



# Visão Geral da Pesquisa

## Análise de Séries Temporais - Data Analytics

Eduardo Ogasawara  
[eduardo.ogasawara@cefet-rj.br](mailto:eduardo.ogasawara@cefet-rj.br)  
<https://eic.cefet-rj.br/~eogasawara>

## BIOGRAFIA

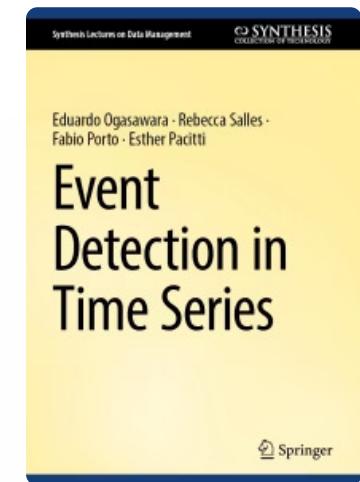
# Trajetória Acadêmica e Profissional

Minha trajetória no CEFET/RJ reúne 15 anos de dedicação ao ensino, à pesquisa e à extensão, com atuação consistente em Ciência da Computação, formação de recursos humanos e contribuições institucionais.

Sua atividade docente abrange os cursos:

- Bacharelado em Ciência da Computação (BCC)
- Mestrado em Ciência da Computação (PPCIC)
- Doutorado em Engenharia de Produção e Sistemas (PPPRO)

Como autor do livro "**Event Detection in Time Series**", publicado pela Springer Nature, consolidou sua expertise na área. É líder do **Data Analytics Lab** e mantém filiações ativas na: **IEEE (Sênior Member)**, SBC e ACM.



# Temas de Pesquisa em Séries Temporais

A pesquisa se concentra em técnicas avançadas de análise de séries temporais, com ênfase em três pilares fundamentais que formam a base de sistemas inteligentes de processamento temporal de dados.

## Pré-processamento

Preparação resiliente a não-estacionariedade

## Predição

Modelos adaptativos e robustos

## Detecção de Eventos

Identificação inteligente de padrões

A detecção de eventos abrange múltiplas subáreas especializadas:



### Detecção de anomalias

Identificação de padrões incomuns e outliers



### Pontos de mudança e desvios

Análise de transições e alterações de comportamento



### Descoberta de motifs

Identificação de padrões recorrentes



### Detecção online

Processamento em tempo real



### Avaliação de detecções

Métricas e validação de resultados

- Referência:** E. Ogasawara, R. Salles, F. Porto, and E. Pacitti, *Event Detection in Time Series*, 1st ed. Springer Nature Switzerland, 2025. doi: 10.1007/978-3-031-75941-3.

# Pré-processamento de Dados em Séries Temporais

O pré-processamento é uma etapa crítica que determina a qualidade das análises subsequentes. A pesquisa desenvolve técnicas especializadas para lidar com os desafios únicos de séries temporais não-estacionárias.

## Abordagens Principais

- **Normalização adaptativa:** Técnicas que se ajustam às mudanças nas características dos dados ao longo do tempo
- **Transformações resilientes:** Métodos que mantêm a integridade dos padrões temporais
- **Filtragem inteligente:** Remoção de ruídos preservando informações relevantes
- **Aumento de dados:** Geração sintética para enriquecer conjuntos limitados

## Extração de Componentes

Decomposição utilizando transformadas de Fourier (FFT), wavelets e decomposição empírica modal (EMD) para revelar estruturas ocultas nos dados.

