

UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE GRADUAÇÃO
CURSO DE CIÊNCIA DA COMPUTAÇÃO

FERNANDO MACHADO

PREVISÃO DE RECEITA PARA EMPRESAS COM O USO DE DIFERENTES
TÉCNICAS DE APRENDIZADO DE MÁQUINA

SÃO LEOPOLDO
2018

FERNANDO MACHADO

PREVISÃO DE RECEITA PARA EMPRESAS COM O USO DE DIFERENTES
TÉCNICAS DE APRENDIZADO DE MÁQUINA

Artigo apresentado como requisito parcial
para obtenção do título de Bacharel, em
Ciência da Computação da Universidade
do Vale do Rio dos Sinos - UNISINOS

Orientador: Prof. Dr. Gustavo Pessin

São Leopoldo

2018

PREVISÃO DE RECEITA PARA EMPRESAS COM O USO DE DIFERENTES TÉCNICAS DE APRENDIZADO DE MÁQUINA

Fernando Machado

Gustavo Pessin

Resumo: Prever receita baseando-se em períodos históricos é um tema muito importante para as empresas, pois auxilia no desempenho e no apoio no processo de tomada de decisões, garantindo às organizações um crescimento escalável e sustentável no mercado. Este trabalho propõe investigar diferentes técnicas de Aprendizado de Máquina em modelos de previsão a fim de auxiliar no planejamento e no processo de tomada de decisão das empresas de forma rápida e eficaz. Para isto, as técnicas escolhidas para realizar esta investigação serão a Regressão Linear, *Random Forest* e a Redes Neurais Artificiais aplicadas em modelos de intervalos distintos de períodos passados predizendo a receita de um período futuro. Dentre as técnicas escolhidas, *Random Forest* foi a que apresentou o resultado de previsibilidade mais próxima do real.

Palavras-chave: previsão de receita, inteligência artificial, aprendizado de máquina, redes neurais artificiais, regressão linear, *random forest*.

1 INTRODUÇÃO

A previsão de receita é um ponto importante para as equipes que gerenciam as empresas possam acompanhar o desempenho e também apoiar os processos de tomada de decisão relacionados a garantir um bom desempenho do negócio. Ainda que existam muitas publicações detalhando a teoria da previsão, no contexto de negócios, em contrapartida, a previsão de receita possui pouca publicação acadêmica associada, sendo um tema complexo e importante de ser abordado para incentivar futuras pesquisas (WHITFIELD; DUFFY, 2013).

A receita em um contexto de negócios refere-se ao ganho recebido através da venda de bens ou serviços durante um determinado período de tempo, sendo o indicador de entrada de ativos dentro das organizações. Administrações organizacionais monitoram atenciosamente este indicador a fim de garantir justificativa suficiente para apoiar potenciais empregados ou decisões de investimento de capital. Caso a receita tende para baixo, é um indício para adiar ou reduzir compromissos de custos, agora se a receita está tendendo para cima de forma sustentada, então o investimento oportuno para apoiar o crescimento continuado pode ser pertinente. O crescimento da receita, do ponto de vista do investidor ou do

acionista, é um dos principais indicadores de desempenho em avaliação (WHITFIELD; DUFFY, 2013).

Uma previsão de receita tem como objetivo orientar a organização para que a mesma obtenha um crescimento escalável e de forma sustentável em um determinado período de tempo visando sua consolidação no mercado. Organizações que realizam previsão de receita evitam otimismo excessivo e sua estagnação pois conseguem ter uma visão real do próprio negócio, além de orientar o melhor direcionamento aos investimentos a serem realizados, em vista que o gestor sabe o que trouxe resultados positivos e o que precisa ser melhorado (PEREIRA DE; SILVA; AUGUSTO, 2018).

Para (DISCONZI, 2018), a Inteligência Artificial (IA) é uma área que tem muito a contribuir no auxílio de processos de tomada de decisão e na elaboração do planejamento estratégico das organizações, visto que é capaz de solucionar problemas de maneira rápida e eficaz, muito acima da capacidade humana.

Segundo (FUCHS; FUMAGALLI, 2016) o uso de IA nas organizações proporciona benefícios tais como: (i) previsão de decisões através da análise de padrões; (ii) facilita a tomada de decisão através da previsão de dados antes mesmo de serem requisitados; (iii) automatização de tarefas levando a redução de custos.

A proposta deste trabalho tem como objetivo de investigar técnicas de Aprendizado de Máquina em modelos de previsão de receita de uma empresa, servindo como base para trabalhos futuros.

Para a investigação da previsão de receita serão empregados os algoritmos *Random Forest*, Regressão Linear e o *Multilayer Perceptron* (MLP) baseando-se em experiências passadas, no caso, das informações de histórico de receita, criando modelos com intervalos distintos de instâncias para realização da análise.

A escolha do algoritmo *Multilayer Perceptron* se deu por sua empregabilidade em uma série de problemas de predição de séries temporais, baseando-se em atividades passadas (GOMES et al., 2017). Já a escolha do *Random Forest* baseou-se por ser um algoritmo de aprendizado de máquina eficiente e preciso em termos de previsão (CRISCI; GHATTAS; PERERA, 2012). Por fim, Regressão Linear foi escolhido pela capacidade de analisar dados amostrais verificando se há relacionamento entre determinadas variáveis e se estas podem ser utilizadas para estimar ou predizer valores futuros quando conhecidos valores de outras variáveis (RODRIGUES; DE MEDEIROS; GOMES, 2013).

