

Sistemas de Informação e Aplicações Computacionais

Ernane Rosa Martins
(Organizador)

 **Atena**
Editora
Ano 2020

Sistemas de Informação e Aplicações Computacionais

Ernane Rosa Martins
(Organizador)

 **Atena**
Editora
Ano 2020

Editora Chefe

Profª Drª Antonella Carvalho de Oliveira

Assistentes Editoriais

Natalia Oliveira

Bruno Oliveira

Flávia Roberta Barão

Bibliotecário

Maurício Amormino Júnior

Projeto Gráfico e Diagramação

Natália Sandrini de Azevedo

Camila Alves de Cremona

Karine de Lima Wisniewski

Luiza Alves Batista

Maria Alice Pinheiro

Imagens da Capa

Shutterstock

Edição de Arte

Luiza Alves Batista

Revisão

Os Autores

2020 by Atena Editora

Copyright © Atena Editora

Copyright do Texto © 2020 Os autores

Copyright da Edição © 2020 Atena Editora

Direitos para esta edição cedidos à Atena Editora pelos autores.



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição *Creative Commons*. Atribuição 4.0 Internacional (CC BY 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.

A Atena Editora não se responsabiliza por eventuais mudanças ocorridas nos endereços convencionais ou eletrônicos citados nesta obra.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação.

Conselho Editorial

Ciências Humanas e Sociais Aplicadas

Prof. Dr. Álvaro Augusto de Borba Barreto – Universidade Federal de Pelotas

Prof. Dr. Alexandre Jose Schumacher – Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso

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

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. Carlos Antonio de Souza Moraes – Universidade Federal Fluminense

Profª Drª Cristina Gaio – Universidade de Lisboa

Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia
Prof. Dr. Edvaldo Antunes de Farias – Universidade Estácio de Sá
Prof. Dr. Elson Ferreira Costa – Universidade do Estado do Pará
Prof. Dr. Eloi Martins Senhora – Universidade Federal de Roraima
Prof. Dr. Gustavo Henrique Cepolini Ferreira – Universidade Estadual de Montes Claros
Profª Drª Ivone Goulart Lopes – Istituto Internazionale delle Figlie de Maria Ausiliatrice
Prof. Dr. Jadson Correia de Oliveira – Universidade Católica do Salvador
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Profª Drª Lina Maria Gonçalves – Universidade Federal do Tocantins
Prof. Dr. Luis Ricardo Fernandes da Costa – Universidade Estadual de Montes Claros
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Marcelo Pereira da Silva – Pontifícia Universidade Católica de Campinas
Profª Drª Maria Luzia da Silva Santana – Universidade Federal de Mato Grosso do Sul
Profª Drª Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa
Profª Drª Rita de Cássia da Silva Oliveira – Universidade Estadual de Ponta Grossa
Prof. Dr. Rui Maia Diamantino – Universidade Salvador
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande
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
Profª Drª Carla Cristina Bauermann Brasil – Universidade Federal de Santa Maria
Prof. Dr. Antonio Pasqualetto – Pontifícia Universidade Católica de Goiás
Prof. Dr. Cleberton Correia Santos – Universidade Federal da Grande Dourados
Profª Drª Daiane Garabeli Trojan – Universidade Norte do Paraná
Profª Drª 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. Fágner Cavalcante Patrocínio dos Santos – Universidade Federal do Ceará
Profª Drª Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
Prof. Dr. Jael Soares Batista – Universidade Federal Rural do Semi-Árido
Prof. Dr. Júlio César Ribeiro – Universidade Federal Rural do Rio de Janeiro
Profª Drª Lina Raquel Santos Araújo – Universidade Estadual do Ceará
Prof. Dr. Pedro Manuel Villa – Universidade Federal de Viçosa
Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará
Profª Drª 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
Profª Drª Anelise Levay Murari – Universidade Federal de Pelotas
Prof. Dr. Benedito Rodrigues da Silva Neto – Universidade Federal de Goiás
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^a Dr^a Eleuza Rodrigues Machado – Faculdade Anhanguera de Brasília
Prof^a Dr^a Elane Schwinden Prudêncio – Universidade Federal de Santa Catarina
Prof^a Dr^a Eysler Gonçalves Maia Brasil – Universidade da Integração Internacional da Lusofonia Afro-Brasileira
Prof. Dr. Ferlando Lima Santos – Universidade Federal do Recôncavo da Bahia
Prof^a Dr^a 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^a Dr^a Iara Lúcia Tescarollo – Universidade São Francisco
Prof. Dr. Igor Luiz Vieira de Lima Santos – Universidade Federal de Campina Grande
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^a Dr^a Magnólia de Araújo Campos – Universidade Federal de Campina Grande
Prof. Dr. Marcus Fernando da Silva Praxedes – Universidade Federal do Recôncavo da Bahia
Prof^a Dr^a Mylena Andréa Oliveira Torres – Universidade Ceuma
Prof^a Dr^a Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Paulo Inada – Universidade Estadual de Maringá
Prof^a Dr^a Regiane Luz Carvalho – Centro Universitário das Faculdades Associadas de Ensino
Prof^a Dr^a Renata Mendes de Freitas – Universidade Federal de Juiz de Fora
Prof^a Dr^a Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa
Prof^a Dr^a Vanessa Bordin Viera – Universidade Federal de Campina Grande

Ciências Exatas e da Terra e Engenharias

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto
Prof. Dr. Alexandre Leite dos Santos Silva – Universidade Federal do Piauí
Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás
Prof^a Dr^a Carmen Lúcia Voigt – Universidade Norte do Paraná
Prof. Dr. Douglas Gonçalves da Silva – Universidade Estadual do Sudoeste da Bahia
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Prof^a Dra. Jéssica Verger Nardeli – Universidade Estadual Paulista Júlio de Mesquita Filho
Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande
Prof^a Dr^a 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^a Dr^a Neiva Maria de Almeida – Universidade Federal da Paraíba
Prof^a Dr^a Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista

Linguística, Letras e Artes

Prof^a Dr^a Adriana Demite Stephani – Universidade Federal do Tocantins
Prof^a Dr^a Angeli Rose do Nascimento – Universidade Federal do Estado do Rio de Janeiro
Prof^a Dr^a Carolina Fernandes da Silva Mandaji – Universidade Tecnológica Federal do Paraná
Prof^a Dr^a Denise Rocha – Universidade Federal do Ceará

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 de Mato Grosso
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

