

# APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL E CIÊNCIA DE DADOS

Julio C. Uzinski  
Caio C. E. de Abreu  
Bruno R. de **Oliveira**  

---

organizadores



Pantanal Editora

2020

Julio Cezar Uzinski  
Caio Cesar Enside de Abreu  
Bruno Rodrigues de Oliveira  
(Organizadores)

**Aplicações de  
Inteligência Artificial e  
Ciência de Dados**



Pantanal Editora

2020

Copyright© Pantanal Editora  
Copyright do Texto© 2020 Os Autores  
Copyright da Edição© 2020 Pantanal Editora  
Editor Chefe: Prof. Dr. Alan Mario Zuffo  
Editores Executivos: Prof. Dr. Jorge González Aguilera  
Prof. Dr. Bruno Rodrigues de Oliveira

Diagramação: A editora  
Edição de Arte: A editora  
Revisão: Os autor(es), organizador(es) e a editora

#### Conselho Editorial

- Prof. Dr. Adailson Wagner Sousa de Vasconcelos – OAB/PB
- Profa. Msc. Adriana Flávia Neu – Mun. Faxinal Soturno e Tupanciretã
- Profa. Dra. Albys Ferrer Dubois – UO (Cuba)
- Prof. Dr. Antonio Gasparetto Júnior – IF SUDESTE MG
- Profa. Msc. Aris Verdecia Peña – Facultad de Medicina (Cuba)
- Profa. Arisleidis Chapman Verdecia – ISCM (Cuba)
- Prof. Dr. Bruno Gomes de Araújo - UEA
- Prof. Dr. Caio Cesar Enside de Abreu – UNEMAT
- Prof. Dr. Carlos Nick – UFV
- Prof. Dr. Claudio Silveira Maia – AJES
- Prof. Dr. Cleberton Correia Santos – UFGD
- Prof. Dr. Cristiano Pereira da Silva – UEMS
- Profa. Ma. Dayse Rodrigues dos Santos – IFPA
- Prof. Msc. David Chacon Alvarez – UNICENTRO
- Prof. Dr. Denis Silva Nogueira – IFMT
- Profa. Dra. Denise Silva Nogueira – UFMG
- Profa. Dra. Dennyura Oliveira Galvão – URCA
- Prof. Dr. Elias Rocha Gonçalves – ISEPAM-FAETEC
- Prof. Me. Ernane Rosa Martins – IFG
- Prof. Dr. Fábio Steiner – UEMS
- Prof. Dr. Gabriel Andres Tafur Gomez (Colômbia)
- Prof. Dr. Hebert Hernán Soto Gonzáles – UNAM (Peru)
- Prof. Dr. Hudson do Vale de Oliveira – IFRR
- Prof. Msc. Javier Revilla Armesto – UCG (México)
- Prof. Msc. João Camilo Sevilla – Mun. Rio de Janeiro
- Prof. Dr. José Luis Soto Gonzales – UNMSM (Peru)
- Prof. Dr. Julio Cezar Uzinski – UFMT
- Prof. Msc. Lucas R. Oliveira – Mun. de Chap. do Sul
- Prof. Dr. Leandro Argente-Martínez – ITSON (México)
- Profa. Msc. Lidiene Jaqueline de Souza Costa Marchesan – Consultório em Santa Maria
- Prof. Msc. Marcos Pisarski Júnior – UEG
- Prof. Dr. Mario Rodrigo Esparza Mantilla – UNAM (Peru)
- Profa. Msc. Mary Jose Almeida Pereira – SEDUC/PA
- Profa. Msc. Nila Luciana Vilhena Madureira – IFPA
- Profa. Dra. Patrícia Maurer
- Profa. Msc. Queila Pahim da Silva – IFB
- Prof. Dr. Rafael Chapman Auty – UO (Cuba)
- Prof. Dr. Rafael Felipe Ratke – UFMS
- Prof. Dr. Raphael Reis da Silva – UFPI

