

Relatório Técnico

**Núcleo de
Computação Eletrônica**

Avaliação de Redes Neurais Aplicadas à Previsão de Índices de Mercados de Ações

**Renato S. Vieira
Antonio C. G. Thomé**

NCE - 11/00

Universidade Federal do Rio de Janeiro

RENATO S. VIEIRA, ANTONIO C. G. THOMÉ

Área de Ensino e Pesquisa – NCE/IM, Universidade Federal do Rio de Janeiro
Caixa Postal 2324, CEP 20.001-970, Cidade Universitária, Rio de Janeiro, RJ, Brasil
E-mails: rvieira@posgrad.nce.ufrj.br, thome@nce.ufrj.br

Resumo— As redes neurais artificiais vêm sendo utilizadas na modelagem da solução de problemas de previsão de séries temporais em diferentes segmentos da área financeira, como por exemplo, análise de balanços, indicadores macroeconômicos, mercado de câmbio, cotação de ações e índices de mercados. Nesses problemas, é usual mensurar a qualidade do modelo de previsão através do uso de alguma medida de erro entre o valor real e o valor previsto pela rede. Contudo, aplicações na área financeira demandam o atendimento a objetivos financeiros subjacentes, tais como nível de lucratividade ou exposição ao risco. A obtenção de medidas de erro com magnitude pouco significativa não é garantia de atendimento a esses objetivos: há necessidade do estabelecimento de critérios adicionais, de forma a possibilitar a aferição da qualidade dos resultados obtidos à luz de objetivos financeiros específicos. Este artigo apresenta resultados de alguns experimentos realizados com vistas a comparar diferentes arquiteturas de redes neurais para a previsão do índice Ibovespa, da Bolsa de Valores de São Paulo, envolvendo diferentes critérios de treinamento e estratégias de avaliação do desempenho com base em objetivos financeiros e de negócio.

Abstract— Artificial neural networks have been utilized in modeling solutions for time series forecasting problems arisen in different financial area segments such as financial statements analysis, macro-economic indicators, currency market, stock quotations and market indexes. When dealing with such problems, the forecasting model quality is usually appraised in terms of the difference between the actual value and the network forecasted value. But financial area applications also require that related financial goals such as profitability and low risk exposure be considered. The commonly used mean square error generally does not grant those needs are met. It seems then to be necessary to establish additional criteria considering specific financial goals. The current paper shows the results obtained in experiments carried on to compare different neural network architectures to forecast the São Paulo Stock Exchange Ibovespa index using different training criteria and performance evaluation strategies based on business and financial goals.

Keywords— Financial Time Series; Neural Networks; Forecasting

1 Introdução

A previsão de séries temporais financeiras é considerada uma tarefa de grande dificuldade, em razão da pequena quantidade de observações da série, em geral disponíveis, da presença de intenso ruído, de seu caráter não estacionário e da típica não-linearidade inerente à tais séries.

Ao longo dos anos diferentes técnicas vêm sendo utilizadas para previsão: métodos estatísticos diversos (com grande ênfase em modelos lineares), teoria do caos, redes neurais artificiais e mesmo modelos híbridos. Em particular, as redes neurais artificiais oferecem potencial significativo para a abordagem do problema, como sugerem pesquisas de aplicação da técnica em diferentes áreas do mercado financeiro, dentre outras:

- Mercado de câmbio de moedas: marco/dólar (Klimauskas, 1992), dólar/franco suíço (Lequarré, 1994);
- Índices de bolsa de valores: Amsterdam (Baestaens & Van den Bergh, 1995), ATX¹ (Haefke & Helmenstein, 1996), DAX² (Siegler & Steurer, 1998), S&P500 (Moody & Saffell, 1998);

- Cotação de ações: Apple Computer (Deboeck, 1992), Kyokuyo Company³ (Hutchinson, 1994), Hochtief⁴ (Schumann & Lohrbach, 1996), Telebras (Diniz et al., 1998);
- Indicadores macro-econômicos: índice de desemprego americano (Draisma, Kaashoek & Dijk, 1993).

Aplicações na área financeira demandam o atendimento a objetivos financeiros subjacentes, tais como nível de lucratividade ou exposição ao risco. Independente do ferramental teórico por traz da construção do modelo de previsão, essa premissa deve ser observada. As redes neurais não constituem exceção a essa regra.