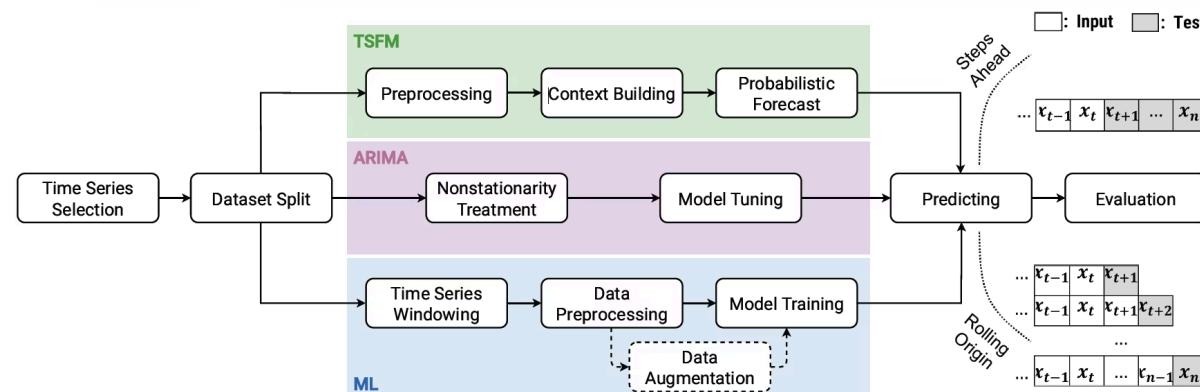
-  **Publicação:** E. Ogasawara, L. C. Martinez, D. De Oliveira, G. Zimbrão, G. L. Pappa, and M. Mattoso, "Adaptive Normalization: A novel data normalization approach for non-stationary time series," *Proceedings of the International Joint Conference on Neural Networks*, 2010. doi: 10.1109/IJCNN.2010.5596746.

# Predição de Séries Temporais

A predição de séries temporais envolve a aplicação de diversos paradigmas de modelagem, desde técnicas estatísticas clássicas até modelos de aprendizado profundo e foundation models especializados. A pesquisa explora a **adaptabilidade e robustez** desses modelos diante de mudanças nos padrões temporais.



## Predições usando ARIMA, ML e TSFM



A otimização e seleção de hiperparâmetros são aspectos fundamentais para garantir o desempenho ideal dos modelos preditivos.

- ❑ **Publicação:** R. Parracho, F. Alexandrino, L. de Souza Figueiredo, B. Dutra de Macedo, A. Lamblet Vaz, D. Louback, V. C. Desouzart, R. Salles, D. Carvalho, F. Porto, and E. Ogasawara, "Leveraging Large Language Models for Time Series Prediction on Low-Frequency Data," *Simpósio Brasileiro de Banco de Dados (SBBD)*, SBC, 2025.

# Detecção de Anomalias em Séries Temporais

A detecção de anomalias identifica padrões incomuns que se desviam significativamente do comportamento esperado.

## Formalização e Taxonomia

Desenvolvimento de frameworks conceituais para classificar e caracterizar diferentes tipos de anomalias: pontuais, contextuais e coletivas.

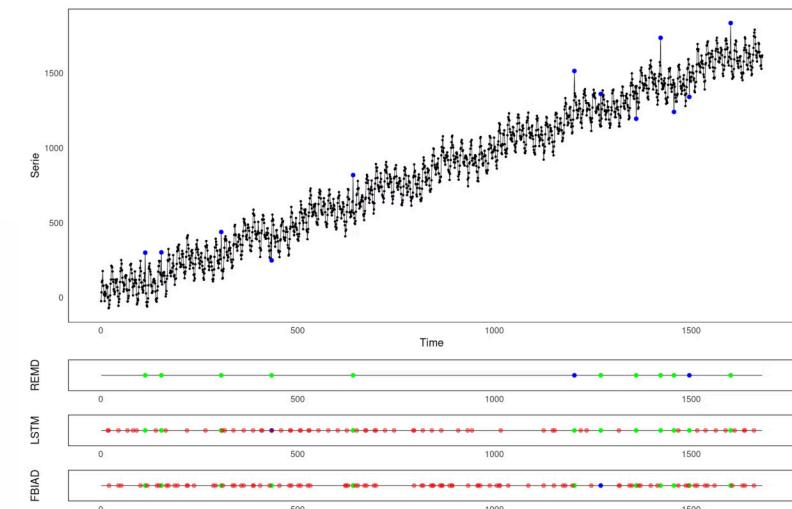
## Métodos Avançados

- **Híbridos:** Combinação de múltiplas técnicas para detecção robusta
- **Preditivos:** Baseados em desvios de previsões
- **Reconstrução:** Utilizando autoencoders e modelos gerativos