2 TRABALHOS RELACIONADOS

Neste capítulo serão apresentados trabalhos que empregaram o uso de técnicas de Aprendizagem de Máquina com o propósito de realizar previsão.

(GOMES et al., 2017) propuseram avaliar seis arquiteturas diferentes de Rede Neurais Artificiais (*Multilayer Perceptron*), alternando topologias e estruturas com o objetivo de prever o nível de atividades das abelhas baseando-se em dados históricos de níveis de atividades. Tal previsão visa em ajudar a detectar situações adversas, inclusive potencializar a utilização das abelhas em culturas. (FERREIRA; MATIAS, 2011) também propôs o uso de *Multilayer Perceptron* para prever a produção de campos de petróleo através dos dados históricos de produção diretamente do site da ANP (Agência Nacional do Petróleo, Gás Natural e Biocombustíveis), visando fornecer os volumes de produção para o cálculo dos royalties e participações especiais.

(CRISCI; GHATTAS; PERERA, 2012) utilizou diferentes técnicas de Aprendizado de Máquina, sendo *Random Forest* a técnica em comum com este trabalho, com o propósito de prever eventos de mortandade em massa nas comunidades rochosas bentônicas do Mar Mediterrâneo.

(RODRIGUES; DE MEDEIROS; GOMES, 2013) propôs a utilização o de Regressão Linear para previsão de desempenho de estudantes através de dados de suas interações em um ambiente virtual de aprendizagem.

A grande parte dos trabalhos descritos utilizaram apenas uma técnica de Aprendizado de Máquina, sendo que este trabalho propõe o emprego de três técnicas distintas para no final comparar qual técnica obterá melhor resultado para a previsão. A Tabela 1 mostra um comparativo quanto ao uso de técnicas de Aprendizado de Máquina.

Tabela 1 - Comparativo das técnicas apresentadas entre os trabalhos relacionados

Trabalho	Regressão Linear	Random Forest	Multilayer Perceptron
(GOMES et al., 2017)	Não	Não	Sim
(FERREIRA; MATIAS, 2011)	Não	Não	Sim
(CRISCI; GHATTAS; PERERA, 2012)	Não	Sim	Não
(RODRIGUES; DE MEDEIROS; GOMES, 2013)	Sim	Não	Não
Presente trabalho	Sim	Sim	Sim

Fonte: Autor.

3 FUNDAMENTAÇÃO TEÓRICA E TECNOLÓGICA

3.1 Inteligência Artificial (IA)

Segundo (LASKEY; LEVITT, 2001) Inteligência Artificial (IA) é a disciplina da percepção, raciocínio e ação do computação.

A IA esforça-se a entender o pensamento humano com a finalidade de construir entidades inteligentes que funcionem de forma eficiente para alguns problemas complicados, embora a compreensão do pensamento complexo de um cérebro humano seja um assunto difícil para ser resolvido. Apenas algumas áreas ultrapassam o desempenho do cérebro humano, enquanto outras já foram superadas com o desenvolvimento da tecnologia, como máquinas de computador, construídas para realizar inúmeros cálculos por segundo, enquanto isso seria impossível para um cérebro humano médio. A IA é empregada em diversos campos, tais como: medicina, banco de dados, planejamento de produção e economia de distribuição e indústria, contabilidade, monitoramento de qualidade de alimentos, recuperação de informações, biométrico e forense, design de produto, entre outros. A IA baseia-se em diversas teorias de aprendizagem, por exemplo, aprendizagem estatística, aprendizagem evolutiva, aprendizagem neural, etc (JHA et al., 2017).

3.2 Aprendizado de Máquina

O Aprendizado de Máquina, do inglês *Machine Learning* (ML), é um subcampo da Inteligência Artificial (AI) com o propósito da aprendizagem de computadores a partir da entrada de dados sem a interferência humana. O AM introduz algumas abordagens, geralmente divididas em três categorias para o processo de aprendizagem, tais como (TOIVONEN; JORMANAINEN, 2016):

- (i) aprendizagem supervisionada: um algoritmo de aprendizado de máquina é ensinado a partir de um conjunto de dados de entrada e dados de saída desejados permitindo que o algoritmo desenvolva generalizações, baseadas em técnicas de classificação e regressão;
- (ii) aprendizagem não supervisionada: nenhuma saída conhecida é fornecida ao algoritmo, porém o algoritmo tenta encontrar quaisquer

estruturas a partir dos dados não rotulados, para então, apresentar uma saída;

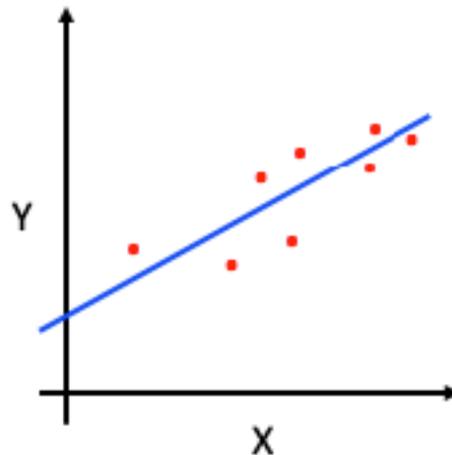
- (iii) aprendizagem por reforço: o algoritmo interage com um ambiente dinâmico, treinando através de tentativa e erro, tentando atingir uma determinada meta com um feedback sobre suas ações.