- Prof. Dr. Ricardo Alves de Araújo – UEMA
- Prof. Dr. Wéverson Lima Fonseca – UFPI
- Prof. Msc. Wesclen Vilar Nogueira – FURG
- Profa. Dra. Yilan Fung Boix – UO (Cuba)
- Prof. Dr. Willian Douglas Guilherme – UFT

#### Conselho Técnico Científico

- Esp. Joacir Mário Zuffo Júnior
- Esp. Maurício Amormino Júnior
- Esp. Tayronne de Almeida Rodrigues
- Esp. Camila Alves Pereira
- Lda. Rosalina Eufrausino Lustosa Zuffo

#### Ficha Catalográfica

<b>Dados Internacionais de Catalogação na Publicação (CIP)</b> (eDOC BRASIL, Belo Horizonte/MG)	
A642	<p>Aplicações de inteligência artificial e ciência de dados [recurso eletrônico] / Organizadores Julio Cezar Uzinski, Caio Cesar Enside de Abreu, Bruno Rodrigues de Oliveira. – Nova Xavantina, MT: Pantanal, 2020. 100p.</p> <p>Formato: PDF  Requisitos de sistema: Adobe Acrobat Reader  Modo de acesso: World Wide Web  ISBN 978-65-88319-26-0  DOI <a href="https://doi.org/10.46420/9786588319260">https://doi.org/10.46420/9786588319260</a></p> <p>1. Inteligência artificial. 2. Automação. 3. Processamento de dados. I. Uzinski, Julio Cezar. II. Abreu, Caio Cesar Enside de. III. Oliveira, Bruno Rodrigues de.</p> <p style="text-align: right;">CDD 001.535</p>
<b>Elaborado por Maurício Amormino Júnior – CRB6/2422</b>	

O conteúdo dos livros e capítulos, seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva do(s) autor (es). O download da obra é permitido e o compartilhamento desde que sejam citadas as referências dos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

#### **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](mailto:contato@editorapantanal.com.br)

## APRESENTAÇÃO

Ciência de dados (*Data science*) e Inteligência artificial (*Artificial intelligence*) podem ser consideradas como algumas das áreas da ciência mais importantes de nosso tempo. Ademais, não estão apenas no mundo acadêmico ou no futuro como no filme *The terminator*, estão ao nosso redor nesse exato momento em situações simples, por exemplo, são empregadas para sugerir qual o próximo emoji que você enviará em uma conversa no seu aplicativo de bate papo favorito. Ciência de dados se refere a um campo de estudo muito amplo que se vale de métodos científicos para se obter informações e percepções de conjuntos de dados, enquanto que a inteligência artificial refere-se ao que chamamos de inteligência das máquinas. As aplicações dessas ferramentas estão relacionadas às tecnologias que nos envolvem em nosso cotidiano, e.g., as redes sociais ou comércio eletrônico, bem como aplicações que escapam ao senso comum, como em cibersegurança ou astrofísica.

Tais abordagens, às vezes, são utilizadas juntas, de forma intercalada ou separadas. Uma pesquisa poderá contar com ambas as ferramentas ou apenas com uma delas. Nesse livro, o leitor encontrará aplicações diversas dessas ferramentas em diferentes perspectivas. Em seis capítulos são apresentados resultados de pesquisas de dezesseis pesquisadores sobre temas diversos que dão uma demonstração do poder da Inteligência Artificial e da Ciência de Dados.

O primeiro capítulo traz uma comparação dos resultados da Transformada Wavelet (WT) e do Filtro Savitzky-Golay (SG) na estimação da tendência em séries temporais. Os resultados são obtidos a partir de uma série temporal artificial e uma série de dados reais, i.e, a cotação da moeda americana (Dólar US\$) frente à moeda brasileira (Real R\$).

Considerando que a principal abordagem em Aprendizado de Máquinas é a construção de algoritmos que, por meio das experiências e aprendizado, possam ser melhorados automaticamente, o segundo capítulo desse livro traz uma avaliação de um algoritmo usando Redes Neurais Artificiais LSTM. Essa abordagem é justificada pela necessidade de reconhecimento de padrões de comportamento de presença de elementos em um ambiente para realizar a predição de ações no local por meio dos dados coletados fornecendo uma base para o desenvolvimento de um sistema doméstico inteligente.

