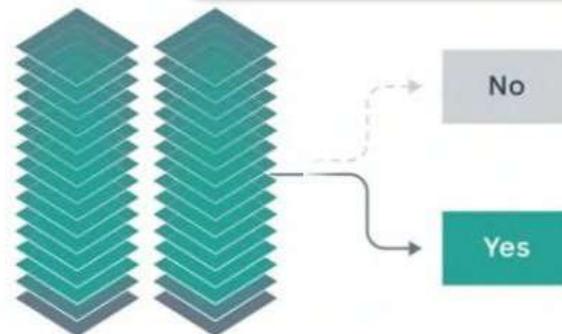
# The power of multi-modality in misinformation detection



To explore the underlying structure of **multi-modal datasets**, i.e., information extraction by integrating and modeling **multiple modalities**.

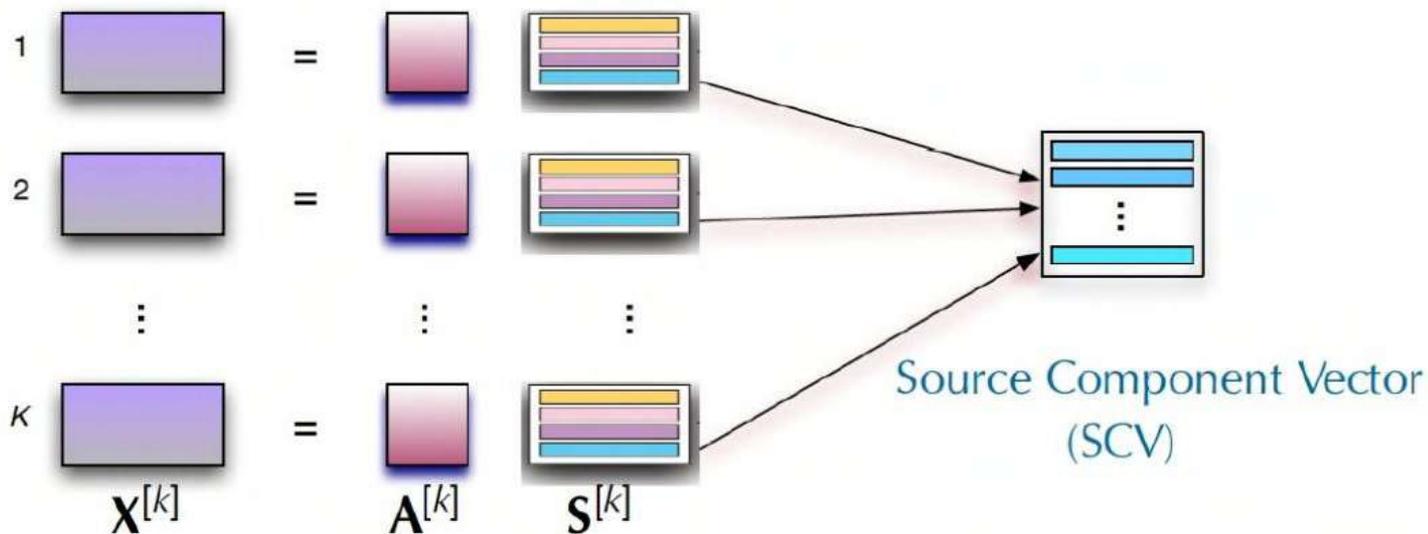


Is this meme hateful?



ICA:  $\mathbf{x} = \mathbf{A}\mathbf{s}$        $\mathbf{y} = \mathbf{W}\mathbf{x}$ ,       $\mathbf{W} \in \mathbb{R}^{N \times N}$

IVA:  $\mathbf{x}^{[k]} = \mathbf{A}^{[k]}\mathbf{s}^{[k]}$        $\mathbf{y}^{[k]} = \mathbf{W}^{[k]}\mathbf{x}^{[k]}$ ,       $\mathbf{W}^{[k]} \in \mathbb{R}^{N \times N}$ ,       $k = 1, \dots, K$



*By utilizing an SCV, IVA empowers intelligent integration of diverse datasets, promoting effective multi-modal learning*

# Misinformation detection Results for high-impact events



## Twitter Dataset and Pipeline

1. MediaEval 2016: A multimodal benchmark dataset for misinformation detection during high impact events
2. 20,000 social media posts (text + images)
3.  $X^{[1]} \in \mathbb{R}^{300 \times V}$  is based on Word2Vec trained on the Google News to generate word embeddings
4.  $X^{[2]} \in \mathbb{R}^{4,096 \times V}$  is based on the VGG-16 pre-trained model with 4,096 hidden units
5.  $X^{[3]} \in \mathbb{R}^{300 \times V}$  "Image2text" features using an Image Captioning PyTorch model pre-trained with ResNet101 features to generate captions for each image in our datasets
6.  $X^{[4]} \in \mathbb{R}^{4,096 \times V}$  is a 200-dimension vector representing the top 200 topics assigned to a tweet using topic modeling

