



Ricardo Augusto Manfredini
Geraldo Nunes Corrêa
Bruno Rodrigues de Oliveira
Suellen Teixeira Zavadzki de Pauli
Organizadores

Aplicações de Machine Learning



2021

Ricardo Augusto Manfredini
Geraldo Nunes Corrêa
Bruno Rodrigues de Oliveira
Suellen Teixeira Zavadzki de Pauli
Organizadores

Aplicações de Machine Learning



Pantanal Editora

2021

Copyright© Pantanal Editora

Editor Chefe: Prof. Dr. Alan Mario Zuffo

Editores Executivos: Prof. Dr. Jorge González Aguilera e Prof. Dr. Bruno Rodrigues de Oliveira

Diagramação: A editora. **Diagramação e Arte:** A editora. **Imagens de capa e contracapa:** Canva.com. **Revisão:** O(s) autor(es), organizador(es) e a editora.

Conselho Editorial

Grau acadêmico e Nome

Prof. Dr. Adaylson Wagner Sousa de Vasconcelos
Prof. Msc. Adriana Flávia Neu
Prof. Dra. Albys Ferrer Dubois
Prof. Dr. Antonio Gasparetto Júnior
Prof. Msc. Aris Verdecia Peña
Prof. Arisleidis Chapman Verdecia
Prof. Dr. Arinaldo Pereira da Silva
Prof. Dr. Bruno Gomes de Araújo
Prof. Dr. Caio Cesar Enside de Abreu
Prof. Dr. Carlos Nick
Prof. Dr. Claudio Silveira Maia
Prof. Dr. Cleberton Correia Santos
Prof. Dr. Cristiano Pereira da Silva
Prof. Ma. Dayse Rodrigues dos Santos
Prof. Msc. David Chacon Alvarez
Prof. Dr. Denis Silva Nogueira
Prof. Dra. Denise Silva Nogueira
Prof. Dra. Dennyura Oliveira Galvão
Prof. Dr. Elias Rocha Gonçalves
Prof. Me. Ernane Rosa Martins
Prof. Dr. Fábio Steiner
Prof. Dr. Fabiano dos Santos Souza
Prof. Dr. Gabriel Andres Tafur Gomez
Prof. Dr. Hebert Hernán Soto Gonzáles
Prof. Dr. Hudson do Vale de Oliveira
Prof. Msc. Javier Revilla Armesto
Prof. Msc. João Camilo Sevilla
Prof. Dr. José Luis Soto Gonzales
Prof. Dr. Julio Cezar Uzinski
Prof. Msc. Lucas R. Oliveira
Prof. Dra. Keyla Christina Almeida Portela
Prof. Dr. Leandris Argentele-Martínez
Prof. Msc. Lidiene Jaqueline de Souza Costa Marchesan
Prof. Dr. Marco Aurélio Kistemann
Prof. Msc. Marcos Pisarski Júnior
Prof. Dr. Marcos Pereira dos Santos
Prof. Dr. Mario Rodrigo Esparza Mantilla
Prof. Msc. Mary Jose Almeida Pereira
Prof. Msc. Núbia Flávia Oliveira Mendes
Prof. Msc. Nila Luciana Vilhena Madureira
Prof. Dra. Patrícia Maurer
Prof. Msc. Queila Pahim da Silva
Prof. Dr. Rafael Chapman Auty
Prof. Dr. Rafael Felipe Ratke
Prof. Dr. Raphael Reis da Silva
Prof. Dr. Renato Jaqueto Goes
Prof. Dr. Ricardo Alves de Araújo
Prof. Dra. Sylvana Karla da Silva de Lemos Santos
Prof. Dr. Wéverson Lima Fonseca
Prof. Msc. Wesclen Vilar Nogueira
Prof. Dra. Yilan Fung Boix
Prof. Dr. Willian Douglas Guilherme

Instituição

OAB/PB
Mun. Faxinal Soturno e Tupanciretã
UO (Cuba)
IF SUDESTE MG
Facultad de Medicina (Cuba)
ISCM (Cuba)
UFESSPA
UEA
UNEMAT
UFV
AJES
UFGD
UEMS
IFPA
UNICENTRO
IFMT
UFMG
URCA
ISEPAM-FAETEC
IFG
UEMS
UFF
(Colômbia)
UNAM (Peru)
IFRR
UCG (México)
Mun. Rio de Janeiro
UNMSM (Peru)
UFMT
Mun. de Chap. do Sul
IFPR
Tec-NM (México)
Consultório em Santa Maria
UFJF
UEG
FAQ
UNAM (Peru)
SEDUC/PA
IFB
IFPA
UNIPAMPA
IFB
UO (Cuba)
UFMS
UFPI
UFG
UEMA
IFB
UFPI
FURG
UO (Cuba)
UFT

Conselho Técnico Científico

- Esp. Joacir Mário Zuffo Júnior

- Esp. Maurício Amormino Júnior
- Esp. Tayronne de Almeida Rodrigues
- Lda. Rosalina Eufrausino Lustosa Zuffo

Ficha Catalográfica

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

A642 Aplicações de machine learning [livro eletrônico] / Organizadores Ricardo Augusto Manfredini... [et al.]. – Nova Xavantina, MT: Pantanal, 2021. 55 p. : il.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

ISBN 978-65-81460-20-4

DOI <https://doi.org/10.46420/9786581460204>

1. Inteligência artificial. 2. Redes neurais. 3. Aprendizado de máquina. I. Manfredini, Ricardo Augusto. II. Corrêa, Geraldo Nunes. III. Oliveira, Bruno Rodrigues de. IV. Pauli, Suellen Teixeira Zavadzki de.

CDD 006.3

Elaborado por Maurício Amormino Júnior – CRB6/2422



Nossos e-books são de acesso público e gratuito e seu download e compartilhamento são permitidos, mas solicitamos que sejam dados os devidos créditos à Pantanal Editora e também aos organizadores e autores. Entretanto, não é permitida a utilização dos e-books para fins comerciais, exceto com autorização expressa dos autores com a concordância da Pantanal Editora.

Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000.
Nova Xavantina – Mato Grosso – Brasil.
Telefone (66) 99682-4165 (Whatsapp).
<https://www.editorapantanal.com.br>
contato@editorapantanal.com.br

APRESENTAÇÃO

Este livro aborda cinco diferentes contextos em que as técnicas de aprendizado de máquina podem ser utilizadas, servindo como referência prática em diferentes abordagens, tais como: previsão de consumo de energia elétrica, previsão do valor do preço do petróleo, classificação de arritmias cardíacas e método para a seleção automática de artigos.

