

Information Systems and Technology Management

Marcos William Kaspchak Machado
(Organizador)



Marcos William Kaspchak Machado

(Organizador)

Information Systems and Technology Management

Atena Editora
2019

2019 by Atena Editora

Copyright © da Atena Editora

Editora Chefe: Profª Drª Antonella Carvalho de Oliveira

Diagramação e Edição de Arte: Lorena Prestes e Karine de Lima

Revisão: Os autores

Conselho Editorial

- Prof. Dr. Alan Mario Zuffo – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Álvaro Augusto de Borba Barreto – Universidade Federal de Pelotas
Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná
Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília
Profª Drª Cristina Gaio – Universidade de Lisboa
Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa
Profª Drª Daiane Garabeli Trojan – Universidade Norte do Paraná
Prof. Dr. Darllan Collins da Cunha e Silva – Universidade Estadual Paulista
Profª Drª Deusilene Souza Vieira Dall’Acqua – Universidade Federal de Rondônia
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul
Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria
Prof. Dr. Gilmei Fleck – Universidade Estadual do Oeste do Paraná
Profª Drª Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
Profª Drª Ivone Goulart Lopes – Istituto Internazionele delle Figlie de Maria Ausiliatrice
Profª Drª Juliane Sant’Ana Bento – Universidade Federal do Rio Grande do Sul
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Prof. Dr. Jorge González Aguilera – Universidade Federal de Mato Grosso do Sul
Profª Drª Lina Maria Gonçalves – Universidade Federal do Tocantins
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa
Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande
Profª Drª Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

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

143 Information systems and technology management [recurso eletrônico] / Organizador Marcos William Kaspchak Machado. – Ponta Grossa (PR): Atena Editora, 2019. – (Information Systems and Technology Management; v. 1)

Formato: PDF

Requisitos do sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

ISBN 978-85-7247-201-2

DOI 10.22533/at.ed.012191903

1. Gerenciamento de recursos de informação. 2. Sistemas de informação gerencial. 3. Tecnologia da informação. I. Machado, William Kaspchak. II. Série.

CDD 658.4

Elaborado por Maurício Amormino Júnior – CRB6/2422

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores.

2019

Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

www.atenaeditora.com.br

APRESENTAÇÃO

A obra denominada “*Information Systems and Technology Management*” contempla dois volumes de publicação da Atena Editora. O volume I apresenta, em seus 25 capítulos, um conjunto de estudos direcionados para a gestão da inovação e informações aplicadas no gerenciamento de processos e operações.

As áreas temáticas de gestão da informação e do conhecimento mostram a mais recentes aplicações científicas de ferramentas tecnológicas nas etapas de coleta, processamento e avaliação de dados nos diversos ambientes gerenciais. A crescente aplicação tecnológica e inovação nos sistemas produtivos evidenciam a necessidade de processos de gestão integrada de informações que agilizem, tanto o fluxo, como a aplicação estratégica das informações. A diversidade de aplicações apresentada nos capítulos, desde aplicações militares à gestão agropecuária, ressalta a interdisciplinaridade da gestão do conhecimento e informação.

Este volume dedicado à gestão da inovação, gestão de informação e suas aplicações em processos e operações tratam de temas emergentes sobre ferramentas interativas de gestão de dados, aplicações da informação em ambientes virtuais, educacionais e industriais.

Aos autores dos capítulos, ficam registrados os agradecimentos do Organizador e da Atena Editora, pela dedicação e empenho sem limites que tornaram realidade esta obra que retrata os recentes avanços científicos do tema.

Por fim, espero que esta obra venha a corroborar no desenvolvimento de novos, e valiosos conhecimentos, e que auxilie os estudantes e pesquisadores na imersão em novas reflexões acerca dos tópicos relevantes na área de gestão estratégica da informação e conhecimento.

Boa leitura!

Marcos William Kaspchak Machado

SUMÁRIO

CAPÍTULO 1	1
GESTÃO DA INFORMAÇÃO E CONHECIMENTO NA ERA DIGITALCOMPETÊNCIA INFORMACIONAL E MAPAS CONCEITUAIS	
Francisco Carlos Paletta	
DOI DOI 10.22533/at.ed.0121919031	
CAPÍTULO 2	17
THE CONVERGENCE OF INTERNET OF THINGS AND BLOCKCHAIN TECHNOLOGIES AND BUSINESSES	
Anna Beatriz de Sena de Arruda José Carlos Cavalcanti	
DOI DOI 10.22533/at.ed.0121919032	
CAPÍTULO 3	33
THE CREATIVE USE OF SEARCH ENGINES WEB 2.0 TO RESEARCH INVENTIONS AND CREATE FRUGAL INNOVATIONS	
Carlos Mamori Kono Leonel Cezar Rodrigues Luc Quoniam	
DOI DOI 10.22533/at.ed.0121919033	
CAPÍTULO 4	49
QUALIDADE, AGILIDADE E INOVAÇÃO DE SOFTWARE, UM TRIPÉ PARA APOIAR PEQUENAS EMPRESAS A ALCANÇAR SEU TOTAL POTENCIAL	
Edcley José da Silva Suzana Cândido de Barros Sampaio	
DOI DOI 10.22533/at.ed.0121919034	
CAPÍTULO 5	65
THE EVALUATION OF EXPOSURE RISKS TO NON-IONIZING ELECTROMAGNETIC RADIATIONS: PREDICTION, MEASUREMENT AND MAPPING MODELING FOR THE CITY OF NATAL	
Fred Sizenando Rossiter Pinheiro Silva Gutembergue Soares da Silva André Pedro Fernandes Neto	
DOI DOI 10.22533/at.ed.0121919035	
CAPÍTULO 6	85
LABORATÓRIO DE QUÍMICA: EXPERIÊNCIAS SIMPLES E DE BAIXO CUSTO NAS ESCOLAS E NOS PARQUES	
Ana Beatriz de Souza Prado Andressa de Cássia Faria Alvarenga Anna Beatriz Martins Batista Esther Teodoro da Silva Juliana Soares Mariane Borim Lima Nathalie Paixão de Oliveira Veronica Alves Costa Victória Maria Xavier de Lima	
DOI DOI 10.22533/at.ed.0121919036	