Conselho Técnico Científico

Prof. Me. Abrãao Carvalho Nogueira – Universidade Federal do Espírito Santo
Prof. Me. Adalberto Zorzo – Centro Estadual de Educação Tecnológica Paula Souza
Prof. Me. Adalto Moreira Braz – Universidade Federal de Goiás
Prof. Dr. Adaylson Wagner Sousa de Vasconcelos – Ordem dos Advogados do Brasil/Seccional Paraíba
Prof. Dr. Adilson Tadeu Basquerote Silva – Universidade para o Desenvolvimento do Alto Vale do Itajaí
Prof. Me. Alexsandro Teixeira Ribeiro – Centro Universitário Internacional
Prof. Me. André Flávio Gonçalves Silva – Universidade Federal do Maranhão
Profª Ma. Anne Karynne da Silva Barbosa – Universidade Federal do Maranhão
Profª Drª Andreza Lopes – Instituto de Pesquisa e Desenvolvimento Acadêmico
Profª Drª Andrezza Miguel da Silva – Faculdade da Amazônia
Prof. Dr. Antonio Hot Pereira de Faria – Polícia Militar de Minas Gerais
Prof. Me. Armando Dias Duarte – Universidade Federal de Pernambuco
Profª Ma. Bianca Camargo Martins – UniCesumar
Profª Ma. Carolina Shimomura Nanya – Universidade Federal de São Carlos
Prof. Me. Carlos Antônio dos Santos – Universidade Federal Rural do Rio de Janeiro
Prof. Ma. Cláudia de Araújo Marques – Faculdade de Música do Espírito Santo
Profª Drª Cláudia Taís Siqueira Cagliari – Centro Universitário Dinâmica das Cataratas
Prof. Me. Daniel da Silva Miranda – Universidade Federal do Pará
Profª Ma. Daniela da Silva Rodrigues – Universidade de Brasília
Profª Ma. Daniela Remião de Macedo – Universidade de Lisboa
Profª Ma. Dayane de Melo Barros – Universidade Federal de Pernambuco
Prof. Me. Douglas Santos Mezacas – Universidade Estadual de Goiás
Prof. Me. Edevaldo de Castro Monteiro – Embrapa Agrobiologia
Prof. Me. Eduardo Gomes de Oliveira – Faculdades Unificadas Doctum de Cataguases
Prof. Me. Eduardo Henrique Ferreira – Faculdade Pitágoras de Londrina
Prof. Dr. Edwaldo Costa – Marinha do Brasil
Prof. Me. Eliel Constantino da Silva – Universidade Estadual Paulista Júlio de Mesquita
Prof. Me. Ernane Rosa Martins – Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Prof. Me. Eivaldo de Sousa Costa Junior – Prefeitura Municipal de São João do Piauí
Profª Ma. Fabiana Coelho Couto Rocha Corrêa – Centro Universitário Estácio Juiz de Fora
Prof. Dr. Fabiano Lemos Pereira – Prefeitura Municipal de Macaé
Prof. Me. Felipe da Costa Negrão – Universidade Federal do Amazonas
Profª Drª Germana Ponce de Leon Ramírez – Centro Universitário Adventista de São Paulo
Prof. Me. Gevair Campos – Instituto Mineiro de Agropecuária
Prof. Dr. Guilherme Renato Gomes – Universidade Norte do Paraná
Prof. Me. Gustavo Krahl – Universidade do Oeste de Santa Catarina
Prof. Me. Helton Rangel Coutinho Junior – Tribunal de Justiça do Estado do Rio de Janeiro
Profª Ma. Isabelle Cerqueira Sousa – Universidade de Fortaleza

Profª Ma. Jaqueline Oliveira Rezende – Universidade Federal de Uberlândia
Prof. Me. Javier Antonio Albornoz – University of Miami and Miami Dade College
Prof. Me. Jhonatan da Silva Lima – Universidade Federal do Pará
Prof. Dr. José Carlos da Silva Mendes – Instituto de Psicologia Cognitiva, Desenvolvimento Humano e Social
Prof. Me. Jose Elyton Batista dos Santos – Universidade Federal de Sergipe
Prof. Me. José Luiz Leonardo de Araujo Pimenta – Instituto Nacional de Investigación Agropecuaria Uruguay
Prof. Me. José Messias Ribeiro Júnior – Instituto Federal de Educação Tecnológica de Pernambuco
Profª Drª Juliana Santana de Curcio – Universidade Federal de Goiás
Profª Ma. Juliana Thaisa Rodrigues Pacheco – Universidade Estadual de Ponta Grossa
Profª Drª Kamilly Souza do Vale – Núcleo de Pesquisas Fenomenológicas/UFGA
Prof. Dr. Kárpio Márcio de Siqueira – Universidade do Estado da Bahia
Profª Drª Karina de Araújo Dias – Prefeitura Municipal de Florianópolis
Prof. Dr. Lázaro Castro Silva Nascimento – Laboratório de Fenomenologia & Subjetividade/UFPR
Prof. Me. Leonardo Tullio – Universidade Estadual de Ponta Grossa
Profª Ma. Lilian Coelho de Freitas – Instituto Federal do Pará
Profª Ma. Liliani Aparecida Sereno Fontes de Medeiros – Consórcio CEDERJ
Profª Drª Lívia do Carmo Silva – Universidade Federal de Goiás
Prof. Me. Lucio Marques Vieira Souza – Secretaria de Estado da Educação, do Esporte e da Cultura de Sergipe
Prof. Me. Luis Henrique Almeida Castro – Universidade Federal da Grande Dourados
Prof. Dr. Luan Vinicius Bernardelli – Universidade Estadual do Paraná
Prof. Dr. Michel da Costa – Universidade Metropolitana de Santos
Prof. Dr. Marcelo Máximo Purificação – Fundação Integrada Municipal de Ensino Superior
Prof. Me. Marcos Aurelio Alves e Silva – Instituto Federal de Educação, Ciência e Tecnologia de São Paulo
Profª Ma. Maria Elanny Damasceno Silva – Universidade Federal do Ceará
Profª Ma. Marileila Marques Toledo – Universidade Federal dos Vales do Jequitinhonha e Mucuri
Prof. Me. Ricardo Sérgio da Silva – Universidade Federal de Pernambuco
Prof. Me. Rafael Henrique Silva – Hospital Universitário da Universidade Federal da Grande Dourados
Profª Ma. Renata Luciane Polsaque Young Blood – UniSecal
Prof. Me. Sebastião André Barbosa Junior – Universidade Federal Rural de Pernambuco
Profª Ma. Silene Ribeiro Miranda Barbosa – Consultoria Brasileira de Ensino, Pesquisa e Extensão
Profª Ma. Solange Aparecida de Souza Monteiro – Instituto Federal de São Paulo
Prof. Me. Tallys Newton Fernandes de Matos – Faculdade Regional Jaguaribana
Profª Ma. Thatianny Jasmine Castro Martins de Carvalho – Universidade Federal do Piauí
Prof. Me. Tiago Silvio Dedoné – Colégio ECEL Positivo
Prof. Dr. Welleson Feitosa Gazel – Universidade Paulista

Sistemas de informação e aplicações computacionais

Editora Chefe: Profª Drª Antonella Carvalho de Oliveira
Bibliotecário: Maurício Amormino Júnior
Diagramação: Karine de Lima Wisniewski
Edição de Arte: Luiza Alves Batista
Revisão: Os Autores
Organizador: Ernane Rosa Martins

Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG)

S622 Sistemas de informação e aplicações computacionais [recurso eletrônico] / Organizador Ernane Rosa Martins. – Ponta Grossa, PR: Atena, 2020.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN 978-65-5706-317-0

DOI 10.22533/at.ed.170201808

1. Computação – Pesquisa – Brasil. I. Martins, Ernane Rosa.
CDD 004

Elaborado por Maurício Amormino Júnior – CRB6/2422

Atena Editora

Ponta Grossa – Paraná – Brasil

Telefone: +55 (42) 3323-5493

www.atenaeditora.com.br

contato@atenaeditora.com.br

APRESENTAÇÃO

O termo Sistemas de Informação (SI), é utilizado para descrever sistemas que sejam automatizados. Este campo de estudo se preocupa com questões, tais como: o desenvolvimento, uso e implicações das tecnologias de informação e comunicação nas organizações. Os dados são os fatos de forma bruta das organizações, antes de terem sido organizados e arranjados de forma que as pessoas os entendam e possam usá-los. As informações, por sua vez, são os dados de forma significativa e útil para as pessoas.

Dentro deste contexto, esta obra aborda diversos assuntos relevantes para profissionais e estudantes das mais diversas áreas, tais como: um sistema para automatizar o processo de seleção de alunos, a investigação da visão computacional para classificar automaticamente a modalidade de uma imagem médica, o projeto extensionista “Clube de programação e robótica”, as estratégias do framework MeteorJS para a sincronização de dados entre os clientes e os servidores, a proposta de um modelo de predição capaz de identificar perfis de condução de motoristas utilizando aprendizado de máquina, a avaliação das estratégias, arquiteturas e metodologia aplicadas na Integração de aplicativos nos processos de gestão e organização da informação, o desenvolvimento de um jogo educativo, para auxiliar o processo de ensino-aprendizagem na área de testes de software, um ensaio que apresenta um método baseado nos RF-CC-17, para elaborar um Mapeamento de Conformidade e Mobilização (MCM), a análise das estratégias do modelo pedagógico ML-SAI, o qual foi desenvolvido para orientar atividades de m-learning, fundamentado na Teoria da Sala de Aula Invertida (SAI), uma proposta de um método para o projeto, a fabricação e o teste de um veículo aéreo não tripulado de baixo custo, o uso de dois modelos neurais trabalhando em conjunto a fim de efetuar a tarefa de detecção de pedestres, rastreamento e contagem por meio de imagens digitais, um estudo sobre a segurança em redes sociais, um sistema de elicitação de requisitos orientado pela modelagem de processo de negócio, um Sistema de Informação Ambiental, desenvolvido para armazenar e permitir a consulta de dados históricos ambientais, o uso de técnicas para segurança em aplicações web, uma metodologia que possa aumentar a confiança dos dados na entrada e saída do dinheiro público com uma rede blockchain, a construção de um simulador do reator nuclear de pesquisa TRIGA IPR-R1.

