

# Sistema para análise e estatística do mercado de ações

*System for stock market analysis and statistics*

**Wyller Queiroz Martins**

Graduando do curso de Sistemas de Informação (UNIPAM).

E-mail: [wyllerxd@gmail.com](mailto:wyllerxd@gmail.com)

**Juliana Lilis da Silva**

Professora orientadora (UNIPAM).

E-mail: [juliana@unipam.edu.br](mailto:juliana@unipam.edu.br)

---

**Resumo:** A ascensão do Mercado Financeiro pode ser notada a cada dia, logo vem surgindo um número massivo de novos investidores inexperientes que não têm conhecimento para investir nesse seguimento. Com base nesse contexto, este artigo apresenta o desenvolvimento de um sistema para prever as transações das empresas da Bovespa, tendo por objetivo auxiliar os investidores com base em previsões e índices. Para gerar os resultados, foi utilizada uma técnica de *Machine Learning*, chamada Rede Neural, possibilitando, assim, uma análise mais eficiente dos dados. Com um estudo aprofundado do mundo do Mercado Financeiro e mais especificamente da Bovespa, foi possível que o sistema conseguisse gerar diversos gráficos, como de investimentos e de volumes. Assim, o sistema possibilita aos investidores uma visão mais ampla e estratégica de como está o mercado no momento atual e como ele estará nos próximos dias.

**Palavras-chaves:** Bovespa. *Machine Learning*. Mercado Financeiro.

**Abstract:** The Financial Market rise can be noted every day, and a large number of inexperienced new investors, who do not have the knowledge to invest, have emerged. Based on this context, this article presents the development of a system to predict the transactions of Bovespa companies in order to assist investors based on forecasts and indices. To generate results, a Machine Learning technique called Neural Network was used, thus facilitating data analysis. With an in-depth study of the Financial Market world and more specifically of Bovespa, it was possible that the system can generate several graphs, such as investments and volumes. Thus, the system gives investors a broader and strategic view of how the market is like at the moment and how it will be in the coming days.

**Keywords:** Bovespa. *Machine Learning*. Financial Market.

---

## 1 INTRODUÇÃO

Assimilar a capacidade humana de raciocinar, agir, perceber as coisas ao seu redor e tomar decisões não é um processo trivial. O desafio de tentar programar a máquina para aprender essas características tão complexas aliado ao fraco poder de processamento existente há alguns anos fizeram com que a aplicabilidade da

inteligência artificial ficasse estagnada por muitos anos. Com a grande evolução do hardware nos últimos anos e o surgimento de ramificações como o *Machine Learning*, o cenário mudou bastante. Assim, têm-se estudado e aplicado técnicas com o objetivo de dar ao computador a habilidade de aprender algo sem ser explicitamente programado para isso (SAMUEL, 1959).

Nos dias atuais, é possível um computador analisar, em minutos, o que o ser humano não conseguiria em anos, computando um grande conjunto de variáveis que seriam impossíveis de analisar com tal precisão por um ser humano comum. Esse tipo de análise e estimativa é chamado de *Data Science* (Ciência dos Dados). *Data Science* combina estatística, matemática, programação, resolução de problemas, capturando dados de maneiras engenhosas, tendo a capacidade de olhar as coisas de forma diferente para encontrar padrões, juntamente com as atividades de limpeza, preparação e alinhamento dos dados (MONNAPPA, 2018).

No mercado de ações, existem inúmeros dados a serem avaliados, que variam para cada bolsa de valor. Sabe-se que existe uma infinidade de bolsas em todo o mundo. Com um sistema computacional, é possível analisar todos esses dados, estimando assim o fluxo da bolsa de valores. O interessante, também, é que quanto mais antiga for a bolsa de valores, mais dados o sistema tem para analisar, assim, tornando-se mais certo em suas estimativas.

Em uma negociação entre investidores no mercado de ações, existem os intermediários, que normalmente são corretoras que fazem todo o processo de negociação em nome desses investidores. Entretanto, devem-se comprar ou vender quais ações e em que momento devem-se realizar essas operações são os quesitos mais relevantes nesse tipo de negociação. Por exemplo, de acordo com Fuller (2018), comprar na baixa e vender na alta é um dos grandes equívocos que existem hoje no mercado de ações, além de ser considerado um mito por muitos, pois é impossível ser tão preciso em uma previsão relacionada à bolsa de ações.

Percebe-se, portanto, que o investidor não precisa escolher pontos exatos de viragem do mercado para obter lucros, mas precisa saber ler os gráficos, a história apresentada no gráfico e entender o que aqueles dados representam. O investidor deve procurar sinais de ação de preços que fazem sentido e estejam coesos com a história da bolsa de valor analisada (FULLER, 2018).