Estas aplicações são explanadas pelos autores e diferentes técnicas de aprendizado de máquina são utilizadas, dentre elas: redes neurais (Dense, convolucional, recorrentes, Perceptron multicamadas, Elman e Jordan), Naïve Bayes e mineração de textos. Para a aplicação os autores empregam os softwares (línguas de programação) Python e R. Com o objetivo de apresentar aplicações de algumas das técnicas com destaque na atualidade, primeiramente há um descritivo a respeito de cada abordagem e então, são reportados os treinamentos dos modelos de aprendizado de máquina e os resultados. As técnicas incluem classificação, regressão e também mineração de texto. As possíveis abordagens para os problemas relatados não se restringem às técnicas utilizadas, mas a intenção é motivar o leitor a explorar aplicações na área de aprendizado de máquina.

O livro é destinado a profissionais, estudantes, pesquisadores e demais interessados no tema aprendizado de máquina, estatística e áreas relacionadas a fim de colaborar com a explanação de possibilidades de aplicações destas técnicas em contextos diversos. Presume-se que o leitor esteja familiarizado com os conceitos básicos de machine learning, álgebra linear, probabilidade, e análise de algoritmos. A intenção com esta obra é, primordialmente, explicar as possibilidades de aplicação dos algoritmos elencados.

Nos capítulos 1 e 2 as técnicas de redes neurais artificiais são aplicadas para a previsão de preço do valor de petróleo e consumo de energia elétrica, respectivamente. Tais técnicas tratam de modelos computacionais inspirados no sistema nervoso central de um animal. Elas são apresentadas como um sistema de neurônios interconectados, que podem computar valores de entradas, simulando o comportamento de redes neurais biológicas. Na primeira abordagem a autora utiliza as redes Perceptron multicamadas, Elman e Jordan, já na segunda o autor faz uso das redes híbridas Dense, convolucional e recorrente.


No capítulo 3 é tratada a classificação de arritmias cardíacas e, além da técnica de Naïve Bayes também é utilizada a Transformada Wavelet, que é uma transformada integral que utiliza função wavelets que são capazes de decompor determinado sinal (dado) em diferentes escalas. Além desta, também é empregada uma técnica de Ensemble, que encapsula os modelos obtidos por vários algoritmos de aprendizagem a fim de obter uma única previsão global. Por fim, no capítulo 4 é abordado um método para a seleção automática de artigos. Para isto, é utilizado mineração de texto, que trata do processo de obtenção de informações importantes de um texto.

Os organizadores

SUMÁRIO

Apresentação	4
Capítulo I.....	6
Predição diária do preço de petróleo WTI	6
Capítulo II	15
Redes Neurais Artificiais Híbridas Para a Predição de Consumo de Energia Elétrica	15
Capítulo III.....	32
Reconhecimento de padrões de arritmias cardíacas no Eletrocardiograma (ECG) empregando Transformada Wavelet e o classificador Naïve Bayes	32
Capítulo IV	45
Uso da mineração de textos na análise exploratória de artigos científicos.....	45
Índice Remissivo	54
Sobre os organizadores.....	55

Reconhecimento de padrões de arritmias cardíacas no Eletrocardiograma (ECG) empregando Transformada Wavelet e o classificador Naïve Bayes

 10.46420/9786581460204cap3

Bruno Rodrigues de Oliveira^{1*} 

INTRODUÇÃO

Uma das principais causas de óbito no mundo é ocasionada por doenças cardiovasculares, que já são consideradas de proporções epidêmicas de acordo com a Organização Mundial de Saúde. Em 2016, por consequência de tal doença, cerca de 17,9 milhões de pessoas vieram a óbito². Para se ter uma ideia dos números envolvidos, nos EUA a cada 36 segundos uma pessoa morre de doença cardiovascular e a cada 4 óbitos 1 é em decorrência de alguma doença do coração (CDC, 2020). No Brasil, a taxa de mortalidade por conta de infarto agudo do miocárdio (IAM) é de 183,3 por 100 mil habitantes (Santos, 2018) e a cada 90 segundos morre uma pessoa por doença cardiovascular de acordo com a Sociedade Brasileira de Cardiologia³.

O coração humano é composto por quatro câmaras, sendo dois átrios e dois ventrículos. As câmaras direitas recebem o sangue do sistema circulatório e o bombeia para os pulmões, já as câmaras esquerdas recebem este sangue oxigenado e o bombeia para o sistema circulatório e para os órgãos periféricos. A atividade contrátil das câmaras ocorre devido a despolarização e repolarização elétrica das células do coração, que decorrem das alterações químicas no conteúdo intracelular (Guyton; Hall, 2006; Hampton, 2014; Mohrman, 2011).

Um dos exames mais empregados para avaliar a saúde do coração é o eletrocardiograma (ECG), o qual é “considerado padrão ouro para o diagnóstico não invasivo das arritmias e distúrbios de condução, além de ser muito importante nos quadros isquêmicos coronarianos, constituindo-se em um marcador de doença do coração” (Nicolau et al., 2003). O ECG é o resultado da sobreposição da atividade elétrica das células do miocárdio, estas estão localizadas em diferentes partes do coração e cada conjunto delas tem características próprias, pois apresentam potenciais de repouso e de ação com magnitudes e durações distintas. Isso torna o ECG um sinal com representação peculiar, sendo este formado geralmente por ondas nominadas de P, Q, R, S e T, onde a onda P representa a despolarização

¹ Pantanal Editora.

* Autor correspondente: bruno@editorapantanal.com.br

² [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))

³ <http://www.cardiometro.com.br/>

dos átrios, o complexo QRS a despolarização dos ventrículos e a onda T a repolarização ventricular (Hampton, 2014).

Para registrar o ECG, diferentes configurações de eletrodos (sensores) podem ser utilizadas e estas recebem o nome de derivações. Nas derivações bipolares (DI, DII e DIII) e unipolares aumentadas (avR, avL e avF) os eletrodos são dispostos nos braços e pernas. Por outro lado, na derivação precordial, rotuladas de V1 a V6, estes são dispostos no tórax e nos membros inferiores (Hampton, 2014; Mohrman, 2011).

Normalmente o marcapasso do coração é determinado no nodo Sinoatrial (SA), localizado no átrio direito. O impulso elétrico se propaga das células adjacentes para o átrio esquerdo e para o nodo Atrioventricular (AV), que é retardado em cerca de 130 milissegundos (ms), possibilitando que a contração dos átrios se encerre antes de iniciar a dos ventrículos. O impulso elétrico continua seu trajeto e chega às fibras de Purkinge, onde a condução é rápida. Estas fibras são formadas pelo feixe de His e seus ramos esquerdo e direito, os quais conduzem o impulso elétrico a todas as células ventriculares (Mohrman, 2011). Pode ocorrer que o marcapasso cardíaco seja assumido por outras áreas do coração devido a certos bloqueios da condução do impulso elétrico, mecanismos de reentrada, doença do nodo SA, bradicardia sinusal, alimentação, uso de tabaco, dentre outros fatores (Woods et al., 2005). Nestes casos ocorrem batimentos ectópicos e mudanças no ritmo cardíaco, levando ao surgimento das arritmias cardíacas.

