

# UM PORTFÓLIO INTELIGENTE NO MERCADO ESPECULATIVO USANDO TÉCNICAS DE MACHINE LEARNING - AÇÕES e CRIPTO.

ANDRE MOTTA, Universidade Federal de Minas Gerais, Brasil

O surgimento das tecnologias baseadas em blockchain culminaram na criação de tokens (Criptomoedas) que são trocadas como ativos. Assim como ações esses tokens são trocados de maneira especulativa, e a movimentação do mercado gira em torno de 10 bilhões de dólares diários. Contudo o mercado de criptomoedas é um mercado bem jovem. E como demonstrado em trabalhos anteriores em [1], é um mercado ineficiente que possui certa persistência. Baseando-se nisso buscamos demonstrar a possibilidade do uso de técnicas de machine learning para previsão no mercado de criptomoedas em busca de criar um portfólio inteligente capaz de investir no mercado com um ganho razoável.

Palavras Chave: Machine Learning, Time Series Prediction, Time Series Clustering, Cryptocurrency, Stock Markets, Investing

## 1 INTRODUÇÃO

O mercado especulativo de ações, e mais recentemente de criptomoedas, há muito tempo se apresentam como uma opção de se “investir” e ganhar dinheiro a partir de análises de cunho técnico e fundamental sobre o passado histórico de uma opção de investimento. Seja investindo na Alphabet (GOOGL), seja mais recentemente trocando criptomoedas (BTCETH), esses especuladores utilizam-se de técnicas já consagradas no mercado ao analisar o histórico de sua opção para fazerem uma decisão seja de compra ou de venda. O objetivo de qualquer um desses especuladores é de alcançar retornos consistentes acima da média de mercado.

A Teoria da Eficiência de Mercado contudo demonstra por fim uma impossibilidade de se obter vantagem consistente no mercado, dado que ele seja eficiente. Como dito por Sewell em 2011 um mercado é dito eficiente em respeito à informação se o valor corrente do mercado refletir com precisão todas as informações a ele relevantes, sejam essas informações públicas e privadas. Essa teoria da Eficiência surge de maneira indireta pela primeira vez em 1564 quando Cardano disse que o princípio mais fundamental em qualquer aposta seriam condições igualitárias.

Dessa maneira, em um mercado dito eficiente, seria impossível para investidores alcançarem retornos consistentes em suas especulações. Assim, seria algum dos mercados citados ineficiente de alguma maneira. Ineficiente a ponto de possibilitar previsões, se essas previsões são de cunho técnico ou de cunho informacional.

Como visto em [1] o mercado de criptomoedas se comparado ao mercado de ações comuns possui certa ineficiência, o que o torna mais previsível e provavelmente mais suscetível ao uso de técnicas de machine learning para realizar previsões do comportamento do mercado como um todo.

Desta maneira buscamos desenvolver uma ferramenta capaz de investir no mercado de criptomoedas de maneira satisfatória.

---

Author's address: Andre Motta, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil, andre.motta@dcc.ufmg.br.

---

© 2019 Copyright held by the owner/author(s).

## 2 CONTEXTUALIZAÇÃO E TRABALHOS RELACIONADOS

Para este trabalho, nos baseamos em descobertas anteriores em [1] quanto à persistência de mercado e usamos técnicas de machine learning inspiradas nos trabalhos de [2] e [3] adaptando os modelos descritos em redes neurais recorrentes descritas em [4] para modelos feitos em redes neurais convolucionais unidimensionais [5].

Um conceito importante para a análise desenvolvida neste trabalho é o conceito de persistência de mercado. A persistência de mercado é a taxa que correlaciona a tendência do mercado observada e o preço futuro. Sendo esta tendência a derivada do mercado dado um período de tempo. A tendência pode ser de curto, médio ou longo prazo. Assim se um mercado possui persistência isso significa que o preço de um ativo pode ser previsto estudando os valores passados do mesmo. Obviamente dado os conceitos citados anteriormente de eficiência de mercado. A existência de persistência seria uma prova de ineficiência do mercado.

Em [1] ficou demonstrada a persistência de mercado prevista por CAPORALE em 2017 [6] e unido a isso um novo trabalho de CAPORALE em 2018 [7] demonstrou que a volatilidade do mercado de criptomoedas é muito alta. O que pode aumentar substancialmente as chances de ganhos se acertarmos a operação de compra ou venda.