CAPÍTULO 7	91
ANÁLISE DAS TAXONOMIAS DE TELESSAÚDE E TELEMEDICINA: UMA REVISÃO SISTEMÁTICA DA LITERATURA	
Diego Armando de Oliveira Meneses Adicinéia Aparecida de Oliveira	
DOI DOI 10.22533/at.ed.0121919037	
CAPÍTULO 8	108
VALOR FINANCEIRO COMO INDICADOR DA ACURACIDADE DA BASE DE DADOS - SIA/SUS	
Denise Mathias Chennifer Dobbins Abi Rached	
DOI DOI 10.22533/at.ed.0121919038	
CAPÍTULO 9	117
A GESTÃO DO CONHECIMENTO E OS SISTEMAS DE INFORMAÇÃO EM UM AMBULATÓRIO DE SAÚDE DE UMA INSTITUIÇÃO JUDICIÁRIA FEDERAL	
Elisabete Felix Farias Antônio Pires Barbosa	
DOI DOI 10.22533/at.ed.0121919039	
CAPÍTULO 10	134
AVALIAÇÃO DA QUALIDADE DOS SERVIÇOS DE MERCADO DE CAPITAIS DE UMA INSTITUIÇÃO FINANCEIRA BRASILEIRA	
Eric David Cohen	
DOI DOI 10.22533/at.ed.01219190310	
CAPÍTULO 11	149
A MARKET PREDICTION MODEL STOCK BASED ON FUZZY LOGIC	
Sofiane Labidi Allisson Jorge Silva Almeida	
DOI DOI 10.22533/at.ed.01219190311	
CAPÍTULO 12	171
JUROS SOBRE CAPITAL PRÓPRIO: UM ESTUDO DA CONTRIBUIÇÃO NO RESULTADO TRIBUTÁRIO NAS EMPRESAS GOL E LATAM	
Caio Bonacina Nedel Fagundes Sérgio Murilo Petri	
DOI DOI 10.22533/at.ed.01219190312	
CAPÍTULO 13	200
INVESTMENTS IN INFORMATION TECHNOLOGY AND THE ACCESS OF BRAZILIAN POPULATION TO BANKING SERVICES AND FACILITIES	
Oscar Bombonatti Filho Marcos Antonio Gaspar Ivanir Costa Marcos Vinicius Cardoso	
DOI DOI 10.22533/at.ed.01219190313	
CAPÍTULO 14	216
DIMENSÕES INTERVENIENTES NO ATO DO COMPARTILHAMENTO DA INFORMAÇÃO A PARTIR DO MODELO DE GESTÃO EM UMA INSTITUIÇÃO FINANCEIRA	
Rita de Cássia Martins de Oliveira Ventura Mônica Erichsen Nassif	

CAPÍTULO 15 244

COMPARAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA NA PREDIÇÃO DA TENDÊNCIA DE VALORIZAÇÃO DA BITCOIN

Antonio Ricardo Alexandre Brasil

Luiz Alberto Pinto

Karin Satie Komati

DOI DOI 10.22533/at.ed.01219190315

CAPÍTULO 16 255

IMPLANTAÇÃO DO XBRL NO BRASIL: TERRA À VISTA?

Vladimir Pereira Lemes

Carlos Elder Maciel de Aquino

Napoleão Verardi Galegale

DOI DOI 10.22533/at.ed.01219190316

CAPÍTULO 17 274

MODELAGEM DO SISTEMA DE GERENCIAMENTO AGROPECUÁRIO DO MARANHÃO (SGAMA) UTILIZANDO A UML

Lucélia Lima Souza

Yonara Costa Magalhães

Will Ribamar Mendes Almeida

Glynara Kylma Carvalhede Feitosa Almeida

DOI DOI 10.22533/at.ed.01219190317

CAPÍTULO 18 291

FATORES DE SUCESSO NA TERCEIRIZAÇÃO DA TECNOLOGIA DA INFORMAÇÃO: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Fernando Ayabe

Edmir Parada Vasques Prado

DOI DOI 10.22533/at.ed.01219190318

CAPÍTULO 19 309

A UTILIZAÇÃO DA FERRAMENTA DE ANÁLISE DE MODO E EFEITO DE FALHA (FMEA) NA PREVENÇÃO DE RISCOS AMBIENTAIS EM UMA ORGANIZAÇÃO MILITAR