Então, um bom investidor é aquele que sabe ler, interpretar e tirar conclusões de acordo com os dados apresentados em um gráfico. Nesse sentido, o intuito deste trabalho foi desenvolver um sistema que conseguisse executar esses três passos, com uma taxa de acurácia superior a 50%, assim auxiliando o investidor no momento de realizar conclusões, podendo o agir com base nos gráficos estimados.

## 2 REFERENCIAL TEÓRICO

Nesta seção, são apresentados estudos referentes a *Machine Learning*, *Data Science*, *Deep Learning* e Mercado de Ações, os quais foram a base para o desenvolvimento deste trabalho.

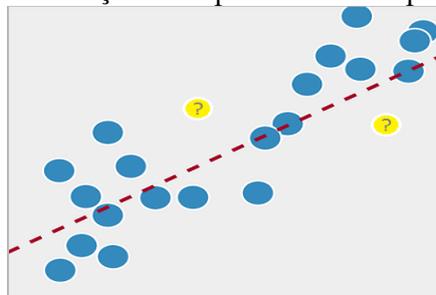
## 2.1 MACHINE LEARNING

Os seres humanos sabem facilmente distinguir uma informação de outra, e, por meio da experiência, podem tirar conclusões em decisões simples, como reconhecer se um animal é um cão ou um porco, se um e-mail é spam ou não ou decidir se uma movimentação bancária é uma fraude ou não. O computador pode aprender de forma similar, em um processo chamado de Classificação dentro da área de *Machine Learning*. A Classificação é uma ferramenta para responder a perguntas, mas antes é preciso saber quais e quantas perguntas fazer, a partir de quais informações, e ainda, como interpretar as respostas (GUILHERME; BENNET, 2017).

Para que esse aprendizado aconteça, há, entre inúmeros métodos, o Aprendizado Supervisionado. Esse método pode ser utilizado quando se tem um conjunto de dados de saída para se basear e há o desejo de se prever esse padrão em outros dados. Sendo assim, um conjunto de dados de saída bem definido é suficiente para os algoritmos preverem os padrões que relacionam as entradas com as saídas. Dessa forma, se houver novos dados apenas com as entradas, as saídas com base nos padrões previamente encontrados podem ser previstas (BAIA, 2016).

Como demonstra a Figura 1, o objetivo do uso de *Machine Learning*, especificamente do uso do Aprendizado Supervisionado, é prever os pontos em amarelo com base nos pontos azuis.

**Figura 1** – Ilustração do Aprendizado Supervisionado



Fonte: BAIA (2016, p.5)

Com esse tipo de aprendizado, é possível prever os valores das bolsas de valores com base no histórico que ela apresenta. Nesse contexto, o objetivo de utilizar inteligência artificial é treinar o sistema, com base no histórico da bolsa de valores, para reconhecer o padrão entre as variáveis de entrada e os valores das ações. Com esses dados de entrada e de saída, o sistema é treinado para aprender a usar esse padrão para prever, somente com as variáveis de entrada, os valores das ações futuras. Quanto maior o histórico, maior a quantidade de dados para serem usados como base, assim aumentando a acurácia do sistema.

## 2.2 DATA SCIENCE

A Ciência dos Dados (*Data Science*) incorpora várias ferramentas para reunir um conjunto de dados, processar e derivar estimativas desse conjunto de dados, extrair dados significativos do conjunto e interpretá-los para fins de tomada de decisão. As áreas disciplinares que compõem o campo da ciência dos dados incluem mineração, estatística, aprendizagem de máquina, análise e alguma programação (LLC, 2018).

Diante das várias possibilidades e vantagens identificadas, utilizou-se a estimativa que o *Data Science* proporciona, junto com o *Machine Learning* como base, para estimar um continuamente linear, em formatos de gráficos, visando a identificar como estará o valor de cada bolsa de valor em datas futuras. Assim, proporciona-se uma fácil leitura e interpretação para rápidas tomadas de decisões.

## 2.3 DEEP LEARNING

O *Deep Learning* é uma forma de *Machine Learning*, que permite computadores aprenderem com a experiência e entenderem o mundo em termos de hierarquia e conceitos. Quando o computador reúne conhecimento a partir da experiência, não há necessidade para um operador de computador humano formalmente especificar todo o conhecimento necessário para o mesmo. A hierarquia de conceitos permite ao computador aprender conceitos complicados, construindo-os de forma mais simples (GOODFELLOW; BENGIO; COURVILLE, 2016).

Aplicando *Deep Learning* no desenvolvimento do projeto, observou-se que o sistema toma melhores decisões com base nos históricos de dados fornecidos a ele, assim possibilitando que o investidor tenha uma visão ampla de vários anos da bolsa de valores, estabelecendo métricas e aumentando a acurácia de sua estimativa.