Sendo assim, os trabalhos que compõe esta obra permitem aos seus leitores, analisar e discutir os diversos assuntos interessantes abordados. Por fim, desejamos a cada autor, nossos mais sinceros agradecimentos por suas contribuições, e aos leitores, desejamos uma excelente leitura com excelentes e novas reflexões.

Ernane Rosa Martins

SUMÁRIO

CAPÍTULO 1	1
AUTOMAÇÃO DE PROCESSOS DA SECRETARIA GERAL DE UNIVERSIDADES VISANDO A SUSTENTABILIDADE	
Beatriz da Mota Bonanno Daniela Vieira Cunha Fabio Kawaoka Takase	
DOI 10.22533/at.ed.1702018081	
CAPÍTULO 2	15
CLASSIFICAÇÃO DE IMAGENS MÉDICAS EM MODALIDADES USANDO VISÃO COMPUTACIONAL	
Sara Conceição de Sousa Araújo Silva Glauco Vitor Pedrosa	
DOI 10.22533/at.ed.1702018082	
CAPÍTULO 3	26
CLUBE DE PROGRAMAÇÃO E ROBÓTICA: EXPERIMENTOS EDUCACIONAIS NO ENSINO FUNDAMENTAL NO INTERIOR DA AMAZÔNIA	
Ruan Carlos Tavares Reis Andrew Pedreiro Amorim Angel Pena Galvão Andrik Guimarães Ferreira Juarez Benedito da Silva Clayton André Maia dos Santos	
DOI 10.22533/at.ed.1702018083	
CAPÍTULO 4	36
ESTRATÉGIAS PARA SINCRONIZAÇÃO E PROTEÇÃO DE DADOS EM APLICAÇÕES WEB REAL-TIME UTILIZANDO METEORJS	
Renan Gomes Barreto Lucas Oliveira Costa Aversari	
DOI 10.22533/at.ed.1702018084	
CAPÍTULO 5	48
IDENTIFICAÇÃO AUTOMÁTICA DE PERFIS DE MOTORISTAS USANDO APRENDIZADO DE MÁQUINA	
Ricardo Roberto Carlos da Silva Júnior Hilário Tomaz Alves de Oliveira	
DOI 10.22533/at.ed.1702018085	
CAPÍTULO 6	60
INTEGRAÇÃO DE APLICATIVOS: ESTRATÉGIA, ARQUITETURA E METODOLOGIA	
Francisco Carlos Paletta	
DOI 10.22533/at.ed.1702018086	
CAPÍTULO 7	70
ISLANDTEST: JOGO EDUCATIVO PARA APOIAR O PROCESSO ENSINO-APRENDIZAGEM DE TESTES DE SOFTWARE	
Rafael Jesus de Queiroz Fabrício de Sousa Pinto Paulo Caetano da Silva	
DOI 10.22533/at.ed.1702018087	

CAPÍTULO 8 82

MÉTODO BASEADO NOS REFERENCIAIS DE FORMAÇÃO DA SBC PARA REESTRUTURAÇÃO DE DESCRITIVOS DE DISCIPLINAS DE CIÊNCIA DA COMPUTAÇÃO EM CONFORMIDADE COM AS DCN DE 2016

Alcides Calsavara
Ana Paula Gonçalves Serra
Francisco de Assis Zampiroli
Leandro Silva Galvão de Carvalho
Miguel Jonathan
Ronaldo Celso Messias Correia

DOI 10.22533/at.ed.1702018088

CAPÍTULO 9 95

ML-SAI: UM MODELO PEDAGÓGICO PARA ATIVIDADES DE M-LEARNING QUE INTEGRA A ABORDAGEM DA SALA DE AULA INVERTIDA

Ernane Rosa Martins
Luís Manuel Borges Gouveia

DOI 10.22533/at.ed.1702018089

CAPÍTULO 10 107

MODELAGEM PARA ESTIMATIVA E PROJEÇÃO DE ESTOQUE DE CARBONO EM FRAGMENTOS DE FLORESTA OMBRÓFILA DENSA DE TERRAS BAIXAS POR MEIO DE ÍNDICES DE VEGETAÇÃO E LINGUAGEM R

Eric Bem dos Santos
Hernande Pereira da Silva
Jones Oliveira de Albuquerque

DOI 10.22533/at.ed.17020180810

CAPÍTULO 11 120

PROJETO, CONSTRUÇÃO DE UM VEÍCULO AÉREO NÃO TRIPULADO COM BASE EM CO-PROJETO DE HARDWARE E SOFTWARE

Alex Ribeiro Souza
Mariana Cardoso
Junio Horniche
Patricia Boff
João Guilherme Bonilha Viana
Maurício Acconcia Dias

DOI 10.22533/at.ed.17020180811

CAPÍTULO 12 133

RASTREAMENTO E CONTAGEM DE PEDESTRE EM TEMPO REAL POR MEIO DE IMAGENS DIGITAIS

Alexssandro Ferreira Cordeiro
Cristhian Urunaga Ojeda
Pedro Luiz de Paula Filho
Gustavo Rafael Valiati

DOI 10.22533/at.ed.17020180812

CAPÍTULO 13 143

SEGURANÇA EM REDES SOCIAIS: UMA ABORDAGEM BASEADA NA CONSCIENTIZAÇÃO DE CRIANÇAS E ADOLESCENTES EM UMA ESCOLA MUNICIPAL DA CIDADE E SANTARÉM

Clayton André Maia dos Santos
João Vitor Mota dos Santos
Yan Marcos Bentes dos Anjos
Angel Pena Galvão

Irley Monteiro Araújo
Juarez Benedito da Silva
Aloísio Costa Barros
Pablo Nunes de Oliveira
Brenda da Silva Nunes

DOI 10.22533/at.ed.17020180813

CAPÍTULO 14 151

SISREMO – SISTEMA DE ELICITAÇÃO DE REQUISITOS COM BASE NA TÉCNICA REMO

Carlos Ricardo Bandeira de Souza
Sérgio Roberto Costa Vieira

DOI 10.22533/at.ed.17020180814

CAPÍTULO 15 166

SISTEMA DE INFORMAÇÃO AMBIENTAL: VISUALIZAÇÃO DE DADOS DO ÍNDICE DE QUALIDADE DA ÁGUA APLICADO A MÚLTIPLOS PONTOS

Vania Elisabete Schneider
Odacir Deonísio Gracioli
Helena Graziottin Ribeiro
Adriano Gomes da Silva
Mayara Cechinato
Taison Anderson Bortolin

DOI 10.22533/at.ed.17020180815

CAPÍTULO 16 172

TÉCNICAS PARA SEGURANÇA EM APLICAÇÕES WEB - BASEADO EM MESSAGE-DIGEST ALGORITHM

Daniel Rodrigues Ferraz Izario
Yuzo Iano
João Luiz Brancalhone Filho
Karine Mendes Siqueira Rodrigues Ferraz Izario

DOI 10.22533/at.ed.17020180816

CAPÍTULO 17 183

UMA PROPOSTA INOVADORA UTILIZANDO BLOCKCHAIN PARA A GESTÃO FINANCEIRA EM OBRAS PÚBLICAS, TENDO COMO BASE O SISTEMA BRASILEIRO

Ricardo Silva Parente
Ítalo Rodrigo Soares Silva
Paulo Oliveira Siqueira Júnior
Jorge de Almeida Brito Júnior
Manoel Henrique Reis Nascimento
David Barbosa de Alencar
Jandecy Cabral Leite
Paulo Francisco da Silva Ribeiro

