



FELIPE DIAS PAIVA

**REDES NEURAIIS PARA DECISÕES NO
MERCADO DE AÇÕES BRASILEIRO**

LAVRAS - MG

2014

FELIPE DIAS PAIVA

**REDES NEURAIS PARA DECISÕES NO MERCADO DE AÇÕES
BRASILEIRO**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Administração, área de concentração em Gestão de Negócios, Economia e Mercados, para a obtenção título de Doutor.

Orientador

Dr. Ricardo Pereira Reis

LAVRAS - MG

2014

**Ficha Catalográfica Elaborada pela Coordenadoria de Produtos e
Serviços da Biblioteca Universitária da UFLA**

Paiva, Felipe Dias.

Redes neurais para decisões no mercado de ações brasileiro /
Felipe Dias Paiva. – Lavras : UFLA, 2014.
118 p. : il.

Tese (doutorado) – Universidade Federal de Lavras, 2014.
Orientador: Ricardo Pereira Reis.
Bibliografia.

1. Investimento. 2. Mercado de capitais. 3. Redes neurais
artificiais. 4. Modelo de decisão. I. Universidade Federal de Lavras.
II. Título.

CDD – 332.6322

FELIPE DIAS PAIVA

**REDES NEURAIIS PARA DECISÕES NO MERCADO DE AÇÕES
BRASILEIRO**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Administração, área de concentração em Gestão de Negócios, Economia e Mercados, para a obtenção título de Doutor.

APROVADA em 25 de abril de 2014.

| | |
|------------------------------------|----------|
| Dr. Antônio Carlos dos Santos | UFLA |
| Dr. Gideon Carvalho de Benedicto | UFLA |
| Dr. Arthur Rodrigo Bosco Magalhães | CEFET-MG |
| Dr. Rodrigo Tomás Nogueira Cardoso | CEFET-MG |

Dr. Ricardo Pereira Reis
Orientador

LAVRAS - MG

2014

A Deus.

Dedico.

AGRADECIMENTOS

À Universidade Federal de Lavras (UFLA) e ao Departamento de Administração e Economia (DAE), pela oportunidade concedida para realização do Doutorado.

Ao Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG), por incentivar uma melhor qualificação dos seus professores.

Ao meu orientador, Prof. Dr. Ricardo Pereira Reis, pela amizade, carinho e confiança. Serei sempre grato.

Ao Prof. Dr. Paulo Fernandes Sanches Junior, que nunca poupou palavras e gestos de incentivo.

Ao Prof. Dr. Rodrigo Cardoso, sempre pronto para promover riquíssimas discussões teóricas.

Aos membros do grupo de Estudos em Sistemas Complexos, em especial aos professores Arthur Rodrigo Bosco de Magalhães e Allbens Atman Picardi Faria.

Ao colega Gustavo Peixoto Hanaoka muito obrigado pela disposição e toda colaboração.

Aos alunos de iniciação científica, pelas diversas contribuições.

Em especial, à minha família, que sempre esteve presente quando eu mais precisei.

*Chegar ao topo e ser reconhecido é agradável,
mas a questão é o que se teve de deixar de lado para chegar lá,
incluindo a diversidade de vida e, mais, o essencial à vida.
Se a pessoa abandona o essencial, ela perde a identidade.*