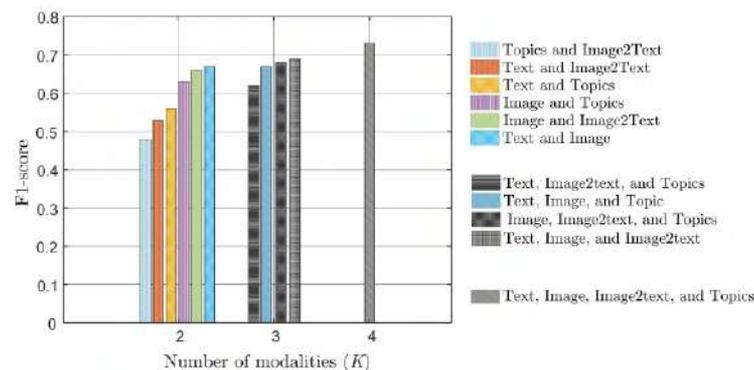


Methods	F1	CPU time
Concatenate	<b>77.59%</b>	$1.7 \times 10^4$
Text	40.04%	$2.7 \times 10^3$
Image	65.78%	$1.03 \times 10^4$

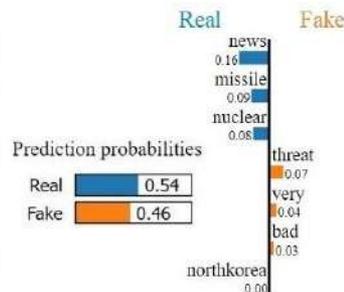
(a) Regular approach

Combination	F1	CPU time
Concatenate	73.77%	$2.4 \times 10^3$
Maximum	73.11%	$1.5 \times 10^3$
Average	<b>77.45%</b>	$1.3 \times 10^3$

(b) IVA-M-EMK



#NorthKorea's Nuclear Missile Threat: Very Bad News <https://t.co/ZUYzdaPKbu>  
<https://t.co/QWm6a6sxWa>





## IVA with Class-Based Constraints

- Incorporate prior knowledge of "Fake" and "Real" classes into the IVA equations.
- Introduce additional constraints to guide the extraction of components **most relevant to classification**.

## Incorporation of Fisher Criterion

- Apply the Fisher Criterion to **maximize the separation between classes**.
- Integrate discrimination metrics (e.g., mean distance and intra-class variance) into the definition of independent vectors.

## Integration of Fisher Discriminant Analysis (FDA)

- Utilize FDA to create a projection space that **enhances class distinction**.
- Align IVA-extracted components with the most discriminative directions defined by FDA.



# On the applications of the Cramér-Rao lower bound for target localization in ISAC networks

Michel Gonzaga dos Santos

Walter da Cruz Freitas Jr.

SISTEMAS E REDES DE COMUNICAÇÕES/ SINAIS E SISTEMAS



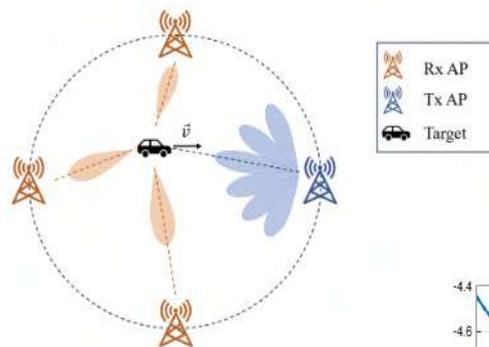
- Integrated Sensing and Communication (ISAC): It aims to combine both radar sensing and communication into the same network.
- Target localization is an important task in radar sensing networks, which can be achieved by exploiting the:
  - Time-of-arrival
  - Direction-of-arrival
  - Doppler Shift
- **The better the accuracy of estimating this parameter, the better the accuracy of the estimated target's position will be.**
  - The Cramér-Rao Lower Bound (CRLB) is an useful metric.