As arritmias cardíacas são distúrbios ocasionados por alterações na formação e/ou condução do impulso elétrico através do tecido do miocárdio, podendo, assim, modificar a origem e/ou a difusão fisiológica do estímulo elétrico do coração, motivo pelo qual têm no eletrocardiograma o método de escolha para seu estudo e diagnóstico. As alterações na velocidade da propagação do estímulo elétrico, isoladamente, levando a bloqueios dos fascículos ou ramos, não são consideradas arritmias cardíacas (Nicolau et al., 2003).

O estudo da eletrofisiologia do coração teve início com Willem Einthoven, por volta de 1885, com o desenvolvimento do galvanômetro de corda. Muitos avanços foram feitos no aperfeiçoamento do eletrocardiógrafo, em 1961 Norman Jefferis Holter descreveu os primeiros usos práticos da utilização de eletrocardiógrafos mais compactos para monitoramento ambulatorial (Dimarco; Philbrick, 1990). Hoje tais dispositivos são utilizados para registro de sinais de ECG em períodos superiores à dias de duração (Barrett et al., 2014). Algumas das vantagens da utilização do monitoramento ambulatorial são: correlação entre sintomas e arritmias, detecção de isquemia miocárdica, monitoramento após IAM, avaliação de arritmias em pacientes assintomáticos, prevalência de contração ventricular prematura, avaliação do envolvimento cardíaco na sarcoidose, diagnóstico de acidente vascular cerebral, dentre outros (Latchamsetty; Bogun, 2015; Kuchar et al., 1987; Suzuki et al., 1994; Lipski et al., 1976; Shafqat et al., 2004).

Devido à grande quantidade de dados que são gerados pelos dispositivos Holter, ferramentas computacionais são indispensáveis para os diagnósticos médicos. Muitos métodos computacionais foram

concebidos nos últimos anos para análise automática de ECG. Interessa a essa pesquisa aqueles métodos que são dedicados ao reconhecimento dos padrões arrítmicos empregando técnicas de aprendizado de máquina.

Neste capítulo é descrita uma abordagem matemático/computacional para o reconhecimento de arritmias cardíacas empregando uma das técnicas mais simples de aprendizado de máquina, denominada de Naïve Bayes. Para a extração de atributos dos sinais de ECG é utilizado o método de processamento de sinais denominado de Transformada Wavelet e, visto que são gerados muitos vetores de atributos para o mesmo sinal, várias máquinas de aprendizado foram induzidas, exigindo, portanto, o emprego da técnica de Comitê de Máquinas.

Este capítulo está assim organizado. A seção material e métodos está dividida em 2 subseções, na primeira, Base de Dados, estão discriminados os registros ECG utilizados. Na segunda, Ferramentas, são descritas a Transformada Wavelet, a abordagem Naïve Bayes e o Comitê de Máquinas (Ensemble). Na seção Metodologia Proposta é apresentada uma nova metodologia para o reconhecimento de arritmias cardíacas e, por fim, na seção Resultados e Discussões, são apresentados os resultados obtidos empregando a base de dados MIT-DB e a metodologia proposta.

MATERIAL E MÉTODOS

Base de dados

As arritmias são classificadas pela *Association for the Advancement of Medical Instrumentation* (AAMI) de acordo com o Quadro 1 (AAMI, 1987). Devido a quantidade de batimentos cardíacos da classe normal ser superior as quantidades de batimentos arrítmicos, na pesquisa ora apresentada foram consideradas apenas duas classes, a saber: normal e abnormal, sendo que a última inclui as classes supraventricular ectópico e ventricular ectópico. Os batimentos cardíacos das classes fusão e desconhecido não foram empregadas.

Quadro 1. Classes AAMI dos batimentos cardíacos e rótulos associados.

Classe AAMI	Batimento Cardíaco	Rótulo
Normal	Normal	N
	Bloqueio do ramo esquerdo	L
	Bloqueio do ramo direito	R
	Escape atrial	e
	Escape atrioventricular	j
Supraventricular Ectópico	Contração prematura atrial	A
	Contração prematura atrial aberrante	a
	Contração atrioventricular prematura	J
	Contração prematura supraventricular	S
	Ventricular Ectópico	Contração prematura ventricular

Classe AAMI	Batimento Cardíaco	Rótulo
	Escape ventricular	E
Fusão	Fusão de normal e ventricular	F
Desconhecido	Ritmado	/
	Fusão ritmado e normal	f
	Não classificado	Q

As classificações dos batimentos cardíacos (coluna 2 do Quadro 1) são empregados pela PhysioNet (Research Resource for Complex Physiologic Signals) nos sinais de ECG que são disponibilizados em seu repositório para alguns dos seus conjuntos de dados. Nesta pesquisa foi utilizada a base de dados MIT-BIH Arrhythmia Database (MIT-DB) (Goldberger et al., 2000) que é composta por 48 registros de ECG de 47 pacientes com duração aproximada de 30 minutos cada, os quais foram obtidos entre 1975 e 1979 no Boston's Beth Israel Hospital (BIH) Arrhythmia Laboratory. Os sinais de ECG foram amostrados a taxa de 360 Hz com 11 bits de resolução sobre um intervalo de 10 microvolt (mV), todos foram previamente analisados por especialistas que providenciaram as marcações das arritmias, seguindo o esquema dos rótulos discriminado no Quadro 1.

Ferramentas

A seguir serão descritas, de forma sucinta, as ferramentas matemáticas utilizadas para resolver o problema de reconhecimento de arritmias cardíacas. Para mais detalhes sobre estas ferramentas, o leitor deve consultar as referências (Daubechies, 1992; Mallat, 2009; Soman et al., 2010).

Transformada Wavelet

A Transformada Wavelet Contínua (Continuous Wavelet Transform - CWT) é uma transformada integral multiescala que computa a similaridade entre um sinal x e uma função núcleo ψ , denominada de wavelet. A CWT tem sido aplicada nas mais diversas áreas, tais como análise do clima, séries financeiras, monitoramento cardíaco, remoção de ruído em dados sísmicos e astronômicos, caracterização de fissuras, solução rápida de equações diferenciais parciais, computação gráfica, caracterização de turbulência, dentre outras (Soman et al., 2010).