## 2.4 MERCADO DE AÇÕES

O mercado de ações, também chamado de mercado da bolsa de valores, é o mercado das oportunidades de investimento de capital, consistindo na demanda em ativos e em crescimento financeiro por muitos empresários, comerciantes, pequenos investidores, acionistas etc. O mercado de ações é referência de economia nacional, tendo um alto fluxo de oferta e demanda por ser representado pela Bovespa e por oferecer um prognóstico de referência para o crescimento do país (MERCADO DE AÇÕES, 2012).

Os investidores usam as corretoras para investir nas bolsas de valores. As corretoras servem para intermediar a compra e a venda de ações. Por meio dessas corretoras, obtêm-se os dados que são utilizados para o aprendizado e treinamento do sistema, possibilitando o acesso a um grande volume de dados para que seja possível obter bons resultados por meio do Aprendizado Supervisionado.

### 3 METODOLOGIA

Para o desenvolvimento do trabalho, inicialmente foi realizado um levantamento bibliográfico para realização dos estudos referentes às técnicas de inteligência artificial, as quais poderiam ser aplicadas para análises de dados do setor financeiro de bolsa de valores. Sendo assim, foram utilizados livros e artigos acadêmicos referentes ao tema.

Após os estudos, foi definido que seria utilizada a técnica de *Machine Learning* para o treinamento e previsão do comportamento das bolsas de valores. Para análise do comportamento dos dados, foi utilizada a técnica de *Deep Learning*, que aumentou a acurácia da previsão do sistema, usando aprendizado supervisionado e se baseando nos longos históricos disponibilizados.

Para análise e estudo dos dados, foram utilizadas as ferramentas relacionadas à *Data Science*. *Data Science* é o conceito no qual foi baseado todo o sistema, todas as técnicas, ferramentas e metodologias. Importante destacar que o conceito em foco foi utilizado principalmente para a análise e o estudo dos dados.

Para o desenvolvimento do sistema, foram utilizadas as ferramentas relacionadas a seguir:

- Python: foi a linguagem de programação usada para desenvolver todo o sistema. Essa linguagem é conhecida por ser expressiva no processo de traduzir o raciocínio em um algoritmo (PYSCIENCE-BRASIL, 2018). Sua base automatizada e suas bibliotecas específicas em aplicações de *Machine Learning* atendeu com êxito à demanda do sistema.

- Pandas: o Pandas é uma biblioteca Python que fornece uma estrutura para tratar os dados, tornando-os maleáveis, portanto melhores de trabalhar (PANDAS-DOCS, 2018). O Pandas teve o papel de manipular os dados dentro do sistema para a técnica de Rede Neural fazer suas previsões.

- Rede Neural: redes neurais artificiais é um conceito da computação que visa a trabalhar no processamento e na previsão de dados, de maneira semelhante ao cérebro humano. O cérebro é tido como um processador altamente complexo, que realiza processamentos de maneira paralela. Para isso, ele organiza sua estrutura, ou seja, os neurônios, de forma que eles realizem o processamento necessário. Isso é feito numa velocidade extremamente alta e não existe qualquer computador no mundo capaz de realizar o que o cérebro humano faz (ALECRIM, 2004).

A arquitetura de Rede Neural foi produzida e testada para um maior desempenho e velocidade no processamento dos dados. Essa arquitetura foi executada na linguagem Python, utilizando Pandas. Devido a essa combinação, foi possível testar diversas arquiteturas diferentes, assim encontrando uma que satisfizesse, tanto em desempenho, quanto em acurácia as previsões.

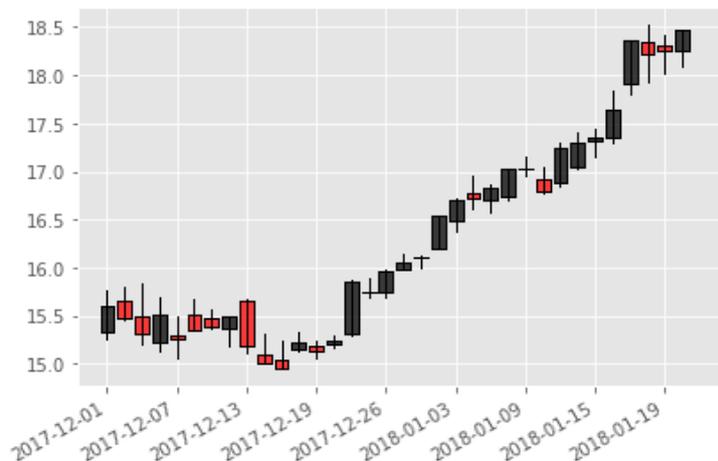
#### 4 DESENVOLVIMENTO E RESULTADOS

O objetivo inicial do trabalho, que utilizou o método *Random Forest*, era gerar um gráfico de *Candlestick* no qual os dados dos meses anteriores seriam apresentados e os de algumas semanas posteriores seriam projetados como previsão para os investidores. Após todos os dados estarem estruturados e prontos para executar a previsão, ficou visível que seria inviável prever essa enorme quantidade de dados com essa metodologia.

