Uso de GANs na Previsão do Mercado de Ações Brasileiro

Palavras-Chave: Inteligência Artificial, Generative Adversarial Networks, Previsão de Mercado de Ações

Autores/as:

Pedro Henrique Figueiredo Piovesan FEM-Unicamp

Prof. Dr. Ricardo Ribeiro Gudwin (orientador) FEEC-Unicamp

INTRODUÇÃO:

Uma GAN, ou rede adversarial gerativa, é uma rede neural capaz de aprender, seguindo a apresentação de exemplos que mantenham certa uniformidade, a gerar padrões distintos dos exemplos que foram utilizados, mas mantendo as uniformidades e regularidades encontradas. Goodfellow et al. (2014) apresentam um exemplo do uso de uma GAN para gerar imagens foto-realistas, na prática, indistinguíveis de fotos reais, depois de um treinamento onde um número muito grande de fotos é apresentado e utilizado para treinar a rede. Uma GAN é composta, por duas redes acopladas uma à outra, fazendo uma o papel de um Gerador de padrões e a outra um Discriminador de padrões. A primeira (Gerador) tem como objetivo (idealmente) gerar uma imagem nova, a partir de uma entrada aleatória (ruído branco), que possa ser confundida como pertencente ao banco de imagens utilizado no treinamento. As imagens geradas, são então direcionadas, junto com as imagens reais do banco de dados, para o Discriminador, que tem como objetivo tentar diferenciar se a imagem recebida é uma imagem do banco de dados ou foi gerada artificialmente pelo gerador.

Dessa ideia, Zhang et al. (2019) abstrairam o fato de que a entrada é uma imagem fotográfica, e decidiram utilizar uma GAN para fazer predições para o mercado financeiro, trocando o que seria uma imagem pelo valor do dia seguinte da cotação de uma ação. Isso mostrou resultados promissores para o auxílio de agentes financeiros. Importante notar que esse insight veio com uma pequena alteração no processo de treinamento da GAN. Em vez de um ruído branco ser a entrada do gerador, os valores dos ativos da S&P 500, NASDAQ, entre outras bolsas fizeram esse papel. Essa mudança trouxe a possibilidade de se analisar séries temporais e criar relações entre as informações de entrada e saída do Gerador, o que se torna essencial para a análise do mercado financeiro.

Neste trabalho, nosso intuito foi tentar reproduzir os resultados de Zhang et al (2019) adaptando-o para o Bovespa (a bolsa de valores brasileira), modificando algumas de suas características com o objetivo de poder prover um indicativo de direção das flutuações que a bolsa naturalmente tem, auxiliando assim os traders nos seus investimentos.

