

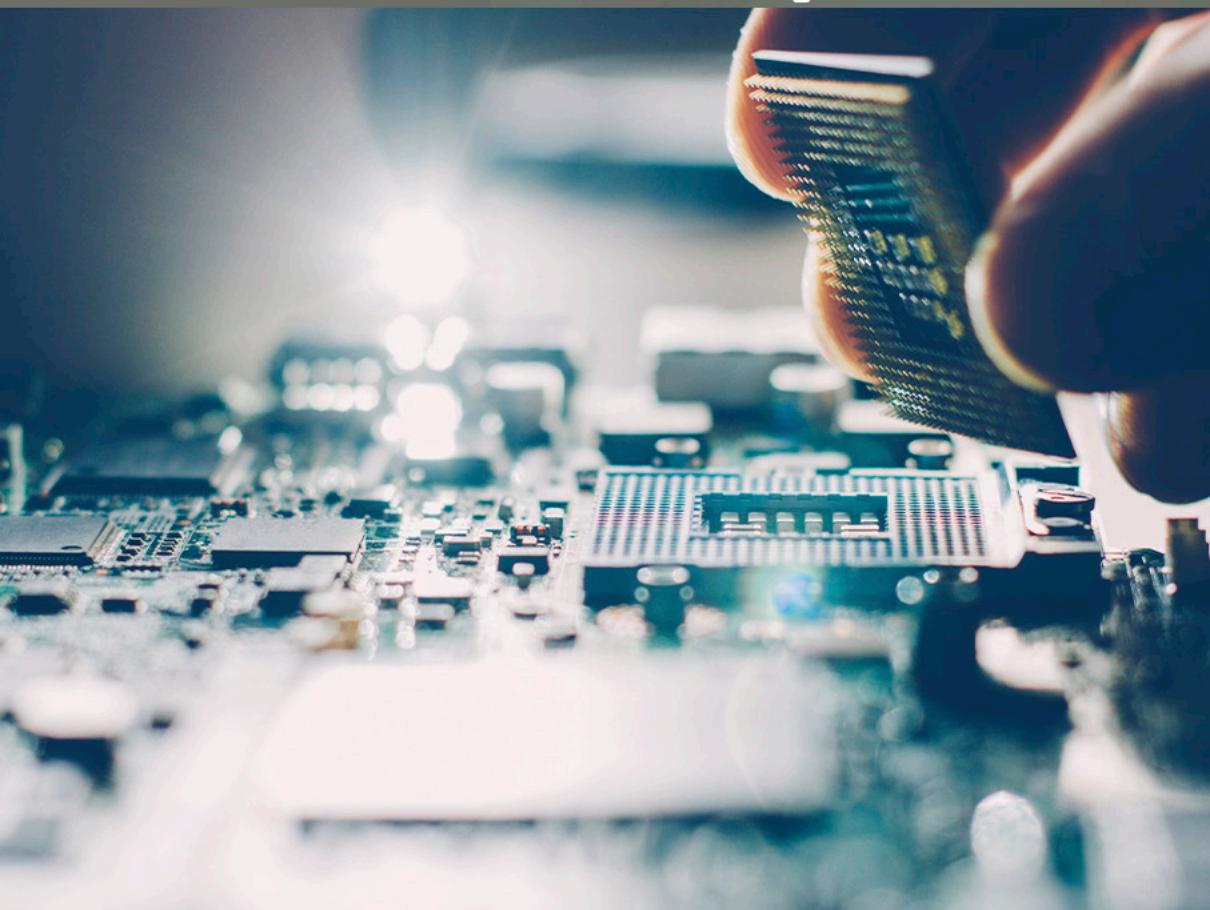
COLEÇÃO

# DESAFIOS

DAS

# ENGENHARIAS:

## ENGENHARIA DE COMPUTAÇÃO



ERNANE ROSA MARTINS  
(ORGANIZADOR)

 Atena  
Editora  
Ano 2021

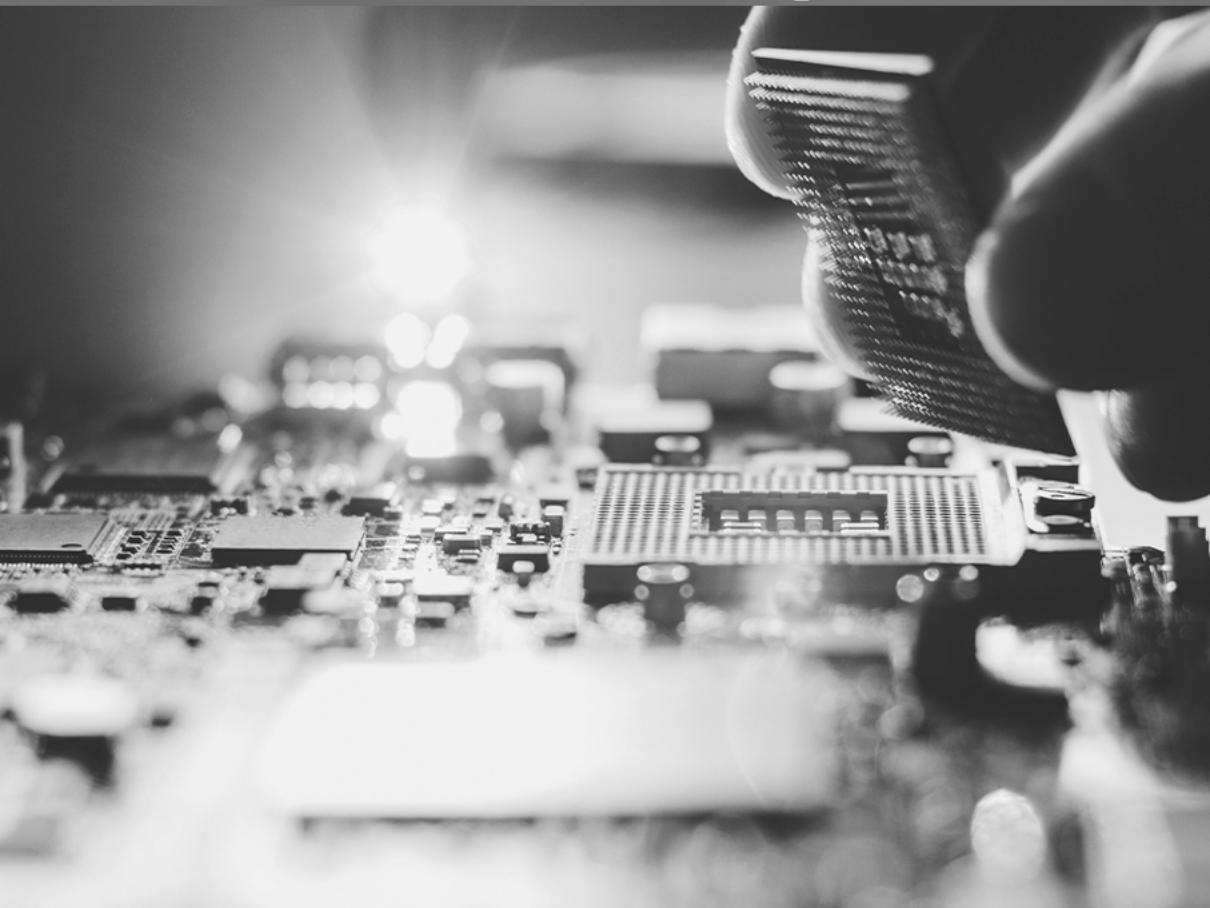
COLEÇÃO

# DESAFIOS

DAS

# ENGENHARIAS:

## ENGENHARIA DE COMPUTAÇÃO



ERNANE ROSA MARTINS  
(ORGANIZADOR)

 Atena  
Editora  
Ano 2021

**Editora chefe**

Prof<sup>a</sup> Dr<sup>a</sup> Antonella Carvalho de Oliveira

**Assistentes editoriais**

Natalia Oliveira

Flávia Roberta Barão

**Bibliotecária**

Janaina Ramos

**Projeto gráfico**

Natália Sandrini de Azevedo

Camila Alves de Cremo

Luiza Alves Batista

Maria Alice Pinheiro

**Imagens da capa**

iStock

**Edição de arte**

Luiza Alves Batista

**Revisão**

Os autores

2021 by Atena Editora

Copyright © Atena Editora

Copyright do Texto © 2021 Os autores

Copyright da Edição © 2021 Atena Editora

Direitos para esta edição cedidos à Atena Editora pelos autores.

Open access publication by Atena Editora



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição Creative Commons. Atribuição-Não-Comercial-NãoDerivativos 4.0 Internacional (CC BY-NC-ND 4.0).

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores, inclusive não representam necessariamente a posição oficial da Atena Editora. Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação com base em critérios de neutralidade e imparcialidade acadêmica.

A Atena Editora é comprometida em garantir a integridade editorial em todas as etapas do processo de publicação, evitando plágio, dados ou resultados fraudulentos e impedindo que interesses financeiros comprometam os padrões éticos da publicação. Situações suspeitas de má conduta científica serão investigadas sob o mais alto padrão de rigor acadêmico e ético.