No momento que uma organização empresarial procura consultoria interessada em resolver um problema de previsão na área financeira, seu interesse deve ser traduzido, após exame apurado, em objetivos financeiros e de negócio bem definidos. Esses objetivos, em suas diversas formas, contribuem para a especificação de hipóteses que serão testadas quando da avaliação do modelo de previsão, de forma a garantir que os resultados obtidos estejam em sintonia com os objetivos da organização, uma vez que estes resultados serão utilizados para subsidiar algum processo de tomada de decisão.

¹ Índice da Bolsa de Valores da Austrália.

² Índice da Bolsa de Valores da Alemanha.

³ Empresa japonesa de porte médio.

⁴ Empresa alemã.




Figura 1. Índice Ibovespa (nominal). Valor diário de fechamento, em reais, do Índice Ibovespa, identificando o período de treinamento e o período de testes utilizados, este último realçado na figura.

A organização não está interessada no arsenal de figuras de mérito utilizadas pelo projetista neural para aferir a acurácia dos resultados encontrados, a menos que essas figuras possam ser traduzidas em resultados financeiros que atinjam os objetivos previamente estabelecidos.

Com intuito de analisar a relação existente entre a acurácia e o atendimento a objetivos financeiros estabelecidos em uma aplicação na área financeira, adotou-se o problema de previsão da variação diária do valor de fechamento do índice Ibovespa, descrito na próxima seção, como estudo de caso. Para tal, foram desenvolvidos experimentos, cujos resultados, utilizando-se das medidas descritas na seção 4, são apresentados na seção 6, integrando modelos neurais, detalhados na seção 3, a um protótipo de sistema de negociação de ativos descrito de forma sucinta na seção 5. O leitor encontra, na seção 7, as conclusões, finalizando com uma breve revisão bibliográfica na seção 8.

2 Representatividade do Ibovespa

O Ibovespa, índice da Bovespa - Bolsa de Valores de São Paulo, retrata o comportamento dos principais papéis negociados nesse mercado organizado, constituindo o mais importante indicador do desempenho médio das cotações do mercado de ações brasileiro e mesmo da América Latina (Bovespa, 1999).

As empresas emissoras das ações integrantes da carteira teórica do Ibovespa são responsáveis, em média, por aproximadamente 65% do somatório da capitalização bursátil de todas as empresas com ações negociáveis na Bovespa, conforme apresentado na Tabela 1. Essas informações fornecem uma visão geral sobre a importância do índice para os participantes do mercado de capitais brasileiro, uma das justificas de sua escolha como estudo de caso.

A título ilustrativo apresenta-se o valor de fechamento nominal do índice na Figura 1. A série histórica utilizada foi obtida junto a uma conceituada empresa de serviço de informações para o mercado financeiro, alternativa em geral não acessível ao

Tabela 1. Valor de mercado das empresas representativas do Ibovespa e do total das empresas negociadas na Bolsa paulista.

Empresas	R\$ Mil			US\$ Mil		
	Jun/99	Jul/99	Var%	Jun/99	Jul/99	Var%
do Ibovespa	191.373.485,08	174.144.079,86	-9,00	102.131.164,22	97.330.693,09	-10,00
Total	278.588.964,83	266.482.020,81	-4,35	157.439.369,79	148.939.202,33	-5,40

pequeno investidor. Embora extremamente recomendável (Cheng, Wagner & Lin, 1996), não houve validação desses dados com base em outras fontes de informação.

3 Arquiteturas e Restrições

A previsão através da utilização de modelos de uma única variável não é a estratégia mais recomendada para obtenção de resultados com real potencial de utilização, principalmente em se tratando de séries com as características apresentadas pelo Ibovespa. Contudo, essa tática é, no mínimo, recomendada como figura de *benchmark* para a avaliação de modelos mais elaborados (Jenkins, 1979), e mostrou-se adequada para o desenvolvimento deste trabalho, cujo objetivo consiste em comparar critérios e medidas de erro para avaliação financeira do desempenho de diferentes arquiteturas de redes neurais para a previsão do índice Ibovespa.

Foram utilizadas no presente trabalho, redes neurais *feedforward*, regra de aprendizado gradiente descendente com função de custo dada pelo somatório do erro quadrático, e demais características conforme descrito a seguir.