3.3 Regressão Linear

Regressão Linear é um algoritmo da AM utilizado para estimar valores reais (totais de vendas, número de chamadas, custo de residência) baseado em variáveis contínuas estabelecendo uma relação entre variáveis dependentes e independentes a fim de ajustar a melhor linha. Esta linha é conhecida como linha de regressão e é representada através da equação linear $Y = a * x + b$. A Regressão Linear pode ser classificada em dois grupos, tais como: (i) Regressão Linear Simples, caracterizada por uma única variável independente; (ii) Regressão Linear Múltipla, caracterizada por inúmeras variáveis independentes (FUNDAMENTOS DOS ALGORITMOS DE MACHINE LEARNING, 2018).

Na equação linear duas características são importantes destacar: coeficiente linear da reta (representado pela letra “b”) e o coeficiente angular (representado pela letra “a”). Ainda na equação, “Y” é a variável que será predita (variável resposta ou dependente) e “x” será o valor predito (variável independente ou explicativa), ou seja, preferentemente recomenda-se utilizar “x” como a variável mais acessível, sendo a mais fácil se ser encontrada. Recomenda-se, em geral, desenvolver um trabalho preliminar para afirmar se um modelo linear é apropriado, pois nem todas as situações são aproximadas por uma equação linear. O processo mais simples para verificar se o modelo linear está apropriado, é verificar se os valores de “x” e “Y” mostram visualmente uma tendência linear (RODRIGUES; DE MEDEIROS; GOMES, 2013) conforme ilustrado na Figura 1.

Figura 1 – Exemplo melhor linha de uma Regressão Linear



Fonte: Adaptado (MÍNIMOS QUADRADOS, 2018).

3.4 Random Forest

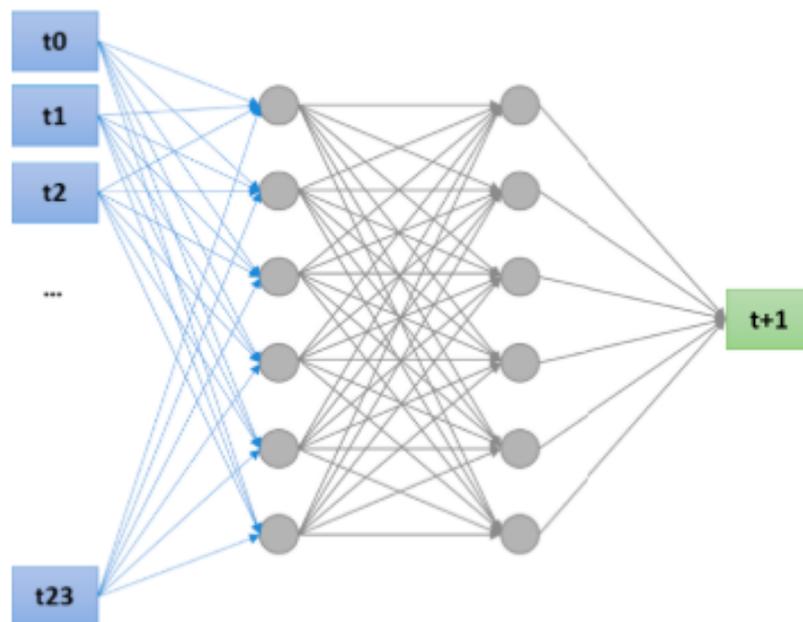
Random Forest é um algoritmo de classificação para Aprendizado de Máquina proposto por Leo Breiman consistido de uma técnica de agregação de inúmeras árvores de decisão, construídas de forma aleatória. Para determinar a classe de uma determinada instância, o algoritmo combina o resultado destas árvores de decisão através de um mecanismo de votação, sendo determinado a classificação final aquela classe que receber o maior número de votos (DINIZ et al., 2013).

Random Forest possui seu classificador baseado no método *Bagging*, ou seja, para cada: (i) árvore gerada, um conjunto diferente de treinamento é usado formado por n instâncias de treinamento escolhidas aleatoriamente; (ii) nó de árvore gerada, m atributos que orientam o direcionamento do nó são escolhidos aleatoriamente, baseado na melhor discriminação das classes do conjunto de treinamento. Via de regra, valor de m deve ser bem menor que o total de atributos da base, afim que possam ser geradas árvores distintas, combinadas para classificar uma nova instância. O modelo gerado elege, entre as opções individuais de cada árvore, a classe mais frequente. Assim, a seleção de atributos é realizada no momento da construção do modelo de classificação, caracterizando esta seleção do tipo embutida. A principal vantagem deste classificador é que ele permite bases de dados com um número grande de atributos, porém é suscetível a um super ajuste em determinadas bases (DINIZ et al., 2013).

