

INTELIGÊNCIA COMPUTACIONAL:

Coletânea de Estudos de Casos




Jefferson Gustavo Martins
(Organizador)

Atena
Editora
Ano 2021

INTELIGÊNCIA COMPUTACIONAL:

Coletânea de Estudos de Casos



Jefferson Gustavo Martins
(Organizador)

Atena
Editora
Ano 2021

Editora Chefe

Profª Drª Antonella Carvalho de Oliveira

Assistentes Editoriais

Natalia Oliveira

Bruno Oliveira

Flávia Roberta Barão

Bibliotecária

Janaina Ramos

Projeto Gráfico e Diagramação

Natália Sandrini de Azevedo

Camila Alves de Cremo

Luiza Alves Batista

Maria Alice Pinheiro

Imagens da Capa

Shutterstock

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.



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. 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
Prof. Dr. Crisóstomo Lima do Nascimento – Universidade Federal Fluminense
Profª Drª Cristina Gaio – Universidade de Lisboa
Prof. Dr. Daniel Richard Sant’Ana – Universidade de Brasília
Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia
Profª Drª 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. Elói 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
Prof. Dr. Pablo Ricardo de Lima Falcão – Universidade de Pernambuco
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. Saulo Cerqueira de Aguiar Soares – Universidade Federal do Piauí
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande
Profª Drª 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
Profª Drª Carla Cristina Bauermann Brasil – Universidade Federal de Santa Maria
Prof. Dr. Cleberton Correia Santos – Universidade Federal da Grande Dourados
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. Jayme Augusto Peres – Universidade Estadual do Centro-Oeste
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
Profª Drª Daniela Reis Joaquim de Freitas – Universidade Federal do Piauí
Profª Drª 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
Profª Drª Elizabeth Cordeiro Fernandes – Faculdade Integrada Medicina
Profª Drª Eleuza Rodrigues Machado – Faculdade Anhanguera de Brasília
Profª Drª Elane Schwinden Prudêncio – Universidade Federal de Santa Catarina
Profª Drª Eysler Gonçalves Maia Brasil – Universidade da Integração Internacional da Lusofonia Afro-Brasileira
Prof. Dr. Ferlando Lima Santos – Universidade Federal do Recôncavo da Bahia
Profª Drª Fernanda Miguel de Andrade – Universidade Federal de Pernambuco
Prof. Dr. Fernando Mendes – Instituto Politécnico de Coimbra – Escola Superior de Saúde de Coimbra
Profª Drª 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
Profª Drª 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
Profª Drª Magnólia de Araújo Campos – Universidade Federal de Campina Grande
Prof. Dr. Marcus Fernando da Silva Praxedes – Universidade Federal do Recôncavo da Bahia
Profª Drª Maria Tatiane Gonçalves Sá – Universidade do Estado do Pará
Profª Drª Mylena Andréa Oliveira Torres – Universidade Ceuma
Profª Drª Natiéli Piovesan – Instituto Federacl 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
Profª Drª Regiane Luz Carvalho – Centro Universitário das Faculdades Associadas de Ensino
Profª Drª Renata Mendes de Freitas – Universidade Federal de Juiz de Fora
Profª Drª Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande
Profª Drª 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
Profª Drª Ana Grasielle Dionísio Corrêa – Universidade Presbiteriana Mackenzie
Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás
Profª Drª 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. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Profª Drª 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 Gonçalves 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 Miraniide 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. 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
Profª Ma. Adriana Regina Vettorazzi Schmitt – Instituto Federal de Santa Catarina
Prof. Dr. Alex Luis dos Santos – Universidade Federal de Minas Gerais
Prof. Me. Alexsandro Teixeira Ribeiro – Centro Universitário Internacional
Profª Ma. Aline Ferreira Antunes – Universidade Federal de Goiás
Profª Drª Amanda Vasconcelos Guimarães – Universidade Federal de Lavras
Prof. Me. André Flávio Gonçalves Silva – Universidade Federal do Maranhão
Profª Ma. Andréa Cristina Marques de Araújo – Universidade Fernando Pessoa
Profª Drª Andrezza Lopes – Instituto de Pesquisa e Desenvolvimento Acadêmico
Profª Drª Andrezza Miguel da Silva – Faculdade da Amazônia
Profª Ma. Anelisa Mota Gregoleti – Universidade Estadual de Maringá
Profª Ma. Anne Karynne da Silva Barbosa – Universidade Federal do Maranhão
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. Me. Carlos Augusto Zilli – Instituto Federal de Santa Catarina
Prof. Me. Christopher Smith Bignardi Neves – Universidade Federal do Paraná
Profª Drª Cláudia de Araújo Marques – Faculdade de Música do Espírito Santo
Profª Drª Cláudia Taís Siqueira Cagliari – Centro Universitário Dinâmica das Cataratas
Prof. Me. Clécio Danilo Dias da Silva – Universidade Federal do Rio Grande do Norte
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. Edson Ribeiro de Britto de Almeida Junior – Universidade Estadual de Maringá
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. Euvaldo de Sousa Costa Junior – Prefeitura Municipal de São João do Piauí
Prof. Dr. Everaldo dos Santos Mendes – Instituto Edith Theresa Hedwing Stein
Prof. Me. Ezequiel Martins Ferreira – Universidade Federal de Goiás
Profª Ma. Fabiana Coelho Couto Rocha Corrêa – Centro Universitário Estácio Juiz de Fora
Prof. Me. Fabiano Eloy Atilio Batista – Universidade Federal de Viçosa
Prof. Me. Felipe da Costa Negrão – Universidade Federal do Amazonas
Prof. Me. Francisco Odécio Sales – Instituto Federal do Ceará
Prof. Me. Francisco Sérgio Lopes Vasconcelos Filho – Universidade Federal do Cariri
Profª Drª Germana Ponce de Leon Ramírez – Centro Universitário Adventista de São Paulo
Prof. Me. Gevair Campos – Instituto Mineiro de Agropecuária
Prof. Me. Givanildo de Oliveira Santos – Secretaria da Educação de Goiás
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 Fenomenología & Subjetividade/UFPR
Prof. Me. Leonardo Tullio – Universidade Estadual de Ponta Grossa
Profª Ma. Lilian Coelho de Freitas – Instituto Federal do Pará
Profª Ma. Lilian de Souza – Faculdade de Tecnologia de Itu
Profª Ma. Liliani Aparecida Sereno Fontes de Medeiros – Consórcio CEDERJ
Profª Drª Lúvia do Carmo Silva – Universidade Federal de Goiás
Prof. Dr. Lucio Marques Vieira Souza – Secretaria de Estado da Educação, do Esporte e da Cultura de Sergipe
Prof. Dr. Luan Vinicius Bernardelli – Universidade Estadual do Paraná
Profª Ma. Luana Ferreira dos Santos – Universidade Estadual de Santa Cruz
Profª Ma. Luana Vieira Toledo – Universidade Federal de Viçosa
Prof. Me. Luis Henrique Almeida Castro – Universidade Federal da Grande Dourados
Prof. Me. Luiz Renato da Silva Rocha – Faculdade de Música do Espírito Santo
Profª Ma. Luma Sarai de Oliveira – Universidade Estadual de Campinas
Prof. Dr. Michel da Costa – Universidade Metropolitana de Santos

Prof. Me. Marcelo da Fonseca Ferreira da Silva – Governo do Estado do Espírito Santo
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. Dr. Pedro Henrique Abreu Moura – Empresa de Pesquisa Agropecuária de Minas Gerais
Prof. Me. Pedro Panhoca da Silva – Universidade Presbiteriana Mackenzie
Profª Drª Poliana Arruda Fajardo – Universidade Federal de São Carlos
Prof. Me. Rafael Cunha Ferro – Universidade Anhembi Morumbi
Prof. Me. Ricardo Sérgio da Silva – Universidade Federal de Pernambuco
Prof. Me. Renan Monteiro do Nascimento – Universidade de Brasília
Prof. Me. Renato Faria da Gama – Instituto Gama – Medicina Personalizada e Integrativa
Profª Ma. Renata Luciane Polsaque Young Blood – UniSecal
Prof. Me. Robson Lucas Soares da Silva – Universidade Federal da Paraíba
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
Profª Ma. Taiane Aparecida Ribeiro Nepomoceno – Universidade Estadual do Oeste do Paraná
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

Inteligência computacional: coletânea de estudos de casos

Bibliotecária: Janaina Ramos
Diagramação: Natália Sandrini de Azevedo
Correção: Mariane Aparecida Freitas
Edição de Arte: Luiza Alves Batista
Revisão: Os Autores
Organizador: Jefferson Gustavo Martins

Dados Internacionais de Catalogação na Publicação (CIP)

C569 Inteligência computacional: coletânea de estudos de casos /
Organizador Jefferson Gustavo Martins. – Ponta Grossa
- PR: Atena, 2021.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN 978-65-5983-092-3

DOI 10.22533/at.ed.923210521

1. Inteligência Computacional. 2. Inteligência Artificial.
3. Aprendizagem de Máquinas. 4. Reconhecimento de
Padrões. 5. Visão Computacional. I. Martins, Jefferson
Gustavo (Organizador). II. Título.

CDD 006.37

Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166

Atena Editora

Ponta Grossa – Paraná – Brasil

Telefone: +55 (42) 3323-5493

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.

DEDICATÓRIA

À
Tatiany Mottin Dartora
e
Laura Dartora Martins

PREFÁCIO

Os termos Inteligência Computacional, Inteligência Artificial, Aprendizagem de Máquinas, Reconhecimento de Padrões, Visão Computacional, além de outros, são geralmente utilizados como sinônimos. Embora existam diferenças em suas definições ou ênfases, estas não são o foco deste livro ou deste prefácio. O conjunto de trabalhos que compõem este livro utiliza alguns dos termos citados, sendo que no presente texto optamos pelo termo Inteligência Computacional, o qual também faz parte do título da coletânea.

Os termos anteriores muitas vezes nos remetem aos filmes de ficção científica. Em seus enredos, máquinas substituem seres humanos ou há batalhas em que ambos lutam entre si na tentativa de garantir uma dominância de uma parte em relação à outra ou simplesmente a própria sobrevivência. À medida que os estudos avançam e novas perspectivas surgem, algumas especulações como as que acabamos de citar são descartadas.

Neste livro apresentamos alguns estudos desenvolvidos em colaboração com docentes, técnicos e discentes da Universidade Tecnológica Federal do Paraná (UTFPR), Câmpus Toledo. Tais estudos estão relacionados a atividades de pesquisa decorrentes do desenvolvimento de trabalhos de conclusão de curso e iniciação científica. Eles compreendem três contextos de aplicação da Inteligência Computacional como área interdisciplinar que auxilia ou substitui o especialista humano na execução de suas tarefas.

O primeiro eixo é formado por artigos que trabalham com a identificação da composição de concretos, enquanto o segundo contempla artigos com foco na morfologia da corrosão em armaduras. Ambos os eixos estão relacionados a problemas inerentes à Engenharia Civil, mas cada um dos estudos utiliza abordagens e ferramentais distintos. Finalizando o livro, o terceiro eixo tem foco na área de saúde, mais especificamente no diagnóstico de câncer de mama usando imagens.

Este livro se destina a docentes, técnicos e discentes que tenham interesse na área de Inteligência Computacional. Modestamente, este serve como introdução a esta área de conhecimento e a algumas ferramentas atualmente disponíveis, mas também apresenta alguns apontamentos para trabalhos futuros e necessidades relacionados aos problemas abordados e aos ferramentais utilizados ou que podem servir como alternativa.

SUMÁRIO

CAPÍTULO 1..... 1

IDENTIFICAÇÃO DA COMPOSIÇÃO DE CONCRETO POR MEIO DE RECONHECIMENTO DE PADRÕES

Jefferson Gustavo Martins
Alessandra Iolanda Pacheco dos Santos
Eduarda Simonis Gavião
Sara Rico Bocato Marin
Marcos Vinícius Schlichting
Wilson Leobet
Fabio Alexandre Spanhol

DOI 10.22533/at.ed.9232105211

CAPÍTULO 2..... 12

IDENTIFICAÇÃO DE TRAÇOS DE CONCRETO POR MEIO DE DESCRITORES BASEADOS EM PONTOS DE ATENÇÃO

Jefferson Gustavo Martins
Alessandra Iolanda Pacheco dos Santos
Eduarda Simonis Gavião
Sara Rico Bocato Marin
Marcos Vinícius Schlichting
Wilson Leobet
Fabio Alexandre Spanhol

DOI 10.22533/at.ed.9232105212

CAPÍTULO 3..... 25

IDENTIFICAÇÃO DE DETERIORAÇÃO DE BARRAS DE AÇO POR MEIO DE IMAGENS DO RECOBRIMENTO DE CONCRETO

Jefferson Gustavo Martins
Alessandra Iolanda Pacheco dos Santos
Eduarda Simonis Gavião
Guilherme Dias Almanza
Kelly Chapla
Marcos Vinícius Schlichting
Wilson Leobet
Fabio Alexandre Spanhol

DOI 10.22533/at.ed.9232105213

CAPÍTULO 4..... 40

VISÃO COMPUTACIONAL APLICADA NA IDENTIFICAÇÃO DOS NÍVEIS DE DETERIORAÇÃO DE BARRAS DE AÇO POR MEIO DE IMAGENS

Jefferson Gustavo Martins
Alessandra Iolanda Pacheco dos Santos
Eduarda Simonis Gavião
Guilherme Dias Almanza

Kelly Chapla
Marcos Vinícius Schlichting
Wilson Leobet
Fabio Alexandre Spanhol

DOI 10.22533/at.ed.9232105214

CAPÍTULO 5..... 52

**CLASSIFICAÇÃO DE IMAGENS HISTOPATOLÓGICAS DE CÂNCER DE MAMA USANDO
PEQUENAS SUBIMAGENS SELECIONADAS**

Fabio Alexandre Spanhol
Jefferson Gustavo Martins
Henrique Frederico Trentini
Gabriel Fernando Ferrazoli

DOI 10.22533/at.ed.9232105215

SOBRE O ORGANIZADOR..... 61

IDENTIFICAÇÃO DA COMPOSIÇÃO DE CONCRETO POR MEIO DE RECONHECIMENTO DE PADRÕES

Data de aceite: 01/03/2021

Jefferson Gustavo Martins

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2102993901875277>

Alessandra Iolanda Pacheco dos Santos

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7255176749334236>

Eduarda Simonis Gavião

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7977085762352521>

Sara Rico Bocato Marin

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/9318173807574063>

Marcos Vinícius Schlichting

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/1152652374544629>

Wilson Leobet

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2563896946139465>

Fabio Alexandre Spanhol

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/4381300863323095>

RESUMO: Sistemas computacionais que trabalhem com reconhecimento de padrões têm sido aplicados a problemas para auxiliar especialistas humanos. Tais problemas, assim como a identificação de traços de concreto, são caracterizados como processos repetitivos, monótonos e demorados, demandam altos níveis de experiência e produzem resultados sujeitos a fatores físicos e subjetivos. Este artigo apresenta uma proposta para identificar diferentes composições de concreto por meio de visão computacional. Para isso, foram empregados ferramentais amplamente conhecidos na área de aprendizagem de máquina. As melhores taxas de acerto compreendem 84,7% usando o descritor GLCM.

PALAVRAS-CHAVE: Construção civil. Defesa civil. Segurança pública. Automação.

IDENTIFICATION OF CONCRETE COMPOSITION THROUGH PATTERN RECOGNITION

ABSTRACT: Computer systems applied to pattern recognition have been used to problems to assist human experts. Such problems, as well as the identification of concrete traces, are characterized as repetitive, monotonous and time-consuming processes, requiring high levels of experience and producing results influenced by physical and subjective factors. This paper presents a proposal to identify different concrete traces through computer vision. For this, tools widely known in the machine learning area were employed. The best hit rates comprise 84.7% using the GLCM descriptor.

KEYWORDS: Construction. Civil defense. Public security. Automation.

1 | INTRODUÇÃO

Os traços de concreto são caracterizados por seus componentes e as respectivas quantidades. Tal definição é uma característica extremamente importante em qualquer obra e muda de acordo com a finalidade de aplicação: lajes, contrapisos, muros, fundações, calçadas, vigas, etc. Além disso, a proporção e a origem dos materiais exercem influência nas características finais do traço, dentre as quais tem-se resistência, durabilidade e trabalhabilidade. Dentre os materiais comumente utilizados, tem-se cimento, areia, brita e água, mas concretos com características especiais podem ser obtidos com o acréscimo de aditivos, isopor, pigmentos, fibras ou outros tipos de adições (ABNT, 2015; MALTA, 2012; MONTEIRO, 2010).

A principal função dos agregados é aumentar o volume final e torná-lo mais econômico. Suas propriedades têm influências da formação geológica local, pois estes são extraídas de jazidas próximas às localidades de dosagem e edificação. O conhecimento das características individuais dos elementos, e também de sua combinação, é essencial para garantir certas características fundamentais ao concreto e a segurança da estrutura. Além disso, materiais com diferentes granularidades podem ser combinados dependendo da finalidade e produzem diferentes características texturais (ABNT, 2015; BAUER, 1994; MALTA, 2012; MEHTA; MONTEIRO, 2008; MONTEIRO, 2010).

A água deve ser adicionada em quantidade suficiente para envolver os grãos e promover a hidratação do cimento, além de atender os requisitos da ABNT NBR 15900-1, a qual também contempla exigências de utilização da água sob a forma de gelo. Sua função é ativar a reação química que transforma o cimento em uma pasta aglomerante que criará um bloco único com a areia e a brita (agregados). Se em excesso, ter-se-á uma pasta mais porosa e melhores níveis trabalhabilidade. Porém, também piores níveis de resistência e aderência entre a pasta e o agregado devido à exsudação. Para a definição de tal proporção é necessário identificar o teor de umidade dos agregados, pois estes podem transportar diferentes quantidades de água para o concreto e ocasionar o decréscimo de sua resistência mecânica (ABNT, 2009; ABNT, 2015; MALTA, 2012; MONTEIRO, 2010).

Além dos custos envolvidos devido a degradação destas estruturas, o risco em termos de colapsos estruturais merece atenção. Nos últimos anos, têm sido recorrentes os casos de colapsos de estruturas, dentre os quais tem-se o colapso parcial de um viaduto em Brasília no ano de 2018 (VIADUTO, 2018), a interdição do acesso à Rodovia Presidente Dutra em São Paulo no ano de 2019 (PREFEITURA, 2019) e o desabamento de prédios na comunidade de Muzema, na Zona Oeste do Rio, em 2019 (MAIA; GARCIA, 2019). Portanto, estudos pertinentes que auxiliem a fiscalização e a prevenção destes acontecimentos são necessários com vistas a garantir estruturas mais seguras e duráveis e manutenções preventivas.

Além do exposto, outra importante característica deste cenário compreende o fato de que as inspeções para avaliar a composição do concreto e também se este mantém suas propriedades são realizadas visualmente por especialistas humanos. Tais inspeções demandam altos níveis de experiência por ser um fator decisivo para uma correta avaliação. Dentre as possíveis ferramentas a serem empregadas, tem-se filmadoras, máquinas fotográficas, lupas e binóculos (ABNT, 2014; SCHVAICKARDT; MATTOS, 2018).

A Figura 1 ilustra o problema abordado no projeto e o grau de dificuldade a ele inerente. Suas imagens foram obtidas a partir de dois diferentes traços (cimento : areia : brita : água), com as proporções (1 : 1,49 : 2,88 : 0,48) e (1 : 1,49 : 2,70 : 0,48). Neste exemplo, pode-se nitidamente observar a variação na quantidade de britas entre os concretos.




Figura 1: Composições de concreto (cimento : areia : brita : água): (a) 1 : 1,49 : 2,88 : 0,48; (b) 1 : 1,49 : 2,70 : 0,48.

Fonte: Autoria própria (2020).

Diante do exposto, esta artigo apresenta uma alternativa para auxiliar as inspeções realizadas por especialistas humanos a identificar a composição do concreto. Esta propicia vantagens relativas à rapidez e precisão quando comparado à avaliação realizada manualmente. A redução de fatores físicos e subjetivos inerentes ao ser humano também reduz o número de etapas executadas manualmente e sua influência nos resultados finais. Tal influência compreende questões como subjetividade dos especialistas humanos e características do processo (repetitivo, monótono e demorado), além de requerer alto grau de concentração. Este conjunto de exigências sobrecarrega o profissional que realiza a inspeção e o leva a possíveis distrações e baixas taxas de acerto (CONNERS *et al.*, 1997; PHAM; ALCOCK, 1997; RADOVAN *et al.*, 2001).

2 | MATERIAIS E MÉTODOS

Sistemas computacionais que trabalhem com reconhecimento de padrões geralmente apresentam as seguintes etapas: aquisição da base de dados, pré-processamento, segmentação, extração de características e classificação. Cada uma constitui um diferente contexto, possui diferentes níveis de complexidade e envolve conhecimentos específicos e próprios, além daqueles inerentes ao domínio da aplicação.