A partir dessa constatação, foi decidido que o método chamado Rede Natural, método muito eficiente no mundo de *Machine Learning*, seria utilizado. Com esse método, foi possível aplicar várias fórmulas, práticas contábeis e melhorar a estrutura de dados para executar a previsão com maior velocidade de execução e resultados com melhor acurácia.

Conforme abordado anteriormente e para demonstrar todas as etapas de desenvolvimento do trabalho, o Gráfico 1 apresenta o primeiro gráfico gerado, um gráfico de *Candlestick*, que mostra a estrutura de dados e como ficaria essa estrutura após a previsão, usando o método *Random Forest*.

**Gráfico 1 – Candlestick**



**Fonte:** Elaborado pelo autor, 2018.

O Gráfico 1 demonstra um ano dos dados compilados no qual se basearia a previsão inicial, mas não foi viável por baixa acurácia e tempo de execução. Conforme já mencionado, a metodologia de Rede Neural passou a ser utilizada.

Nas primeiras previsões com Rede Neural, conforme demonstra a Figura 2, a acurácia foi muito aquém ao esperado, tanto pela desordem dos dados, quanto pelo tempo de execução. Então, foi notado que os dados estavam muito instáveis e que estava muito complicado encontrar um padrão em meio a tanta desigualdade de dados, pelo fato de as empresas da Bovespa serem muito diferentes entre si.

**Figura 2 – Resultados iniciais**

```

Epoch 48/50
2709/2709 [=====] - 51s 19ms/step - loss: 4.4623e-07
Epoch 49/50
2709/2709 [=====] - 55s 20ms/step - loss: 4.8540e-07
Epoch 50/50
2709/2709 [=====] - 53s 20ms/step - loss: 4.5396e-07
    
```

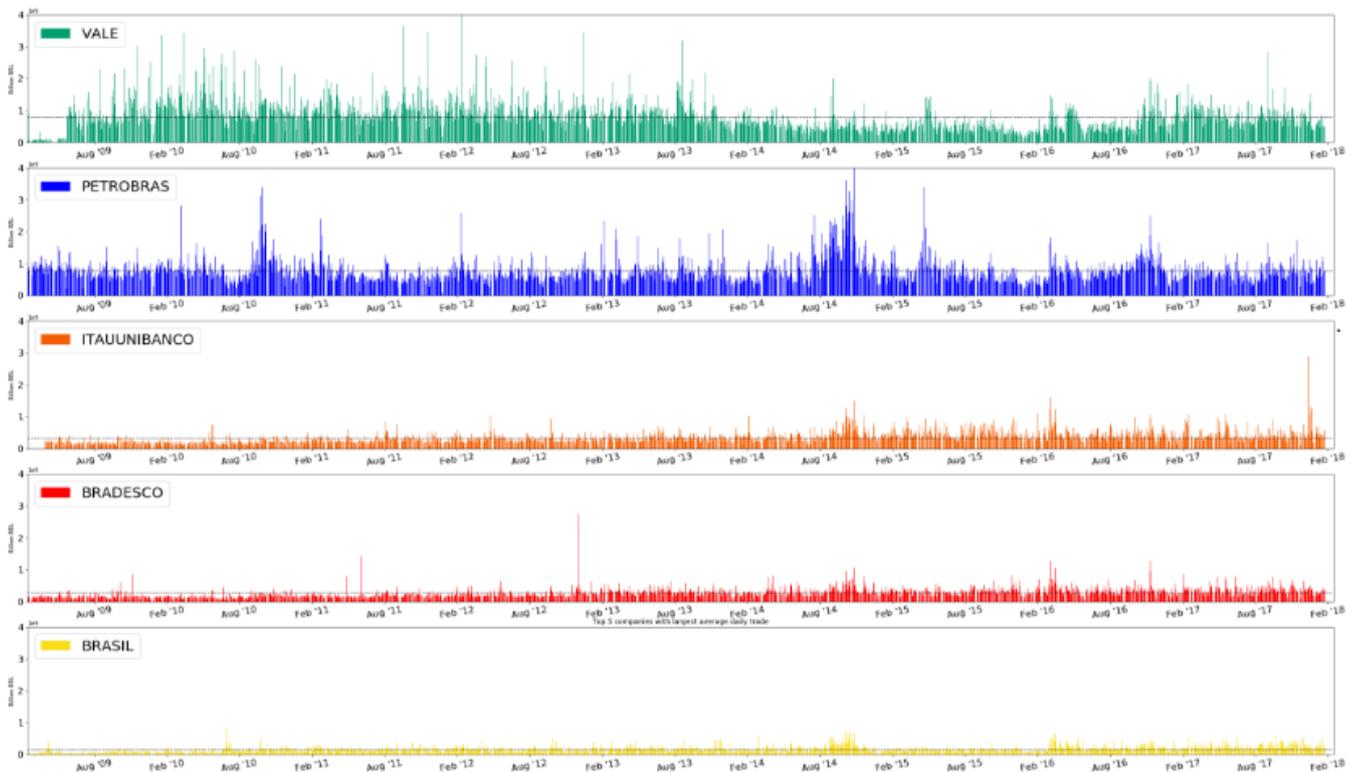
Fonte: Elaborador pelo autor, 2018.