3.5 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são consideradas aproximações universais compostas por inúmeros elementos computacionais interagindo por meio de conexões de pesos diferentes. RNA é inspirada no cérebro humano caracterizando-se pela capacidade de aprender complexos padrões de dados assim como generalizar informações aprendidas. No processo de aprendizagem de uma RNA, a configuração de parâmetros é determinante. *Multilayer Perceptron* (MLP) é a forma mais comum de uma RNA constituindo-se por uma arquitetura de três camadas, sendo: (i) camada de entrada; (ii) camada oculta; (iii) camada de saída. A Figura 2 ilustra um exemplo de uma arquitetura MLP completamente conectada com suas camadas de entrada, ocultas e de saída. (DOS SANTOS et al., 2018).

Figura 2 - Arquitetura de uma Rede Neural Artificial *Multilayer Perceptron* com duas camadas ocultas com seis neurônios cada



Fonte: (DOS SANTOS et al., 2018).

Conforme mostrado na Figura 2, a camada de entrada, representada pelos quadrados em azul, é o ponto de entrada dos dados fornecidos ao modelo. Já a camada oculta, representado pelos círculos em cinza, é responsável por realizar o processamento, treinamento e aprendizado da rede. Por fim, a camada de saída, representada pelo quadrado em verde, conclui e exibe o resultado final (DISCONZI, 2018).

3.6 Weka

Weka é um software de código aberto, *portable* e multiplataforma desenvolvido na linguagem Java que possui uma coleção de algoritmos de Aprendizado de Máquina utilizado para solução de tarefas de mineração de dados. Weka contém um conjunto de ferramentas padrão para preparação de dados, classificação, regressão, mineração de regras de associação e visualização (WEKA, 2018).

Existem no Weka cinco interfaces de aplicação, sendo: *explorer*, *experimenter*, *knowledge flow*, *workbench* e linha de comando simples. As tarefas podem ser processadas utilizando qualquer uma destas interfaces (SRIVASTAVA, 2014). Para este trabalho, será utilizada a versão 3.8.3 e a interface *explorer* do Weka.

4 METODOLOGIA

Nesta seção serão detalhados os passos realizados para a validação dos algoritmos propostos neste trabalho descrevendo a coleta dos dados, a definição do modelo, a normalização dos dados e por fim a execução destes dados utilizando a ferramenta Weka.

4.1 Coleta de Dados

Os dados para o estudo foram coletados de um banco de dados de uma empresa do ramo industrial de grande porte. Por questão de confidencialidade, o nome da empresa não será divulgado, sendo então, referenciado como “Empresa A”, assim como os dados coletados que foram normalizados entre 0 e 1, mantendo a proporção e o sigilo dos valores.

Os dados coletados trazem informações referente a um período mensal com seu respectivo valor de receita conforme exemplificado na Tabela 2. Sendo estes dados coletados a partir de janeiro de 2015 a outubro de 2018, totalizando quarenta e seis meses de base de dados.

Tabela 2 - Dados de período e receita coletados para a investigação da previsão da receita

Período	Receita
01.2015	0,57395916
02.2015	0,56366700
03.2015	0,53249074
...	...
08.2018	0,91985137
09.2018	0,96947275
10.2018	1,00000000

Fonte: Autor.

4.2 Modelo

Neste respectivo trabalho serão utilizados os algoritmos Regressão Linear, *Random Forest* e *Multilayer Perceptron* com o propósito de prever a receita do período seguinte. Para isto, os algoritmos serão executados em séries de treinamentos, definindo intervalos distintos de instâncias. Estas instâncias serão dispostas em intervalos de três, seis e doze períodos anteriores à previsão conforme Tabela 3.

Tabela 3 - Configuração dos vetores de entrada para previsão da receita. Quanto ao vetor de entrada, t_0 representa o instante atual, t_1 significa 2 períodos anteriores a ser previsto, t_2 indica 3 períodos anteriores a ser previsto e assim por diante

Referência	Vetor de Entrada	Instante a ser Previsto
w3	t_0, t_1, t_2	t_{+1}
w6	$t_0, t_1, t_2, t_3, t_4, t_5$	t_{+1}
w12	$t_0, t_1, t_2, t_3, t_4, t_5, t_6, t_7, t_8, t_9, t_{10}, t_{11}$	t_{+1}

Fonte: Autor.

Através deste modelo, cada algoritmo será executado com três vetores de dados de entrada a fim de validar a amplitude do valor previsto, resultando em um total de nove execuções. Com isto, será possível demonstrar o desempenho de cada algoritmo.