Brunna Guedes da Silva

Juliano Machado Zoch

Victor Paulo Kloeckner Pires

Andressa Rocha Lhamby

DOI DOI 10.22533/at.ed.01219190319

CAPÍTULO 20 325

GESTÃO DA INFORMAÇÃO VIA SISTEMA DIGITAL PARA A EDUCAÇÃO ESPECIAL DO CENTRO DE REFERÊNCIA E APOIO A EDUCAÇÃO INCLUSIVA – CRAEI -

Paulo Sérgio Araújo

Luis Borges Gouveia

DOI DOI 10.22533/at.ed.01219190320

CAPÍTULO 21 345

LITERACIAS DE MÍDIA E INFORMAÇÃO: DAS ARESTAS DA COMPLEXIDADE, DA INFORMAÇÃO E DO HIBRIDISMO AO VÉRTICE DA EDUCAÇÃO

Beatrice Bonami

DOI DOI 10.22533/at.ed.01219190321

CAPÍTULO 22 369

SISTEMA PARA GESTÃO DE EGRESSOS DE UMA INSTITUIÇÃO DE ENSINO SUPERIOR

Ana Flávia de Carlos Teodoro

Leandro Duarte Pereira

André Luis Duarte

DOI DOI 10.22533/at.ed.01219190322

CAPÍTULO 23 376

THE LISBON MUNICIPAL ARCHIVES: CONTRIBUTION FOR THE STUDY OF ITS INFORMATION SERVICE

Paulo Jorge dos Mártires Batista

DOI DOI 10.22533/at.ed.01219190323

CAPÍTULO 24 391

DO ESTUDO DE USUÁRIOS À ARQUITETURA DE INFORMAÇÃO DE UM PORTAL ESPECIALIZADO EM TEATRO

Adriane Maria Arantes de Carvalho

Luciene Borges Ramos

Evanicleide Rodrigues de Souza

Juliana Cristina Leal Fernandes

DOI DOI 10.22533/at.ed.01219190324

CAPÍTULO 25 410

COGNITIVE COMPUTING IN THE ANALYSIS OF COMPLEX SYSTEMS

Carlos de Amorim Levita

João Mattar

DOI DOI 10.22533/at.ed.01219190325

CAPÍTULO 26 414

PROCESSO PARA DESCRIÇÃO DE UMA ARQUITETURA DE REFERÊNCIA APLICADA NUMA LINHA DE PRODUTO CRM

Luana Peres Silva

DOI DOI 10.22533/at.ed.01219190326

SOBRE O ORGANIZADOR..... 431

COMPARAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA NA PREDIÇÃO DA TENDÊNCIA DE VALORIZAÇÃO DA BITCOIN

Antonio Ricardo Alexandre Brasil

Instituto Federal do Espírito Santo, Programa de Pós-Graduação em Engenharia de Controle e Automação (ProPECAut)
Serra - Espírito Santo

Luiz Alberto Pinto

Instituto Federal do Espírito Santo, Programa de Pós-Graduação em Engenharia de Controle e Automação (ProPECAut)
Serra - Espírito Santo

Karin Satie Komati

Instituto Federal do Espírito Santo, Programa de Pós-Graduação em Engenharia de Controle e Automação (ProPECAut)
Serra - Espírito Santo

RESUMO: A moeda virtual Bitcoin surgiu em meados de 2008 e atualmente movimentada mais de 200 mil transações por dia. Um dos maiores interesses dos investidores é saber se o preço sofrerá uma queda ou alta, para que assim, possam realizar compras ou vendas. Neste trabalho foram usadas técnicas de aprendizado de máquina, os classificadores Floresta Aleatória, Rede Bayesiana Gaussiana, Rede Neural Perceptron de Múltiplas Camadas, para predição da tendência de preço da Bitcoin em determinado dia. Para avaliação dos resultados serão utilizados as métricas: Precisão, Revocação e Medida F_1 . Os resultados são

promissores alcançando medida F_1 de 70,50%, melhor que alguns trabalhos correlatos.

PALAVRAS-CHAVE: Bitcoin, Rede Bayesiana Gaussiana, Floresta Aleatória, Rede Neural Perceptron de Múltiplas Camadas.

ABSTRACT: Bitcoin emerged in mid-2008 and currently handles more than 200,000 transactions per day. One of the biggest interests of investors is to know at what point the price will fall or rise, so that they can make purchases or sales. In this work, were used machine learning techniques as Random Forest, Gaussian Bayesian Network and Multilayer Perceptron, to predict Bitcoin's price trend on a given day. To validate the results, the precision, recall and F_1 measure will be used. The preliminary results are promising, reaching 70,50%, better than some correlated works.

KEYWORDS: Bitcoin, Gaussian Bayesian Network, Random Forest, Multilayer Perceptron.

1 | INTRODUÇÃO

A moeda Bitcoin é considerada a primeira moeda digital mundial descentralizada, e é um sistema eletrônico descentralizado de moeda virtual sem depender de bancos centrais. Surgiu em meados de 2008 por meio do artigo "*Bitcoin: A Peer-to-Peer Electronic Cash System*"

elaborado por um programador ou grupo de programadores sob o pseudônimo de Satoshi Nakamoto (NAKAMOTO, 2008).

