

VOL VIII

AGRÁRIAS

PESQUISA E INOVAÇÃO NAS CIÊNCIAS QUE
ALIMENTAM O MUNDO

EDUARDO EUGÊNIO
SPERS
(Organizador)

 EDITORA
ARTEMIS

2022

VOL VIII

AGRÁRIAS

PESQUISA E INOVAÇÃO NAS CIÊNCIAS QUE
ALIMENTAM O MUNDO

EDUARDO EUGÊNIO
SPERS
(Organizador)

 EDITORA
ARTEMIS

2022



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). Direitos para esta edição cedidos à Editora Artemis pelos autores. Permitido o download da obra e o compartilhamento, desde que sejam atribuídos créditos aos autores, e sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

A responsabilidade pelo conteúdo dos artigos e seus dados, em sua forma, correção e confiabilidade é exclusiva dos autores. A Editora Artemis, em seu compromisso de manter e aperfeiçoar a qualidade e confiabilidade dos trabalhos que publica, conduz a avaliação cega pelos pares de todos manuscritos publicados, com base em critérios de neutralidade e imparcialidade acadêmica.

Editora Chefe	Prof. ^a Dr. ^a Antonella Carvalho de Oliveira
Editora Executiva	M. ^a Viviane Carvalho Mocellin
Direção de Arte	M. ^a Bruna Bejarano
Diagramação	Elisângela Abreu
Organizador	Prof. Dr. Eduardo Eugênio Spers
Imagem da Capa	Shutterstock
Bibliotecária	Janaina Ramos – CRB-8/9166

Conselho Editorial

Prof.^a Dr.^a Ada Esther Portero Ricol, *Universidad Tecnológica de La Habana “José Antonio Echeverría”*, Cuba
Prof. Dr. Adalberto de Paula Paranhos, Universidade Federal de Uberlândia
Prof.^a Dr.^a Amanda Ramalho de Freitas Brito, Universidade Federal da Paraíba
Prof.^a Dr.^a Ana Clara Monteverde, *Universidad de Buenos Aires, Argentina*
Prof.^a Dr.^a Ana Júlia Viamonte, Instituto Superior de Engenharia do Porto (ISEP), Portugal
Prof. Dr. Ángel Mujica Sánchez, *Universidad Nacional del Altiplano, Peru*
Prof.^a Dr.^a Angela Ester Mallmann Centenaro, Universidade do Estado de Mato Grosso
Prof.^a Dr.^a Begoña Blandón González, *Universidad de Sevilla, Espanha*
Prof.^a Dr.^a Carmen Pimentel, Universidade Federal Rural do Rio de Janeiro
Prof.^a Dr.^a Catarina Castro, Universidade Nova de Lisboa, Portugal
Prof.^a Dr.^a Cirila Cervera Delgado, *Universidad de Guanajuato, México*
Prof.^a Dr.^a Cláudia Padovesi Fonseca, Universidade de Brasília-DF
Prof.^a Dr.^a Cláudia Neves, Universidade Aberta de Portugal
Prof. Dr. Cleberton Correia Santos, Universidade Federal da Grande Dourados
Prof. Dr. David García-Martul, *Universidad Rey Juan Carlos de Madrid, Espanha*
Prof.^a Dr.^a Deuzimar Costa Serra, Universidade Estadual do Maranhão
Prof.^a Dr.^a Dina Maria Martins Ferreira, Universidade Estadual do Ceará
Prof.^a Dr.^a Eduarda Maria Rocha Teles de Castro Coelho, Universidade de Trás-os-Montes e Alto Douro, Portugal
Prof. Dr. Eduardo Eugênio Spers, Universidade de São Paulo
Prof. Dr. Eloi Martins Senhoras, Universidade Federal de Roraima, Brasil



Prof.ª Dr.ª Elvira Laura Hernández Carballido, *Universidad Autónoma del Estado de Hidalgo*, México
Prof.ª Dr.ª Emilas Darlene Carmen Lebus, *Universidad Nacional del Nordeste/ Universidad Tecnológica Nacional*, Argentina
Prof.ª Dr.ª Erla Mariela Morales Morgado, *Universidad de Salamanca*, Espanha
Prof. Dr. Ernesto Cristina, *Universidad de la República*, Uruguay
Prof. Dr. Ernesto Ramírez-Briones, *Universidad de Guadalajara*, México
Prof. Dr. Gabriel Díaz Cobos, *Universitat de Barcelona*, Espanha
Prof.ª Dr.ª Gabriela Gonçalves, Instituto Superior de Engenharia do Porto (ISEP), Portugal
Prof. Dr. Geoffroy Roger Pointer Malpass, Universidade Federal do Triângulo Mineiro, Brasil
Prof.ª Dr.ª Gladys Esther Leoz, *Universidad Nacional de San Luis*, Argentina
Prof.ª Dr.ª Glória Beatriz Álvarez, *Universidad de Buenos Aires*, Argentina
Prof. Dr. Gonçalo Poeta Fernandes, Instituto Politécnico da Guarda, Portugal
Prof. Dr. Gustavo Adolfo Juarez, *Universidad Nacional de Catamarca*, Argentina
Prof.ª Dr.ª Iara Lúcia Tescarollo Dias, Universidade São Francisco, Brasil
Prof.ª Dr.ª Isabel del Rosario Chiyon Carrasco, *Universidad de Piura*, Peru
Prof.ª Dr.ª Isabel Yohena, *Universidad de Buenos Aires*, Argentina
Prof. Dr. Ivan Amaro, Universidade do Estado do Rio de Janeiro, Brasil
Prof. Dr. Iván Ramon Sánchez Soto, *Universidad del Bío-Bío*, Chile
Prof.ª Dr.ª Ivânia Maria Carneiro Vieira, Universidade Federal do Amazonas, Brasil
Prof. Me. Javier Antonio Albornoz, *University of Miami and Miami Dade College*, Estados Unidos
Prof. Dr. Jesús Montero Martínez, *Universidad de Castilla - La Mancha*, Espanha
Prof. Dr. João Manuel Pereira Ramalho Serrano, Universidade de Évora, Portugal
Prof. Dr. Joaquim Júlio Almeida Júnior, UniFIMES - Centro Universitário de Mineiros, Brasil
Prof. Dr. José Cortez Godinez, Universidad Autónoma de Baja California, México
Prof. Dr. Juan Carlos Cancino Diaz, Instituto Politécnico Nacional, México
Prof. Dr. Juan Carlos Mosquera Feijoo, *Universidad Politécnica de Madrid*, Espanha
Prof. Dr. Juan Diego Parra Valencia, *Instituto Tecnológico Metropolitano de Medellín*, Colômbia
Prof. Dr. Juan Manuel Sánchez-Yáñez, *Universidad Michoacana de San Nicolás de Hidalgo*, México
Prof. Dr. Júlio César Ribeiro, Universidade Federal Rural do Rio de Janeiro, Brasil
Prof. Dr. Leinig Antonio Perazolli, Universidade Estadual Paulista (UNESP), Brasil
Prof.ª Dr.ª Livia do Carmo, Universidade Federal de Goiás, Brasil
Prof.ª Dr.ª Luciane Spanhol Bordignon, Universidade de Passo Fundo, Brasil
Prof. Dr. Luis Fernando González Beltrán, Universidad Nacional Autónoma de México, México
Prof. Dr. Luis Vicente Amador Muñoz, *Universidad Pablo de Olavide*, Espanha
Prof.ª Dr.ª Macarena Esteban Ibáñez, *Universidad Pablo de Olavide*, Espanha
Prof. Dr. Manuel Ramiro Rodriguez, *Universidad Santiago de Compostela*, Espanha
Prof.ª Dr.ª Márcia de Souza Luz Freitas, Universidade Federal de Itajubá, Brasil
Prof. Dr. Marcos Augusto de Lima Nobre, Universidade Estadual Paulista (UNESP), Brasil
Prof. Dr. Marcos Vinicius Meiado, Universidade Federal de Sergipe, Brasil
Prof.ª Dr.ª Mar Garrido Román, *Universidad de Granada*, Espanha
Prof.ª Dr.ª Margarida Márcia Fernandes Lima, Universidade Federal de Ouro Preto, Brasil
Prof.ª Dr.ª Maria Aparecida José de Oliveira, Universidade Federal da Bahia, Brasil
Prof.ª Dr.ª Maria Carmen Pastor, *Universitat Jaume I*, Espanha
Prof.ª Dr.ª Maria do Céu Caetano, Universidade Nova de Lisboa, Portugal
Prof.ª Dr.ª Maria do Socorro Saraiva Pinheiro, Universidade Federal do Maranhão, Brasil
Prof.ª Dr.ª Maria Lúcia Pato, Instituto Politécnico de Viseu, Portugal