DOI 10.22533/at.ed.17020180817

CAPÍTULO 18 197

UTILIZAÇÃO DO ARDUINO COMO FERRAMENTA DE DIVULGAÇÃO DA ÁREA NUCLEAR

Hudson Henrique da Silva
Samira Santos da Silva
Sincler Peixoto de Meireles

DOI 10.22533/at.ed.17020180818

SOBRE O ORGANIZADOR..... 207

ÍNDICE REMISSIVO 208

IDENTIFICAÇÃO AUTOMÁTICA DE PERFIS DE MOTORISTAS USANDO APRENDIZADO DE MÁQUINA

Data de aceite: 06/08/2020

Data de submissão: 07/07/2020

Ricardo Roberto Carlos da Silva Júnior

Centro Universitário de João Pessoa – Unipê

João Pessoa – Paraíba

Hilário Tomaz Alves de Oliveira

Instituto Federal do Espírito Santo – Campus

Serra

Serra - Espírito Santo

<http://lattes.cnpq.br/8980213630090119>

RESUMO: Sistemas de gerenciamento de frotas tem por objetivo gerenciar a produtividade, custos, segurança e eficiência da frota de veículos de uma organização. Esse tipo de sistema apresenta diversos desafios, como: monitorar e gerenciar a frota de veículos, controlar despesas com combustível, manutenções, entre outras. O uso de técnicas de Inteligência Artificial vem sendo cada vez mais utilizado em sistemas de informação para solucionar problemas que exigem a capacidade de decidir baseado em experiências prévias do problema. Este trabalho propõe um modelo de predição capaz de identificar perfis de condução de motoristas utilizando Aprendizado de Máquina. Para isso, utilizamos dados de motoristas gerados a partir de um sistema de gerenciamento de frotas de veículos. A

investigação realizada abordou o problema de identificação dos perfis dos motoristas, como um problema de classificação binária e de uma única classe. Experimentos foram realizados para avaliar o modelo proposto nessas duas vertentes utilizando uma base de dados real coletada de um sistema de gestão de frota. Os resultados experimentais demonstram que a solução desenvolvida é viável, e o melhor modelo obteve uma acurácia global de 80,96% na identificação dos perfis de condução dos motoristas usando o algoritmo de máquina de vetores de suporte.

PALAVRAS-CHAVE: Inteligência Artificial; Sistemas de Informação; Aprendizado de Máquina; Gestão de Frotas.

AUTOMATIC IDENTIFICATION OF DRIVERS PROFILES USING MACHINE LEARNING

ABSTRACT: Fleet management systems aim to manage the productivity, costs, safety, and efficiency of an organization's vehicle fleet. This kind of system presents several challenges, such as monitoring and managing the vehicle fleet, controlling fuel expenses, maintenance, among others. The use of Artificial Intelligence techniques has been increasingly used in information systems to solve problems that

require the ability to decide based on previous experiences of the problem. This work proposes a prediction model capable of identifying driving profiles using Machine Learning. We use driving data generated from a vehicle fleet management system. The investigation carried out addressed the problem of identifying driving profiles as a binary and a one-class classification problem. Experiments were carried out to evaluate the model proposed in these two aspects using a real database collected from a fleet management system. The experimental results demonstrate that the developed solution is viable, and the best model obtained an overall accuracy of 80.96% in the identification of driving profiles using the support vector machine algorithm.

KEYWORDS: Artificial Intelligence; Information systems; Machine Learning. Fleet management.

1 | INTRODUÇÃO

O uso de sistemas de informação tornou-se indispensável para as empresas poderem gerenciar os seus processos de forma rápida e eficiente. Um Sistema de Informação (SI) pode ser definido como uma coleção de módulos interligados com funções de coletar, manipular, armazenar e disseminar dados, fornecendo um instrumento de realimentação para alcançar um determinado objetivo (STAIRS e REYNOLDS, 2015).

Qualquer empresa, independente da sua área de atuação, necessita de algum modelo de software de SI que permita mais precisão e agilidade nos seus processos. Atualmente, é praticamente impossível garantir a eficácia em uma empresa ou organização sem a utilização de um, ou mais, sistemas computacionais em seus processos. São vários os benefícios da utilização de sistemas, entre eles, podem-se observar o aumento da produtividade, redução de custos, melhoria na comunicação, maior facilidade na tomada de decisões e como consequência, o aumento da receita (STAIRS e REYNOLDS, 2015).

Com o avanço da tecnologia, têm-se observado um crescente interesse na implantação de Inteligência Artificial (IA) nos SI existentes. Sistemas computacionais que usam técnicas de IA estão cada dia mais presentes no cotidiano das pessoas, por exemplo, nos sistemas de e-mail que adotam algoritmos de IA para filtragem de SPAM, assistentes virtuais de conversação, entre outros. Além disso, existem ainda diversas outras possíveis áreas de aplicação que podem se beneficiar do uso de técnicas de IA. Em particular, uma dessas áreas é a de gestão de frotas, que envolve o gerenciamento de um grande conjunto de atividades referentes aos veículos de uma empresa ou organização. Essas atividades são auxiliadas pela utilização de técnicas, ferramentas e métodos que permitem eliminar possíveis riscos inerentes ao investimento dos veículos, além de aumentar a qualidade do serviço, a produtividade e a efetividade das operações (SILVA e OLIVEIRA, 2018).

Uma das principais funcionalidades de um sistema de gestão de frotas é a identificação do motorista que está conduzindo um certo veículo. Em geral, para obter esse

reconhecimento é necessário o uso de equipamentos de elevado custo para leitura explícita de um cartão de identificação do motorista. Além do problema do alto investimento, esse tipo de identificação está propício à fraude. Nesse contexto, o uso de técnicas de IA para auxiliar no reconhecimento automático do motorista ou de características relacionadas ao perfil de condução de um motorista, pode ser uma solução de grande potencial.

O objetivo deste trabalho é propor uma solução usando Aprendizado de Máquina para identificar perfis de condução de motoristas automaticamente em um sistema de gestão de frotas. A solução proposta utiliza dados da forma como o motorista conduz um veículo, coletadas a partir de um sistema de gerenciamento de frotas. Os dados utilizados neste trabalho são: excessos de velocidade dos veículos, realização de ações como freadas bruscas, distâncias percorridas, tempo ocioso do motor, entre outras.

O objetivo da solução proposta é mitigar o problema do alto custo com equipamentos e agregar mais praticidade ao processo de identificação de motoristas. Nossa ideia é que usando um modelo de classificação é possível aprender com dados históricos, o modo como um motorista conduz um certo veículo. Dessa forma, no futuro, caso ocorra em um determinado dia um comportamento muito diferente do normal, isso demonstra um desvio atípico daquele perfil de condução, o que deve ser identificado pelo modelo e, posteriormente, emitido um alerta para esse fato seja analisado pelo gestor responsável.

Para avaliar a viabilidade da solução proposta, dois experimentos foram realizados utilizando uma base de dados real contendo dados de dez motoristas, coletados a partir de 1.513 dias de monitoramento. Os resultados experimentais demonstram que o modelo de classificação criado obteve uma acurácia de 80,96% na identificação dos perfis de condução dos motoristas utilizando o algoritmo de máquina de vetores de suporte.

2 | SOLUÇÃO PROPOSTA

Inicialmente, como o módulo de identificação de motorista proposto neste trabalho funcionará de forma integrada a um sistema de gestão de frota, é necessário entender como a arquitetura atual desse sistema funciona. Esse entendimento é essencial para compreender como os dados que serão utilizados pelo modelo de classificação proposto são capturados. A Figura 1 apresenta a arquitetura do sistema de gerenciamento de frotas utilizado neste trabalho.