## Desafios Principais

1. Não-estacionariedade dos dados
2. Alta dimensionalidade
3. Escassez de rótulos confiáveis

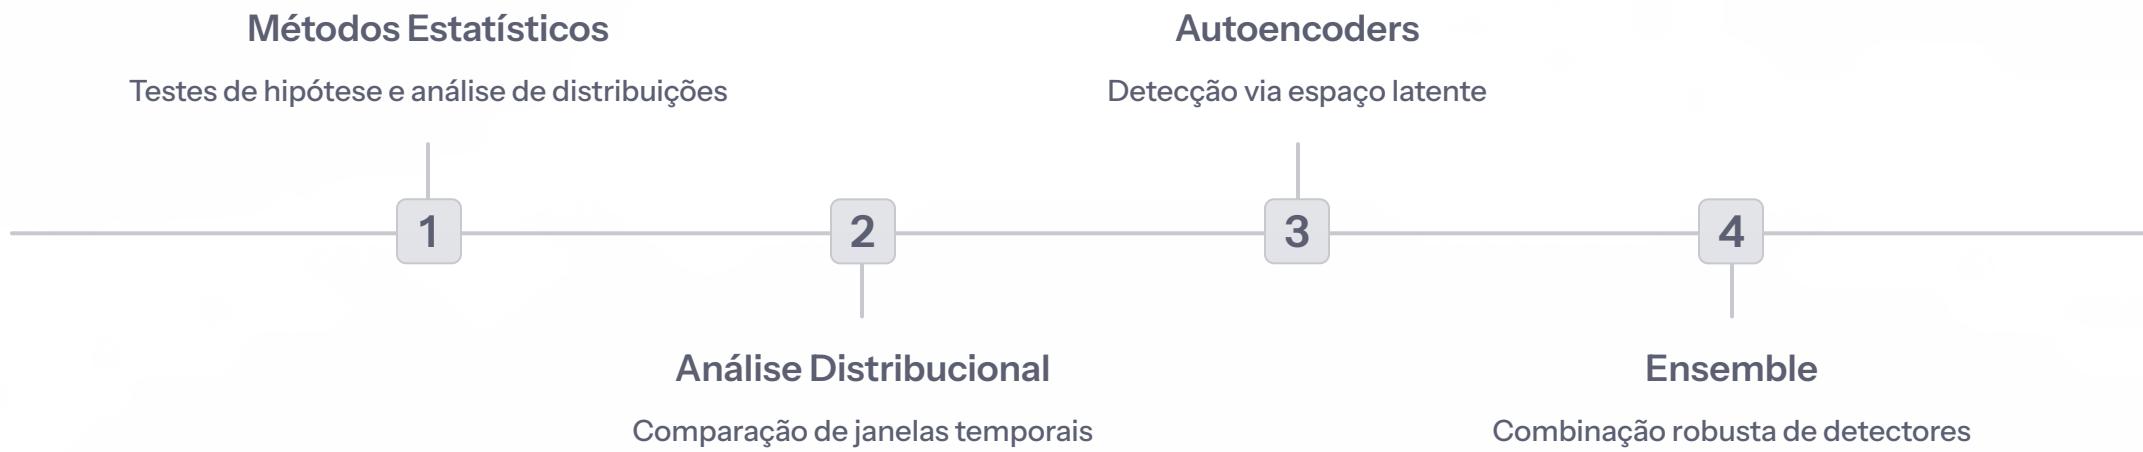
## Detector usando REMD, FIBAD, LSTM



**Publicação:** J. Souza, E. Paixão, F. Fraga, L. Baroni, R. F. S. Alves, K. Belloze, J. Dos Santos, E. Bezerra, F. Porto, and E. Ogasawara, "REMD: A Novel Hybrid Anomaly Detection Method Based on EMD and ARIMA," *Proceedings of the International Joint Conference on Neural Networks*, 2024. doi: 10.1109/IJCNN60899.2024.10651192.

# Detecção de Pontos de Mudança e Desvio de Conceito

Pontos de mudança marcam transições fundamentais no comportamento de séries temporais, enquanto desvios de conceito representam alterações graduais ou abruptas nas relações subjacentes dos dados. A detecção precisa desses eventos é crucial para manter a acurácia de sistemas preditivos.



## Abordagens Inovadoras

Modelos ensemble proporcionam detecção mais robusta ao combinar múltiplos detectores, enquanto a análise espectral em camadas latentes de redes profundas revela mudanças sutis não aparentes no espaço original.

- ❑ **Publicação:** L. G. Tavares et al., "Fuzzy-Based Ensemble Method for Robust Concept Drift Detection in Multivariate Time Series," *Proceedings of the International Joint Conference on Neural Networks*, 2025.