Com uma acurácia baixa, que não passava de 5%, não seria viável para nenhum investidor confiar no sistema. Então, foi necessário retornar à estrutura dos dados e estudar como seria possível melhorá-los.

Ao estudar e ao avaliar a Bovespa e o mundo do Mercado Financeiro mais profundamente, ficou claro que, para aumentar a acurácia, seria necessário dividir e estruturar os dados de cada empresa individualmente e, somente em tal situação, fazer uma previsão total de todos os dados previstos.

Outro problema encontrado foi saber quais empresas eram mais significantes para a previsão. Sendo assim, foi criado um gerador de gráficos inteligente que poderia demonstrar, em ordem, as empresas que tinham maiores investimentos, conforme apresentado no Gráfico 2.

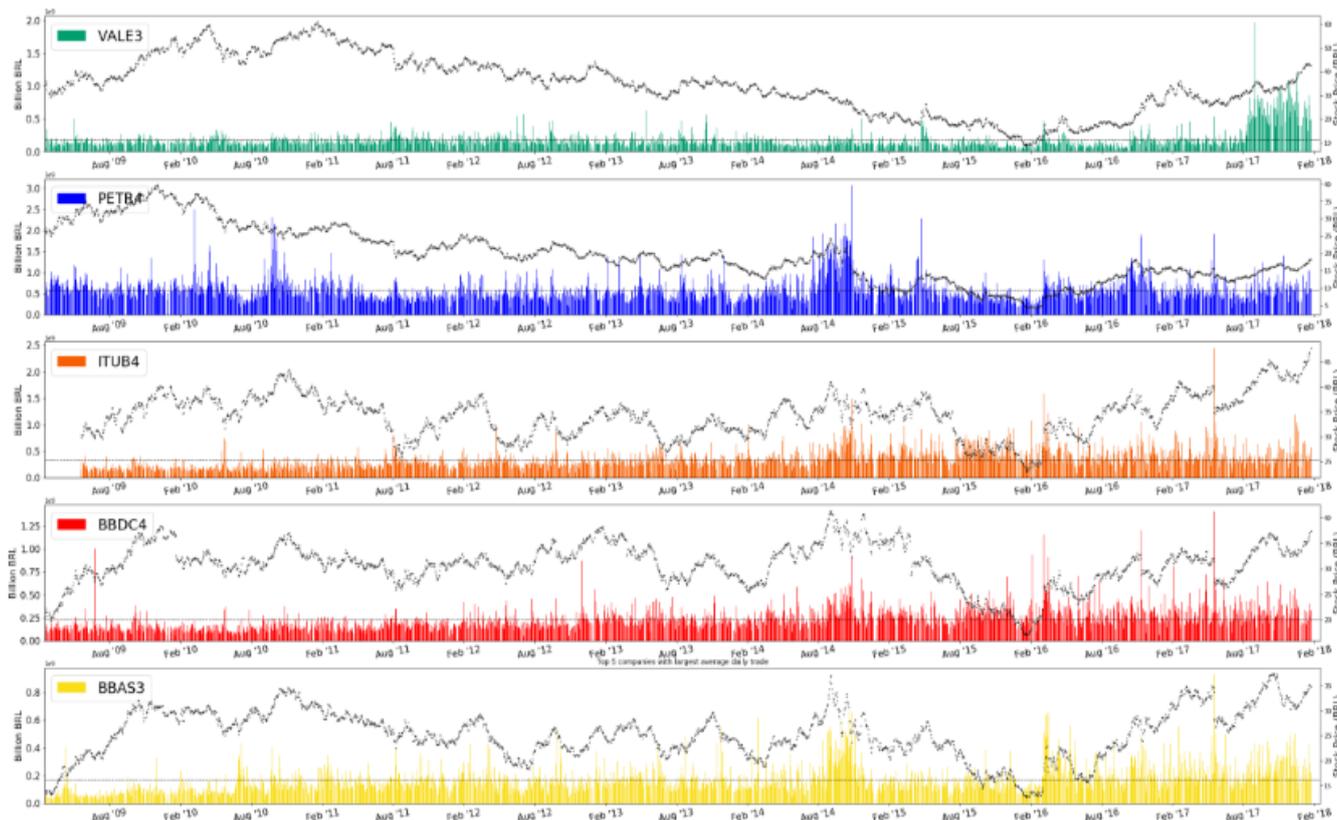
**Gráfico 2 – Trades**



Fonte: Elaborado pelo autor, 2018.

Por meio desse gerador de gráficos, os investimentos e as vendas de cada empresa podem ser demonstrados. Como exemplo, foram geradas análises apenas para as 5 primeiras empresas. Com base nesse gráfico, um gráfico importante no mundo dos investimentos, que é o gráfico de volume, foi gerado e pode ser observado no Gráfico 3.

**Gráfico 3 – Volume**



Fonte: Elaborado pelo autor, 2018.

Com esses gráficos, ficou claro que esse tipo de divisão seria fundamental para o crescimento da acurácia dos dados, mas também foi percebido que existiam empresas que tinham uma instabilidade muito grande, normalmente empresas com menos de um ano de criação, que atrapalhariam o sistema a encontrar um padrão para as previsões. Essas empresas específicas foram retiradas dos dados.