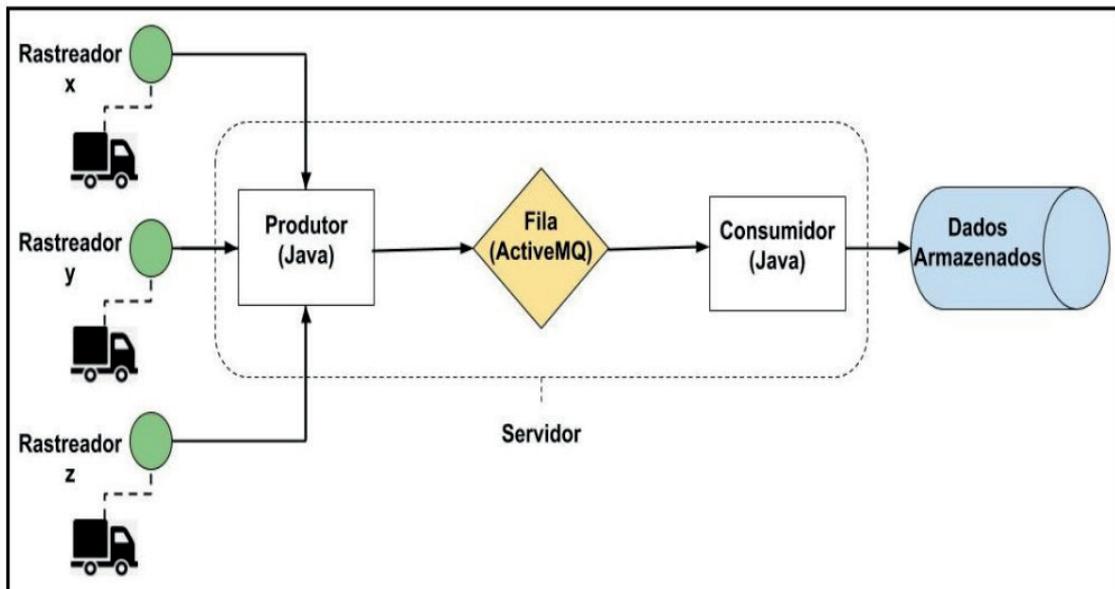


Figura 1. Arquitetura do Sistema de gestão de frotas.

A arquitetura do sistema pode ser descrita iniciando pelos equipamentos de rastreamento adotados. Cada veículo monitorado pelo sistema tem um rastreador conectado. Esses equipamentos além de recuperar a localização geométrica, capturam em um intervalo de no máximo 30 segundos diversos dados relevantes para o gerenciamento dos veículos, como: velocidade, distância percorrida, status da ignição, aceleração brusca, freada brusca, curva acentuada, entre outras. Esses dados são obtidos e enviados para um servidor via internet, pois, cada rastreador contém modem com tecnologia 2G, 3G ou 4G.

A comunicação entre o rastreador e o servidor foi desenvolvida seguindo uma arquitetura clássica do tipo Produtor-Consumidor e foi completamente desenvolvida usando a linguagem de programação Java. O módulo Produtor possui três funções principais: **(i)** receber pacotes de dados dos equipamentos conectados nos veículos; **(ii)** enviar alguma instrução para os mesmos; e **(iii)** armazenar em uma estrutura de dados do tipo fila todos os dados coletados no ActiveMQ.

O ActiveMQ é um intermediário de mensagem de código-fonte aberto escrito na linguagem Java, com um cliente do tipo Java Message Service (JMS). O ActiveMQ promove a comunicação entre mais de um cliente ou servidor. Neste caso, o ActiveMQ armazena temporariamente os pacotes de dados que recebeu do Produtor até que outro *software* denominado Consumidor capture cada pacote.

O módulo Consumidor tem como função principal receber e tratar os dados armazenados no ActiveMQ. Esse tratamento significa interpretar os pacotes, separando os dados e atribuindo o devido valor a cada atributo. Após esse processo, o sistema Consumidor armazena de forma definitiva todos os eventos e dados recebidos e tratados em um banco de dados MySQL.

O objetivo do módulo de predição proposto neste trabalho é a identificação do perfil de condução dos motoristas através dos dados gerados pelo equipamento rastreador, excluindo a obrigatoriedade do uso agregado de outros equipamentos. Dessa forma, espera-se reduzir o custo da implantação da funcionalidade de identificação explícita do motorista, ajudando a solucionar o problema da possibilidade de fraude.

A Figura 2 apresenta uma visão geral das etapas realizadas pelo módulo de identificação proposto neste trabalho que tem início a partir da leitura da base de dados do monitoramento dos veículos. A solução proposta neste trabalho foi desenvolvida utilizando a linguagem Python.

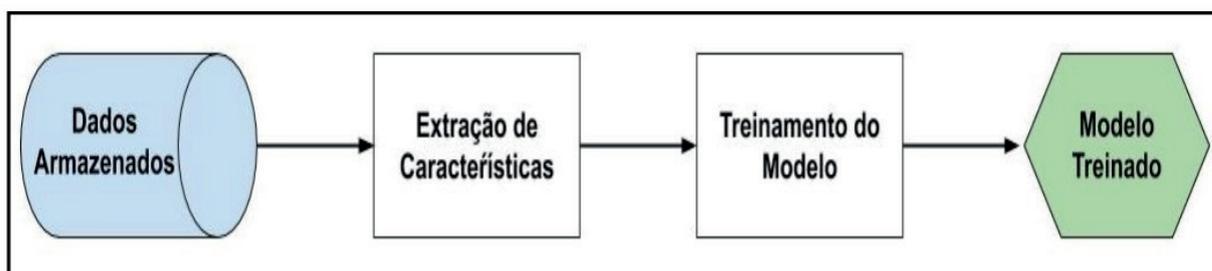


Figura 2. Arquitetura do módulo proposto.

Com os dados do veículo coletados pelos rastreadores é possível ter acesso aos dados gerados durante os trajetos e rotas percorridas pelos veículos, como: velocidade, quilômetros percorridos, status de ignição ligada ou desligada, identificação do motorista, latitude, longitude, data e hora do momento da informação. Além desses, os rastreadores geram eventos através do seu acelerômetro, como excesso de velocidade, aceleração brusca, freada brusca e curva acentuada.

Inicialmente, o módulo proposto realiza a leitura dos dados armazenados no banco de dados e executa a extração das características (atributos) que, posteriormente, são usadas para a construção do modelo de predição proposto. Os atributos investigados neste trabalho são:

- **Aceleração brusca:** evento gerado pelo rastreador quando o motorista acelera o veículo de forma brusca ou fora do padrão configurado.
- **Freada brusca:** evento gerado pelo rastreador quando o motorista freia o veículo de forma brusca ou fora do padrão configurado.
- **Curva acentuada:** evento gerado pelo rastreador quando o motorista faz uma curva, movendo o volante de forma brusca ou fora do padrão configurado.
- **Excesso de velocidade:** evento gerado quando o veículo ultrapassa a velocidade permitida configurada no rastreador.
- **Velocidade máxima:** velocidade máxima alcançada pelo veículo por dia.
- **Velocidade média:** velocidade média do veículo por dia.

Os dados supracitados são transmitidos pelos equipamentos rastreadores através de eventos gerados no intervalo máximo de 30 segundos. Por isso, foi necessário desenvolver uma rotina para agrupar esses dados e derivar os atributos por dia. Dessa forma, foi possível obter para cada dia a velocidade máxima, velocidade média e a quantidade dos eventos de aceleração brusca, freada brusca, curva acentuada e excesso de velocidade.

As características extraídas são utilizadas como um vetor de atributos para treinar o modelo de classificação proposto. Para treinar um modelo de aprendizado supervisionado é necessário ter exemplos rotulados para que o algoritmo possa aprender a partir desses exemplos de treinamento. Para isso, utilizou-se a base de dados do sistema de gestão de frotas que possui diversos dados de monitoramento dos veículos, com seus respectivos motoristas identificados pelo seu cartão de identificação.

É importante ressaltar que o objetivo do módulo proposto neste trabalho não é classificar os dados de um dia de condução (vetor de atributos) predizendo os nomes dos motoristas. O cenário vislumbrado é sem nenhuma identificação explícita do motorista, coletar dados do processo de condução de um certo veículo, de forma a aprender o comportamento de direção do motorista desse veículo. Dessa forma, caso no futuro aconteça um comportamento atípico de condução, o mesmo seja identificado e sinalizado para o sistema de gestão de frota.