# Descoberta de Motifs em Séries Temporais

Motifs são padrões recorrentes em séries temporais que representam comportamentos ou eventos significativos. Sua descoberta e indexação permite a interpretação de eventos complexos e a identificação de estruturas temporais importantes.

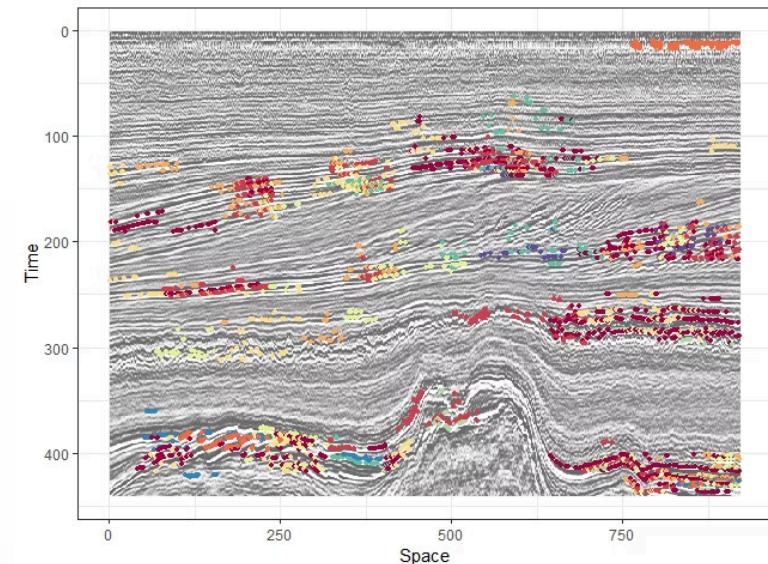
## Contribuições Principais

- **Indexação eficiente:** Estruturas de dados para busca rápida de motifs
- **Rotulação semântica:** Atribuição de significado aos padrões descobertos
- **Motifs espaço-temporais:** Extensão para dados com dimensão espacial

## Aplicações

A descoberta de motifs tem aplicações em diversas áreas, incluindo monitoramento sísmico, análise de sinais biomédicos, detecção de fraudes e manutenção preditiva.

## Detecção em dados sísmicos



- **Publicação:** H. Borges, M. Dutra, A. Bazaz, R. Coutinho, F. Perosi, F. Porto, F. Masseglia, E. Pacitti, and E. Ogasawara, "Spatial-time motifs discovery," *Intelligent Data Analysis*, vol. 24, no. 5, pp. 1121–1140, 2020. doi: 10.3233/IDA-194759.

TEMPO REAL

## Detecção Online de Eventos

A detecção online processa fluxos contínuos de dados com restrições rigorosas de latência, essencial para aplicações que exigem respostas imediatas. Esta área apresenta desafios únicos relacionados à eficiência computacional e adaptação contínua.

### Processamento Contínuo

Análise em tempo real sem interrupções

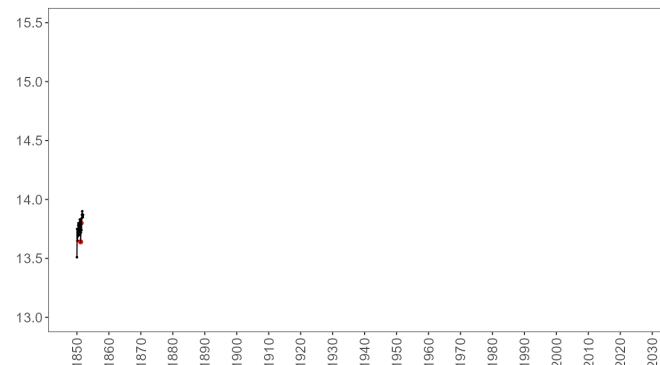
### Janelas Deslizantes

Atualização incremental de modelos

### Adaptação Dinâmica

Ajuste automático a mudanças

#### Exemplo: Detecção Online de Anomalia



O sistema ilustrado demonstra a capacidade de identificar anomalias em tempo real, permitindo respostas imediatas a eventos críticos.