O termo *Peer to Peer* (do inglês par-a-par ou simplesmente ponto-a-ponto, com sigla P2P) é uma arquitetura de redes de computadores onde cada um dos pontos ou nós da rede funciona tanto como cliente quanto como servidor, permitindo compartilhamentos de serviços e dados sem a necessidade de um servidor central (PARAMESWARAN, 2001). No contexto da Bitcoin, o P2P se refere às trocas efetuadas *online* entre duas partes, sem a necessidade de uma instituição financeira, onde a transação é validada pela rede da Bitcoin, e cada usuário dessa rede funciona como um cliente, ou um servidor. De modo comparativo, num sistema bancário centralizado, há uma instituição que tem como principal objetivo regular e supervisionar todas as instituições financeiras e suas operações (BANCO CENTRAL, 2018).

A *blockchain* é uma tecnologia de registro das Bitcoins que utiliza de validação descentralizada como medida de segurança, para garantir a veracidade das transações. Funciona como uma espécie de livro contábil, que mantém o registro de todas as transações efetuadas na rede da Bitcoin, que vão desde o nó gênese (aquele que deu origem a toda a rede da Bitcoin) até os nós atuais. Desse modo, cada transação, que é realizada na rede, é digitalmente assinada com um determinado código, com o objetivo de garantir a sua autenticidade, impedindo que haja ataque na originalidade de uma transação, mantendo toda integridade da rede Bitcoin (SWAN, 2015).

A implementação da *blockchain* utiliza de uma lista de blocos encadeados, com o seu conteúdo (a transação financeira) e a referência para a impressão digital do bloco anterior. Por isso o nome *blockchain* que significa “cadeia de blocos”. Para cada bloco, há também o *hash* gerado por ele, baseando-se no conteúdo do bloco, para manter a integridade e a segurança da rede da *blockchain*. Ou seja, caso haja alteração de determinado bloco na rede da *blockchain*, sua integridade é garantida pelo bloco posterior, que conhece o *hash* do anterior. É claro, há ainda a possibilidade de um atacante manipular toda a cadeia de bloco, todavia, como a rede é compartilhada possui muitos nós, o atacante demoraria anos para quebrar toda a segurança. Além disso, teria que alterar 51% de toda a rede compartilhada pelos usuários da *blockchain*.

Uma outra diferença da moeda virtual com relação à moeda convencional é a garantia de anonimato, transparência e manipulação das transações. Não é necessário informar, por exemplo, dados de nome, telefone para efetuar transações na cadeia de blocos. Há apenas a necessidade de se criar um endereço para efetuar as trocas, sem esses dados sensíveis. A transparência é uma das principais características das criptomoedas, uma vez que é possível visualizar todas as transações efetuadas na cadeia de blocos (TAR, 2018).

Atualmente, há três formas para se obter uma Bitcoin: a pessoa poderá comprá-la por meio de mercados de moedas virtuais; ou recebê-la, por meio de uma transferência, pois milhares de pessoas e lojas por todo o mundo já aceitam Bitcoins como forma de pagamento; ou poderá fazer a mineração, disponibilizando tempo e processamento de

sua máquina para compor a rede de Bitcoins (SILVA, 2016).

Atualmente, a Bitcoin movimenta mais de 200 mil transações por dia, com o preço de unitário de R\$34.200,00 (referente ao dia 22/02/2018) (BITCOIN, 2018) e possui uma capitalização de mais de 9 bilhões de dólares (BLOCKCHAIN, 2018). Diversos investidores têm sido atraídos pela forte valorização do preço da moeda (YOUNG, 2017), mas há o risco da volatilidade em seu preço. Volatilidade é a possibilidade de queda ou alta do preço do ativo, muitas vezes de forma significativa, em um determinado período de tempo. Por meio da Figura 1 é possível constatar a ocorrência da alta volatilidade do preço da Bitcoin desde abril de 2016. Nesse gráfico, onde o eixo **y** é o preço da Bitcoin, e o eixo **x** o tempo, é possível visualizar que no decorrer de janeiro de 2018 a abril de 2018 houve uma alta queda no preço, indo de quase 20 mil dólares para cerca de 8 mil dólares.



Figura 1 - Volatilidade do Preço da Bitcoin de abril de 2016 à abril de 2018 (WALLABIT, 2018).

Um dos maiores interesses dos investidores é ter uma predição desta tendência de valorização (se o preço sofrerá uma queda ou alta), para que assim, possam realizar compras ou vendas, processo denominado no mercado de ações como *trading*.

Diferente dos trabalhos que tratam da predição de valores de ações, em um futuro, este trabalho trata principalmente da classificação binária de seu preço final - ou seja - o interesse é avaliar se após o início de determinado dia, o seu preço irá aumentar ou baixar; sem tratar diretamente o preço final, e sim, avaliar a tendência de desvalorização ou valorização daquele dia específico.

Desse modo, um sistema inteligente para predição da tendência dos preços da Bitcoin pode ser uma vantagem extremamente competitiva no mercado financeiro, auxiliando na tomada de decisões de investidores e análise de riscos da aplicação da moeda virtual.

Para a modelagem deste cenário, será usada a notação proposta por Gareth et al. (JAMES, 2013): dado um determinado dia, a moeda Bitcoin inicia o dia com um preço **X**, e finaliza com um preço **Y**. Esta variação será modelada por uma variável

binária, **B**, descrita na Equação 1, onde 0 (zero) representa que naquele dia o preço da Bitcoin fechará com alta, e 1 (um) com baixa.

$$B = \begin{cases} 0 & \text{se alta} \\ 1 & \text{se baixa} \end{cases} \quad (1)$$

A representação do modelo matemático é feita por meio de uma equação $\mathbf{C} = \mathbf{f}(\mathbf{A})$, onde **A** é a entrada: o vetor de atributos correspondente ao dia que se inicia, **f** é a função que aplica o algoritmo de aprendizado de máquina nos atributos, tendo como retorno **C**, a resposta do classificador que é uma saída binária, cujos valores foram definidos em **B**.