Prof.^a Dr.^a Maritza González Moreno, *Universidad Tecnológica de La Habana*, Cuba
Prof.^a Dr.^a Mauriceia Silva de Paula Vieira, Universidade Federal de Lavras, Brasil
Prof.^a Dr.^a Odara Horta Boscolo, Universidade Federal Fluminense, Brasil
Prof. Dr. Osbaldo Turpo-Gebera, *Universidad Nacional de San Agustín de Arequipa*, Peru
Prof.^a Dr.^a Patrícia Vasconcelos Almeida, Universidade Federal de Lavras, Brasil
Prof.^a Dr.^a Paula Arcoverde Cavalcanti, Universidade do Estado da Bahia, Brasil
Prof. Dr. Rodrigo Marques de Almeida Guerra, Universidade Federal do Pará, Brasil
Prof. Dr. Saulo Cerqueira de Aguiar Soares, Universidade Federal do Piauí, Brasil
Prof. Dr. Sergio Bitencourt Araújo Barros, Universidade Federal do Piauí, Brasil
Prof. Dr. Sérgio Luiz do Amaral Moretti, Universidade Federal de Uberlândia, Brasil
Prof.^a Dr.^a Silvia Inés del Valle Navarro, *Universidad Nacional de Catamarca*, Argentina
Prof.^a Dr.^a Solange Kazumi Sakata, Instituto de Pesquisas Energéticas e Nucleares. Universidade de São Paulo (USP), Brasil
Prof.^a Dr.^a Teresa Cardoso, Universidade Aberta de Portugal
Prof.^a Dr.^a Teresa Monteiro Seixas, Universidade do Porto, Portugal
Prof. Dr. Valter Machado da Fonseca, Universidade Federal de Viçosa, Brasil
Prof.^a Dr.^a Vanessa Bordin Viera, Universidade Federal de Campina Grande, Brasil
Prof.^a Dr.^a Vera Lúcia Vasilévski dos Santos Araújo, Universidade Tecnológica Federal do Paraná, Brasil
Prof. Dr. Wilson Noé Garcés Aguilar, *Corporación Universitaria Autónoma del Cauca*, Colômbia

Dados Internacionais de Catalogação na Publicação (CIP)

A277 Agrárias: pesquisa e inovação nas ciências que alimentam o mundo - Vol. VIII / Organizador Eduardo Eugênio Spers. – Curitiba-PR: Artemis, 2022.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN 978-65-87396-68-2

DOI 10.37572/EdArt_260822682

1. Ciências agrárias. 2. Pesquisa. 3. Agronegócio. 4. Agroecologia. I. Spers, Eduardo Eugênio (Organizador). II. Título.

CDD 630

Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166



APRESENTAÇÃO

As Ciências Agrárias são um campo de estudo multidisciplinar por excelência, e um dos mais profícuos em termos de pesquisas e aprimoramento técnico. A demanda mundial por alimentos e a crescente degradação ambiental impulsionam a busca constante por soluções sustentáveis de produção e por medidas visando à preservação e recuperação dos recursos naturais.

A obra **Agrárias: Pesquisa e Inovação nas Ciências que Alimentam o Mundo** compila pesquisas atuais e extremamente relevantes, apresentadas em linguagem científica de fácil entendimento. Na coletânea, o leitor encontrará textos que tratam dos sistemas produtivos em seus diversos aspectos, além de estudos que exploram diferentes perspectivas ou abordagens sobre a planta, o meio ambiente, o animal, o homem e a sociedade no ambiente rural.

É uma obra que fornece dados, informações e resultados de pesquisas tanto para pesquisadores e atuantes nas diversas áreas das Ciências Agrárias, como para o leitor que tenha a curiosidade de entender e expandir seus conhecimentos.

Este Volume VIII traz 26 artigos de estudiosos de diversos países, divididos em quatro eixos temáticos: *Cultura e Sociedade no Contexto Rural; Produção Sustentável; Produção Vegetal e Solos e Aquacultura, Produção Animal e Veterinária.*

Desejo a todos uma proveitosa leitura!

Eduardo Eugênio Spers

SUMÁRIO

CULTURA E SOCIEDADE NO CONTEXTO RURAL

CAPÍTULO 1..... 1

DESAFIOS DE UMA PAISAGEM CULTURAL MEDITERRÂNICA: O MONTADO, O TIRADOR DE CORTIÇA E A TRANSMISSÃO DO SABER-FAZER TRADICIONAL

Sónia Bombico

Carlos Manuel Faísca

 https://doi.org/10.37572/EdArt_2608226821

CAPÍTULO 2.....28

DISEÑO DE UN SISTEMA DE BUENAS PRACTICAS AGRICOLAS COMO ESTRATEGIA DE IMPLEMENTACION EN LA ASOCIACION APRIMUJER UBICADA EN EL MUNICIPIO DE SAN VICENTE DE CHUCURI

Leidy Andrea Carreño Castaño

Mónica María Pacheco Valderrama

Héctor Julio Paz Díaz

Miguel Arturo Lozada Valero

Rafael Calderón Silva

Jhoan Arley Ochoa Martínez

Angélica María Montoya Hernández

Irina Alean Carreño

Shirley Mancera

Daniel Augusto Buitrago Ibañez

Ana Milena Salazar

Sandra Milena Montesino Rincón

 https://doi.org/10.37572/EdArt_2608226822

CAPÍTULO 3..... 38

ESPECIES FORESTALES DE IMPORTANCIA CULTURAL DE BADIRAGUATO SINALOA

Yulisa Rodríguez López

Heréndira Flores Almeida

Gilberto Sandoval Varela

Bladimir Salomón Montijo

Aidé Avendaño Gómez

 https://doi.org/10.37572/EdArt_2608226823

CAPÍTULO 4..... 50

CONTRIBUCIÓN POTENCIAL DE LAS SEMILLAS DE *Carica papaya* Linn Y SU ACEITE EN LA SALUD

Amelia Andrea Espitia Arrieta
Jennifer Judith Lafont Mendoza
Ana Karina Paternina Zapa

 https://doi.org/10.37572/EdArt_2608226824

CAPÍTULO 5.....62

PROTOTIPOS DE INNOVACIÓN SOCIAL EN PESCA ARTESANAL, REGIÓN DE LOS RÍOS – CHILE

Griselda Ilabel Pérez
Meyling Tang Ortiz
Claudio Barrientos Aguila

 https://doi.org/10.37572/EdArt_2608226825

PRODUÇÃO SUSTENTÁVEL

CAPÍTULO 6.....70

CONCEPTO DE BIORREFINERÍA: DESARROLLO SOSTENIBLE Y PROPUESTA DE PROCESO LIMPIO EN LA EXTRACCIÓN DE COMPUESTOS FENÓLICOS DE RESIDUOS INDUSTRIALES DE PISTACHO (*Pistacia vera* var. *Kerman*)

Daniela Zalazar-García
Rosa Rodriguez
María Paula Fabani
Germán Mazza
Marcelo Echegaray
Romina Zabaleta
Eliana Sanchez
Erick Torres

 https://doi.org/10.37572/EdArt_2608226826

CAPÍTULO 7..... 83

REDUCCIÓN DE LA CANTIDAD DE VINAZA POR AUMENTO DE LA CONCENTRACIÓN FINAL DE ETANOL POR FERMENTACIÓN DE *Saccharomyces cerevisiae*

María Laura Muruaga
María Gabriela Muruaga
Cristian Andrés Sleiman
Nora Inés Perotti

 https://doi.org/10.37572/EdArt_2608226827

CAPÍTULO 8.....97

EVALUACIÓN DE LA *CHLORELLA SP* Y LA *DUNALIELLA TERTIOLECTA* COMO FUENTE POTENCIAL DE ÁCIDOS GRASOS PARA LA PRODUCCIÓN DE BIODIESEL

Dally Esperanza Gáfaró Álvarez
Mónica María Pacheco Valderrama
Daniel Augusto Buitrago Ibañez
Yuleisi Tatiana Caballero Hernandez
Leidy Andrea Carreño Castaño
Ana Milena Salazar Beleño
Miguel Arturo Lozada Valero
Leidy Carolina Ortiz Araque
Olga Cecilia Alarcón Vesga
Sandra Milena Montesino Rincón
Cristian Giovanni Palencia Blanco
Nora Milena Ortiz Garcia

 https://doi.org/10.37572/EdArt_2608226828

CAPÍTULO 9..... 110

A TEMPORARY IMMERSION SYSTEM (TIS) BIOREACTOR USED FOR THE IN VITRO PROPAGATION OF *PRUNUS* AND *PYRUS* ROOTSTOCKS

Carlos Rolando Mendoza
Ramon Dolcet-Sanjuan

 https://doi.org/10.37572/EdArt_2608226829

CAPÍTULO 10.....125

CARACTERIZAÇÃO DE CORANTES PARA ELABORAÇÃO DE CEREJAS CANDEADA: ERITROSINA VERSUS VERMELHO GARDENIA

Juan Ignacio González Pacheco
Mariela Beatriz Maldonado
Ariel Fernando Márquez Agüero
Emanuel Félix Condori Laura
Paula Anabella Giorlando Videla

 https://doi.org/10.37572/EdArt_26082268210

PRODUÇÃO VEGETAL E SOLOS

CAPÍTULO 11..... 141

THE QUALITY OF APPLE FRUIT PRODUCTS WHEN USING THE GROWTH BIOREGULATOR ALBIT IN THE SYSTEM OF PROTECTION

Svetlana Levchenko
Elena Stranishevskaya

Elena Matveikina
Vladimir Boiko
Nadezhda Shadura
Vitalii Volodin
D. Belash
Ya. Volkov
Marina Volkova