Já no terceiro capítulo, uma metodologia para descrição de Casos de Uso (Uc) no desenvolvimento de sistemas de informação é apresentada. A motivação para a criação desta metodologia é que muitos UC's são descritos com pouca riqueza de detalhes, o que prejudica a qualidade dos sistemas de informação.

O quarto capítulo traz uma aplicação bastante diversa de todas as outras: um estudo dos aspectos e causas da obesidade por meio do algoritmo de agrupamento Farthest First para agrupar

peças com informações demográficas, socioeconômicas, de biotipo e de conjunto de ações observáveis recorrentes.

No quinto capítulo é desenvolvida uma aplicação utilizando regressão logística como um mapeamento do espaço de atributos não-linearmente separável baseado em um tipo especial de funções denominadas de Golden Wavelets. Nesse texto, os autores buscam tratar a matemática envolvida no método de aprendizado de máquina denominado de Regressão Logística e propor a utilização de funções wavelets para mapeamento do espaço de atributos.

Para encerrar esse e-book com chave de ouro, o sexto capítulo, apresenta uma classificação de cenas acústicas utilizando a Transformada Wavelet e Aprendizagem de Máquina. Os autores dedicam a redação à apresentação dos principais métodos de Classificação de Cenas Acústicas (CCA) e os principais atributos utilizados para esta classificação, exemplos de aplicações, e uma investigação adicional centrada na utilização da Transformada Wavelet Contínua (TWC).

Caríssimo(a) leitor(a), convidamos você à leitura de Aplicações de Inteligência Artificial e Ciência de Dados, e esperamos que a mesma seja um deleite ilimitado e que contribua de alguma forma com suas aspirações.

**Julio Cezar Uzinski**

## SUMÁRIO


<b>Apresentação</b> .....	4
<b>Capítulo I</b> .....	7
Obtenção de Tendências em Série Temporal empregando a Transformada Wavelet e o filtro Savitzky-Golay.....	7
<b>Capítulo II</b> .....	24
Aplicação de Redes Neurais Artificiais LSTM em domótica inteligente .....	24
<b>Capítulo III</b> .....	32
Uma Metodologia Simples para Descrição de Casos de Uso no Desenvolvimento de Sistemas de Informação.....	32
<b>Capítulo IV</b> .....	49
Aspectos e causas da obesidade: uma análise utilizando algoritmo de agrupamento <i>Farthest First</i> .....	49
<b>Capítulo V</b> .....	59
Mapeamento de espaço de atributos não-linearmente separável baseado na Golden wavelet: aplicação na regressão logística .....	59
<b>Capítulo VI</b> .....	85
Classificação de Cenas Acústicas Utilizando a Transformada Wavelet Contínua e Aprendizagem de Máquina .....	85
<b>Índice Remissivo</b> .....	99

---

# Aplicação de Redes Neurais Artificiais LSTM em domótica inteligente

Recebido em: 03/07/2020

Aceito em: 02/09/2020

 10.46420/9786588319260cap2

Gilberto de Melo Júnior<sup>1\*</sup> 

Matheus Chagas Lee<sup>2</sup> 

Sanderson Oliveira de Macedo<sup>1</sup> 

## INTRODUÇÃO

Muitos avanços vêm acontecendo na área de Inteligência Artificial (IA). Um dos maiores ramos da IA é o Aprendizado de Máquina, onde a abordagem principal é como construir computadores que com experiências e aprendizado possam automaticamente ser melhorados (Jordan e Mitchell, 2015).

Um dos mais utilizados algoritmos de aprendizado de máquina são as Redes Neurais Artificiais (RNAs). Esses algoritmos são modelos abstratos de computadores do que simulam em suas peculiaridades o cérebro humano (Munakata, 2008). Há atualmente várias arquiteturas de RNAs, como por exemplo, Redes Multilayer Perceptrons (MLPs), Redes Neurais Convolucionais (CNNs), Redes de Hopfield, Redes Neurais Recorrentes dentre outras.