Neste trabalho serão estudadas técnicas de Aprendizado de Máquina no histórico de preços da Bitcoin para predição da tendência de sua valorização. Serão avaliados os resultados da aplicação dos seguintes classificadores: Floresta Aleatória (BREIMAN, 2001), Rede Bayesiana Gaussiana (LEWIS, 1998) e Rede Neural Perceptron de Múltiplas Camadas (POPESCU, 2009).

2 | TRABALHOS CORRELACIONADOS

Serão listados alguns trabalhos correlatos em ordem cronológica. O trabalho de Shah e Zhang (SHAH; ZHANG, 2014) utilizou a regressão Bayesiana para prever a variação de preço da Bitcoin. De acordo com os resultados de seus experimentos de simulação, foi demonstrado que a proposta do artigo chegaria a duplicar os investimentos de uma pessoa em um tempo inferior a 60 dias.

O trabalho de Greaves e Au (GREAVES; AU, 2015) utilizou as características da rede *Blockchain* para prever o preço da Bitcoin, aplicando técnicas de classificação SVM (*Support Vector Machine* ou Máquina de Vetor de Suporte), Regressão Linear e Redes Neurais com duas camadas, obtendo as acurácias de 53,7%, 54,3%, 55,1%, respectivamente. Entretanto os autores concluíram que a sua previsibilidade é limitada, pois os preços são em sua maior parte ditado por trocas, cujo comportamento está fora do *Blockchain*.

No trabalho de Georgoula e colegas (GEORGOULA et. al, 2015), além do uso do SVM como classificador, foi empregada a análise de sentimentos sobre as consultas na Wikipédia, mostrando que o grau de interesse público na Bitcoin tem um efeito positivo na determinação do seu preço.

No trabalho de Matta, Lunesu e Marchesi (MATTA; LUNESU; MARCHESI, 2015) foram comparadas as tendências de preço da Bitcoin com dados obtidos no Google Trends e o volume de *tweets* positivos postados na rede social Twitter. Dessa forma, o trabalho encontrou uma correlação cruzada positiva nestes *websites*, especialmente entre o preço Bitcoin e os dados do Google Trends.

Um recente trabalho estudou a automatização do *trading* de Bitcoin e por meio dos dados obtidos pela *blockchain* ao longo de cinco anos, gravados diariamente e alcançaram a previsão quanto à mudança diária (alta ou baixa) de preços com uma precisão de 98,7%. Entretanto, ao tentar prever preços futuros eles conseguiram obter uma precisão de apenas 50-55%, com dados em intervalos de 10 minutos (MADAN; SALUJA; ZHAO, 2015).

O trabalho de Amjad e Shah (AMJAD; SHAH, 2017) propôs uma análise da Bitcoin em tempo real para prever os preços futuros para execução de *trades* (compra e venda de Bitcoins). Os pesquisadores constataram que alguns métodos clássicos de previsão de séries temporais, como o ARIMA, produziram previsões precárias, e que a proposta do trabalho que usava uma fusão de algoritmos simples escaláveis, Floresta Aleatória, *Logistic Regression* e LDA, obteve um alto retorno do investimento em Bitcoin, com precisão em torno de 60% a 70%.

3 | MATERIAIS E MÉTODOS

Nesta seção são descritos os materiais, os métodos desenvolvidos e a coleta das métricas de comparação. Um dos materiais é a base de dados, fonte de informação usada nos experimentos. Serão descritas as três técnicas de classificação usadas neste artigo: Floresta Aleatória, Rede Bayesiana Gaussiana e Rede Neural Perceptron de Múltiplas Camadas. E ao final da seção, serão detalhados as métricas de comparação dos resultados.

3.1 Base de Dados

A base de dados que será utilizada nos experimentos está disponível no próprio site da Bitcoin (BITCOIN, 2018), que contém as transações desde o ano de 2011, de hora em hora. A base de dados está no formato CSV e contém as informações da data e hora, valor de abertura, maior preço do dia, menor preço do dia, preço de fechamento do dia, preço médio da Bitcoin do dia, além de outras informações.

Os experimentos serão sobre uma base de dados com as transações de 2011 a 2017, com mais de 80.000 mil registros. Após a obtenção da base de dados, foi necessário realizar um pré-processamento para a remoção das linhas com valores iguais a zero ou valores nulos. Após a etapa de pré-processamento, foi criado mais um atributo referente à variável **B**, conforme a Equação 1.

3.2 Classificadores

Um modelo preditivo pode ser descrito como uma função que, a partir de um determinado conjunto de dados rotulados, constrói um estimador. O estimador pode

ser definido como classificador ou regressor, dependendo da estrutura do conjunto de dados. Se o domínio for um conjunto de valores nominais, tem-se um problema de classificação, mas se o domínio for um conjunto infinito e ordenado de valores, tem-se um problema de regressão (DIETTERICH, 1998).