 https://doi.org/10.37572/EdArt_26082268211

CAPÍTULO 12 151

THE EFFECT OF VEGETATIVE TREATMENT OF GRAPES WITH A PREPARATION
BASED ON AMINO ACIDS ON THE PHENOLIC COMPLEX OF BERRIES

Svetlana Levchenko
Elena Ostroukhova
Sofia Cherviak
Vladimir Boyko
Dmitriy Belash
Irina Peskova
Nataliya Lutkova
Mariya Viugina
Olga Zaitseva
Aleksandr Romanov

 https://doi.org/10.37572/EdArt_26082268212

CAPÍTULO 13 162

ANÁLISIS FÍSICOQUÍMICO DE ACEITES SEMILLAS CON APROVECHAMIENTO
POTENCIAL ZONAS TROPICALES

Amelia Andrea Espitia Arrieta
Jennifer Judith Lafont Mendoza

 https://doi.org/10.37572/EdArt_26082268213

CAPÍTULO 14 175

PLAGAS DESENCADENANTES DE EPIFITIAS DEL CULTIVO DE PLATANO &
ESTRATEGIAS DE CONTROL

Francisco Angel Simón Ricardo
Renso Oswaldo Lozano Gámez
Cristhian Andrés Méndez Cedeño
Luis Pérez Vicente

 https://doi.org/10.37572/EdArt_26082268214

CAPÍTULO 15 191

EFFECTOS ABIÓTICOS DE LA SALINIDAD EN CULTIVOS DE ARÁNDANO BAJO RIEGO POR GOTEJO, EN LA PROVINCIA DE BUENOS AIRES

Alejandro Pannunzio

Pamela Texeira

Luciana Tozzini

 https://doi.org/10.37572/EdArt_26082268215

CAPÍTULO 16 200

EVALUACIÓN DEL RENDIMIENTO DEL GRANO CON LOS TRES HÍBRIDOS ASOCIADOS CON TRES NIVELES DE LA FERTILIZACIÓN NITROGENADA EN EL CULTIVO DE MAÍZ ENTRE LA ASPERSIÓN Y GOTEJO POR FERTIRIEGO DURANTE LA ESTACIÓN SECA EN UN SUELO VERTISOL

Kentaro Tomita

Jaime Proaño

 https://doi.org/10.37572/EdArt_26082268216

CAPÍTULO 17 209

APLICAÇÃO DE TÉCNICAS DE MACHINE LEARNING PARA CLASSIFICAÇÃO DA APTIDÃO DOS SOLOS PARA O REGADIO

Pedro Torres

António Canatário Duarte

João Gerales

Sílvia Marques

 https://doi.org/10.37572/EdArt_26082268217

AQUACULTURA, PRODUÇÃO ANIMAL E VETERINÁRIA

CAPÍTULO 18 225

INFLUENCIA DE LAS VARIABLES MORFOLÓGICAS Y POBLACIONALES DE *Eichornia crassipes* Y *Pistia stratiotes* SOBRE LA COMUNIDAD DE MACROINVERTEBRADOS ACUÁTICOS EN UNA MADRE VIEJA DEL VALLE DEL CAUCA

Daniel Feriz Garcia

Jency Nathaly Palacio Bayer

Laura Melissa Muños Burbano

 https://doi.org/10.37572/EdArt_26082268218

CAPÍTULO 19239

AVALIAÇÃO DO CRESCIMENTO DE ACHIGÃS PRODUZIDOS EM AQUACULTURA

António Moitinho Rodrigues

António Vasco de Mello

Miguel de Mello

Filipa Inês Pitacas

 https://doi.org/10.37572/EdArt_26082268219

CAPÍTULO 20250

EFICÁCIA DO TRATAMENTO COMBINADO DE AMITRAZ E FLUMETRINA NO CONTROLO DA VARROOSE

Maria Alice Carvalho Hipólito

Catarina Manuela Almeida Coelho

Sância Maria Afonso Pires

Jorge Belarmino Ferreira de Oliveira

 https://doi.org/10.37572/EdArt_26082268220

CAPÍTULO 21263

CAPTACIÓN Y DISTRIBUCIÓN DE AGUA PARA RIEGO DE PASTURAS EN CHIPAUQUIL (DPTO. VALCHETA). ARGENTINA

Juan José Gallego

Ciro Adrián Saber

Germán Cariac

Pablo Giovinne

Julio Argentino Llampá

Horacio Alberto Pallao

Diego Milipil

Hernán Zelmer

Roberto Angel Molina

Ines Mora Jara

María Victoria Cortés

 https://doi.org/10.37572/EdArt_26082268221

CAPÍTULO 22270

POTENCIALES MECANISMOS POR LOS CUALES SE MANIFIESTAN LAS ENFERMEDADES INFECCIOSAS EMERGENTES DEL CERDO

Carlos J. Perfumo

Mariana Machuca

Alejandra Quiroga

 https://doi.org/10.37572/EdArt_26082268222

CAPÍTULO 23285

CONFORTO TÉRMICO PARA FRANGOS DE CORTE EM CENÁRIOS DE MUDANÇA CLIMÁTICA NO RS

Zanandra Boff de Oliveira
Emanuel Luis Christmann
Eduardo Leonel Bottega
Tiago Rodrigo Francetto

 https://doi.org/10.37572/EdArt_26082268223

CAPÍTULO 24298

GANADERÍA EQUINA EXTENSIVA, FIESTAS Y PRODUCTOS TRADICIONALES: COOPERATIVA MONTE CABALAR Y RAPA DAS BESTAS DE SABUCEDO (A ESTRADA, PONTEVEDRA)

Francisco Xavier Barreiro
Adolfo Cano Guervós

 https://doi.org/10.37572/EdArt_26082268224

CAPÍTULO 25316

VINCRISTINA SUBCUTÁNEA COMO VIA ALTERNATIVA PARA EL TRATAMIENTO DE TUMOR VENÉREO TRANSMISIBLE EN PERROS

Gloria Beatriz Cabrera Suarez
David Octavio Rugel González

 https://doi.org/10.37572/EdArt_26082268225

CAPÍTULO 26326

A MASTITE E SEU EFEITO NO DESEMPENHO ZOOTÉCNICO E QUALIDADE DO LEITE

Greyce Kelly Schmitt Reitz
Mariana Monteiro Boeng Pelegrini
Pietra Viertel Molinari
Fabiana Moreira
Ivan Bianchi
Juliano Santos Gueretz
Vanessa Peripolli
Elizabeth Schwegler

 https://doi.org/10.37572/EdArt_26082268226

SOBRE O ORGANIZADOR.....332

ÍNDICE REMISSIVO333

APLICAÇÃO DE TÉCNICAS DE MACHINE LEARNING PARA CLASSIFICAÇÃO DA APTIDÃO DOS SOLOS PARA O REGADIO

Data de submissão: 19/07/2022

Data de aceite: 25/07/2022

Pedro Torres

Instituto Politécnico de
Castelo Branco
Escola Superior de Tecnologia
Castelo Branco – Portugal
SYSTEC - Research Center for
Systems & Technologies
4200-465
Porto, Portugal

<https://orcid.org/0000-0003-4835-5022>

António Canatário Duarte

Instituto Politécnico de
Castelo Branco
Escola Superior Agrária
Castelo Branco – Portugal
Centro de Estudos CERNAS-IPCB
Castelo Branco – Portugal

<https://orcid.org/0000-0002-0319-378X>

João Gerales

Instituto Politécnico de
Castelo Branco
Escola Superior de Tecnologia
Castelo Branco – Portugal

Sílvia Marques

Instituto Politécnico de
Castelo Branco
Escola Superior Agrária
Castelo Branco – Portugal

RESUMO: Este trabalho consiste no desenvolvimento e validação de modelos de *Machine Learning* para a otimização de um sistema de rega de precisão utilizando algoritmos de classificação. A finalidade é atribuir a cada solo, localizado a sul do concelho do Fundão, Portugal, uma classe de aptidão para o regadio, classes essas que identificam as zonas regáveis, não regáveis bem como as que precisam de intervenção para serem regadas. Os dados dos casos de estudo foram anteriormente recolhidos por uma aluna de Mestrado da Escola Superior Agrária do IPCB (Portugal), onde incluíam vários condicionalismos (características dos solos que podem condicionar a aptidão para o regadio). A análise exploratória dos dados permitiu utilizar apenas os valores dos resultados relativamente às características dos solos que podem condicionar a aptidão para o regadio rejeitando assim todo o cálculo efetuado para a obtenção dos mesmos. Desta forma os dados do caso de estudo foram enriquecidos com esta informação para a aplicação nos algoritmos de *Machine Learning*. Em geral, o facto de retirar estas características que não revelavam impacto no estudo ajudaram a melhorar os modelos de classificação bem como a sua precisão. Diferentes algoritmos de *Machine Learning* foram desenvolvidos, testados e validados, tais como, *Support Vector Machine*, *kNN*, *Árvore de Decisão*, *Naive Bayes* e *Regressão Logística*, para otimizar um sistema de rega de precisão de modo a atribuir uma a classe

de aptidão de rega a novos solos introduzidos. A comparação dos modelos demonstrou que o método *Naive Bayes* é o que apresenta uma melhor precisão na altura de gerar uma classe de previsão.