# Problem Description



## Main assumptions

- Distributed MIMO network
- Single Tx AP ( $M_T$  antenna elements)
- $K$  Rx APs ( $M_R$  antenna elements)
- Single passive moving target
- Resolved AP-to-AP interference
- All APs communicate with a CPU
- LoS from the APs to the target



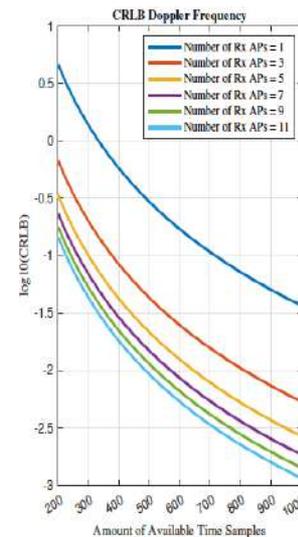
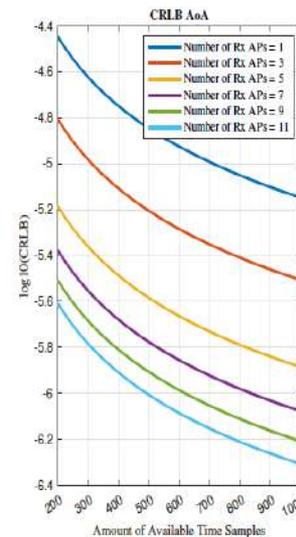
## Received Signal Model

$$\mathbf{y}_k(t) = \alpha_k e^{-j2\pi\tau_l} \mathbf{a}_T(\phi) \mathbf{a}_R^T(\theta) \mathbf{w}_s(t) + \mathbf{z}_k(t) \in \mathbb{C}^{M_T \times 1}$$

Where the index  $k$  represents the  $k$ th AP.

## Problem

Use the Cramér-Rao lower bound as a performance metric to evaluate the asymptotical behavior of the estimation quality of the angle of arrival and Doppler frequency for a single passive target assuming different scenarios.





- Evaluate the viability of using the CRLB as an objective function to allow resource allocation:
  - Time-resources
  - Power budget
- Exploit multipath scenarios, and the impact on the estimation performance
- Replicate the results assuming multiple targets



# Entropia da curvatura multiescala e agregação de descritores no reconhecimento de folhas de plantas

Raphael Gomes Pinheiro

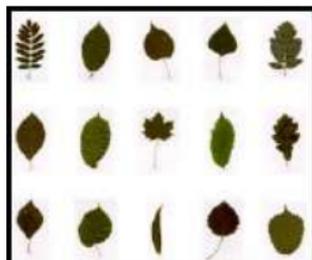
Fátima N. S. de Medeiros

Processamento de Sinais e Imagens / Sinais e Sistemas

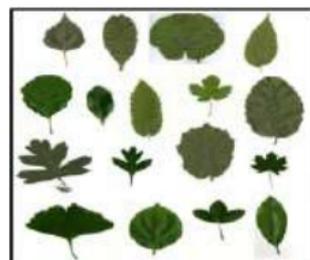
- O reconhecimento tradicional de plantas a partir de suas folhas é uma tarefa desafiadora.
  - Processo demorado e subjetivo;
  - Depende de especialistas qualificados;
  - Demanda por rapidez e precisão.
- Necessidade de automatizar o reconhecimento com métodos computacionais.
  - Redução do esforço humano;
  - Agilidade na classificação de espécies para estudos;
  - Otimização na produção e manejo agrícola.
- Este estudo depende de atributos morfológicos da folha: **forma** e **textura**.
  - A fusão de atributos é capaz de potencializar a classificação de folhas de plantas.



(a) Flavia



(b) Swedish



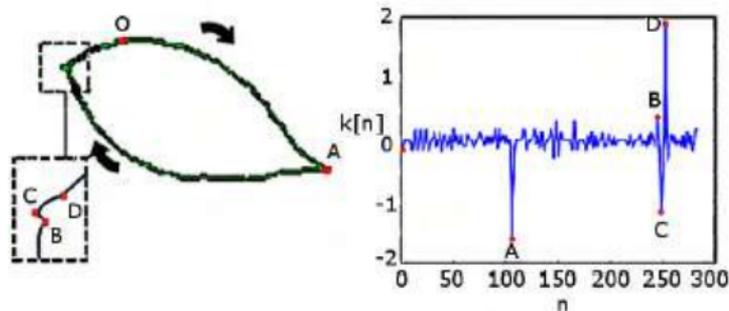
(c) Plantscan

**Figura 1:** Bases públicas de imagens de folhas utilizadas na pesquisa.

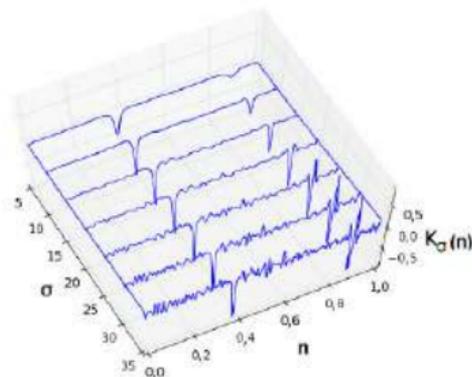
- Descritor proposto: Entropia da Curvatura Multiescala (MEC)



(a) Processamento, segmentação e aquisição do contorno.