**Conselho Editorial**

**Ciências Humanas e Sociais Aplicadas**

Prof. Dr. Alexandre Jose Schumacher – Instituto Federal de Educação, Ciência e Tecnologia do Paraná

Prof. Dr. Américo Junior Nunes da Silva – Universidade do Estado da Bahia

Prof<sup>a</sup> Dr<sup>a</sup> Andréa Cristina Marques de Araújo – Universidade Fernando Pessoa

Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná

Prof. Dr. Antonio Gasparetto Júnior – Instituto Federal do Sudeste de Minas Gerais

Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília

Prof. Dr. Arnaldo Oliveira Souza Júnior – Universidade Federal do Piauí  
Prof. Dr. Carlos Antonio de Souza Moraes – Universidade Federal Fluminense  
Prof. Dr. Crisóstomo Lima do Nascimento – Universidade Federal Fluminense  
Prof<sup>a</sup> Dr<sup>a</sup> Cristina Gaio – Universidade de Lisboa  
Prof. Dr. Daniel Richard Sant'Ana – Universidade de Brasília  
Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia  
Prof<sup>a</sup> Dr<sup>a</sup> Dilma Antunes Silva – Universidade Federal de São Paulo  
Prof. Dr. Edvaldo Antunes de Farias – Universidade Estácio de Sá  
Prof. Dr. Elson Ferreira Costa – Universidade do Estado do Pará  
Prof. Dr. Elio Martins Senhora – Universidade Federal de Roraima  
Prof. Dr. Gustavo Henrique Cepolini Ferreira – Universidade Estadual de Montes Claros  
Prof. Dr. Humberto Costa – Universidade Federal do Paraná  
Prof<sup>a</sup> Dr<sup>a</sup> Ivone Goulart Lopes – Istituto Internazionale delle Figlie di Maria Ausiliatrice  
Prof. Dr. Jadson Correia de Oliveira – Universidade Católica do Salvador  
Prof. Dr. José Luis Montesillo-Cedillo – Universidad Autónoma del Estado de México  
Prof. Dr. Julio Cândido de Meirelles Junior – Universidade Federal Fluminense  
Prof<sup>a</sup> Dr<sup>a</sup> Lina Maria Gonçalves – Universidade Federal do Tocantins  
Prof. Dr. Luís Ricardo Fernandes da Costa – Universidade Estadual de Montes Claros  
Prof<sup>a</sup> Dr<sup>a</sup> Natiéli Piovesan – Instituto Federal do Rio Grande do Norte  
Prof. Dr. Marcelo Pereira da Silva – Pontifícia Universidade Católica de Campinas  
Prof<sup>a</sup> Dr<sup>a</sup> Maria Luzia da Silva Santana – Universidade Federal de Mato Grosso do Sul  
Prof. Dr. Miguel Rodrigues Netto – Universidade do Estado de Mato Grosso  
Prof. Dr. Pablo Ricardo de Lima Falcão – Universidade de Pernambuco  
Prof<sup>a</sup> Dr<sup>a</sup> Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa  
Prof<sup>a</sup> Dr<sup>a</sup> Rita de Cássia da Silva Oliveira – Universidade Estadual de Ponta Grossa  
Prof. Dr. Rui Maia Diamantino – Universidade Salvador  
Prof. Dr. Saulo Cerqueira de Aguiar Soares – Universidade Federal do Piauí  
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará  
Prof<sup>a</sup> Dr<sup>a</sup> Vanessa Bordin Viera – Universidade Federal de Campina Grande  
Prof<sup>a</sup> Dr<sup>a</sup> Vanessa Ribeiro Simon Cavalcanti – Universidade Católica do Salvador  
Prof. Dr. William Cleber Domingues Silva – Universidade Federal Rural do Rio de Janeiro  
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

#### **Ciências Agrárias e Multidisciplinar**

Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano  
Prof. Dr. Arinaldo Pereira da Silva – Universidade Federal do Sul e Sudeste do Pará  
Prof. Dr. Antonio Pasqualetto – Pontifícia Universidade Católica de Goiás  
Prof<sup>a</sup> Dr<sup>a</sup> Carla Cristina Bauermann Brasil – Universidade Federal de Santa Maria  
Prof. Dr. Cleberton Correia Santos – Universidade Federal da Grande Dourados  
Prof<sup>a</sup> Dr<sup>a</sup> Diocléa Almeida Seabra Silva – Universidade Federal Rural da Amazônia  
Prof. Dr. Écio Souza Diniz – Universidade Federal de Viçosa  
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul  
Prof. Dr. Fágnier Cavalcante Patrocínio dos Santos – Universidade Federal do Ceará  
Prof<sup>a</sup> Dr<sup>a</sup> Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia  
Prof. Dr. Jael Soares Batista – Universidade Federal Rural do Semi-Árido  
Prof. Dr. Jayme Augusto Peres – Universidade Estadual do Centro-Oeste  
Prof. Dr. Júlio César Ribeiro – Universidade Federal Rural do Rio de Janeiro  
Prof<sup>a</sup> Dr<sup>a</sup> Lina Raquel Santos Araújo – Universidade Estadual do Ceará  
Prof. Dr. Pedro Manuel Villa – Universidade Federal de Viçosa  
Prof<sup>a</sup> Dr<sup>a</sup> Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão  
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará  
Prof<sup>a</sup> Dr<sup>a</sup> Talita de Santos Matos – Universidade Federal Rural do Rio de Janeiro

Prof. Dr. Tiago da Silva Teófilo – Universidade Federal Rural do Semi-Árido  
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

### **Ciências Biológicas e da Saúde**

Prof. Dr. André Ribeiro da Silva – Universidade de Brasília  
Prof<sup>a</sup> Dr<sup>a</sup> Anelise Levay Murari – Universidade Federal de Pelotas  
Prof. Dr. Benedito Rodrigues da Silva Neto – Universidade Federal de Goiás  
Prof<sup>a</sup> Dr<sup>a</sup> Daniela Reis Joaquim de Freitas – Universidade Federal do Piauí  
Prof<sup>a</sup> Dr<sup>a</sup> Débora Luana Ribeiro Pessoa – Universidade Federal do Maranhão  
Prof. Dr. Douglas Siqueira de Almeida Chaves – Universidade Federal Rural do Rio de Janeiro  
Prof. Dr. Edson da Silva – Universidade Federal dos Vales do Jequitinhonha e Mucuri  
Prof<sup>a</sup> Dr<sup>a</sup> Elizabeth Cordeiro Fernandes – Faculdade Integrada Medicina  
Prof<sup>a</sup> Dr<sup>a</sup> Eleuza Rodrigues Machado – Faculdade Anhanguera de Brasília  
Prof<sup>a</sup> Dr<sup>a</sup> Elane Schwinden Prudêncio – Universidade Federal de Santa Catarina  
Prof<sup>a</sup> Dr<sup>a</sup> Eysler Gonçalves Maia Brasil – Universidade da Integração Internacional da Lusofonia Afro-Brasileira  
Prof. Dr. Ferlando Lima Santos – Universidade Federal do Recôncavo da Bahia  
Prof<sup>a</sup> Dr<sup>a</sup> Fernanda Miguel de Andrade – Universidade Federal de Pernambuco  
Prof. Dr. Fernando Mendes – Instituto Politécnico de Coimbra – Escola Superior de Saúde de Coimbra  
Prof<sup>a</sup> Dr<sup>a</sup> Gabriela Vieira do Amaral – Universidade de Vassouras  
Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria  
Prof. Dr. Helio Franklin Rodrigues de Almeida – Universidade Federal de Rondônia  
Prof<sup>a</sup> Dr<sup>a</sup> Iara Lúcia Tescarollo – Universidade São Francisco  
Prof. Dr. Igor Luiz Vieira de Lima Santos – Universidade Federal de Campina Grande  
Prof. Dr. Jefferson Thiago Souza – Universidade Estadual do Ceará  
Prof. Dr. Jesus Rodrigues Lemos – Universidade Federal do Piauí  
Prof. Dr. Jônatas de França Barros – Universidade Federal do Rio Grande do Norte  
Prof. Dr. José Max Barbosa de Oliveira Junior – Universidade Federal do Oeste do Pará  
Prof. Dr. Luís Paulo Souza e Souza – Universidade Federal do Amazonas  
Prof<sup>a</sup> Dr<sup>a</sup> Magnólia de Araújo Campos – Universidade Federal de Campina Grande  
Prof. Dr. Marcus Fernando da Silva Praxedes – Universidade Federal do Recôncavo da Bahia  
Prof<sup>a</sup> Dr<sup>a</sup> Maria Tatiane Gonçalves Sá – Universidade do Estado do Pará  
Prof<sup>a</sup> Dr<sup>a</sup> Mylena Andréa Oliveira Torres – Universidade Ceuma  
Prof<sup>a</sup> Dr<sup>a</sup> Natiéli Piovesan – Instituto Federal do Rio Grande do Norte  
Prof. Dr. Paulo Inada – Universidade Estadual de Maringá  
Prof. Dr. Rafael Henrique Silva – Hospital Universitário da Universidade Federal da Grande Dourados  
Prof<sup>a</sup> Dr<sup>a</sup> Regiane Luz Carvalho – Centro Universitário das Faculdades Associadas de Ensino  
Prof<sup>a</sup> Dr<sup>a</sup> Renata Mendes de Freitas – Universidade Federal de Juiz de Fora  
Prof<sup>a</sup> Dr<sup>a</sup> Vanessa da Fontoura Custódio Monteiro – Universidade do Vale do Sapucaí  
Prof<sup>a</sup> Dr<sup>a</sup> Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa  
Prof<sup>a</sup> Dr<sup>a</sup> Vanessa Bordin Viera – Universidade Federal de Campina Grande  
Prof<sup>a</sup> Dr<sup>a</sup> Welma Emidio da Silva – Universidade Federal Rural de Pernambuco

### **Ciências Exatas e da Terra e Engenharias**

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto  
Prof<sup>a</sup> Dr<sup>a</sup> Ana Grasielle Dionísio Corrêa – Universidade Presbiteriana Mackenzie  
Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás  
Prof<sup>a</sup> Dr<sup>a</sup> Carmen Lúcia Voigt – Universidade Norte do Paraná  
Prof. Dr. Cleiseano Emanuel da Silva Paniagua – Instituto Federal de Educação, Ciência e Tecnologia de Goiás  
Prof. Dr. Douglas Gonçalves da Silva – Universidade Estadual do Sudoeste da Bahia  
Prof. Dr. Eloí Rufato Junior – Universidade Tecnológica Federal do Paraná  
Prof<sup>a</sup> Dr<sup>a</sup> Érica de Melo Azevedo – Instituto Federal do Rio de Janeiro

Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará  
Profª Dra. Jéssica Verger Nardeli – Universidade Estadual Paulista Júlio de Mesquita Filho  
Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande  
Profª Drª Luciana do Nascimento Mendes – Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte  
Prof. Dr. Marcelo Marques – Universidade Estadual de Maringá  
Prof. Dr. Marco Aurélio Kistemann Junior – Universidade Federal de Juiz de Fora  
Profª Drª Neiva Maria de Almeida – Universidade Federal da Paraíba  
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte  
Profª Drª Priscila Tessmer Scaglioni – Universidade Federal de Pelotas  
Prof. Dr. Sidney Gonçalo de Lima – Universidade Federal do Piauí  
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista

**Linguística, Letras e Artes**

Profª Drª Adriana Demite Stephani – Universidade Federal do Tocantins  
Profª Drª Angeli Rose do Nascimento – Universidade Federal do Estado do Rio de Janeiro  
Profª Drª Carolina Fernandes da Silva Mandaji – Universidade Tecnológica Federal do Paraná  
Profª Drª Denise Rocha – Universidade Federal do Ceará  
Profª Drª Edna Alencar da Silva Rivera – Instituto Federal de São Paulo  
Profª Drª Fernanda Tonelli – Instituto Federal de São Paulo,  
Prof. Dr. Fabiano Tadeu Grazioli – Universidade Regional Integrada do Alto Uruguai e das Missões  
Prof. Dr. Gilmei Fleck – Universidade Estadual do Oeste do Paraná  
Profª Drª Keyla Christina Almeida Portela – Instituto Federal de Educação, Ciência e Tecnologia do Paraná  
Profª Drª Miranilde Oliveira Neves – Instituto de Educação, Ciência e Tecnologia do Pará  
Profª Drª Sandra Regina Gardacho Pietrobon – Universidade Estadual do Centro-Oeste  
Profª Drª Sheila Marta Carregosa Rocha – Universidade do Estado da Bahia

## Coleção desafios das engenharias: engenharia de computação

**Diagramação:** Camila Alves de Cremo  
**Correção:** Maiara Ferreira  
**Indexação:** Gabriel Motomu Teshima  
**Revisão:** Os autores  
**Organizador:** Ernane Rosa Martins

### Dados Internacionais de Catalogação na Publicação (CIP)

C691 Coleção desafios das engenharias: engenharia de computação / Organizador Ernane Rosa Martins. – Ponta Grossa - PR: Atena, 2021.

Formato: PDF  
Requisitos de sistema: Adobe Acrobat Reader  
Modo de acesso: World Wide Web  
Inclui bibliografia  
ISBN 978-65-5983-387-0  
DOI: <https://doi.org/10.22533/at.ed.870211808>

1. Engenharia da computação. I. Martins, Ernane Rosa (Organizador). II. Título.

CDD 621.39

Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166

**Atena Editora**

Ponta Grossa – Paraná – Brasil

Telefone: +55 (42) 3323-5493

[www.atenaeditora.com.br](http://www.atenaeditora.com.br)

contato@atenaeditora.com.br

## **DECLARAÇÃO DOS AUTORES**

Os autores desta obra: 1. Atestam não possuir qualquer interesse comercial que constitua um conflito de interesses em relação ao artigo científico publicado; 2. Declaram que participaram ativamente da construção dos respectivos manuscritos, preferencialmente na: a) Concepção do estudo, e/ou aquisição de dados, e/ou análise e interpretação de dados; b) Elaboração do artigo ou revisão com vistas a tornar o material intelectualmente relevante; c) Aprovação final do manuscrito para submissão.; 3. Certificam que os artigos científicos publicados estão completamente isentos de dados e/ou resultados fraudulentos; 4. Confirmam a citação e a referência correta de todos os dados e de interpretações de dados de outras pesquisas; 5. Reconhecem terem informado todas as fontes de financiamento recebidas para a consecução da pesquisa; 6. Autorizam a edição da obra, que incluem os registros de ficha catalográfica, ISBN, DOI e demais indexadores, projeto visual e criação de capa, diagramação de miolo, assim como lançamento e divulgação da mesma conforme critérios da Atena Editora.

## **DECLARAÇÃO DA EDITORA**

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação constitui apenas transferência temporária dos direitos autorais, direito sobre a publicação, inclusive não constitui responsabilidade solidária na criação dos manuscritos publicados, nos termos previstos na Lei sobre direitos autorais (Lei 9610/98), no art. 184 do Código penal e no art. 927 do Código Civil; 2. Autoriza e incentiva os autores a assinarem contratos com repositórios institucionais, com fins exclusivos de divulgação da obra, desde que com o devido reconhecimento de autoria e edição e sem qualquer finalidade comercial; 3. Todos os e-book são *open access*, *desta forma* não os comercializa em seu site, sites parceiros, plataformas de e-commerce, ou qualquer outro meio virtual ou físico, portanto, está isenta de repasses de direitos autorais aos autores; 4. Todos os membros do conselho editorial são doutores e vinculados a instituições de ensino superior públicas, conforme recomendação da CAPES para obtenção do Qualis livro; 5. Não cede, comercializa ou autoriza a utilização dos nomes e e-mails dos autores, bem como nenhum outro dado dos mesmos, para qualquer finalidade que não o escopo da divulgação desta obra.

## APRESENTAÇÃO

A Engenharia de Computação tem como definição ser o ramo da engenharia que se caracteriza pelo projeto, desenvolvimento e implementação de sistemas, equipamentos e dispositivos computacionais, segundo uma visão integrada de hardware e software, apoiando-se em uma sólida base matemática e conhecimentos de fenômenos físicos. O objetivo é a aplicação das tecnologias de computação na solução de problemas de Engenharia.

Deste modo, este livro, aborda diversos aspectos tecnológicos computacionais, tais como: o desenvolvimento de um jogo de RPG acessível em LIBRAS; uma reflexão quanto à necessidade de aplicação de supressores de surto como proteção de transformadores devido a eventos transitórios em manobras de disjuntores; um algoritmo para geração de contorno 2D envolvendo regiões irregulares; avaliação da influência das tensões residuais e imperfeições geométricas iniciais em colunas de aço submetidas à flexão em torno do eixo de menor inércia; os esforços em estruturas laminares, de características de geometria e carregamentos diversos através da implementação computacional de um elemento finito sólido hexaédrico de 8 nós programado com uma linguagem computacional de alto nível; uma análise computacional realizada através do programa SAP2000; a estabilidade e as vibrações de anéis e tubulações apoiados em uma fundação elástica de Pasternak; um controlador neural para dois eixos de um robô manipulador de três graus de liberdade (3 GDL); uma ferramenta de autoria para livros relacionados a área da educação; um aplicativo com propósito de aumentar a taxa de reciclagem e minimizar os danos ambientais devido ao descarte incorreto de resíduos na natureza; a conscientização de crianças e adolescentes sobre as ocorrências de bullying; uma aplicação web interativa, de fácil utilização e interface amigável, por meio do pacote Shiny, destinada aos tópicos de intervalo de confiança e dimensionamento de amostra para o parâmetro proporção; segmentar e detectar, por meio de redes neurais convolutivas, as pás dos raspadores de escória em panelas de ferro gusa do Reator Kambara de uma siderúrgica; integrar a Biblioteca Digital de Artigos (IFPublica) e a Plataforma de Digital de Inscrição e Administração de Projetos (PDIAP), por meio de adaptações nos dois projetos, para impedir erros humanos e automatizar o processo de cadastro de artigos do PDIAP na base de dados do IFPublica.

Assim, espero que a presente obra venha a se tornar um guia aos estudantes e profissionais da área de Engenharia de Computação, auxiliando-os em diversos assuntos relevantes da área, fornecendo a estes novos conhecimentos para poderem atender as necessidades informacionais, computacionais e de automação das organizações de uma forma geral. Por fim, agradeço aos autores por suas contribuições na construção desta importante obra e desejo muito sucesso a todos os nossos leitores.

## SUMÁRIO

### CAPÍTULO 1.....1

A ELASTO-PLASTIC CONSTITUTIVE MODEL BASED ON CHABOCHE KINEMATIC HARDENING OF ALUMINUM ALLOY 7050-T7451

Renzo Fernandes Bastos

Daniel Masarin

Ernesto Massaroppi Junior

 <https://doi.org/10.22533/at.ed.8702118081>

### CAPÍTULO 2.....11

ACANNO: UM JOGO DE RPG COM UMA PROPOSTA DE ACESSIBILIDADE USANDO LIBRAS

Gabriel Barroso da Silva Lima

Marcos Roberto dos Santos

Almir de Oliveira Costa Junior

Jucimar Maia da Silva Junior

 <https://doi.org/10.22533/at.ed.8702118082>

### CAPÍTULO 3.....23

A IMPORTÂNCIA ATUAL DE ESTUDOS DE TRANSITÓRIOS ELETROMAGNÉTICOS PARA DEFINIÇÃO DE SISTEMAS DE PROTEÇÃO DE TRANSFORMADORES CONTRA SOBRETENSÕES E AS APLICAÇÕES RECENTES COM A INSTALAÇÃO DE SUPRESSORES DE SURTO

Nelson Clodoaldo de Jesus

João Roberto Cogo

Luiz Marlus Duarte

Luis Fernando Ribeiro Ferreira

Éverson Júnior de Mendonça

Leandro Martins Fernandes

 <https://doi.org/10.22533/at.ed.8702118083>

### CAPÍTULO 4.....38

ALGORITMO PARA GERAÇÃO DE CONTORNO DE MALHAS RETANGULARES PARA CÁLCULO DE DIFERENÇAS FINITAS

Pedro Zaffalon da Silva

Neyva Maria Lopes Romeiro

Rafael Furlanetto Casamaximo

Iury Pereira de Souza

Paulo Laerte Natti

Eliandro Rodrigues Cirilo

 <https://doi.org/10.22533/at.ed.8702118084>

### CAPÍTULO 5.....53

ANÁLISE DA RESISTÊNCIA DE PILARES DE AÇO SOB A INFLUÊNCIA DE TENSÕES RESIDUAIS E IMPERFEIÇÕES GEOMÉTRICAS INICIAIS

Jefferson Alves Ferreira

Giovani Vitório Costa  
Harley Francisco Viana  
Renata Gomes Lanna da Silva

 <https://doi.org/10.22533/at.ed.8702118085>

**CAPÍTULO 6.....70**

ANÁLISE DE ESTRUTURAS LAMINARES UTILIZANDO UM ELEMENTO SÓLIDO DE BAIXA ORDEM ENRIQUECIDO COM MODOS INCOMPATÍVEIS

Erijohnson da Silva Ferreira  
William Taylor Matias Silva  
Sebastião Simão da Silva  
Adenilda Timóteo Salviano  
José Lucas Pessoa de Oliveira