PALAVRAS-CHAVE: Aptidão solos regadio. Machine Learning. Scikit-Learn. Aprendizagem Supervisionada.

APPLICATION OF MACHINE LEARNING TECHNIQS FOR EVALUATION OF THE SOILS CAPABILITY TO IRRIGATION

ABSTRACT: This work consists of the development and validation of Machine Learning models for the optimization of a precision irrigation system using classification algorithms. The purpose is to assign to each soil, located in the south of the municipality of Fundão, Portugal, an class of capability to irrigation, classes that identify the irrigable and non-irrigated areas as well as those that need intervention to be irrigated. Data from the case studies were previously collected by a Master's student at the Escola Superior Agrária – IPCB (Portugal), which included several constraints (characteristics of soils that may affect the suitability for irrigation). The exploratory analysis of the data allowed us to use only the values of the results regarding the characteristics of the soils that may affect the suitability for irrigation, thus rejecting all the calculation made to obtain them. In this way, the case study data were enriched with this information for application in Machine Learning algorithms. In general, removing these features that had no impact on the study helped to improve the classification models as well as their accuracy. Different Machine Learning algorithms were developed, tested, and validated, such as Support Vector Machine, kNN, Decision Tree, Naive Bayes and Logistic Regression, to optimize a precision irrigation system in order to assign an irrigation suitability class to new introduced soils. The comparison of the models showed that the Naive Bayes method is the one that presents the best precision when generating a prediction class.

KEYWORDS: Soils capability irrigation. Machine Learning. Scikit-Learn. Supervised Learning.

1 INTRODUÇÃO

Nos dias de hoje o conceito de Agricultura Inteligente ou de Precisão tem se destacado e é fortemente enriquecido com a aplicação de sensores que possibilitam a avaliação e monitorização das condições ambientais, bem como a análise inteligente dos dados produzidos por estes sensores. Este conceito está associado à utilização de equipamentos de alta tecnologia com algoritmos de precisão que tornaram mais eficiente e eficaz este conceito. A agricultura de precisão possibilita que o agricultor “olhe” para uma parcela de solo e perceba que a deve tratar de forma diferenciada, esta nova mentalidade veio revolucionar a forma de ser agricultor. Duas máximas estão associadas a esta mentalidade, o aumento do rendimento da economia dos agricultores e a redução do impacto ambiental causado pelo setor agrícola. Um dos mecanismos impulsionadores deste conceito é o *Machine Learning (ML)* [1], que consiste em fazer com que as máquinas

aprendam através de experiências que lhes são fornecidas sem ser propriamente necessário programá-las. Acoplado a este conceito outras tecnologias como Big Data e computação de alto desempenho, novas oportunidades foram desenvolvidas para quantificar e compreender processos intensivos de dados em ambiente agrícola.

O ML aplicado ao setor agrícola utiliza um conjunto de modelos de aprendizagem bem definidos que recolhem dados específicos bem como aplicam algoritmos para obter resultados esperados. Os modelos de ML podem ser usados para prever a qualidade do solo, a quantidade de água necessária para regar, entre outros.

1.1 ENQUADRAMENTO

Neste trabalho, aplica-se, avalia-se, prevê-se, classificam-se e validam-se a aptidão dos solos para rega, através de modelos de precisão com o auxílio a técnicas de ML (*Machine Learning*). Os diferentes modelos aplicados visam estabelecer uma comparação entre diferentes métodos de classificação e avaliar a sua precisão. O objetivo passa por avaliar a aptidão para o regadio dos solos existentes a sul do concelho do Fundão, Portugal, com a intenção de expandir o regadio da Cova da Beira a zonas onde não existe regadio.

O trabalho tem uma aplicabilidade prática no qual o torna motivante para o seu desenvolvimento visto que a importância do regadio é essencial para sustentar as atividades agrícolas e pela qual dependem muitas famílias de agricultores. O regadio da Cova da Beira não é extenso o suficiente para que outras zonas menos beneficiadas e com grande potencial agrícola se possam servir dele. O estudo da aptidão dos solos para o regadio pode determinar quais as áreas com capacidade para serem regadas, ou não.

Com o aumento da quantidade de dados recolhidos sobre as características do solo estão reunidas as condições para aplicar técnicas de *Machine Learning* no setor agrícola. O grande desafio passa por encontrar o algoritmo que melhor se aplica ao objetivo do projeto. Os diferentes algoritmos de ML que consigam modelar e prever uma classe de aptidão de rega podem ser importantes para ajudar a perceber quais as áreas que podem ser regadas, com o objetivo de estender o regadio a zonas menos beneficiadas e com forte potencial agrícola. Os algoritmos de ML como também a sua aplicabilidade estão em constante expansão. Estes algoritmos categorizam-se em diferentes tipos de aprendizagem (supervisionada, não supervisionada e de reforço) bem como também por técnicas de formulação (classificação e regressão). A seleção de um algoritmo depende muito do tipo de problema que se vai abordar. Na rega de precisão a técnica de classificação é bastante utilizada para prever uma dotação correta de quando

regar ou não regar, devido ao facto de as características dos solos serem apresentadas em forma de dados, onde fica presente a informação sobre as características dos solos bem como a avaliação de cada solo.

1.2 INTELIGÊNCIA ARTIFICIAL E *MACHINE LEARNING*

Atualmente Inteligência Artificial (I.A.) é um conceito com bastante aplicabilidade, caracteriza-se como uma ciência ou ramo da engenharia, que procura estudar e compreender o fenómeno da inteligência e por outro lado compreender o modo como os seres humanos pensam, a fim de modelar o pensamento em processos computacionais e consequentemente construir um corpo de explicações algorítmicas dos processos mentais humanos.

Machine Learning é um sub ramo da IA, onde se usam algoritmos para adquirir dados, inferir com eles, e fazer uma determinação ou previsão sobre algo. A máquina é “treinada” através de uma grande quantidade de dados e implementa algoritmos que lhe dão a habilidade de aprender como executar a tarefa [2]. O *Machine Learning* ensina os computadores a fazer o que os humanos e os animais naturalmente fazem, aprender através de experiências. Os algoritmos de *Machine Learning* utilizam métodos de aprendizagem computacional para “aprender” a informação através de dados sem depender de equações predeterminadas como modelos. Os algoritmos melhoram de forma adaptativa a sua performance à medida que o número de amostras disponíveis aumenta.

1.3 APRENDIZAGEM SUPERVISIONADA E NÃO SUPERVISIONADA

Quando se fala em algoritmos de ML conduz, normalmente, à referência de dois paradigmas: aprendizagem supervisionada e não supervisionada[3]. Na aprendizagem supervisionada são usados dois conjuntos de dados, o de input e output esperado. Na aprendizagem não supervisionada apenas é apresentado um conjunto de dados, input.

A aprendizagem supervisionada está diretamente relacionada com a previsão enquanto a aprendizagem não supervisionada relaciona padrões num conjunto de dados de modo a agrupá-los [3]. O objetivo da aprendizagem supervisionada é construir um modelo que faça previsões baseadas em evidências na presença de incertezas. O algoritmo de aprendizagem supervisionada usa um conjunto de dados de entrada (inputs) e respostas (outputs) conhecidos e treina o modelo para gerar previsões razoáveis para a resposta de novos dados. Todas as técnicas de aprendizagem supervisionada são sob a forma de classificação que preveem respostas discretas ou regressão para previsão de respostas contínuas.

A regressão é habitualmente utilizada para a previsão de valores de variáveis dependentes (variáveis que se pretende prever) a partir de uma ou mais variáveis independentes (atributos conhecidos) e nos casos em que essas mesmas variáveis são contínuas. Trata-se de uma tarefa utilizada na aproximação dos dados recebidos.

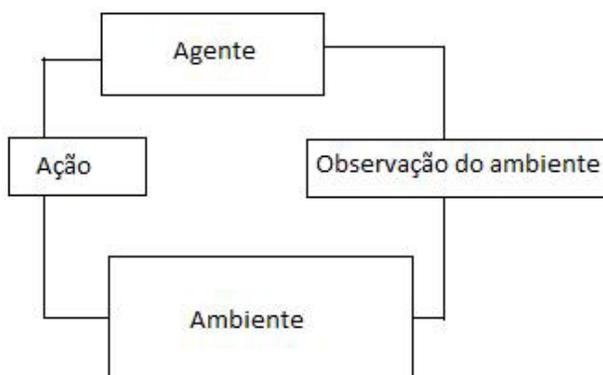
- A classificação consiste no processo de encontrar um modelo que descreva e distinga classes de dados ou conceitos. Depois de encontrado esse modelo, é possível aplicá-lo de forma a prever a classe de um novo objeto. O modelo gerado é baseado na análise de um conjunto de dados, designado por conjunto de treino.

Para a execução da tarefa de classificação é possível aplicar uma série de métodos de aprendizagem automática nomeadamente: árvores de decisão, regras de classificação (regras if-then), programação lógica indutiva, SVM, redes bayesianas, entre outros.