(b) Curvatura estimada do contorno de uma folha da base Flavia.



(c) Curvograma.

Figura 2: Processo de extração da curvatura multiescala.

- Como gerar os vários sinais de curvatura?

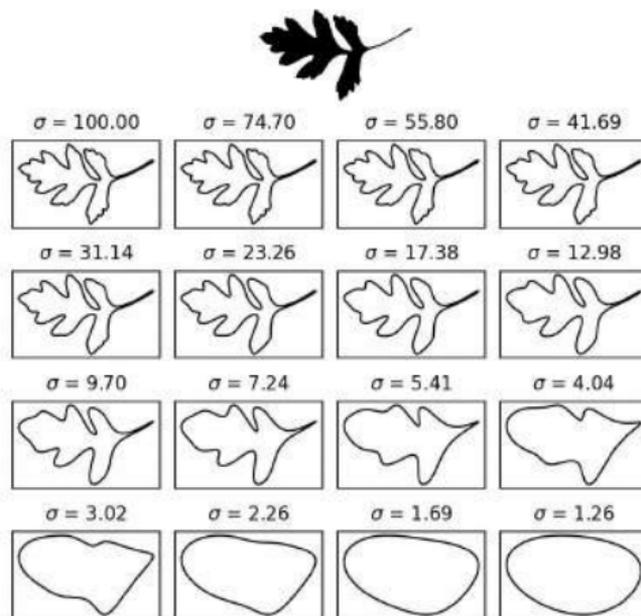


Figura 3: Contorno multiescala de uma folha.



## Definição:

Entropia é uma medida que avalia a quantidade média de informação que uma dada variável aleatória carrega.

- Quanto mais informativa uma variável aleatória é, maior é o seu valor de entropia.
- Em nosso estudo, tal informação advém do contorno das formas e do cálculo de curvatura em múltiplas escalas.