 <https://doi.org/10.22533/at.ed.8702118086>

**CAPÍTULO 7.....84**

ANÁLISE ESTRUTURAL DO EDIFÍCIO SEDE DA PROCURADORIA GERAL DA REPÚBLICA: O ESTUDO DE CASO DO BLOCO “A”

Stefano Galimi  
Márcio Augusto Roma Buzar  
Marco Aurélio Bessa  
Leonardo da Silveira Pirillo Inojosa

 <https://doi.org/10.22533/at.ed.8702118087>

**CAPÍTULO 8.....103**

ANÁLISE ESTRUTURAL DO EDIFÍCIO SEDE DA PROCURADORIA GERAL DA REPÚBLICA: O ESTUDO DE CASO DO BLOCO “B”

Stefano Galimi  
Márcio Augusto Roma Buzar  
Marco Aurélio Bessa  
Marcos Henrique Ritter de Gregorio

 <https://doi.org/10.22533/at.ed.8702118088>

**CAPÍTULO 9.....119**

APPLICATION OF A MULTIOBJETIVE OPTIMIZATION PARETO APPROACH TO DESIGN THE SDRE CONTROLLER FOR A RIGID-FLEXIBLE SATELLITE

Luiz Carlos Gadelha de Souza

 <https://doi.org/10.22533/at.ed.8702118089>

**CAPÍTULO 10.....131**

APPLICATION OF DEEP LEARNING FOR ANALYSIS OF CRACKS IN PELLET FALLING TESTS

Marconi Junio Henriques Magnani  
Jorge José Fernandes Filho  
Thyago Rosa Souza  
Marco Antonio de Souza Leite Cuadros

 <https://doi.org/10.22533/at.ed.87021180810>

**CAPÍTULO 11.....143**

FLAMBAGEM E VIBRAÇÃO DE ANÉIS E TUBULAÇÕES ESBELTAS EM UMA FUNDAÇÃO ELÁSTICA

Mariana Barros dos Santos Dias

Paulo Batista Gonçalves

 <https://doi.org/10.22533/at.ed.87021180811>

**CAPÍTULO 12.....155**

CALIDAD ÁGIL: PATRONES DE DISEÑO EN UN CONTEXTO DE DESARROLLO DIRIGIDO POR PRUEBAS

Anna Grimán Padua

Manuel Capel Tuñón

Eladio Garví

 <https://doi.org/10.22533/at.ed.87021180812>

**CAPÍTULO 13.....168**

CONTROLE NEURAL DE DOIS ELOS DE UM ROBÔ DE TRÊS GRAUS DE LIBERDADE

José Antonio Riul

Paulo Henrique de Miranda Montenegro

 <https://doi.org/10.22533/at.ed.87021180813>

**CAPÍTULO 14.....181**

SUBOPTIMAL CONTROL ON NONLINEAR SATELLITE SIMULATIONS USING SDRE AND H-INFINITY

Alessandro Gerlinger Romero

Luiz Carlos Gadelha de Souza

 <https://doi.org/10.22533/at.ed.87021180814>

**CAPÍTULO 15.....193**

CREATE REALITY IN BOOKS (CRINB) - PROPOSTA DE FERRAMENTA DE AUTORIA DE LIVROS COM REALIZADADE AUMENTADA

Lucas Velho Gomes

Felipe Zunino

Gabriel Abreu Freire

Sidney Ferreira Coutinho

Rogério Grijo Biazotto

Eduardo Henrique Gomes

Nelson Nascimento Júnior

 <https://doi.org/10.22533/at.ed.87021180815>

**CAPÍTULO 16.....198**

DESENVOLVIMENTO DE ATIVIDADES DE ORIENTAÇÃO E CAPACITAÇÃO EM SISTEMAS DE COMPUTAÇÃO - RECYCLING IS BETTER

Líbero Passador Neto

Dimitre Moreira Ort

 <https://doi.org/10.22533/at.ed.87021180816>

<b>CAPÍTULO 17.....</b>	<b>206</b>
DESENVOLVIMENTO DE UM JOGO DIGITAL (2D) PARA CONSCIENTIZAÇÃO DE CRIANÇAS CONTRA O BULLYING	
Rafael Guedes da Silva	
Anderson Fabian Melo Nakanome	
 <a href="https://doi.org/10.22533/at.ed.87021180817">https://doi.org/10.22533/at.ed.87021180817</a>	
<b>CAPÍTULO 18.....</b>	<b>215</b>
DESENVOLVIMENTO DE UMA APLICAÇÃO WEB PARA PROPORÇÃO E DIMENSIONAMENTO DE AMOSTRA POR MEIO DO PACOTE SHINY	
Pablo Fellipe de Souza Almeida	
Cristina Henriques Nogueira	
 <a href="https://doi.org/10.22533/at.ed.87021180818">https://doi.org/10.22533/at.ed.87021180818</a>	
<b>CAPÍTULO 19.....</b>	<b>226</b>
DESIGN PATTERNS FOR SOFTWARE EVOLUTION REQUIREMENTS	
Anna Grimán Padua	
Manuel Capel Tuñón	
Eladio Garví	
 <a href="https://doi.org/10.22533/at.ed.87021180819">https://doi.org/10.22533/at.ed.87021180819</a>	
<b>CAPÍTULO 20.....</b>	<b>240</b>
DETECTION AND SEGMENTATION OF PIG IRON SLAG SCRAPERS USING MASK RCNN FOR WEAR CONTROL	
Carlos Eduardo Oliveira Milanez	
Marco Antonio de Souza Leite Cuadros	
Gustavo Maia de Almeida	
 <a href="https://doi.org/10.22533/at.ed.87021180820">https://doi.org/10.22533/at.ed.87021180820</a>	
<b>CAPÍTULO 21.....</b>	<b>252</b>
DIMENSIONAMENTO DE BLOCOS SOBRE ESTACAS METÁLICAS	
Fernanda Calado Mendonça	
Bernardo Horowitz	
 <a href="https://doi.org/10.22533/at.ed.87021180821">https://doi.org/10.22533/at.ed.87021180821</a>	
<b>CAPÍTULO 22.....</b>	<b>268</b>
ESTIMATION OF STELLAR PARAMETERS FOR J-PLUS SURVEY WITH MACHINE LEARNING	
Carlos Andres Galarza Arevalo	
Simone Daflon	
Vinicius Moris Placco	
Carlos Allende-Prieto	
 <a href="https://doi.org/10.22533/at.ed.87021180822">https://doi.org/10.22533/at.ed.87021180822</a>	
<b>CAPÍTULO 23.....</b>	<b>279</b>
ESTUDO ANALÍTICO E NUMÉRICO VIA MÉTODO DOS ELEMENTOS FINITOS DA	

## RIGIDEZ DOS PILARES DE PONTES EM CONCRETO ARMADO

Sávio Torres Melo  
Rebeka Manuela Lobo Sousa  
Pablo Juan Lopes e Silva Santos  
Francisca Itaynara de Souza Araújo  
Thiago Rodrigues Piauilino Ribeiro  
Amanda Evelyn Barbosa de Aquino  
Diogo Raniere Ramos e Silva  
Tiago Monteiro de Carvalho  
Carlos Henrique Leal Viana  
João Paulo dos Santos Silva  
Madson Nogueira da Silva  
Ilanna Castelo Branco Mesquita

 <https://doi.org/10.22533/at.ed.87021180823>

## CAPÍTULO 24..... 290

### ESTUDO ANALÍTICO E NUMÉRICO VIA MÉTODO DOS ELEMENTOS FINITOS DOS EFEITOS DE SEGUNDA ORDEM EM PILARES DE PONTES EM CONCRETO ARMADO

Sávio Torres Melo  
Rebeka Manuela Lobo Sousa  
Pablo Juan Lopes e Silva Santos  
Francisca Itaynara de Souza Araújo  
Thiago Rodrigues Piauilino Ribeiro  
Amanda Evelyn Barbosa de Aquino  
Diogo Raniere Ramos e Silva  
Tiago Monteiro de Carvalho  
Carlos Henrique Leal Viana  
João Paulo dos Santos Silva  
Madson Nogueira da Silva  
Ilanna Castelo Branco Mesquita

 <https://doi.org/10.22533/at.ed.87021180824>

## CAPÍTULO 25..... 311

### ESTUDO DO MOVIMENTO DOS CORPOS MOEDORES NO PROCESSO DE MOAGEM UTILIZANDO O MÉTODO DOS ELEMENTOS DISCRETOS

Wladimir José Gomes Florêncio  
Neilor Cesar dos Santos

 <https://doi.org/10.22533/at.ed.87021180825>

## CAPÍTULO 26..... 329

### FLUID FLOW SUMMARIZATION USING DYNAMIC MULTI-VECTOR FEATURE SPACES

Renato José Policani Borsetti  
Leandro Tavares da Silva  
Gilson Antonio Giraldi

 <https://doi.org/10.22533/at.ed.87021180826>

**CAPÍTULO 27.....351**

GESTÃO DE PROCESSOS: ALINHAMENTO ESTRATÉGICO ENTRE TI E NEGÓCIO  
COM BPMN

Aryel Evelin Vieira Garcia

Rodrigo Elias Francisco

 <https://doi.org/10.22533/at.ed.87021180827>

**CAPÍTULO 28.....359**

IFINTEGRA - INTEGRADOR DA PLATAFORMA DE REGISTRO DE PROJETOS COM A  
BIBLIOTECA DIGITAL DE ARTIGOS DE UM CAMPUS DO IFSUL

Mateus Roberto Algayer

Geovane Griesang

 <https://doi.org/10.22533/at.ed.87021180828>

**SOBRE O ORGANIZADOR.....366****ÍNDICE REMISSIVO.....367**

# CAPÍTULO 22

## ESTIMATION OF STELLAR PARAMETERS FOR J-PLUS SURVEY WITH MACHINE LEARNING

Data de aceite: 02/08/2021

**Carlos Andres Galarza Arevalo**

Observatorio Nacional-MCTI( ON)  
Rio de Janeiro, Brazil

**Simone Daflon**

Observatorio Nacional-MCTI( ON)  
Rio de Janeiro, Brazil

**Vinicius Moris Placco**

Department of Physics, University of Notre Dame  
Notre Dame, USA  
JINA Center for the Evolution of the Elements  
(JINA-CEE),USA

**Carlos Allende-Prieto**

Instituto de Astrofísica de Canarias  
La Laguna, Tenerife, Spain  
Universidad de La Laguna, Departamento de  
Astrofísica  
La Laguna, Tenerife, Spain

Anais do XIV Encontro Acadêmico de Modelagem Computacional. Laboratório Nacional de Computação Científica, 08 a 11 de Fevereiro de 2021.