- A aprendizagem não supervisionada procura encontrar padrões similares entre as várias características dos dados. O *Clustering* é a técnica mais comum de aprendizagem não supervisionada, é usada para análise exploratória de dados para encontrar padrões e agrupar os dados em grupos, clusters.

A Aprendizagem por reforço [4] foca-se no objetivo de maximizar a recompensa final, ou seja, atingir o objetivo definido com o máximo número de recompensas acumuladas em cada passo e ação, evitando dessa forma as ações com resultados negativos e obtendo a solução ótima para todo o problema, sem qualquer ajuda. A **Figura 1** esquematiza o modelo de aprendizagem por reforço.

Figura 1 - Modelo de aprendizagem por reforço.



1.4 ALGORITMOS DE CLASSIFICAÇÃO (ABORDADOS NESTE TRABALHO)

No estado da arte existem diversos algoritmos de classificação e cada algoritmo tem abordagens diferentes de aprendizagem.

O melhor método ou o método único não existe. Encontrar o algoritmo certo, em parte, é ir por tentativa erro – os cientistas altamente experientes não conseguem provar se o método irá funcionar sem o experimentarem. Mas a seleção dos algoritmos também depende do tamanho e tipo de dados com os quais estamos a trabalhar.

1.4.1 Método 1, kNN (K-nearest neighbors)

OkNN[5] categoriza objetos baseando-se na proximidade das observações, assume que objetos próximos são semelhantes, logo pertencem à mesma classe. Usa métricas como a distância Euclidiana, distância de Hamming, distância de Manhattan e Distância de Markowski para encontrar o vizinho mais próximo.

1.4.2 Método 2, SVM (Support-vector machine)

O Support Vector Machine (SVM) [6] é um método de aprendizagem supervisionada, utilizado quer para classificação como para regressão.

Em tarefas que requerem a aprendizagem de duas classes, o objetivo do SVM é encontrar a melhor função de classificação que permita a distinção entre membros de duas classes num conjunto de treino . As SVM's classificam os dados de modo a encontrar uma função de classificação linear que separa os dados por um hiperplano que atravessa as duas classes. O melhor hiperplano para uma SVM tem de apresentar uma margem larga entre as duas classes, quando os dados estão linearmente separados. Se os dados não estiverem separados linearmente, uma função de perda é utilizada.

1.4.3 Método 3, Regressão Logística

O método de Regressão Linear [7] pode ser utilizado para estudar a relação entre duas variáveis . Por ser um método simples, a regressão logística é usada como um ponto de partida para problemas de classificação binária (MathWork em *Introducing Machine Learning*). A expressão linear que explica a relação binária é dada por:

$$y = B_0 + B_1x + u$$

Onde,

y, consiste na variável dependente;

x, diz respeito á variável independente;

u, ou erro, fatores que influenciam y para além de x;

B₀, parâmetro de interceção, conhecido por constante;

B₁, representa o declive na relação entre x e y.

Para estimar B₀ e B₁ é necessário recorrer ao método dos mínimos quadrados.

1.4.4 Método 4, Naive Bayes

O classificador Naive Bayes [8] baseia-se na aplicação do teorema Bayes, expressão matemática usada para o cálculo da probabilidade de um dado evento acontecer visto que outro ocorreu, e assume que a presença de características particulares numa classe não está relacionada com as características de outra classe. O desempenho deste método pode ser comparado ao método de Árvores de Decisão . O método classifica novos dados baseados na probabilidade de pertencerem a uma determinada classe . O Teorema de Bayes é expresso matematicamente pela seguinte equação:

$$P(A, B) = \frac{P(B, A)P(A)}{P(B)}$$

Onde,

$P(A)$ e $P(B)$, são as probabilidades de A ocorrer e B ocorrer;

$P(A, B)$ é a probabilidade de A acontecer dado que B ocorreu;

$P(B, A)$ é a probabilidade de B acontecer dado que A ocorreu.

1.4.5 Método 5, Árvores de Decisão

As Árvores de Decisão [9] têm por base algoritmos que dividem o conjunto inicial de dados em subconjuntos mais homogêneos que por sua vez se podem dividir em subconjuntos ainda mais homogêneos . Uma árvore de decisão é formada por um conjunto de nós de decisão, perguntas, que permitem a classificação de cada caso. A árvore de decisão permite prever as respostas dos dados seguindo uma rota desde o início ao fim do último nó. A árvore consiste em condições de ramificação em que o valor da previsão é comparado a um peso de treino. O número de ramificações e os valores dos pesos são determinados no processo de treino. Modificações adicionais podem ser usadas para simplificar o modelo.

As árvores de decisão caracterizam-se por utilizarem a estratégia de divisão e conquista. Sendo assim, focam-se num problema considerado complexo, dividindo-o em problemas mais simples e recursivamente aplicando a mesma estratégia a sub-problemas. No final, as soluções dos sub-problemas podem ser combinadas para gerar a solução do problema inicial.

2 CASO DE ESTUDO – CLASSIFICAÇÃO DA APTIDÃO DOS SOLOS PARA O REGADIO NA REGIÃO DA COVA DA BEIRA

A agricultura é afetada pelos problemas de seca e escassez de água em algumas regiões do País, imediatamente se percebe a importância da estratégia de implementar

um regadio para sustentar níveis de produtividade e redução de custos nos processos agrícolas de maneira a não comprometer as gerações futuras.

Segundo a Direção Geral de Agricultura (DGA), Portugal apresenta níveis de precipitação média anual da ordem dos 700mm, contudo o desequilíbrio da precipitação pelo país gera problemas de escassez principalmente nos meses de abril a setembro. Posto isto o desenvolvimento da cultura vegetativa no período primavera-verão torna-se difícil.

O regadio surge então com um papel preponderante no que diz respeito à sustentabilidade da agricultura como também para o desenvolvimento socioeconómico das zonas rurais. É importante realçar que o uso de regadio não implica que os utilizadores tomem medidas eficientes para assegurar a quantidade de água que cada um necessita, dado que este recurso (água) em questões económicas, sociais e ambientais é deveras importante.

Na região da Cova da Beira, o regadio abrange vários concelhos: Sabugal, Belmonte, Penamacor, Covilhã e Fundão, com uma área de 12360ha, [10]. Atualmente está em estudo o alargamento do regadio, concretamente a sul da Serra da Gardunha, para zonas com forte potencial na atividade frutícola onde se verificou um aumento das áreas de pomar.

Dada a importância do regadio no que diz respeito ao setor agrícola, a análise e avaliação da aptidão que os solos têm para receber água é crucial para a construção do mesmo. A aptidão dos solos para a atividade agrícola permite avaliar a capacidade de cada parcela de solo para uma determinada cultura com o objetivo de tornar rentável os recursos bem como aumentar a produtividade.

2.1 ANÁLISE DOS DADOS

Nesta secção são descritos os condicionantes dos solos, estes apresentam as características dos solos utilizadas para efeitos de estudo que irão permitir identificar uma classe de aptidão de rega. Cada parcela de solo foi classificada relativamente a diversas características tais como, a natureza do solo (NR), como sendo boa, regular, sofríveis, medíocres e maus.

A espessura efetiva do solo (E), para espessura superior a 100 cm, classe E1, classe E2 para espessuras entre 60 cm e 100 cm, E3 para espessuras entre os 40 cm e 60 cm, classe E4 para espessuras entre os 25 cm e 40 cm e classe E5 para espessuras de solo inferiores a 25 cm.

A capacidade de água utilizável (CA), por uma camada de solo, corresponde a mais um critério da classificação para a aptidão de rega e estabelece 5 classes. A capacidade

de água utilizável pelas plantas mais elevadas, requerem regas mais alargadas e por consequência menos mão-de-obra.

Condições de drenagem (HD), muitas culturas precisam de boas condições de drenagem dos solos para que consigam produzir com maior eficiência e eficácia. Um solo com fraca capacidade de escoar e eliminar o excesso de água pode alagar-se. Esta característica compreende 5 classes. Solos com boa capacidade de drenagem (HD1) até uma fraca capacidade de drenagem (HD5).

Outra característica é o risco de erosão (RE), as práticas agrícolas e a forma inadequada como se utiliza o solo são os principais fatores responsáveis pelo processo de erosão, como consequência perdem-se camadas superficiais reduzindo assim a sua produtividade.

O risco de inundação (HI), esta característica é importante no sentido em que zonas com elevado risco de inundação não necessitem de ser regadas, este condicionalismo apresenta 5 classes, (HI1) para solos com riscos nulos de inundação e (HI5) até riscos elevados.

A perigosidade (P), é simplesmente a característica, que afeta o uso de máquinas agrícolas. Define-se em 5 classes, (P1) para solos sem pedregosidade até (P5) que impossibilitam o uso de máquinas agrícolas.

Por último a salinidade (S) dos solos, que permite identificar o grau de afetação dos solos nas culturas. Esse impacto é definido em 5 classes, na classe (S1) são incluídos os solos que não afetam qualquer tipo de cultura, contudo a classe (S5) estão incluídos os solos que impedem o desenvolvimento das culturas.

Com base nestes condicionalismos a tabela seguinte faz corresponder as características de cada parcela de solo a uma classe de aptidão de rega.

Tabela 1 – Condicionalismos e classe de aptidão do solo para o regadio.