As Redes Neurais Recorrentes são redes especialmente voltadas para o processamento de dados sequenciais, linguagem natural e séries temporais. Sua característica fundamental é que ela contém pelo menos uma conexão de *feedback*, para que as ativações possam fluir em um *loop*. Assim, são permitidas a essas redes neurais realizem processamento temporal e aprendam sequências, por exemplo, realizam reconhecimento/reprodução de sequência ou associação/previsão temporal (Zaccone et al., 2017).

As Redes Neurais *Long Short-Term Memory* (LSTM), ou em português, Redes Neurais de Memória de Longo Prazo foram elaboradas em meados dos anos 90 para a solução de um problema comum nas Redes Neurais Recorrentes, o retorno do erro. Ele pode aprender a preencher intervalos de tempo superiores a 1000 etapas mesmo no caso de sequências de entrada incompressíveis e ruidosas, sem perda de recursos de curto espaço de tempo, o que é conseguido por um algoritmo eficiente e baseado em gradiente para uma arquitetura que impõe um fluxo de erro constante (não explodindo nem desaparecendo) através dos estados internos de unidades especiais (desde que o cálculo do gradiente

---

<sup>1</sup> Docente do Departamento IV no Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

<sup>2</sup> Discente do curso de Engenharia de Controle e Automação no Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

\* Autor correspondente: gilberto.melo@outlook.com



seja truncado em determinados pontos específicos da arquitetura isso não afeta o fluxo de erro de longo prazo) (Hochreiter e Schmidhuber, 1997).

Uma área encontrada para aplicação da Redes Neurais LSTM foi a domótica. A definição de Domótica está relacionado a instalações eletroeletrônicas e sistemas inteligentes no ambiente residencial, permitindo uma gestão, local ou remota, para oferecer aplicações nas áreas de segurança, conforto e comunicação (Linz e Moura, 2010).

Takiuchi et al. (2004) estende o conceito de domótica, a domótica inteligente, onde principal é analisar os dados obtidos pelos sensores de modo a adaptar suas regras de automação ao comportamento dos habitantes. Isso é necessário, pois o comportamento humano sofre mudanças ao longo tempo.

O objetivo desse estudo foi o desenvolvimento e avaliação de um algoritmo usando Redes Neurais Artificiais LSTM para reconhecimento de padrões de comportamento de presença de pessoas em uma residência e assim realizar a predição de ações na residência por meio dos dados coletados pelos sensores, assim, obtendo uma base para o desenvolvimento de um sistema domótico inteligente.

## **MATERIAL E MÉTODOS**

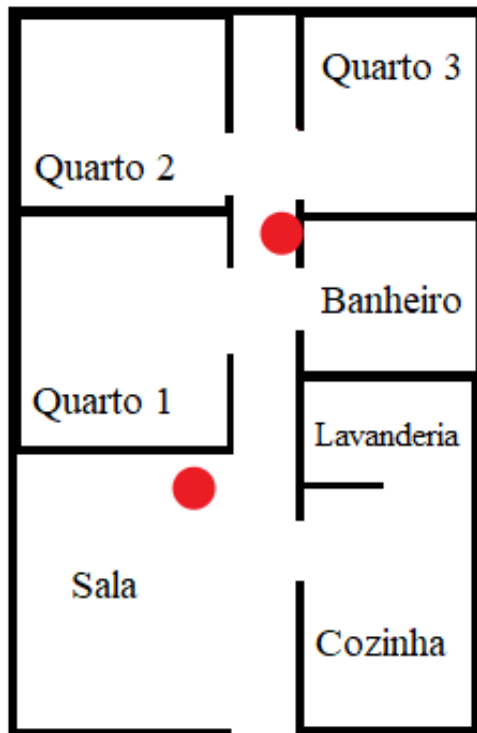
O trabalho inicial foi a realização da coleta de dados para utilização nos algoritmos de predição. A casa de um casal foi o local para aquisição dos dados de presença dos mesmos. Com a anuência do casal, foi instalado dois sensores de presença PIR-HC-SR501.