**ABSTRACT:** The amount of data produced by the current and future astronomic surveys will require more efficient processing methods to carry out scientific research that leads us to more exciting discoveries. One particular example is the identification of very low-metallicity stars ( $[Fe/H] < 3.0$ ) that can allow us to imposed

constraints improving our current understanding of the formation and chemical evolution of our Galaxy. To accomplish this goal, we present the J-PLUS Stellar Parameters Estimation based on Ensemble Methods (J-PLUS SPEEM) pipeline that is capable of performing a variety of tasks such as morphological and spectral classification along with the estimation of the three main stellar parameters ( $T_{eff}$ ,  $[Fe/H]$  and  $\log g$ ) with absolute mean errors of 139.2K, 0.16 and 0.32 dex respectively.

**KEYWORDS:** Machine learning, Astroinformatics, Stellar parameters, Low-metallicity stars.

**RESUMO:** A quantidade de dados produzidos pelas pesquisas astronômicas atuais e futuras exigirá métodos de processamento mais eficientes para realizar pesquisas científicas que nos levem a descobertas mais interessantes. Um exemplo particular é a identificação de estrelas de metalicidade muito baixa ( $[Fe/H] < -3.0$ ) que podem nos permitir impor restrições, melhorando nosso entendimento atual da formação e evolução química de nossa Galáxia. Para cumprir este objetivo, apresentamos o pipeline J-PLUS Stellar Parameters Estimation baseado em Ensemble Methods (J-PLUS SPEEM) que é capaz de realizar uma variedade de tarefas, como classificação morfológica e espectral, juntamente com a estimativa dos três principais parâmetros estelares (Teff,  $[Fe/H]$  e logg) com erros médios absolutos de 139,2 K, 0,16 e 0,32 dex, respectivamente.

**PALAVRAS-CHAVE:** Aprendizado de máquina, astronomia, astrofísica, árvores aleatórios, métodos de regressão.

## 1 | INTRODUCTION

The main goal of any astronomical observation is to determine the physical properties of observed objects to study their chemical composition, which provides reasonable arguments regarding their formation and evolution processes.

Notably, in the case of stars, one can estimate its surface parameters such as effective temperature  $T_{\text{eff}}$ ; metallicity, usually expressed in terms of the iron-to-hydrogen ratio  $[Fe/H]$ ; and surface gravity  $\log g$  based on the light received from them and collected by a telescope or satellite. The accomplishment of this goal requires at least two different approaches that we can use in order to obtain data through observations: these are Photometry and Spectrometry. The first offers the advantage of better signal-to-noise ratios and data collection from multiple sources simultaneously in exchange for losing the ability to track individual spectral features. On the other hand, spectrometry allows one to make a detailed study of chemical abundances (high-resolution observations), with the disadvantage of being extremely difficult to obtain spectra from many sources simultaneously (even using multi-slit or multi-fiber spectrographs).

Before applying machine learning models to research in astronomy, different photometric calibrations provided reliable estimations of stellar parameters. For instance, Ivezić et al. [11] found that ( $gr$ ) color from SDSS provides an accurate estimation for  $T_{\text{eff}}$  and  $[Fe/H]$  can be obtained through a polynomial fitting using ( $u - g$ )<sup>1</sup> some restrictions on ( $g - r$ ) while Casagrande et al. [6] used the infrared flux method (Casagrande et al. [5]) to obtain  $T_{\text{eff}}$  of a sample of F, G and K type stars using  $BV JHK_s$  photometry. Regarding spectroscopic observations, Lee et al. [12] presented the SEGUE Stellar Parameter Pipeline (SSPP), which made estimations of stellar parameters using both theoretical and empiric calibrations of medium resolution stellar spectra ( $(R \approx 10000)$ ) along with the implementation of neural networks based on spectral libraries (ELODIE and MILES; Prugniel and Soubiran [15], Falcon-Barroso J. et al. [8]) and high-resolution spectra for the validation process.

Nevertheless, in the following years, the data sets produced by different extensive surveys will be so giant (the order of many Petabytes) that we will need to develop new effective ways to deal with it. In this sense, machine learning algorithms and any other statistical tools could be beneficial to analyze data and make predictions in a reasonably short amount of time. Some machine learning methods like artificial neural networks (ANN) have been applied successfully for some time ago in a wide variety of astronomical applications. For instance, Gulati and Gupta [9] propose a model to estimate  $E(B-V)$ <sup>2</sup> for O and B stars; and Whitten et al. [18] that implemented ANNs to estimate  $T_{\text{eff}}$  and  $[Fe/H]$  for J-PLUS data in order to search for low-metallicity stars. On the other hand, we can find that other models based on algorithms such as Random Forest (Breiman [4]) have produced exciting results in

<sup>1</sup>  $u$ ,  $g$  with and  $r$  are photometric magnitudes measured by the optical filter system of Sloan survey.

<sup>2</sup> A measure of the interstellar reddening that is related to the quality of the light received by a telescope from the observed stars

terms of morphological classifications and estimation of physical parameters. For instance, Miller [14] presented a Random Forest (hereafter RF) model capable of inferring  $T_{\text{eff}}$ ,  $\log g$  and  $[\text{Fe}/\text{H}]$  based on SDSS de-reddened colors; Bai et al. [1] built an RF model that performs a Star-Galaxy-QSO<sup>3</sup> classification and calculates the  $T_{\text{eff}}$  for stars using data from SDSS and LAMOST.

This work presents the J-PLUS Stellar Parameters Estimation based on Ensemble Methods pipeline (J-PLUSSPEEM). It consists of a series of machine learning models capable of performing different tasks such as separating stars from QSOs and estimating three main stellar parameters ( $T_{\text{eff}}$ ,  $[\text{Fe}/\text{H}]$ ,  $\log g$ ). Additionally, SPEEM makes spectral classification (A, F, G, K, and WD<sup>4</sup>), allowing us to build a catalog of stars for a wide variety of interests. We also tested the model for looking for new very metal-poor stars observed with the Javalambre Photometric Local Universe Survey (J-PLUS, Cenarro et al. [7]) thanks to the comparison between machine learning predictions and analysis of medium resolution spectra obtained with the William Hershel Telescope (WHT) at the Canary Islands.

## 2 | METHODOLOGY

There are two strategies to properly implement machine learning algorithms that allow one to obtain reliable estimations and predictions on astronomic data, known as supervised learning and unsupervised learning. In supervised learning, one usually starts with a fraction of data for which the target variables of interest are well known:  $T_{\text{eff}}$ ,  $[\text{Fe}/\text{H}]$ , and  $\log g$ . Then an optimized algorithm is applied to search for statistical relations between these target variables and a set of measured parameters, being photometric magnitudes and colors<sup>5</sup> in our case. The data used to apply the algorithm is known as the training sample. The variables to be estimated are referred to as labels (for classification problems) or targets (for regression), while the input parameters considered to deploy a model are named features. Supervised methods are handy to make regressions and classifications based on a subset of well-known data, while unsupervised learning is based on unknown labels to find possible patterns or associations from the features suitable for being interpreted as classes.[3] [10]

For this work, we restrained the focus to applying the random forest algorithm, a supervised learning method.[4]

### 2.1 Training Datasets

The sample used in this work comes from applying a query to retrieve magnitudes in the dual AB system from the second data release of the J-PLUS Survey (hereafter JPLUS DR2<sup>6</sup>). Additionally, selections of 6 arcsec aperture photometry and proper configuration

<sup>3</sup> quasi-stellar object: A type of galaxy with extremely active nucleus that appear as a bright star

<sup>4</sup> White Dwarf: A kind of star in its final evolutionary state

<sup>5</sup> A photometric color is defined as the subtraction between two magnitudes.

<sup>6</sup> [http://www.j-plus.es/datarereleases/data release dr 2](http://www.j-plus.es/datarereleases/data_release_dr_2)

in MASKS and FLAGS values in the query ensure high-quality measurements in each of the 12 filters. The quality checks also include the stellar wide dwarf loci photometric calibration proposed by Lopez-Sanjuan et al. [13]. We ended up with a sample of 575,593 (hereafter referred to as gold sample) objects considered as unknown/unlabelled data in principle. Then the gold sample was crossed with other surveys such as Sloan DR12<sup>7</sup>, SEGUE (Yanny et al. [20]), LAMOST, and WISE (Wright et al. [19]) in order to gain new information regarding the target variables. This strategy resulted in 7393 common objects (referred to as JPLUSxSLOANxWISE) with Sloan DR12 and WISE, which provides information on morphological classification. In addition, there are another 9436 common objects (JPLUSxSSPP) with SEGUE, which is a spectroscopic survey of Sloan that allows us to get information regarding stellar parameters ( $T_{\text{eff}}$  [Fe/H], and log g). Finally, we found 106769 (JPLUSxLAMOST) objects in common with LAMOSTDR6<sup>8</sup> to test the model's predictions.