CONDICIONALISMOS (Características dos solos que podem condicionar a sua aptidão para o regadio)	CLASSES DE APTIDÃO DO SOLO PARA O REGADIO						
	CLASSE I	CLASSE II	CLASSE III	CLASSE IV	CLASSE V	CLASSE VI	CLASSE VII
NATUREZA DO SOLO (NR)	NR1	NR2	NR3	NR4	NR5	NR5	NR5
ESPESSURA EFECTIVA (E)	E1	E2	E3	E4	E5	E5	E5
RISCOS DE EROÇÃO (RE)	RE1	RE2	RE3	RE4	RE5	RE5	RE5
CAPACIDADE DE ÁGUA UTILIZÁVEL (CA)	CA1	CA2	CA3	CA4	CA5	CA5	CA5

DRENAGEM (HD)	HD1	HD2	HD3	HD4	HD5	HD5	HD5
RISCOS DE INUNDAÇÃO (HI)	HI1	HI2	HI3	HI4	HI5	HI5	HI5
PEDREGOSIDADE E AFLORAMENTOS ROCHOSOS (P – R)	P1 – R1	P1 – R1	P2 – R2	P3 – R3	P4 – R4	P4 – R4	P5 – R5
SALINIDADE E/OU ALCALINIDADE (S)	S1	S2	S3	S4	S5	S5	S5

2.2 RESULTADOS DE CLASSIFICAÇÃO

Os dados são estruturados da seguinte maneira: o ficheiro Excel contém 696 linhas de dados. Para efeitos de programação dos métodos, 75% dos mesmos são utilizados para treinar o modelo enquanto os restantes 25% são utilizados para testar o modelo de previsão. Para gerar uma classe de previsão baseada no histórico os algoritmos obrigatoriamente precisam de uma nova entrada, para tal utilizaram-se os mesmos dados em todos os modelos para avaliar a precisão dos modelos, [3,5,4,5,2,3,1]. Recorreu-se à Matriz de Confusão para avaliar os modelos de classificação, ou seja, se o mesmo previu de forma correta a classe desejada. De uma forma muito simples a Matriz de Confusão é uma tabela que mostra as frequências de classificação para cada classe do modelo. Os valores registados da precisão estão de acordo com a nova entrada.

A fórmula seguinte permitiu validar a precisão dos modelos.

$$Precisão = \frac{TP}{(TP+FP)} \quad (1)$$

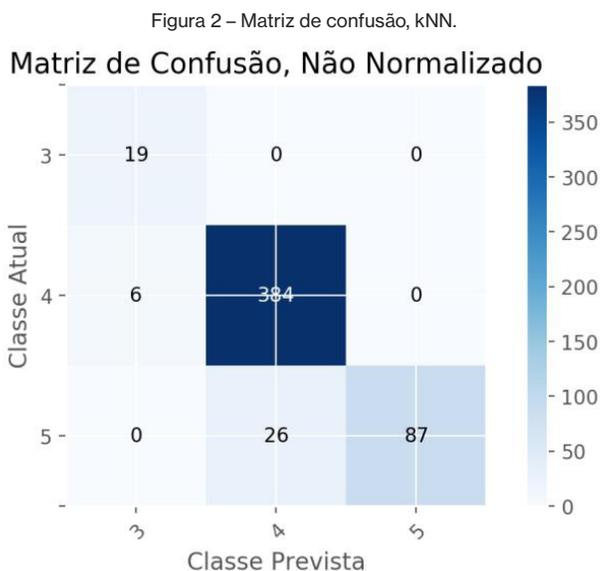
TP: True Positives, FP: False Positives

Tabela 2 – Comparação de métodos.

Método	Métrica de precisão
kNN	93.86 %
SVM	92.91 %
RL	90.80 %
NB	94.63 %
AD	94.44 %

2.2.1 Método kNN

O Método kNN, apresentou uma precisão de 93.8% e atribuiu ao novo dado introduzido a classe de previsão, 5. Segundo a matriz de confusão da Figura 9, as 19 amostras de classe 3, foram corretamente classificadas em classe 3, das 390 amostras de classe 4, 384 foram corretamente classificadas como 4 e 6 foram classificadas em classe 3. Das 113 amostras de classe 5, 87 foram corretamente classificadas, 26 amostras foram identificadas como classe 4.



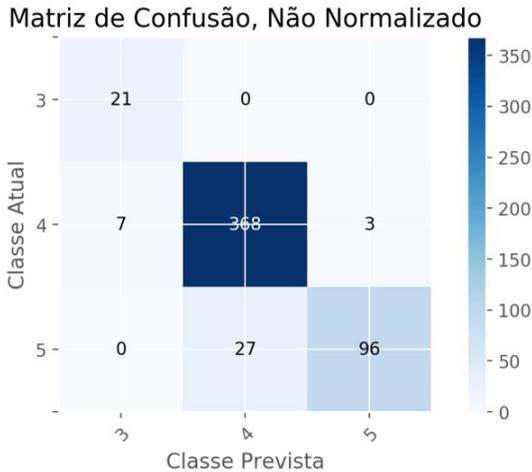
Validação da Precisão

$$Precisão = \frac{TP}{(TP + FP)} = \frac{19 + 384 + 87}{(19 + 384 + 87) + (6 + 26)} = 0.938$$

2.2.2 Método SVM

O Método SVM, apresentou uma precisão de 92.9% e atribuiu ao novo dado introduzido a classe de previsão, 5. Segundo a matriz de confusão da Figura 10, as 21 amostras de classe 3, foram corretamente classificadas em classe 3, das 378 amostras de classe 4, 368 foram corretamente classificadas como 4, 7 classificadas em classe 3 e 3 foram classificadas na classe 5. Das 123 amostras de classe 5, 96 foram corretamente classificadas, 27 amostras foram identificadas como classe 4.

Figura 3 – Matriz de confusão, SVM.



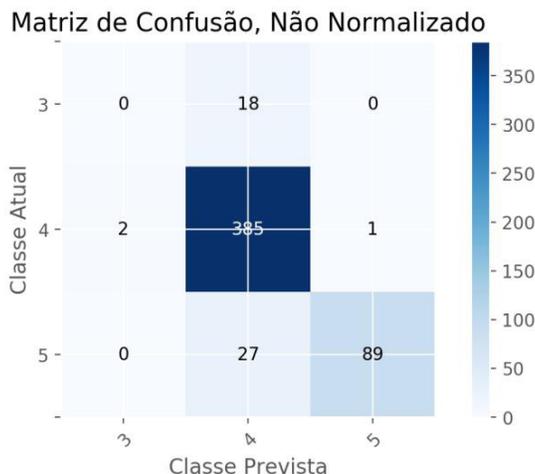
Validação da Precisão

$$Precisão = \frac{TP}{(TP + FP)} = \frac{21 + 368 + 96}{(21 + 368 + 96) + (7 + 3 + 27)} = 0,929$$

2.2.3 Método RL

O Método Regressão Logística, apresentou uma precisão de 90.8% e atribuiu ao novo dado introduzido a classe de previsão, 5. De acordo com a matriz de confusão da Figura 11, as 18 amostras de classe 3, foram classificadas em classe 4, das 388 amostras de classe 4, 385 foram corretamente classificadas como 4, 2 foram classificadas em classe 3 e 1 em classe 5. Das 116 amostras de classe 5, 89 foram corretamente classificadas, 27 amostras foram identificadas como classe 4.

Figura 4 – Matriz de confusão, RL.

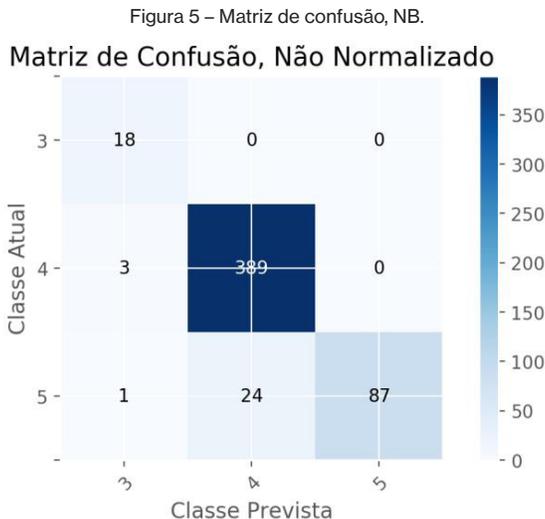


Validação da Precisão

$$Precisão = \frac{TP}{(TP + FP)} = \frac{385 + 89}{(385 + 89) + (18 + 3 + 27)} = 0.908$$

2.2.4 Método NB

O Método probabilístico Naive Bayes, apresentou uma precisão de 94.6% e atribuiu ao novo dado introduzido a classe de previsão, 5. Segundo a matriz de confusão da Figura 12, as 18 amostras de classe 3, foram corretamente classificadas em classe 3, das 392 amostras de classe 4, 389 foram corretamente classificadas como 4 e 3 foram classificadas em classe 3. Das 112 amostras de classe 5, 87 foram corretamente classificadas, 24 amostras foram identificadas como classe 4 e 1 na classe 3.