Uma função $\psi(t) \in L^2(\mathbb{R})^4$ com norma unitária é uma função wavelet se a condição de admissibilidade, $C_\psi = 2\pi \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty$, for satisfeita, onde $\Psi(\omega)$ é a Transformada de Fourier de $\psi(t)$. Essa condição implica que a função $\psi(t)$ tem média nula, isto é $\int_{-\infty}^{\infty} \psi(t) dt = 0$ (Daubechies, 1992), e isso caracteriza seu caráter ondulatório e o suporte compacto, diferenciando-a das funções núcleo do tipo senoides que oscilam indefinidamente.

⁴ Espaço das funções reais de quadrado integrável.

Em processamento de sinais a CWT é empregada, principalmente, para análise multiescala. Para tanto é necessário gerar uma família de funções wavelets, utilizando translações por τ e dilatações por $s \neq 0$ da “wavelet mãe” $\psi_{s,\tau}(t) = |s|^{-0.5}\psi(\frac{t-\tau}{s})$, onde t é um índice de tempo. Assim, a CWT de um sinal $x(t) \in \mathbb{R}^N$ é dada pela integral $CWT_x(s, \tau) = \int_{-\infty}^{\infty} x(t)\underline{\psi}_{s,\tau}(t) dt$ onde $\underline{\psi}_{s,\tau}(t)$ e denota o conjugado complexo de $\psi_{s,\tau}(t)$. Portanto, a CWT transforma um sinal unidimensional de comprimento N em uma representação bidimensional $s \times N$. Quando o parâmetro de escala s está restrito ao intervalo aberto $(0, 1)$, a família de wavelets é uma versão comprimida da wavelet “mãe” $\psi_{s,\tau}(t)$. Portanto, as porções do sinal $x(t)$ com a mais alta frequência serão ressaltadas. Por outro lado, se $s > 1$, tem-se uma versão dilatada da wavelet mãe e então as oscilações de baixa frequência são destacadas na transformada (Mallat, 2009).

Existem muitas funções wavelets e cada uma possui características que a tornam mais ou menos adequada dependendo da aplicação selecionada. Neste capítulo foi empregada a wavelet complexa de Morlet pois ela possui características frequências que são úteis para a resolução do problema de reconhecimento de padrões arrítmicos. Sua expressão analítica é dada por $\psi(t) = \frac{1}{\sqrt{\pi}} \exp(-t^2)\exp(j2\pi Ct)$, onde j é a unidade imaginária, C a frequência central e $\exp()$ a função exponencial.

Aprendizado de Máquina, Naïve Bayes e Comitê de Máquinas

Dado um conjunto de dados $T = \{(\mathbf{x}_k, y_k)\}_{k=1}^K$ que possui informações de um ambiente qualquer, o objetivo do aprendizado de máquina é aprender uma função $\hat{h}(\mathbf{x}_k, \theta) = y_k$ que associa os padrões $\mathbf{x}_k \in \mathbb{R}^N$ às classes⁵ $y_k \in \{0,1\}$ ⁶, onde θ é um vetor de parâmetros da função \hat{h} a qual é uma estimativa da função real h , que por sua vez representa o processo que gera y_k a partir de \mathbf{x}_k . Os padrões $\mathbf{x}_k = [x_{k1}, x_{k2}, \dots, x_{kN}]$ são compostos das variáveis (atributos) x_{kn} ($n = 1, 2, \dots, N$) independentes, sendo que cada componente explica, ao seu modo, a variável dependente y_k . Para aprender a função \hat{h} , utiliza-se parte do conjunto T na etapa conhecida como treinamento (ou indução). Esta abordagem é denominada de aprendizado supervisionado, pois conhecemos *a priori* as classes de cada padrão. A outra parte do conjunto T , não empregada para o aprendizado, é utilizada para testar se a função aprendida é uma boa estimativa da função real, utilizando alguma(s) métrica(s) de performance.

Um dos algoritmos mais simples para aprender \hat{h} é conhecido como Naïves Bayes, que se baseia no conceito de probabilidade condicional pelo Teorema de Bayes (Kubat, 2015). Assim, para obter a probabilidade de um padrão \mathbf{x}_k pertencer à classe y_{ki} , calculamos a probabilidade condicional

⁵ Em problemas de regressão y_k é um valor real.

⁶ $\{0,1\}$ significa um problema de classificação binário. Outras designações podem ser adotadas conforme o número de classes.

$p(y_{ki}|\mathbf{x}_k) = p(\mathbf{x}_k|y_{ki})p(y_{ki})/p(\mathbf{x}_k)$. Como a verossimilhança depende de N variáveis, seu cálculo tem alto custo computacional. Para driblar esse custo, supõe-se que as variáveis independentes são também mutuamente independentes, por isso o método é denominado “*Naïve*” que significa ingênuo. Portanto, a equação anterior toma a forma $p(y_{ki}|\mathbf{x}_k) \approx p(y_{ki}) \prod_{n=1}^N p(x_{kn}|y_{ki})$, onde o denominador não foi considerado pois é uma constante para todas as classes. Embora tal suposição não se verifica em muitos problemas reais, ainda assim este método é um bom classificador, porque o valor em si da probabilidade computada é menos importante, já que ela é utilizada na comparação das probabilidades. Ou seja, faz-se o seguinte: se $p(y_{ki}|\mathbf{x}_k) > p(y_{kj}|\mathbf{x}_k)$, então \mathbf{x}_k pertence à classe i , onde $i = 0$ e $j = 1$ (ou $i = 1$ e $j = 0$). Se as variáveis são reais (valores contínuos), então deve-se utilizar alguma função de distribuição de probabilidade (Kubat, 2015). A mais utilizada é a Gaussiana, dada pela equação $p(x_{kn}|y_{ki}) = (2\pi\sigma_{n,y_i}^2)^{-0.5} \exp[-(x_{kn} - \mu_{n,y_i})/2\sigma_{n,y_i}^2]$, onde os parâmetros desvio padrão σ_{n,y_i}^2 e média μ_{n,y_i} são aprendidos na fase de treinamento para cada variável independente e classe, os quais compõem o vetor θ .