Os métodos preditivos de aprendizado de máquina podem ser classificados da (FACELI et. al, 2011):

- Métodos baseados em procura, tais como o Floresta Aleatória, ID3, ASSISTANT, CART e C4.5.
- Métodos probabilísticos, tais como o Classificador *Naive Bayes*, Aprendizado Bayesiano e Redes Bayesianas para Classificação;
- Métodos baseados em otimização, tais como o SVM e Redes Neurais Artificiais;
- Métodos baseados em distância, tais como o *k-Nearest Neighbors* e Raciocínio Baseado em Casos;

Para este trabalho, selecionou-se as seguintes técnicas: Floresta Aleatória, Redes Bayesianas e Redes Neurais Artificiais. Todas foram desenvolvidas na ferramenta PyCharm IDE na linguagem Python, utilizando a biblioteca *SCIKIT-LEARN*.

3.2.1 Floresta Aleatória

A Floresta Aleatória é um classificador que usa uma combinação de árvores de decisão, por meio de treinamento supervisionado. Sua divisão é realizada em nós, onde cada nó consiste em outra árvore, que, por meio de amostras, retornam uma classe como saída (BREIMAN, 2001). Essa classe de saída é retornada por meio de votação, aquela classe que receber mais votos de todas as árvores é a escolhida como predição do problema.

Neste caso, damos como entrada o vetor de valores da Bitcoin e o classificador retorna se para aquela entrada o valor que o Bitcoin irá fechar no dia será da classe 1 ou da classe 0, isto é, se ele irá fechar positivamente ou se haverá uma queda no preço.

Em geral, a técnica é robusta em relação à variância nos dados de entrada, menos sensível à presença de características irrelevantes e *overfitting* (RODRIGUEZ-GALIANO et al., 2012). Foi considerado um parâmetro de 50 florestas no algoritmo.

3.2.2 Rede Bayesiana Gaussiana

Diferente da Floresta Aleatória, as Redes Bayesianas (LEWIS, 1998) é um tipo de classificador que utiliza o cálculo de distribuição de probabilidade de uma respectiva entrada pertencer a uma das categorias, e tem como saída a classificação da entrada

na categoria que possuir maior probabilidade.

Ao se trabalhar com Rede Bayesiana, considera-se que os dados são linearmente organizados, todavia, ao avaliar a base de dados utilizada neste trabalho foi identificado que ela não possui essa característica. Desse modo, foi aplicado a Rede Bayesiana com distribuição Gaussiana. Assim, o modelo de resultado terá um alto desempenho com alta velocidade de treinamento, além de possuir uma maior capacidades para prever a probabilidade do dado pertencer a uma determinada classe. Não houve variação dos parâmetros da biblioteca, disponibilizada pela *SCIKIT-LEARN*.

3.2.3 Rede Neural Perceptron de Múltiplas Camadas

A Rede Neural Perceptron de Múltiplas Camadas (MLP) é um tipo de classificador que tem como objetivo superar as limitações da rede Perceptron, sendo bastante eficaz e eficiente, além de simples de se treinar (POPESCU, 2009). Ela é composta por entradas, camadas de neurônios escondidos que levam a algumas saídas. Ele tenta representar matematicamente alguns dos comportamentos dos sistemas biológicos (BISHOP, 2006).

Neste trabalho considerou-se a utilização de uma Rede Neural de Múltiplas Camadas contendo 12 camadas escondidas. Dessa forma, após treinar a Rede Neural, é possível receber como saída a classificação da transação dada como entrada, que conseguirá prever se, a partir dos parâmetros de entrada, o preço da Bitcoin irá cair ou subir no fim do dia.

3.3 MÉTRICAS DE AVALIAÇÃO

Será usada a validação *Holdout*, na qual a base de dados será dividida em um percentual para dados de teste e o restante para treinamento dos algoritmos. Os experimentos serão realizados com os seguintes percentuais para teste e treino: 30% e 70%.

Para avaliar os resultados serão utilizadas as métricas de Precisão, Revocação e a Medida F_1 . O objetivo da Precisão é calcular o número de dados que foram identificados corretamente pelo classificador, ou o quão preciso é o classificador. Em contrapartida, a Revocação representa número de dados de uma classe que foram previstos na classe correta, ou seja, qual a frequência em que o classificador encontra a classe correta.

Há uma relação inversa entre precisão e revocação, onde é possível aumentar um à custa de reduzir o outro. Para avaliar ambas as métricas, usa-se a medida F_1 (Equação 2) é uma média harmônica ponderada da Precisão e da Revocação, onde seu melhor valor é 1 (um) e o seu pior valor é 0 (zero).

$$F_1 = 2 * \frac{\text{precisao} * \text{revocacao}}{\text{precisão} + \text{revocação}}$$

4 | RESULTADOS E DISCUSSÃO

Conforme citado anteriormente, foi feita a etapa de pré processamento e a criação da variável B. Na etapa de criação da variável B, foi extraída uma nova informação para ser utilizada na predição do valor final da Bitcoin para o dia, denominada aqui de *ValorFinal*. O *ValorFinal* é a diferença entre o preço que o Bitcoin fechou (ou a última transação) no dia e do preço que ele abriu. Desta forma, foi possível obter duas classes, conforme a Equação 1: sendo 1 a classe em que o preço da Bitcoin obteve uma alta no dia, finalizando com o valor acima do valor de abertura e, 0 onde o preço Bitcoin obteve uma baixa no dia, finalizando com um preço menor do que o inicial.