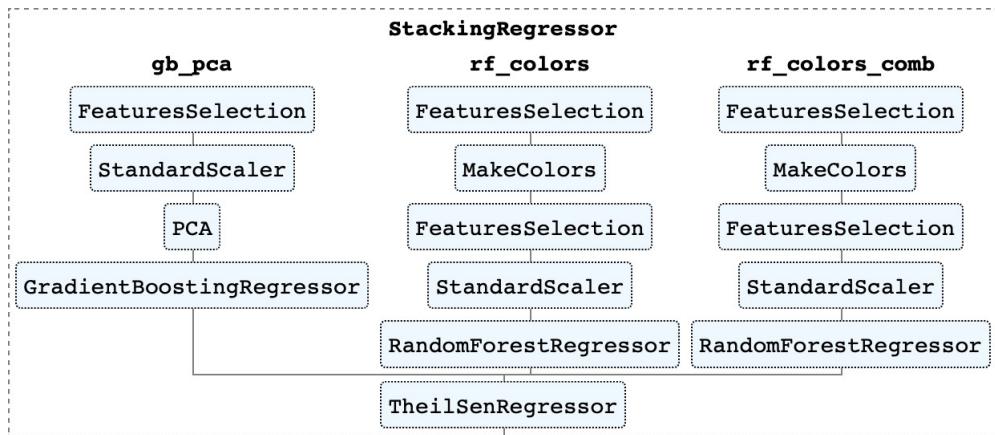


Fig. 1: SPEEM Architecture.

## 2.2 Architecture of SPEEM

SPEEM is in charge of two main tasks. The first one is to distinguish between different types of stars and contaminants such as QSOs. Then the second task that SPEEM accomplishes is to estimate the stellar parameters through a stacking regressor that combines three different ensemble regressors passing into a final Theil-Sen estimator, as shown in Figure 1. Each of the ensemble regressors considers different features varying from PCA analysis to different combinations of photometric colors.

<sup>7</sup> <https://www.sdss.org/dr12/>

<sup>8</sup> <http://dr6.lamost.org>

## 3 | RESULTS AND DISCUSSION

### 3.1 Morphological and Spectral Classification

In order to estimate stellar parameters from a sample, we need to make sure that no contaminants are present in the data, like QSOs or WDs in this case. So, the first step consisted of attempting a morphological classification of the data. For this purpose, we used the JPLUSxSLOANxWISE dataset as the training data to build a model that allows us to make a preliminary classification of DR1, which can help us clean the sample as best as possible (keeping a pure sample of stars). In figure 2, we can see that without applying any model, we can use W1, W2, and W3 magnitudes from WISE (that, fortunately, has many common fields with JPLUS) to classify at least Stars from QSOs. This color-color diagram is widely discussed by Wright et al. [19]; and Scaringi et al. [17]. Recall that WISE magnitudes are located in the infrared region of the electromagnetic spectrum while JPLUS magnitudes belong to the optical part; in general, QSOs tend to be redder than Stars regarding WISE colors.

On the other hand, identifying possible White Dwarfs means excluding them from the sample. Otherwise, they will be mixed with stars with very low metallicity when a photometric estimation is applied, resulting in many false positives. This misinterpretation is a well-known issue from the analysis of SEGUE and BOSS data from Sloan. Therefore, we are not interested in making a precise spectral classification of stars that composed the sample in this work. Instead, we want to identify and separate WDs from our sample of interest. Table 2 contains a classification report containing metrics regarding the precision of the model. Galaxy refers to broadband sources identified by SEGUE, and Recall means the correctness of the classification in the test sample. Due to limitations on temperature range, values on G-type stars are lower, resulting in misclassifications as F or K-type stars.

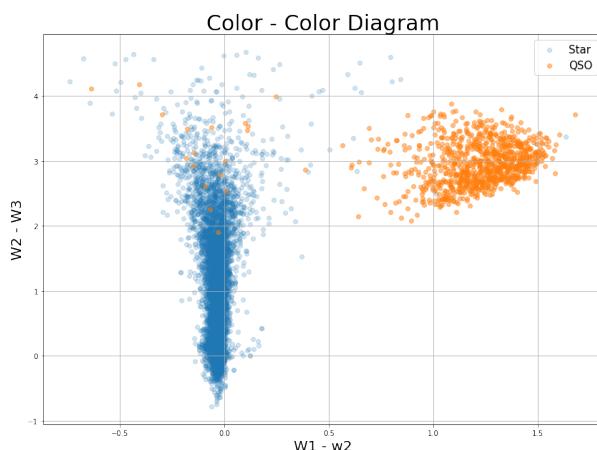


Fig. 2: Color-color diagram using W1, W2, W3 magnitudes from WISE.

Confusion Matrix		
Actual/Predicted Morph. Type	QSO	STAR
QSO	224	5
STAR	6	1614

Table1: Validation of Stars/QSOs separation model with accuracy score of 0.99.

### 3.2 Stellar Parameters Estimations - $T_{\text{eff}}$ [Fe/H] and $\log g$

#### 3.2.1 Effective Temperature $T_{\text{eff}}$

This parameter is usually the easiest to calculate using photometry. Specifically, in the case of the J-PLUS survey, one can define color indexes based on broad or narrowband filters to fit some polynomial function to adjust the data in the same way that was done by Bond and Ivezić [11] with the formula.

$$\log(T_{\text{eff}}) = F(g-r) \quad (1)$$

Nevertheless, a machine learning model was deployed based on different color indexes taking advantage of the 12 filter system of J-PLUS. This model includes 8523 stars with temperatures between 4200 K and 9200 K as part of the training sample. The validation process (showed in Figure 3) reported a mean absolute error of 139.5 K for a test sample of more than 100 000 stars that measure the performance of SPEEM.

Classification Report				
Spectral Class	Precision	Recall	f1-score	Support
A	0.88	0.86	0.87	268
F	0.86	0.93	0.89	1434
G	0.58	0.37	0.45	222
Galaxy	1.00	0.88	0.93	8
K	0.91	0.82	0.87	205
M	0.71	0.83	0.77	6
WD	1.00	0.62	0.77	8
accuracy			0.85	2151
macro avg	0.85	0.76	0.79	2151
weighted avg	0.84	0.85	0.84	2151

Table 2: Validation of Spectral Class model based on photometric magnitudes with accuracy score of 0.99.

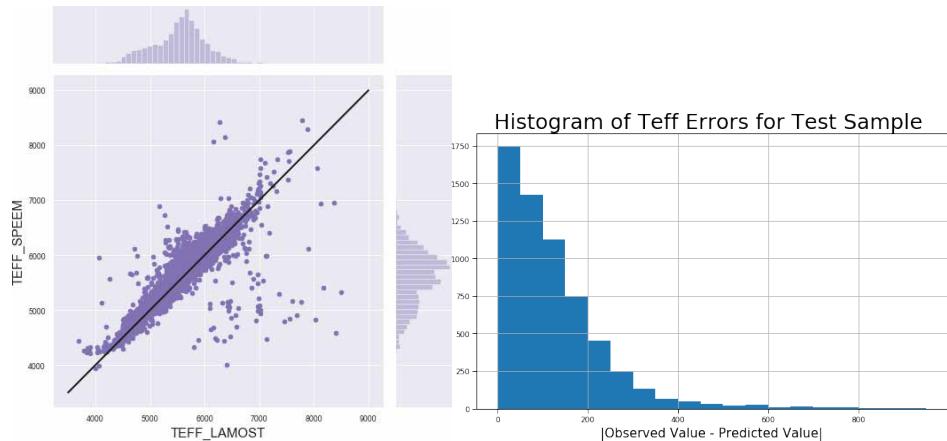


Fig. 3: Validation of effective temperature estimations for a test sample of nearly 106769 stars from JPLUSxLAMOST.

### 3.2.2 Metallicity [ $\text{Fe}/\text{H}$ ]

It is another physical parameter suitable for photometric estimation. However, its determination is usually more challenging than  $T_{\text{eff}}$  due to high sensitivities to signal-to-noise ratio observation which decreases the precision of the measurements of some filters, especially in the blue region of the spectrum.

Since one of the goals of this work is to identify possible candidates to very metal-poor stars (VMPs), we need to train the model on a sample that contains a wide range of  $[\text{Fe}/\text{H}]$  values. The sample used contains stars of  $[\text{Fe}/\text{H}]$  between 3.0 and 0.5 dex, and figure 4 shows the validation test results for the same validation sample used in the estimation of  $T_{\text{eff}}$ . The left side presents a reasonable agreement between the predicted and the adopted values with some outliers that require further analysis. On the right side, the histogram of errors suggests that most estimations present an error of less or equal to 0.2 dex. The mean absolute error calculated was 0.16 dex.

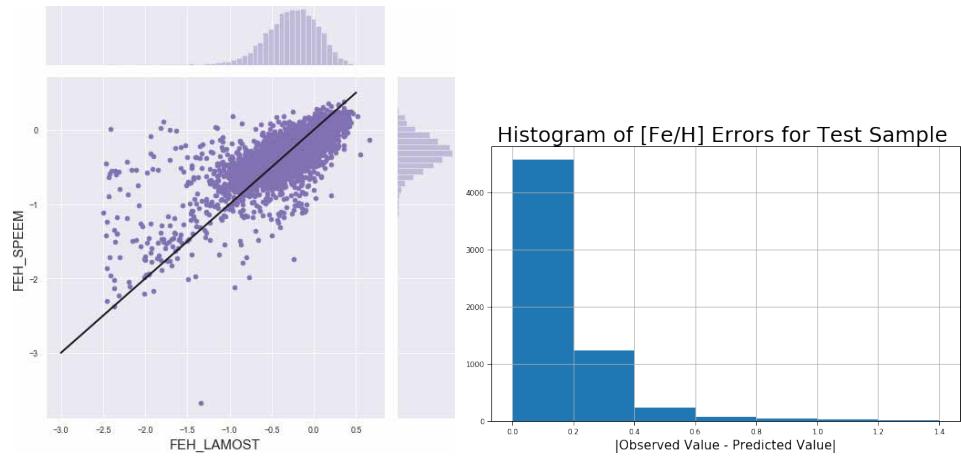


Fig. 4: Validation of metallicity estimations for a test sample of nearly 106769 stars from JPLUSxLAMOST.

