

Redes Neurais na Previsão de Tipos e Variações de *Candles* em Séries Temporais de *Candlesticks*

Murillo G. Carneiro, Fábio J. Sabai

Faculdade de Computação – Programa de Pós-Graduação em Ciência da Computação –
Universidade Federal de Uberlândia (UFU)

Laboratório de Inteligência Artificial – 38400-902 – Uberlândia, MG – Brasil

carneiro.murillo@gmail.com, fjsabai@uol.com.br

Abstract. *The prediction of future events through time series is a desire from several areas. This work presents two models of time series forecasting of candlesticks using artificial neural networks. The first model is based on the prediction of the next type of candle by the presentation of these series and the second seeks to predict the variation of the next candle. Our goal is to investigate patterns of variation in financial asset prices in an attempt to predict the next movements and also start construction of a model able to predict the next types of candles for these assets.*

Resumo. *A previsão de acontecimentos futuros através de séries temporais é um desejo de diversas áreas. Neste trabalho apresentamos dois modelos de previsão de séries temporais de candlesticks utilizando redes neurais artificiais. O primeiro modelo é baseado na previsão do próximo tipo de candle mediante a apresentação de séries temporais destes e o segundo busca prever a variação do candle seguinte. O nosso objetivo é pesquisar padrões de variação em preços de ativos financeiros na tentativa de prever os próximos movimentos e também iniciar a construção de um modelo capaz de prever os próximos tipos de candles para esses ativos.*

1. Introdução

Prever o futuro é um desejo de muitas áreas de pesquisa. Os meteorologistas estudam para antecipar à comunidade as próximas condições do tempo. Engenheiros procuram respostas acerca do comportamento futuro dos sistemas dinâmicos. Economistas pesquisam como será o próximo instante do mercado de ações e taxas de câmbio. Enfim, diante destes e muitos outros exemplos percebe-se que se antecipar ao que está por vir constitui o objetivo de muitos estudos, empresas e, considerando a sociedade de modo geral, é uma cobiça de grande parte das pessoas.

Certamente a possibilidade de construir previsões não é uma preocupação de agora e é certo também que vários modelos estatísticos já foram desenvolvidos para esse fim. Em seu trabalho, Jain (2007) lista uma série de características para considerar um bom modelo de previsão e destaca ainda uma pesquisa que realizou com dez empresas a fim de estimar o modelo estatístico mais utilizado para previsão. Abaixo são listadas algumas dessas características e logo em seguida é apresentada a figura 1 que demonstra o resultado obtido pela pesquisa:

- ✓ Não é necessário acerto de 100%. A decisão do melhor modelo não aponta para uma previsão perfeita;
- ✓ Modelos sofisticados não são necessariamente melhores. Frequentemente, os modelos mais simples trabalham bem;
- ✓ Não existe modelo mágico, isto é, nenhum modelo é perfeitamente adequado a todos os dados;
- ✓ Previsões estatísticas nada mais são que a linha base das previsões, não sendo somente ciência e nem somente arte, mas a combinação de ambas. Portanto é necessária uma análise de todos os fatores envolvidos;

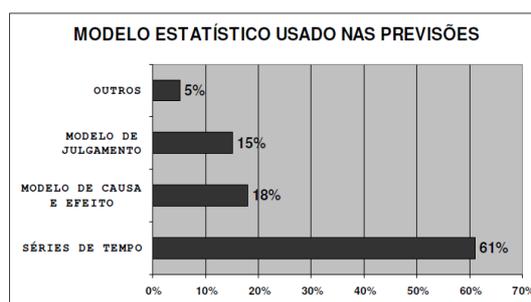


Figura 1. Modelos estatísticos mais usados em previsões.

Em Castro (2001) entende-se que desde o início do século XX são conhecidos métodos matemáticos empregados para a previsão de séries temporais. Sabe-se também que tais métodos usam algoritmos matemáticos para determinar as tendências do passado a fim de definir as projeções e tendências do futuro. Além disso, suas maiores vantagens são o baixo custo, a facilidade de aplicação e a rapidez na qual podem ser adotados.