Alguns dos resultados apresentados não embutem a existência de custos de negociação, sempre presentes e de impacto significativo numa aplicação real, principalmente em se tratando do mercado brasileiro. Da mesma forma, não foi considerado qualquer desconto relativo ao custo de oportunidade dos juros ou da variação do dólar em relação à moeda local.

Com relação ao horizonte de previsão, todos os experimentos realizados visaram a previsão do valor de fechamento de um único dia de negociação no futuro, através da utilização de múltiplas janelas temporais.

Foram adotadas arquiteturas com até duas camadas intermediárias: a primeira camada com (5, 10, 20, ou 40) neurônios e a segunda com (0, 5, 10, 20, ou 40). Para cada uma dessas vinte arquiteturas distintas possíveis, foram gerados dez grupos de redes com diferentes parâmetros de iniciação para efeito de treinamento.

Foi considerado uma semana de cinco dias tanto para o período de treinamento como para o de testes, exigindo a criação de valores fictícios para o primeiro período, equivalentes ao valor do último dia negociado, para os dias em que não houve funcionamento do mercado.

Todas as observações da série foram transformadas, usando a mediana do período de treinamento como elemento de centralização dos dados, para o intervalo (-1,1), de forma a ficarem




Figura 2. Diagrama de representação das arquiteturas. Uma representação 4-5-10(100) descreve uma rede neural utilizando janela temporal de quatro dias, com duas camadas intermediárias, a primeira com 5 neurônios e a segunda com 10. A quantidade especificada entre parênteses significa que a rede foi submetida a 100 interações de apresentação de dados durante o treinamento.

compatíveis com a função de propagação tangente hiperbólica empregada em todas as redes.

As observações da série, correspondentes ao período de treinamento arbitrado, 08/01/1996 a 03/06/1998 (628 observações), foram submetidas a cada uma das diferentes redes um total de 100, 1000 e 5000 vezes.

Para a realização dos testes foi fixado o período crítico, marcado por alta volatilidade do mercado, entre 04/06/1998 a 08/01/1999 (157 observações) – correspondente ao período realçado na Figura 1.

A Figura 2, apresenta uma visão geral das 480 diferentes configurações utilizadas. Cada uma dessas configurações possíveis foi submetida a dez seções de treinamento, com diferentes configurações de pesos iniciais, perfazendo um total de 4800 diferentes redes neurais utilizadas no experimento.

4 Medidas de Acurácia e Desempenho

Uma alternativa muito adotada para a mensuração da acurácia de algoritmos de previsão de séries temporais, consiste no cálculo de alguma forma de erro representando a diferença entre o valor previsto (pelo algoritmo) e o valor real (observado).

Weiss & Indurkha(1998:36), por exemplo, sugerem que o cálculo do desempenho da previsão, em um modelo ideal, consiste em mensurá-lo em termos do erro médio, taxa de erro ou alguma medida de distância – euclideana, por exemplo - entre o valor real e o previsto pelo algoritmo utilizado.

De forma semelhante, Diniz et. al.(1998) descrevem a implementação de um sistema híbrido para a previsão das séries temporais da Telebras, utilizando uma função de erro médio relativo para avaliar a acurácia da previsão.

A literatura provê várias técnicas utilizadas como instrumentos para a mensuração da acurácia de modelos de previsão (Levenbach & Cleary, 1981; Refenes, 1995), dentre as quais: comparação gráfica; diagramas de dispersão; diagramas previsão – realização; coeficiente de correlação; erro quadrático acumulado (SSE); erro médio quadrático ;variância relativa média; erro percentual médio absoluto; raiz do erro médio quadrático; raiz do erro médio quadrático normalizada; erro absoluto médio

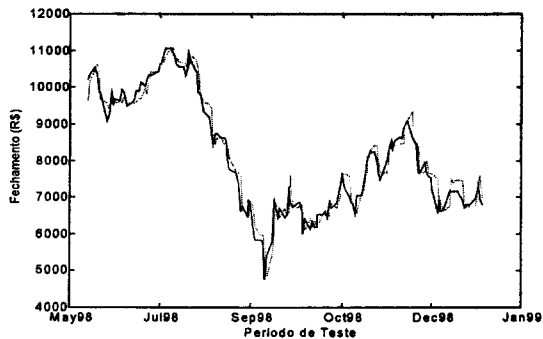


Figura 3. Índice Ibovespa e sua previsão (maior lucro). Valor diário de fechamento, em reais, do Índice, para o período de treinamento. A linha cheia corresponde ao valor real e a tracejada ao valor previsto pela melhor rede em lucratividade.

percentual; percentual/número de pontos de inflexão incorretos; e, coeficiente U de Theil. Uma variedade de métricas, com características e méritos próprios, eventualmente utilizadas de forma indevida.

