

REDES NEURAIIS RECORRENTES APLICADAS NA PREDIÇÃO DE BOLSA DE VALORES

Matheus Pereira Gondim¹
July Gomes Evangelista Reis¹

Tarnie Vilela Nunes Narques¹
Florisvaldo Cardozo Bomfim Jr¹

¹Universidade de Uberaba - UNIUBE

matheus-pg1@hotmail.com, florisvaldo.bomfim@uniube.br

Resumo

O artigo, vem a demonstrar a aplicação de redes neurais artificiais recorrentes na predição do comportamento de bolsas de valores para tomada de decisão, a mesma demonstrou uma grande robustez por determinar a tendência do comportamento da ação escolhida.

Palavras-chave: Inteligência Artificial, Bolsa de Valores, Redes Neurais.

1 Introdução

A bolsa de valores é um ambiente para a negociação de títulos de empresas, compra e a venda de ações entre investidores ou possíveis investidores. Podendo essas empresas serem de capital público, misto ou privado. Esse processo é executado com auxílio de correspondentes de negociações através de corretoras, configurando assim, um ambiente seguro e organizado, efetuando transações rápidas e de maneira práticas, garantindo que as duas o bem-estar das duas partes.

E é neste ambiente onde empresas decidem abrir seu capital para investimento, disponibilizando as ditas ações, representações de pequenas

fatias da empresa, ou seja parte do capital social. A venda dessas ações é basicamente os novos investimentos da empresa, os compradores viram “sócios”, sendo de menor ou maior grau, pode ter direito a dividendos, dependendo da ação adquirida ou da quantidade, colendo assim lucros de ações quando valorizadas ou perdendo dinheiro em casos de depreciação.

Contudo, não e somente um bom balanço patrimonial que indica a valorização ou depreciação das ações, e todo um conjunto de por menores envolvendo desde politica a uma futura negociação da empresa. Por isso investir na bolsa, demanda estudo, tempo dedicação e cautela. Esse e o grande erro de novos investidores, a falta de preparo juntamente com a pressa para enriquecer da noite para o dia, aplicando altas quantias logo de início, porque ouviu de um amigo investidor que uma certa ação estava em alta ou leu em um jornal. Tornando assim seus investimentos em uma loteria, podendo perder milhões em uma única tacaada.

Mesmo com todos os riscos possíveis, a Ibovespa, um dos principais indicadores do desempenho das cotações das ações negociadas na B3, indicou um aumento de 45 mil novos investidores só no mês de janeiro deste ano, chegando a uma

marca inédita de 858 mil investidores pessoas físicas. Com crescente de novos investidores, veio a ideia deste projeto, usando o conhecimento de um RNN¹, para criar um sistema para auxiliar investidores mais inexperientes ou até mesmo pessoas com anos dentro do mercado.

A plataforma escolhida para o desenvolvimento do algoritmo foi o Scilab®² que uma linguagem de alto nível para resolução de problemas numéricos.

2 Materiais e métodos

Neste tópico será apresentado as estruturas e métodos usados no desenvolvimento do algoritmo.

2.1 Redes Neurais

As redes neurais artificiais é um algoritmo com a capacidade de processar informações e, a partir delas, cumprir tarefas cognitivas como perceber, aprender, melhorar seu desempenho, classificar, tomar decisões e agir de acordo com as condições externas.

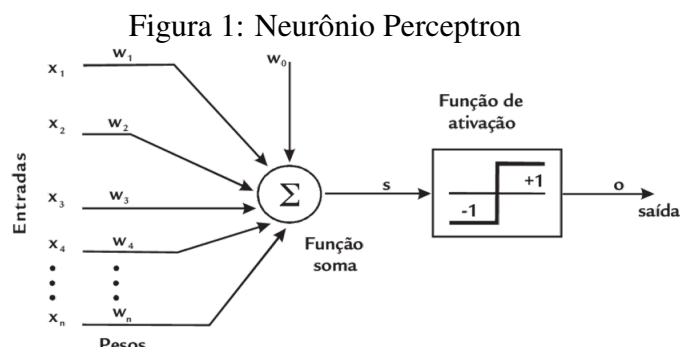
Haykin (1999, p. 59) descreve que uma IA³ deve ser capaz de armazenar conhecimento, aplicar o conhecimento armazenado para resolver problemas, e adquirir novo conhecimento através da experiência.