É importante esclarecer que se os valores futuros de uma série temporal são determinados exatamente por alguma função matemática, esta série é denominada “determinística”, caso contrário, se os valores futuros podem ser descritos apenas em termos de uma distribuição de probabilidade, a série temporal é chamada “não determinística” ou simplesmente série temporal “estocástica”.

É óbvio que o grau de acurácia das séries temporais é muito maior em séries determinísticas do que nas estocásticas. Contudo o estudo dessas últimas tem sido o maior desafio para os pesquisadores afinal como lidar com o comportamento completamente instável do mercado de ações ou mesmo do clima em algumas regiões do mundo.

Este artigo apresenta a construção de dois modelos de redes neurais artificiais (RNA) com os objetivos de, mediante a análise de uma série temporal de *candlesticks* para um ativo qualquer, determinar o próximo tipo de *candle* desse ativo (modelo CWType) e sua variação aproximada (modelo CWVariation), ou seja, considerando-se uma série contendo os últimos $t-1$ tipos de *candles* pretende-se descobrir o tipo de *candle* e a sua variação aproximada para t , onde t refere-se ao próximo instante de tempo.

Candlestick, ou apenas *candle*, é o nome de uma técnica japonesa de análise gráfica de mercado. Para se criar o *candlestick* usa-se o preço de abertura, de fechamento, o máximo e o mínimo do ativo em um determinado período. Os períodos

mais utilizados são os de 1 minuto, 15 minutos e diário. O corpo do *candlestick* é representado por uma barra cuja altura é dada pela diferença entre o preço de fechamento e abertura, enquanto a linha acima e abaixo correspondem ao preço máximo e mínimo respectivamente. A figura 2 apresenta dois *candles*, o da esquerda indicando valor do fechamento menor que da abertura e o outro indicando valor de fechamento maior que da abertura.

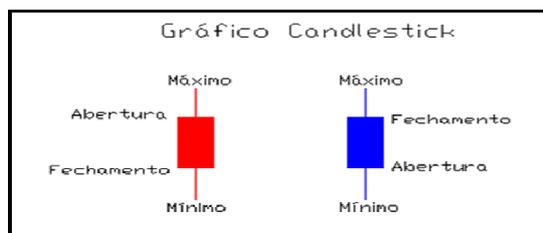


Figura 2. Exemplos de *candlesticks*.

O uso de RNA para análise de séries temporais não é novo. Na próxima seção são descritos vários trabalhos relacionados. Contudo, é importante destacar que não se encontrou na literatura nenhum trabalho que aborde o uso de redes neurais para realizar análises de séries temporais de *candlesticks* a fim de prever o tipo e a variação do próximo *candle*.

Na seção 3 são descritos os modelos propostos neste trabalho e na seção seguinte são apresentados resultados e análises da aplicação dos modelos no mercado de ações da Petrobras (petr4). Na seção 5 têm-se as considerações finais acerca de toda pesquisa.

2. Trabalhos Relacionados

O uso de RNAs na tentativa de previsão de séries temporais no mercado de ações tem se tornado comum, porém ainda não se conhece nenhuma abordagem completamente eficaz. Apesar disso, alguns resultados promissores já foram alcançados e acredita-se que resultados ainda melhores são mantidos em sigilo por empresas e organizações.

Dentre os trabalhos encontrados na literatura, em Castro (2001) e Coelho e Junior (2000) destacam-se modelos para previsão não linear de séries temporais baseadas em RNA do tipo *Radial Basis Function* (RBF). Em Zouca (2009) propõe-se a aplicação de um modelo de RNA composto por duas redes, RNN (*Recurrent Neural Network*) e TDNN (*Time Delay Neural Network*), que foram aplicadas em previsões de demanda do segmento industrial. O uso da primeira rede (RNN) através de um algoritmo de aprendizado baseado em filtros também foi proposto em Connor et al (1994). Em Ribeiro et al (2009), Lakshminarayanan (2005), Dongxiao et al (2010), Lanzhen e Fan (2010), Neto et al (2009) e Han et al (2006) abordam-se o uso dos algoritmos de RNA, como por exemplo, o *backpropagation*, contextualizados com modelos econométricos e/ou relacionados diretamente às séries de tempo. Em Gruca et al (1999) tem-se um trabalho mais específico relacionado às respostas do mercado pela comparação da previsão de modelos FFNN (*Feed-Forward Neural Network*) e de modelos da técnica de modelagem de mercado, denominada *Multiplicative Competitive Interaction* (MCI). Em Fu et al (2001) mostra-se o uso de SOM (*Self-Organizing Maps*) para a descoberta de padrões em séries temporais do mercado financeiro. Em Mahdi et al (2009) pode ser visto um modelo de rede neural adaptativo para previsão de séries