Se um certo padrão \mathbf{x}_k puder ser representado de diferentes modos, aplicando por exemplo uma ferramenta como a CWT para extrair informações latentes deste padrão, então é necessário aprender várias funções \hat{h} para cada modo, onde cada uma delas aprenderá particularidades distintas do mesmo padrão. Neste caso, tem-se um comitê de máquinas de aprendizado e a decisão final sobre a classe do padrão \mathbf{x}_k será tomada levando em conta a predição de cada uma das funções induzidas. Para tanto, o voto majoritário ponderado é uma das abordagens possíveis, e nesta considera-se que a classe predita é dada por $\hat{y}_k = \arg \max_c \{1/Q \sum_{q=1}^Q w_q p_q(c|\mathbf{x}_k)\}$, onde c é uma classe, $p_q(c|\mathbf{x}_k)$ é a probabilidade associada à função \hat{h}_q , w_q o peso dessa função, sendo estes valores associados à q -ésima função aprendida (Dietterich, 2000).

Para a determinação dos pesos w_q calcula-se $w_q = M_{\hat{h}_q} / \sum_{q'=1}^Q M_{\hat{h}_{q'}}$, onde $M_{\hat{h}_q}$ é uma métrica de performance obtida pela função estimada \hat{h}_q . Outras abordagens para calcular os pesos podem ser encontradas em Oliveira et al. (2019).

Para medir a performance dos modelos induzidos foram utilizadas três medidas: Acurácia (Acc), Precisão (Pr) e Recobrimento (Re) dadas pelas fórmulas: $Acc = \frac{TP+TN}{TP+TN+FP+FN}$, $Pr = \frac{TP}{TP+FP}$ e $Re = \frac{TP}{TP+FN}$, onde TP, TN, FP, FN são as quantidades de verdadeiros positivos e negativos, e falsos positivos e negativos, respectivamente.

METODOLOGIA PROPOSTA

Para reconhecer um batimento cardíaco como pertencente a classe normal ou abnormal (arritmico), primeiro é necessário separar cada batimento do sinal de ECG. Isso é feito detectando as

ondas R de cada batimento. Visto que na base MIT-DB a posição das ondas R já estão destacadas, estes valores serão utilizados para segmentação de cada batimento tomando um segmento correspondente a 0,8 segundos (tempo médio de um ciclo cardíaco), sendo 0,3 segundos antes e 0,5 segundos depois de cada onda R. Para cada batimento é aplicada a CWT nas escalas que possuem informações espectrais relevantes. Para descobrir quais as faixas de frequências mais importante para cada tipo de batimento e, portanto, quais as escalas mais adequadas, foi feita uma análise frequencial da média de 10 batimentos da mesma classe empregando a Transformada de Fourier de Tempo Curto (Sundararajan, 2001). Considerando como corte o valor da densidade espectral de potência $2 \times 10^{-4} mV^2/Hz$, o Quadro 2 a seguir mostra as informações espectrais dos batimentos cardíacos considerados pela AAMI (Quadro 1).

Quadro 2. Intervalos de frequência para cada tipo de batimento cardíaco.

Batimento	Intervalo de frequência (Hz)
N	2,50 – 24,50
L	1,20 – 13,70
R	0,60 – 30,50
e	0,03 – 30,00
j	0,80 – 26,40
A	0,25 – 33,00
a	0,05 – 35,80
J	0,05 – 22,45
S	0,15 – 34,10
V	0,03 – 12,25
E	0,18 – 13,00
F	0,37 – 16,05
P	0,02 – 9,05
f	0,09 – 21,00
Mínimo – Máximo	0,02 – 35,80

Nota-se do Quadro 2 (cinco primeiras linhas) que os batimentos classificados na classe normal, estão compreendidos no intervalo de frequência [0,03 ; 30,50]Hz, enquanto que, para os batimentos das outras classes, observa-se um intervalo de [0,02 ; 35,80]Hz. Logo, apenas as informações espectrais não são suficientes para a classificação. No entanto, a CWT combina informações espectrais com informações temporais, e mesmo que o espectro Wavelet seja diferente do espectro de Fourier, uma vez que existe uma relação proporcional inversa entre escala e frequência, as informações frequenciais do Quadro 2 são úteis para que se possa fixar as escalas de análise da CWT.

Visto que os sinais de ECG foram amostrados a 360Hz, então, quando a frequência central da Wavelet Complexa de Morlet é igual a 1, na escala $s = 1$ os coeficientes wavelets representam informações em torno dos 360Hz. Portanto, considerando as frequências mínimas e máximas dos batimentos analisados, Quadro 2, as escalas escolhidas devem variar de $s = 10$ a $s = 1000$, onde na escala $s = 10$ aparecerão as componentes espectrais em torno de 36Hz e na escala $s = 1000$ em torno de 0,36Hz. No entanto, essa escala muito alta pouca informação adiciona à análise, pois, a maior parte da energia está concentrada nas frequências mais altas. Sendo assim, aqui será fixada a escala máxima igual $s = 100$, a qual conterà informações em torno de 3,6Hz. Embora nem todo o conteúdo espectral seja coberto com esta escolha, destaca-se que na aplicação da transformada wavelets existe o fenômeno denominado de escape de energia. Isso significa que outras frequências além daquelas mencionadas poderão ser cobertas, já que, as respostas em frequências das funções wavelets não são ideais. Mais detalhes podem ser consultados em Oliveira et al. (2018).

Para exemplificar como as informações espectrais variam entre escalas, na Figura 1 (a) está ilustrado um segmento inicial do sinal de ECG do registro 233 e na Figura 1 (b) o escalograma dos coeficientes wavelets deste sinal, o qual é obtido calculando o quadrado do valor absoluto desses coeficientes. As escalas variam entre 10 e 100 com um incremento de 5. Na Figura 1 (b), as cores mais claras e mais escuras representam os maiores e menores valores, respectivamente. Na Figura 1 (a) o 1º e o 3º batimentos são da classe contração prematura ventricular, enquanto os demais são da classe normal.