Os resultados obtidos, considerando os classificadores apresentados anteriormente, estão apresentados na Tabela 1, onde é possível notar que o algoritmo que obteve maior precisão foi a Rede Neural Perceptron de Múltiplas Camadas, obtendo 70,50% na medida F_1 , embora, o resultado da Floresta Aleatória ficou bem próximo.

Classificador	Precisão	Revocação	Medida F_1
Floresta Aleatória	69,00%	70,00%	69,50%
Rede Bayesiana	63,00%	67,00%	64,94%
Perceptron (MLP)	71,00%	70,00%	70,50%

Tabela 1 - Resultado dos algoritmos aplicados.

A precisão de 70,50% atingida nos resultados parciais deste trabalho foram melhores que o resultado do trabalho de Greaves e Au (GREAVES; AU, 2015) e Madan, Saluja e Zhao (MADAN; SALUJA; ZHAO, 2015), que obtiveram respectivamente 53,00% e 55,00% de precisão. Entende-se que a abordagem da transformação dos dados em binário auxiliou na construção e aplicação dos algoritmos, obtendo resultados favoráveis.

Um dos fatores que auxiliaram em uma maior precisão dos algoritmos aplicados foi a quantidade de dados que utilizou-se para treinar os classificadores. Enquanto na maioria dos casos da literatura foram utilizadas bases de dados menores, neste trabalho foi utilizado uma base mais homogênea, com mais dados relativos ao preço da Bitcoin.

Entretanto, é necessário realizar um estudo mais aprofundado, e as técnicas aqui apresentadas podem ser utilizadas apenas para apoiar a decisão de um investidor.

Dado que o preço da Bitcoin não é determinado apenas pelas balanças de mercados tradicionais, e sim, pelas mudanças da *Blockchain* e as quantidades de transações realizadas, além de interferências ocasionais no mundo, por exemplo, a proibição da Bitcoin em transações virtuais como em alguns países.

5 | CONCLUSÕES E TRABALHOS FUTUROS

Os resultados obtidos são promissores e são motivadores para continuar os estudos para melhorar a acurácia da predição. Identificam-se várias frentes diferentes como trabalhos futuros, desde testar outros algoritmos de aprendizado de máquina, também é possível avaliar técnicas de fusão dos vários classificadores para se extrair um resultado melhor e mais robusto (KUNCHEVA, 2004).

Outra questão é que podem existir fatores externos que impactam no preço da Bitcoin. O preço é tecnicamente ditado pelas trocas, cujos comportamentos estão em grande parte fora do Blockchain (GREAVES; AU, 2015). Assim, é possível que o uso de Análise de Sentimentos em redes sociais seja importante para ser usado conjuntamente com os resultados dos algoritmos de predição.

A quantidade de Bitcoin é limitada, o número de Bitcoins gerados por bloco decresce geometricamente com uma redução de 50% a cada 210.000 mil blocos, ou aproximadamente 4 anos. Assim, sua disponibilidade vem diminuindo, tornando cada vez mais difícil minerar uma moeda Bitcoin. Ao mesmo tempo, conforme foi se popularizando, diversas outras moedas foram surgindo, totalizando cem na lista da Investing.com (INVESTING, 2018), tais como a Ethereum (WOOD, 2014), a Ripple (RIPPLE, 2018), Nano, CloakCoin, Aeon, Litecoin, Namecoin, Peercoin, Dogecoin, Mastercoin, Nxt, Emercoin, Auroracoin, BlackCoin, Dash, DigitalNote, MazaCoin, Monero, PotCoin, E-Coins, Zcash e Niobio Cash. Assim, outra possibilidade de trabalho futuro seria a análise destas outras moedas virtuais. Uma que se destaca é a Ethereum que teve uma valorização muito rápida nos últimos meses, conforme mostrado no gráfico da Figura 2, onde o eixo *x* é o tempo e o *y* é o valor da moeda. Essa análise seria feita por meio da obtenção e utilização dos dados de transações da moeda e um estudo seria avaliar se o seu crescimento continuará nos próximos anos, uma vez que ela sofreu uma valorização no seu preço similar da Bitcoin (CAP, 2018).



Figura 2 - Valoração da moeda Ethereum (Cap, 2018).

REFERÊNCIAS

AMJAD, Muhammed; SHAH, Devavrat. **Trading Bitcoin and Online Time Series Prediction**. Proceedings of the Time Series Workshop at NIPS 2016, p. 1-15, 2017.

BANCO CENTRAL DO BRASIL. **Banco Central do Brasil**. Disponível em: <<https://www.bcb.gov.br>>. Acesso em: 12 out. 2018.

BISHOP, Christopher M. **Pattern recognition and machine learning**. Springer, 2006.

BITCOIN. **Bitcoin is an Innovative Payment Network and a New Kind of Money**. Disponível em: <<http://bitcoin.org>>. Acesso em 10 nov. 2018.

BLOCKCHAIN LUXEMBOURG S.A. **BLOCKCHAIN**. Disponível em: <<http://blockchain.info>>. Acesso em 10 out. 2018.

BREIMAN, Leo. **Random forests**. Springer, Machine learning, v.45, p. 5-32, 2001.

CAP, Coin Market. **Crypto-currency market capitalizations**. Disponível em: <coinmarket.com>. Acesso em 10 de set. 2018.