Apesar da usual prática de utilização de medidas de erro para avaliar a acurácia de métodos de previsão, convém notar que as aplicações na área financeira têm, em geral, como objetivo subjacente, a obtenção de lucros e, o fato de um algoritmo apresentar uma previsão com valor de erro menor - quando comparado a outro algoritmo -, não significa, necessariamente, a obtenção de lucro superior (Klimasauskas, 1992).

Diversas medidas clássicas podem ser utilizadas na avaliação do desempenho financeiro de modelos de previsão acoplados a sistemas de negociação de ativos (Klimasauskas, 1992; Deboeck, 1992; Hutchinson, 1994).

Deboeck (1992) formula uma classificação apresentando três classes principais de critérios para avaliação de redes neurais financeiras: o da lucratividade, o da consistência e da robustez.

Esses critérios de avaliação permitem uma grande flexibilidade para a otimização das redes neurais visando atingir objetivos e requisitos específicos de um sistema de negociação de ativos. Por exemplo, considerando esses critérios, uma rede neural pode ser selecionada visando: minimizar o risco; maximizar o retorno; minimizar a volatilidade dos retornos médios ;minimizar o número de negociações ou seus custos; maximizar a relação entre a lucratividade média e o prejuízo máximo em negociações sucessivas; ou, uma combinação desses fatores.

Em função da multiplicidade de alternativas referentes à avaliação do desempenho da previsão, uma alternativa aparentemente simples seria concentrar os esforços na otimização de um determinado fator de erro, que seja crítico para a aplicação em mãos. Ao mesmo tempo, em que devem ser obtidos valores moderadamente ótimos para os outros fatores de erro. Na seção 6, reúnem-se elementos que sugerem grande dificuldade para tal tarefa.




Figura 4. Diagrama de Dispersão Lucro x Tendência. Relação entre o percentual de vezes em que a tendência, de alta ou de baixa, foi efetuada com sucesso e a lucratividade das redes treinadas. A rede neural que apresentou o menor SSE aparece em destaque marcada com uma seta.




Figura 5. Diagrama de Dispersão SSE x Tendência. Relação entre o percentual de vezes em que a tendência, de alta ou de baixa, foi efetuada com sucesso e o SSE das redes treinadas. A rede neural que apresentou a maior lucratividade, aparece em destaque marcada com uma seta

5 Estratégias de Negociação

Um sistema de negociações de ativos é simplesmente algum método sistemático de repetidamente comprar ou vender algum ativo, como por exemplo ouro, ações ou opções. A compra e venda de ativos pressupõem a existência de alguma estratégia de negociação.

A mais simples das estratégias, consiste na compra e manutenção do ativo em carteira até posterior negociação. Essa estratégia, prática comum de investidores inexperientes, é frequentemente adotada como estratégia de *benchmark* de modelos de sistemas negociação. Uma vez que o ativo é mantido em carteira desde o momento de sua aquisição, o cálculo do lucro (ou prejuízo) auferido consiste em computar a diferença entre o atual valor do ativo e o de compra, deduzindo-se custos de negociação e de oportunidade. Como pode ser observado na Figura 1, mesmo sem consideração dos custos envolvidos, a adoção dessa estratégia para o período de testes arbitrado – de queda do Ibovespa -, geraria prejuízo significativo ao investidor.

Para simulação e avaliação do desempenho financeiro dos modelos neurais construídos, foi adotada uma estratégia alternativa (Refenes, 1995), um pouco mais elaborada. A lucratividade é mensurada pela acumulação, a cada negociação, da diferença entre o valor previsto e o valor real, ponderado por um sinal de compra (positivo) ou venda (negativo), ao longo do período. Assume-se a ausência de componentes de custo e outras imperfeições do mercado.

6 Análise de Resultados

Para fins de avaliação dos experimentos, foram utilizados alguns dos critérios apresentados na seção 4, em especial: quanto à acurácia (comparação gráfica, diagramas de dispersão), lucratividade

(Percentual/Número de pontos de inflexão incorretos, lucratividade sobre todo o período de teste) e consistência (lucro ou prejuízo máximo em negociações sucessivas).