4.3 Organização dos Dados

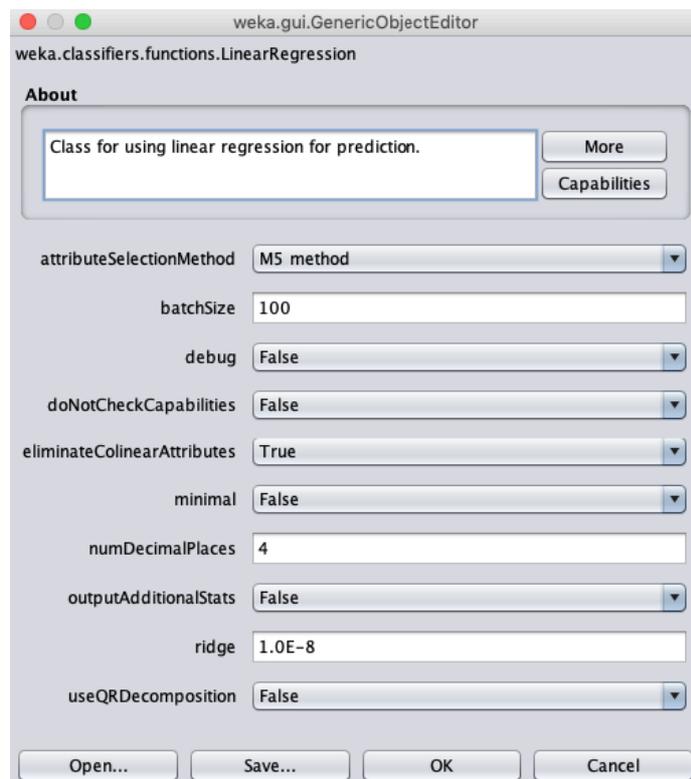
Como os dados coletados estão organizados de forma cronológica, para serem analisados pelo Weka, será necessário dispor os valores da coluna “Receita” criando novas colunas referente aos instantes anteriores à previsão (t_0 , t_1 , t_2 , ..., t_{11}) e ao valor a prever (t_{+1}), de acordo com a definição de cada modelo.

Após a normalização dos dados, é necessário exportar estes dados salvando em arquivos em formato CSV para poderem ser analisados no Weka.

4.4 Configuração Weka

Os algoritmos Regressão Linear, *Random Forest* e *Multilayer Perceptron* serão treinados e testados utilizando os parâmetros de configuração da ferramenta Weka conforme apresentado nas Figura 3, Figura 4 e Figura 5.

Figura 3 - Parâmetros de configuração algoritmo Regressão Linear



Fonte: Autor.

Figura 4 - Parâmetros de configuração algoritmo *Random Forest*

weka.gui.GenericObjectEditor

weka.classifiers.trees.RandomForest

About

Class for constructing a forest of random trees.

bagSizePercent

batchSize

breakTiesRandomly

calcOutOfBag

computeAttributeImportance

debug

doNotCheckCapabilities

maxDepth

numDecimalPlaces

numExecutionSlots

numFeatures

numIterations

outputOutOfBagComplexityStatistics

printClassifiers

seed

storeOutOfBagPredictions

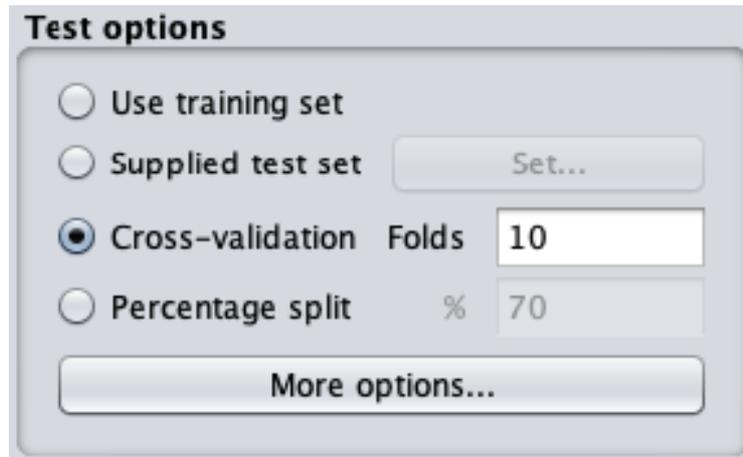
Fonte: Autor.

Figura 5 - Parâmetros de configuração algoritmo *Multilayer Perceptron*

Fonte: Autor.

Para o treinamento dos algoritmos, utilizou-se o valor de 10 *Folds* para a opção “*Cross-validation*” em “*Test options*” conforme ilustrado na Figura 6.

Figura 6 - Configuração para Teste e Treinamento na ferramenta Weka



Fonte: Autor.

Com a configuração utilizada para a opção “*Cross-validation*”, os dados serão divididos aleatoriamente em dez partes iguais. Uma parte é utilizada como conjunto de teste e as outras nove partes como treinamento. Este processo se repete ao total de 10 vezes (conforme valor determinado para o campo *Folds*). No final, os resultados do teste serão calculados sobre os dez casos (RAVI et al., 2005).

5 RESULTADOS

Neste capítulo serão apresentados os resultados obtidos a partir da execução dos algoritmos propostos neste trabalho.

Os resultados obtidos a partir da execução dos algoritmos com o uso de vetores de entrada de instâncias de períodos de três, seis e doze podem ser observados conforme Tabela 4 e Figura 7.