Diante da importância do tema, um amplo conjunto de trabalhos têm sido desenvolvido, inclusive a partir da base de imagens empregada neste estudo. Tal fato implica na execução das etapas anteriormente apresentadas utilizando diferentes ferramentas, mas ainda considerando o foco de cada uma delas em sua essência.

Na primeira etapa foi obtida a base de dados, ou seja, o conjunto de imagens, padrões e etc. Inicialmente foram preparados os corpos de prova de concreto sob a forma cilíndrica e com medidas de 10 cm de diâmetro e 20 cm de altura. Foram utilizadas 2 corpos de prova de concreto para cada um dos diferentes traços analisados. Tal escolha é consequência do fato (e se adequa a ele) de que 2 (dois) corpos de prova são construídos com amostras de cada carga de concreto utilizada nas construções.

Os traços utilizados para a construção dos corpos de prova consideraram a proporção 1: 1,41: 2,01: 0,49 utilizando cimento do tipo Portland CII, areia média, brita zero e água potável disponibilizada pela companhia de saneamento. Para avaliar a variação da granularidade do agregado brita, foi utilizada uma variação do traço padrão com a troca da brita zero pela brita um, gerando o traço 1: 1,49: 2,60: 0,49. Nesta variação de traço, tem-se um uso maior dos agregados (areia e brita) devido a um maior volume e superfície de cada unidade do agregado brita, sendo necessária menor quantidade de cimento para a construção de peças com um mesmo volume final (Figura 1).

Na sequência, foram realizados cortes transversais a cerca de 5 mm da base e outro 5 mm do topo do corpo de prova. Tais cortes estão ilustrados na Figura 2(a) e seu objetivo de ambos os cortes é eliminar a camada superficial e expor a caracterização da composição real do concreto, tal como apresenta a Figura 2(b). A partir disto, foram realizados outros 8 cortes transversais em cada corpo de prova de concreto. Considerando que as lâminas de corte têm aproximadamente 2 mm, sendo obtido um total de 9 amostras distintas para cada corpo de prova. Considerando as duas faces de cada amostra, chegou-se a um total de 18 imagens para cada corpo de prova. Ao todo, foram utilizadas 72 imagens para construção dos modelos de reconhecimento dos traços de concreto.

O pré-processamento aplica operações para realçar as características importantes no processo de diferenciação das classes existentes no problema. Nesta etapa, basicamente foi utilizada a biblioteca OpenCV para converter a base toda em escala de cinza, tal como ilustra as imagens da Figura 2(b-c).

A segmentação compreende a próxima etapa do processo e busca separar apenas a região de interesse da imagem original e da qual depende o sucesso de um modelo de identificação ou de classificação. O processo de segmentação se refere ao método de “fragmentar” uma imagem em múltiplas regiões, com o objetivo de simplificar ou mudar sua representação, a fim de facilitar sua análise. Nesta etapa, buscou-se por uma imagem que estivesse toda formada pela área de interesse, tal como ilustrado na Figura 2(f). As imagens da Figura 2(c-d) representam a aplicação da técnica de limiarização para destacar o objeto na imagem. Na sequência, aplicou-se o algoritmo de detecção de bordas Canny (BUENO, 2020) para ressaltar os contornos das bordas dos objetos e a função *HoughCircles* da biblioteca OpenCV para identificar objetos semelhantes a circunferências na imagem. Ao final, após selecionar a maior circunferência identificada com a definição do traço de concreto e calcular seu raio, Figura 2(e), definiu-se e salvou-se o retângulo circunscrito na mesma, culminando na Figura 2(f).

Para a etapa de Extração de Características, busca-se representar a imagem por meio de um vetor numérico de medidas. Nesta etapa foram utilizados os descritores GLCM (*Gray Level Co-occurrence Matrix*) e LBP (*Local Binary Pattern*, Padrão Binário Local)

apresentados nas seções seguintes.

Por fim, na etapa de classificação foi utilizada o algoritmo kNN (*k-Nearest Neighbors*, k-vizinhos mais próximos), o qual utiliza o conjunto de treinamento como referências durante o processo de predição de uma classe para uma instância do conjunto de testes. Diferentes tamanhos de vizinhanças foram testadas.




Figura 2: Ilustração do processo de reconhecimento de padrões: (a) corpo de prova de concreto; (b) corte do corpo de prova; (c) pré-processamento com conversão para níveis de cinza; (d-e) segmentação.

Fonte: Autoria própria (2020).

Para a definição dos conjuntos de treinamento e teste, dividiu-se a base de imagens em 3 partes (folds), os quais mantinham a representatividade das classes pertencentes ao problema em questão. Foi empregada validação cruzada com 3 execuções, sendo que em que execução, um parte era usada como conjunto de teste e as outras duas eram utilizadas como conjunto de treinamento. Os resultados finais são expressos pela acurácia média (acertos do classificador) e desvio padrão (dp) das taxas de classificações corretas das três execuções.

2.1 Matriz de Coocorrência de Níveis de Cinza

Matriz de Coocorrência de Níveis de Cinza (*Gray Level Co-occurrence Matrix - GLCM*) é um método estatístico proposto por Haralick e se caracteriza como um dos mais

conhecidos métodos que exploram repetições de ocorrências de padrões. Tais padrões são caracterizados pela dependência entre os níveis de cinza dos *pixels* das imagens e por sua distribuição espacial. As repetições dos padrões provêm medidas quanto a propriedades como rugosidade, suavidade e regularidade sob diferentes perspectivas com a variação dos parâmetros direção e distância (HARALICK, 1979).

Formalmente, Haralick fundamenta GLCM pela seguinte definição: dada uma imagem I com dimensões $N_r \times N_c$, tal que $L_r = [1, N_r]$ e $L_c = [1, N_c]$ representam os possíveis valores para linhas e colunas, respectivamente; e $L = [1, N_g]$ o conjunto de N_g níveis de cinza quantizados de I . A imagem I pode ser representada como uma função que associa algum nível de cinza de G a uma célula ou par de coordenadas de $L_r \times L_c$. Ou seja, $I : L_r \times L_c \rightarrow G$ (HARALICK, 1979; PEDRINI; SCHWARTZ, 2008).

A partir disto, Haralick define o uso de uma matriz $N_g \times N_g$ para representar a frequência P_{ij} , tal que um pixel p_i possua nível de cinza n_i e um pixel vizinho a p_i (p_j - a uma distância d e um ângulo α) possua nível de cinza n_j . Embora Haralick tenha estabelecido ângulos com intervalos de 45 graus, os cálculos podem assumir outros ângulos (HARALICK, 1979; TOU, 2007).

Seguindo as definições anteriores, as GLCM da Figura 3 (b) foi gerada para a imagem da Figura 3(a) com $N_g = 5$, distância $d = 1$ e direção 0 grau, respectivamente. Dentre as possíveis medidas extraídas de GLCM, tem-se as apresentadas por Haralick: Segundo Momento Angular, Contraste (Soma do Quadrado da Variância), Correlação, Variância (Soma dos Quadrados), Momento de Diferença Inverso (Homogeneidade), Soma da Média, Soma da Variância, Soma da Entropia, Entropia, Diferença da Variância, Diferença da Entropia, Informação de Medidas de Correlação 1, Informação de Medidas de Correlação 2 e Coeficiente de Correlação Máxima (HARALICK, 1979).

Embora a proposta inicial tenha definido 14 elementos, diferentes trabalhos consideram diferentes subconjuntos destes e afirmam haver correlações ou redundâncias entre as informações provenientes de alguns deles. Assim, aqui empregou-se apenas seis das características propostas por Haralick (1979): energia, contraste, entropia, homogeneidade, probabilidade máxima e momento de terceira ordem. Tais características têm suas equações apresentadas a seguir. N_g é o número de diferentes níveis de cinza da imagem; i e j são os níveis de cinza e servem como índices da GLCM; e $P(i,j)$ é a probabilidade de co-ocorrência do par (i,j) de níveis de cinza.




Figura 3: Geração de GLCMs.

Fonte: Martins (2014).

$$\begin{aligned}
\text{Energia} &= \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \{P(i,j)\}^2} \\
\text{Contraste} &= \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} |i-j|^2 P(i,j)} \\
\text{Entropia} &= - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i,j) \log(P(i,j)) \\
\text{Homogeneidade} &= \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{P(i,j)}{1 + |i-j|^2} \\
\text{Probabilidade Máxima} &= \max_{i=0}^{N_g-1} P(i,j) \\
\text{Momento de Terceira Ordem} &= \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} |i-j|^3 P(i,j)}
\end{aligned}$$

2.2 Padrão Binário Local

Classificado como um método estrutural, o Padrão Binário Local (*Local Binary Pattern* – LBP) foi introduzido, em 1996, como uma medida complementar para contraste local de uma imagem em níveis de cinza, sendo definido como invariante a mudanças monotônicas dos níveis de cinza. Em sua versão original, LBP considera uma vizinhança-8 e distância um para o pixel central (x_c, y_c) de uma máscara com dimensões 3 x 3, tal como ilustra a Figura 4 (a) (MÄENPÄÄ *et. al.*, 2000).

Cada ponto da imagem é tomado como sendo o ponto central (x_c, y_c), cujo valor é utilizado como limiar na comparação com o conteúdo de cada um de seus vizinhos (x_i, y_i). Como ilustrado na Figura 4 (b), desta comparação gera-se uma cadeia de zeros e uns, pois cada vizinho assume o valor um se seu conteúdo for maior que o do ponto central (x_c, y_c) e zero caso contrário. A organização dessa cadeia considera a posição relativa j de cada um dos vizinhos, iniciando do canto superior-esquerdo com valor zero e circundando o ponto central no sentido anti-horário, tal como apresentado na Figura 4 (c). Ao ser tomada como uma representação em base dois e convertida para a base dez, Figura 4 (d-e), tem-se o padrão que representa a região sobreposta pela máscara (MÄENPÄÄ *et. al.*, 2000).

Após gerar os padrões para todos os pontos da imagem, as frequências destes padrões são contabilizadas por meio de um histograma com um total de 2^P padrões para P vizinhos. A consideração de $P = 8$, Figura 4 (a) gera um total de 256 padrões de transição de bits, Figura 4 (b). Dentre estes padrões, apenas 58 atendem a definição de uniformidade, isto é, a ocorrência de, no máximo, duas transições do valor zero para um e vice-versa. Todos os demais padrões são contabilizados juntos, levando a um total de 59 valores para

o descritor denominado LBP uniforme (LBP^{u2}).

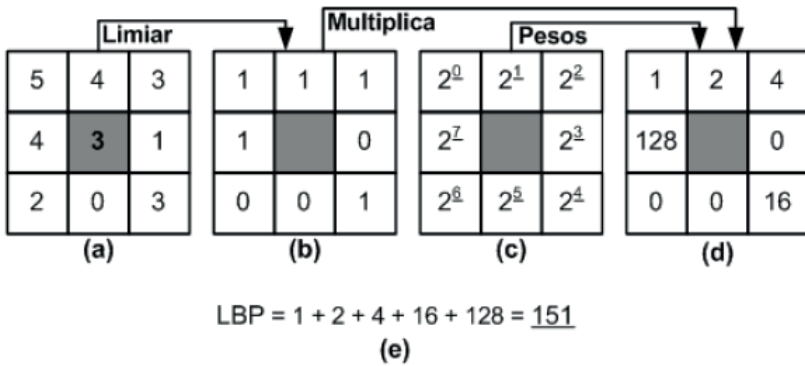


Figura 4: Cálculo do padrão LBP.

Fonte: Martins (2014, p. 34).

3 I RESULTADOS E DISCUSSÃO

Para cada etapa do processo de reconhecimento de padrões foram testados diferentes parâmetros, muitos dos quais já identificados anteriormente na seção de materiais e métodos. Para GLCM, foram testadas diferentes distâncias, enquanto que para LBP foram testados diferentes raios e números de vizinhos. A Figura 5 apresenta a variação das acurácias alcançadas com diferentes tamanhos de vizinhanças para o algoritmo k-NN, considerando as melhores configurações relativas a LBP e GLCM.

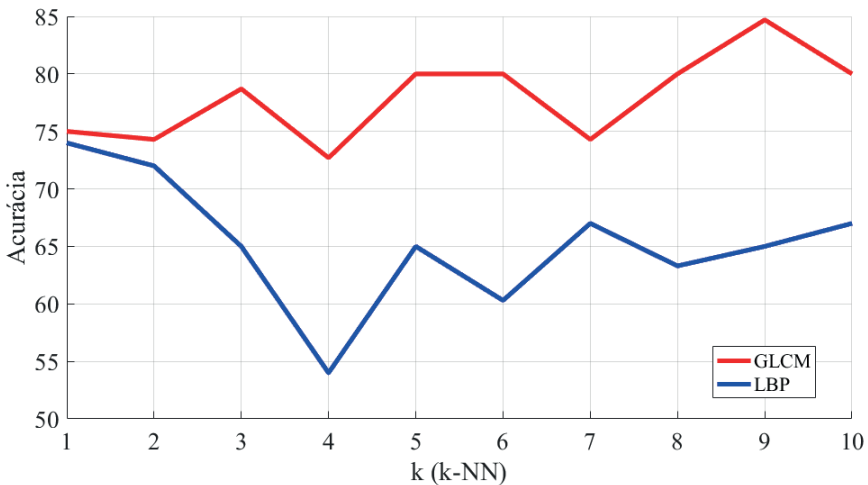


Figura 5: Gráfico com a evolução da acurácia em decorrência da variação da vizinhança utilizada no k-NN.

Fonte: Autoria própria (2020).

Os melhores resultados gerais alcançados foram 74,0% (dp = 0,01) para LBP, com raio igual a 1 e k (k-NN) igual a 6. Para GLCM, obteve-se 84,7% (dp = 0,04), com distância 5 e k (k-NN) igual a 9. Tais resultados se mostraram bem interessantes, principalmente para o problema em questão, o qual envolve segurança e vidas humanas, além dos altos valores monetários envolvidos na construção e também manutenção das edificações. Além do exposto, tem-se o fato de que o descritor GLCM representa uma complexidade computacional bem menor para sua extração.

4 | CONSIDERAÇÕES FINAIS

Este trabalho avaliou a aplicação de classificadores construídos a partir dos descritores GLCM e LBP ao problema de reconhecimento de traços de concreto por meio de imagens. Os resultados obtidos se mostraram bastante promissores, sendo que as melhores taxas de reconhecimento foram 84,7% (dp = 0,04), com k (k-NN) igual a 9 para o descritor GLCM.

Na sequência busca-se pela ampliação da base de imagens, com maior variedade de traços. A ampliação da base representará um desafio maior e, por isso, buscar-se-á por novos descritores e algoritmos de seleção e combinação de classificadores na tentativa de melhorar os resultados obtidos. Diante deste problema mais desafiador, tem-se a concatenação dos vetores de características como alternativa à realizada neste trabalho, bem como a construção de modelos independentes a partir dos mesmos vetores de características, com a seleção e combinação de alguns dos modelos previamente construídos. Um estudo comparativo de ambas as abordagens foi apresentada por Martins, Oliveira e Sabourin (2012), o qual demonstrou a superioridade desta nova abordagem.

REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 15900-1**: Água para amassamento do concreto Parte 1: Requisitos. Rio de Janeiro, 2009.

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 6118**: Projeto de estruturas de concreto – Procedimento. Rio de Janeiro, 2014.

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 12655**: Concreto de cimento Portland – Preparo, controle, recebimento e aceitação – Procedimento. Rio de Janeiro, 2015.

BAUER, L. A. F. **Materiais de Construção**. 5.ed. Vol 1. Rio de Janeiro: LTC – Livros técnicos e Científicos Editora S.A., 1994.

BUENO, M. L. **Deteção de Bordas através de Algoritmo Canny**. Disponível em: <http://www.inf.ufsc.br/~aldo.vw/visao/2000/Bordas/index.htm>. Acesso em: 20 jan. 2020.

CONNERS, R. W.; KLINE, D. E.; ARAMAN, P. A.; DRAYER, T. H. **Machine vision technology for the forest products industry**. Computer, v. 30, n. 7, p. 43-48, 1997.

HARALICK, R.M. **Statistical and structural approaches to texture**. v. 67, n. 5, p. 786-804, 1979.

MÄENPÄÄ, T.; OJALA, T. PIETIKÄINEN, M.; SORIANO, M. **Robust texture classification by subsets of local binary patterns**. 15th International Conference on Pattern Recognition, p. 947-950, 2000.

MAIA, D. e GARCIA, D. **Dois prédios desabam na zona oeste do Rio de Janeiro**. Folha de São Paulo, São Paulo - SP, 12 de abr. de 2019. Disponível em: <https://www1.folha.uol.com.br/cotidiano/2019/04/dois-predios-desabam-na-zona-oeste-do-rio-de-janeiro.shtml#:~:text=%E2%80%8B%20desabamento%20de%20dois,adolescente%20est%C3%A3o%20entre%20as%20v%C3%ADtimas.&text=%E2%80%8B%20pr%C3%A9dios%20ca%C3%ADram%20por%20volta%20das%206h30>. Acesso em: 20 de jun. de 2019.

MALTA, J. O. **Dosagem de concretos produzidos com agregado miúdo reciclado de resíduo de construção e demolição**. Dissertação de Mestrado em Engenharia Ambiental Urbana. Escola Politécnica (EPUFBA). Universidade Federal da Bahia (UFBA). Salvador, 2012.

MARTINS, J.G.; OLIVEIRA, L.E.S.; SABOURIN, R. **Combining textural descriptors for forest species recognition**. In IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society, p. 1483-1488, 2012.

MARTINS, J.G. **Identificação de Espécies Florestais utilizando Seleção Dinâmica de Classificadores no Espaço de Dissimilaridade**. Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba-PR, 2014.

MEHTA, P.K.; MONTEIRO, P. **Concreto**: Microestrutura, Propriedades e Materiais. 3.ed. São Paulo: IBRACON, 2008.

MONTEIRO, A. C. N. **Concreto Poroso**: dosagem e desempenho. Monografia de Graduação em Engenharia Civil. Universidade Federal de Goiás (UFGO). Goiania, 2010.

PEDRINI, H.; SCHWARTZ, W.R. **Análise de Imagens Digitais**: princípios, algoritmos e aplicações. São Paulo: Thomson Learning, 2008.

PHAM, D. T.; ALCOCK, R. J. **Automated visual inspection of birch wood boards**. IEE Colloquium on Artificial Intelligence in Manufacturing, p. 1-4, 1997.

PREFEITURA de SP interdita ponte que leva à Dutra pela Marginal Tietê. G1 SP, São Paulo - SP, 23 de jan. de 2019. Disponível em: <https://g1.globo.com/sp/sao-paulo/noticia/2019/01/23/prefeitura-de-sp-interdita-ponte-que-leva-a-dutra-pela-marginal-tiete.html>. Acesso em: 20 de jun. de 2019.

RADOVAN, S.; GEORGE, P.; PANAGIOTIS, M.; MANOS, G.; ROBERT, A.; IGOR, D. **An approach for automated inspection of wood boards**. International Conference on Image Processing, 1, p. 798-801, 2001.

SCHVAICKARDT, C. M.; MATTOS, J. R. G. **Estudo de traço para peças pré-moldadas de concreto para pavimentos intertravados**. Revista Nacional de Gerenciamento de Cidades, v. 6, n. 39. 2018.

TOU, J.Y.; LAU, P.Y.; TAY, Y.H. **Computer vision-based wood recognition system**. Intern. Workshop on Advanced Image Techn., p. 197-202, 2007.

VIADUTO da Galeria dos Estados desaba e abre cratera no Eixão Sul. Correio Braziliense, Brasília - DF, 06 de fev. de 2018. Disponível em: https://www.correiobraziliense.com.br/app/noticia/cidades/2018/02/06/interna_cidadesdf,658118/parte-do-viaduto-da-galeria-dos-estados-desaba-no-centro-de-brasilia.shtml. Acesso em: 20 de jun. de 2019.

IDENTIFICAÇÃO DE TRAÇOS DE CONCRETO POR MEIO DE DESCRITORES BASEADOS EM PONTOS DE ATENÇÃO

Data de aceite: 01/03/2021

Jefferson Gustavo Martins

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2102993901875277>

Alessandra Iolanda Pacheco dos Santos

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7255176749334236>

Eduarda Simonis Gavião

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7977085762352521>

Sara Rico Bocato Marin

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/9318173807574063>

Marcos Vinícius Schlichting

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/1152652374544629>

Wilson Leobet

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2563896946139465>

Fabio Alexandre Spanhol

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/4381300863323095>

RESUMO: Edificações são amplamente dependentes da combinação de estruturas de concreto e aço. A composição do concreto, também chamado traço, é um fator de grande importância, sendo que os principais elementos são cimento, areia, brita e água. Tanto a proporção quanto a origem destes materiais exercem influência nas características finais do traço, dentre as quais tem-se resistência, durabilidade e trabalhabilidade. Inserido neste contexto, o presente artigo avalia três descritores baseado em pontos de atenção para identificar diferentes composições de concreto. Os melhores resultados foram obtidos por meio do descritor SURF e atingiram 87,1% de acerto.