Baseado no objetivo vislumbrado, a ideia é treinar um modelo de classificação a partir de um conjunto de exemplos, contendo o histórico de monitoramento de condução de um certo veículo Y. Dessa forma, dada uma nova ocorrência, ou seja, um novo dia de monitoramento do veículo Y, o objetivo do modelo é estimar se o comportamento de direção foi normal com base nos exemplos usados para treiná-lo ou se houve um comportamento de direção fora do normal.

3 | EXPERIMENTOS

Nesta seção, são apresentados dois experimentos realizados para avaliar o módulo de identificação proposto. Na subseção 3.1, são apresentadas algumas informações importantes relacionadas ao ambiente experimental utilizado. O primeiro experimento, apresentado na subseção 3.2, compara a execução de diferentes algoritmos de AM para a identificação do perfil de condução. Nesse experimento, a tarefa de identificação do motorista foi tratada, como um problema de classificação binária. Na subseção 3.3, são apresentados os resultados do segundo experimento, cujo o objetivo é comparar o desempenho de diferentes algoritmos de AM, mas neste caso, tratando a tarefa de identificação do perfil de condução como um problema de classificação de uma única classe.

3.1 CONFIGURAÇÃO DOS EXPERIMENTOS

Os experimentos foram realizados usando o mesmo conjunto de dados reais extraídos de um sistema de gestão de frotas. Os dados usados nos experimentos foram coletados entre os meses de junho de 2018 e dezembro de 2018, sendo monitorados dez motoristas, que por questões de privacidade foram identificados com os rótulos de 1 até 10. Os dados foram extraídos do banco de dados e exportados em arquivos Comma Separated Values (CSV) para a execução do protótipo do módulo de identificação proposto neste trabalho de maneira independente do sistema de gestão de frota.

No total foram usados 1.513 dias de monitoramento, considerando o intervalo de tempo e os dez motoristas. Esse conjunto de dados é usado em todos os experimentos realizados neste trabalho. É importante ressaltar que para cada dia de monitoramento foram coletados os seguintes dados de cada motorista: quantidade dos eventos de aceleração brusca, freada brusca, curva acentuada, e excesso de velocidade. Além disso, foram coletados a velocidade máxima e média do dia. Dessa forma, seis atributos são usados para a construção do modelo.

A medida de avaliação usada nos experimentos foi a taxa de acerto ou acurácia global, que consiste na razão entre o total de classificações corretas feitas pelo algoritmo em relação ao total de classificações realizadas.

3.2 EXPERIMENTO 1 – CLASSIFICAÇÃO BINÁRIA

Neste primeiro experimento, a tarefa de identificação do perfil do motorista foi tratada, como um problema de classificação de duas classes (binária), ou seja, o objetivo é criar um modelo de predição capaz de identificar, dado um monitoramento de um veículo de um dia, se este foi conduzido pelo Motorista X ou não.

Foram avaliados os seguintes algoritmos de AM: Árvore de Decisão (FACELI et al, 2011), K-vizinhos mais próximos, do inglês, K-nearest Neighbours (KNN) (AHA e KIBLER, 1991), Naive Bayes (JOHN e LANGLEY, 1995), Random Forest (BREIMAN, 2001), e quatro variações do algoritmo de Máquinas de Vetores de Suporte (CORTES e VAPNIK, 1995), do inglês *Support Vector Machines* (SVM), usando como funções de núcleo as seguintes opções: **(i)** Uma função linear (SVM Linear); **(ii)** Uma função de base radial, do inglês *Radial Basis Function* (SVM RBF); **(iii)** Uma função polinomial (SVM Polinomial); e **(iv)** a função Sigmoide (SVM Sigmoide). Todos os algoritmos mencionados foram utilizados usando as implementações disponíveis na ferramenta *scikit-learn* (<https://scikit-learn.org/>), usando suas configurações padrões.

Como metodologia de avaliação, foi utilizado o método de *Leave-one-out* (LOO). Esse método consiste em realizar para cada um dos 1.513 dias (exemplos), as seguintes etapas:

- **Treinamento:** Nesta etapa, 1.512 exemplos (dias) são usados para treinamento, gerando ao final um modelo de classificação.
- **Teste:** O exemplo (dia) de monitoramento não usado na etapa de treinamento é usado nesta etapa para testar o modelo gerado na etapa anterior.

Como o processo de classificação adotado foi binário, para cada exemplo analisado, os 1.512 usados para o treinamento do modelo foram alterados da seguinte forma: Caso o exemplo de treinamento seja do mesmo motorista do exemplo de teste, esse rótulo do motorista permanece; caso contrário o rótulo do exemplo fica como sendo 'Outro'. Ou seja, o algoritmo é treinado para classificar um exemplo como sendo da classe motorista 'X', onde X é o identificador do motorista, ou da classe 'Outro'.

Para comparar os algoritmos de AM investigados, ao final das 1.513 execuções, computou-se a acurácia global de cada algoritmo. São apresentados na Tabela 1 os resultados obtidos na execução dos experimentos. O melhor resultado com base na medida de acurácia está destacado em negrito.

Algoritmos	Acurácia (%)
Árvore de Decisão	45,87
KNN	43,89
Naive Bayes	54,73
Random Forest	40,12
SVM Linear	79,51
SVM Polinomial	65,30
SVM RBF	80,96
SVM Sigmoides	60,74

Tabela 1. Resultados da comparação dos algoritmos de AM na tarefa de classificação binária com base na medida de acurácia.

Como pode ser observado na Tabela 1, as variações do algoritmo de SVM apresentaram resultados superiores aos demais algoritmos considerados. O algoritmo que apresentou o melhor desempenho foi o de SVM usando como núcleo uma função radial (SVM RBF). Esse algoritmo conseguiu classificar corretamente 1.225 dos 1.513 exemplos considerados, o que representa uma taxa de assertividade de 80,96%. Por outro lado, o algoritmo *Random Forest* apresentou o pior desempenho acertando apenas 607 (40,12%) dos exemplos.

Os algoritmos foram executados usando todos os seis atributos, ou seja, nenhum algoritmo de seleção de características foi executado. Nesse caso, nada foi verificado sobre a relevância de cada um dos atributos para o processo de classificação. Deixamos essa tarefa como uma possível linha de investigação futura.

Um ponto importante a ser mencionado e que pode impactar no desempenho dos algoritmos, é que motoristas diferentes podem ter comportamentos de conduções semelhantes, ou seja, ter um modo de dirigir similar. Por isso, é muito complexo realizar o processo de decisão de classificação, dado que podem existir exemplos similares nas duas classes de categorização. Uma investigação futura para analisar esses casos é necessário para melhorar o processo de classificação.

3.3 EXPERIMENTO 2 – CLASSIFICAÇÃO DE UMA ÚNICA CLASSE

Neste segundo experimento, a tarefa de identificação do perfil de condução foi abordada, como um problema de classificação de uma única classe, do inglês *One-class classification* (OCC). O objetivo é criar um modelo de predição capaz de identificar, dado um monitoramento de um veículo de um dia, se este representa um comportamento normal (*inlier*), ou seja, pertence à classe usada para treinar o modelo, ou se representa um comportamento anormal (anomalia) que não pertence a essa classe (*outlier*).

A tarefa de classificação de uma única classe é muito usada para a detecção de valores discrepantes. Nessa tarefa o objetivo é separar observações regulares de algumas observações considerada anormais, chamadas *outliers*. Os seguintes algoritmos foram selecionados por serem comumente usados para detecção de *outliers*: *Elliptic Envelope* (ROUSSEEUW e VAN DRIESSEN, 1999), *Local Outlier Factor* (BREUNIG et al., 2000), *Isolation Forest* (LIU; TING; ZHOU, 2008) e *One Class Support Vector Machines* (OSVM) (SCHOLKOPF et al., 2000) usando, como núcleo as seguintes variações: **(i)** a função de base radial (OSVM RBF); **(ii)** a função Sigmoide (OSVM Sigmoide); **(iii)** a função linear (OSVM Linear); e **(iv)** a função polinomial (OSVM Polinomial). Todos os algoritmos mencionados foram utilizados com as implementações disponíveis na ferramenta *scikit-learn*, usando suas configurações padrões.