Agora, com os dados de cada empresa da Bovespa separados e estruturados para o treinamento, foram feitas as primeiras previsões usando o método de Rede Neural, e a avaliação de cada empresa foi feita individualmente. Na Figura 3, está representado o algoritmo utilizado para dividir e gerar a previsão dos dados.

**Figura 3 – Código de treinamento e previsão**

```

1 split_percentage = 0.8
2 split = int(split_percentage*len(Df))
3
4 X_train = X[:split]
5 y_train = y[:split]
6
7 X_test = X[split:]
8 y_test = y[split:]
9 cls = SVC().fit(X_train, y_train)
10
11 accuracy_train = accuracy_score(y_train, cls.predict(X_train))
12 accuracy_test = accuracy_score(y_test, cls.predict(X_test))
13
14 print('\nTrain Accuracy: {:.2f}%'.format(accuracy_train*100))
15 print('Test Accuracy: {:.2f}%'.format(accuracy_test*100))

```

Fonte: Elaborador pelo autor, 2018.

Na Figura 3, nas linhas 1 e 2 do código fonte, está definido o momento de divisão dos dados de teste, em porcentagem. Nas linhas 4 a 9, ocorre o treinamento do sistema, utilizando a biblioteca do *Sklearn*. Em seguida, nas linhas 11 e 12 é executado o código que realiza a previsão dos dados com o sistema já treinado. No final, nas linhas 14 e 15 o sistema demonstra seu nível de precisão. Esse processo possibilitou chegar a uma precisão viável e confiável para os investidores, conforme apresentado na Figura 4.

**Figura 4 – Resultados finais**

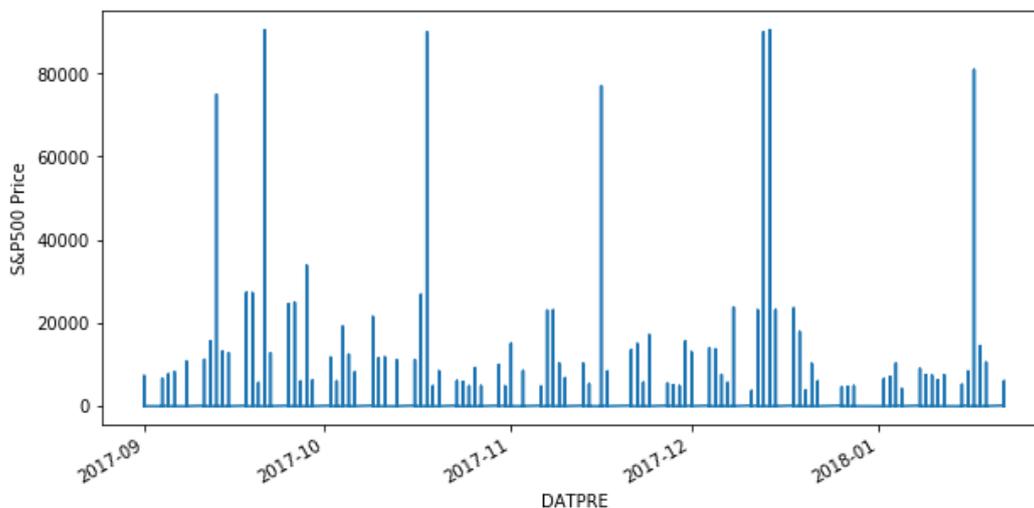
```

Train Accuracy: 53.82%
Test Accuracy: 54.21%

```

Fonte: Elaborador pelo autor, 2018.