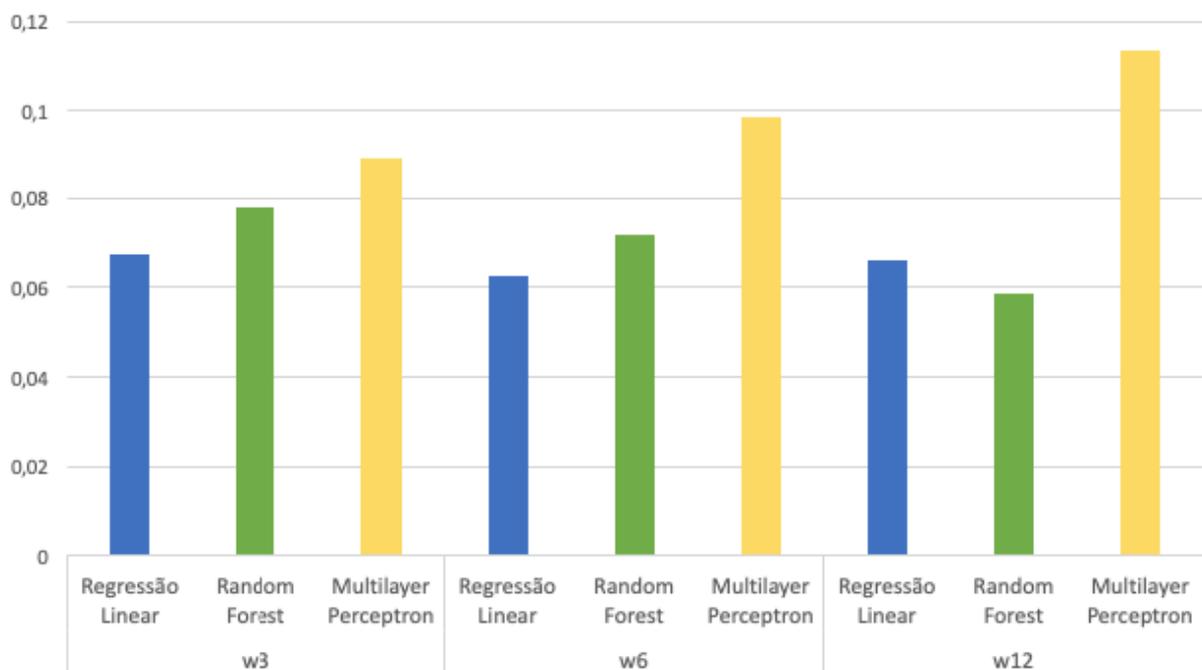
Tabela 4 - Resultados da execução dos algoritmos na ferramenta Weka

Referência	Algoritmo	MAE
w3	Regressão Linear	0.0676
	Random Forest	0.0781
	Multilayer Perceptron	0.0894
w6	Regressão Linear	0.0628
	Random Forest	0.0720
	Multilayer Perceptron	0.0985
w12	Regressão Linear	0.0662
	Random Forest	0.0586*
	Multilayer Perceptron	0.1136

Fonte: Autor.

Conforme observamos na Figura 7, a técnica de *Multilayer Perceptron* apresenta piora de desempenho quando aumentada a janela de dados de entrada, ao contrario da técnica de *Random Forest* que obteve uma diminuição. Já para a técnica de *Regressão Linear*, manteve-se um desempenho estável nos modelos definidos.

Figura 7 - Gráfico comparativo dos resultados da execução dos algoritmos na ferramenta Weka



Fonte: Autor.

5.1 Medidas de Erro

A análise do desempenho dos algoritmos ocorreu através do índice Erro Médio Absoluto (MAE) conforme detalhados no subtópico a seguir.

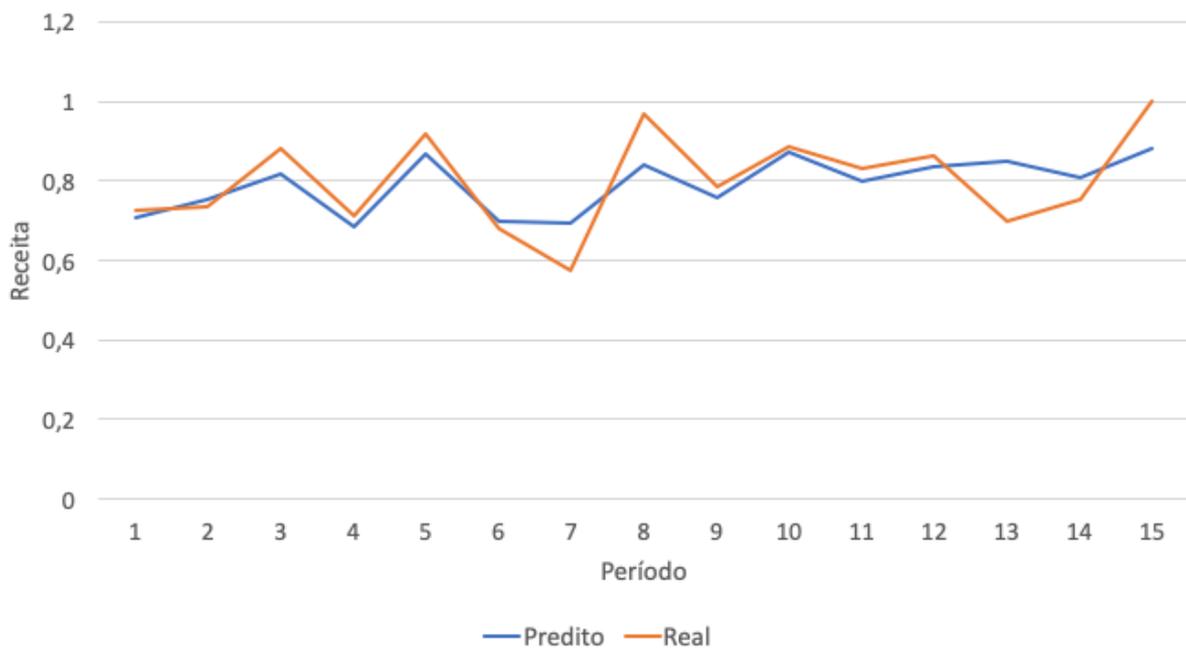
5.1.1 Erro Médio Absoluto (MAE)