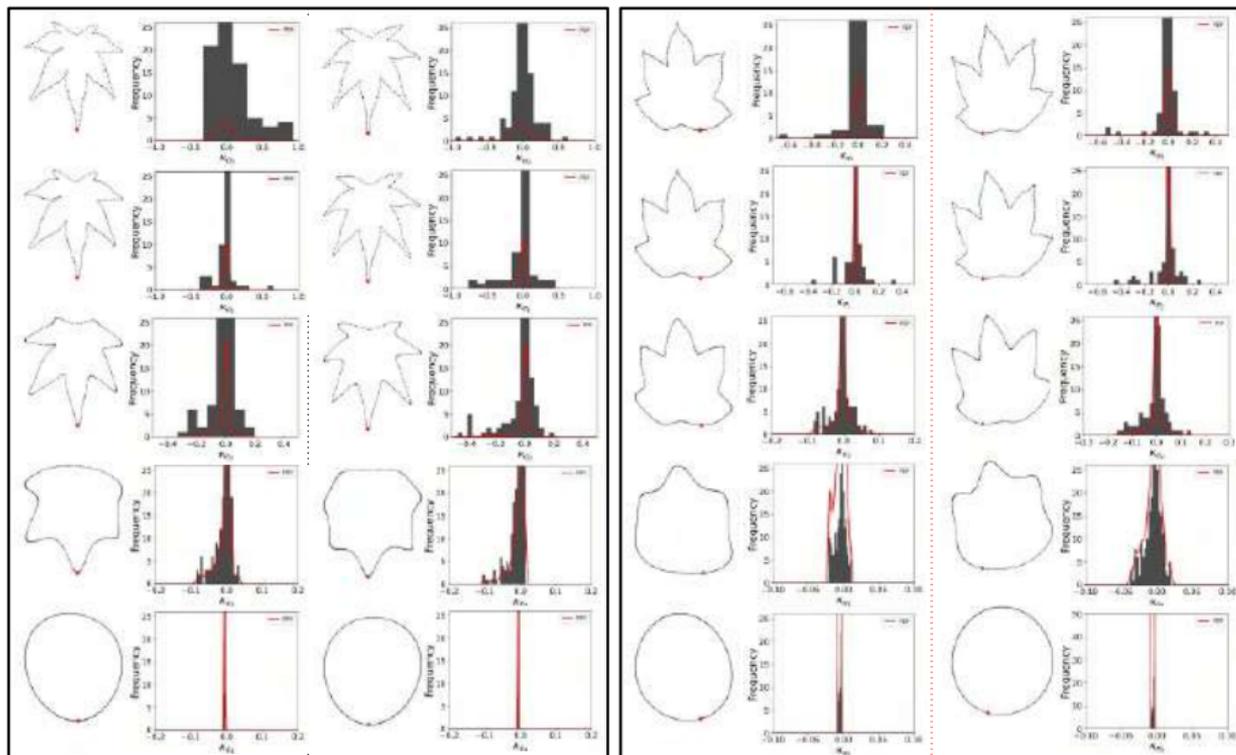
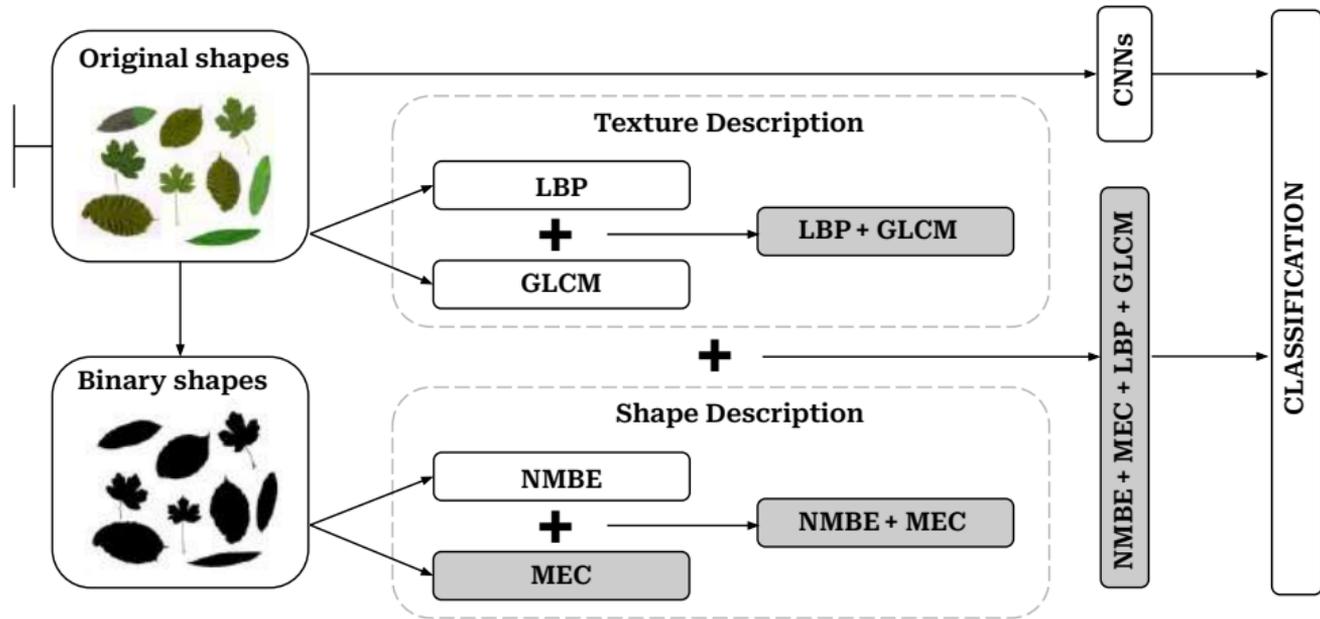


Figura 4: Histogramas em múltiplas escalas das curvaturas de folhas da mesma classe em comparação com folhas de classe diferente.



**Figura 5:** Diagrama da metodologia proposta. As caixas cinzas referem-se às minhas contribuições para derivar o descritor combinado por forma e textura.