A Figura 3 apresenta o gráfico do valor de fechamento do Ibovespa referente ao período de testes, em linha cheia, simultaneamente aos previstos pela rede neural que apresentou o melhor desempenho financeiro, sob a forma do lucro total sobre o período de teste. A figura aparentemente permite visualizar o comportamento global do modelo de previsão utilizado e, em casos extremos, observar suas falhas de previsão. Podemos identificar na figura, uma propensão a superestimar o valor previsto em situações de tendência de queda do mercado, bem como subestimar esse valor num mercado em alta. Contudo, a mera visualização do gráfico, a despeito da prática corrente, pouca informação traz com relação à qualidade do modelo utilizado sob a ótica do desempenho financeiro.

Uma das mais simples e intuitivas formas de mensuração da acurácia de modelos de previsão, a computação do percentual de vezes em que a tendência (previsão de alta ou baixa) foi efetivada com sucesso é apresentada na Figura 4 (em relação ao lucro) e na Figura 5 (em relação ao SSE), para as cem redes neurais que apresentaram melhor desempenho financeiro. Na Figura 5, a rede neural que apresentou o maior desempenho em todo o grupo, sob a ótica do resultado financeiro, aparece em destaque marcada com uma seta. De forma semelhante, a Figura 4 efetua a comparação com o desempenho financeiro, destacando uma seta a rede de menor SSE.

Com base na Figura 5 verifica-se que a rede que obteve a maior lucratividade para todo o período de testes, uma configuração 1-40-10-1(5000), não acertou a tendência o maior número de vezes, o que ocorreu em uma configuração 1-5-5-1(5000), nem obteve o menor SSE acumulado durante o período de treinamento.

De forma semelhante, observa-se que na Figura 4, por exemplo, o rol de redes que acertaram a tendência por volta de 60% das vezes resultaram em uma lucratividade entre R\$ 5.500,00 e R\$ 8.500,00, o que representa uma variação de 50%, nada desprezível quando o objetivo consiste em maximizar lucros. Além disso, a rede com menor lucratividade nesta faixa de valores, ainda obtém menor lucratividade que uma das redes que acertou a tendência pouco acima de 52% das vezes, uma acurácia 15% inferior, porém com lucratividade bem superior, em torno de R\$ 7.800,00.

A arquitetura que obteve a melhor lucratividade final⁵, R\$ 10.006,00, acertou a tendência do mercado em 62,4% das vezes. Esta rede obteve lucro máximo, em uma única negociação, de R\$ 1.087,00. Outro fator que colaborou significativamente para o resultado final foi o lucro máximo acumulado em sucessivas boas negociações de R\$ 4.881,00. Ou seja, cerca de 60% do desempenho final resultou desses dois fatores. Essa arquitetura, no melhor caso, foi capaz de prever a direção do mercado durante 3 semanas (15 negociações) consecutivas. Em contrapartida, no pior caso, durante cinco dias consecutivos apresentou erros de previsão. Quanto às más negociações, a arquitetura gerou prejuízo máximo de R\$ 731,00 em uma única negociação e R\$ 1.362,00 em más negociações sucessivas.

Já a rede de melhor resultado quanto à tendência, acertou a direção do mercado 64,3% das vezes, resultando numa lucratividade de R\$ 8.308,00. A rede obteve um lucro máximo acumulado em sucessivas boas negociações de R\$ 2.382,00. Nas más negociações, a arquitetura gerou prejuízo máximo de R\$ 742,00 em uma única negociação, e, de R\$ 1.387,00 em más negociações sucessivas, mantendo para os demais fatores o mesmo comportamento da arquitetura de melhor desempenho.

Tabela 2. Resultado Global: A rede com melhor lucratividade. As linhas indicam o número de vezes, para o período de testes, representativos da tendência (queda, estável ou alta) observada no mercado entre dois dias de negociação consecutivos. As colunas, apresentam a mesma informação com relação à previsão para a rede com maior lucratividade. A coluna % *Correto* apresenta o percentual de vezes em que determinada tendência foi efetuada com sucesso.