Como metodologia de avaliação, foi utilizado uma variação do método de *Leave-one-out* (LOO). Como mencionado anteriormente, esse método executa para cada um dos 1.513 dias (exemplos), as seguintes etapas:

- **Treinamento:** Nesta etapa, somente os exemplos que são do motorista selecionado para teste, são usados para treinar o modelo de classificação. É importante ressaltar que essa estratégia foi adotada porque na tarefa de classificação OCC, apenas exemplos de uma única classe são usados durante o treinamento. Dessa forma, todos os X exemplos que não são do mesmo motorista do indivíduo de teste, não são utilizados aqui.
- **Teste:** O exemplo (dia) de monitoramento não usado na etapa de treinamento, é usado nesta etapa para testar o modelo criado na etapa anterior. Como na etapa de treinamento apenas exemplos que são da mesma classe do indivíduo de teste foram usados para treinar o modelo, apenas a capacidade de detectar comportamentos normais (*inliers*) será avaliado, ou seja, todos os indivíduos de teste são

inliers. Dessa forma, foram realizados 1.513 testes de identificação de *inliers*. Para testar a capacidade do modelo gerado de identificar a presença de anomalias (outliers), foi usada a ideia de usar todos os X exemplos que não são do motorista do indivíduo de teste, como exemplos de teste de outliers. Dessa forma, para esta avaliação, foram realizados ao todo 13.617 testes de identificação de outliers.

Seguindo o processo de avaliação descrito anteriormente, foram realizados 1.513 testes para identificação de *inliers* e 13.617 testes para o reconhecimento de outliers. Por isso, computou-se a acurácia de cada algoritmo no processo de identificação de *inliers*, *outliers*, e a acurácia global. Na Tabela 2 são apresentados os resultados obtidos na execução deste experimento, com o melhor resultado em cada cenário avaliado está destacado em negrito.

Algoritmos	<i>Inliers</i> (%)	<i>Outliers</i> (%)	Acurácia Global (%)
<i>Elliptic Envelope</i>	89,29	32,67	38,33
<i>Local Outlier Factor</i>	91,14	40,00	45,11
<i>Isolation Forest</i>	84,73	42,38	46,62
<i>OSVM Linear</i>	48,45	81,05	77,79
OSVM RBF	48,98	71,50	69,24
OSVM Polinomial	47,65	72,50	70,01
OSVM Sigmoide	50,36	70,54	68,52

Tabela 2. Resultados da comparação dos algoritmos de AM na tarefa de classificação de uma única classe com base na medida de acurácia.

Os resultados dos experimentos demonstram que o desempenho dos algoritmos varia consideravelmente nas tarefas de detecção de *inliers* e outliers. O algoritmo *Local Outlier Factor* obteve o melhor desempenho na tarefa de classificação de *inliers*, identificando corretamente 1.379 dos 1.513 casos de teste. Por outro lado, os seus resultados no processo de reconhecimento de outliers foi muito baixo, classificando corretamente apenas 5.446 dos 13.617 casos de teste.

O algoritmo OSVM Linear apresentou o melhor desempenho no processo de reconhecimento de outliers, classificando corretamente 11.037 dos 13.617 testes realizados. Na tarefa de reconhecimento de *inliers* sua performance foi baixa, apenas 733 classificações corretas dentre os 1.513 testes. Apesar desse baixo desempenho, o algoritmo OSVM Linear obteve a melhor acurácia global com 11.770 identificações corretas, o que representa uma taxa de 77,79% de assertividade.

Assim como no experimento anterior, o fato de existirem motoristas diferentes com comportamentos de direção similares, acabou diminuindo o desempenho dos algoritmos. Dessa forma, uma categorização por comportamentos similares e não pelo motorista pode ser interessante para refinar melhor o processo de classificação.

4 | CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Neste trabalho, investigamos o problema de identificação de comportamento de condução de motoristas em um sistema de gestão de frotas. Essa tarefa tem por objetivo aprender a identificar automaticamente o modo como um determinado motorista dirige um certo veículo monitorado, com base nas informações coletadas por rastreadores. Os modelos de predição investigados utilizaram informações extraídas durante o processo de monitoramento dos veículos, sendo eles a quantidade dos eventos de aceleração brusca, freada brusca, curva acentuada, e excesso de velocidade; velocidade máxima e média do dia.

Dois experimentos foram realizados para avaliar a solução inicial desenvolvida, tratando o problema como uma tarefa de classificação binária e de uma única classe. Os resultados experimentais iniciais em uma base de dados real com 1.513 exemplos foram encorajadores. Baseado nos resultados obtidos, a melhor forma de abordar o problema de identificação de perfis do motorista foi tratá-lo como uma tarefa de classificação binária. O algoritmo de máquina de vetores de suporte com núcleo radial obteve 80,96% de acurácia na identificação de comportamento dos motoristas.

Com base nas limitações observadas e nas lições aprendidas, como trabalhos futuros, iremos realizar as seguintes linhas de investigação para a extensão e melhoria da solução proposta: (i) Uma maior investigação de possíveis dados que podem ser utilizados como atributos para criar os modelos de predição; (ii) Expansão da base de dados e uma melhor categorização dos exemplos com base no perfil de condução e não no motorista; (iii) Integração do módulo proposto ao sistema de gestão de frotas para validação da solução proposta em ambiente real; e (iv) Analisar o desempenho da aplicação de algoritmos de aprendizado de máquina profundo (Deep Learning).

REFERÊNCIAS

AHA, D.; KIBLER, D. **Instance-based learning algorithms**. Machine Learning, v. 6, p.37–66, 1991.

BREIMAN, L. **Random forests**. Machine Learning, v. 45, n^o. 1, p. 5–32, 2001.

BREUNIG, M.; KRIEGEL, H.; NG, R.; SANDER, J. **LOF: identifying density-based local outliers**. In International conference on Management of data. Dallas, Texas, USA, pp. 93-104, 2000.

CORTES, C.; VAPNIK, V. **Support-vector networks**. Machine Learning, v. 20, n^o 3, pp 273–297, 1995.

FACELI, K., LORENA, A. C., GAMA, J. CARVALHO, A. C. P. L. F. **Inteligência Artificial: Uma Abordagem de Aprendizagem de Máquina**. Rio de Janeiro: LTC, 2011.

JOHN, G. H.; LANGLEY, P. **Estimating continuous distributions in bayesian classifiers**. In: Eleventh Conference on Uncertainty in Artificial Intelligence. San Mateo: Morgan Kaufmann, p. 338–345, 1995.

LIU, F.; TING, K.; e ZHOU, Z. **Isolation forest**. In Eighth IEEE International Conference on Data Mining, pp.413-422, 2008.

ROUSSEEUW, P.; VAN DRIESSEN, K. **A fast algorithm for the minimum covariance determinant estimator**. Technometrics, v. 41, nº 3, pp. 212-223, 1999.

SCHOLKOPF, B.; WILLIAMSON, R.; SMOLA, A.; TAYLOR, J.; PLATT, J. **Support vector method for novelty detection**. In Neural Information Processing Systems, pp. 582–588, 2000.

SILVA, L. L. A., OLIVEIRA, P. A. **Métodos de depreciação de veículos nacionais de até mil cilindradas: Um estudo de caso**. Tekhne e Logos, Botucatu, SP, v.9, n.2, set., 2018.

STAIRS, R. M., REYNOLDS, G. W. **Princípios de Sistemas de Informação**. 3ª ed. São Paulo: Cengage Learning, 2015.