PALAVRAS-CHAVE: Construção civil. Defesa civil. Segurança pública. Automação.

IDENTIFICATION OF CONCRETE TRACES THROUGH KEYPOINT-FEATURES-BASED DESCRIPTORS

ABSTRACT: Buildings are largely dependent on the combination of concrete and metal structures. The composition of concrete, also called dosage or trace, is a factor of great importance, and its main elements are cement, sand, gravel, and water. Both, proportion and the origin of these materials, have influence on the final characteristics of the traces, i.e., resistance, durability, and workability. In this context, this paper evaluates three keypoint-features-based descriptors to identify different concrete compositions. The best results were obtained by using the SURF descriptor and achieved 87,1% of correct classification.

KEYWORDS: Construction. Civil defense. Public security. Automation.

1 | INTRODUÇÃO

A composição do concreto, também chamado traço, é uma característica extremamente importante em qualquer obra e muda de acordo com a finalidade de aplicação: lajes, contrapisos, muros, fundações, calçadas, vigas etc. Tanto a proporção quanto a origem dos materiais exercem influência nas características finais do traço, dentre as quais tem-se resistência, durabilidade e trabalhabilidade. Dentre os materiais comumente utilizados, tem-se cimento, areia, brita e água, mas concretos com características especiais podem ser obtidos com o acréscimo de aditivos, isopor, pigmentos, fibras ou outros tipos de adições (ABNT, 2015; MALTA, 2012; MONTEIRO, 2010).

A quantidade de água deve ser suficiente para envolver os grãos e promover a hidratação do cimento, além de atender os requisitos da ABNT NBR 15900-1. Esta ativa a reação química que transforma o cimento em uma pasta aglomerante que criará um bloco único com a areia e a brita (agregados). Se em excesso, ter-se-á uma pasta mais porosa e melhores níveis trabalhabilidade. Porém, também piores níveis de resistência e aderência entre a pasta e o agregado devido à exsudação. A definição de tal proporção também envolve a identificação do teor de umidade dos agregados (ABNT, 2009; ABNT, 2015; MALTA, 2012; MONTEIRO, 2010).

Os agregados são adicionados à pasta de cimento e água para aumentar o volume final e torná-lo mais econômico. Suas propriedades têm influências da formação geológica local, visto que são extraídas de jazidas próximas às localidades de dosagem e edificação. O conhecimento das características individuais dos elementos, e também de sua combinação, é essencial para garantir certas características fundamentais ao concreto e a segurança da estrutura. Além disso, materiais com diferentes granularidades podem ser combinados dependendo da finalidade e produzem diferentes características texturais (ABNT, 2015; BAUER, 1994; MEHTA; MONTEIRO, 2008).

Além dos custos devido a degradação das estruturas, o risco em termos de colapsos estruturais merece atenção. Nos últimos anos, têm sido recorrentes os casos de colapsos de estruturas, dentre os quais tem-se o colapso parcial de um viaduto em Brasília no ano de 2018 (VIADUTO, 2018), a interdição do acesso à Rodovia Presidente Dutra em São Paulo no ano de 2019 (PREFEITURA, 2019) e o desabamento de prédios na comunidade de Muzema, na Zona Oeste do Rio, em 2019 (MAIA; GARCIA, 2019). Portanto, estudos pertinentes ferramentas que auxiliem a fiscalização e a prevenção destes acontecimentos são necessários com vistas a garantir estruturas mais seguras e duráveis e manutenções preventivas.

É importante destacar que as inspeções para avaliar a composição do concreto, e também se este mantém suas propriedades, são realizadas visualmente por especialistas humanos. Tais inspeções demandam altos níveis de experiência por ser um fator decisivo para uma correta avaliação. Dentre as possíveis ferramentas a serem empregadas, tem-se filmadoras, máquinas fotográficas, lupas e binóculos (ABNT, 2014; SCHVAICKARDT; MATTOS, 2018).

As imagens da Figura 1 foram obtidas a partir de dois diferentes traços (cimento : areia : brita : água), com as proporções (1 : 1,49 : 2,88 : 0,48) e (1 : 1,49 : 2,70 : 0,48). Nelas, pode-se nitidamente observar a variação na quantidade de britas entre os concretos

e o grau de dificuldade a ele inerente.




Figura 1: Composições de concreto (cimento : areia : brita : água): (a) 1 : 1,49 : 2,88 : 0,48;
(b) 1 : 1,49 : 2,70 : 0,48.

Fonte: Autoria própria (2020).

Diante do exposto, este artigo apresenta uma proposta para auxiliar as inspeções realizadas para identificar a composição de traços de concreto. Tal solução propicia vantagens relativas à rapidez e precisão quando comparado à avaliação realizada por especialistas humanos. A redução de fatores físicos e subjetivos inerentes ao ser humano também reduzir o número de etapas executadas manualmente e sua influência nos resultados finais. Tal influência compreende questões como subjetividade do especialistas humanos e características do processo (repetitivo, monótono e demorado), além de requerer alto grau de concentração. Este conjunto de exigências sobrecarrega o profissional que realiza a inspeção e o leva a possíveis distrações e baixas taxas de acerto (CONNERS *et al.*, 1997; PHAM; ALCOCK, 1997; RADOVAN *et al.*, 2001).

2 | MATERIAIS E MÉTODOS

Sistemas computacionais com foco em reconhecimento de padrões contemplam as seguintes etapas: aquisição, pré-processamento, segmentação, extração de características e classificação. Cada etapa constitui um diferente contexto, possui diferentes níveis de complexidade e envolve conhecimentos específicos e próprios, além daqueles inerentes ao domínio da aplicação.

Diante da importância do tema, diversos trabalhos têm sido desenvolvidos, inclusive a partir da base de imagens aqui utilizada. Tal fato implica na execução das etapas apresentadas utilizando diferentes ferramentas, mas ainda considerando o foco de cada uma delas em sua essência.

Durante a aquisição, a imagem é capturada e armazenada utilizando sistemas de cores, resolução e quantização específicos. Nesta primeira etapa foi obtida a base de dados, ou seja, o conjunto de imagens, padrões e etc. Inicialmente foram preparados os corpos de prova de concreto sob a forma cilíndrica e com medidas de 10 cm de diâmetro e 20 cm de altura. Foram utilizadas 2 corpos de prova de concreto para cada um dos

diferentes traços analisados. Tal escolha é consequência do fato (e se adequa a ele) de que 2 (dois) corpos de prova são construídos com amostras de cada carga de concreto utilizada nas construções.

Os traços utilizados para a construção dos corpos de prova consideraram a proporção 1: 1,41: 2,01: 0,49 utilizando cimento do tipo Portland CPII, areia média, brita zero e água potável disponibilizada pela companhia de saneamento. Para avaliar a variação da granularidade do agregado brita, foi utilizada uma variação do traço padrão com a troca da brita zero pela brita um, gerando o traço 1: 1,49: 2,60: 0,49. Nesta variação de traço, tem-se um uso maior dos agregados (areia e brita) devido a um maior volume e superfície de cada unidade do agregado brita, sendo necessária menor quantidade de cimento para a construção de peças com um mesmo volume final (Figura 1).

Na sequência, foram realizados cortes transversais a cerca de 5 mm da base e outro 5 mm do topo do corpo de prova. Tais cortes estão ilustrados na Figura 2(a) e seu objetivo de ambos os cortes é eliminar a camada superficial e expor a caracterização da composição real do concreto, tal como apresenta a Figura 2(b). A partir disto, foram realizados outros 8 cortes transversais em cada corpo de prova de concreto. Considerando que as lâminas de corte têm aproximadamente 2 mm, sendo obtido um total de 9 amostras distintas para cada corpo de prova. Considerando as duas faces de cada amostra, chegou-se a um total de 18 imagens para cada corpo de prova. Ao todo, foram utilizadas 72 imagens para construção dos modelos de reconhecimento dos traços de concreto.

Devido à possibilidade de problemas decorrentes da aquisição, o pré-processamento foca a melhoria da qualidade da imagem. As imagens da Figura 2(b-c) apresentam o pré-processamento realizado, com a aplicação de operações para realçar as características importantes no processo de diferenciação das classes existentes no problema. Neste caso, basicamente toda a base de imagens foi convertido para escalas de cinza.

A próxima etapa compreende a segmentação, a qual busca separar apenas a região de interesse da imagem original e da qual depende o sucesso de um modelo de identificação ou de classificação. Nesta etapa, buscou-se por uma imagem que estivesse toda formada pela área de interesse, tal como ilustrado na Figura 2(f). As imagens da Figura 2(c-d) representam a aplicação da técnica de limiarização para destacar o objeto na imagem. Na sequência, aplicou-se o algoritmo de detecção de bordas Canny (BUENO, 2020) para ressaltar os contornos das bordas dos objetos e a função *findContours* da biblioteca OpenCV para identificar os objetos. Esta função retorna os contornos de todos os possíveis objetos presentes na imagem, seja do próprio traço de concreto, das britas ou de qualquer outra região com contraste em relação a seu entorno. A partir da identificação dos possíveis objetos, os pontos pertencentes ao maior contorno com a definição do traço de concreto foram selecionados. Após o cálculo do raio da circunferência, definiu-se e salvou-se o retângulo circunscrito na mesma, Figura 2(e), culminando na Figura 2(f).

A etapa de Extração de Características permite identificar uma abstração (descritor ou conjunto de características) adequada para a representação e a descrição das áreas de interesse, a qual é constituída por um vetor numérico de medidas. Nesta etapa foram utilizadas características extraídas de pontos de atenção. Os pontos de atenção são amplamente empregados na identificação de objetos em problemas relacionados no

rastreamento de objetos, principalmente no monitoramento de ambientes como aeroportos. As características extraídas dos pontos de atenção detectados possuem alto potencial devido aos padrões texturais decorrentes das composições dos traços de concreto (Figura 1).




Figura 2: Ilustração do processo de reconhecimento de padrões: (a) corpo de prova de concreto; (b) corte do corpo de prova; (c) pré-processamento com conversão para níveis de cinza; (d-e) segmentação.

Fonte: Autoria própria (2020).

Foram utilizados os descritores Transformação de Características Invariantes à Escala (*Scale Invariant Feature Transform* - SIFT), Características Robustas Aceleradas (*Speed-Up Robust Feature* - SURF) e Regiões Extremas Maximamente Estáveis (*Maximally Stable Extremal Regions* - MSER), os quais são descritos nas seções seguintes. Devido à variação do número de regiões e pontos identificados em cada imagem, optou-se por utilizar momentos estatísticos para padronizar sua representação. Foram calculadas média, variância, obliquidade e curtose para cada coluna dos vetores gerados pelos descritores. Ao final, obteve-se quatro vetores de características para cada imagem, sendo um para cada momento estatístico anteriormente definido. Esta abordagem é comumente utilizada com filtros de Gabor (YANG; NEWSAM, 2008; ZHU *et al.*, 2008).

A classificação utiliza as representações anteriores para diferenciar os objetos nas imagens, atribuindo-lhes identificadores e significados de acordo com suas características e descritores (PEDRINI; SCHWARTZ, 2008). Nesta etapa foi utilizado o algoritmo Máquinas de Vetores de Suporte (*Support Vector Machine* - SVM), por meio da implementação LibSVM 3.2 disponibilizada no endereço eletrônico <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>. Dentre

as possibilidades disponibilizadas pela biblioteca, os melhores resultados foram obtidos com a função de base radial Gaussiana e uma busca gulosa para encontrar os melhores parâmetros C e γ . A normalização dos dados considerou a escala linear de cada atributo dos vetores de características no intervalo $[-1,+1]$.

Diferentes avaliações foram consideradas a partir dos vetores de características com os momentos estatísticos anteriormente descritos, além de uma avaliação utilizando apenas número de pontos de atenção identificados em cada imagem como característica. Para a definição dos conjuntos de treinamento e teste, dividiu-se a base de imagens em 3 partes (folds), os quais mantinham a representatividade das classes pertencentes ao problema em questão. Foi empregada validação cruzada com 3 execuções, sendo que em que execução, um parte era usada como conjunto de teste e as outras duas eram utilizadas como conjunto de treinamento. Os resultados finais são expressos pela acurácia média (acertos do classificador) e desvio padrão (dp) das taxas de classificações corretas das três execuções.

2.1 Transformação de Características Invariantes à Escala

SIFT foi proposto por Lowe (1999) com o objetivo de identificar regiões de interesse e extrair características que permitam a comparação de imagens de objetos ou cenas capturadas de diferentes perspectivas. A detecção dos pontos de interesse é realizada por um processo de filtragem em cascata tomando uma mesma imagem sob diferentes escalas. A cada iteração são tomadas novas amostras dos pixels da imagem, as quais são geradas pela interpolação bilinear dos pontos contidos numa vizinhança de raio 1,5 da escala imediatamente anterior. Este processo garante a estabilidade do descritor, pois tenta correlacionar uma região detectada em uma iteração com aquelas identificadas nas demais iterações. Além disso, os pontos identificados apresentam diferenças máximas e mínimas da função Gaussiana. Estas altas variações das regiões e escalas constituem as principais garantias para a estabilidade do descritor e para a invariância a translação, escala e rotação, além de invariância parcial a mudanças de iluminação e projeções 3D (LOWE, 1999, 2004).

Embora o descritor SIFT considere um conjunto de 4×4 descritores computados em uma vizinhança 16×16 , a Figura 3(b) mostra apenas 2×2 descritores computados em uma vizinhança 8×8 a partir da Figura 3(a), o que não prejudica o entendimento. Os gradientes da Figura 3(a) são ponderados pela Gaussiana e acumulados em um histograma de orientação que sumariza os conteúdos em 4×4 sub-regiões, Figura 3(b), com o comprimento das arestas correspondendo à soma das magnitudes dos gradientes que pertencem àquela sub-região e que possuem a mesma direção (LOWE, 1999, 2004; VEDALDI e FULKERSON, 2008).

Considerando os histogramas das 4×4 regiões e que cada um acumula a avaliação dos gradientes nas oito direções possíveis, cada ponto é representado por um vetor de características com 128 elementos. Além disso, geralmente são detectados centenas ou até milhares de pontos para cada imagem, todos potencialmente candidatos a compor o conjunto de suas características (LOWE, 1999, 2004; VEDALDI e FULKERSON, 2008).

Seguindo o padrão de representação SIFT, foram gerados vetores com 128 elementos

para cada ponto identificado em cada imagem. Posteriormente, estes foram sumarizados por meio dos vetores com as representações dos quatro momentos estatísticos. Maiores detalhes quanto ao descritor SIFT e a metodologia adotada para ele podem ser obtidos em Martins (2014).




Figura 3: Descritor SIFT: (a) aplicação da máscara na imagem e obtenção dos gradientes para cada direção na região sobreposta; (b) acúmulo dos gradientes para cada sub-região para as oito direções.

Fonte: Martins (2014).

2.2 Características Robustas Aceleradas

Proposto por Bay *et al.* (2006), Características Robustas Aceleradas (*Speed-Up Robust Feature* - SURF) apresenta semelhanças ao SIFT e permite detecção e descrição de regiões de interesse. Porém, este reduz a alta dimensionalidade e custo computacional do descritor SIFT, pois possui a metade do número de elementos do SIFT e é baseado em matrizes Hessianas e no conceito de imagens integrais. O uso de determinantes de matrizes Hessianas garante robustez quanto a estruturas mal localizadas e alongadas, maior estabilidade se comparados a detectores de cantos de Harris, além de boa performance em termos de tempo computacional e taxas de acerto (BAY *et al.*, 2006, 2008).

O uso das imagens integrais reduz drasticamente o tempo de computação devido aos filtros de convolução baseados em caixas. Por definição, cada elemento (x,y) de uma imagem integral representa a soma de todos os pixels da imagem original contidos na região retangular situada entre a origem e suas coordenadas (x, y) . Diante disto, conforme ilustrado na Figura 4(a), o cálculo da soma dos pixels contidos em uma região qualquer requer apenas três operações de adição. Conseqüentemente, o tempo necessário para aplicar qualquer filtro à imagem permanece constante (independente de suas dimensões), todos os filtros são aplicados na imagem integral sem a necessidade de criar novas imagens por meio de interpolações, os componentes de alta frequência são preservados e poderão ser recuperados independentemente da escala corrente (BAY *et al.*, 2006, 2008).

Após identificar a região de interesse e sua orientação, conforme Figura 4(b), o

próximo passo consiste em calcular os valores do descritor. Para isso, conforme Figura 4(c), define-se uma região quadrada (8x8) centrada no ponto de interesse e alinhada com a orientação previamente identificada. Para cada um dos 64 elementos, obtém-se a resposta da wavelet de Haar nas direções x e y, denominadas respectivamente d_x e d_y . Para cada sub-região 2x2, d_x , d_y , $|d_x|$ e $|d_y|$ são acumuladas separadamente, gerando 16 conjuntos com as quatro características (Σd_x , Σd_y , $\Sigma |d_x|$ e $\Sigma |d_y|$), num total de 64 elementos. Ao final, como SIFT, geralmente são detectados centenas ou até milhares de pontos para a imagem. Todos estes pontos são invariantes à translação, escala e rotação, além de ser parcialmente invariante a mudanças de iluminação e projeções 3D e potencialmente candidatos a compor o conjunto de características que descreve a imagem (BAY *et al.*, 2006, 2008).

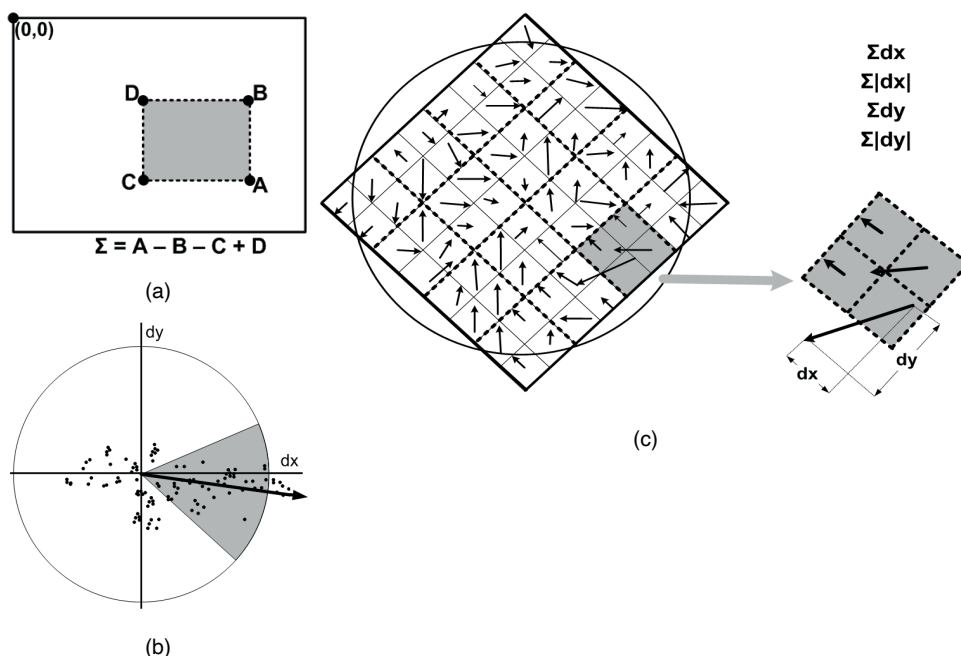


Figura 4: Processo de cálculo para o descritor SURF: (a) imagem integral; (b) janela deslizante de orientação com ângulo $\pi/3$; (c) aplicação da máscara 8x8 alinhada com a orientação identificada e obtenção dos gradientes para cada direção na região sobreposta da imagem (esquerda), seguido do acúmulo dos gradientes para cada sub-região (direita).

Fonte: Autoria própria (2020).

Os autores também apresentaram a variante SURF-128, a qual duplica o número de características que compõem o vetor final. Esta variante acumula d_x e $|d_x|$ separadamente para $d_y < 0$ e $d_y \geq 0$, sendo o mesmo considerado para d_y e $|d_y|$ de acordo com o sinal de d_x . Embora esta variação garanta descritores mais discriminantes, a maior dimensionalidade do vetor de características exige maiores recursos computacionais (BAY *et al.*, 2006, 2008).

Seguindo o padrão de representação SURF, foram gerados vetores com 64 e 128 elementos para cada ponto identificado em cada imagem. Posteriormente, estes foram sumarizados por meio dos vetores com as representações dos quatro momentos

estatísticos, gerando novos vetores com 64 ou 128 elementos. Maiores detalhes quanto ao descritor SURF e a metodologia adotada para ele podem ser obtidos em Martins (2014).