temporais em sistemas financeiros, denominado *Self-Organized Multilayer Perceptron* (SOMLP) e que, posteriormente, é comparado ao *Multilayer Perceptron* (MLP). Em Crone e Dhawan (2007) tem-se novamente uma MLP, contudo neste trabalho o autor busca a previsão de séries temporais sazonais mediante uma análise da sensibilidade dos parâmetros da arquitetura da rede. Em Abbas e Arif (2005) tem-se a proposta de um novo algoritmo baseado em CLNN (*Competitive Learning Neural Networks*) para a previsão de longas séries temporais do mercado financeiro.

É importante esclarecer que as séries temporais utilizadas em grande parte dos trabalhos de previsão sobre o mercado de ações são compostas de valores numéricos e tendem a considerar um conjunto de outras variáveis além da previsão em si, tais como pode ser visto em Lakshminarayanan (2005): valor mínimo, valor máximo, tendência, entre outros.

As idéias desse trabalho, segundo pesquisas realizadas nas mais diversas fontes de informação tais como ACM e IEEE, são originais, ou seja, a construção de um modelo de RNA para prever o próximo tipo de *candle* de uma série temporal de *candlesticks* e de outro para prever a variação aproximada do próximo *candle* são completamente novas. Há que se considerar que a importância de saber o tipo do próximo *candle* não é quantitativa como a previsão de sua variação, porém é uma informação qualitativamente importante para aqueles que acompanham o mercado de valores. Assim, sobre os trabalhos relacionados às propostas deste artigo que utilizam *candlesticks*, encontrou-se apenas Adashi (2004) e Goswami et al (2009), onde no primeiro é realizado um estudo acerca da extração de informações contidas em séries temporais de *candlesticks* para tentar prever o comportamento diário dos *candles* com o uso do algoritmo *backpropagation* e no segundo, é construído um modelo baseado em SOM e CBR (*Case Based Rationality*) para a predição de séries temporais curtas.

3. Modelos Propostos: CWType e CWVariation

O desenvolvimento dos modelos que são propostos nesta seção foi motivado pelas idéias inovadoras do trabalho, pois, como já se mencionou, não foi encontrado na literatura nenhum artigo cujos objetivos fossem semelhantes a este. Assim, partiu-se de estudos sobre RNAs e modelos econométricos aplicados em séries temporais com o intuito de auxiliar na fundamentação teórica e empírica do trabalho e mais ainda, na própria construção do modelo.

O passo inicial para o desenvolvimento do primeiro modelo proposto foi considerar os possíveis tipos de *candles* para a rede. Nesse modelo inicial resolvemos estabelecer, de modo geral, quatro possíveis tipos conforme é exibido na figura 3. No segundo modelo proposto, a variação é definida de acordo com a fórmula: $V = (C - O)/O$, onde V é o valor da variação, O o valor de abertura do *candle* e C o valor de fechamento. Note que, caso o ativo em questão tenha um valor de fechamento menor que seu valor de abertura a sua variação será negativa.

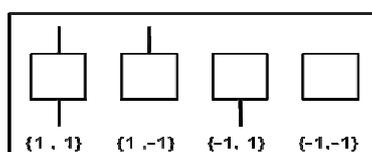


Figura 3. Representação de candlesticks para o modelo CWType.

Posterior à definição da representação dos tipos de *candles*, tendeu-se a considerar redes de algoritmos mais complexos, tais como RBF, RNN e outras apresentadas na seção anterior para a construção do primeiro modelo. Contudo, essas redes normalmente estão relacionadas a representações quantitativas e programá-las constitui-se em um trabalho futuro, uma vez que será necessária uma quantidade considerável de tempo na codificação e mais ainda na análise dos resultados obtidos.