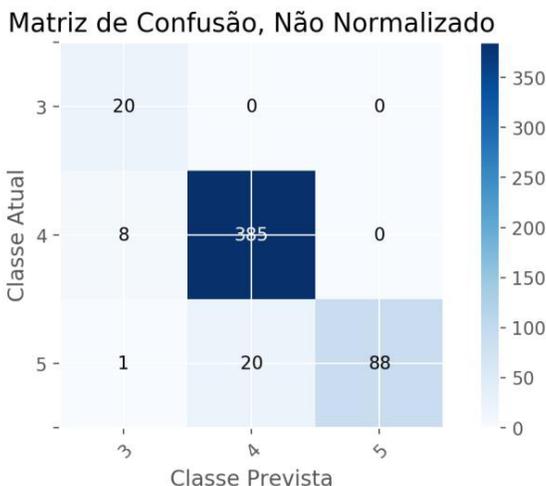
Validação da Precisão

$$Precisão = \frac{TP}{(TP + FP)} = \frac{18 + 389 + 87}{(18 + 389 + 87) + (3 + 1 + 24)} = 0.946$$

2.2.5 Método NB

O Método probabilístico Árvore de Decisão, foi avaliado com uma precisão de 94.4% e atribuiu ao novo dado introduzido a classe de previsão, 3. Segundo a matriz de confusão da Figura 13, as 20 amostras de classe 3, foram corretamente classificadas em classe 3, das 393 amostras de classe 4, 385 foram corretamente classificadas como 4 e 8 foram classificadas em classe 3. Das 109 amostras de classe 5, 88 foram corretamente classificadas, 20 amostras foram identificadas como classe 4 e 1 em classe 3.

Figura 6 – Matriz de confusão, AD.



Validação da Precisão

$$Precisão = \frac{TP}{(TP + FP)} = \frac{20 + 385 + 88}{(20 + 385 + 88) + (8 + 1 + 20)} = 0.944$$

2.3 DISCUSSÃO DOS RESULTADOS

Neste capítulo faz-se a comparação dos resultados obtidos dos diferentes métodos de classificação, avaliar o comportamento dos classificadores após introduzir uma nova entrada (valores que correspondem a cada característica da parcela de solo) como também identificar quais as características das parcelas de solo que influenciam mais os resultados obtidos dos classificadores.

Segundo a literatura, o método SVM é o que melhor se aplica tendo em conta a quantidade de dados presente e o facto de ser um estudo que utilizou métodos de classificação para prever classes de aptidão. Após a análise dos resultados e a validação dos mesmos este estudo mostra que o método que prevê uma melhor classe de aptidão é o método NB (*Naive Bayes*).

A comparação dos métodos de classificação permitiu avaliar o método que gerou da melhor forma a classe após introduzir uma nova entrada. De acordo com a tabela 2 podemos analisar que o método RL apresenta uma métrica de precisão inferior comparada com os restantes métodos. Em relação ao método AD, atribuiu à nova entrada classe 3, contudo apresenta uma métrica superior à da maioria dos métodos, seguindo esta análise os métodos RL e SVM com métricas de precisão inferiores atribuíram à nova entrada, classe 5, a mesma previsão gerada pelo método NB.

Em relação às características que influenciam mais os resultados gerados pelos métodos de classificação, posso afirmar que as características físicas/químicas e biológicas a espessura efetiva como também o risco de inundação são as que influenciam mais os resultados, de modo que, alterando um valor das mesmas o classificador gera outra classe. Para tal, os classificadores que utilizei para comprovar a afirmação acima revelada foi o método de classificação SVM e o método AD.

Os resultados encontrados no presente estudo sugerem que, para uma melhor classificação, previsão e precisão dos métodos, a quantidade de dados recolhidos é bastante importante, quer isto dizer que, como os métodos de previsão utilizam parâmetros de percentagem de dados de teste e treino, quanto mais dados existirem melhor estes métodos classificam as novas entradas introduzidas gerando assim resultados mais fidedignos. Os métodos introduzidos geraram previsões na ordem dos 90 e 95 por cento, o que significa que os mesmos estão bastante otimizados e preveem classes de aptidão para novas entradas de uma forma fidedigna.

3 CONCLUSÕES

Este trabalho vem na sequência de outros projetos anteriormente desenvolvidos com objetivo de implementar, avaliar e validar os diferentes modelos de classificação para prever uma classe de aptidão de solos de modo a otimizar um sistema de rega de precisão com uma contribuição importante para a qual se pretende alargar o regadio da Cova da Beira.

Este estudo é baseado na informação das características dos solos, projeto que foi desenvolvido em 2016 em uma tese de dissertação de mestrado apresentada Escola Superior Agrária do Instituto Politécnico de Castelo Branco [11].

Numa fase inicial o principal desafio foi interpretar e analisar os dados com recurso à linguagem de programação *Python*, posteriormente ultrapassei diversas dificuldades na implementação dos classificadores bem como as respetivas análises de resultados através de matrizes de confusão.

Na sequência deste trabalho, podem ser desenvolvidos projetos na qual o objetivo é construir uma base de dados digital com a informação das características dos solos e introduzir novos dados, de forma a gerar automaticamente classes de previsão para os mesmos com recurso a modelos de classificação com o intuito de fornecer uma resposta mais eficaz na altura de gerar uma previsão.

Como nota final, foi um trabalho realmente desafiante pelo facto de contribuir ou não na decisão de implementar um regadio a sul do concelho do Fundão, como também pelo facto de abordar este capítulo da Inteligência Artificial que é o *Machine Learning*.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] LIAKOS, K.G., P. BUSATO, D. MOSHOV, S. PEARSON, D. BOCHTIS. 2018. **Machine Learning in Agriculture: A Review**. *Sensors*, 18, 2674. <https://doi.org/10.3390/s18082674>.
- [2] COPELAND, M. 2016. **A Diferença Entre Inteligência Artificial, Machine Learning e Deep Learning, Dara Science Brigade**. Disponível online em: <https://medium.com/data-science-brigade/a-diferen%C3%A7a-entre-intelig%C3%Aancia-artificial-machine-learning-e-deep-learning-930b5cc2aa42>, consultado em julho de 2022.
- [3] STIMPSON, A. J., M. L. CUMMINGS. 2014. **Assessing intervention timing in computer-based education using machine learning algorithms**. *IEEE Access* 2: 78-87.
- [4] ARULKUMARAN, K., M. P. DEISENROTH, M. BRUNDAGE, A. A. BHARATH. 2017. **Deep Reinforcement Learning: A Brief Survey**, in *IEEE Signal Processing Magazine*, vol. 34, no. 6, pp. 26-38, , doi: 10.1109/MSP.2017.2743240.
- [5] ZHANG, Z. 2016. **Introduction to machine learning: k-nearest neighbors**. *Ann Transl Med.*, 4(11):218. doi: 10.21037/atm.2016.03.37. PMID: 27386492; PMCID: PMC4916348.
- [6] CERVANTES, J., F. GARCIA-LAMONT, L. RODRÍGUEZ-MAZAHUA, A. LOPEZ. 2020. **A comprehensive survey on support vector machine classification: Applications, challenges and trends**, *Neurocomputing*, Volume 408, Pages 189-215, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2019.10.118>.
- [7] SPERANDEI, S. 2014. **Understanding logistic regression analysis**. *Biochem Med (Zagreb)*. 15;24(1):12-8. doi: 10.11613/BM.2014.003. PMID: 24627710; PMCID: PMC3936971.
- [8] MURPHY, K. P. 2006. **Naive bayes classifiers**.” University of British Columbia 18.60: 1-8.
- [9] SONG, Y. Y., Y. LU. 2015. **Decision tree methods: applications for classification and prediction**. *Shanghai Arch Psychiatry*. 27(2):130-5. doi: 10.11919/j.issn.1002-0829.215044. PMID: 26120265; PMCID: PMC4466856.
- [10] DGADR. 2015. **Sistema de informação do regadio**. Direção Geral de Agricultura e Desenvolvimento Rural. Disponível em: http://sir.dgadr.pt/expl_centro.
- [11] MARQUES, S. G. 2016., **Avaliação da Aptidão dos Solos a Sul do Concelho do Fundão com vista à sua beneficiação pelo regadio, com o uso de ferramentas SIG**. Dissertação para a obtenção de grau mestre na Escola Superior Agrária do Instituto Politécnico de Castelo Branco. Disponível em: <https://webcache.googleusercontent.com/search?q=cache:j5rCGodffCsJ:https://repositorio.ipcb.pt/bitstream/10400.11/5333/1/Thesis.pdf+&cd=13&hl=pt-PT&ct=clnk&gl=pt>

SOBRE O ORGANIZADOR

EDUARDO EUGENIO SPERS realizou pós-doutorado na Wageningen University (WUR), Holanda, e especialização no IGIA, França. Possui doutorado em Administração pela Universidade de São Paulo (USP). Foi Professor do Programa de Mestrado e Doutorado em Administração e do Mestrado Profissional em Comportamento do Consumidor da ESPM. Líder do tema Teoria, Epistemologia e Métodos de Pesquisa em Marketing na Associação Nacional de Pós-Graduação e Pesquisa em Administração (ANPAD). Participou de diversos projetos de consultoria e pesquisa coordenados pelo PENSE e Markestrat. É Professor Titular no Departamento de Economia, Administração e Sociologia, docente do Mestrado em Administração e Coordenador do Grupo de Extensão MarkEsalq no campus da USP/Esalq. Proferiu palestras em diversos eventos acadêmicos e profissionais, com diversos artigos publicados em periódicos nacionais e internacionais, livros e capítulos de livros sobre agronegócios, com foco no marketing e no comportamento do produtor rural e do consumidor de alimentos.