O PIR-HC-SR501 é um sensor de movimento simples, muito utilizado no mercado, e compatível com muitos microcontroladores. O sensor pode ser alimentado com uma tensão de 5 a 20 volts. O seu range de leitura é entre 3 e 7 metros, assim qualquer movimento dentro do seu range o pino de saída vai para nível lógico alto (Datasheet, 2016).


Para este trabalho foi utilizado dois sensores PIR para aquisição de dados de presença em dois locais diferentes na casa. A disposição dos sensores é ilustrada na Figura 1, onde as marcações em vermelho na planta da casa, indicam onde os mesmos foram instalados.

Para a aquisição dos dados, os sensores foram conectados a placa NodeMCU, plataforma microcontroladora da família ESP8266, criada para o desenvolvimento de projetos de *Internet of Things* (IoT), em português, Internet das coisas (Al Dahoud e Mohamed, 2018). Entre as particularidades dessa placa, destaca-se o baixo custo, suporte integrado a redes WiFi, tamanho reduzido e baixo consumo de energia.

A Figura 2 A) ilustra a pinagem do sensor PIR HC-SR501 e a Figura 2 B) a placa microcontroladora NodeMCU.

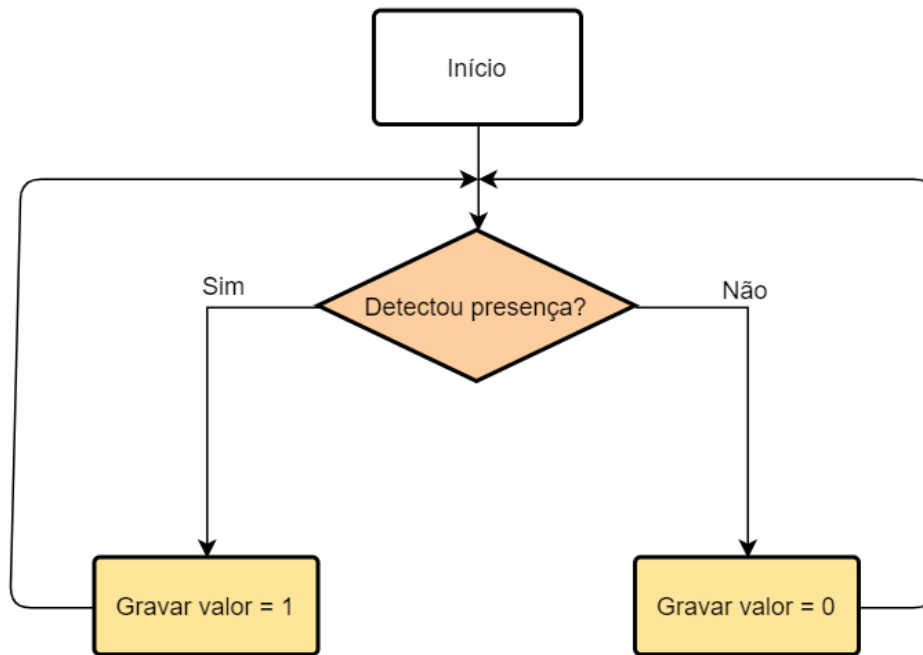


**Figura 1.** Disposição dos sensores (em vermelho) na casa para coleta dos dados de presença. Fonte: os autores



**Figura 2.** A) Detalhes do sensor PIR HC-SR501. Fonte: Adaptado (Datasheet, 2016); B) Placa NodeMCU – ESP8266. Fonte: Adaptado (Al Dahoud e Mohamed, 2018).

A placa NodeMCU pode ser programada em linguagem LUA ou C/C++, linguagem que o microcontrolador Arduino utiliza. Utilizou a IDE do Arduino para programar o algoritmo de configuração do sensor de presença. O algoritmo foi programado para realizar a aquisição dos dados de presença, a lógica para aquisição é ilustrada na Figura 3.



**Figura 3.** Fluxograma do algoritmo do sensor de presença. Fonte: os autores

Os dados coletados foram enviados a um servidor local responsável pelo armazenamento e atualização dos dados. O servidor foi desenvolvido usando o *micro-framework* Flask em um Raspberry Pi 3 B +. O Flask é destinado a pequenas aplicações com requisitos mais simples, possui um núcleo simples e expansível (Grinberg, 2018).