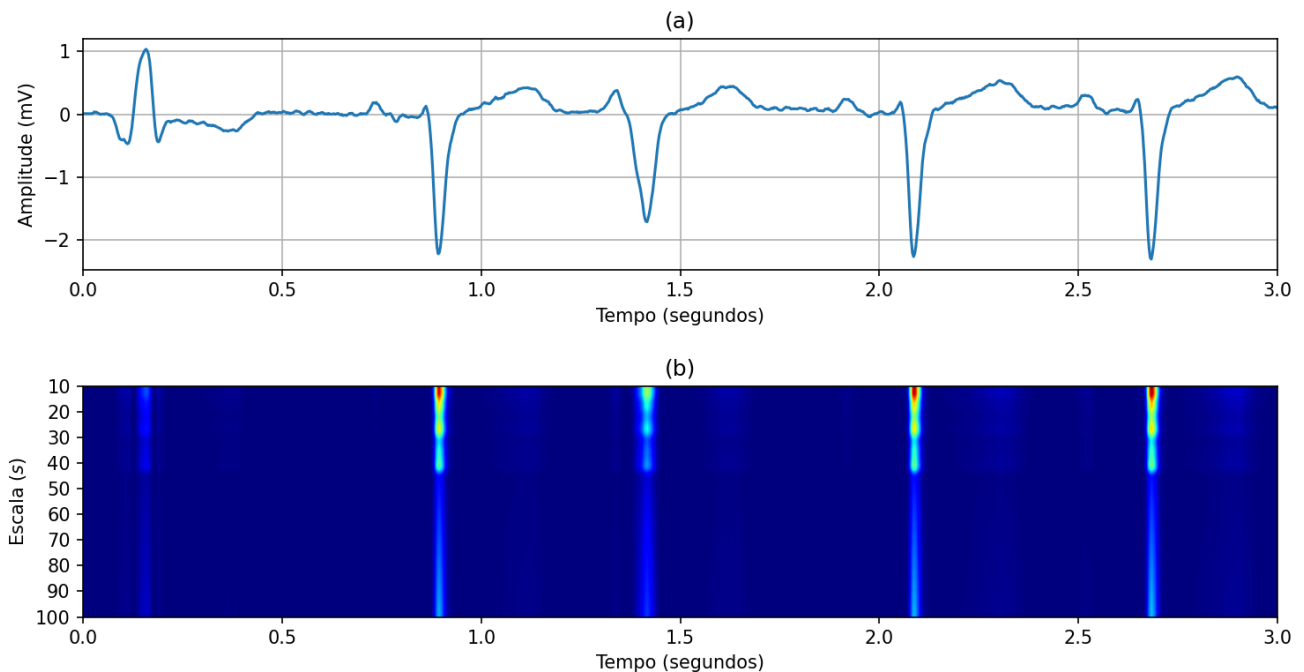


Figura 1. A curva (a) representa os 3 segundos iniciais do sinal de ECG do registro 233 e a imagem (b) o escalograma dos coeficientes wavelets.

Comparando as porções do escalograma relativas aos batimentos de classes distintas nota-se que os coeficientes wavelets refletem informações espectrais distintas para estas classes de batimentos cardíacos nas escalas selecionadas, como por exemplo: a faixa de coeficientes significantes que aparece (azul bem claro) imediatamente ao lado esquerdo, somente para os batimentos do tipo contração prematura ventricular. Além disso, é notável que há maior concentração de energia nas localizações das ondas R para os batimentos do tipo normal do que para as contrações prematuras ventriculares, já que esta classe de arritmia tem frequência máxima em torno de 12Hz, conforme Quadro 2.

Para as fases de treinamento (indução) e teste dos modelos de reconhecimento de padrões foram fixados dois conjuntos de registros de ECG, de acordo com o Quadro 3. Essa separação, com alguma permutação entre os registros, é bastante comum na literatura especializada, pois os registros selecionados para treinamento possuem características variadas possibilitando que o aprendizado seja mais diverso e com isso seja atingida uma melhor capacidade de generalização (Oliveira, 2020). Além disso, essa divisão proporciona uma distribuição adequada das classes positiva e negativa para ambas as fases.

Quadro 3. Registros de ECG utilizados nas fases de treinamento e teste.

Registros	Fase
101, 102, 104, 106, 108, 109, 112, 114, 115, 116, 118, 119, 122, 124, 201, 203, 205, 207, 208, 209, 215, 220, 223, 230, 232, 234	Treinamento
100, 103, 105, 107, 111, 113, 117, 121, 123, 200, 202, 210, 212, 213, 214, 217, 219, 221, 222, 228, 231, 233	Teste

Na abordagem proposta, os coeficientes wavelets foram empregados como vetores de atributos para o treinamento dos modelos de reconhecimento de padrões. Visto que as escalas para aplicação da CWT devem ser selecionadas no intervalo $[10, 100]$ e a quantidade destas depende do incremento utilizado para gerar os valores nesse intervalo, então, há muitos vetores de coeficientes wavelets, implicando na indução de muitas máquinas de aprendizado, para um mesmo padrão. Para simplificar o processo de aprendizagem e reduzir o custo computacional, foram realizadas três médias dos coeficientes dentro deste intervalo, e os vetores médios foram empregados para a indução de três máquinas⁷ de aprendizado. A primeira delas aprenderá os padrão médios no intervalo $[10, 40]$, a segunda máquina no intervalo $]40, 70]$ e a terceira no intervalo $]70, 100]$.

RESULTADOS E DISCUSSÃO

O emprego da abordagem proposta resulta, na fase de treinamento, em 7.715 instâncias da classe positiva e 54.469 da classe negativa, enquanto na fase de teste, 4.726 instâncias da classe positiva e 46.302

⁷ Pode-se utilizar também outras quantidades de máquinas à critério do projetista.

da classe negativa. Após induzidos os três modelos de reconhecimento de padrões, empregando as médias dos coeficientes conforme especificado na seção anterior, obtém-se os resultados da Tabela 1. Os pesos dos modelos M0, M1 e M2, obtidos a partir da acurácia, foram de 0,2052, 0,3781 e 0,4166, significando que os modelos apresentam diferentes valores de acurácia, logo sua importância geral para reconhecimento dos padrões é significativamente distinta.

Tabela 1. Resultados obtidos nas fases de treinamento e teste, para cada máquina induzida e também para o comitê.

Máquina M0			Máquina M1			Máquina M2		
Acc	Pr	Re	Acc	Pr	Re	Acc	Pr	Re
Fase de treinamento								
0,4330	0,1385	0,7448	0,7975	0,1655	0,1841	0,8788	0,4712	0,3640
Fase de teste								
0,3264	0,0774	0,5749	0,9062	0,4920	0,3912	0,9188	0,6443	0,2463
Comitê de Máquinas								
Acc			Pr			Re		
0,9199			0,5921			0,4344		

A partir dos resultados apresentados na Tabela 1, observa-se que a máquina M0, que foi induzida empregando os coeficientes nas escalas 10 a 40, gerou os piores resultados de acurácia (Acc) e precisão (Pr), enquanto que a máquina M2, que empregou as escalas mais altas, acima de 70 até 100, gerou a mais alta acurácia (Acc) e precisão (Pr) em ambas fases. Apenas na fase de treinamento esta máquina também retornou um recobrimento (Re) maior que àquele da máquina M1, a qual foi induzida com os coeficientes nas escalas acima de 40 até 70. Entretanto, as máquinas M1 e M2, em ambas fases, geraram um recobrimento (Re) menor que àquele da máquina M0.