**Publicação:** J. Lima, L. G. Tavares, E. Pacitti, J. E. Ferreira, I. Santos, I. G. Siqueira, D. Carvalho, F. Porto, R. Coutinho, and E. Ogasawara, "Online Event Detection in Streaming Time Series: Novel Metrics and Practical Insights," *Proceedings of the International Joint Conference on Neural Networks*, 2024. doi: 10.1109/IJCNN60899.2024.10650809.

# Avaliação de Detecções em Séries Temporais

A avaliação de detectores de eventos em séries temporais requer métricas especializadas que considerem a natureza temporal dos dados. Diferentemente de problemas de classificação tradicionais, pequenos desalinhamentos temporais não devem ser penalizados severamente.

## Desafios na Avaliação

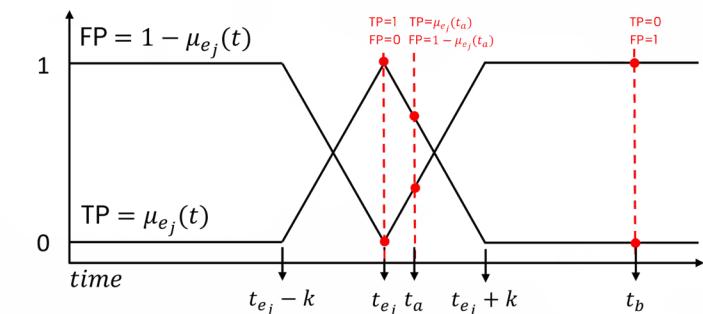
- Tolerância temporal:** Detecções próximas devem ser consideradas corretas
- Curadoria contínua:** Validação de detecções em fluxos de dados
- Imprecisão inerente:** detecção de eventos raramente são exatas

## Contribuições

Desenvolvimento de métricas baseadas em lógica fuzzy que incorporam tolerância temporal, permitindo avaliação mais justa e realista de sistemas de detecção.

A construção de benchmarks com rótulos consistentes e interpretações padronizadas é fundamental para o avanço da área, permitindo comparações justas entre diferentes métodos.

## Tolerância temporal fuzzy

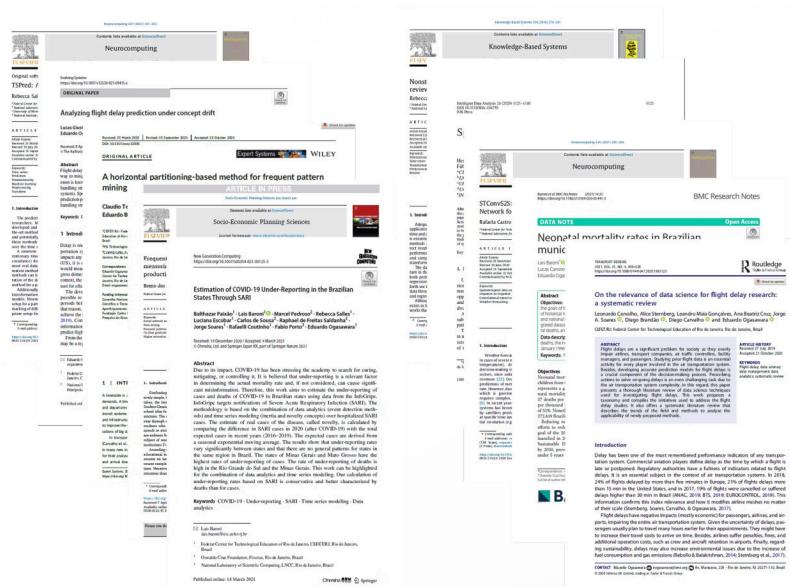


- Publicação:** R. Salles, J. Lima, M. Reis, R. Coutinho, E. Pacitti, F. Masseglia, R. Akbarinia, C. Chen, J. Garibaldi, F. Porto, and E. Ogasawara, "SoftED: Metrics for soft evaluation of time series event detection," *Computers and Industrial Engineering*, vol. 198, 2024. doi: 10.1016/j.cie.2024.110728.