## 3 DESENVOLVIMENTO DO TRABALHO

### 3.1 A Base de Dados

A coleta dos dados foi realizada usando-se um script em python para obter a maior quantidade possível de dados com a maior quantidade de granularidades disponíveis. No caso de Criptomoedas, coletamos da base de dados da Poloniex todos os pares ali disponíveis nos períodos de 300, 900, 1800, 7200, 14400, e 86400 segundos, ou seja 5 minutos, 15 minutos, meia hora, 2 horas, 4 horas e finalmente diário. Essas granularidades nos permitiram a coleta de 3.29GB de dados para 99 pares de criptomoedas.

No caso de valores de ações, infelizmente os datasets públicos tem a granularidade mínima de 1 dia. Assim embora tenha coletado até os últimos 18 anos de cada empresa e os registros de 7026 empresas a quantidade bruta de dados foi menor, 556MB de informação dentro desta granularidade.

Ainda assim o número total de entradas foi muito grande da ordem de milhões de entradas. Esta foi exatamente a mesma base de dados usada em [1] re coletada e atualizada para o momento atual. Além das features padrão que estão presentes no gráfico (preço de abertura, preço mais alto, preço mais baixo, preço de fechamento, volume) a cada intervalo de tempo, fizemos uso da biblioteca em python TA-Lib. Com ela fomos capazes de gerar mais de 100 features baseadas em diferentes indicadores econômicos. Expandindo ainda mais a nossa base de treinamento.

### 3.2 Os Modelos

Para realizarmos a previsão usamos quatro tipos de modelos preditivos em suas versões classificadoras e regressoras a depender do comportamento a ser previsto.

**3.2.1 Random Forest Model.** Definimos a Random Forest a partir do modelo padrão do SkLearn usando como métrica a área abaixo da curva (AUC/ROC) que avalia a razão de falsos positivos para verdadeiros positivos no caso de classificadores, e o erro médio quadrático (RMSE) no caso de regressores.

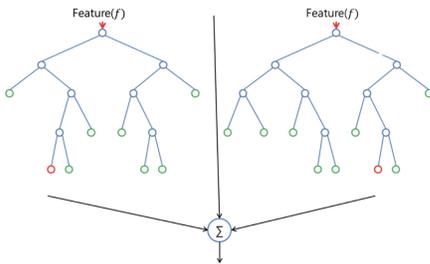


Fig. 1. Random Forest Model

A Random Forest recebe como mostrado na figura um intervalo de tempo como input gerando diversas árvores de decisão que serão avaliadas em conjunto para retornar uma saída a depender da resposta esperada.

**3.2.2 Neural Network Model.** O modelo de redes neurais padrão foi definido como uma rede completamente conectada com duas hidden layers, uma camada de input e uma de output.

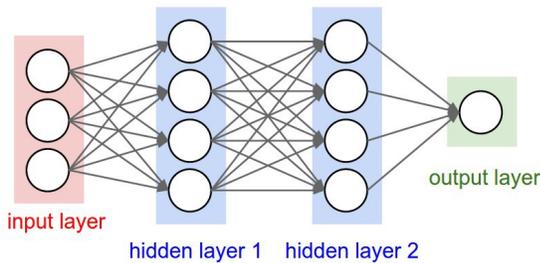


Fig. 2. Neural Network Model

Similar a Random Forest, este modelo recebe um intervalo de tempo e tenta ajustar os pesos relativos a cada aresta conectando dois vértices para que o output seja dentro do esperado. Esse ajuste é feito usando o algoritmo padrão de backpropagation

**3.2.3 Recurrent Neural Network Model.** O modelo escolhido de RNN( Recurrent Neural Network) foi de uma LSTM. A LSTM como definida em [4] é um modelo capaz de usar o contexto temporal e

carregar uma memória de longo prazo dentro da rede. Como podemos ver na figura a seguir, a LSTM possui um mecanismo de transferência de memória, possuindo dentro de si três perceptrons diferentes a cada nó. Um para decidir o que deve ser esquecido da rede anterior, um para decidir o que deve ser lembrado desta iteração e um para fazer a previsão propriamente dita.