O módulo Raspberry Pi 3B + é um equivalente em miniatura de um computador pessoal completo em formato miniaturizado, suas dimensões são de apenas 86 x 54 mm. Ele contém todos os componentes necessários para usar o microcomputador como um computador pessoal comum (Saluch, 2018). Possui um processador com um *clock* de 1,4 GHz e com memória RAM de 1 Gb.

Com toda a infraestrutura para aquisição montada e configurada, iniciou-se a preparação da rede neural LSTM. Foi utilizado o *framework* TensorFlow juntamente com a biblioteca Keras. O TensorFlow é um sistema de aprendizado de máquina que opera em larga escala e em ambientes heterogêneos. Ele usa gráficos de fluxo de dados para representar a computação, o estado compartilhado e as operações que modificam esse estado (Abadi et al., 2016).

O Keras é uma biblioteca para rede neural artificial desenvolvida na linguagem Python. Ela funciona como *front-end* em TensorFlow, e foi desenvolvida para facilitar as experiências em redes neurais, possui uma rápida e fácil prototipagem, suporta redes neurais Convolucionais e Recorrentes (Gulli e Pal, 2017).

A rede neural artificial LSTM foi executada em um ambiente virtual, o *Google Colaboratory*, mais conhecido como *Google Colab* ou simplesmente *Colab*. O *Colab* é um projeto de pesquisa para criar protótipos de modelos de aprendizado de máquina em poderosas opções de *hardware*, como *Graphics Processing Units* (GPUs) e *Tensor Processing Units* (TPUs), fornece um ambiente de notebook *Jupyter* sem servidor para desenvolvimento interativo e é gratuito (Bisong, 2019).

Para a aplicação dos dados coletados na rede neural houve um processo de limpeza e transformação dos dados. Os dados “ano” e “mês” foram descartados por não fazerem parte da ciclotimia da série temporal em questão. Além disso, realizou-se a transformação da dimensão tempo em uma sequência temporal com a seguinte característica: [dia\_semana, dia, hora, minuto].

A transformação da dimensão tempo em sequência facilitou a observação da dimensão tempo, haja vista que, cada sequência foi observada como um vocabulário para a rede neural LSTM.

A rede neural LSTM foi elaborada com a camada de entrada de dimensão das sequências definidas anteriormente; 100 neurônios artificiais; regularização normal de 0,2; regularização recorrente de 0,2; uma camada densa de saída com 1 neurônio com ativação *sigmoid*. Para compilação da rede foi utilizado: *loss* = *binary\_crossentropy*; otimizador = Adam. E para métrica de avaliação da rede neural utilizou-se a acurácia.

## RESULTADOS E DISCUSSÕES

Foram coletados em torno de 100 mil linhas de informações no período de 01 de fevereiro de 2019 a 11 de abril de 2019, com frequência de coleta definida a cada um minuto. Cada linha de dado apresentou as informações de: ano, mês, dia, hora, minuto, dia da semana e a presença. A presença é a variável que expressa o valor captado pelo sensor na janela de tempo definida pelas outras variáveis e como mostrado na Figura 3 essa variável possui valores binários (quando há presença captada pelo sensor = 1; quando não há presença captada pelo sensor = 0). Tabela 1 apresenta uma amostra dos dados coletados pelos sensores.

**Tabela 1.** Amostra dos dados coletados. Fonte: os autores

ano	mês	dia	hora	minuto	dia_semana	presença
2019	2	1	12	41	7	1
2019	2	1	12	42	7	1
2019	2	1	12	43	7	1
2019	2	1	12	44	7	1
2019	2	1	12	45	7	1

A rede neural artificial LSTM construída foi executada no *Colab* utilizando uma placa aceleradora para processamento paralelo, a K-80 da Nvídia. A acurácia foi a métrica de avaliação escolhida para

rede neural. Ela é a taxa de acerto global, ou seja, a proporção de predições corretas em relação ao tamanho do conjunto de dados (Silva et al., 2012).