2.3 Regiões Extremas Maximamente Estáveis

Em 2002, Matas *et al.* (2002) conceituaram regiões extremas (*Extremal Regions* - ER) e propuseram o algoritmo MSER para detectá-las. ERs são caracterizadas como componentes conexos invariantes a transformações das coordenadas das imagens e a transformações das intensidades de seus pixels. De forma simplificada, ERs são identificadas por meio de uma sequência de limiarizações da imagem original (em níveis de cinza) e das imagens binárias geradas. Tal sequência de imagens inicia com um quadro totalmente branco e termina com um outro totalmente negro, passando por diversas imagens intermediárias nas quais as regiões de interesse são identificadas. Tais regiões se tornam cada vez maiores e se fundem à medida que o valor utilizado como limiar é incrementado (LÓPES, 2011; MATAS *et al.*, 2002).




Figura 5: Processo de definição das regiões extremas. Considere a imagem da Figura 1(b). Após esta ser convertida para níveis de cinza, diferentes limiares são aplicados e diferentes imagens binarizadas são geradas para a identificação das regiões extremas. As imagens (a) a (f) ilustram os resultados para os limiares 35, 50, 60, 81, 117 e 124.

Fonte: Autoria própria (2020).

De forma geral, as ERs são identificadas em função dos níveis de cinza dos pixels que as compõem e daqueles externos a elas. Ou seja, tais regiões são ou mais escuras ou mais claras que sua vizinhança, sendo estáveis diante de diferentes limiares no processo de binarização, conforme pode-se perceber na Figura 5. Os autores afirmam que essas regiões são estáveis e invariantes a escalas, a transformações das coordenadas das imagens e a transformações das intensidades de seus pixels. A enumeração destas regiões inicia com a ordenação dos pixels da imagem. Em seguida, tal sequência é percorrida e as posições dos pixels na imagem permitem que os componentes conexos e suas áreas sejam identificados e mantidos por meio do algoritmo *union-find*. Níveis de cinza caracterizados como mínimos locais da taxa de mudança da área são selecionados como limiares produzindo as MSERs (MATAS *et al.*, 2002).

Um fato importante a ser destacado é que MSER não possui um algoritmo para a extração de características. Assim, MSER foi utilizado para a identificação das regiões, enquanto que as características foram extraídas com o uso do SURF (BAY *et al.*, 2006, 2008). Como antes, foram gerados vetores com 64 e 128 elementos para cada região identificada em cada imagem. Posteriormente, estes foram sumarizados por meio dos vetores com as representações dos quatro momentos estatísticos, gerando novos vetores com 64 ou 128 elementos. Maiores detalhes quanto ao descritor MSER e a metodologia adotada para ele podem ser obtidos em Martins (2014).

3 I RESULTADOS E DISCUSSÃO

Para cada etapa do processo de reconhecimento de padrões foram testados diferentes parâmetros, tal como identificados na seção de materiais e métodos. Os melhores resultados são apresentados nos Quadros 1 à 3.

Atributos	# Atributos	%	dp
# Atributos	1	56,4	3,2
Média	128	81,3	2,8
Variância	128	84,8	2,9
Obliquidade	128	81,4	7,9
Curtose	128	82,5	5,3

Quadro 1: Resultados obtidos para o descritor SIFT.

Fonte: Autoria própria (2020).

Atributos	SURF-64			SURF-128		
	# Atributos	%	dp	# Atributos	%	dp
# Atributos	1	57,6	1,4	1	57,6	1,4
Média	64	82,2	3,5	128	78,9	2,3
Variância	64	87,1	3,1	128	87,1	3,1
Obliquidade	64	69,3	2,4	128	72,9	2,3
Curtose	64	74,1	7,0	128	74,0	6,2

Quadro 2: Resultados obtidos para o descritor SURF.

Fonte: Autoria própria (2020).

Atributos	MSER-SURF-64			MSER-SURF-128		
	# Atributos	%	dp	# Atributos	%	dp
# Atributos	1	62,5	5,5	1	62,5	5,5
Média	64	63,4	6,4	128	61,1	3,1
Variância	64	57,8	9,4	128	74,2	3,8
Obliquidade	64	61,2	1,9	128	56,5	1,9
Curtose	64	63,5	4,2	128	54,2	6,7

Quadro 3: Resultados obtidos para o conjunto MSER-SURF.

Fonte: Autoria própria (2020).

Para SIFT, os melhores resultados alcançados foram 84,8% (dp = 2,9) utilizando os vetores obtidos pelo cálculo do momento estatístico variância para sumarizar as características dos pontos de atenção identificados em cada imagem. Já para SURF, ambas as versões com 64 e 128 atributos geraram 87,1% (dp = 3,1) para para variância. A combinação MSER-SURF, nas versões com 64 e 128 atributos, produziu 63,5% (dp = 4,2) para curtose e 74,2% (dp = 3,8) para variância, respectivamente.

O problema em questão envolve segurança e vidas humanas, além dos altos valores monetários empregados na construção e manutenção das edificações. Os resultados obtidos se mostraram importantes, principalmente com as boas taxas de reconhecimento apresentadas. Além do exposto, destaca-se a combinação do identificador de regiões de interesse MSER e do descritor SURF.

4 | CONSIDERAÇÕES FINAIS

Este trabalho avaliou a aplicação de classificadores construídos a partir de descritores baseados em pontos de atenção ao problema de reconhecimento de traços de concreto por meio de imagens. Os resultados alcançados são bastante promissores para problema abordado. Nossos resultados apontam para alternativas viáveis a serem empregadas, sendo que a melhor taxa de reconhecimento foi 87,1% (dp = 3,1) usando o descritor SURF.

Os trabalhos futuros compreenderão a ampliação da base de imagens, com maior variedade de traços e imagens. Ao mesmo tempo, serão investigados novos descritores e opções para seleção e combinação de classificadores, tais como as apresentadas por Martins, Oliveira e Sabourin (2012).

REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 15900-1**: Água para amassamento do concreto Parte 1: Requisitos. Rio de Janeiro, 2009.

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 6118**: Projeto de estruturas de concreto – Procedimento. Rio de Janeiro, 2014.

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 12655: Concreto de cimento Portland – Preparo, controle, recebimento e aceitação – Procedimento.** Rio de Janeiro, 2015.

BAUER, L. A. F. **Materiais de Construção.** 5.ed. Vol 1. Rio de Janeiro: LTC – Livros técnicos e Científicos Editora S.A., 1994.

BAY, H.; TUYTELAARS, T.; e VAN GOOL, L. **SURF: Speeded up robust features.** In ECCV, 2006, p. 404-417.

BAY, H.; ESS, A.; TUYTELAARS, T.; e VAN GOOL, L. **Speeded-up robust features (SURF).** Compute Vision. Image Understanding, v. 110, n. 3, 2008, p. 346-359.

BUENO, M. L. **Deteção de Bordas através de Algoritmo Canny.** Disponível em: <http://www.inf.ufsc.br/~aldo.vw/visao/2000/Bordas/index.htm>. Acesso em: 20 jan. 2020.

CONNERS, R. W.; KLINE, D. E.; ARAMAN, P. A.; DRAYER, T. H. **Machine vision technology for the forest products industry.** Computer, v. 30, n. 7, p. 43-48, 1997.

LÓPES, G. A. P. **Aforapro: reconhecimento de objetos invariante sob transformações afins.** Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, São Paulo, 2011.

LOWE, D.G. **Object recognition from local scale-invariant features.** In International Conference on Computer Vision, v. 2, p. 1150-, Washington, DC, USA, 1999.

LOWE, D.G. **Distinctive image features from scale-invariant keypoints.** In Int. Journal of Computer Vision, v. 60, n. 2, p. 91-110, 2004.

MAIA, D. e GARCIA, D. **Dois prédios desabam na zona oeste do Rio de Janeiro.** Folha de São Paulo, São Paulo - SP, 12 de abr. de 2019. Disponível em: <https://www1.folha.uol.com.br/cotidiano/2019/04/dois-predios-desabam-na-zona-oeste-do-rio-de-janeiro.shtml#:~:text=%E2%80%8BBO%20desabamento%20de%20dois,adolescente%20est%C3%A3o%20entre%20as%20v%C3%ADtimas.&text=%E2%80%8BBOs%20pr%C3%A9dios%20ca%C3%ADram%20por%20volta%20das%206h30>. Acesso em: 20 de jun. de 2019.

MALTA, J. O. **Dosagem de concretos produzidos com agregado miúdo reciclado de resíduo de construção e demolição.** Dissertação de Mestrado em Engenharia Ambiental Urbana. Escola Politécnica (EPUFBA). Universidade Federal da Bahia (UFBA). Salvador, 2012.

MARTINS, J.G.; OLIVEIRA, L.E.S.; SABOURIN, R. **Combining textural descriptors for forest species recognition.** In IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society, p. 1483-1488, 2012.

MARTINS, J.G. **Identificação de Espécies Florestais utilizando Seleção Dinâmica de Classificadores no Espaço de Dissimilaridade.** Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba-PR, 2014.

MATAS, J.; CHUM, O.; MARTIN, U.; e PAJDLA, T. **Robust wide baseline stereo from maximally stable extremal regions.** In British Machine Vision Conference, p. 384–393, 2002.

MEHTA, P.K.; MONTEIRO, P. **Concreto: Microestrutura, Propriedades e Materiais.** 3.ed. São Paulo: IBRACON, 2008.

MONTEIRO, A. C. N. **Concreto Poroso: dosagem e desempenho.** Monografia de Graduação em Engenharia Civil. Universidade Federal de Goiás (UFGO). Goiania, 2010.

PEDRINI, H.; SCHWARTZ, W.R. **Análise de Imagens Digitais**: princípios, algoritmos e aplicações. São Paulo: Thomson Learning, 2008.

PHAM, D. T.; ALCOCK, R. J. **Automated visual inspection of birch wood boards**. IEE Colloquium on Artificial Intelligence in Manufacturing, p. 1-4, 1997.

PREFEITURA de SP interdita ponte que leva à Dutra pela Marginal Tietê. G1 SP, São Paulo - SP, 23 de jan. de 2019. Disponível em: <https://g1.globo.com/sp/sao-paulo/noticia/2019/01/23/prefeitura-de-sp-interdita-ponte-que-leva-a-dutra-pela-marginal-tiete.ghtml>. Acesso em: 20 de jun. de 2019.

RADOVAN, S.; GEORGE, P.; PANAGIOTIS, M.; MANOS, G.; ROBERT, A.; IGOR, D. **An approach for automated inspection of wood boards**. International Conference on Image Processing, 1, p. 798-801, 2001.

SCHVAICKARDT, C. M.; MATTOS, J. R. G. **Estudo de traço para peças pré-moldadas de concreto para pavimentos intertravados**. Revista Nacional de Gerenciamento de Cidades, v. 6, n. 39. 2018.

VEDALDI, A.; FULKERSON, B. **VLFeat: An Open and Portable Library of Computer Vision Algorithms**. 2008. URL: <http://www.vlfeat.org/>.

VIADUTO da Galeria dos Estados desaba e abre cratera no Eixão Sul. Correio Braziliense, Brasília - DF, 06 de fev. de 2018. Disponível em: https://www.correiobraziliense.com.br/app/noticia/cidades/2018/02/06/interna_cidadesdf,658118/parte-do-viaduto-da-galeria-dos-estados-desaba-no-centro-de-brasilia.shtml. Acesso em: 20 de jun. de 2019.

YANG, Y.; e NEWSAM, S. **Comparing SIFT descriptors and Gabor texture features for classification of remote sensed imagery**. In 15th IEEE International Conference on Image Processing, p. 1852-1855, 2008.

ZHU, J.; HOI, S. C.H.; LYU, M. R.; e YAN, S. **Near-duplicate keyframe retrieval by nonrigid image matching**. In 16th ACM international conference on Multimedia, p. 41–50, New York, NY, USA, 2008.

IDENTIFICAÇÃO DE DETERIORAÇÃO DE BARRAS DE AÇO POR MEIO DE IMAGENS DO RECOBRIMENTO DE CONCRETO

Data de aceite: 01/03/2021

Jefferson Gustavo Martins

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2102993901875277>

Alessandra Iolanda Pacheco dos Santos

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7255176749334236>

Eduarda Simonis Gavião

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7977085762352521>

Guilherme Dias Almanza

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7691365391625214>

Kelly Chapla

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/5977440276620782>

Marcos Vinícius Schlichting

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/1152652374544629>

Wilson Leobet

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2563896946139465>

Fabio Alexandre Spanhol

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/4381300863323095>

RESUMO: A corrosão das armaduras em estruturas de concreto é um dos principais mecanismos que leva a sua degradação e pode levar a colapsos estruturais. Dada importância do tema, este artigo aplica reconhecimento de padrões para auxiliar o processo de inspeção realizado por especialistas humanos. Este processo é repetitivo, monótono e demorado, além de demandar altos níveis de experiência e ter seus resultados influenciados por fatores físicos e subjetivos. Os melhores foram 73,3% obtidos pela combinação do descritor TAS e do algoritmo de aprendizagem de máquinas SVC.

PALAVRAS-CHAVE: Construção civil. Defesa civil. Segurança pública. Automação.

IDENTIFICATION OF DETERIORATION IN STEEL BARS BY USING IMAGES OF CONCRETE SURFACE LAYER

ABSTRACT: Reinforcement corrosion in concrete structures is one of the main mechanisms that lead to its degradation, and may lead to structural collapses. Due to the importance of this issue, this paper applies pattern recognition to help human experts in the inspection process. This process is repetitive, monotonous and time consuming, require high levels of experience and have its results, and is influenced by physical and subjective aspects. The best achieved results were 73.3% achieved by using TAS descriptor and SVC machine learning algorithm.

KEYWORDS: Construction. Civil defense. Public security. Automation.

1 | INTRODUÇÃO

A corrosão pode ser definida basicamente como a deterioração de um metal (ou liga) a partir do contato de sua superfície com o meio no qual este esteja inserido. O processo envolve reações de oxidação e de redução (redox) que convertem o metal ou componente metálico em óxidos ou hidróxidos expansivos (SILVA; PEREIRA; CODARO, 2015).

Dentre os possíveis problemas relacionados à corrosão das armaduras, muitos têm relação com as características do concreto, cuja função é oferecer uma dupla proteção ao aço. Primeiramente, tem-se a proteção física com a separação do aço e do meio externo. Já a proteção química é decorrente do elevado pH da solução presente nos poros do concreto e consequente formação de uma película passivadora que envolverá o aço no interior do concreto (FIGUEIREDO; MEIRA, 2012).

Dentre os fatores que influenciam o processo de corrosão do aço imerso no concreto estão: o coeficiente de difusão do concreto, a relação água/cimento, a espessura de revestimento, a presença e a quantidade de adições, a umidade relativa, o pH do concreto e a temperatura de exposição (ANDRADE, 2001; GU; BEAUDOIN, 1998).

Definida como um dos principais problemas relacionados a degradação de estruturas de concreto armado no mundo, a corrosão das armaduras pode demandar até 50% dos recursos financeiros investidos em construção civil para a reabilitação de estruturas degradadas (MEHTA; MONTEIRO, 2008). Segundo Cunha, Helene e Lourenço. (2013), tal problema consome direta ou indiretamente uma parcela significativa do produto interno bruto (PIB) de uma nação industrializada.

Além das perdas financeiras, as consequências mais graves são possíveis danos corporais e até mesmo perdas de vidas humanas. O risco em termos de colapsos estruturais merece atenção. Nos últimos anos, têm sido recorrentes os casos de colapsos de estruturas devido à corrosão de armaduras. Dentre vários casos com repercussão na mídia nacional, pode-se citar o colapso parcial de um viaduto na cidade de Brasília em 2018 (VIADUTO, 2018) e a interdição do acesso à Rodovia Presidente Dutra, na cidade de São Paulo em 2019 (PREFEITURA, 2019).

A Figura 1 ilustra a ação da corrosão com a ocorrência das duas situações concomitantemente, isto é, fissuras da camada de revestimento do concreto acompanhadas de manchas corrosivas (CASCUDO, 1997). Caso o concreto esteja muito úmido, os óxidos serão gerados a uma velocidade constante e podem emigrar através da rede de poros, aparecendo na superfície sob a forma de manchas marrom-avermelhadas, mas não apresentando fissuras, conforme apresenta a Figura 1(a).

Complementando a ilustração anterior, a Figura 2 apresenta a perda de seção na região anódica devido à dissolução do ferro. A perda de seção provoca a redução de aderência entre aço e concreto, a redução da capacidade estrutural da peça e externamente o surgimento de manchas. As tensões internas expansivas provenientes dos produtos da corrosão (situados na região anódica) provoca a deterioração da ferragem e o destacamento da camada de revestimento, tal como apresenta as imagens da Figura 1(b-c) (ANDRADE, 2001; LOPES *et al.*, 2018).

Quando se observa o estado de corrosão, pode-se constatar o surgimento de

fissuras paralelas às armaduras; fragmentação e destacamento do cobrimento e, no estado avançado, o lascamento do concreto. Logo, quando há indicações externas do processo corrosivo, normalmente parte da armadura já se encontra comprometida, pois, a manifestação é tão somente o afloramento deste.




Figura 1: Efeitos da corrosão na camada de cobrimento de concreto: (a) manchas; (b) fissuras e rachaduras; (c) destacamento total.

Fonte: Autoria própria (2020).



Figura 2: Barra de aço: (a) original; (b) perda de seção devido à corrosão.

Fonte: Autoria própria (2020).

Outra importante característica deste cenário é o fato de que, em sua maior parte, as inspeções para avaliar o grau de corrosão são realizadas visualmente por especialistas humanos. Tais avaliações demandam altos níveis de experiência por ser um fator decisivo para uma correta avaliação do estado de deterioração da estrutura. Dentre as possíveis ferramentas a serem empregadas, tem-se filmadoras, máquinas fotográficas, lupas e binóculos (ABNT, 2014).

Diante do exposto, identifica-se a necessidade de estudos pertinentes ao melhor entendimento dos processos de degradação de estruturas devido a corrosão com vistas a edificar estruturas mais seguras e duráveis. Assim, este artigo busca auxiliar o processo de inspeção por meio da aplicação de visão computacional para identificar níveis de deterioração em barras de aço. Com isso, busca-se reduzir fatores inerentes ao ser humano que influenciam nas inspeções realizadas para avaliar o grau de corrosão em barras de aço em estruturas de concreto armado. Tal influência compreende questões como subjetividade do especialista humano e características do processo (repetitivo, monótono e demorado), além de requerer alto grau de concentração. Este conjunto de exigências sobrecarrega o profissional que realiza a inspeção e o leva a possíveis distrações e baixas taxas de acerto (CONNERS *et al.*, 1997; PHAM; ALCOCK, 1997; RADOVAN *et al.*, 2001).

2 | MATERIAIS E MÉTODOS

Sistemas computacionais desenvolvidos com base em técnicas de reconhecimento de padrões geralmente apresentam as seguintes etapas: aquisição, pré-processamento, segmentação, extração de características e classificação. Cada etapa constitui um diferente contexto, possui diferentes níveis de complexidade e envolve conhecimentos específicos e próprios, além daqueles inerentes ao domínio da aplicação.

Diante da importância do tema, diversos trabalhos têm sido desenvolvidos, inclusive a partir da base de imagens aqui empregada. Tal fato implica na execução das etapas já apresentadas utilizando diferentes ferramentais, mas ainda considerando o foco de cada uma delas em sua essência.

A construção da base de imagens envolveu 24 (vinte e quatro) amostras, sendo que 6 (seis) delas formando o grupo de controle (referências isentas de corrosão) e outros três grupos de seis barras foram submetidos a processos de aceleração de corrosão por períodos de 24, 48 e 72 horas (Figura 3).




Figura 3: Processo de construção da base de imagens: (a) barra original; (b) corpo de concreto envolvendo a barra original; (c) corpo de concreto envolvendo a barra após 28 dias de cura do concreto; (d-f) corpos de concreto envolvendo a barra após o processo de aceleração (respectivamente 24, 48 e 72 horas); (g-i) barras retiradas dos corpos de concreto após o processo de aceleração (respectivamente 24, 48 e 72 horas).

Fonte: Autoria própria (2020).

Para a construção da base de imagens foram utilizadas barras de aço da marca Gerda com 12,5 mm de diâmetro. Cada amostra é caracterizada por um comprimento com aproximadamente 25 cm, sendo que todas foram obtidas de barras pertencentes a um mesmo lote de fabricação, tal como ilustrado na Figura 3(a). O segundo passo compreendeu o recobrimento de 2 cm dos corpos de prova de aço com concreto para simular o contexto real das estruturas nas edificações, conforme apresentado na Figura 3(b). O traço de concreto utilizado tinha a proporção 1 : 1,49 : 2,77 : 0,65 (Cimento : Areia : Brita : Água). Cada amostra tinha 10 cm de suas extremidades cobertas por fita isolante para garantir que a corrosão ocorresse apenas na parte central da amostra. Um fio elétrico foi conectado às barras com o objetivo de permitir o ensaio de aceleração da corrosão. Depois, a amostra foi inserida em um cano de PVC com diâmetro nominal de 50 mm e 25 cm de comprimento.