Existem vários tipos de IAs que se diferenciam pela suas formas de processar e classificar informações. A Rede Neural Artificial, que será utilizada neste projeto, baseia-se no funcionamento do cérebro biológico. Formado por cadeias de neurônios artificiais, elas se adaptam conforme o ambiente, sendo capazes de generalizar e organizar os dados obtidos na aprendizagem de acordo com padrões detectados.

¹Recurrent Neural Network/Redes neurais recorrentes.

²Software de simulação matemática.

³Inteligência Artificial



A figura 1 representa um neurônio artificial do modelo MCP⁴, proposto por McCullock e Pitts em 1943. De acordo com o modelo, os vetores x_n são as entradas do neurônio, estas obtidas a partir dos dados externos de uma certa aplicação. Cada vetor possui um peso sináptico w que mede a relevância de tal entrada na saída do neurônio. Com os valores de $x(n)$ e $w(n)$ definidos, é feita a soma ponderada das entradas, sendo esta a saída linear u .

2.1.1 Função de ativação

Conforme Silva(2010), a função de ativação é o limiar de saída neural, temos dois tipos de função de ativação sendo:

- função de ativação parcialmente diferenciais - São funções que possuem pontos os quais a derivada de primeira ordem não existe.
- função de ativação totalmente diferenciais - São funções as quais a derivada de primeira ordem existem em toda sua extensão.

A função de ativação logística é apresentada na equação 1 e sua derivada representada por meio da equação 2.

$$\Phi(\text{net}) = \frac{1}{1 + e^{-\text{net}}} \quad (1)$$

⁴McCullock e Pitts

$$\frac{\delta\Phi(net)}{\delta net} = \Phi(net) \cdot (1 - \Phi(net)) \quad (2)$$

2.2 Função de avaliação

O erro quadrático médio para testar a aproximação da saída da rede neural com seu *target*, sendo uma das mais usadas e é representada pela equação n.

$$EQM = \frac{\sum_1^n (target_n - \Phi_n)^2}{n} \quad (3)$$

2.3 Número de neurônios na camada escondida

Heaton 2008, afirma que em aplicações prática, modelos PMC⁵ não precisam possuir mais de duas camadas ocultas, para apresentar um bom desempenho, propondo as seguintes regras para determinação do número de neurônios em uma camada oculta:

- Modelo 1 : O número de neurônios em uma camada oculta deve estar entre o tamanho da entrada e o tamanho da saída. A média entre a entrada e a saída é uma boa medida;
- Modelo 2 : O número de neurônios deve ser 2/3 da entrada mais a saída;
- Modelo 3 : O número de neurônios deve ser menor que o dobro da entrada;

Silva e Oliveira 2004, apresentam também que a quantidade adotada de neurônios na camada escondida, corresponde ao valor da quantidade de amostras usadas no treinamento dividida por dez.

⁵Perceptron Multi Camada.

3 Resultados

Contudo a rede neural recorrente, usada nesse projeto, tem como estrutura, no mínimo 3 camadas, onde a camada intermediária ou camada escondida se retrô alimenta com seus próprios resultados, parando o treinamento quando:

- Completar o número de 3000 ciclos;
- Detectar um *overfitting*;
- Atingir o erro quadrático médio desejado.

Para realizar a aprendizagem da rede neural, optou-se em efetuar três modelos, quanto a quantidade de neurônio na camada escondida, para que possamos determinar a melhor quantidade.

No treinamento foi utilizado 90% dos dados deixando 10% para a validação, conforme a literatura.

Configuração adotada:

- Função de Ativação : Logística;
- Bias : -1;
- Dados de entrada (PTR4⁶) : Preço Máximo, Preço Mínimo, Preço de Abertura, Preço de Fechamento e Dia da Semana;
- Target : Preço de Fechamento;
- RNA do tipo recorrente.

3.0.1 Primeiro modelo

Para a simulação foi adotado quatro neurônios na camada escondida, pois representa a média da camada de entrada, o treinamento foi interrompido por *overfitting*⁷ apresentado na figura 2,

⁶PETR4 é apenas um código de um tipo de ações da Petrobras

⁷É um termo usado para descrever que um modelo foi muito bem ajustado, aos dados anteriores, mas se mostra ineficaz para prever novos resultados.

com um erro quadrático médio de 0.0268807 em 190 ciclos.