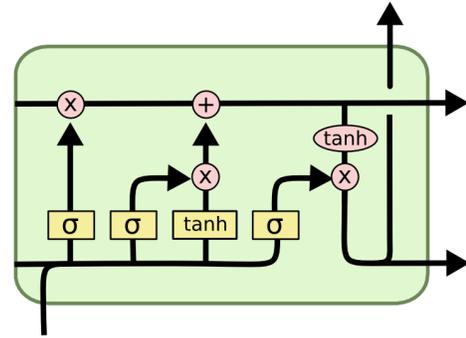


Fig. 3. LSTM

Uma rede neural comum não tem essa capacidade pois se analisarmos o algoritmo de backpropagation fica visível que o erro propaga muito fracamente para camadas muito profundas na rede devido aos passos de normalização que ocorrem em cada nó. Isso não acontece na arquitetura da LSTM.

**3.2.4 Convolutional Neural Network Model.** Por fim definimos um modelo de rede convolucional baseado em redes convolucionais unidimensionais. A ideia é de analisar intervalos fixos de tempo para realizar convoluções e fazer previsões baseando num contexto de tamanho fixado. Diferentemente das redes neurais recorrentes onde todo o contexto pode ser analisado para tirar uma conclusão.

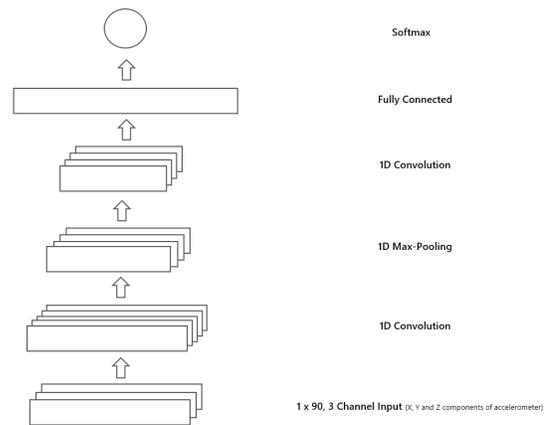


Fig. 4. 1D - CNN

Isso pode ser interessante porque comportamentos locais da rede podem ser mais valiosos para a previsão do que comportamentos globais devido à própria natureza do mercado especulativo

### 3.3 Os Comportamentos a serem Previstos

Para este trabalho desenvolvemos quatro comportamentos que gostaríamos de prever.

- (1) O Padrão Fractal de Comportamento  
Existe no Mercado um Padrão que pode denotar uma chance elevada de ganhos. Esse padrão pode ser considerado como um previsor de forte tendência de subida ou descida.
- (2) A Tendência de Preços  
Se o preço esta tendendo a subir ou descer no próximo intervalo de tempo. Lembrando que, devido às taxas de corretagem este valor não garante lucratividade
- (3) A Tendência de Preços Removidas as Taxas de Corretagem  
O mesmo comportamento acima mas garantindo a lucratividade
- (4) Variação Percentual do Valor entre Intervalos de Tempo  
Tentativa de prever com precisão o valor entre diferentes Intervalos de Tempo.

**3.3.1 O Padrão Fractal de Comportamento.** Para descobrir o Padrão Fractal de Comportamento usamos técnicas de minerações de dados. Mais especificamente usamos o KMeans para categorizar os tipos de curvas mais comuns ao gráfico baseado em variações percentuais. Ao realizar esta análise, ficou perceptível a existência de três grandes padrões no mercado, um deles de subida acima da taxa, um de movimentações dentro da taxa de corretagem e outro de quedas acima da taxa.

É importante observar que a previsão desse padrão Fractal de Comportamento é apenas um indicador forte de tendência, e a previsão real da tendência sem taxas de corretagem é feita posteriormente.

## 4 EXPERIMENTOS

Os experimentos a seguir foram realizados obtendo a média das taxas dos modelos aplicados a cada um dos 99 pares de criptomoedas e 6000 empresas diferentes. Dada a grande quantidade de modelos treinados mostraremos aqui apenas os resultados da LSTM por serem os mais interessantes do treino destes modelos. Uma vez que de todos os modelos o mais preciso foi a LSTM, que nos quatro cenários se demonstrou mais capaz de conseguir aprender os comportamentos e fazer boas previsões.

O Gap apresentado aqui entre as ações comuns e as criptomoedas foi similar dentre todos os modelos.