Em linhas gerais, estes resultados significam que a utilização de escalas mais altas resulta em máquinas cujos modelos predizem melhor as instâncias da classe positiva, pois a precisão foi maior para as máquinas M1 e M2, implicando em menos Falsos Positivos (FP). Por outro lado, nas escalas mais baixas as máquinas induzidas predizem melhor as instâncias da classe negativa, menos Falsos Negativos (FN), por isso o recobrimento foi maior para a máquina M0. Esta constatação está de acordo com o que foi observado no fragmento de ECG e seu respectivo escalograma, ilustrados na Figura 1, a partir da qual podemos observar que existe diferença na distribuição de energia entre escalas para diferentes classes de batimentos cardíacos.

Deste modo, o algoritmo Naïve Bayes construiu três modelos distintos, pois foram utilizados dados distintos referentes à diferentes bandas de frequência. Como cada máquina é melhor para reconhecer determinado tipo de padrão, a utilização de um comitê de máquina é imprescindível. Sua utilidade fica evidente nos resultados obtidos, pois foi possível combinar o melhor de cada uma das máquinas. Ou seja, se utilizássemos apenas uma das máquinas, ou teríamos uma acurácia e precisão mais

altas, ou um recobrimento mais alto. Por outro lado, ao combiná-las, consegue-se obter uma acurácia maior que os resultados individuais, e uma precisão e recobrimento mais equilibrados.

Embora a precisão do comitê de máquinas seja inferior à precisão da Máquina M2 em 0,0523, o valor do recobrimento é maior para o comitê em 0,1881. Analogamente ocorre para o recobrimento na comparação do comitê de máquinas e da máquina M0. Portanto, embora haja perda de performance em relação à alguma medida, o ganho obtido ao utilizar o comitê de máquina é bastante superior.

Adicionalmente, um resultado surpreendente que observamos na Tabela 1 é que as máquinas M1 e M2 geraram resultados superiores na fase de teste em relação à fase de treinamento. É surpreendente pois na fase de treinamento os mesmos dados foram utilizados para induzir o modelo e também para predição, ao contrário do que foi implementado na fase de teste.

Em geral, a abordagem proposta é efetiva para o reconhecimento dos padrões eletrocardiográficos, sendo que a melhor acurácia obtida foi de 91,99%. Tal resultado foi conseguido empregando uma técnica de aprendizado de máquina de baixo custo computacional, a qual se baseia apenas no cálculo de probabilidade e na estimação de dois parâmetros para cada atributo, que no presente estudo foi de 288⁸ atributos por instância. Além disso, não foi empregada nenhuma fase de pré-processamento, mas utilizados os dados crus provenientes da base dados, sendo que alguns destes possuíam ruídos típicos encontrados em sinais de ECG (Oliveira, 2020).

Para concluir, destaca-se que a abordagem proposta para reconhecimento de padrões cardíacos normais ou arrítmicos ainda está em estágio inicial de desenvolvimento e, portanto, carece de melhorias e ajustes. Vários outros caminhos podem ser tentados a fim de melhorar a performance de predição, dentre eles: testar outras funções wavelets⁹ e variações de escala que possam, porventura, serem mais adequadas à análise eletrocardiográfica; verificar se outros comprimentos de janelas de análise dos sinais de ECG possam contribuir com mais informação relevante; empregar outros modelos de aprendizados de máquinas mais robustos e ampliar a base de dados empregada; verificar como o método de pré-processamento empregado pode melhorar a predição.

Os arquivos (scripts) utilizados para o desenvolvimento da pesquisa apresentada estão disponíveis neste link <https://github.com/brunobro/reconhecimento-de-arritmias-utilizando-transformada-wavelet>.

REFERÊNCIAS BIBLIOGRÁFICAS

AAMI (1987). Practice for Testing and Reporting Performance Results of Ventricular Arrhythmia Detection Algorithms. Arlington.

⁸ Esse valor é devido ao tamanho da janela de análise escolhido, que foi de 0.8 segundos.

⁹ Uma função que vem ganhando destaque na análise de ECG e que foi recentemente proposta são as Golden Wavelets Gossler et al. (2016).

- Barrett PM et al. (2014). Comparison of 24-hour Holter monitoring with 14-day novel adhesive patch electrocardiographic monitoring. *The American journal of medicine*, 127(1): 11-95. DOI: 10.1016/j.amjmed.2013.10.003.
- CDC (2020). Centers for Disease Control and Prevention. *Circulation*, 141(9): e139-e596.
- Daubechies I (1992). *Ten Lectures on Wavelets*. Auckland: Society for Industrial and Applied Mathematics. DOI: 10.1137/1.9781611970104.
- Dietterich TG (2000). Ensemble methods in machine learning. Dietterich TG. *Multiple Classifier Systems*. Berlin: Springer. DOI: 10.1007/3-540-45014-9_1.
- Dimarco JP, Philbrick JT (1990). Use of ambulatory electrocardiographic (Holter) monitoring. *Annals of internal medicine*, 113(1): 53-68.
- Goldberger AL et al. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation*, 101(23): e215–e220.
- Gossler FE et al. (2016). A wavelet generated from Fibonacci-coefficient polynomials and its application in cardiac arrhythmia classification. In *Proc. of XIX ENMC-National Meeting on Comp. Model. and VII ECTM-Meeting on Materials Science and Tech.*
- Guyton AC, Hall JE (2006). *Tratado de fisiologia médica*. 11ª ed. Rio de Janeiro: Elsevier.
- Hampton JR (2014). *ECG Essencial*. 8ª ed. Rio de Janeiro: Elsevier.
- Kuchar DL et al. (1987). Prediction of serious arrhythmic events after myocardial infarction: signal-averaged electrocardiogram, Holter monitoring and radionuclide ventriculography. *Journal of the American College of Cardiology*, 9(3): 531-538.
- Kubat M (2015). *An Introduction to Machine Learning*. New York: Springer.
- Latchamsetty R, Bogun F (2015). Premature ventricular complexes and premature ventricular complex induced cardiomyopathy. *Current Problems in Cardiology*, 40: 379-422.
- Lipski J et al. (1976). Value of Holter monitoring in assessing cardiac arrhythmias in symptomatic patients. *The American journal of cardiology*, 37(1): 102-107.
- Mallat S (2009). *A Wavelet Tour of Signal Processing: The Sparse Way*. 3ª ed. Burlington: Elsevier.
- Mohrman DE (2011). *Fisiologia cardiovascular*. 6. ed. Porto Alegre: McGraw-Hill.
- Nicolau JC et al. (2003). Diretriz de interpretação de eletrocardiograma de repouso. *Arquivo Brasileiro de Cardiologia*, São Paulo, 80(2):1-18. DOI: 10.1590/S0066-782X2003000800001.
- Oliveira BR de et al. (2018). A wavelet-based method for power-line interference removal in ECG signals. *Research on Biomedical Engineering*, 34(1): 73-86. DOI: [10.1590/2446-4740.01817](https://doi.org/10.1590/2446-4740.01817).
- Oliveira BR de et al. (2019). Geometrical features for premature ventricular contraction recognition with analytic hierarchy process based machine learning algorithms selection. *Computer methods and programs in biomedicine*, 169: 59-69. DOI: 10.1016/j.cmpb.2018.12.028.
- Oliveira BR de (2020). Reconhecimento de Contração Prematura Ventricular utilizando separação cega de fontes e comitê de máquinas bayesianas. Programa de Pós-graduação em Engenharia Elétrica