ÍNDICE REMISSIVO

A

Aeromodelo 123, 128

Algoritmo 19, 20, 48, 50, 53, 54, 55, 57, 58, 90, 138, 172, 173, 174, 180, 182

AngularJS 37, 38, 39, 43, 47

Aplicativos 38, 60, 61, 62, 63, 64, 65, 66, 67, 99, 101, 146, 174

Aprendizado de máquina 48, 50, 58

Aprendizagem 26, 27, 31, 33, 34, 35, 58, 70, 71, 72, 75, 77, 78, 79, 80, 81, 84, 87, 95, 96, 97, 98, 99, 100, 101, 102, 103, 104, 105, 137, 197, 198, 199, 200, 206

Arduino 28, 29, 30, 34, 124, 130, 131, 197, 198, 199, 201, 202, 203, 205, 206

Arquitetura 4, 6, 7, 11, 36, 37, 39, 40, 41, 42, 43, 46, 50, 51, 52, 60, 65, 66, 67, 76, 93, 97, 100, 130, 156, 184, 186, 187, 190, 191, 192, 194

Ataques cibernéticos 172, 174, 176, 180

Automação 1, 3, 5, 9, 13, 26, 28, 30, 33, 90

B

Banco de dados 4, 8, 10, 20, 36, 37, 40, 41, 42, 43, 44, 46, 51, 52, 54, 70, 74, 93, 156, 167, 174, 175, 176, 207

Bateria 76, 121, 124, 125, 126, 127, 129, 130

Blockchain 183, 184, 185, 186, 187, 188, 190, 191, 194, 195, 196

BPMN 4, 9, 13, 14, 151, 152, 153, 154, 155, 156, 158, 160, 161, 164, 165

C

Cálculo espectral 107, 109, 116

Ciência da informação 60, 61, 68, 207

Circuitos elétricos 26, 28, 30, 33, 203

Competência 78, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92, 93

Computação 1, 35, 36, 66, 70, 71, 72, 76, 81, 82, 83, 84, 85, 87, 88, 89, 90, 91, 92, 93, 94, 103, 105, 121, 137, 201, 207

Contagem de pedestre 133, 138, 139

D

Digital 1, 2, 60, 61, 62, 68, 69, 80, 104, 123, 129, 133, 134, 143, 144, 146, 173, 182, 187, 190, 193

Diretrizes curriculares 82, 83, 94

Disciplina 72, 75, 76, 77, 80, 82, 83, 85, 86, 87, 88, 89, 90, 91, 92, 93, 94, 95, 96, 102, 103, 104, 160

Dispersão criptográfica 172, 173

Drone 120, 121, 122, 123, 124, 125, 126, 127, 128, 129, 130, 131, 132

E

Educação 3, 4, 5, 6, 7, 14, 27, 28, 33, 34, 35, 82, 83, 96, 104, 105, 107, 173, 183, 194, 195, 198, 206, 207

Elicitação de requisitos 151, 152, 154, 156, 164, 165

Engenharia de software 70, 71, 72, 80, 81, 165

Ensino 5, 7, 26, 27, 28, 29, 34, 35, 70, 71, 72, 74, 75, 77, 78, 80, 84, 85, 87, 88, 91, 93, 94, 95, 96, 97, 98, 99, 104, 105, 106, 143, 160, 197, 198, 199, 200, 206

F

Formação 13, 25, 34, 72, 82, 83, 84, 86, 87, 91, 92, 94, 105, 119, 200

Framework 5, 8, 36, 37, 40, 41, 43, 46, 47, 156, 182

Front-end 37, 39, 40, 43

Full-stack 36, 37, 40, 43

I

Imagens médicas 15, 16, 17, 19, 25

Informação 1, 2, 3, 4, 5, 7, 8, 14, 15, 16, 20, 24, 25, 26, 27, 36, 45, 48, 49, 52, 59, 60, 61, 62, 63, 66, 67, 68, 69, 70, 75, 76, 77, 82, 84, 85, 89, 91, 95, 107, 120, 133, 134, 137, 143, 144, 146, 149, 150, 151, 160, 164, 166, 167, 168, 172, 183, 184, 185, 186, 188, 189, 190, 197, 204, 207

Inteligência artificial 48, 49, 58, 62

Internet 33, 47, 51, 62, 69, 75, 100, 101, 103, 144, 149, 150, 172, 182, 185, 195, 196

Islandtest 70, 71, 72, 74, 75, 76, 77, 78, 79, 80

J

Java 38, 51, 87, 156, 178, 191

Javascript 37, 38, 40, 41, 43, 44, 47, 70, 71, 74, 75, 173, 177, 181, 182, 190

Jogos 29, 31, 32, 33, 70, 71, 72, 79, 80, 81, 206

Jogos educativos 70, 72, 80

L

Laboratório 7, 29, 31, 33, 168

Linguagem R 107, 110

M

Manutenção 2, 5, 6, 10, 43, 63, 72, 109, 158

Message-Digest Algorithm 172, 173, 181

MeteorJS 36, 37, 40

ML-SAI 95, 96, 97, 99, 101, 102, 104, 105
Mobile learning 96, 98, 104
Modelo pedagógico 95, 96, 97, 99, 100, 101, 102, 104, 105
MongoDB 37, 40, 43, 44

N

node.js 37, 41, 47

O

Ontologia 1, 3, 4, 5, 6, 7, 9, 10, 11, 12, 13

P

Programação 19, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 37, 38, 39, 51, 82, 85, 86, 87, 88, 89, 90, 91, 92, 93, 95, 96, 99, 102, 103, 104, 105, 124, 137, 168, 173, 201, 203, 205, 207
Protótipo 54, 129, 203, 205
Python 52, 87, 88, 137, 173, 181

Q

Quadricóptero 126, 129, 130
QuantumGIS 107, 108

R

Raciocínio lógico 30, 33, 34
Rastreamento 51, 133, 134, 135, 137, 138, 140, 141
Reator nuclear 197, 199, 200, 202, 204, 205
Redes sociais 99, 143, 144, 145, 146, 147, 148, 149, 150, 192
Rede YOLO 135, 136, 137, 140
Requisitos 74, 77, 78, 79, 81, 101, 120, 122, 126, 134, 151, 152, 154, 155, 156, 157, 158, 159, 160, 161, 162, 163, 164, 165
Robótica 26, 27, 28, 29, 30, 32, 33, 34, 35, 90

S

Sala de aula invertida 95, 96, 98, 99, 100, 104, 105, 106
Scratch 26, 28, 29, 30, 31, 32, 33
Segurança 42, 48, 76, 107, 120, 122, 126, 134, 143, 144, 145, 146, 149, 150, 172, 173, 174, 181, 185, 186, 187, 190, 192, 194
Simulador 197, 199, 200, 201, 202, 203, 204, 205, 206
Sincronização de dados 36, 37, 44, 46

Sistema de informação ambiental 166

Sistemas de informação 1, 15, 26, 36, 48, 49, 59, 60, 69, 70, 75, 76, 77, 82, 84, 91, 95, 107, 120, 133, 143, 151, 166, 172, 183, 197, 207

Sustentabilidade 1, 2, 13

T

Técnica REMO 151, 152, 154, 155, 156, 158, 160, 161, 162, 163, 164, 165

Tecnologia 3, 4, 5, 7, 1, 2, 14, 27, 28, 29, 33, 49, 51, 60, 61, 62, 63, 66, 67, 68, 69, 77, 82, 98, 99, 100, 105, 107, 123, 129, 132, 137, 150, 151, 152, 162, 183, 184, 185, 186, 187, 188, 189, 190, 192, 194, 195, 196, 197, 199, 200, 201, 204, 207

Tecnologia da informação 2, 14, 60, 61, 62, 63, 68, 184, 188, 204, 207

Testes de software 70, 71, 72, 74, 75, 76, 77, 79, 80

V

VANT 121, 126, 128, 130, 131

Visão computacional 15, 24, 137

W

Web de dados 60, 61

X

XPDL 151, 152, 153, 154, 156, 157, 158, 161, 164, 165

Sistemas de Informação e Aplicações Computacionais

www.atenaeditora.com.br 

contato@atenaeditora.com.br 

[@atenaeditora](https://www.instagram.com/atenaeditora) 

www.facebook.com/atenaeditora.com.br 

Atena
Editora

Ano 2020

Sistemas de Informação e Aplicações Computacionais

www.atenaeditora.com.br 

contato@atenaeditora.com.br 

[@atenaeditora](https://www.instagram.com/atenaeditora) 

www.facebook.com/atenaeditora.com.br 

Atena
Editora

Ano 2020