Erro Médio Absoluto, do inglês *Mean Absolute Error* (MAE), pode ser obtido pela soma dos erros absolutos dividido pelos resultados previstos. Este cálculo nos mostra a proximidade do modelo previsto com o modelo real (KUMAR; SAHOO, 2012).

Conforme resultados mostrados na Tabela 4 pode-se observar que o modelo “w12” utilizando o algoritmo Random Forest foi o que realizou a previsão com o menor desvio do valor real da variável, tornando assim o mais preciso dentre as execuções realizadas.

A Figura 8 apresenta um gráfico comparativo entre o valor histórico (valor real) e o valor previsto, mostrando grande similaridade entre as linhas predito e real.

Figura 8 - Gráfico comparativo entre os valores reais e preditos



Fonte: Autor.

6 CONCLUSÃO

Neste trabalho foram avaliadas diferentes técnicas de Aprendizado de Máquina para realizar a previsão de receita de uma empresa. Para aplicação destas técnicas foi utilizada uma base histórica criando modelos com intervalos distintos de instâncias em intervalos de três, seis e doze períodos anteriores à previsão. Dos algoritmos aplicados (Regressão Linear, *Random Forest* e *Multilayer Perceptron*), *Random Forest* foi o que obteve uma previsibilidade mais próxima do real. Para obter este desempenho, o algoritmo precisou de um histórico de doze períodos anteriores à previsão.

Conforme os resultados obtidos neste trabalho, observou-se que foi possível realizar uma previsão de receita consistente, podendo auxiliar organizações no seu desempenho assim como apoiar no processo de tomada de decisões.

Como sugestão de trabalhos futuros, identificou-se a possibilidade de elaborar outros modelos que contenham mais variáveis como parâmetros para análise, aumentando assim a qualidade previsibilidade.

REVENUE FOR COMPANIES WITH THE USE OF DIFFERENT MACHINE LEARNING TECHNIQUES

Abstract: Predicting revenue based on historical periods is a very important topic for companies, as it assists in performance and support in the decision-making process, ensuring organizations a scalable and sustainable growth in the market. This paper proposes to investigate different Machine Learning techniques in prediction models in order to assist in the planning and decision making process of the companies in a fast and effective way. For this, the techniques chosen to perform this investigation will be the Linear Regression, Random Forest and the Artificial Neural Networks applied in models of different intervals of past periods predicting the revenue of a future period. Among the techniques chosen, Random Forest was the one that presented the predictability result closer to the real.

Keywords: revenue forecasting, artificial intelligence, machine learning, artificial neural networks, linear regression, random forest.

REFERÊNCIAS

CRISCI, C.; GHATTAS, B.; PERERA, G. A review of supervised machine learning algorithms and their applications to ecological data. **Ecological Modelling**, [s. l.], v. 240, p. 113–122, 2012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304380012001081>>. Acesso em: 13 nov. 2018.

DINIZ, Fabio Abrantes et al. RedFace: um sistema de reconhecimento facial baseado em técnicas de análise de componentes principais e autofaces. **Revista Brasileira de Computação Aplicada**, [s. l.], v. 5, n. 1, p. 42–54, 2013. Disponível em: <<http://www.upf.br/seer/index.php/rbca/article/view/2627>>. Acesso em: 5 nov. 2018.

DISCONZI, Claudia Maria Dias Guerra. **Previsão dos preços de commodities agrícolas brasileiras no mercado futuro utilizando redes neurais artificiais**. 2018. Universidade Federal do Pampa, [s. l.], 2018. Disponível em: <[http://dspace.unipampa.edu.br/bitstream/rii/2967/1/Claudia Guerra Disconzi - 2018.pdf](http://dspace.unipampa.edu.br/bitstream/rii/2967/1/Claudia%20Guerra%20Disconzi%202018.pdf)>. Acesso em: 29 out. 2018.

DOS SANTOS, Uélison Jean L. et al. AgriPrediction: A proactive internet of things model to anticipate problems and improve production in agricultural crops. **Computers and Electronics in Agriculture**, [s. l.], 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169917313856>>. Acesso em: 9 nov. 2018.