DIETTERICH, T. G. **Approximate Statistical Tests For Comparing Supervised Classification Learning Algorithms**. Neural computation, MIT Press, v. 10, n. 7, p. 1895–1923, 1998.

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

GEORGOULA, Ifigeneia; POURNARAKIS, Demitrios; BILANAKOS, Christos; SOTIROPOULOS, Dionisios; GIAGLIS, George M. **Using Time-Series and Sentiment Analysis to Detect the Determinants of Bitcoin Prices**. 2015. Disponível em <<https://srn.com/abstract=2607167>>. Acesso em 23 out. de 2017.

GREAVES, Alex; AU, Benjamin. **Using the Bitcoin Transaction Graph to Predict the Price of Bitcoin**. No Data, 2015.

INVESTING. **Todas as criptomoedas**. Disponível em: <<https://br.investing.com/crypto/currencies>>. Acesso em 12 out. 2018.

JAMES, Gareth e Witten, Daniela e Hastie, Trevor e Tibshirani, Robert. **An introduction to statistical learning**. Springer, v. 112, 2013.

KUNCHEVA, Ludmila I. **Combining pattern classifiers: methods and algorithms**, John Wiley & Sons, 2004.

LEWIS, David D. **Naive (Bayes) at forty: The independence assumption in information retrieval**. Springer, European conference on machine learning, p. 4-15, 1998.

MADAN, Isaac; SALUJA, Shaurya; ZHAO, Aojia. **Automated Bitcoin Trading via Machine Learning Algorithms**, 2015. Disponível em: <<http://cs229.stanford.edu/proj2014/Isaac%20Madan,%20Shaurya%20Saluja,%20Aojia%20Zhao,Automated%20Bitcoin%20Trading%20via%20Machine%20Learning%20Algorithms.pdf>>. Acessado em 12 abr. 2018.

MATTA, Martina; LUNESU, Ilaria; MARCHESI, Michele. **Bitcoin Spread Prediction Using Social and Web Search Media**. UMAP Workshops, 2015.

NAKAMOTO, S. **Bitcoin: A peer-to-peer electronic cash system**, 2008.

PARAMESWARAN, M., SUSARLA, A., WHINSTON, A., “**P2P Networking: An Information-Sharing Alternative**”. IEEE Computer, Julho de 2001.

TAR, ANDREW. **Moedas Digitais vs Criptomoedas, Explicado**. Disponível em: <<https://br.cointelegraph.com/explained/digital-currencies-vs-cryptocurrencies-explained>>. Acesso em 10 de set. 2018.

POPESCU, Marius-Constantin; BALAS, Valentina; PERESCU-POPESCU, Liliana; MASTORAKIS, Nikos. **Multilayer perceptron and neural networks**. WSEAS Transactions on Circuits and Systems, v .8, p. 579-588, 2009.

RIPPLE. **Ripple**. Disponível em: <<https://ripple.com/xrp/>>. Acesso em 10 de set. 2018.

RODRIGUEZ-GALIANO, V. F.; GHIMIRE, B.; ROGAN, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. **An Assessment of the Effectiveness of a Random Forest Classifier for Land-cover Classification**. ISPRS Journal of Photogrammetry and Remote Sensing, Elsevier, v. 67, p. 93–104, 2012.

SILVA, GUILHERME ALBURQUEQUE B., e CARLO KLEBER DA S. RODRIGUES. “**Mineração individual de bitcoins e litecoins no mundo**.” XVI Simpósio Brasileiro em Segurança da Informação e de Sistemas Computacionais. Workshop de Trabalhos de Iniciação Científica e de Graduação (SBSeg), Niterói, RJ, novembro. 2016.

SHAH, Devavrat, ZHANG, Kang. **Bayesian regression and Bitcoin**. Communication, Control, and Computing (Allerton), IEEE 52nd Annual Allerton Conference on, p. 409-414, 2014.

SWAN, M.. **Blockchain: Blueprint for a new economy**. O`Reilly Media Inc., 2015.

WOOD, Gavin. **Ethereum: A secure decentralised generalised transaction ledger**. Ethereum project yellow paper p. 1-32. 2014.

WALLABIT, Media LLC. **Gráfico do Histórico de Preço do Bitcoin**. Disponível em: <<http://buybitcoinworldwide.com/pt-br/preco>>. Acessado em 12 abr. 2018.

YOUNG, Joseph. **Billionaire Investor Novogratz: Institutional Investors Will Soon Adopt Bitcoin**. Disponível em: <<https://cointelegraph.com/news/billionaire-investor-novogratz-institutional-investors-will-soon-adopt-bitcoin>>. Acesso em 23 out. de 2017.

SOBRE O ORGANIZADOR

Marcos William Kaspchak Machado - Professor na Unopar de Ponta Grossa (Paraná). Graduado em Administração- Habilitação Comércio Exterior pela Universidade Estadual de Ponta Grossa. Especializado em Gestão industrial na linha de pesquisa em Produção e Manutenção. Doutorando e Mestre em Engenharia de Produção pela Universidade Tecnológica Federal do Paraná, com linha de pesquisa em Redes de Empresas e Engenharia Organizacional. Possui experiência na área de Administração de Projetos e análise de custos em empresas da região de Ponta Grossa (Paraná). Fundador e consultor da MWM Soluções 3D, especializado na elaboração de estudos de viabilidade de projetos e inovação.

Agência Brasileira do ISBN
ISBN 978-85-7247-201-2