### 3.2.3 Surface Gravity $\log g$

The estimation of  $T_{\text{eff}}$ ,  $[Fe/H]$ , and  $\log g$  share the same process, and figure 5 shows the validation test results. In this case, a wider dispersion can be appreciated compared to the previous cases. The range of values used in the training data was between [1.0, 5.0] dex. The results obtained for this particular parameter suggest that either additional restrictions are needed or the input features used by the machine learning algorithms are not enough to develop a higher precision model. Despite the more significant dispersion and the outliers presented, the histogram of errors suggests that most estimations presented an error between 0 and 0.5 dex with a calculated mean absolute error of 0.32 dex.

## 3.3 Spectroscopical confirmation of VMPs candidates

After the test, the model was applied to a sample of one million stars to search for new very metal-poor stars candidates to validate with spectroscopic analysis. Eleven stars were selected, and Carlos Allende made the observations using the William Herschel Telescope (WHT). To obtain the spectroscopic values for  $T_{\text{eff}}$ ,  $[Fe/H]$  and  $\log g$ , we use the pipeline n-SSPP (Beers et al. [2]). Figure 6 shows a comparison between the parameters estimated by the model and those obtained by spectroscopic analysis. The analysis of the predictions also presents a systematic median error of 178 K, 0.76, and 0.5 dex for  $T_{\text{eff}}$ ,  $\log g$  and  $[Fe/H]$ , respectively.

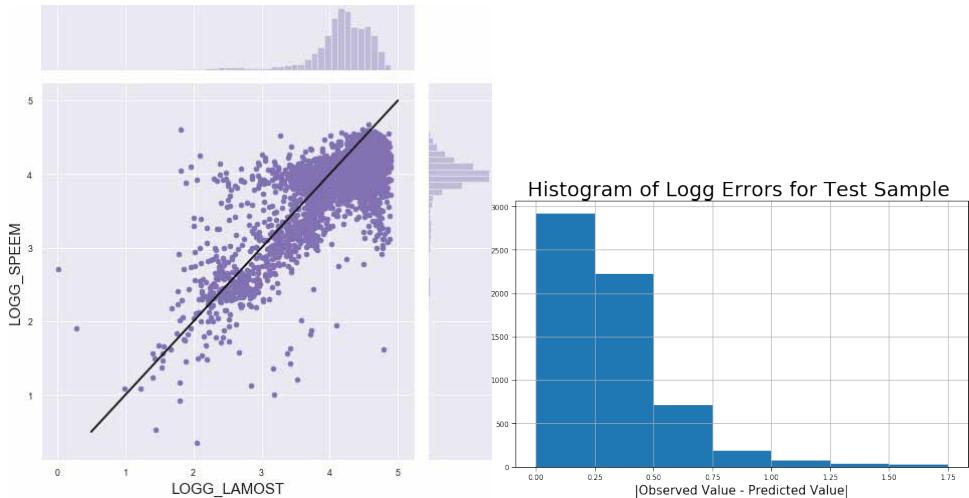


Fig. 5: Validation of surface gravity estimations for a test sample of nearly 106769 stars from JPLUSxLAMOST.

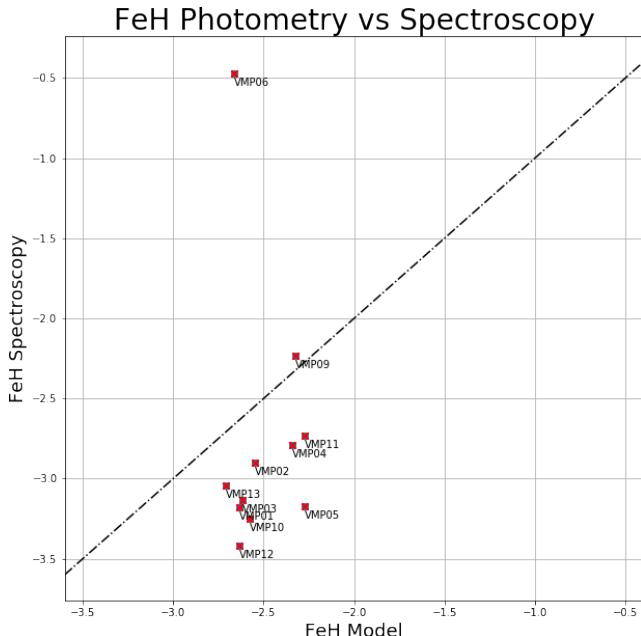


Fig. 6: Validation of metallicity estimations for a sample of nearly 1945 stars from JPLUSxSSPP.

## 4 | CONCLUSION

The primary goal of J-PLUSSPEEM is to identify good, very metal-poor stars candidates that can be used to detailed study its chemical abundances with high-resolution spectroscopy that is one of the most potent observational methods up to date in the field of astrophysics. As shown primarily in figures 4 and 6, the pipeline identified new low metallicity

stars, further confirmed by independent spectroscopic analysis. There is a good agreement between the values predicted by J-PLUS SPEEM and those found by independent spectroscopic analysis. We expect to find and validate more interesting candidates applying the pipeline to future data releases of the J-PLUS survey.

## ACKNOWLEDGEMENTS

C. A. Galarza acknowledges the full financial support from CAPES for the development of this Ph.D. project. Furthermore, all the authors thank Observatorio Astrofísico de Javalambre in Teruel, managed and operated by the Centro de Estudios de Física del Cosmos de Aragón (CEFCA) in charge of the JAST/T80 telescope responsible for carrying out the observations for the J-PLUS survey. There is also a special acknowledgment to the Roque de Los Muchachos Observatory in charge of the Isaac Newton Group of telescopes where the William Herschel Telescope (WHT) belongs. A final mention to the Scikit-learn team [16] for the significant contributions to the machine learning libraries for the python language.

## REFERENCES

- [1] Y. Bai, J. Liu, S. Wang, and F. Yang. Machine learning applied to star–galaxy–qso classification and stellar effective temperature regression. *The Astronomical Journal*, 157 (1): 9, 2018.
- [2] T.C. Beers, J. E. Norris, V. M. Piacco, Y. S. Lee, S. Rossi, D. Carollo, and T. Masseron. Population studies. xiii. a new analysis of the bidelman-macconnell “weak-metal” stars—confirmation of metal-poor stars in the thick disk of the galaxy. *The Astrophysical Journal*, 794 (1): 58, 2014.
- [3] C. Bishop. *Pattern Recognition and Machine Learning*. Information Science and Statistics. Springer, 2006.
- [4] L. Breiman. Random forests. *Machine learning*, 45 (1): 5–32, 2001.
- [5] L. Casagrande. Infrared flux method and colour calibrations. *Physica Scripta*, 2008 (T133): 014020, 2008.
- [6] L. Casagrande, I. Ramírez, J. Meléndez, M. Bessell, and M. Asplund. An absolutely calibrated teff scale from the infrared flux method-dwarfs and subgiants. *Astronomy & Astrophysics*, 512: A54, 2010.
- [7] A. J. Cenarro, M. Moles, D. Cristóbal-Hornillos, A. Marín-Franch, A. Ederoclite, J. Varela, C. López-Sanjuan, C. Hernández-Monteagudo, R. Angulo, H. V. Ramió, et al. J-plus: The javalambre photometric local universe survey. *Astronomy & Astrophysics*, 622: A 176, 2019.
- [8] J. Falcón-Barroso, P. Sánchez-Blázquez, A. Vazdekis, E. Ricciardelli, N. Cardiel, A. Cenarro, J. Gorgas, and R. Peletier. An updated miles stellar library and stellar population models. *Astronomy & Astrophysics*, 532: A95, 2011.