Previsto Real	Queda	Estável	Alta	Total	% Correto
Queda	43	0	37	80	54
Estável	3	0	6	9	0.00
Alta	22	0	46	68	68

Efetuando-se uma comparação entre a Tabela 2 e a Tabela 3, o leitor pode observar que apesar da rede representada na Tabela 3 ter previsto a tendência de queda do mercado com uma acurácia 23% superior à

rede da Tabela 2, esta última obteve maior lucratividade, indicando ausência de uma relação direta entre acerto na tendência e lucratividade. Sob o ponto de vista global, a mesma situação pode ser observado na Figura 4.

As redes de maior lucratividade (Tabela 2) e de melhor tendência (Tabela 3) superaram significativamente o desempenho da rede de menor SEE (Tabela 4), uma acurácia de apenas 43,3%.

Interessante notar que na Tabela 4, referente à rede que apresentou o melhor SSE quando do treinamento realizado, a quantidade significativa de pontos de inflexão (61) incorretamente previstos, acertando somente 24% das vezes em que ocorreu uma queda na cotação do índice. Em contrapartida, a mesma rede apresentou desempenho satisfatório nas previsões de alta do índice, acertando em 72% das vezes, pouco superior à rede que apresentou a melhor lucratividade, prevendo corretamente 68% dos casos de alta do índice.

7 Conclusão

A análise dos resultados apresentados sugere que a relação entre a lucratividade auferida e a acurácia de um determinado modelo neural não apresenta relação direta e previsível, como a princípio poderia o projetista ser levado a supor. O mesmo se aplica para outras métricas, tais como o lucro (ou prejuízo máximo) global ou acumulado.

Da mesma forma, a quantidade de vezes em que uma tendência de alta ou baixa é prevista corretamente, guarda em si uma tênue relação com a lucratividade, já que a obtenção de lucro sofre influência direta da magnitude da variação de alta ou baixa do mercado, alterando de forma significativa o lucro final auferido.

Tabela 3. Resultado Global: A rede que previu corretamente a tendência do mercado o maior número de vezes (em número de dias)

Previsto Real	Queda	Estável	Alta	Total	% Correto
Queda	53	0	27	80	0.66
Estável	5	0	4	9	0.00
Alta	29	0	39	68	0.57

Tabela 4. Resultado Global: A rede com o melhor SSE (em número de dias)

Previsto Real	Queda	Estável	Alta	Total	% Correto
Queda	19	0	61	80	24
Estável	1	0	8	9	0.00
Alta	19	0	49	68	72

A constatação desses fatores dificulta sobremaneira a avaliação sobre a viabilidade de aplicação prática de muitos resultados de pesquisas de previsão utilizando modelos neurais na área

⁵ Cerca de 28% de R\$ 36.308,00, o desempenho financeiro, em função da estratégia de negociação adotada (sem custos), de uma rede que previsse a tendência corretamente 100% das vezes.

financeira, que tenham como critério de avaliação somente medidas de acurácia.

Tabela 5. Composição do Resultado Financeiro Global: A rede com a melhor lucratividade (valores apurados em R\$)

Previsto Real	Queda	Leve Queda	Estável	Leve Alta	Alta	Total	%Correto
Queda	2677.00	7319.00	0.00	-4028.00	-5004.00	19028.00	14.07
Leve Queda	320.00	53.00	0.00	-269.00	-21.00	663.00	7.99
Estável	0.00	0.00	0.00	0.00	0.00	0.00	0.00
Leve Alta	-66.00	-116.00	0.00	190.00	89.00	461.00	41.21
Alta	-1381.00	-2266.00	0.00	7343.00	5166.00	16156.00	31.98

Não obstante à adequada interpretação das figuras de mérito utilizadas, é crucial que o projetista leve em consideração o impacto que as restrições oferecidas pelo modelo utilizado podem trazer para a análise dos resultados. Exemplificando, neste artigo uma das restrições significativas consiste em apurar o desempenho financeiro sem levar em consideração a existência de custos envolvidos. Ou seja, assume-se que todos os sinais de compra e venda gerados a partir da interpretação dos resultados da previsão são utilizados para efeito de negociação. Contudo, essa é uma restrição inviável em um sistema de negociação de ativos que tenha por objetivo atuar no mundo real. O custo de cada negociação pode, por exemplo, em muitas das tendências previstas corretamente, ser superior à expectativa de variação (alta ou queda) do ativo em análise, transformando operações aparentemente lucrativas em prejuízo real, como pode ser observado a partir da análise da Tabela 5 (onde *leve alta* e *leve queda* apresentam variações abaixo do custo de negociação calculados em 1% do valor transacionado).