Figura 2: Resultado com 4 neurônios




Figura 3: Resultado com 5 neurônios


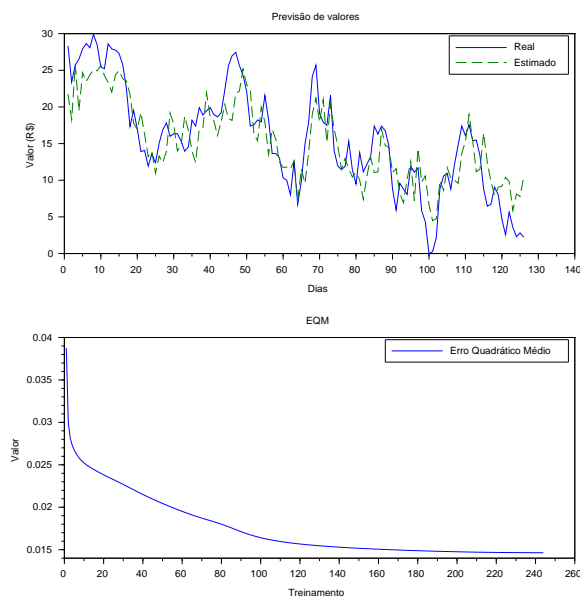


Figura 4: Resultado com 10 neurônios



3.0.2 Segundo Modelo

Para a simulação foi adotado cinco neurônios na camada escondida, por ser o valor resultante de $2/3$ de neurônios da camada de entrada mais a camada de saída, o treinamento foi interrompido por número de ciclos, apresentado na figura 3, com um erro quadrático médio de 0.0168146.

3.0.3 Terceiro Modelo

Para a simulação foi adotado dez neurônios na camada escondida, por ser dez vezes menor que a quantidade de amostra, o treinamento foi interrompido por número de ciclos apresentado na figura 3, com um erro quadrático médio de 0.0146422.

4 Discussão

Os resultados encontrados no presente método sugeriram que, deve se buscar melhorias no método de recursão, aumentando assim o número de

saídas, ou a alteração da estrutura da rede neural. Sendo assim é possível afirmar que existe a probabilidade da otimização do processo de predição.

5 Conclusão

Por meio dos resultados encontrados, podemos comprovar que o uso das redes neurais recorrentes para a predição dos valores de fechamento, atingiu seu objetivo, encontrando um padrão muito semelhante ao real, demonstrado que a rede neural pode ser usada como ferramenta de tomada de decisão sobre a compra e venda de ações.

Referências

- [1] BARONE, Dante Augusto Couto: "Sociedades Artificiais: a nova fronteira da inteligência nas máquinas", (2003), Porto Alegre: Bookman
- [2] HAYKIN, Simon. Redes neurais: princípios e prática. trad. Paulo Martins Engel. - 2.ed. - Porto Alegre: Bookman, 2001.
- [3] COSTA, Newton Carneiro Affonso da et al. Lógica paraconsistente aplicada. São Paulo: Atlas, 1999. ABE, Jair Minoro et al. Lógica Paraconsistente Anotada Evidencial Et. Santos: Comunicar, v. 1, 2011, 99 p. Hebb, D.O.. Brain Mechanisms and Learning. London: J. F. Delafresnaye (Ed.), 1961.
- [4] Braga, Antônio de Pádua; Carvalho, André P. L. Ferreira; Ludermir, Teresa Bernarda, "Redes Neurais Artificiais: Teoria e Aplicações"(2000), Rio de Janeiro: LTC. WASSERMAN, Philip D. Neural Computing : Theory and Practice. New York : Van Nostrand Reinhold, 1989.
- [5] REZENDE, Solange Oliveira. Sistemas Inteligentes:fundamentos e aplicações, 2003, Barueri,SP:Manole ZSOLT L KOVACS, REDES NEURAIAS ARTIFICIAIS: FUNDAMENTOS E APLICAÇOES(Ed.4), 2006.
- [6] SILVA, IN da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes neurais artificiais para engenharia e ciências aplicadas. São Paulo: Artliber, v. 23, n. 5, p. 33-111, 2010.
- [7] Jeff Heaton. Introduction to neural networks with Java. Heaton Research, Inc., 2008. 28
- [8] SILVA, P. C., MASCHIO, C. e SCHIOZER, D. J., Use of Neuro-Simulation Techniques as Proxies to Reservoir Simulation: Application in Production History Matching. Science Direct, Journal of Petroleum Science and Engineering 57, p.273-280, 2006.
- [9] SILVA, E. e OLIVEIRA, A. C., Dicas para a Configuração de Redes Neurais. Universidade Federal do Rio de Janeiro - NCE, 2004.