Os testes iniciais a rede neural atingiu acurácia de 90%, porém foi utilizado reguladores para obtenção de maior generalidade e redução do overfitting. Assim os testes finais apresentaram uma acurácia de 85,27%.

O tamanho do arquivo da rede neural gerado pelo Keras foi de 825 KB possibilitando assim o desenvolvimento de um sistema inteligente em um dispositivo com baixa capacidade computacional.

## CONCLUSÃO

Conclui-se que, com a acurácia de 85,27%, a rede neural artificial LSTM obteve um bom desempenho ao detectar padrões de presença de pessoas em uma residência. Assim, utilizando tal rede neural é possível o desenvolvimento de um sistema domótico inteligente baseado no comportamento dos residentes. Em trabalhos futuros, há a possibilidade de avaliar o comportamento da rede neural LSTM com camadas Convolucionais de uma dimensão, analisar outros hiper parâmetros de configuração e o desenvolvimento de um sistema domótico inteligente.

## AGRADECIMENTOS

Os autores agradecem o suporte do Instituto Federal de Educação, Ciência e Tecnologia de Goiás (IFG), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

## REFERÊNCIAS BIBLIOGRÁFICAS

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Kudlur, M. (2016). Tensorflow: A system for large-scale machine learning. In *12th {USENIX} symposium on operating systems design and implementation ({OSDI} 16)* (pp. 265-283).
- Ahmad, M. A., Eckert, C., & Teredesai, A. (2018, August). Interpretable machine learning in healthcare. In *Proceedings of the 2018 ACM international conference on bioinformatics, computational biology, and health informatics* (pp. 559-560).
- Al Dahoud, A e Mohamed F. (2018). NodeMCU V3 For Fast IoT Application Development.
- Bertoni, A., Dasari, S. K., Hallstedt, S. I., & Andersson, P. (2018). Model-based decision support for value and sustainability assessment: Applying machine learning in aerospace product development. In *DS 92: Proceedings of the DESIGN 2018 15th International Design Conference* (pp. 2585-2596).

- Bisong, E. (2019). Google Colaboratory. In *Building Machine Learning and Deep Learning Models on Google Cloud Platform* (pp. 59-64). Apress, Berkeley, CA.
- Bonica, A. (2018). Inferring Roll- Call Scores from Campaign Contributions Using Supervised Machine Learning. *American Journal of Political Science*, 62(4), 830-848.
- Culkin, R., & Das, S. R. (2017). Machine learning in finance: The case of deep learning for option pricing. *Journal of Investment Management*, 15(4), 92-100.
- Datasheet, P.I.R. (2016). Sensor (HC-SR501). *Diakses tanggal*, v. 30.
- de Melo, G., Oliveira, S. M., Ferreira, C. C., Vasconcelos Filho, E. P., Calixto, W. P., & Furriel, G. P. (2017, October). Evaluation techniques of machine learning in task of reprovation prediction of technical high school students. In *2017 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON)* (pp. 1-7). IEEE.
- Ge, Z., Song, Z., Ding, S. X., & Huang, B. (2017). Data mining and analytics in the process industry: The role of machine learning. *Ieee Access*, 5, 20590-20616.
- Grinberg, M. (2018). *Flask web development: developing web applications with python*. " O'Reilly Media, Inc."
- Gulli, A., & Pal, S. (2017). *Deep learning with Keras*. Packt Publishing Ltd.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Jean, N., Burke, M., Xie, M., Davis, W. M., Lobell, D. B., & Ermon, S. (2016). Combining satellite imagery and machine learning to predict poverty. *Science*, 353(6301), 790-794.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Knoll, D., Prüglmeier, M., & Reinhart, G. (2016). Predicting future inbound logistics processes using machine learning. *Procedia CIRP*, 52, 145-150.
- Libbrecht, M. W., & Noble, W. S. (2015). Machine learning applications in genetics and genomics. *Nature Reviews Genetics*, 16(6), 321-332.
- Lins, V., & Moura, W. (2010). Domótica: Automação Residencial. *Recife, dez*.
- Munakata, T. (2008). *Fundamentals of the new artificial intelligence: neural, evolutionary, fuzzy and more*. Springer Science & Business Media.
- Saluch, M., Tokarski, D., Grudniewski, T., Chodyka, M., Nitychoruk, J., Woliński, P., ... & Adamczewski, G. (2018). Raspberry PI 3B+ microcomputer as a central control unit in intelligent building automation management systems. In *MATEC Web of Conferences* (Vol. 196, p. 04032). EDP Sciences.
- Silva, R. M., Almeida, T. A., & Yamakami, A. (2012). Análise de desempenho de redes neurais artificiais para classificação automática de web spam. *Revista Brasileira de Computação Aplicada*, 4(2), 42-57.