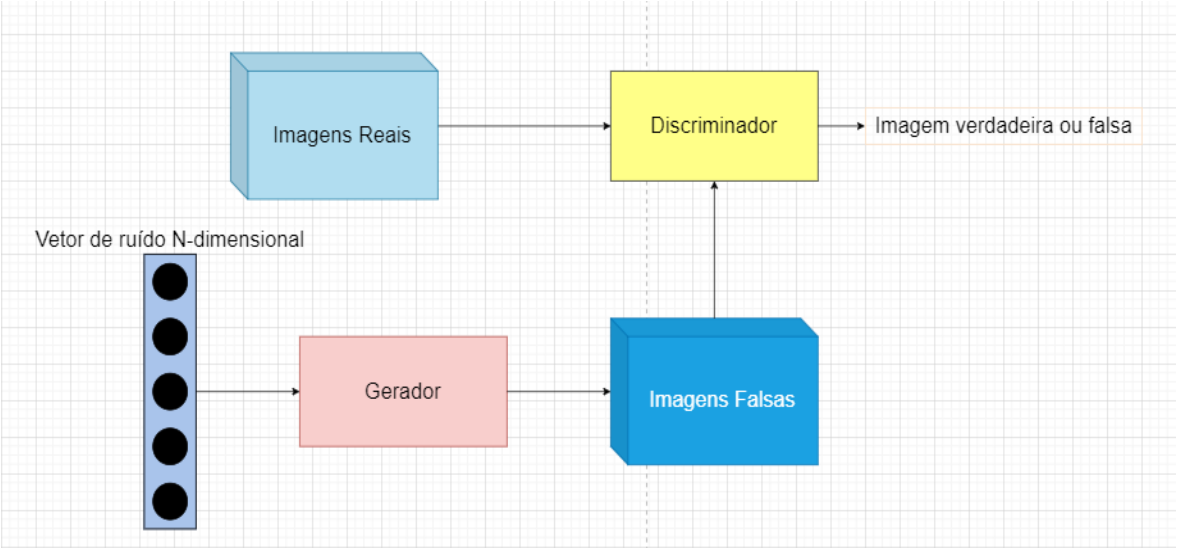

Figura 1: Esquema de treinamento de uma GAN

Todas as bolsas de valores possuem sua peculiaridade, seja na volatilidade dos ativos, seja em regras criadas para garantir estabilidade de valores, o que influencia em como as ações variam ao decorrer do tempo. A Bovespa não é diferente nesse aspecto e apresenta comportamentos diferentes das outras bolsas. Dessa forma, o uso de uma GAN adaptada ao Bovespa poderia ser uma importante fonte de recomendações de investimento, adaptada às peculiaridades da bolsa brasileira.

METODOLOGIA:

Podemos ver esquematicamente o funcionamento da rede na figura 1, onde temos um Gerador que recebe ruido e nos devolve imagens Falsas e um Discriminador que recebe as imagens verdadeiras e falsas e as classifica.

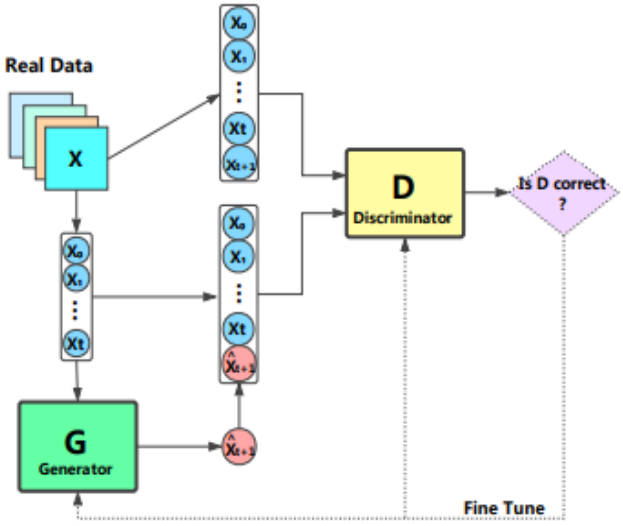

*Figura 2: Treinamento da GAN para o mercado de ações (adaptado de:**Zhang et al. 2019**[2])*

As GANs funcionam por meio de uma disputa entre o Gerador e o Discriminador, onde o desempenho de cada um vai influenciar no quanto o outro deve melhorar. Se o Gerador criar imagens mais “fidedignas” vair existir uma pressão na pontuação do Discriminador para que ele melhore sua classificação. O inverso também ocorre. Se o discriminador diferenciar com facilidade as imagens geradas, o Gerador vai precisar gerar imagens cada vez mais próximas da realidade para aumentar sua pontuação, nesse processo tanto o Discriminador quanto o Gerador evoluem em paralelo.

Para estender esse conceito ao mercado de ações, em vez de criar imagens “falsas”, o gerador tem como objetivo criar um conjunto de valores que simboliza o próximo dia de uma sequência temporal. Para isso, é necessario adaptar a entrada do Gerador com uma série temporal de valores reais, ao invés do ruido aleatorio como mostrado na figura 2. Esses valores são: valor de abertura, valor de fechamento, máximo do dia, mínimo do dia, volume de dinheiro e média de fechamento dos últimos 5 dias. Como entrada, os valores aleatórios são substituídos pelos valores reais.

Como Gerador, utilizamos uma rede neural do tipo Long Short-term Memory (LSTM), para processar a série temporal de entrada. O LSTM tem a capacidade de não perder a importância das informações mais antigas com facilidade, como ocorre em uma rede neural recursiva (Recursive Neural Network - RNN) comum, que a cada valor da série que passa os valores mais antigos ficam com influência cada vez menor. A escolha de arquitetura para o Gerador foi uma camada de LSTM seguida por 1 camada totalmente conectada.