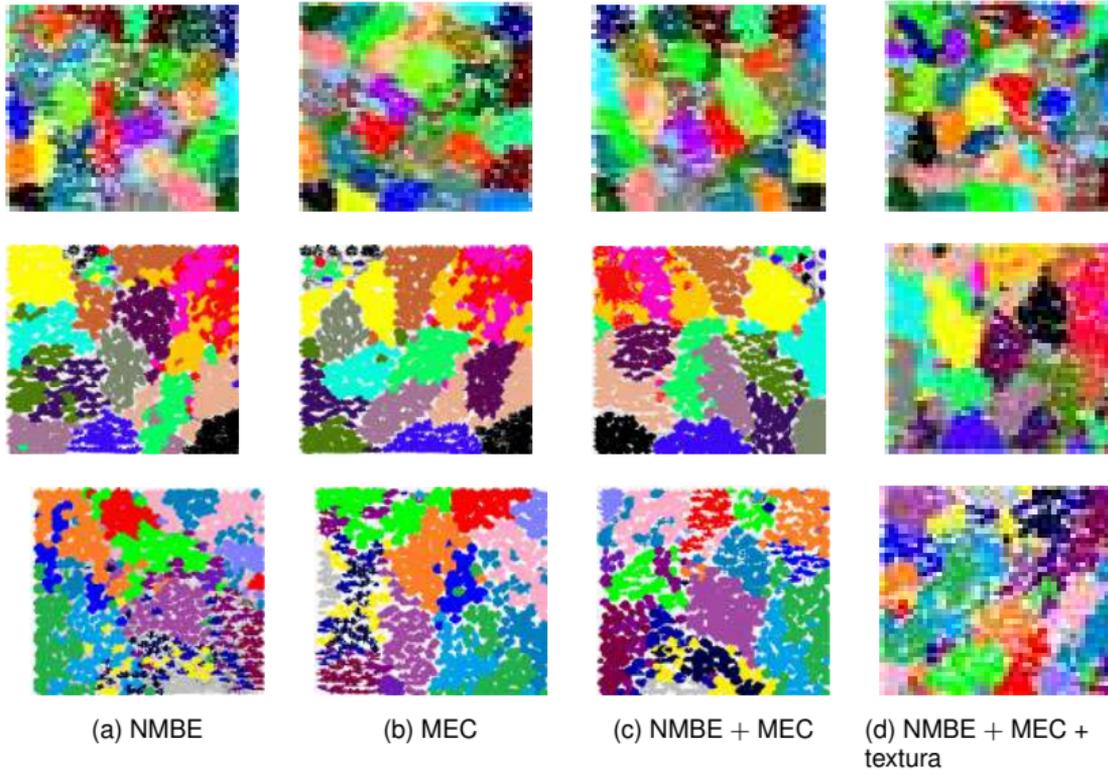


Figura 6: U-matrizes para as folhas das bases Flavia, Swedish e Plantscan, respectivamente.

**Tabela 1:** Resultados de comparação de desempenho dos testes realizados com descritores manuais e profundos para Flavia, Swedish e Plantscan.

Método	Flavia		Swedish		Plantscan	
	F1-score (%)	Acurácia (%)	F1-score (%)	Acurácia (%)	F1-score (%)	Acurácia (%)
NMBE	81.65	81.97	87.39	87.46	79.01	79.54
MEC	90.90	90.97	89.05	89.12	87.76	88.10
NMBE + MEC	93.84	93.88	91.42	91.35	91.35	91.36
<b>NMBE + MEC + Textura</b>	<b>98.93</b>	<b>98.96</b>	<b>98.19</b>	<b>98.21</b>	<b>97.92</b>	<b>97.94</b>
LeNet	86.06	86.04	88.56	88.46	79.74	80.26
VGG16	93.80	93.86	97.14	97.11	93.95	93.99
Xception	88.13	88.00	85.50	85.75	78.54	78.23
EfficientNetV2L	92.67	92.53	94.67	94.63	85.41	85.13



**Tabela 2:** Resultados da comparação de desempenho com diferentes métodos da literatura na classificação de folhas de plantas.

Método	Atributo	Flavia		Swedish	
		F1-score (%)	Acurácia (%)	F1-score (%)	Acurácia (%)
MTCO [1]	Forma	84.82	85.49	96.25	96.31
MFD [2]	Forma	88.83	89.51	97.46	97.60
IMTD [3]	Forma	97.15	97.20	97.86	97.87
<b>NMBE + MEC + Textura</b>	Forma + Textura	98.93	98.96	98.19	98.21
MTD + LBP-HF [4]	Forma + Textura	98.89	99.16	98.54	98.48
VGG16 + relu5-2 [5]	Deep learning	98.24	98.25	98.68	98.67
MaskCOV [6]	Deep learning	99.32	99.30	98.26	98.27



C. Yang, H. Wei, Q. Yu, Multiscale triangular centroid distance for shape-based plant leaf recognition, in: Proceedings of the Twenty-Second European Conference on Artificial Intelligence, ECAI'16, IOS Press, NLD, 2016, p. 269–276.

doi:[10.3233/978-1-61499-672-9-269](https://doi.org/10.3233/978-1-61499-672-9-269).



C. Yang, Q. Yu, Multiscale Fourier descriptor based on triangular features for shape retrieval, Signal Processing: Image Communication 71 (2019) 110–119.

doi:<https://doi.org/10.1016/j.image.2018.11.004>.



H. Wu, L. Fang, Q. Yu, J. Yuan, C. Yang, Plant leaf identification based on shape and convolutional features, Expert Systems with Applications 219 (2023) 119626.

doi:<https://doi.org/10.1016/j.eswa.2023.119626>.



C. Yang, Plant leaf recognition by integrating shape and texture features, Pattern Recognition 112 (APR 2021).

doi:[10.1016/j.patcog.2020.107809](https://doi.org/10.1016/j.patcog.2020.107809).



K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition (2015).

arXiv:1409.1556.



X. Yu, Y. Zhao, Y. Gao, S. Xiong, Maskcov: A random mask covariance network for ultra-fine-grained visual categorization, Pattern Recognition 119 (2021) 108067.

doi:<https://doi.org/10.1016/j.patcog.2021.108067>.