O objetivo do modelo CWType neste trabalho pode ser descrito da seguinte forma: dada uma série temporal de tipos de *candles* de tamanho Z após t espaços de tempo, deseja-se prever o próximo tipo de *candle* ($Z+1$) no próximo espaço de tempo ($t+1$). Já o objetivo do modelo CWVariation pode ser descrito assim: dada uma série temporal com variações de *candles* e tamanho Z , após t espaços de tempo, deseja-se prever a variação média do próximo *candle* ($Z+1$) no próximo espaço de tempo ($t+1$).

É oportuno ressaltar que as séries temporais as quais se deseja prever em ambos os modelos são reais, apresentam caráter estocástico e foram retiradas da base histórica da ação preferencial da Petrobras (petr4). Partindo-se desse princípio (aplicação em ambientes reais), optou-se pela incorporação do conceito de janelas de tempo à rede neural. Uma janela J pode ser definida como o número de dados que serão apresentados à rede para que aconteça a saída desejada ($J+1$). Dessa forma, o tamanho escolhido para J deve ser feito manualmente e de preferência baseando-se no estudo das séries temporais consideradas a fim de atribuir a J um valor que esteja relacionado com a maior parte das saídas desejadas.

Sobre a arquitetura construída para a rede do modelo CWType diz-se que é simples uma vez que a tarefa tende a ser mais qualitativa que quantitativa e também pelo fato deste ser um modelo inicial que certamente incorporará uma série de outros estudos e pesquisas. Na figura 4 apresenta-se a arquitetura do modelo proposto. Nela podemos ver uma camada de entrada onde J tipos de *candles* são apresentados a rede e a saída desejada é $J+1$ para toda a janela. Os pesos são compostos por W_1 e W_2 e desempenham papel fundamental no modelo uma vez que refletem as tendências das séries de tempo para as futuras janelas (próximas séries). Ao centro, tem-se um vasto conjunto de funções tanto econométricas quanto relacionadas ao erro gerado pela rede, a fim de considerar, através do ajuste dos pesos, os resultados dessas funções para os próximos dados que serão apresentados.

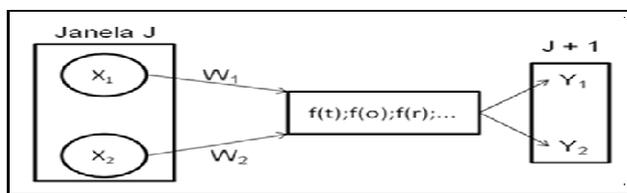


Figura 4. Arquitetura da rede desenvolvida para o modelo CWType.

O algoritmo para o CWType foi desenvolvido através de uma mesclagem das funções da rede neural e das funções econométricas. Inicialmente, tem-se uma série temporal de tamanho Z , composta por $\{Z_0, Z_1, \dots, Z_J, Z_{J+1}, \dots, Z_N\}$, como entrada da rede neural. Define-se então o tamanho da Janela como J , dessa forma o conjunto $\{Z_0, \dots, Z_J\}$ será apresentado a rede e a saída desejada é o tipo de *candle* em Z_{J+1} . Outro passo do algoritmo é o cálculo das variáveis econométricas construídas no modelo e

denominadas: *tendency* (tendência geral da série temporal), *orderCte* (significância quantitativa da ordem dos elementos na janela tomando por base todas as janelas) e *repeatCte* (grau de significância da repetição de elementos dentro de uma mesma janela considerando todas as janelas). Durante a execução do algoritmo, são calculadas para cada janela duas variáveis econométricas: *order* e *repeat*, com a intenção de representar as séries também localmente (dentro de cada janela). É importante dizer que quando definimos variáveis econométricas globais e locais, temos o interesse de não perdermos nem a tendência geral, muito menos as características específicas de cada janela, ou seja, visamos alcançar um ponto equilíbrio entre elas.

Para o modelo CWVariation, desenvolveu-se um modelo baseado na rede *Multilayer Perceptron* (MLP). Diz-se “baseado” porque se incorporou ao MLP as mesmas janelas utilizadas para o CWType. É importante ressaltar que a previsão da variância do próximo *candle* é dada por um valor real e acredita-se que com o algoritmo *backpropagation* a rede será capaz de detectar alguns padrões dessas variâncias entre os *candles*. A arquitetura da rede MLP é exibida na figura 5.