Takiuchi, M., Melo, É., & Tonidandel, F. (2004). Domótica inteligente: automação baseada em comportamento. *Centro Universitário da FEI–UniFE, São Bernardo do Campo-SP.*

Zaccone, G., Karim, M. R., & Menshawy, A. (2017). *Deep Learning with TensorFlow*. Packt Publishing Ltd.

## ÍNDICE REMISSIVO

### A

agrupamento, 49, 53, 54  
aprendizado de máquina, 8, 25, 28, 29, 59, 60, 61, 80  
Aprendizagem de Máquina, 50, 57, 83

### C

caso de uso, 41, 42, 44, 46  
CCA, 84, 85, 86, 87, 88, 95  
cenário, 39, 43, 44, 45, 85  
Cenas Acústicas, 83, 84, 95

### Ch

*checklist*, 34, 39, 41

### C

Ciência de Dados, 33  
classificação, 31, 39, 50, 56, 59, 60, 61, 62, 63, 68, 69, 72, 73, 74, 84, 85, 88, 90, 94  
clusterização, 50, 51, 54  
coeficiente, 10, 11, 89, 94  
comportamento, 8, 9, 22, 26, 30, 32, 37, 56, 70

### D

*Deep Learning*, 31, 32, 59, 81, 87, 90, 94  
desenvolvimento de SI, 35, 36, 39  
domótica, 25, 26

### E

Engenharia de Requisitos, 33, 47, 48  
escalograma, 89, 90  
espaço de atributos, 59, 60, 70, 73, 74, 76, 80, 81  
espectro, 86, 89  
espectrograma, 85, 86

### F

*Farthest First*, 49, 50, 53, 54, 56

filtro, 8, 9, 10, 11, 15, 16, 17, 18, 19, 20, 21, 22, 89

### G

GWS, 89, 90, 91, 92, 93, 94

### I

Inteligência Artificial, 25

### M

*machine learning*, 30, 31, 84, 87  
mapeamento, 48, 60, 70, 73, 74, 77, 78, 80, 81, 88  
metodologia, 33, 34, 35, 36, 37, 39, 41, 42, 47  
MFCCs, 84, 86, 87, 90, 91, 93, 94

### O

obesidade, 49, 50, 55, 56, 57, 58

### P

polinômio, 10, 11, 16, 20, 21  
prototipação, 33, 35, 39, 41, 47

### Q

qualidade, 33, 34, 35, 39, 41, 47, 57

### R

Redes Neurais  
  Artificiais, 25, 26  
  LSTM, 26  
regressão logística, 59, 62, 63, 70  
requisitos, 28, 33, 34, 35, 39, 41, 48

### S

Savitzky-Golay, 8, 9, 10, 15, 16, 17, 18, 19, 20, 21, 22, 23  
sensores, 26, 27, 29  
Série Temporal, 8, 9  
Sistema de Informação, 47, 48



*Software*, 47, 48, 95

superfície de decisão, 62, 77

## **T**

tendência, 8, 9, 10, 14, 15, 16, 17, 18, 19, 21,  
22, 57, 58

Transformada Wavelet, 8, 9, 10, 13, 70, 83, 84,  
87, 88, 90, 95



**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](mailto:contato@editorapantanal.com.br)

ISBN 978-658831926-0