# Tensor Decomposition-Based Machine Learning Approach for Epilepsy Seizure Detection Using EEG Signals

Raul Victor de Oliveira Paiva

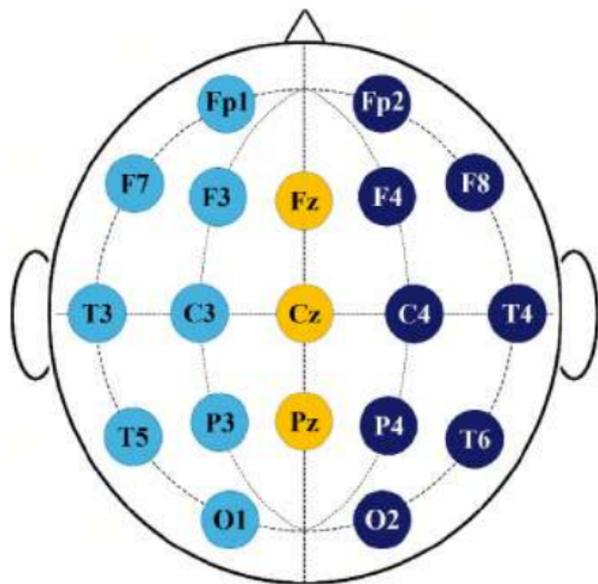
Prof. Dr. Tarcisio Ferreira Maciel

Processamento de Sinais e Imagens / Sinais e sistemas

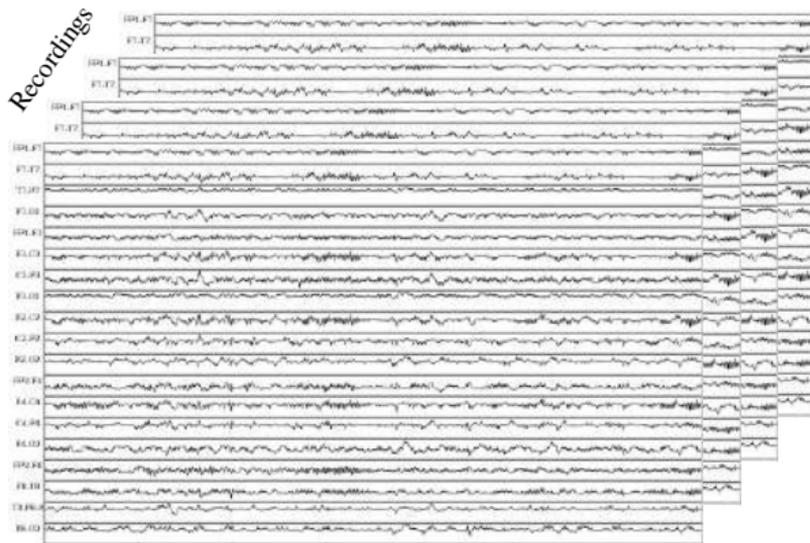


## Epilepsy overview

- Chronic neurological.
- It can occur in humans and animals.
- From primary source or caused.
- Can have life-threatening consequences.
- Utilizes Electroencephalography (EEG) signal analysis.



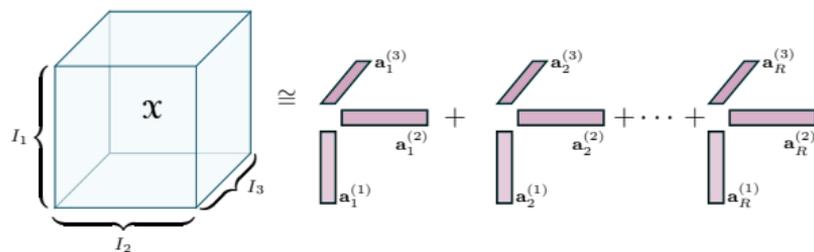
(a) Arrangement of electrodes on the scalp.



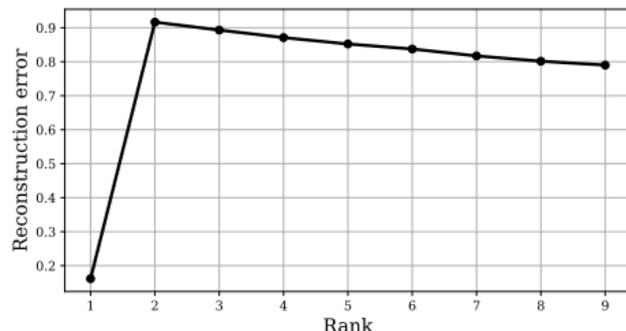
(b) Stacking EEG recordings: Tensorization.

Figure 1: Representation of the tensorization applied to the methodology.