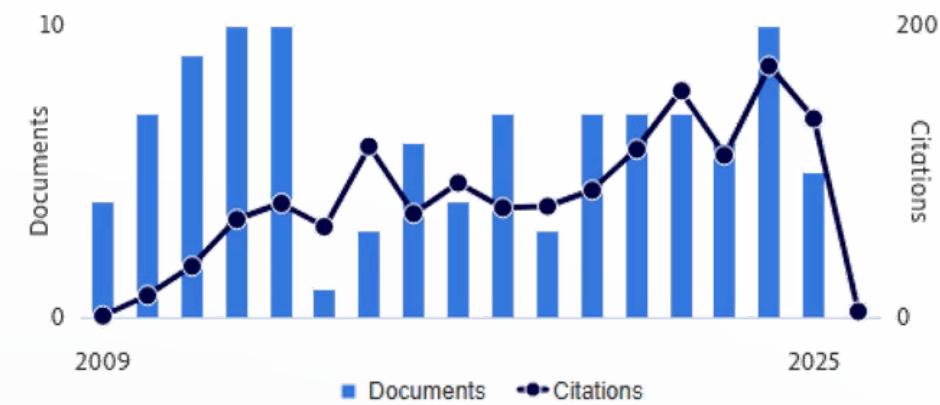
# Produção Intelectual: Visão Geral

A produção intelectual é um pilar fundamental da contribuição científica (qualidade, consistência e impacto internacional). As métricas apresentadas, provenientes do Scopus e Web of Science, demonstram a relevância e o alcance da pesquisa realizada.

Base	Publicações	H-index	Citações
Scopus	106	19	1480
Web of Science	94	15	819

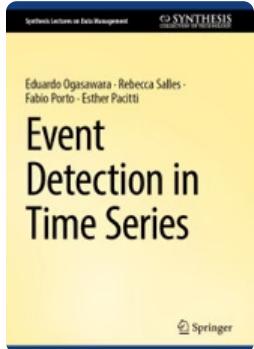


## Document & citation trends



# Produção Intelectual: Destaques

1



## Livro Springer

Publicação de livro pela Springer. O livro aborda detecção de eventos em séries temporais, consolidando as minhas pesquisas nos últimos anos e estabelecendo trilhas para novas pesquisas.

2



## Normalização Adaptativa

Desenvolvimento de técnica de normalização adaptativa para séries temporais. A técnica permite ajuste dinâmico de escala conforme características locais dos dados.

3



## Álgebra de Workflows

Criação de álgebra e motor de workflows científicos Chiron que viabiliza a execução otimizada de workflows em ambientes paralelos e distribuídos.

4



## Fuzzyficação do tempo

Os trabalhos recentes que introduzem tolerância temporal na detecção de eventos, abrindo novas possibilidades de avaliação e aplicação prática.

# Desenvolvimento Tecnológico

A produção tecnológica materializa a pesquisa científica em ferramentas práticas que beneficiam pesquisadores, profissionais e a sociedade. Os pacotes de software desenvolvidos são **disponibilizados como código aberto**, promovendo transparência, colaboração e amplo impacto social.



## daltoolbox

Framework para ciência de dados em R, com ferramentas integradas para pré-processamento, modelagem, visualização e avaliação. Serve de base para o harbinger e tsredit.



## harbinger

Pacote especializado em detecção de eventos em séries temporais. Implementa algoritmos de estado da arte e as métricas SoftED, facilitando a pesquisa reproduzível e aplicações industriais em monitoramento e alertas.



## tsredit

Conjunto de ferramentas para previsão de séries temporais, que integram métodos estatísticos clássicos e técnicas de aprendizado de máquina. Permite a comparação de modelos e a seleção automatizada de hiperparâmetros.

daltoolbox	downloads 1147/month
harbinger	downloads 22K/month
tsredit	downloads 22K/month
daltoolboxdp	downloads 422/month

# Projetos e Grupos de Pesquisa



## Liderança do DAL

Criação e liderança do **Data Analytics Lab (DAL)**, grupo de pesquisa consolidado e certificado pelo CNPq, que reúne professores, pesquisadores e estudantes em torno de pesquisas em ciência de dados, especialmente na análise de séries temporais.

## Projetos de Pesquisa Financiados

- **CNPq:** Bolsa de Produtividade em Pesquisa (Nível C)
- **FAPERJ:** Cientista do Nosso Estado\* e projetos de pesquisa básica e aplicada
- **INRIA:** Cooperação internacional no projeto Dinizia (*Data Science for the Natural Environment*).

Estes projetos proporcionam recursos para formação de recursos humanos, infraestrutura de pesquisa e estabelecimento de colaborações nacionais e internacionais

# Orientações: Visão Quantitativa

O histórico de orientações demonstra consistência, amplitude e qualidade na formação de estudantes e pesquisadores.