- [9] R. Gulati, R. Gupta, and H. Singh. E (bv) determinations of o and b stars using artificial neural networks. *Publications of the Astronomical Society of the Pacific*, 109 (737): 843, 1997.
- [10] T. Hastie, R. Tibshirani, and J. Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer series in statistics. Springer, 2001.
- [11] M. Jurić, Ž. Ivezić, A. Brooks, R. H. Lupton, D. Schlegel, D. Finkbeiner, N. Padmanabhan, N. Bond, B. Sesar, C. M. Rockosi, et al. The milky way tomography with sdss. i. stellar number density distribution. *The Astrophysical Journal*, 673 (2): 864, 2008.
- [12] Y. S. Lee, T. C. Beers, T. Sivarani, C. A. Prieto, L. Koesterke, R. Wilhelm, P. R. Fiorentin, C. A. Bailer-Jones, J. E. Norris, C. M. Rockosi, et al. The segue stellar parameter pipeline. i. description and comparison of individual methods. *The Astronomical Journal*, 136(5): 2022, 2008.
- [13] C. López-Sanjuan, J. Varela, D. Cristóbal-Hornillos, H. V. Ramió, J. Carrasco, P.-E. Tremblay, D. Whitten, V. Placco, A. Marín-Franch, A. Cenarro, et al. J-plus: photometric calibration of large-area multi-filter surveys with stellar and white dwarf loci. *Astronomy & Astrophysics*, 631: A119, 2019.
- [14] A. Miller, J. Bloom, J. Richards, Y. Lee, D. Starr, N. Butler, S. Tokarz, N. Smith, and J. A. Eisner. A machine-learning method to infer fundamental stellar parameters from photometric light curves. *The Astrophysical Journal*, 798 (2): 122, 2015.
- [15] J. Mouttaka, S. Ilovaisky, P. Prugniel, and C. Soubiran. The elodie archive. *Publications of the Astronomical Society of the Pacific*, 116 (821): 693, 2004.
- [16] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blon-del, P. Prettenhofer, R. Weiss, V. Dubourg, et al. Scikit-learn: Machine learning in python. *the Journal of machine Learning research*, 12: 2825–2830, 2011.
- [17] S. Scaringi, P. Groot, K. Verbeek, S. Greiss, C. Knigge, and E. Körding. Spectroscopic identifications of blue-ha-excess sources in the kepler field of view. *Monthly Notices of the Royal Astronomical Society*, 428(3): 2207–2215, 2013.
- [18] D. Whitten, V. Placco, T. Beers, A. Chies-Santos, C. Bonatto, J. Varela, D. Cristóbal-Hornillos, A. Ederoclite, T. Masseron, Y. Lee, et al. J-plus: Identification of low-metallicity stars with artificial neural networks using sphinx. *Astronomy & Astrophysics*, 622: A 182, 2019.
- [19] E. L. Wright, P. R. Eisenhardt, A. K. Mainzer, M. E. Ressler, R. M. Cutri, T. Jarrett, J. D. Kirkpatrick, D. Padgett, R. S. McMillan, M. Skrutskie, et al. The wide-field infrared survey explorer (wise): mission description and initial on-orbit performance. *The Astronomical Journal*, 140(6): 1868, 2010.
- [20] B. Yanny, C. Rockosi, H. J. Newberg, G. R. Knapp, J. K. Adelman-McCarthy, B. Alcorn, S. Allam, C. A. Prieto, D. An, K. S. Anderson, et al. Segue: A spectroscopic survey of 240,000 stars with  $g=14-20$ . *The Astronomical Journal*, 137(5): 4377, 2009.

## ÍNDICE REMISSIVO

### A

- Algoritmo 38, 40, 42, 44, 46, 48, 50, 70, 82, 120, 168, 169, 182, 257, 262, 265, 322, 330  
Análise avançada 53, 54, 55, 68  
Análise computacional 84, 103  
Análise estrutural 55, 71, 82, 84, 85, 92, 93, 94, 95, 97, 103, 109, 110, 111  
Aprendizado 13, 174, 193, 194, 197, 208, 215, 224, 268

### B

- Bullying 206, 207, 208, 210, 211, 212, 213, 214

### C

- Carga crítica 143, 144, 147, 148, 149, 152, 153  
Computational fluid dynamics 329, 330, 350  
Constitutive model 1, 2, 5, 6, 10  
Contorno 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 49, 50, 51, 71, 299  
Controlador neural 168, 169, 170, 171, 172, 173, 174, 175, 179  
Controle 19, 119, 120, 131, 168, 169, 171, 173, 174, 175, 176, 177, 178, 179, 180, 181, 182, 240, 295, 312, 352, 353, 356, 358

### D

- Deep learning 131, 132, 134, 135, 136, 137, 138, 141, 142  
Descarte adequado 198  
Desenvolvimento 11, 12, 14, 15, 17, 20, 21, 35, 36, 40, 44, 82, 83, 193, 194, 195, 197, 198, 199, 200, 205, 206, 208, 209, 210, 211, 215, 216, 217, 221, 225, 226, 227, 254, 260, 265, 281, 294, 327, 352, 354, 357, 359, 361, 362, 363, 364  
Design patterns 155, 156, 166, 167, 226, 227, 228, 230, 231, 234, 238  
Diferenças finitas 38, 39, 40, 45, 50, 51, 52, 315  
Digital 167, 197, 206, 207, 210, 213, 239, 243, 319, 320, 358, 359, 360, 362, 363, 365  
Drop test 131, 132, 133, 134, 135, 141

### E

- Educação 12, 13, 14, 21, 53, 68, 70, 191, 193, 195, 197, 208, 212, 215, 225, 279, 290, 311, 326, 359, 366  
Educacional 14, 82, 206, 208, 209  
Elemento hexaédrico 70, 72, 75, 77  
Elementos finitos 53, 55, 69, 70, 71, 72, 83, 279, 280, 281, 285, 286, 290, 291, 294, 297,

- 299, 303, 306, 309, 321  
Equações diferenciais 39, 40, 44, 51, 71, 294  
Estabilidade estrutural 143  
Estatística 21, 215, 216, 217, 218, 224, 225  
Estrutura 17, 38, 54, 71, 72, 75, 77, 78, 81, 82, 84, 85, 87, 89, 90, 91, 97, 98, 99, 101, 102, 103, 104, 106, 112, 113, 114, 115, 116, 117, 118, 152, 218, 221, 253, 266, 279, 280, 281, 282, 283, 284, 286, 288, 291, 292, 293, 297, 298, 302, 309, 362, 363

## F

- Ferramenta 15, 18, 22, 39, 193, 194, 195, 196, 200, 204, 210, 211, 216, 224, 294, 313, 354, 356, 360, 361, 363  
Frequências naturais 143, 144, 146, 147, 149, 150, 151, 152, 153

Fundação elástica 143

## G

- Geometria irregular 38  
Gestão de processos 351, 352, 354, 355, 358

## I

- Imperfeições geométricas iniciais 53, 54, 55, 62, 64, 67, 69  
Inclusão 29, 33, 35, 36, 67, 68, 197, 359, 360  
Industrial process 131  
Informação 12, 21, 193, 205, 216, 351, 354, 355, 356, 357, 358, 360, 366  
Inovação 86, 104, 105, 193, 366  
Interfaces 215, 216, 225, 231, 232, 233, 234, 235, 361

## J

- Jogo 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 206, 207, 209, 210, 211, 212, 213

## L

- Layout 221, 222, 359, 360, 362  
Libras 11, 12, 13, 14, 17, 18, 19, 20, 21, 22

## M

- Malha 38, 39, 40, 44, 45, 46, 49, 50, 72, 79, 108, 182, 285, 299, 303, 304, 313, 321, 322, 326  
Modelagem 31, 33, 35, 36, 38, 39, 70, 72, 149, 194, 251, 255, 268, 280, 285, 294, 295, 299, 305, 351, 352, 353, 354, 356, 357, 358  
Modos incompatíveis 70, 72, 75, 76, 77, 79, 80, 82, 83

## O

Oscar Niemeyer 84, 85, 86, 87, 89, 101, 102, 103, 104, 105, 118

## P

Pasternak 143, 144, 145, 149, 151, 153, 154

Processos 82, 171, 240, 312, 351, 352, 353, 354, 355, 356, 357, 358, 359, 361

Programação 72, 211, 215, 224, 361

Programas 55, 205, 206, 210, 214, 294, 359

Projeto socioambiental 198

## R

Realidade aumentada 193, 194, 195, 196, 197

Rede neural 168, 169, 171, 175

Resistência 53, 54, 55, 56, 60, 61, 62, 63, 64, 65, 66, 67, 68, 89, 96, 131, 145, 255, 256, 258, 261, 262, 263, 280, 294, 314

Robô 168, 169, 170, 173, 174, 175, 176, 177, 178, 179

Robótica 168

RPG 11, 12, 15, 16, 18

RStudio 215, 216, 217, 218, 220, 224, 225

## S

Shiny 215, 216, 217, 218, 220, 221, 224, 225

Simulações 23, 24, 30, 31, 33, 35, 38, 44, 50, 168, 169, 175, 181, 311, 312, 326, 329

Sobretensões de manobras 23, 24, 25, 29, 30

Software 1, 6, 12, 18, 40, 53, 55, 66, 70, 71, 72, 77, 79, 80, 82, 103, 155, 156, 157, 158, 159, 166, 167, 196, 210, 215, 216, 217, 218, 220, 224, 225, 226, 227, 228, 229, 230, 231, 232, 233, 235, 237, 238, 239, 256, 257, 263, 265, 266, 267, 281, 285, 297, 299, 300, 311, 320, 321, 330, 356, 357, 359, 360, 363, 364

Stable hysteresis cycle 1, 3, 9

Summarization 329, 330, 331, 332, 343, 349, 350

Supressores de surto 23, 25, 28, 29, 30, 33, 34, 35, 36

Sustentabilidade 198, 199

## T

Tecnologia 11, 12, 21, 54, 70, 168, 193, 194, 196, 197, 206, 208, 215, 279, 290, 311, 326, 351, 355, 358, 359, 362, 366

Tensão 1, 24, 25, 26, 27, 28, 33, 34, 59, 62, 63, 66, 67, 75, 170, 255, 256, 258, 260, 261,

266, 295

Tensões residuais 53, 54, 55, 61, 62, 63, 64, 65, 66, 67, 68, 69

Transformadores 23, 24, 25, 28, 30, 34, 35, 36

Transitórios eletromagnéticos 23, 24, 31

## W

Web 54, 194, 195, 196, 200, 215, 216, 217, 218, 221, 222, 225, 355, 359, 360, 361, 362, 363, 365

COLEÇÃO

# DESAFIOS

DAS

# ENGENHARIAS:

## ENGENHARIA DE COMPUTAÇÃO

- 
- 🌐 [www.atenaeditora.com.br](http://www.atenaeditora.com.br)
  - ✉️ [contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)
  - 📷 [@atenaeditora](https://www.instagram.com/atenaeditora)
  - FACEBOOK [www.facebook.com/atenaeditora.com.br](https://www.facebook.com/atenaeditora.com.br)

COLEÇÃO

# DESAFIOS

DAS

# ENGENHARIAS:

## ENGENHARIA DE COMPUTAÇÃO

- 
- 🌐 [www.atenaeditora.com.br](http://www.atenaeditora.com.br)
  - ✉️ [contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)
  - 📷 [@atenaeditora](https://www.instagram.com/atenaeditora)
  - FACEBOOK [www.facebook.com/atenaeditora.com.br](https://www.facebook.com/atenaeditora.com.br)