Este cano de PVC foi preenchido com concreto de tal forma que a cobertura se mantivesse homogênea em termos de espessura da camada de cobrimento (2 cm). As amostras permaneceram sob cura por 28 dias para o processo de hidratação do cimento, Figura 3(c). Seguiu-se com o processo de aceleração de corrosão das amostras com os corpos de concreto parcialmente imersos em um tanque de água com 3,5% (concentração próxima a água do mar) de cloreto de sódio (NaCl) e submetidos ao ensaio de aceleração da corrosão através da condução de eletricidade. Os três grupos de corpos de concreto foram mantidos por três diferentes períodos de tempo no tanque, sendo estes 24, 48 e 72 horas, Figura 3(d-f), o que gerou diferentes níveis de corrosão, Figura 3(g-i).

Depois de cessado o processo de aceleração de corrosão, os corpos de concreto, bem como as barras internas depois de extraídas e limpas com solução ácida, foram submetidos a uma coleta de imagens para compor a base. Para cada amostra de barra, foram capturadas 5 (cinco) imagens abrangendo a diferentes perspectivas da superfície dos corpos de concreto e também da barra depois de extraída, num total de 120 imagens para cada caso. No presente estudo foram consideradas as imagens relativas aos corpos de concreto, Figura 3(d-f).

A Figura 4 ilustra as etapas de pré-processamento e segmentação, sendo que a primeira aplica operações para realçar as características importantes no processo de diferenciação das classes existentes no problema. Nesta etapa, utilizou-se principalmente da biblioteca OpenCV para converter a base toda em escala de cinza, conforme ilustração das imagens da Figura 4(a-b).

A segmentação é ilustrada pelo par de imagens da Figura 4(b-c). Esta compreende a próxima etapa do processo e busca separar apenas a região de interesse da imagem original e da qual depende o sucesso de um modelo de identificação ou de classificação. Nesta etapa, buscou-se por uma imagem que estivesse toda formada pela área de interesse, tal como ilustrado na Figura 4(c).

Para a segmentação, foram utilizados a técnica de limiarização para descartar os objetos na imagem, o algoritmo de detecção de bordas Canny (BUENO, 2020) para ressaltar os contornos das bordas destes objetos e a função *findContours* da biblioteca OpenCV para identificar os pontos que pertenciam a tais contornos. Esta função retorna os pontos que formam os contornos de todos os possíveis objetos presentes na imagem, os quais são caracterizados por qualquer região com contraste em relação a seu entorno. A partir da identificação dos possíveis objetos, os pontos pertencentes ao maior contorno com a definição do traço de concreto foram selecionados. Ao final, recortou-se e salvou-se a área de interesse em uma nova imagem, tal como ilustrado na Figura 4(c).

A etapa de Extração de Características busca representar a imagem por meio de um vetor numérico de medidas. Nesta etapa foram utilizados os descritores GLCM (*Gray Level Co-occurrence Matrix*), LBP (*Local Binary Pattern*), SURF (*Speed-Up Robust Feature*) e TAS (*Threshold Adjacency Statistics*), os quais são descritos nas seções seguintes.

Na fase de classificação foram utilizados três algoritmos: kNN (*k-Nearest Neighbour*), SVC (*Support Vector Classification*, baseada na *libsvm*) e Linear SVC (que é baseada na *liblinear*). Para os algoritmos baseados em Máquinas de Vetores de Suporte (*Support Vector Machine* - SVM), isto é, SVC e Linear SVC, os melhores resultados foram obtidos

pela execução de uma busca gulosa para encontrar os melhores parâmetros C e y, numa tentativa de identificar o melhor arranjo e otimizar as taxas finais de reconhecimento. A normalização dos dados considerou a escala linear de cada atributo dos vetores de características no intervalo [-1,+1].




Figura 4: Processo de reconhecimento de padrões: (a) corpo de concreto após o processo de aceleração; (b) pré-processamento com conversão para níveis de cinza; (c) segmentação.

Fonte: Autoria própria (2020).

Para a definição dos conjuntos de treinamento e teste, dividiu-se a base de imagens em 3 partes (folds), os quais mantinham a representatividade das classes pertencentes ao problema em questão. Foram realizadas 3 execuções, sendo que em cada execução uma parte era usada como conjunto de teste e os outros dois eram utilizados como conjunto de treinamento. Os resultados finais são expressos pela média e desvio padrão das taxas de classificações corretas das três execuções.

Neste trabalho foram consideradas as métricas acurácia, precisão, chamada e F1 score. Cada uma dessas métricas foi calculada para cada fold. A partir destes valores individuais foram calculadas a média e o desvio padrão (dp), sendo que o desvio padrão é apresentado apenas para a acurácia. A acurácia (Acc) é a taxa obtida pela razão entre as predições corretas totais e o número de amostras. A precisão (Pr) é a razão entre as instâncias previstas corretamente e a quantidade total de predições da classe correspondente. A chamada (Re) se trata da razão entre as instâncias previstas corretamente e o total de instâncias testadas da classe correspondente. F1 score (F1) é a média harmônica entre a precisão e a chamada: $F1 = 2 * \frac{\text{precisão} * \text{chamada}}{\text{precisão} + \text{chamada}}$

2.1 Matriz de Coocorrência de Níveis de Cinza

Matriz de Coocorrência de Níveis de Cinza (*Gray Level Co-occurrence Matrix - GLCM*) é um método estatístico proposto por Haralick e se caracteriza como um dos mais conhecidos métodos que exploram repetições de ocorrências de padrões. Tais padrões são caracterizados pela dependência entre os níveis de cinza dos *pixels* das imagens e por sua

distribuição espacial. As repetições dos padrões provêm medidas quanto a propriedades como rugosidade, suavidade e regularidade sob diferentes perspectivas com a variação dos parâmetros direção e distância (HARALICK, 1979).

Formalmente, Haralick fundamenta GLCM pela seguinte definição: dada uma imagem I com dimensões $N_r \times N_c$, tal que $L_r = [1, N_r]$ e $L_c = [1, N_c]$ representam os possíveis valores para linhas e colunas, respectivamente; e $L = [1, N_g]$ o conjunto de N_g níveis de cinza quantizados de I . A imagem I pode ser representada como uma função que associa algum nível de cinza de G a uma célula ou par de coordenadas de $L_r \times L_c$. Ou seja, $I : L_r \times L_c \rightarrow G$ (HARALICK, 1979; PEDRINI; SCHWARTZ, 2008).

A partir disto, Haralick define o uso de uma matriz $N_g \times N_g$ para representar a frequência P_{ij} , tal que um pixel p_x possua nível de cinza n_x e um pixel vizinho a p_j (p_j - a uma distância d e um ângulo α) possua nível de cinza n_j . Embora Haralick tenha estabelecido ângulos com intervalos de 45 graus, os cálculos podem assumir outros ângulos (HARALICK, 1979; TOU, 2007).

Seguindo as definições anteriores, as GLCM da Figura 5(b) foi gerada para a imagem da Figura 5(a) com $N_g = 5$, distância $d = 1$ e direção 0 grau, respectivamente. Dentre as possíveis medidas extraídas de GLCM, tem-se as apresentadas por Haralick: Segundo Momento Angular, Contraste (Soma do Quadrado da Variância), Correlação, Variância (Soma dos Quadrados), Momento de Diferença Inverso (Homogeneidade), Soma da Média, Soma da Variância, Soma da Entropia, Entropia, Diferença da Variância, Diferença da Entropia, Informação de Medidas de Correlação 1, Informação de Medidas de Correlação 2 e Coeficiente de Correlação Máxima (HARALICK, 1979).

Embora a proposta inicial tenha definido 14 elementos, diferentes trabalhos consideram diferentes subconjuntos destes e afirmam haver correlações ou redundâncias entre as informações provenientes de alguns deles. Assim, aqui empregou-se apenas seis das características propostas por Haralick (1979): energia, contraste, entropia, homogeneidade, probabilidade máxima e momento de terceira ordem. Tais características têm suas equações apresentadas a seguir. N_g é o número de diferentes níveis de cinza da imagem; i e j são os níveis de cinza e servem como índices da GLCM; e $P(i,j)$ é a probabilidade de co-ocorrência do par (i,j) de níveis de cinza.

2.2 Padrão Binário Local

Classificado como um método estrutural, o Padrão Binário Local (*Local Binary Pattern* - LBP) foi introduzido, em 1996, como uma medida complementar para contraste local de uma imagem em níveis de cinza, sendo definido como invariante a mudanças monotônicas dos níveis de cinza. Em sua versão original, LBP considera uma vizinhança-8 e distância um para o pixel central (x_c, y_c) de uma máscara com dimensões 3x3, Figura 6(a) (MÄENPÄÄ *et. al.*, 2000).

Cada ponto da imagem é tomado como sendo o ponto central (x_c, y_c) , cujo valor é utilizado como limiar na comparação com o conteúdo de cada um de seus vizinhos (x_i, y_i) . Desta comparação gera-se uma cadeia de zeros e uns Figura 6(b), pois cada vizinho assume o valor um se seu conteúdo for maior que o do ponto central (x_c, y_c) e zero caso contrário. A organização dessa cadeia considera a posição relativa j de cada um dos vizinhos, iniciando

do canto superior-esquerdo com valor zero e circundando o ponto central no sentido anti-horário, Figura 6(c). Ao ser tomada como uma representação em base dois e convertida para a base dez, tem-se o padrão que representa a região sobreposta pela máscara, Figura 6(d-e) (MÄENPÄÄ *et. al.*, 2000).




Figura 5: Geração de GLCMs.

Fonte: Martins (2014).

$$\begin{aligned}
 \text{Energia} &= \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \{P(i, j)\}^2} \\
 \text{Contraste} &= \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} |i - j|^2 P(i, j)} \\
 \text{Entropia} &= - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j) \log(P(i, j)) \\
 \text{Homogeneidade} &= \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{P(i, j)}{1 + |i - j|^2} \\
 \text{Probabilidade Máxima} &= \max_{i=0}^{N_g-1} P(i, j) \\
 \text{Momento de Terceira Ordem} &= \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} |i - j|^3 P(i, j)}
 \end{aligned}$$

Após gerar os padrões para todos os pontos da imagem, as frequências destes padrões são contabilizadas por meio de um histograma com um total de 2^P padrões para P vizinhos. A consideração de $P = 8$, Figura 6(a), gera um total de 256 padrões de transição de bits, Figura 6(b). Dentre estes padrões, apenas 58 atendem a definição de uniformidade,

isto é, a ocorrência de, no máximo, duas transições do valor zero para um e vice-versa. Todos os demais padrões são contabilizados juntos, levando a um total de 59 valores para o descritor denominado LBP uniforme (LBP^{u2}).

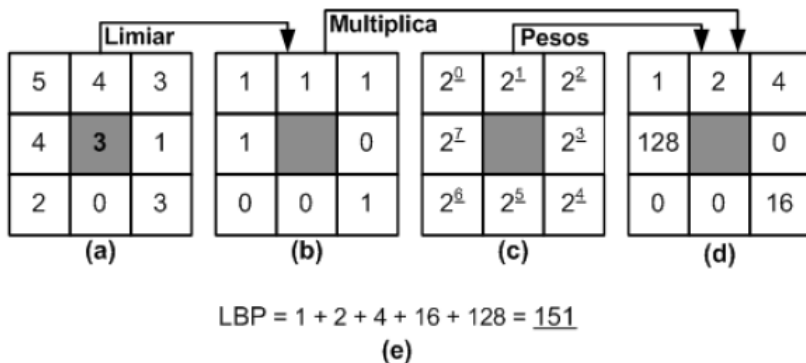


Figura 6: Cálculo do padrão LBP.

Fonte: Martins (2014, p. 34).

2.3 Características Robustas Aceleradas

Proposto por Bay et al. (2006), Características Robustas Aceleradas (*Speed-Up Robust Feature* - SURF) apresenta semelhanças ao SIFT e permite detecção e descrição de regiões de interesse. Porém, este reduz a alta dimensionalidade e custo computacional do descritor SIFT, pois possui a metade do número de elementos do SIFT e é baseado em matrizes Hessianas e no conceito de imagens integrais. O uso de determinantes de matrizes Hessianas garante robustez quanto a estruturas mal localizadas e alongadas, maior estabilidade se comparados a detectores de cantos de Harris, além de boa performance em termos de tempo computacional e taxas de acerto (BAY et al., 2006; BAY et al., 2008).

O uso das imagens integrais reduz drasticamente o tempo de computação devido aos filtros de convolução baseados em caixas. Por definição, cada elemento (x,y) de uma imagem integral representa a soma de todos os pixels da imagem original contidos na região retangular situada entre a origem e suas coordenadas (x, y). Diante disto, conforme ilustrado na Figura 7(a), o cálculo da soma dos pixels contidos em uma região qualquer requer apenas três operações de adição. Consequentemente, o tempo necessário para aplicar qualquer filtro à imagem permanece constante (independente de suas dimensões), todos os filtros são aplicados na imagem integral sem a necessidade de criar novas imagens por meio de interpolações, os componentes de alta frequência são preservados e poderão ser recuperados independentemente da escala corrente (BAY et al., 2006; BAY et al., 2008).

Após identificar a região de interesse e sua orientação, conforme Figura 7(b), o próximo passo consiste em calcular os valores do descritor. Para isso, conforme Figura 7(c), define-se uma região quadrada (8x8) centrada no ponto de interesse e alinhada com a orientação previamente identificada. Para cada um dos 64 elementos, obtém-se a resposta da wavelet de Haar nas direções x e y, denominadas respectivamente d_x e d_y . Para cada

sub-região 2×2 , d_x , d_y , $|d_x|$ e $|d_y|$ são acumuladas separadamente, gerando 16 conjuntos com as quatro características (Σd_x , Σd_y , $\Sigma |d_x|$ e $\Sigma |d_y|$), num total de 64 elementos. Ao final, como SIFT, geralmente são detectados centenas ou até milhares de pontos para a imagem. Todos estes pontos são invariantes à translação, escala e rotação, além de ser parcialmente invariante a mudanças de iluminação e projeções 3D e potencialmente candidatos a compor o conjunto de características que descreve a imagem (BAY et al., 2006; BAY et al., 2008).

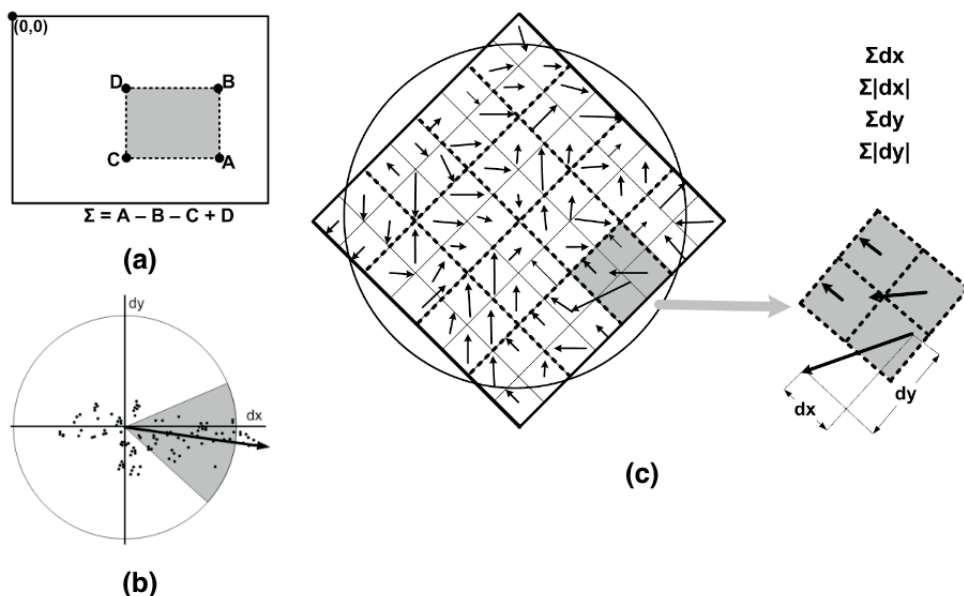


Figura 7: Processo de cálculo para o descritor SURF: (a) imagem integral; (b) janela deslizante de orientação com ângulo $\pi/3$; (c) aplicação da máscara 8×8 alinhada com a orientação identificada e obtenção dos gradientes para cada direção na região sobreposta da imagem (esquerda), seguido do acúmulo dos gradientes para cada sub-região (direita).

Fonte: Autoria própria (2020).

Os autores também apresentaram a variante SURF-128, a qual duplica o número de características que compõem o vetor final. Esta variante acumula d_x e $|d_x|$ separadamente para $d_y < 0$ e $d_y \geq 0$, sendo o mesmo considerado para d_y e $|d_y|$ de acordo com o sinal de d_x . Embora esta variação garanta descritores mais discriminantes, a maior dimensionalidade do vetor de características exige maiores recursos computacionais (BAY et al., 2006; BAY et al., 2008).

Seguindo o padrão de representação SURF, foram gerados vetores com 64 elementos para cada ponto identificado em cada imagem. Posteriormente, estes foram sumarizados por meio dos vetores com as representações dos quatro momentos estatísticos, gerando novos vetores com 64 elementos. Maiores detalhes quanto ao descritor SURF e a metodologia adotada para ele podem ser obtidos em Martins (2014).

2.4 Estatísticas de Adjacência de Limiar

Proposto por Hamilton *et al.* (2007), Estatísticas de Adjacência de Limiar (*Threshold Adjacency Statistics* - TAS) binariza a imagem considerando um subintervalo de intensidades a ser definido no intervalo $[0, 255]$. Para isso, TAS calcula a intensidade média μ dos pixels da imagem com intensidades de cinza acima de 30, sendo que pixels com intensidades abaixo de 30 são considerados como pertencentes ao fundo da imagem. Após o cálculo de μ , TAS binariza a imagem de tal forma que, os pixels com intensidades no intervalo $[\mu - 30, \mu + 30]$ são convertidos para branco e os demais para preto, tal como ilustra as imagens da Figura 8(a-b).

A partir da imagem binarizada na Figura 8(b), são calculadas nove estatísticas com base nos padrões apresentados na Figura 8(c). Para cada pixel branco, conta-se a quantidade de pixels brancos adjacentes (vizinhança-8). O primeiro padrão compreende a quantidade de pixels brancos sem vizinhos brancos; o segundo é definido pela quantidade de pixels brancos com apenas um vizinho branco; até chegar ao nono padrão que considera a quantidade de pixels brancos com todos os oito vizinhos também brancos.

As nove estatísticas são obtidas pela normalização das contagens anteriores com sua divisão pelo número total de pixels brancos na imagem binarizada. Dois outros conjuntos de TAS também são calculados como descrito previamente, mas para imagens binárias de limiar com pixels com intensidades nos intervalos $[\mu - 30, 255]$ e $[\mu, 255]$, culminando num total de 27 elementos no vetor de características finais.




Figura 8: TAS: (a) imagem original; (b) imagem binarizada; (c) padrões utilizados para o cálculo dos descritores.

Fonte: Hamilton *et al.* (2007, p. 4).

Neste trabalho, foi utilizada a implementação disponibilizada por COELHO (2013), por meio da biblioteca Mahotas, e imagens coloridas RGB. Diante disto, o conjunto final de elementos do vetor de características contém 162 atributos, pois são extraídos 27 atributos para a imagem binarizada e outros 27 atributos para sua inversa, para cada um dos três canais de cores.

3 | RESULTADOS E DISCUSSÃO

O Quadro 1 apresenta um resumo dos resultados obtidos, os quais serão discutidos considerando a acurácia média dos modelos como a métrica para comparação de desempenho dos classificadores construídos. Ao se analisar os algoritmos de aprendizagem de máquinas, exceto quando combinado com o GLCM, kNN obteve os piores resultados. Já tomando a perspectiva dos descritores, de forma geral, SURF apresentou o pior desempenho e TAS alcançou acurácias superiores aos demais.

Modelo		Acc	dp	Pr	Re	F1
Descritor	Alg. AM					
GLCM	kNN	53,3	5,4	59,5	54,7	52,7
	LinearSVC	58,9	15,0	60,9	59,9	58,5
	SVC	47,8	3,1	54,1	49,7	44,5
LBP	kNN	48,9	10,3	51,8	50,6	48,0
	LinearSVC	55,6	1,6	55,6	57,4	53,6
	SVC	52,2	11,0	53,2	54,1	52,1
SURF	kNN	40,0	7,2	51,6	42,7	40,2
	LinearSVC	41,2	8,3	40,1	41,6	39,0
	SVC	44,5	4,2	48,0	44,9	43,5
TAS	kNN	54,4	12,9	55,4	55,2	51,5
	LinearSVC	68,9	8,7	71,4	70,8	69,1
	SVC	73,3	7,2	76,5	75,0	73,4

Acc - Acurácia, Pr - Precisão, Re - Rechamada, e F1 - F1 score

Quadro 1: Resultados obtidos.