Como Discriminador, foi escolhida uma MultiLayer Perceptron (MLP). A MLP é uma sequência de 3 ou mais camadas totalmente interconectadas, tendo sido escolhida pois atua muito bem em problemas de classificação binária (Escolha entre 2 classes somente, nesse caso Real ou Falso). A arquitetura para o Discriminador foi de 3 camadas totalmente conectadas.

O treinamento adversarial ocorre de acordo com a figura 2. São passados para o Gerador os valores correspondentes à série temporal de 5 dias e ele retorna uma estimativa do sexto dia. Para o Discriminador, são passados, ou os valores encontrados pelo Gerador, ou os valores reais da bolsa (de modo aleatório), para que este nos classifique a entrada como real ou falso.

RESULTADOS PRELIMINARES E DISCUSSÃO:

Os dados do Bovespa foram obtidos utilizando-se a API Java YahooFinance[1]. A partir dessa API, podemos obter os dados históricos de diferentes empresas, que foram utilizados para o treinamento de nossa GAN. A GAN foi implementada utilizando-se a biblioteca DeepLearning4J[2]

Para realizar o treinamento, conforme ilustrado nas figuras 3 e 4, alimentamos o Gerador com informações reais, a partir dos dados históricos, e obtivemos a predição (idealmente) do dia seguinte, concatenamos esse valor a serie temporal que o Gerador foi alimentado e assim temos metade do DataSet necessario para treinar o Discriminador, a parte faltante vem da própria bolsa, com a mesma serie temporal concatenada com o valor que, de fato, veio da bolsa de valores. Com o treino do Discriminador feito, temos que treinar o Gerador, com a mesma serie temporal que o alimentamos para treinar o Discriminador, agora a saida é comparada com o valor real da Bovespa e é feito o backpropagation dos valores.