- Challenges with EEG data: high storage demands.
- Tensor decomposition models: Parallel Factor Analysis (PARAFAC).
  - Data compression while preserving essential information.
  - Enables efficient training of machine learning models.



(a) PARAFAC decomposition of a 3-way tensor. Sum of a finite number of rank-one tensors.



(b) Reconstruction error alternating least squares (ALS) with 9 ranks.

Figure 2: PARAFAC representation and rank estimation with alternating least squares (ALS).

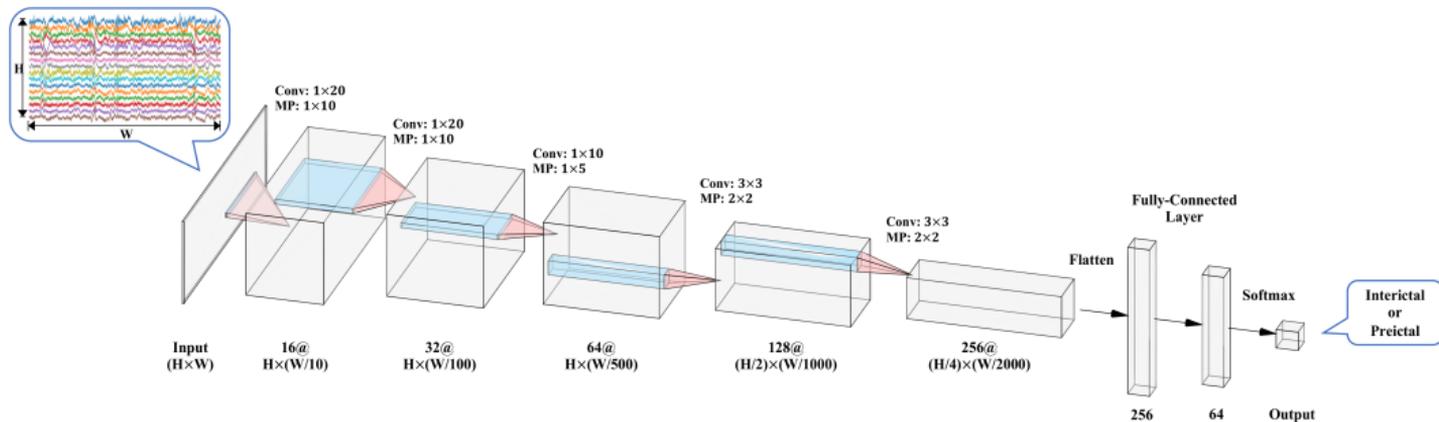
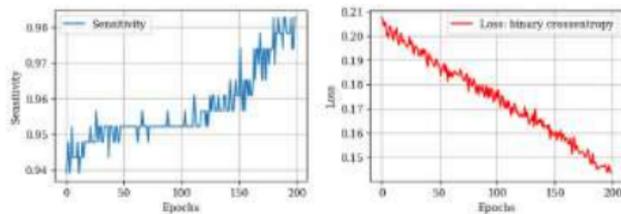
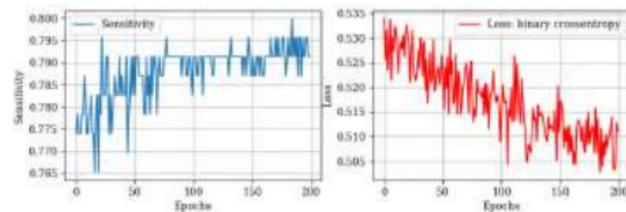


Figure 3: Architecture of the CNN model proposed by [1].

## Previous results



(a) Training evaluation on raw tensor.



(b) Training evaluation on rank-one tensor.

Figure 4: Evaluation during training step on raw and rank-one tensors.

	Raw	Rank-one
Sensitivity [%] - Train / Test	99.0 / 80.0	82.5 / 70.0
Training runtime [s]	$33.0 \pm 0.6$	$30.8 \pm 0.3$

Table 1: Comparison between raw (full-rank) and rank-one tensors, in terms of sensibility and training runtime.



## Perspectives

- Consider more than 1 subject from the CHB-MIT database.
- Preictal intervals to identify impending seizures.
- Reduction of one dimension with PARAFAC (e.g.,  $n^{\circ}$  channels or recordings).

*Thank you !*



-  Y. Xu, J. Yang, S. Zhao, H. Wu, and M. Sawan, “An end-to-end deep learning approach for epileptic seizure prediction,” in *2020 2nd IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS)*. IEEE, Aug. 2020, p. 266–270. [Online]. Available: <http://dx.doi.org/10.1109/AICAS48895.2020.9073988>
-  T. G. Kolda and B. W. Bader, “Tensor decompositions and applications,” *SIAM review*, vol. 51, no. 3, pp. 455–500, 2009.