Fonte: Autoria própria (2020).

A combinação do descritor TAS e do algoritmo de classificação SVC obteve o melhor resultado geral, alcançando 73,3%, 76,5%, 75,0% e 73,4% para as métricas acurácia, precisão, rechamada e F1 score, respectivamente. Os resultados obtidos se mostraram bem interessantes, principalmente para o problema em questão, o qual envolve segurança e vidas humanas, além dos altos valores monetários envolvidos na construção e também manutenção das edificações.

4 | CONSIDERAÇÕES FINAIS

Este trabalho avaliou a aplicação de classificadores construídos a partir da combinação de diferentes descritores e algoritmos de aprendizagem de máquina. Nesta abordagem, o problema de identificação do nível de corrosão de barras de aço por meio de imagens do recobrimento de concreto, sendo que os melhores resultados foram alcançados pela combinação do descritor TAS e do algoritmo SVC, com acurácia de 73,3% (dp = 7,2).

Na sequência, serão avaliados novas alternativas para descritores, classificadores, estratégias de validação e também a seleção e combinação de modelos, com o intuito de

melhorar ainda mais os resultados. Possíveis alternativas foram apresentadas por Martins, Oliveira e Sabourin (2012), Martins (2014), Martins *et al.* (2015) e Spanhol (2018).

REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 6118**: Projeto de estruturas de concreto – Procedimento. Rio de Janeiro, 2014.

ANDRADE, J. J. de O. **Contribuição à previsão da vida útil das estruturas de concreto armado atacadas pela corrosão de armaduras**: iniciação por cloretos. Tese de Doutorado. Programa de Pós-Graduação Em Engenharia Civil (PPGEC). Universidade Federal do Rio Grande do Sul (UFRGS), 2001.

BAY, H.; TUYTELAARS, T.; e VAN GOOL, L. **SURF**: Speeded up robust features. In ECCV, 2006, p. 404-417.

BAY, H.; ESS, A.; TUYTELAARS, T.; e VAN GOOL, L. **Speeded-up robust features (SURF)**. Compute Vision. Image Understanding, v. 110, n. 3, 2008, p. 346-359.

BUENO, M. L. **Deteção de Bordas através de Algoritmo Canny**. Disponível em: <http://www.inf.ufsc.br/~aldo.vw/visao/2000/Bordas/index.htm>. Acesso em: 20 jan. 2020.

CASCUDO, O. **O Controle da Corrosão de Armaduras em Concreto**. Goiânia: PINI e UFG, 1997.

COELHO, L.P. **Mahotas**: Open source software for scriptable computer vision. Journal of Open Research Software 1, v. e3, p. 1-7, 2013.

CONNERS, R. W.; KLINE, D. E.; ARAMAN, P. A.; DRAYER, T. H. **Machine vision technology for the forest products industry**. Computer, v. 30, n. 7, p. 43-48, 1997.

CUNHA, M.; HELENE, P.; LOURENÇO, M. **Corrosão em estruturas de concreto armado**: teoria, controle e métodos de análise. Elsevier Brasil, 2013.

FIGUEIREDO, E. P.; MEIRA, G. **Corrosão das armaduras das estruturas de concreto**. Boletín Técnico 6. Asociación Latino americana de Control de Calidad, Patología y Recuperación de la Construcción. Mexico, 2012.

GU, P.; BEAUDOIN, J. J. **Obtaining effective half-cell potential measurements in reinforced concrete structures**. Construction Technology Update No. 18. National Research Council of Canada, Institute for Research in Construction. Ottawa, 1998.

HAMILTON, N.; PANTELIC, R.; HANSON, K.; TEASDALE, R. **Fast automated cell phenotype classification**. BMC bioinformatics, v. 8, p. 110, 2007.

HARALICK, R.M. **Statistical and structural approaches to texture**. v. 67, n. 5, p. 786-804, 1979.

LOPES, F. L. C.; MONTEIRO, M. D. S.; MELO, H. C. S.; SIQUEIRA, L. M.; LOPES, F. L. G. **Análise quantitativa da perda de massa por oxidação em barras de aço carbono CA-50**: uma proposta metodológica para a contextualização do estudo da corrosão em cursos de engenharia civil/IFS.

Simpósio De Engenharia De Produção De Sergipe, 10, São Cristóvão, SE, 2018. p. 440 - 452.

MÄENPÄÄ, T.; OJALA, T. PIETIKÄINEN, M.; SORIANO, M. **Robust texture classification by subsets of local binary patterns**. 15th International Conference on Pattern Recognition, p. 947-950, 2000.

MARTINS, J.G. **Identificação de Espécies Florestais utilizando Seleção Dinâmica de Classificadores no Espaço de Dissimilaridade**. Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba-PR, 2014.

MARTINS, J.G.; OLIVEIRA, L.E.S.; SABOURIN, R. **Combining textural descriptors for forest species recognition**. In IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society, p. 1483-1488, 2012.

MARTINS, J.G.; OLIVEIRA, L.E.S.; BRITTO, A. S.; SABOURIN, R. **Forest species recognition based on dynamic classifier selection and dissimilarity feature vector representation**. Machine Vision and Applications, v. 26, n. 2, p. 279-293, 2015.

MEHTA, P.K.; MONTEIRO, P. **Concreto: Microestrutura, Propriedades e Materiais**. 3.ed. São Paulo: IBRACON, 2008.

PEDRINI, H.; SCHWARTZ, W.R. **Análise de Imagens Digitais: princípios, algoritmos e aplicações**. São Paulo: Thomson Learning, 2008.

PHAM, D. T.; ALCOCK, R. J. **Automated visual inspection of birch wood boards**. IEE Colloquium on Artificial Intelligence in Manufacturing, p. 1-4, 1997.

PREFEITURA de SP interdita ponte que leva à Dutra pela Marginal Tietê. G1 SP, São Paulo - SP, 23 de jan. de 2019. Disponível em: <https://g1.globo.com/sp/sao-paulo/noticia/2019/01/23/prefeitura-de-sp-interdita-ponte-que-leva-a-dutra-pela-marginal-tiete.ghtml>. Acesso em: 20 de jun. de 2019.

RADOVAN, S.; GEORGE, P.; PANAGIOTIS, M.; MANOS, G.; ROBERT, A.; IGOR, D. **An approach for automated inspection of wood boards**. International Conference on Image Processing, 1, p. 798-801, 2001.

SILVA, M. V. F., PEREIRA, M. C., CODARO, E. N. **Corrosão do aço-carbono: uma abordagem do cotidiano no ensino de química**. Química Nova, v. 38, n. 2, p. 293-296. São Paulo, 2015.

SPANHOL, F. A. **Automatic Breast Cancer Classification From Histopathological Images: A Hybrid Approach**. Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba-PR, 2018.

TOU, J.Y.; LAU, P.Y.; TAY, Y.H. **Computer vision-based wood recognition system**. Intern. Workshop on Advanced Image Techn., p. 197-202, 2007.

VIADUTO da Galeria dos Estados desaba e abre cratera no Eixão Sul. Correio Braziliense, Brasília - DF, 06 de fev. de 2018. Disponível em: https://www.correio braziliense.com.br/app/noticia/cidades/2018/02/06/interna_cidadesdf,658118/parte-do-viaduto-da-galeria-dos-estados-desaba-no-centro-de-brasilia.shtml. Acesso em: 20 de jun. de 2019.

VISÃO COMPUTACIONAL APLICADA NA IDENTIFICAÇÃO DOS NÍVEIS DE DETERIORAÇÃO DE BARRAS DE AÇO POR MEIO DE IMAGENS

Data de aceite: 01/03/2021

Jefferson Gustavo Martins

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2102993901875277>

Alessandra Iolanda Pacheco dos Santos

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7255176749334236>

Eduarda Simonis Gavião

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7977085762352521>

Guilherme Dias Almanza

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7691365391625214>

Kelly Chapla

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/5977440276620782>

Marcos Vinicius Schlichting

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/1152652374544629>

Wilson Leobet

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2563896946139465>

Fabio Alexandre Spanhol

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/4381300863323095>

RESUMO: Especialistas humanos têm sido amplamente auxiliados por sistemas computacionais que trabalham com reconhecimento de padrões. Tal ajuda é muito importante em processos caracterizados como repetitivos, monótonos e demorados, que demandam altos níveis de experiência e cujos resultados estão sujeitos a fatores físicos e subjetivos. Este artigo apresenta uma proposta para identificar diferentes níveis de deterioração em barras de aço por meio de imagens e ferramentas amplamente utilizados na área de aprendizagem de máquina. As melhores taxas de acerto compreendem 79,2% usando o descritor LBP e algoritmo de aprendizagem de máquinas SVM.

PALAVRAS-CHAVE: Construção civil. Defesa civil. Segurança pública. Automação.

COMPUTER-VISION APPLIED FOR IDENTIFICATION OF DETERIORATION LEVELS IN STEEL BARS BY USING IMAGES

ABSTRACT: Human specialists have been widely assisted by computer systems that apply pattern recognition. They are helpful for problems in which there are repetitive, monotonous and time-consuming tasks, demand high levels of experience, and their results can be influenced by physical and subjective aspects. This paper presents a proposal to identify different levels of

deterioration in steel bars using images and a widely set of tools used in the machine learning area. The best achieved recognition rates are 79.2% by using the LBP descriptor and SVM machine learning algorithm.

KEYWORDS: Construction. Civil defense. Public security. Automation.

1 | INTRODUÇÃO

A corrosão das armaduras é um dos principais problemas relacionados a degradação de estruturas de concreto armado no mundo, chegando a envolver até 50% dos recursos financeiros investidos em construção civil para a reabilitação de estruturas degradadas (MEHTA; MONTEIRO, 2008). Segundo Cunha, Helene e Lourenço. (2013), tal problema consome direta ou indiretamente uma parcela significativa do produto interno bruto (PIB) de uma nação industrializada (algo em torno de 3% a 4%).

Além dos custos envolvidos devido a degradação destas estruturas, o risco em termos de colapsos estruturais merece atenção, pois podem provocar danos corporais e mortes. Nos últimos anos, têm sido recorrentes os casos de colapsos de estruturas devido à corrosão de armaduras. Para citar dois casos de grande repercussão na mídia nacional, destacam-se o colapso parcial de um viaduto na cidade de Brasília em 2018 (VIADUTO, 2018) e a interdição do acesso à Rodovia Presidente Dutra, na cidade de São Paulo em 2019 (PREFEITURA, 2019).

Entende-se que são necessários estudos para que se alcance um melhor entendimento dos processos de degradação de estruturas devido à corrosão, tal que se consiga edificar estruturas mais seguras e duráveis. Muitos dos problemas relacionados à corrosão das armaduras têm relação com as características do concreto. Este propicia uma proteção física por meio da separação do aço e do meio externo, bem como uma proteção química decorrente do elevado pH da solução presente nos poros do concreto. Ainda quanto à proteção química, ocorre a formação de uma película passivadora envolvendo o aço no interior do concreto (FIGUEIREDO; MEIRA, 2012).

Basicamente, a corrosão é caracterizada pela deterioração de um metal (ou liga) a partir do contato de sua superfície com o meio no qual este esteja inserido. O processo envolve reações de oxidação e de redução (redox) que convertem o metal ou componente metálico em óxidos ou hidróxidos expansivos (SILVA; PEREIRA; CODARO, 2015). Dentre os fatores que influenciam o processo de corrosão do aço imerso no concreto estão: o coeficiente de difusão do concreto, a relação água/cimento, a espessura de cobrimento, a presença e a quantidade de adições, a umidade relativa, o pH do concreto e a temperatura de exposição (ANDRADE, 2001; GU; BEAUDOIN, 1998).

As Figuras 1 e 2 ilustram a ação da corrosão, a partir da qual se tem a perda de seção na região anódica devido à dissolução do ferro (Figura 1). Comumente, identifica-se a ocorrência das duas situações concomitantemente (Figura 2): fissuras acompanhadas de manchas corrosivas (CASCUDO, 1997). A perda de seção provoca a redução de aderência entre aço e concreto, a redução da capacidade estrutural da peça e externamente o surgimento de manchas. Caso o concreto esteja muito úmido, os óxidos serão gerados a uma velocidade constante e podem emigrar através da rede de poros, aparecendo na

superfície sob a forma de manchas marrom-avermelhadas, mas não apresentando fissuras, Figura 2(a). As tensões internas expansivas provenientes dos produtos da corrosão (situados na região anódica) provoca a deterioração da ferragem e o destacamento da camada de cobrimento, tal como ilustra as imagens da Figura 2(b-c) (ANDRADE, 2001; LOPES *et al.*, 2018).



Figura 1: Barra de aço: (a) original; (b) perda de seção devido à corrosão.

Fonte: Autoria própria (2020).




Figura 2: Efeitos da corrosão na camada de cobrimento de concreto: (a) manchas; (b) fissuras e rachaduras; (c) destacamento total.

Fonte: Autoria própria (2020).

Ao observar o estado de corrosão, pode-se identificar fissuras paralelas às armaduras; fragmentação e destacamento do cobrimento e, no estado avançado, o lascamento do concreto. A presença de indicações externas do processo corrosivo normalmente determina que parte da armadura já se encontra comprometida (ABNT, 2014). Além disso, a maior parte das inspeções são realizadas visualmente por especialistas humanos e demandam altos níveis de experiência (ABNT, 2014).

A partir do cenário apresentado, este artigo realizou uma investigação quanto à aplicação de ferramentas computacionais para identificar níveis de deterioração em barras de aço por meio de imagens. A principal contribuição do trabalho consiste em apresentar uma alternativa para aliviar a sobrecarga do profissional que realiza a inspeção e que está sujeito a possíveis distrações e baixas taxas de acerto. Tal cenário decorre de fatores inerentes ao ser humano, tal como a subjetividade e as características do processo (repetitivo, monótono e demorado), além de requerer alto grau de concentração (CONNERS *et al.*, 1997; PHAM; ALCOCK, 1997; RADOVAN *et al.*, 2001).

2 | MATERIAIS E MÉTODOS

Sistemas computacionais voltados para a área de reconhecimento de padrões contemplam as seguintes etapas: aquisição, pré-processamento, segmentação, extração de características e classificação. Cada etapa constitui um diferente contexto, possui

diferentes níveis de complexidade e envolve conhecimentos específicos e próprios, além daqueles inerentes ao domínio da aplicação.

Diante da importância do tema, diferentes trabalhos têm sido desenvolvidos, inclusive a partir da base de imagens aqui utilizada. Tal fato implica na execução das etapas já apresentadas utilizando diferentes ferramentais, mas ainda considerando o foco de cada uma delas em sua essência.

A construção da base de imagens envolveu 24 (vinte e quatro) amostras, sendo que 6 (seis) delas formando o grupo de controle (referências isentas de corrosão) e outros três grupos de seis barras foram submetidos a processos de aceleração de corrosão por períodos de 24, 48 e 72 horas (Figura 3).




Figura 3: Processo de construção da base de imagens: (a) barra original; (b) corpo de concreto envolvendo a barra original; (c) corpo de concreto envolvendo a barra após 28 dias de cura do concreto; (d-f) corpos de concreto envolvendo a barra após o processo de aceleração (respectivamente 24, 48 e 72 horas); (g-i) barras retiradas dos corpos de concreto após o processo de aceleração (respectivamente 24, 48 e 72 horas).

Fonte: Autoria própria (2020).

Para a construção da base de imagens foram utilizadas barras de aço da marca Gerdau com 12,5 mm de diâmetro. Cada amostra é caracterizada por um comprimento com aproximadamente 25 cm, sendo que todas foram obtidas de barras pertencentes a um mesmo lote de fabricação, tal como ilustrado na Figura 3(a). O segundo passo compreendeu o recobrimento de 2 cm dos corpos de prova de aço com concreto para simular o contexto real das estruturas nas edificações, conforme apresentado na Figura 3(b). O traço de concreto utilizado tinha a proporção 1 : 1,49 : 2,77 : 0,65 (Cimento : Areia : Brita : Água). Cada amostra tinha 10 cm de suas extremidades cobertas por fita isolante para garantir que a corrosão ocorresse apenas na parte central da amostra. Um fio elétrico foi conectado às barras com o objetivo de permitir o ensaio de aceleração da corrosão. Depois, a amostra foi inserida em um cano de PVC com diâmetro nominal de 50 mm e 25 cm de comprimento. Este cano de PVC foi preenchido com concreto de tal forma que a cobertura se mantivesse homogênea em termos de espessura da camada de cobertura (2 cm). As amostras permaneceram sob cura por 28 dias para o processo de hidratação do cimento, Figura 3(c). Seguiu-se com o processo de aceleração de corrosão das amostras com os corpos de concreto parcialmente imersos em um tanque de água com 3,5% (concentração próxima a água do mar) de cloreto de sódio (NaCl) e submetidos ao ensaio de aceleração da corrosão

através da condução de eletricidade. Os três grupos de corpos de concreto foram mantidos por três diferentes períodos de tempo no tanque, sendo estes 24, 48 e 72 horas, Figura 3(d-f), o que gerou diferentes níveis de corrosão, Figura 3(g-i).

Depois de cessado o processo de aceleração de corrosão, os corpos de concreto, bem como as barras internas depois de extraídas e limpas com solução ácida, foram submetidos a uma coleta de imagens para compor a base. Para cada amostra de barra, foram capturadas 5 (cinco) imagens abrangendo a diferentes perspectivas da superfície dos corpos de concreto e também da barra depois de extraída, num total de 120 imagens para cada caso. No presente estudo foram consideradas as imagens relativas às barras, Figura 3(g-i).

A Figura 4 ilustra os resultados das etapas de pré-processamento e segmentação, sendo que a primeira aplica operações para realçar as características importantes no processo de diferenciação das classes existentes no problema. Nesta etapa, utilizou-se principalmente da biblioteca OpenCV para converter a base toda em escala de cinza, conforme ilustração das imagens da Figura 4(a-b).

A segmentação é ilustrada pelo par de imagens da Figura 4(c-d). Esta compreende a próxima etapa do processo e busca separar apenas a região de interesse da imagem original e da qual depende o sucesso de um modelo de identificação ou de classificação. Nesta etapa, buscou-se por uma imagem que estivesse toda formada pela área de interesse, tal como ilustrado nas imagens da Figura 4(c-d).




Figura 4: Processo de reconhecimento de padrões: (a) barra após o processo de aceleração; (b) pré-processamento com conversão para níveis de cinza; (c-d) segmentação.

Fonte: Autoria própria (2020).

Para a segmentação, foram utilizados a técnica de limiarização para destacar os objetos na imagem, o algoritmo de detecção de bordas Canny (BUENO, 2020) para ressaltar os contornos das bordas destes objetos e a função *findContours* da biblioteca OpenCV para identificar os pontos que pertenciam a tais contornos. Esta função retorna os pontos que formam os contornos de todos os possíveis objetos presentes na imagem, os quais são caracterizados por qualquer região com contraste em relação a seu entorno. A partir da identificação dos possíveis objetos, os pontos pertencentes ao maior contorno com a definição da barra de aço foram selecionados. Ao final, recortou-se e salvou-se a área de interesse em uma nova imagem, tal como ilustrado nas imagens da Figura 4(c-d).

A etapa de Extração de Características busca representar a imagem por meio de um vetor numérico de medidas. Nesta etapa foram utilizados os descritores LBP (*Local Binary Pattern*) e SURF (*Speed-Up Robust Feature*), os quais são descritos nas seções seguintes.

Nesta etapa de classificação foi utilizado o algoritmo Máquinas de Vetores de Suporte (*Support Vector Machine* - SVM), por meio da implementação LibSVM 3.2 disponibilizada no endereço eletrônico <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>. Dentre as possibilidades disponibilizadas pela biblioteca, os melhores resultados foram obtidos com a função de base radial Gaussiana e uma busca gulosa para encontrar os melhores parâmetros C e γ , numa tentativa de identificar o melhor arranjo e otimizar as taxas finais de reconhecimento. A normalização dos dados considerou a escala linear de cada atributo dos vetores de características no intervalo [-1,+1].

Para a definição dos conjuntos de treinamento e teste, dividiu-se a base de imagens em 3 partes (folds), os quais mantinham a representatividade das classes pertencentes ao problema em questão. Foram realizadas 3 execuções, sendo que em cada execução uma parte era usada como conjunto de teste e os outros dois eram utilizados como conjunto de treinamento. Os resultados finais são expressos pela média e desvio padrão das taxas de classificações corretas das três execuções.

Neste trabalho foi considerada a métrica acurácia, caracterizada pela razão entre as predições corretas totais e o número de amostras. A métrica foi calculada para cada fold. A partir destes valores individuais foram calculadas a média e o desvio padrão (dp).