Com uma acurácia com mais de 50%, o sistema pode aconselhar matematicamente se é viável ou não investir em cada empresa da Bovespa. Com o intuito de facilitar a interpretação dos dados, foi gerado um gráfico (Gráfico 4) mais simples para o investidor visualizar como serão os próximos dias, semanas ou meses de cada empresa.

**Gráfico 4 – Previsão**

**Fonte:** Elaborador pelo autor, 2018.

Com o estudo dos casos apresentados acima, foi notado que existe um dado contábil muito comum no mundo do Mercado Financeiro, chamado Índice Sharpe, que avalia taxa, juros e volume, por exemplo, por meio de uma fórmula, a qual pode ser visualizada e interpretada na Figura 4.

**Figura 4 – Formula Índice Sharpe**

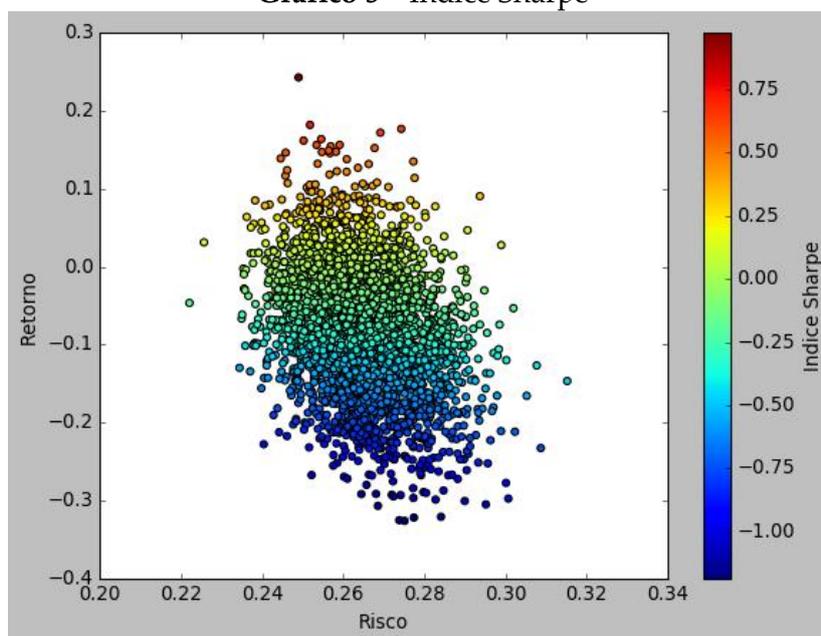
$$\text{Sharpe Ratio} = \frac{R_p - R_f}{\sigma_p}$$

**Sharpe Ratio** = Índice Sharpe  
**R<sub>p</sub>** = Rentabilidade do investimento que estamos avaliando  
**R<sub>f</sub>** = Rentabilidade do investimento livre de risco. Pode ser a taxa DI, taxa Selic ou outro índice que o fundo pretende superar.  
**σ<sub>p</sub>** = Índice de volatilidade do investimento que estamos avaliando.

**Fonte:** ÁVILA (2015)

Essa fórmula simples foi criada por William Sharpe em 1990 com o intuito de ajudar os investidores. William, pela criação da fórmula, ganhou o Prêmio Nobel de economia em 1990 (BLOOMFIELD, 2016). Com essa fórmula, é possível saber o custo benefício de se investir em uma empresa, pois demonstra o risco e o ganho que aquelas ações oferecem. Com os dados em sua nova estrutura, foi criado o gráfico desse índice (Gráfico 5).

Gráfico 5 – Índice Sharpe



Fonte: Elaborado pelo autor

Com esse gráfico e com as demais análises geradas pelo sistema, o investidor pode ser aconselhado com uma previsão confiável e provar contabilmente, por meio do Índice Sharpe, se aquele resultado da previsão é válido e, assim, passar uma maior confiança para o investidor investir na empresa da Bovespa que melhor lhe convier.

## 5 CONCLUSÃO

Com o desenvolvimento deste trabalho, conclui-se que o mundo do Mercado Financeiro, apesar de constituído por várias fórmulas, padrões e enorme volume de dados, é extremamente instável e existem variáveis do mundo externo que interferem diretamente nas empresas, causando uma instabilidade e um desnivelamento que interferem nas metodologias de *Machine Learning* para esses dados.