(Tese), Ilha Solteira-SP, 151p. Disponível em <<http://hdl.handle.net/11449/194111>>. DOI: [10.13140/RG.2.2.24356.60802](https://doi.org/10.13140/RG.2.2.24356.60802).

Santos JD et al. (2018). Mortalidade por infarto agudo do miocárdio no Brasil e suas regiões geográficas: análise do efeito da idade-período-corte. *Ciência & Saúde Coletiva*, 23: 1621-1634. DOI: 10.1590/1413-81232018235.16092016.

Shafqat S et al. (2004). Holter monitoring in the diagnosis of stroke mechanism. *Internal medicine journal*, 34(6): 305-309.

Soman KP et al. (2010). *Insight Into Wavelets: From Theory to Practice*. 3ª ed. New Delhi: PHI.

Suzuki T et al. (1994). Holter monitoring as a noninvasive indicator of cardiac involvement in sarcoidosis. *Chest*, 106(4): 1021-1024.

Sundararajan D (2001). *The Discrete Fourier Transform. Theory, Algorithms and Applications*. New Jersey: World Scientific.

Woods SL et al. (2005). *Enfermagem em cardiologia*. Barueri: Manole.

ÍNDICE REMISSIVO

A

algoritmo, 13, 25, 27, 42, 51
aprendizado de máquina, 4, 9, 13, 16, 17, 35,
37, 43
arritmia, 41

C

classificação, 4, 17, 37, 39
conhecimento, 46, 47, 50, 53
convolucional
rede neural, 4, 21

D

Dense
rede neural, 4, 22

E

Elman
rede neural, 4, 8, 9, 10, 12, 14, 15
energia elétrica, 4, 8, 16, 17, 21, 24, 27, 29
ensemble, 31

J

Jordan
rede neural, 4, 8, 9, 10, 12, 14, 15

M

mineração de texto, 4, 48

P

padrão, 24, 33, 37, 38, 41, 42
petróleo, 4, 7, 8, 10
predição, 4, 16, 17, 18, 21, 25, 26, 28, 29, 38, 43
pré-processamento, 43, 51, 52
Pubmed, 48, 49, 51


R


recorrente
rede neural, 4, 8, 21, 22
rede neural, 7, 8, 9, 17, 20


S


série temporal, 7, 8, 16, 17, 21, 24


SOBRE OS ORGANIZADORES

 **Ricardo Augusto Manfredini** Possui graduação em Bacharel em Ciências da Computação pela Universidade de Caxias do Sul (1990), mestrado em Ciências da Computação pela Universidade Federal do Rio Grande do Sul (2001) , doutorado pelo Instituto de Biotecnologia da Universidade de Caxias do Sul(2015) e pós-doutorado no GECAD do Instituto Superior de Engenharia do Porto em Inteligência Artificial e IoT, também é professor do Instituto Federal de Ciências e Tecnologia do Rio Grande do Sul - campus Farroupilha. Tem experiência na área de Ciência da Computação, com ênfase em Programação, Engenharia de Software e Tolerância a Falhas, atuando principalmente nos seguintes temas: IoT & IA (2020), bioinformática, injeção de falhas, sistemas distribuídos, tolerância a falhas, metodologias de desenvolvimento de sistemas e linguagens de programação.

 **Geraldo Nunes Corrêa** Possui graduação em Ciência da Computação pela Universidade de São Paulo (1991), mestrado em Ciências da Computação (Área de Inteligência Artificial, Banco de Dados e Manufatura) pela Universidade de São Paulo (1994) e doutorado em Engenharia Mecânica (Departamento de Engenharia de Produção) pela Universidade de São Paulo (1999). Pós doutorado em Mineração de Textos no Instituto de Ciências Matemáticas e Computação da Universidade de São Paulo (2013). Consultor em soluções educacionais. Mentor de Startups. Empreendedor Digital.

 **Bruno Rodrigues de Oliveira** Graduado em Matemática pela Universidade Estadual de Mato Grosso do Sul (UEMS, 2008). Mestrado (2015) e Doutorado (2020) em Engenharia Elétrica pela Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP, 2015). Atualmente é Analista Judiciário no Tribunal de Justiça de Mato Grosso do Sul e professor de Matemática no Colégio Maper e Editor na Pantanal Editora. Tem experiência nos temas: Matemática, Processamento de Sinais via Transformada Wavelet, Análise Hierárquica de Processos, Teoria de Aprendizagem de Máquina e Inteligência Artificial.

 **Suellen Teixeira Zavadzki de Pauli** Doutoranda em Métodos Numéricos na Universidade Federal do Paraná, possui mestrado em Engenharia da Produção pela Universidade Federal do Paraná (2020), pós-graduação em Engenharia da Confiabilidade pela Universidade Tecnológica Federal do Paraná (2016) e graduação em Estatística pela Universidade Federal do Paraná (2013). Possui experiência com monitoramento de modelos estatísticos de crédito e análise de indicadores. Atuação no planejamento e estratégia de campanhas de marketing através da análise de produtos e de perfil de clientes, dashboards analíticos e KPIs. Geração e implementação de simulador de oferta ideal para o cliente (next best offer). Experiência na avaliação de dados e cenários, utilização de técnicas estatísticas (análises descritivas, árvores de decisão, testes estatísticos). Experiência como professor substituto na Universidade Tecnológica Federal do Paraná (2020). Experiência com pesquisa em redes neurais artificiais aplicadas em dados de séries temporais (preço de petróleo e valor de ações), modelos mistos, análise de variância, entre outras técnicas. Familiaridade com linguagem SQL e ferramentas de análises como SAS, SPSS, R, Phyton e pacotes office. Coorganizadora do RLadies Curitiba.



Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000

Nova Xavantina – Mato Grosso – Brasil

Telefone (66) 99682-4165 (Whatsapp)

<https://www.editorapantanal.com.br>

contato@editorapantanal.com.br