Encontrar modelos neurais para previsão de séries temporais que atendam objetivos financeiros e de negócio constitui tarefa de grande dificuldade, apresentando inúmeras armadilhas ao projetista. Pode a tentativa de maximização do lucro, por exemplo, induzir a uma escolha inadequada da melhor rede, caso outros fatores como o lucro máximo obtido em uma única negociação ou em negociações sucessivas não sejam considerados de forma integrada.

8 Referências Bibliográficas

- Bovespa – <http://www.bovespa.com.br>
- Cheng, W. Wagner, L. Lin, C. Forecasting the 30-year U.S. Treasury Bond with a System of Neural Networks. *NeuroVeSt Journal*. January/February 1996. 13 pp.
- Deboeck, G. J. Pre-processing and Evaluation of Neural Nets for Trading Stocks. *Advanced Technology for Developers*. USA: Volume 1. August 1992. 1-13 pp.
- Diniz, H. Andrade, L. Carvalho, A. Andrade, M. Previsão de Séries Temporais utilizando Redes Neurais Artificiais e Modelos de Box & Jenkins. *Proceedings of the V Brazilian Symposium on Neural Networks*, pages 173-178, Belo Horizonte, Brazil, December 1998.
- Draisma, G., Kaashoek, J. F. e Dijk, H. K. A Neural Network Applied to Economic Time Series. Erasmus University Rotterdam, Econometric Institute. Report 9474B. 1994
- Haefke, C. e Helmenstein, C. Predicting Stock Market Averages to Enhance Profitable Trading Strategies. Society of Computational Economics. *Second International Conference on Computing in Economics and Finance*. Geneva, Switzerland, 26-28 June 1996.
- Hutchinson, J. M. A Radial Basis Function Approach to Financial Time Series Analysis. PhD Thesis, Massachusetts Institute of Technology, Department of Electrical Engineering and Computer Science, February, 1994. 159 pp.
- Jenkins, G. M. Practical Experiences with Modeling and Forecasting Time Series. 1st Ed. Gwilym Jenkins & Patners (Overseas) Ltd. GJP Time Series Library. 146 pp. Jersey:U.K. 1979.
- Klimasauskas, C. C. Accuracy and Profit in Trading Systems. *Advanced Technology for Developers*. pp 10-14. 1992.
- Levenbach, H., Cleary, J. P. The Beginning Forecaster: The Forecasting Process Through Data Analysis. Lifetime Learning Publications, Belmont, California. 1981. 372 pp.
- Lequarré, Jean Y. Foreign Currency Dealing: A Brief Introduction. pp 131-137. In Weingend, A. S. Gershenfeld, N. A. Eds. *Time Series Prediction: Forecasting the Future and Understanding the Past*. Addison-Wesley, 1994. 643 pp.
- Moody, J. e Saffell, M. Reinforcement Learning for Trading System and Portfolios. In: Agrawal, Rakesh. Piatetsky-shapiro, Gregory. Eds. KDD-98 - Proceedings of The Fourth International Conference on Knowledge Discovery and Data Mining. AAAI Press, California: 1998. pp 279-283.
- Refenes, A. N. Azema-Barac, M. Chen, L. Karoussos, S. A. Currency Exchange Rate Prediction & Neural Network Design Strategies. *Neural Computing & Applications*, Vol. 1, pp 46-58, 1993.
- Refenes, Apostolos-Paul. Testing Strategies and Metrics. pp. 67-76. In: *Neural Networks in the Capital Markets*. Edited by Refenes, Apostolos-Paul. John Wiley & Sons. England. ISBN 0-471-94364-9. 1995. 379 pp.
- Schumann, M. e Lohrbach, T. Comparing Artificial Neural Networks with Statistical Methods within the Field of Stock Market Prediction. 0-7803-2566-4/96. IEEE. 1996.
- Siegler, W. e Steurer, E. Forecasting of the German Stock Index DAX with Neural Networks: Using Daily Data for Experiments with Input Variable Reduction and a Modified Error Function. Pp 265-273. In: Ebecken, Nelson F. F. Editor. *Proceedings of The International Conference on Data Mining - Rio*, September, 1998. ISBN 1-85312-677-2.
- Weiss, S. M. e Indurkha, N. Predictive Data Mining: A Practical Guide. Morgan Kaufmann Publishers. 1998. 228 pp. San Francisc, USA.