**38**

**TCC**

Orientações de TCC na  
graduação, abrangendo temas  
variados em computação e  
ciência de dados

**28**

**Dissertações**

Formação de mestres com  
pesquisas originais publicadas  
em conferências e periódicos  
relevantes

**7**

**Teses**

Orientação de doutores com  
contribuições científicas de  
impacto internacional  
comprovado

**35**

**IC**

Formação inicial de jovens  
pesquisadores, incentivando o  
pensamento científico desde a  
Graduação e ETPNM

Este conjunto totaliza **108 orientações concluídas**, evidenciando uma produção consistente e sustentável ao longo dos anos, com impactos diretos na formação de recursos humanos especializados em áreas estratégicas para o desenvolvimento nacional.

## Orientações: Impacto e Integração



### Publicações Conjuntas

As orientações resultam em **publicações** em conferências e periódicos nacionais e internacionais. Os orientandos aparecem como coautores em trabalhos indexados na Web of Science e Scopus.



### Formação de Recursos Humanos

Os egressos ocupam posições de destaque na **academia, indústria e setor público**.



### Integração com Pesquisa

As orientações estão organicamente integradas aos projetos de pesquisa do Data Analytics Lab (DAL), criando um **ambiente colaborativo e produtivo**.

# Colaboração

As colaborações acadêmicas e profissionais são fundamentais para o desenvolvimento de pesquisas de ponta e para a formação de novos talentos.

## Externos



Marta Mattoso\* (COPPE/UFRJ)



Patrick Valduriez\* (INRIA/LNCC)



Fabio Porto (LNCC)



Esther Pacitti (INRIA/Univ.  
Montpellier)



Daniel de Oliveira (UFF)



Leonardo Murta (UFF)

## Internos



Eduardo Bezerra



Rafaelli Coutinho



Jorge Soares



Gustavo Guedes



Diego Carvalho



João Quadros

## Alunos/Egressos

A formação de recursos humanos qualificados, através da orientação dos nossos alunos, se reflete em seu sucesso profissional e impacto no mercado.



Rebecca Salles (INRIA)



Lais Baroni



Jésica Souza (Nubank)



Alice Sterberg (Petrobras)



Heraldo Borges (CEFET/RJ)



Leonardo Mosqueira (Petrobras)



Luciana Escobar (SENAI)



Ana Beatriz Cruz (Liora Energia)



Janio Lima



Murillo Dutra (Anderson)



Lucas Tavares



Fernando Alexandrino

# Características Esperadas de Orientandos(as)

A orientação bem-sucedida requer um conjunto de características e competências que vão além do conhecimento técnico. Busca-se estudantes que demonstrem comprometimento com a excelência científica e desenvolvimento profissional contínuo.



## Dedicação

Compromisso com o tempo e esforço necessários para conduzir pesquisa de qualidade, priorizando o desenvolvimento acadêmico



## Engajamento

Participação ativa em discussões, seminários e atividades do laboratório, contribuindo para o ambiente coletivo de aprendizado



## Programação

Habilidades sólidas em programação e disposição para aprender novas ferramentas e tecnologias conforme necessário



## Planejamento

Capacidade de estabelecer metas, gerenciar cronogramas e cumprir prazos de forma consistente e organizada



## Escrita

Habilidade e disposição para desenvolver textos científicos claros e bem estruturados, essencial para publicações



## Atitude

Postura proativa, resiliência diante de desafios, curiosidade intelectual e disposição para crescimento contínuo

- ☐ Estas características não são pré-requisitos absolutos, mas sim qualidades que se espera desenvolver e fortalecer ao longo do processo de orientação. O mais importante é demonstrar **vontade de aprender e compromisso com o crescimento**.



# Até logo!



## Eduardo Ogasawara

Professor Titular

CEFET/RJ

[eduardo.ogasawara@cefet-rj.br](mailto:eduardo.ogasawara@cefet-rj.br)

Interessado em colaborar?

<https://eic.cefet-rj.br/~eogasawara>

Entre em contato para discutir oportunidades de pesquisa, orientação ou parcerias

Visite nosso laboratório

<https://eic.cefet-rj.br/dal>

Conheça os projetos em andamento e as ferramentas desenvolvidas pelo Data Analytics Lab