ÍNDICE REMISSIVO

A

Aceite 1, 28, 38, 50, 52, 53, 56, 57, 58, 59, 62, 70, 83, 97, 98, 99, 101, 102, 103, 106, 107, 108, 110, 125, 130, 141, 151, 162, 163, 164, 165, 166, 167, 168, 169, 170, 171, 172, 173, 174, 175, 191, 200, 209, 225, 239, 250, 263, 270, 285, 298, 309, 316, 326

Aceites 33, 56, 57, 100, 107, 109, 162, 163, 165, 166, 168, 169, 170, 171, 172

Agua 33, 42, 47, 71, 72, 73, 74, 77, 78, 80, 81, 86, 87, 99, 101, 102, 103, 104, 105, 106, 107, 126, 130, 131, 133, 136, 163, 164, 167, 168, 169, 180, 187, 191, 192, 193, 194, 195, 196, 197, 198, 203, 204, 208, 211, 215, 216, 217, 225, 226, 227, 228, 230, 231, 236, 239, 241, 242, 244, 245, 246, 247, 263, 264, 265, 266, 267, 268, 269, 294, 295

Alimento composto 239, 244, 245

Amitraz 250, 251, 252, 254, 255, 256, 257, 258, 259, 261, 262

Análisis exergético 71, 75

Análisis fisicoquímicos 162, 163, 169

Apis mellifera 251, 252, 253, 260, 261

Aprendizagem Supervisionada 210, 212, 214

Aptidão solos regadio 210

Arándanos 191, 193, 195, 198

Aspersión 200, 202, 203, 204, 205, 208

Aumento de temperatura 286

Autoevaluación 29, 31, 32, 36

B

Beneficio neto 200, 201

Berry skin 152, 155, 157

Biocombustibles 84, 85, 86, 96, 98, 99, 101, 102, 107, 108, 162, 163, 172

Biocultural 39, 49

Bioetanol 83, 84, 95, 109

Biological effectiveness 142, 146, 147, 148, 150

Biomarcadores 327, 328, 329

Biomasa vegetal 98, 99, 100, 102

C

Cabalo de Pura Raza Galega 298, 299, 303, 310, 312, 313, 314

Carica papaya Linn 50, 51, 52, 53, 54, 55, 56, 57, 58, 60

Cepa 84, 89, 90, 91, 94, 95, 98, 99, 100, 103, 105, 106, 107, 139, 279
Cepas hiperproductoras 84
Cerdo 270, 271, 272, 274, 275, 276, 277, 278, 279, 308
Cerezas 125, 126, 128, 129, 130, 131, 135, 136, 139
Co-diseño 63
Colorantes naturais 125, 126, 129, 130, 137, 138, 139
Complex of amino acids 152, 154
Comprimento 239, 243, 244, 245, 246, 247, 254
Conditional parameters 142, 145, 148
Curros 298, 299, 300, 310, 311, 314, 315

E

Eficácia 143, 180, 217, 250, 251, 254, 256, 257, 258, 259, 260, 261, 307, 324
Enfermedades Infecciosas Emergentes 270, 271
Epifitias 175, 176, 177, 185
Eritrosina 125, 126, 128, 130, 131, 132, 133, 135, 136
Especies nativas 39, 40, 47
Estabilidad 57, 126, 127, 130, 131, 136, 162, 169, 170, 172, 271
Estresse Térmico 286, 294
Extracción de compuestos fenólicos 70, 71, 80

F

Fator K 239, 242, 243, 244, 245, 246, 247
Fermentación 84, 85, 86, 87, 89, 90, 91, 94
Fertilización nitrogenada 200, 202, 203, 206, 207
Flumetrina 251, 254, 255, 256, 257, 258, 259
Fruits 59, 60, 111, 142, 144, 145, 146, 148, 149

G

Ganadería equina 298
Glândula mamária 326, 327, 328, 329, 330
Goteo por fertiriego 200, 202, 203, 204, 205, 206, 208
GreenTray 110, 111
GT bioreactor 110, 111, 112, 115, 116, 117, 118, 120, 121, 122, 123

H

Humedal 225, 226, 227, 228, 231, 237, 238

I

Immune 142, 143, 144

Influenza 3, 80, 102, 225, 226, 228, 234, 235, 236, 246, 296

Innovación social 62, 63, 66, 67, 68, 69

In vitro plant micropropagation 111

IRTA-reactor 111, 112

L

Lactação 326, 327, 329, 330

Lípidos 50, 54, 57, 58, 99, 104, 105, 107, 244, 246

Liquid culture 110, 111, 112, 124

M

Machine Learning 209, 210, 211, 212, 214, 223, 224

Macrófitas acuáticas 225, 226, 229, 230, 235, 236

Macroinvertebrados acuáticos 225, 226, 227, 228, 229, 238

Madre vieja 225, 226, 227, 228

Mal de Panamá 175, 176, 178

Mayos 39, 48

Mecanismos para su presentación 270

Mediterráneo 1, 3, 6

Métodos de extracción 72, 98, 106, 162

Microalgas 98, 99, 100, 101, 102, 103, 107, 108, 109

Micropterus salmoides 239, 240, 247, 248, 249

Moko bacteriano 175, 176

Morfología 190, 226

N

Nematodos 175, 176, 177, 178, 179, 180, 182, 183, 184, 186, 187, 188, 189, 190

O

Optimización de extracción 71

P

Paisagem cultural 1, 2, 3, 22, 25
Parrilla costal 316, 318, 323, 324
Pasturas 263, 264, 265, 269
Património cultural imaterial 1, 13, 22
Perro 52, 316, 317, 318, 324
Pesca artesanal 62, 63, 64, 69
Peso 57, 73, 88, 92, 143, 166, 167, 168, 193, 215, 225, 229, 230, 239, 241, 242, 243, 244, 245, 246, 247, 252, 287, 318, 327, 329
Phenolic compounds 59, 71, 72, 81, 82, 152, 153, 156, 159
Phenolic maturity 152, 153, 154, 158, 160
PH y temperatura 126, 131, 136
Picudo negro 175, 176, 177, 180
Potencialidades 4, 24, 50, 52, 53, 58, 162, 300
Prácticas 28, 29, 30, 31, 32, 35, 36, 37, 40, 187, 188, 310
Produção Animal 286, 326
Productividad 191, 193, 316
Productivity 111, 122, 123, 142, 143, 144, 149, 150, 192
Prototipos 21, 62, 63, 68, 69

Q

Questionários 1
Quimioterapia 316, 317, 324

R

Rapa das Bestas 298, 299, 310, 311, 314
Razas autóctonas 298
Represa 264, 266, 267, 268, 269
Residuos industriales de pistacho 70, 71, 80
Resolución 29, 31, 35, 37
Resultados 1, 12, 16, 18, 19, 21, 22, 29, 32, 34, 39, 43, 47, 57, 58, 69, 71, 73, 74, 76, 79, 81, 88, 90, 95, 100, 106, 126, 131, 132, 133, 136, 168, 169, 170, 172, 182, 183, 184, 185, 187, 188, 194, 200, 201, 205, 207, 208, 209, 211, 213, 218, 222, 223, 230, 233, 239, 243, 245, 247, 251, 256, 257, 258, 267, 270, 279, 280, 289, 291, 304, 307, 316, 319, 324
Riego 33, 180, 191, 192, 193, 194, 195, 196, 197, 198, 199, 200, 201, 202, 204, 263, 264, 265, 266

Rojo gardenia 126

S

Salinidad 102, 103, 104, 191, 192, 193, 194, 195, 196, 197, 198, 199

Salud 28, 29, 35, 50, 51, 52, 53, 54, 58, 72, 97, 125, 128, 129, 164, 271, 272, 273, 278, 279, 316, 324

Scikit-Learn 210

Seeds 51, 59, 60, 82, 152, 158, 159, 160, 173, 174

Semillas 47, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 85, 162, 163, 164, 165, 168, 169, 170, 172, 173, 174, 179, 208

Simulación numérica 71

Sistemas agroforestales 38, 39, 40, 41, 43, 47, 48

Sobreiro 1, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 20, 21, 24, 26

T

Temporary immersion system 110, 111, 121, 122, 123, 124

Tiradores de cortiça 1, 2, 10, 11, 14, 16, 22, 23, 24

TIS 110, 111, 112, 115, 117, 122, 124

Tumor 316, 317, 319, 320, 321, 323, 324, 325

T.V.T 316, 317

V

Valcheta 263, 264, 265

Validación de la innovación social 62, 63, 66, 67

Varroa destructor 250, 251, 252, 255, 259, 260, 261, 262

Vertiente 264, 265, 266, 267

Vertisol 200, 201, 202, 205

Vía subcutánea 316, 318, 323, 324

Vinaza 83, 84, 94, 95, 96