2.1 Padrão Binário Local

Classificado como um método estrutural, o Padrão Binário Local (*Local Binary Pattern* - LBP) foi introduzido, em 1996, como uma medida complementar para contraste local de uma imagem em níveis de cinza, sendo definido como invariante a mudanças monotônicas dos níveis de cinza. Em sua versão original, LBP considera uma vizinhança-8 e distância um para o pixel central (x_c, y_c) de uma máscara com dimensões 3x3, tal como ilustrado na Figura 5(a) (MÄENPÄÄ *et. al.*, 2000).

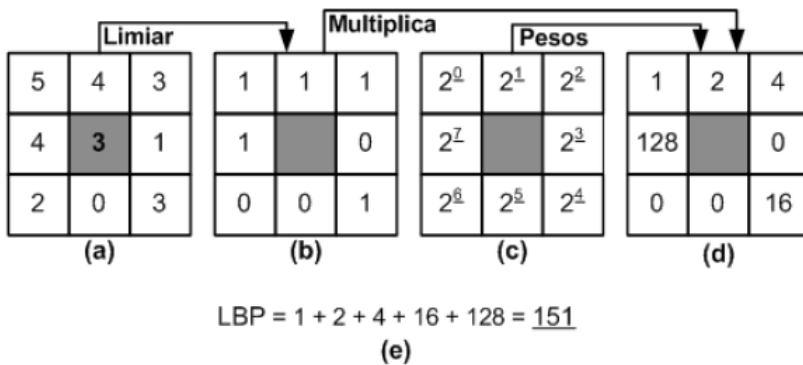


Figura 5: Cálculo do padrão LBP.

Fonte: Martins (2014, p. 34).

Cada ponto da imagem é tomado como sendo o ponto central (x_c, y_c), cujo valor é utilizado como limiar na comparação com o conteúdo de cada um de seus vizinhos (x_i, y_i). Desta comparação gera-se uma cadeia de zeros e uns, Figura 5(b), pois cada vizinho assume o valor um se seu conteúdo for maior que o do ponto central (x_c, y_c) e zero caso

contrário. A organização dessa cadeia considera a posição relativa j de cada um dos vizinhos, iniciando do canto superior-esquerdo com valor zero e circundando o ponto central no sentido anti-horário (Figura 5(c)). Ao ser tomada como uma representação em base dois e convertida para a base dez, tem-se o padrão que representa a região sobreposta pela máscara, Figura 5(d-e) (MÄENPÄÄ *et. al.*, 2000).

Após gerar os padrões para todos os pontos da imagem, as frequências destes padrões são contabilizadas por meio de um histograma com um total de 2^P padrões para P vizinhos. A consideração de $P = 8$, Figura 5(a), gera um total de 256 padrões de transição de bits, Figura 5(b). Dentre estes padrões, apenas 58 atendem a definição de uniformidade, isto é, a ocorrência de, no máximo, duas transições do valor zero para um e vice-versa. Todos os demais padrões são contabilizados juntos, levando a um total de 59 valores para o descritor denominado LBP uniforme (LBP^{u2}).

2.2 Características Robustas Aceleradas

Proposto por Bay *et al.* (2006), Características Robustas Aceleradas (*Speed-Up Robust Feature* - SURF) apresenta semelhanças ao SIFT e permite detecção e descrição de regiões de interesse. Porém, este reduz a alta dimensionalidade e custo computacional do descritor SIFT, pois possui a metade do número de elementos do SIFT e é baseado em matrizes Hessianas e no conceito de imagens integrais. O uso de determinantes de matrizes Hessianas garante robustez quanto a estruturas mal localizadas e alongadas, maior estabilidade se comparados a detectores de cantos de Harris, além de boa performance em termos de tempo computacional e taxas de acerto (BAY *et al.*, 2006; BAY *et al.*, 2008).

O uso das imagens integrais reduz drasticamente o tempo de computação devido aos filtros de convolução baseados em caixas. Por definição, cada elemento (x,y) de uma imagem integral representa a soma de todos os pixels da imagem original contidos na região retangular situada entre a origem e suas coordenadas (x, y) . Diante disto, conforme ilustrado na Figura 6(a), o cálculo da soma dos pixels contidos em uma região qualquer requer apenas três operações de adição. Consequentemente, o tempo necessário para aplicar qualquer filtro à imagem permanece constante (independente de suas dimensões), todos os filtros são aplicados na imagem integral sem a necessidade de criar novas imagens por meio de interpolações, os componentes de alta frequência são preservados e poderão ser recuperados independentemente da escala corrente (BAY *et al.*, 2006; BAY *et al.*, 2008).

Após identificar a região de interesse e sua orientação, conforme Figura 6(b), o próximo passo consiste em calcular os valores do descritor. Para isso, conforme Figura 6(c), define-se uma região quadrada (8×8) centrada no ponto de interesse e alinhada com a orientação previamente identificada. Para cada um dos 64 elementos, obtém-se a resposta da wavelet de Haar nas direções x e y , denominadas respectivamente d_x e d_y . Para cada sub-região 2×2 , d_x , d_y , $|d_x|$ e $|d_y|$ são acumuladas separadamente, gerando 16 conjuntos com as quatro características $(\sum d_x, \sum d_y, \sum |d_x|$ e $\sum |d_y|)$, num total de 64 elementos. Ao final, como SIFT, geralmente são detectados centenas ou até milhares de pontos para a imagem. Todos estes pontos são invariantes à translação, escala e rotação, além de ser parcialmente invariante a mudanças de iluminação e projeções 3D e potencialmente candidatos a compor o conjunto de características que descreve a imagem (BAY *et al.*,

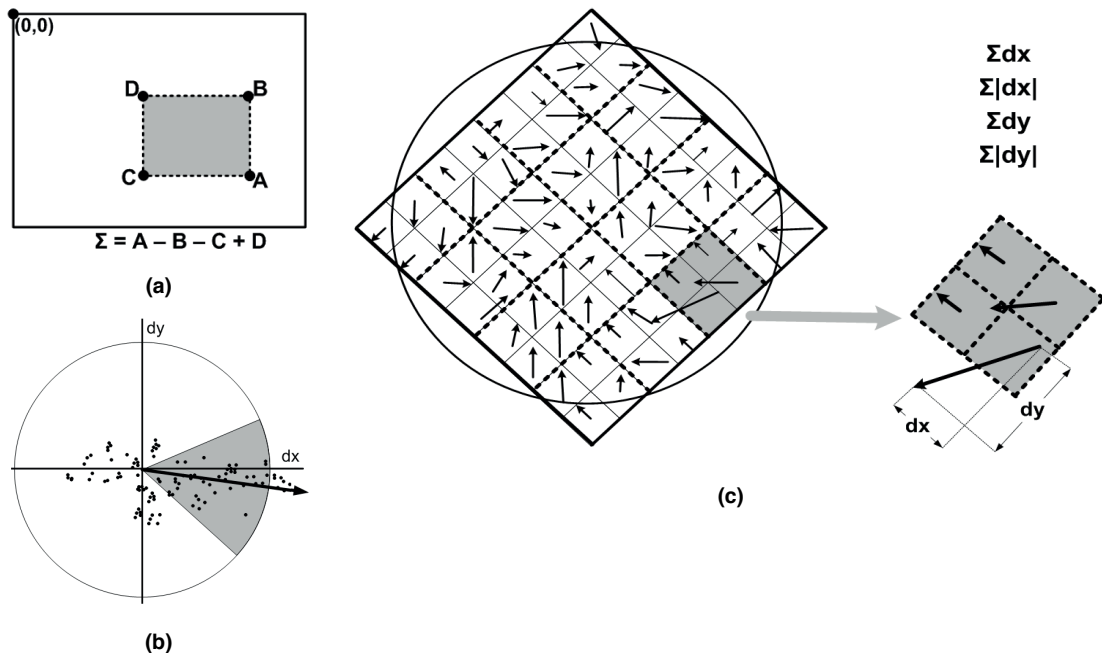


Figura 6: Processo de cálculo para o descritor SURF: (a) imagem integral; (b) janela deslizante de orientação com ângulo $\pi/3$; (c) aplicação da máscara 8x8 alinhada com a orientação identificada e obtenção dos gradientes para cada direção na região sobreposta da imagem (esquerda), seguido do acúmulo dos gradientes para cada subregião (direita).

Fonte: Autoria própria (2020).

Os autores também apresentaram a variante SURF-128, a qual duplica o número de características que compõem o vetor final. Esta variante acumula d_x e $|d_x|$ separadamente para $d_y < 0$ e $d_y \geq 0$, sendo o mesmo considerado para d_y e $|d_y|$ de acordo com o sinal de d_x . Embora esta variação garanta descritores mais discriminantes, a maior dimensionalidade do vetor de características exige maiores recursos computacionais (BAY *et al.*, 2006; BAY *et al.*, 2008).

Seguindo o padrão de representação SURF, foram gerados vetores com 64 elementos para cada ponto identificado em cada imagem. Posteriormente, estes foram sumarizados por meio dos vetores com as representações dos quatro momentos estatísticos, gerando novos vetores com 64 elementos. Maiores detalhes quanto ao descritor SURF e a metodologia adotada para ele podem ser obtidos em Martins (2014).

3 | RESULTADOS E DISCUSSÃO

O Quadros 1 e 2 apresentam os resultados obtidos, isto é, a média e desvio padrão (dp) das taxas de classificações corretas das três execuções utilizando variações dos descritores LBP e SURF. As taxas de classificações corretas de cada execução são obtidas

pela razão entre as predições corretas totais e o número total de amostras.

Versão do LBP	P	R	Média	dp
riu2	8	1	69,2	4,7
	8	2	73,3	6,2
	16	2	79,2	2,4
	24	3	72,5	8,2
u2	8	1	35,8	20,9
	8	2	67,5	12,4
	16	2	50,8	26,3
	24	3	52,5	22,5

Quadro 1: Taxas de classificações corretas para o Descritor LBP.

Fonte: Autoria própria (2020).

Versão do SURF	Medida	Média	dp
64	# Pontos	52,5	2,0
	Média	61,7	2,4
	Variância	70,8	1,2
	Obliquidade	47,5	15,9
	Curtose	46,7	9,4
128	# Pontos	52,5	2,0
	Média	58,3	7,7
	Variância	61,7	6,6
	Obliquidade	49,2	17,8
	Curtose	34,2	13,0

Quadro 2: Taxas de classificações corretas para o Descritor LBP.

Fonte: Autoria própria (2020).

Do Quadro 1 tem-se que o melhor resultado dentre as variações do descritor LBP foi obtido por LBPriu2, a qual alcançou 79,2% (dp = 2,4), tendo sido esta a melhor taxa de reconhecimento geral. Já do Quadro 2, tem-se a taxa de 70,8% (dp = 1,2) para a variante do SURF com 64 atributos e momento estatístico Desvio Padrão. Tais taxas de reconhecimento se mostram bastante interessantes diante das dificuldades que um especialista enfrenta ao tentar identificar visualmente o nível de corrosão nas barras, conforme ilustrado na Figura 7, a seguir.

4 | CONSIDERAÇÕES FINAIS

Este trabalho abordou o problema de identificação do nível de corrosão de barras de aço por meio de imagens, sendo que os melhores resultados foram alcançados pelo descritor LBPriu2, com acurácia de 79,2% (dp = 2,4).

Na sequência, serão avaliados novas alternativas para descritores, classificadores,

estratégias de validação e também a seleção e combinação de modelos, com o intuito de melhorar ainda mais os resultados. Possíveis alternativas foram apresentadas por Martins, Oliveira e Sabourin (2012), Martins (2014), Martins *et al.* (2015) e Spanhol (2018).




Figura 7: Exemplos de barras retiradas dos corpos de concreto após o processo de aceleração: ampliação das imagens da Figura 3(g-i), retiradas dos corpos de concreto após o processo de aceleração (respectivamente 24, 48 e 72 horas).

Fonte: Autoria própria (2020).

REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 6118**: Projeto de estruturas de concreto – Procedimento. Rio de Janeiro, 2014.

ANDRADE, J. J. de O. **Contribuição à previsão da vida útil das estruturas de concreto armado atacadas pela corrosão de armaduras**: iniciação por cloretos. Tese de Doutorado. Programa de Pós-Graduação Em Engenharia Civil (PPGEC). Universidade Federal do Rio Grande do Sul (UFRGS), 2001.

BAY, H.; TUYTELAARS, T.; e VAN GOOL, L. **SURF**: Speeded up robust features. In ECCV, 2006, p. 404-417.

BAY, H.; ESS, A.; TUYTELAARS, T.; e VAN GOOL, L. **Speeded-up robust features (SURF)**. Compute Vision. Image Understanding, v. 110, n. 3, 2008, p. 346-359.

BUENO, M. L. **Deteção de Bordas através de Algoritmo Canny**. Disponível em: <http://www.inf.ufsc.br/~aldo.vw/visao/2000/Bordas/index.htm>. Acesso em: 20 jan. 2020.

CASCUDO, O. **O Controle da Corrosão de Armaduras em Concreto**. Goiânia: PINI e UFG, 1997.

CONNERS, R. W.; KLINE, D. E.; ARAMAN, P. A.; DRAYER, T. H. **Machine vision technology for the forest products industry**. Computer, v. 30, n. 7, p. 43-48, 1997.

CUNHA, M.; HELENE, P.; LOURENÇO, M. **Corrosão em estruturas de concreto armado**: teoria, controle e métodos de análise. Elsevier Brasil, 2013.

FIGUEIREDO, E. P.; MEIRA, G. **Corrosão das armaduras das estruturas de concreto**. Boletín Técnico 6. Asociación Latino americana de Control de Calidad, Patología y Recuperación de la Construcción. Mexico, 2012.

GU, P.; BEAUDOIN, J. J. **Obtaining effective half-cell potential measurements in reinforced concrete structures**. Construction Technology Update No. 18. National Research Council of Canada, Institute for Research in Construction. Ottawa, 1998.

LOPES, F. L. C.; MONTEIRO, M. D. S.; MELO, H. C. S.; SIQUEIRA, L. M.; LOPES, F. L. G. **Análise quantitativa da perda de massa por oxidação em barras de aço carbono CA-50**: uma proposta metodológica para a contextualização do estudo da corrosão em cursos de engenharia civil/IFS. Simpósio De Engenharia De Produção De Sergipe, 10, São Cristóvão, SE, 2018. p. 440 - 452.

MÄENPÄÄ, T.; OJALA, T. PIETIKÄINEN, M.; SORIANO, M. **Robust texture classification by subsets of local binary patterns**. 15th International Conference on Pattern Recognition, p. 947-950, 2000.

MARTINS, J.G. **Identificação de Espécies Florestais utilizando Seleção Dinâmica de Classificadores no Espaço de Dissimilaridade**. Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba-PR, 2014.

MARTINS, J.G.; OLIVEIRA, L.E.S.; SABOURIN, R. **Combining textural descriptors for forest species recognition**. In IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society, p. 1483-1488, 2012.

MARTINS, J.G.; OLIVEIRA, L.E.S.; BRITTO, A. S.; SABOURIN, R. **Forest species recognition based on dynamic classifier selection and dissimilarity feature vector representation**. Machine Vision and Applications, v. 26, n. 2, p. 279-293, 2015.

MEHTA, P.K.; MONTEIRO, P. **Concreto**: Microestrutura, Propriedades e Materiais. 3.ed. São Paulo: IBRACON, 2008.

PHAM, D. T.; ALCOCK, R. J. **Automated visual inspection of birch wood boards**. IEE Colloquium on Artificial Intelligence in Manufacturing, p. 1-4, 1997.

PREFEITURA de SP interdita ponte que leva à Dutra pela Marginal Tietê. G1 SP, São Paulo - SP, 23 de jan. de 2019. Disponível em: <https://g1.globo.com/sp/sao-paulo/noticia/2019/01/23/prefeitura-de-sp-interdita-ponte-que-leva-a-dutra-pela-marginal-tiete.ghtml>. Acesso em: 20 de jun. de 2019.

RADOVAN, S.; GEORGE, P.; PANAGIOTIS, M.; MANOS, G.; ROBERT, A.; IGOR, D. **An approach for automated inspection of wood boards**. International Conference on Image Processing, 1, p. 798-801, 2001.

SILVA, M. V. F., PEREIRA, M. C., CODARO, E. N. **Corrosão do aço-carbono**: uma abordagem do cotidiano no ensino de química. Química Nova, v. 38, n. 2, p. 293-296. São Paulo, 2015.

SPANHOL, F. A. **Automatic Breast Cancer Classification From Histopathological Images: A Hybrid Approach**. Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba-PR, 2018.

VIADUTO da Galeria dos Estados desaba e abre cratera no Eixão Sul. Correio Braziliense, Brasília - DF, 06 de fev. de 2018. Disponível em: https://www.correiobrasiliense.com.br/app/noticia/cidades/2018/02/06/interna_cidadesdf,658118/parte-do-viaduto-da-galeria-dos-estados-desaba-no-centro-de-brasilia.shtml. Acesso em: 20 de jun. de 2019.

CLASSIFICAÇÃO DE IMAGENS HISTOPATOLÓGICAS DE CÂNCER DE MAMA USANDO PEQUENAS SUBIMAGENS SELECIONADAS

Data de aceite: 01/03/2021

Fabio Alexandre Spanhol

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/4381300863323095>

Jefferson Gustavo Martins

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/2102993901875277>

Henrique Frederico Trentini

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/5157100268968776>

Gabriel Fernando Ferrazoli

Universidade Tecnológica Federal do Paraná -
UTFPR
Toledo - PR
<http://lattes.cnpq.br/7464970630930721>

RESUMO: Neste trabalho foram realizados experimentos com a base de imagens BreakHis aplicando uma rede neural convolucional (CNN) para classificar imagens histopatológicas em tumores benignos ou malignos (câncer). Evitando a necessidade de executar uma segmentação explícita das imagens, este método é baseado na extração de várias pequenas subimagens (patches) aleatórias para treinamento e na combinação dessas subimagens para reconhecimento. Visando aumentar o desempenho do modelo classificador foi proposta uma abordagem consistindo em

previamente selecionar subimagens que sejam mais representativas de cada classe, permitindo assim discriminar melhor entre padrões malignos e benignos. Os resultados alcançados pela abordagem de filtragem pré-treinamento da CNN mostraram um ganho na acurácia para os dois maiores fatores de aumento disponíveis no conjunto de imagens, 200x e 400x.

PALAVRAS-CHAVE: Câncer de mama. Imagem histopatológica. Reconhecimento de padrões. Rede neural convolucional.

BREAST CANCER HISTOPATHOLOGICAL IMAGE CLASSIFICATION USING SELECTED SMALL PATCHES

ABSTRACT: In this work, it was conducted experiments on the BreakHis dataset using a convolutional neural network (CNN) to classify histopathological images into benign tumors or malign tumors (cancer). Avoiding the necessity of performing an explicit segmentation of the images, this method is based on the extraction of several small random subimages (patches) for training, and the combination of these subimages for recognition. In order to increase the performance of the classifier model, an approach was proposed consisting of previously selecting sub-images that are more representative of each class, thus letting better discrimination between malignant and benign patterns. The results achieved by CNN's pre-training filtering approach showed a gain in accuracy for the two highest magnification factors available in the set of images, 200x and 400x.

KEYWORDS: Breast cancer. Histopathologic image. Pattern recognition. Convolutional neural network.

1 | INTRODUÇÃO

Apesar dos notáveis avanços em seu diagnóstico e tratamento, o câncer continua constituindo um massivo problema de saúde pública em todo mundo. Fatores como o envelhecimento populacional e a adoção de hábitos não saudáveis — antes restritos aos países industrializados — estão contribuindo para o avanço da incidência dessa doença. Somente na última década, houve um crescimento de 20% nos casos de câncer no mundo, segundo o *World Cancer Research Fund* (WCRF, 2020) e até 2030 projeta-se 27 milhões de novos casos de câncer (Boyle; Levin, 2008). Considerados todos os tipos, o câncer é a segunda causa mais comum de mortes em países desenvolvidos e recentemente está tomando o lugar das doenças cardíacas como a principal causa de morte nos países ocidentais (KUMAR *et al.*, 2013). Dados da *International Agency for Research on Cancer* (IARC), da Organização Mundial de Saúde (OMS), confirmam um número global de 9,5 milhões de mortes por câncer em 2018 (BRAY *et al.*, 2018). Além disso, a OMS também projeta 16 milhões de mortes por câncer de 2018 até 2040, sendo os países em desenvolvimento os mais atingidos (BRAY *et al.*, 2018).

No Brasil, o câncer também é um problema de saúde extremamente preocupante. Estimativas do Ministério da Saúde (MS) e do Instituto Nacional do Câncer José Alencar Gomes da Silva (INCA) apontam que 625 mil novos casos de câncer diagnosticados para o triênio 2020-2022 (INCA, 2020). Destes, a maior incidência está nos cânceres de pele (177 mil casos), de próstata (66 mil), de mama (66 mil), cólon e reto (41 mil), pulmão (30 mil) e estômago (21 mil) (INCA, 2020). Dentre todos os tipos de câncer, excluindo o câncer de pele, o câncer de mama é o segundo mais comum entre as mulheres (BRAY *et al.*, 2018). Embora o câncer de mama ainda seja mais prevalente nas regiões mais desenvolvidas, a mortalidade é relativamente maior nos países menos desenvolvidos devido a dificuldade de diagnóstico precoce e restrições enfrentadas pelas mulheres no acesso aos avanços clínicos de combate à doença.