Ao finalizar este trabalho, foi possível concluir também que estruturar dados e estabelecer treinamentos utilizando técnicas de *Machine Learning* é trabalhoso e complexo. Como dito anteriormente, o próprio Mercado Financeiro por si já é instável, e criar algoritmos para esse tipo de contexto se torna um desafio a ser cumprido. Contudo, mesmo com essas dificuldades, foi possível chegar a quase 55% de precisão nos resultados das previsões, gerar índices e gráficos de volumes e de transações da Bovespa.

Mesmo com os dados bem divididos e a avaliação sendo feita individualmente, ainda falta muito a ser aprimorado. Para que esse sistema se torne cada vez mais forte e cada vez mais confiável, técnicas voltadas para o estudo das variáveis desse universo são fundamentais. Estudar a fundo os índices e os fatores relacionados à moda, à política e ao consumismo das massas se torna essencial.

Para concluir, percebe-se que atualmente vive-se em um mundo onde as pessoas têm grandes sonhos e pequenas realizações. As pessoas querem que as coisas aconteçam de forma muito rápida e não param para aprender e para andar em seu próprio ritmo. Pode-se viver de maneira mais inteligente e calma. Investir é um bom começo para as realizações desses seus sonhos, pois tudo o que se tem de decidir é o que fazer com o tempo que nos é dado (TOLKIEN, 1949). Contar com um sistema que auxilie na identificação de bons investimentos torna-se muito interessante.

## REFERÊNCIAS

- ALECRIM, Emerson. **Redes neurais artificiais**. 2004. Disponível em: <https://www.infowester.com/redesneurais.php>. Acesso em: 15 ago. 2018.
- ÁVILA, Leandro. **Como comparar fundos: índice Sharpe**. 2015. Disponível em: <https://www.clubedospoupadores.com/investimentos/indice-sharpe.html>. Acesso em: 15 ago. 2018.
- BAIA, Carlos. **Introdução ao machine learning**. 2016. Disponível em: <http://carlosbaia.com/2016/07/17/introducao-ao-machine-learning/>. Acesso em: 20 fev. 2018.
- BLOOMFIELD, Nathaniel. **William Sharpe ganhador do Prêmio Nobel de Economia de 1990**. 2016. Disponível em: <https://www.confiancaplanejamento.com/blog/27-william-sharpe-ganhador-do-premio-nobel-de-economia-de-1990>. Acesso em: 08 out. 2018.
- FULLER, Nial. **The myths of trading you must remove from your mind**. 2018. Disponível em: <http://www.learntotradethemarket.com/forex-articles/the-myths-of-trading>. Acesso em: 21 fev. 2018.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. 2016. Disponível em: <https://www.synapse.koreamed.org/Synapse/Data/PDFData/1088HIR/hir-22-351.pdf>. Acesso em: 24 fev. 2018.
- GUILHERME, Silveira; BENNET, Bullock. **Machine Learning: introdução à classificação**. 2017. Disponível em: <http://www.learntotradethemarket.com/forex-articles/the-myths-of-trading>. Acesso em: 21 fev. 2018.
- LLC Investopedia. **Breaking down data science**. 2018. Disponível em: <https://www.investopedia.com/terms/d/data-science.asp>. Acesso em: 20 fev. 2018.

MERCADO de ações. **Introdução ao mercado de ações**. 2012. Disponível em: <http://www.aprendaainvestirnabolsa.com/introducao-ao-mercado-de-acoas/>. Acesso em: 20 fev. 2018.

MONNAPPA, Avantika. **Data science vs. big data vs. data analytics**. 2018. Disponível em: <https://www.simplilearn.com/data-science-vs-big-data-vs-data-analytics-article>. Acesso em: 20 fev. 2018.

PANDAS-DOCS. **Pandas: powerful python data analysis toolkit**. 2018. Disponível em: <https://pandas.pydata.org/pandas-docs/stable/#pandas-powerful-python-data-analysis-toolkit>. Acesso em: 23 fev. 2018.

PYSCIENCE-BRASIL. **Python: o que é? por que usar?**. 2018. Disponível em: <http://pyscience-brasil.wikidot.com/python:python-oq-e-pq>. Acesso em: 23 fev. 2018.

SAMUEL, Arthur Lee. **Some studies in machine learning using the game of checkers**. 1959. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.368.2254&rep=rep1&type=pdf> Acesso em: 19 fev. 2018.

TOLKIEN, John Ronald. **The lord of the rings**. Disponível em: [http://www.liceotr.cl/biblioteca\\_digital/JRR%20Tolkien%20-%20The%20lord%20of%20the%20rings%20collection.pdf](http://www.liceotr.cl/biblioteca_digital/JRR%20Tolkien%20-%20The%20lord%20of%20the%20rings%20collection.pdf) . Acesso em: 21 nov. 2018.