**4.0.1 Previsão de Fractais.** Para a previsão de fractais em ambos os ambientes obtivemos resultados bem similares.

Esses resultados demonstram não haver diferenças substanciais entre os dois mercados quanto a previsão deste indicador forte de tendência. Contudo isso não invalida nenhuma hipótese uma vez que o indicador não dá nenhuma certeza sobre a lucratividade da compra e venda.

**4.0.2 Previsão de Tendência.** Para a previsão de tendência simples, novamente, em ambos os ambientes obtivemos resultados bem similares.

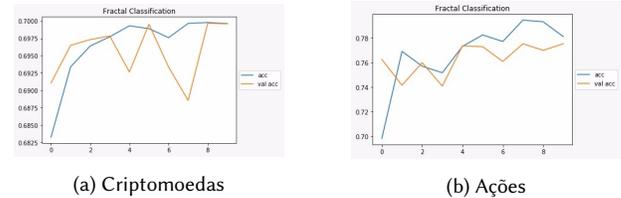


Fig. 5. Fractais

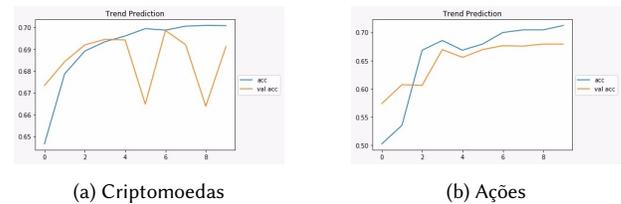


Fig. 6. Tendência

Novamente esses resultados não garantem lucratividade então as redes neurais aqui treinadas estão dentro do comportamento esperado.

**4.0.3 Previsão de Tendência Garantido o Lucro.** Finalmente, ao garantirmos a lucratividade, temos uma mudança drástica na resposta obtida do treinamento das redes neurais recorrentes.

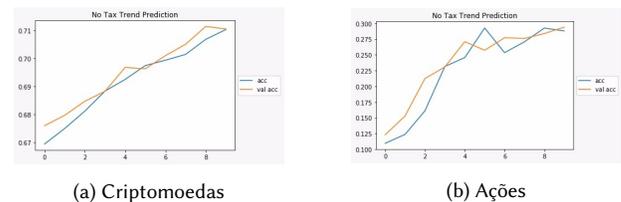


Fig. 7. Tendência Removidas as Taxas

Garantindo a lucratividade do modelo, vemos na figura 7 uma queda drástica na capacidade do modelo em ações comuns e uma manutenção do mesmo modelo em criptomoedas. O que aponta fortemente para a real existência da persistência prevista em [1] e [6].

É muito interessante notar que o modelo descrito aqui possui então a capacidade de prever com 70% de confiabilidade se vale a pena ou não investir no momento seguinte.

4.0.4 *Previsão do Percentual de Variação para o Próximo Candle.* Ao fazermos a previsão do percentual de variação buscávamos confirmar o estabelecido na Figura 7 de que existe uma diferença gritante entre os dois mercados quanto a capacidade preditiva de trocas lucrativas. Contudo, isso se demonstrou infrutífero pois o treino dos modelos para regressão da próxima variação percentual foi o seguinte.

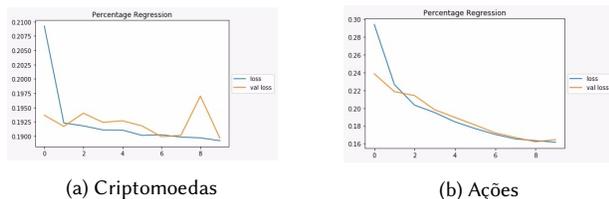


Fig. 8. Percentual de Variação para o Próximo Valor

Os valores de loss estavam muito similares, então decidimos por a prova este modelo regressor de percentuais.

Implementamos um simulador de investimentos capaz de acompanhar o preço das ações e do par de criptomoedas e aplicamos o modelo ao par BitCoin Litecoin e às ações da Apple. Esses foram escolhidos por serem os pares de melhor desempenho da rede.

O modelo iniciou com o equivalente a 1 BTC no caso do par e 10000 Dólares no caso das Ações da Apple.