A detecção e o diagnóstico do câncer de mama podem ser feitos através de métodos não invasivos e biópsia. Métodos não invasivos são basicamente procedimentos de imagem: mamografia (raios-x), imagem por ressonância magnética (MRI) das mamas, ultrassom (sonografia) e termografia. Apesar do uso de técnicas de imagem para diagnóstico do câncer estar difundido, a biópsia é único meio de informar, com segurança, se o câncer está realmente presente. Dentre as técnicas de biópsia, destacam-se procedimentos como aspiração por agulha fina (FNA), biópsia de agulha grossa (CNB), biópsia mamária assistida à vácuo (VABB) e biópsia cirúrgica (SOB) (KUMAR *et al.*, 2013). Os procedimentos de biópsia coletam amostras de células ou tecido. Tais amostras devem ser fixadas em uma lâmina para microscopia para a subsequente coloração e análise microscópica das chamadas imagens histopatológicas. Os médicos patologistas usam os benefícios de uma ampla variedade de corantes para obter informações úteis sobre as lesões e a composição dos tecidos. Na Figura 1 é mostrada a imagem de um tumor mamário maligno (câncer) visto sob o microscópio. Nota-se as estruturas celulares evidenciadas pela hematoxilina e eosina (HE), uma combinação de corantes usada “rotineiramente” em amostras de tecido para revelar as estruturas subjacentes e sua condição (HERRINGTON, 2014). Em resumo, o diagnóstico a partir de imagens histopatológicas permanece sendo o “padrão-ouro” para

diagnosticar a maioria dos tipos de câncer, incluindo o câncer de mama (RUBIN *et al.*, 2012).




Figura 1: Detalhe de uma seção de carcinoma ductal corada com HE (aumento de 100x).

Fonte: SPANHOL (2018).

Apesar da relevância, a análise patológica ainda é bastante manual e subjetiva, dependente do especialista humano. Dado o crescente volume de casos a serem avaliados, principalmente de câncer, almeja-se que sistemas automatizados possam auxiliar o patologista na tarefa de classificação dessas doenças em menor tempo e com maior acurácia no diagnóstico. Neste contexto, considerando o impacto do câncer na saúde pública, especialmente o câncer de mama pela incidência e letalidade na população feminina, somado a urgência de prover ferramentas de suporte ao patologista, propomos um modelo de classificador que possa identificar o câncer de mama através da análise de imagens digitalizadas de lâminas histopatológicas apoiando a decisão do profissional médico.

2 | MATERIAIS E MÉTODOS

Infelizmente, há uma falta de bancos de imagens histopatológicas, públicos e abrangentes, destinados a pesquisa em sistemas de diagnóstico assistido por computador CAD/CADx. A revisão de (VETA *et al.*, 2014) destacou que o maior obstáculo no desenvolvimento de novos métodos de análise de imagens histopatológicas é a falta de grandes bases de dados públicas rotuladas por especialistas. Bases rotuladas também são essenciais para desenvolver e validar sistemas de aprendizado de máquina.

2.1 Base de Imagens BreKHis

Para ajudar a mitigar a escassez de bases de dados públicas de imagens histopatológicas destinadas à pesquisa, em (SPANHOL *et al.*, 2016) foi disponibilizada uma nova base de imagens chamada BreKHis, a qual é composta de imagens microscópicas de lâminas de tumores mamários. As imagens do conjunto estão divididas em tumores

malignos e benignos, coletadas usando quatro diferentes fatores de aumento: 40X, 100X, 200X e 400X. Uma imagem representativa de cada fator de aumento pode ser vista na Figura 2. São mostradas áreas distintas, pertencentes a uma mesma lâmina de um tumor mamário maligno (corado com HE), capturadas em diferentes fatores de aumento: (a) 40X, (b) 100X, (c) 200X e (d) 400X.

Tal base de dados foi construída em colaboração com o laboratório P&D¹ – Anatomia Patológica e Citopatologia, Cascavel, Paraná, Brasil. A base BreakHis é licenciada sob licença *Creative Commons* 4.0 e está disponível no repositório do Laboratório de Visão Robótica e Imagem (VRI)² da Universidade Federal do Paraná (UFPR), através de requisição, para propósito de pesquisa. Atualmente conta com mais de 1200 usuários registrados pelo mundo e mais de 400 citações em publicações acadêmicas indexadas. A base BreakHis foi utilizada nos experimentos reportados neste trabalho.




Figura 2: Exemplos de imagens da base BreakHis: (a) 40x; (b) 100x; (c) 200x; (d) 400x.

Fonte: SPANHOL (2018).

2.2 Abordagem de Aprendizado Profundo

Normalmente, na rotina clínica, somente pequenas regiões de interesse em uma imagem histopatológica são efetivamente utilizadas pelos patologistas para classificar uma imagem como tumor maligno (câncer) ou tumor benigno (não-canceroso). Porém, considerando as imagens da base BreakHis, tais regiões não estão segmentadas ou

1. <https://www.prevencaoediagnose.com.br/>

2. <https://web.inf.ufpr.br/vri/databases/breast-cancer-histopathological-database-breakhis/>

rotuladas, isto é, a exata localização da região de interesse útil para o diagnóstico não é previamente conhecida. Visando evitar a segmentação explícita uma primeira abordagem baseada em aprendizado profundo (*deep learning*) para a base BreaKHis foi originalmente publicada em (SPANHOL *et al.*, 2016b). Em tal trabalho os autores apresentaram os resultados alcançados usando uma CNN (*Convolutional Neural Network*) treinada diretamente com as imagens histopatológicas da BreaKHis, considerando os 4 aumentos e 5 distribuições diferentes de pacientes (partições) nos conjuntos de treinamento e teste.

2.3 Classificação usando Subimagens (*Patches*)

Dado que CNNs exigem grandes conjunto de dados para treinamento, os autores utilizaram a técnica de extrair pequenas subimagens (*patches*) das imagens originais, tanto nas fases de treinamento quanto de teste (SPANHOL *et al.*, 2016b). A ideia é aumentar o conjunto de instâncias disponíveis para treinamento extraindo de cada imagem original do conjunto de treinamento um grande número de *patches* selecionados de posições randômicas. Foram extraídos 1000 *patches* de 64×64 pixels cada. Na fase de testes os *patches* extraídos das imagens originais do conjunto de teste são classificados individualmente e então o resultado é combinado para classificar a imagem original como sendo tumor maligno (câncer) ou benigno.

Entretanto, os padrões de alguns *patches* é muito similar, independente se a imagem original provém de um tumor maligno ou benigno. Exemplos de tais padrões podem ser vistos na Figura 3: em (a) *patches* de áreas de fundo e (b) *patches* de tecido adiposo. Essa intersecção pode ser parcialmente explicada pela presença natural de certos tipos de tecido (como tecido adiposo, tecido rico em colágeno, tecido conectivo, etc.) em muitas das amostras histopatológicas de mama.

Além disso, um significativo número de *patches* extraídos apresenta texturas quase planas, normalmente correspondendo a áreas de formação de líquido, à cavidade central de estruturas tubulares ou mesmo a espaços no tecido (fundo). Um exemplo desse tipo de *patch* pode ser visto na Figura 4. Definitivamente os *patches* contendo apenas tal tipo de padrão plano não são representativos para distinguir entre tumores malignos e benignos. Assim, a proposta é descartar os *patches* que apresentem padrões comuns a ambas as classes. Para tanto, foi aplicada uma técnica de agrupamento (*clustering*) em tais *patches* visando separá-los em três grupos: puramente maligno, puramente benigno e misto. Logo, apenas os grupos puros são considerados como entrada de treinamento para a CNN. Espera-se que usando *patches* mais discriminativos melhore-se a taxa de reconhecimento do modelo de classificação.

2.4 Extração de Características DeCAF

Na extração de características, usando os *patches* já obtidos, é aplicada uma CNN pré-treinada para obter características DeCAF (*Deep Convolutional Activation Feature*) a partir da camada ip1 dessa CNN. Essa camada é uma camada *InnerProduct* (também conhecida como camada totalmente conectada) que trata a imagem de entrada como um vetor e gera como saída também um vetor. Neste modelo tem-se um vetor v_i de 64 dimensões que é salvo em V .




Figura 3: Exemplos de padrões recorrentes: (a) área de fundo; (b) tecido adiposo.

Fonte: SPANHOL (2018).




Figura 4: Retângulo mostrando uma subimagem (*patch*) selecionada de uma área de imagem que apresenta textura completamente plana.

Fonte: SPANHOL (2018).

2.5 Agrupamento de *Patches*

Uma vez extraída a representação a partir da camada *ip1*, aplicou-se um algoritmo de agrupamento *k-means* para criar $k = 50$ agrupamentos no conjunto de dados de entrada. Foram avaliadas variações do número de agrupamentos k tal que $k \in \{10, 20, 50\}$. Analisando a distribuição dos *patches* nos respectivos *clusters* foi escolhido o valor de $k = 50$ para manter os agrupamentos menos densos. Foi executado um agrupamento particionado, isto é, a divisão do conjunto de instâncias de entrada (vetores de características) em subconjuntos não sobrepostos (agrupamentos). Espera-se dividir os *patches* em grupos distintos, baseando-se nas propriedades de coerência e similaridade aprendidos automaticamente pela CNN utilizada como extratora de características DeCAF.

2.6 Filtragem

Este passo objetiva avaliar cada *cluster* (agrupamento) e descartar aqueles que eventualmente possuam padrões mistos. Assim, usando os vetores em V , cria-se os *clusters* C e avalia-se a taxa de pureza p^c para cada *cluster*, descartando os *clusters* que apresentem pureza inferior a um limiar fixado. A taxa de pureza p^c é computada pela Eq. (1). Aqui o termo pureza representa a qualidade de um *cluster* possuir majoritariamente *patches* provindos apenas de uma determinada classe, isto é, minimize a ocorrência de padrões que sejam recorrentes em ambas as classes.

$$p^{C_q} = \max \left(\frac{|L_1|}{N_P}, \dots, \frac{|L_m|}{N_P} \right) \quad (1)$$

tal que, $\forall b, L_b \in C_q$

Tem-se na equação (1) que $1 \leq q \leq k$, e $L_b \in C_q$ representa os *patches* de L_b no *cluster* C_q . Dado um limiar λ , é descartado o *cluster* C_q se $p^{C_q} < \lambda$. Finalmente, para cada *cluster* remanescente, é atribuído o rótulo do *cluster* aos respectivos *patches*. Tais *patches*, presumidamente contendo padrões mais representativos, são usados como entrada para treinar a CNN. Foram avaliados diferentes valores da taxa de pureza considerando valores distintos para o limiar λ . Notou-se que assumindo taxas muito altas ($\lambda \geq 0,99$) causava-se a eliminação completa dos *patches* de certos conjuntos. Assim, foi fixado um limiar $\lambda = 0,9$ que produziu resultados de classificação satisfatórios.

2.7 Treinamento da CNN

Finalizada a filtragem, os *patches* menos discriminativos foram descartados e um conjunto de instâncias menor é obtido para treinar a CNN. Esse modelo foi treinado usando os *patches* filtrados como entrada. O protocolo de treinamento é o supervisionado e aplicou-se o método SGD (*Stochastic Gradient Descent*) para computar os gradientes. Mini-lotes de tamanho 1 foram usados para atualizar os parâmetros da CNN, treinada por 80.000 iterações, iniciando com uma taxa de aprendizado de 10^{-6} em conjunção com um termo *momentum* de 0,9 e um decaimento de peso 4^{-5} .

2.8 Métricas de Avaliação

Para permitir uma comparação direta dos resultados deste trabalho principalmente foi avaliada a acurácia em cada fator de aumento (*zoom*) de forma independente, tanto na métrica nível de imagem quanto em nível de paciente. A acurácia em nível de imagem corresponde ao escore do total de imagens corretamente classificadas. Isto é mostrado na Eq. (2), onde N é o número total de imagens no conjunto de dados e N_c é o total de imagens corretamente classificadas:

$$Ac_{im} = \frac{N_c}{N} \quad (2)$$

Já a acurácia em nível de paciente corresponde a média da acurácia em nível de imagem por paciente. Mais formalmente, fazendo S o número total de pacientes, N_c o

total de imagens classificadas corretamente do paciente ϕ e N_ϕ o total de imagens para o mesmo paciente tem-se a Eq. (3).

$$Ac_{pac} = \frac{\sum_{\phi=1}^S \frac{N_c^\phi}{N_\phi}}{S} \quad (3)$$

3 | RESULTADOS E DISCUSSÃO

Desde a disponibilização pública da base BreakHis alguns métodos de classificação que utilizam tal conjunto de imagens foram propostos na literatura. Logo, considerando a base BreakHis um *benchmark* e os resultados alcançados com descritores convencionais publicados em (SPANHOL *et al.*, 2016) uma linha base (A), podemos comparar o método de CNN sem filtragem (B e B*) (SPANHOL *et al.*, 2016b) com o método de filtragem de *patches* significativos aqui apresentado (C). A arquitetura da CNN é a mesma.

O Quadro 1 compara a acurácia do método de descarte de *patches* proposto neste trabalho com as outras abordagens usando as mesmas 5 partições de treinamento-teste da linha base. A acurácia percentual é a média das 5 partições. Os melhores resultados estão em negrito com fundo cinza. A abordagem B* indica uma combinação de classificadores.

Nota-se que o método de filtragem não conseguiu um desempenho superior em todos os fatores de aumento, mas sim nos dois maiores (200x e 400x) quando comparado com CNN que utiliza os *patches* sem filtragem. Por outro lado, o método proposto tem um desempenho melhor em todos os fatores de aumento quando comparado a linha base.

Abordagem 40x	Fator de aumento				
	100x	200x	400x		
paciente	A	83,8 ± 4,1	82,1 ± 4,9	85,1 ± 3,1	82,3 ± 3,8
	B	88,6 ± 5,6	84,5 ± 2,4	85,3 ± 3,8	81,7 ± 4,9
	B*	90,0 ± 6,7	88,4 ± 4,8	84,6 ± 4,2	86,1 ± 6,2
	C	86,4 ± 5,7	83,6 ± 5,8	92,1 ± 7,3	85,0 ± 4,7
imagem	A	82,8 ± 3,6	80,7 ± 4,9	84,2 ± 1,6	81,2 ± 3,6
	B	89,6 ± 6,5	85,0 ± 4,8	84,0 ± 3,2	80,8 ± 3,1
	B*	85,6 ± 4,8	83,5 ± 3,9	83,1 ± 1,9	80,8 ± 3,0
	C	85,3 ± 3,3	82,5 ± 3,0	87,8 ± 4,9	82,1 ± 3,4

Quadro 1: Acurácia (%) comparada com trabalhos disponíveis na literatura.

Fonte: Autoria própria (2020).

Predições falso positivas, isto é, instâncias de tumor benigno classificadas incorretamente como tumor maligno continuam sendo a maior fonte de erros do modelo.

4 | CONSIDERAÇÕES FINAIS

A técnica de descartar *patches* não discriminativos mostrou-se promissora, com resultados que melhoram o desempenho da CNN na tarefa de classificação de imagens da base BreakHis em tumores malignos ou benignos. Contudo, novos experimentos precisam ser realizados para melhorar o desempenho nos aumentos menores (40X e 100X).

Adicionalmente, além de melhorar a acurácia geral do modelo utilizado para a tomada de decisão clínica pesquisas devem também focar na extração das características da imagem que realmente são significativas para classificação de câncer, permitindo rastrear quais parâmetros levaram o modelo a determinada classificação final. Tais características podem fornecer *insights* inovadores acerca de determinadas áreas específicas que devem ser examinadas pelos especialistas médicos.

REFERÊNCIAS

Boyle, P.; Levin, B. (eds.). **World Cancer Report 2008**. Lyon: IARC, 2008. URL : Disponível em: http://www.iarc.fr/en/publications/pdfs-online/wcr/2008/wcr_2008.pdf. Acesso em: 02 jun/2020.

Bray, F.; FERLAY, J.; Soerjomataram, I.; Siegel, RL; Torre, LA; Jemal, A. **Global Cancer Statistics 2018: GLOBOCAN**. Disponível em: <http://gco.iarc.fr>. Acesso em: 02 jun/2020.

Herrington, C. S. (ed.). **Muir's Textbook of Pathology**. 5 ed. Boca Raton: CRC Press, 2014.

Instituto Nacional de Câncer José de Alencar Gomes da Silva (INCA), Ministério da Saúde (MS), Secretaria de Atenção à Saúde (SAS) (2020). **Estimativa 2020– Incidência de Câncer no Brasil**. Rel. téc. Brasília, 2020. Disponível em: <https://www.inca.gov.br/estimativa>. Acesso em: 21 jul/2020.

KUMAR, V.; ABBAS, A. K.; ASTER, J. C. (eds). (2013). **Robbins Basic Pathology**. 9 ed. Philadelphia: Elsevier, 2013.

RUBIN, R.; STRAYER, D. S.; RUBIN, E. (eds.). **Rubin's Pathology Clinicopathologic Foundations of Medicine**. 6 ed. Philadelphia: Lippincott Williams & Wilkins, 2012.

SPANHOL, F.; OLIVEIRA, L. S.; PETITJEAN, C. HEUTTE, L. **A Dataset for Breast Cancer Histopathological Image Classification**. IEEE Transactions on Biomedical Engineering (TBME), 63 (7), pp. 1455–1462, 2016

SPANHOL, F.; OLIVEIRA, L. S.; PETITJEAN, C. HEUTTE, L. **Breast cancer histopathological image classification using Convolutional Neural Networks**. In: 2016 International Joint Conference on Neural Networks (IJCNN). Vancouver: IEEE, 2016b.

SPANHOL, Fabio Alexadre. **Automatic breast cancer classification from histopathological images: a hybrid approach**. Tese (Doutorado em Ciência da Computação) – Programa de Pós-Graduação em Informática da Universidade Federal do Paraná. Curitiba, 2018. Disponível em: <https://hdl.handle.net/1884/57312>. Acesso em: 22 jul. 2020.

VETA, M.; PLUIM, J. P. W.; DIEST, P. J.; Viergever, Max A. **Breast cancer histopathology image analysis: a review**. IEEE Transactions On Biomedical Engineering (TBME), 61 (5), pp. 1400–1411, 2014.

World Cancer Research Fund (WCRF). **Worldwide Cancer Data**. Disponível em: <https://www.wcrf.org/dietandcancer/cancer-trends/worldwide-cancer-data>. Acesso em: 02 jun/2020.

SOBRE O ORGANIZADOR

JEFFERSON GUSTAVO MARTINS - Bacharel em Informática pela Universidade Estadual do Oeste do Paraná (UNIOESTE), com conclusão em 1999, e Licenciado em Informática pelo Programa Especial de Formação Pedagógica pela Universidade Tecnológica Federal do Paraná (UTFPR), com conclusão em 2009. Em 2002, concluiu o mestrado em Engenharia de Produção, Área de Concentração em “Inteligência Aplicada”, pela Universidade Federal de Santa Catarina (UFSC). Pela Universidade Federal do Paraná (UFPR), realizou doutorado e estágio pós-doutoral, ambos pelo Programa de Pós-Graduação em Informática e concluídos em 2014 e 2019, respectivamente. Desde 2003 é professor da UTFPR, tendo sido aprovado à classe Titular em 2019. Como tal compõe diferentes órgãos colegiados; é responsável pela Divisão de Propriedade Intelectual (DIPIN-TD) e pelo Núcleo de Inovação (NIT) do Câmpus Toledo; já desempenhou funções administrativas como coordenação e vice-coordenação de cursos de graduação e pós-graduação (dentre outros), sendo atualmente vice-coordenador do Programa de Mestrado em Tecnologias em Biociências (PPGBio, UTFPR-TD). Possui experiência na área de Aprendizagem de Máquinas / Reconhecimento de Padrões e Processamento de Imagens, com publicações e trabalhos de revisão em periódicos e conferências nacionais e internacionais. E-mail: martins@utfpr.edu.br.

INTELIGÊNCIA COMPUTACIONAL:

Coletânea de Estudos de Casos



www.atenaeditora.com.br



contato@atenaeditora.com.br



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



www.facebook.com/atenaeditora.com.br

INTELIGÊNCIA COMPUTACIONAL:

Coletânea de Estudos de Casos

-  www.atenaeditora.com.br
-  contato@atenaeditora.com.br
-  [@atenaeditora](https://www.instagram.com/atenaeditora)
-  www.facebook.com/atenaeditora.com.br