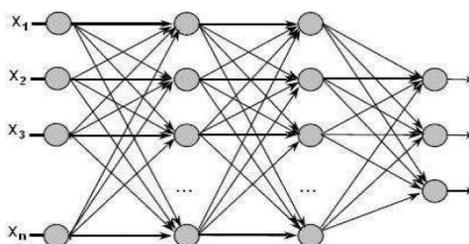


Figura 5. Arquitetura similar à rede utilizada para o modelo CWVariation.

4. Análises e Resultados

Para efeito de organização do artigo essa seção foi dividida em duas partes: a primeira relacionada às análises e resultados obtidos para o modelo CWType e a segunda para o modelo CWVariation.

4.1. Análises e Resultados do Modelo CWType

Para o modelo CWType (previsão do próximo tipo de *candle*), os testes foram realizados sobre duas bases de dados reais da companhia Petrobrás (dados retirados no dia 14 de julho de 2010): a primeira base composta por *candles* atualizados a cada minuto e a segunda por *candles* atualizados a cada quinze minutos.

Sobre o padrão de variáveis empregado nos testes, os principais são expostos a seguir:

- ✓ Janela = 6. A alteração do valor da janela pode provocar diferentes comportamentos na previsão do próximo tipo de *candle*, uma vez que a janela está diretamente relacionada às variáveis econométricas;
- ✓ Tamanho da entrada igual a 10 *candles*. A partir dessa entrada tenta-se prever o próximo tipo de *candle*. Realiza-se tal procedimento por diversas vezes e faz-se a média ao término;
- ✓ $\alpha = \alpha / \text{Tamanho da entrada}$.

Para os testes realizados a cada minuto a rede obteve um desempenho abaixo do esperado nas previsões (aproximadamente 25% de acerto). Contudo, para os testes

realizados a cada quinze minutos a rede obteve um bom desempenho (em torno de 60% de acerto).

Uma possível justificativa para tamanha diferença entre os percentuais de acerto em cada uma das bases de dados pode estar relacionada à falta ou, pelo menos, a dificuldade em se estabelecer padrões nos *candles* atualizados a cada minuto. Em contrapartida, a base de dados dos *candles* gerados a cada quinze minutos estabelece, mesmo que para pequenas entradas, pequenos padrões.

Também foram utilizados todos os *candles* de 15 minutos do ativo petr4 (Petrobras PN) no período de 01/01/2008 à 12/07/2010 em um teste e a rede conseguiu prever o próximo *candle* com sucesso. No entanto, ao se realizar o mesmo teste para *candles* de 1 minuto, a rede não obteve sucesso.

4.2. Análises e Resultados do Modelo CWVariation

Os testes do modelo CWVariation também foram feitos com as bases de 1 e 15 minutos. Porém ao contrário do modelo CWType, as entradas da rede no CWVariation são as variações entre o valor de abertura e o valor de fechamento de cada *candle*. A intenção era, a partir da análise da tendência de variação, tentar prever a variação do próximo *candle*, inclusive indicando o sinal (alta ou queda) da mesma.

Os resultados foram desanimadores. Foram utilizados todos os *candles* de 15 minutos do ativo petr4 (Petrobras PN) no período de 01/01/2008 à 12/07/2010 e realizou-se 100 ciclos de treinamento. Mesmo variando-se os valores da taxa de aprendizagem entre o extremo de 1 ao mínimo de 0,0001, os resultados obtidos ficaram muito distantes do esperado. Apenas como exemplo, para um determinado conjunto de dados de entrada o valor esperado era 0,003, ou seja, variação positiva de 3%, porém o obtido pela rede foi 0,645, ou seja, 64,5% de variação positiva. Os demais resultados ficaram próximos desse. Aliás, mesmo alterando-se vários parâmetros da rede não se conseguiu obter qualquer resultado aceitável.

5. Considerações Finais

Séries temporais têm sido bastante pesquisadas, por seu caráter abrangente e pela incessante tentativa humana de “prever” o futuro. Há um conjunto de trabalhos dentro do campo específico de mercado financeiro. Boa parte dos trabalhos publicados, porém, não apresentam resultados gerais muito satisfatórios. Entretanto, isso é esperado haja vista que grandes empresas investem milhões de dólares em pesquisas nessa área, e todo e qualquer bom resultado é considerado “super secreto”.