Após dois meses de manutenção dos valores o modelo aplicado ao par de criptomoedas foi capaz de lucrar 9% e o modelo aplicado à Apple lucrou 1,2%. O lucro associado ao par de criptomoedas foi muito acima da maioria dos investimentos embora esteja associado a um risco elevado. E o lucro associado à Apple foi baixo demais dado o risco do tipo de investimento. O que nos leva a crer que o modelo regressor para as ações foram capazes de generalizar o dataset mas não foram capazes de generalizar o fenômeno. O que é o esperado dada a não persistência de mercado.

## 5 CONCLUSÃO

Com o trabalho fomos capazes de desenvolver um robô investidor capaz de gerar lucros substanciais a curto prazo em simulações de compra e venda. Também reafirmamos com este trabalho que sim, uma persistência existe no mercado de criptomoedas quando estamos tratando do elemento preço, e essa mesma persistência não se faz presente no mercado de ações. Reafirmando também uma grave ineficiência do mercado de criptomoedas.

Este robô será posto a prova na API da poloniex com dinheiro de verdade para analisar os resultados do mesmo em um ambiente real. Também é importante observar que modelos preditivos melhores e mais bem otimizados a cada mercado podem ser usados, uma vez que existem particularidades inerentes a cada par de criptomoedas e cada tipo de ação.

Um trabalho futuro será o desenvolvimento do portfólio inteligente como produto final para que pessoas possam investir automaticamente no mercado. Outro serão análises dos efeitos da inserção do robô no mercado de criptomoedas conhecido por ser muito sensível e volátil

## CONSPECTUS LIBRORUM

- [1] A. Motta (2018), "Uma Análise Comparativa do Mercado Especulativo de Criptomonedas e seus Indicadores," *Projeto Orientado a Computação I*, Belo Horizonte, MG, Brasil
- [2] Gers, Felix A. and Eck, Douglas and Schmidhuber, Jürgen (2002), "Applying LSTM to Time Series Predictable Through Time-Window Approaches," *Neural Nets WIRN Vietri-01*, London, UK, 2002, pp. 193-200 vol.1. isbn: 978-1-4471-0219-9
- [3] Cheng, Haibin and Tan, Pang-Ning and Gao, Jing and Scripps, Jerry (2006), "Multistep-Ahead Time Series Prediction," *Advances in Knowledge Discovery and Data Mining*, Berlin, Heidelberg, Germany, 2006, pp. 765-774 vol.2. isbn: 978-3-540-33207-7
- [4] Sepp Hochreiter, Jürgen Schmidhuber (1997), "Long short-term memory," *Neural Computation*, 1997, pp. 1735–1780. doi:10.1162/neco.1997.9.8.1735. PMID 9377276.
- [5] Yann LeCun, Patrick Haffner, Léon Bottou, and Yoshua Bengio (1999), "Object Recognition with Gradient-Based Learning," *In Shape, Contour and Grouping in Computer Vision*, Springer-Verlag, London, UK, 1999, pp. 1735–1780.
- [6] CAPORALE, Guglielmo Maria and Gil-Alana, Luis A. and Plastun, Oleksiy (2017), "Persistence in the Cryptocurrency Market," *DIW Berlin Discussion Paper* Berlin, Germany 2017 SSRN: <https://ssrn.com/abstract=3084023> or <http://dx.doi.org/10.2139/ssrn.3084023>
- [7] CAPORALE, Guglielmo Maria and Plastun, Oleksiy (2018), "Price Overreactions in the Cryptocurrency Market," *DIW Berlin Discussion Paper* Berlin, Germany 2017 SSRN: <https://ssrn.com/abstract=3113177> or <http://dx.doi.org/10.2139/ssrn.3113177>
- [8] ELBAHRAWY, Abeer and Alessandretti, Laura and Kandler, Anne and Pastor Satorras, Romualdo and Baronchelli, Andrea (2017), "Evolutionary Dynamics of the Cryptocurrency Market," 2017 SSRN: <https://ssrn.com/abstract=2969708> or <http://dx.doi.org/10.2139/ssrn.2969708>
- [9] KRAFFT, Peter, Nicolás Della Penna, Alex Pentland (2018), "An Experimental Study of Cryptocurrency Market Dynamics," *ACM CHI Conference on Human Factors in Computing Systems (CHI)* 2018
- [10] SEWELL, Martin (2011), "History of the efficient market hypothesis," *Research Note RN/11/04*, University College London, London.