FERREIRA, Fellipe Paes; MATIAS, Ítalo De Oliveira. Previsão da produção de campos de petróleo utilizando redes neurais. **10th Brazilian Congress on Computational Intelligence (CBIC'2011)**, [s. l.], v. d, p. 1–8, 2011. Disponível em: <http://abricom.org.br/wp-content/uploads/2016/03/st_19.2.pdf>

FUCHS, Klaus; FUMAGALLI, Luis André Wernecke. O USO DA INTELIGÊNCIA ARTIFICIAL (IA) NA FORMULAÇÃO DA ESTRATÉGIA ORGANIZACIONAL: UM ESTUDO SOBRE A APLICAÇÃO DA COMPUTAÇÃO COGNITIVA EM EMPRESAS. **Caderno PAIC**, [s. l.], v. 17, n. 1, p. 27–38, 2016. Disponível em: <<https://cadernopaic.fae.edu/cadernopaic/article/view/202>>. Acesso em: 1 nov. 2018.

Fundamentos dos Algoritmos de Machine Learning. 2018. Disponível em: <<https://www.vooo.pro/insights/fundamentos-dos-algoritmos-de-machine-learning-com-codigo-python-e-r/>>. Acesso em: 4 nov. 2018.

GOMES, Pedro A. B. et al. **Avaliação de Diferentes Arquiteturas de Redes Neurais Recorrentes na Previsão do Nível de Atividade de Abelhas**. [s.l.: s.n.]. Disponível em: <<http://csbc2017.mackenzie.br/public/files/8-wcama/7.pdf>>. Acesso em: 2 nov. 2018.

JHA, Sunil Kr. et al. Renewable energy: Present research and future scope of Artificial Intelligence. **Renewable and Sustainable Energy Reviews**, [s. l.], v. 77, p. 297–317, 2017. Disponível em: <<https://www-sciencedirect.ez101.periodicos.capes.gov.br/science/article/pii/S136403211730518X#s0055>>. Acesso em: 4 nov. 2018.

KUMAR, Yugal; SAHOO, G. Analysis of Parametric & Non Parametric Classifiers for Classification Technique using WEKA. **International Journal of Information Technology and Computer Science**, [s. l.], v. 4, n. 7, p. 43–49, 2012. Disponível em: <<http://www.mecs-press.org/>>. Acesso em: 13 nov. 2018.

LASKEY, K. B.; LEVITT, T. S. Artificial Intelligence: Uncertainty. **International Encyclopedia of the Social & Behavioral Sciences**, [s. l.], p. 799–805, 2001. Disponível em: <<https://www-sciencedirect.ez101.periodicos.capes.gov.br/science/article/pii/B0080430767003958#mc0053>>. Acesso em: 4 nov. 2018.

Mínimos Quadrados. 2018. Disponível em: <<https://www.math.tecnico.ulisboa.pt/~calves/cursos/mmq.htm>>. Acesso em: 15 nov. 2018.

PEREIRA DE, Valter; SILVA, Da; AUGUSTO, Leandro. Revista Científica Multidisciplinar Núcleo do Previsão de Vendas no Varejo Através de Rede Neural. [s. l.], v. 03, p. 131–149, 2018. Disponível em: <<https://www.nucleodoconhecimento.com.br/marketing/rede-neural>>. Acesso em: 1 nov. 2018.

RAVI, Nishkam et al. **Activity Recognition from Accelerometer Data**. [s.l.: s.n.]. Disponível em: <www.aaai.org>. Acesso em: 11 nov. 2018.

RODRIGUES, Rodrigo Lins; DE MEDEIROS, Francisco P. A.; GOMES, Alex Sandro. Modelo de Regressão Linear aplicado à previsão de desempenho de estudantes em ambiente de aprendizagem. In: BRAZILIAN SYMPOSIUM ON COMPUTERS IN EDUCATION (SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO - SBIE) 2013, **Anais...** [s.l.: s.n.] Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/2539>>. Acesso em: 5 nov. 2018.

SRIVASTAVA, Shweta. **Weka: A Tool for Data preprocessing, Classification, Ensemble, Clustering and Association Rule Mining**. [s.l.: s.n.]. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.429.1463&rep=rep1&type=pdf>>. Acesso em: 7 nov. 2018.

TOIVONEN, Tapani; JORMANAINEN, Ilkka. Using JS-Eden to introduce the concepts of reinforcement learning and artificial neural networks. In: PROCEEDINGS OF THE 16TH KOLI CALLING INTERNATIONAL CONFERENCE ON COMPUTING EDUCATION RESEARCH - KOLI CALLING '16 2016, New York, New York, USA. **Anais...** New York, New York, USA: ACM Press, 2016. Disponível em: <<http://dl.acm.org/citation.cfm?doid=2999541.2999548>>. Acesso em: 4 nov. 2018.

Weka. 2018. Disponível em: <<https://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 8 nov. 2018.

WHITFIELD, R. I.; DUFFY, A. H. B. Extended revenue forecasting within a service industry. **International Journal of Production Economics**, [s. l.], v. 141, n. 2, p. 505–518, 2013. Disponível em: <<https://www-sciencedirect.ez101.periodicos.capes.gov.br/science/article/pii/S0925527311004786>>. Acesso em: 30 out. 2018.