Nesse trabalho, considerou-se os resultados satisfatórios apenas para o modelo CWType. Ainda assim apenas para *candles* de 15 minutos, onde o comportamento estocástico tende a ser menor que os de 1 minuto. O modelo CWVariation se mostrou completamente equivocado.

Os resultados obtidos com o CWType, apesar de satisfatórios, são irrelevantes quando utilizados isoladamente. Um possível e, acredita-se, promissor trabalho futuro seria associar essa previsão com algum outro parâmetro de modo que isso poderia ser feito para reforçar um resultado ou mesmo para orientar uma tomada de decisão por algum outro algoritmo. Outros trabalhos futuros a serem considerados são a realização de testes com outros tipos de redes neurais, tais como RBF, RNN e outras.

Referências

- Abbas, S. e Arif, M. (2005) “Competitive neural network based algorithm for long range time series forecasting case study: electric load forecasting”. IEEE INMIC.
- ACM, Association for Computing Machinery. <www.acm.org>, até 09/09/2010.
- Adashi, M. (2004) “Applying neural networks to the extraction of available investment information from the previous day’s stock market”. NUCB Journal of Economics and Information Science 48(2), 13-22, Nagoya-Japão.
- Castro, M. (2001) “Predição não-linear de séries temporais usando redes neurais RBF por decomposição em componentes principais”. Tese de Doutorado, UNICAMP. Campinas – SP.
- Coelho, L. e Junior, O. (2000) “Rede neural de base radial aplicada em previsão de séries temporais: algoritmo e aplicação”. ENEGEP.
- Connor, J., Martin, R. e Atlas, L. (1994) “Recurrent neural networks and robust time series prediction”. IEEE Transactions on Neural Network Vol. 5 (2).
- Crone, S. e Dhawan, R. (2007) “Forecasting seasonal time series with neural networks: a sensitivity analysis of architecture parameters”. International Joint Conference on Neural Networks. Orlando-USA.
- Dongxiao, N., Hui, S. e Yanan, W. (2010) “Research on short-term power load time series forecasting model based on BP neural network”. IEEE ICACC.
- Fu, T., Chung, F., Ng, V. e Luk, R. (2001) “Pattern discovery from stock time series using self-organizing maps”. ACM SIGKDD, p. 27-37. San Francisco-USA.
- Goswami, M., Bhensdadia, C. e Ganatra, A. (2009) “Candlestick analysis based short term prediction of stock price fluctuation using SOM-CBR”. IEEE IACC.
- Gruca, T., Klemz, B. e Petersen, E. (1999) “Mining sales data using a neural network model of market response”. ACM SIGKDD Vol. 1 (1), p. 39-43. San Diego-USA.
- Han, M., Fan, M. e Shi, Z. (2006) “Multivariate time series prediction by neural network combining SVD”. IEEE SMC. Taipei-Taiwan.
- IEEE, Institute of Electrical and Electronic Engineers. <www.ieee.org>, até 09/09/2010.
- Jain, C. (2007) “Benchmarking Forecasting Model”. The Journal of Business Forecasting, p. 15-35.
- Lakshminarayanan, S. (2005) “An integrated stock market forecasting model using neural networks”. Tese de Mestrado. Universidade de Ohio. Canadá.
- Lanzhen, L. e Fan, S. (2010) “The study on short-time wind speed prediction based on time-series neural network algorithm”. IEEE APPEEC.
- Mahdi, A., Hussain, J. e Al-Jumeily, D. (2009) “Adaptive neural network model using the immune system for financial time series forecasting”. International Conference on Computational Intelligence. Honolulu-USA.
- Neto, M., Calvalcanti, G. e Ren, T. (2009) “Financial time series prediction using exogenous series and combined neural networks”. International Joint Conference on Neural Networks. Atlanta-USA.
- Ribeiro, C., Goldshmidt, R. e Choren, R. (2009) “Métodos para previsão de séries temporais e suas tendências de desenvolvimento”. IME. Rio de Janeiro.
- Zouca, F. (2009) “Aplicação de redes neurais para previsão de séries temporais em segmentos industriais”. Dissertação de Mestrado. FEI. São Bernardo do Campo – SP.