[1]https://financequotes-api.com/
[2]https://deeplearning4j.konduit.ai/

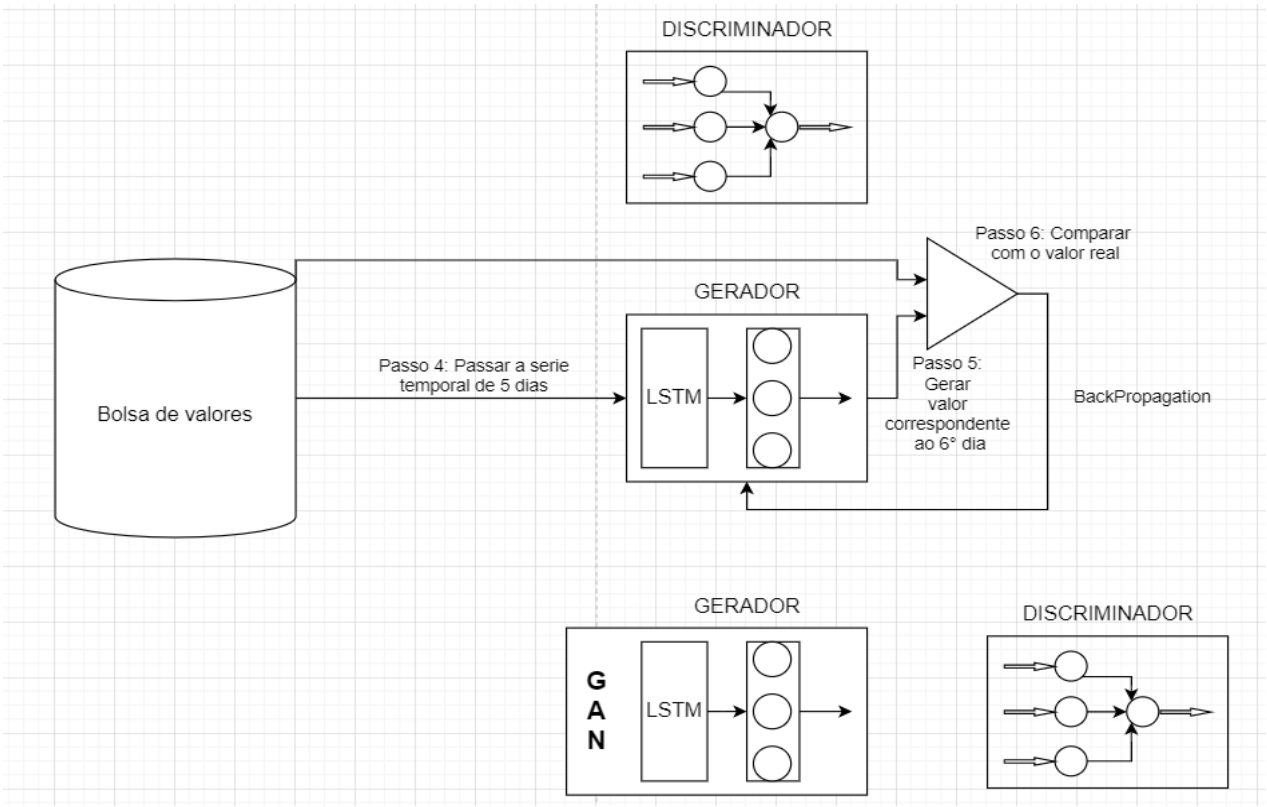

Figura 3: Treinamento do Gerador

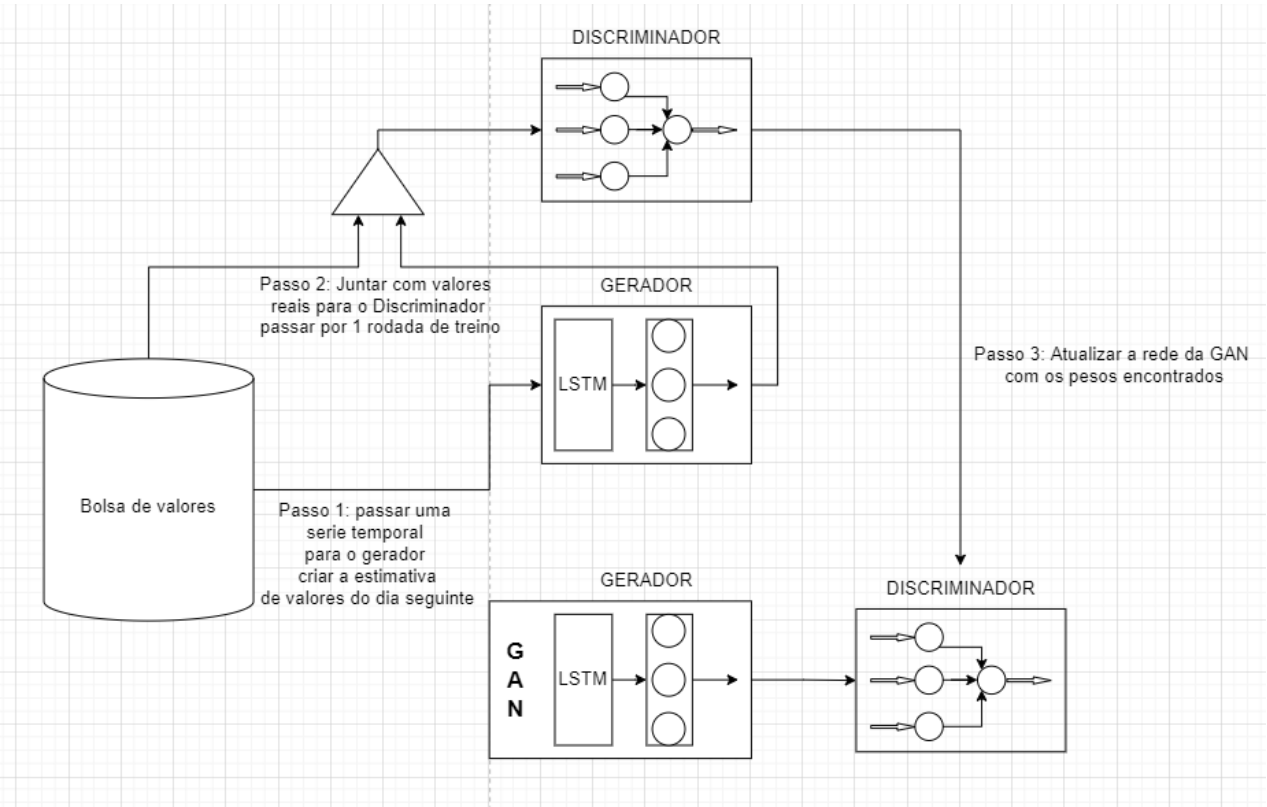

Figura 4: Treinamento do Discriminador

Feito o treinamento, podemos perceber a diferença de variação no Score de cada uma das redes, conforme mostram as figuras 5 e 6. O Gerador obteve scores muito bons chegando a um

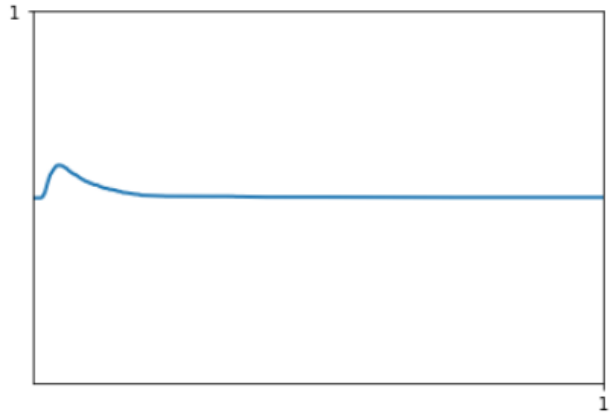

Figura 5: Erro do Discriminador

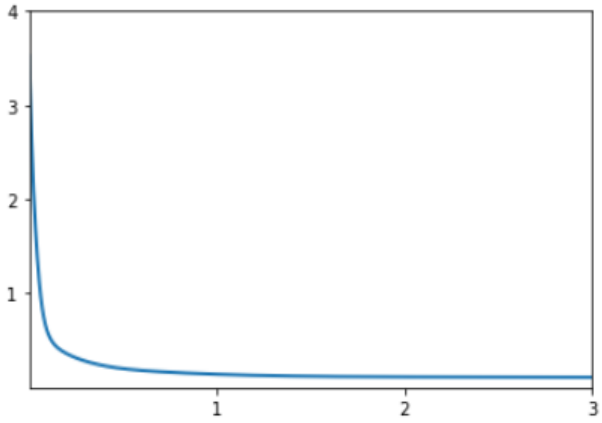

Figura 6: Erro do Gerador

erro absoluto de 0.04, enquanto o Discriminador, no inicio teve uma pequena flutução, porém, assim que o Gerador começou a refinar a qualidade das informações criadas, este não conseguiu mais classificar corretamente as informações que recebia, visto seu score de aproximadamente 0.5. Isso significa que após o treinamento, o discriminador não é mais capaz de diferenciar entre um padrão gerado pela rede geradora ou um padrão real.

CONCLUSÕES:

Os resultados obtidos estão compatíveis com o esperado para uma GAN. Entretanto, a grande questão aqui é como o funcionamento da atual GAN poderia ser generalizado para dados futuros, de tal forma que a mesma possa ser utilizada como predição para novos comportamentos futuros da bolsa, de tal forma que a mesma possa ser utilizada na recomendação de investimentos.

Assim, novos experimentos precisarão ser realizados, de forma a segmentar os dados dentre dados de treinamento e dados de teste, de tal forma a validar a capacidade preditiva do gerador para dados não utilizados no treinamento. Pretendemos realizar estes experimentos, na sequência deste trabalho.

BIBLIOGRAFIA

(Goodfellow et al. 2014) Goodfellow, I. et al. “Generative adversarial nets”. In: Advances in neural information processing systems 27 (2014) (cit. on pp. 3, 9)

(Zhang et al. 2019) Zhang, K., Zhong, G., Dong, J., Wang, S., and Wang, Y. “Stock market prediction based on generative adversarial network”. In: Procedia computer science 147 (2019), pp. 400–406 (cit. on pp. 3, 12)