Mário Sérgio Cortella

RESUMO

A presente pesquisa objetivou estruturar um modelo baseado na técnica de redes neurais artificiais para compra e venda de ativos financeiros do mercado de capitais brasileiro. Para tanto, delineou-se uma amostra de 28 ativos financeiros. O ponto de partida do estudo foi investigar se as séries temporais dos ativos comportam-se de forma aleatória ou não. Ficou comprovado que as séries podem ser consideradas como persistentes (coeficiente de Hurst maior que 0,5), descartando assim os preceitos teóricos da aleatoriedade. Este resultado reforçou ainda mais a proposta da pesquisa, ao sinalizar que é possível identificar padrões de comportamento na cotação dos preços das ações, estabelecendo condições básicas e desejáveis para que se utilizem dados passados como estratégia de precificação das mesmas. O passo seguinte foi projetar as redes neurais que iriam prever as cotações futuras dos ativos para um horizonte de até 5 dias. Para tanto, foram estruturados 50 arranjos diferentes de redes, com variações no número de neurônios ocultos e variáveis de entrada. Sendo que, estas variáveis de entrada foram definidas com base nos conhecimentos da análise técnica. Ao todo foram geradas 630.000 simulações, que foram avaliadas com base nas medidas de desempenho: erro médio quadrático (*EMQ*), coeficiente de explicação (R^2), *U-Theil* e *POCID*. Escolhidos os melhores arranjos de redes, testou-se suas capacidades preditivas para o período de 02/01/2013 a 15/10/2013. Como parte do modelo de decisões de compra e venda de ações foi proposto que o modelo também tivesse gatilhos de compra, definidos a partir de uma expectativa de ganhos mínimo e máximo, e que apenas seriam utilizadas as previsões das redes que, na fase de seleção, apresentaram um valor da estatística *U-Theil* inferior a 1. Para testar o modelo proposto foram realizadas algumas simulações. Sendo que numa destas simulações, o modelo alcançou uma rentabilidade anual de 70,56%. Rentabilidade está superior se comparado a investimentos individuais nos mesmos ativos da amostra e a fundos de ações disponíveis para investimentos no mercado.

Palavras-chave: Investimento. Mercado de ações brasileiro. Redes neurais artificiais. Modelo de decisão.

ABSTRACT

This piece of research aimed at structuring a model based upon the artificial neural networks technique for buying and selling financial assets in the Brazilian capital market. To carry the task on, a sample of 28 financial assets was devised. Investigating whether the temporal series would behave randomly or not was the initial task, and it was possible to observe that they could be considered as persistent (Hurst's coefficient is bigger than 0.5), which has ruled out the randomness theoretical assumptions. This result has reinforced the research proposition, since it has pointed out that it is possible to identify patterns of behavior in the stock prices, thus providing basic and desirable conditions to employ past data as a strategy for pricing. The next step was designing the neural networks to preview the future quotations of assets for a time span of five days. Fifty different network arrangements were structured, with variations on the number of hidden neurons and on entrance variables, defined according to technical analyses. 630.000 simulations were carried out, and were assessed by taking performance measures on account –Mean Squared Error (MSE), explanation coefficient (R^2), *U-Theil* and *POCID*. The best network arrangements were chosen, and their predictive capacities were tested during the period of 1/2/2013 to 10/15/2013. As part of the selling and buying decision model, some buying triggers have been proposed, based on the minimum and maximum earning expectation, and also that it only would be employed the nets whose forecasts had presented a value of the U-Theil statistics inferior to 1, during the selection stage. Simulations were carried out to test the proposed model. The model has reached an annual profitability of 70.56%, which was superior to individual investments on the sample assets and to equity funds available for investment.

Keywords: Investment. Brazilian capital markets. Artificial neural networks. Decision model.

LISTA DE FIGURAS

| | | |
|----------|--|----|
| Figura 1 | Áreas da curva normal..... | 23 |
| Figura 2 | Densidade do movimento browniano..... | 30 |
| Figura 3 | Construção de um <i>candle</i> | 36 |
| Figura 4 | Modelo de neurônio artificial | 45 |
| Figura 5 | Exemplos de funções de ativação..... | 47 |
| Figura 6 | Representação da arquitetura da MLP..... | 50 |
| Figura 7 | Modelo empírico da pesquisa..... | 58 |
| Figura 8 | Janelas para aprendizado e simulação da rede neural..... | 60 |

LISTA DE GRÁFICOS

| | | |
|------------|---|-----|
| Gráfico 1 | Distribuição dos arranjos das redes neurais selecionadas | 79 |
| Gráfico 2 | Sinais de compra do ativo PETR4 Simulação 2 | 95 |
| Gráfico 3 | Sinais de compra do ativo PETR4 Simulação 4 | 96 |
| Gráfico 4 | Distribuição dos arranjos das redes utilizadas nas simulações 3 e 4..... | 99 |
| Gráfico 5 | Rentabilidades anuais dos ativos e modelo de redes neurais | 103 |
| Gráfico 6 | Comparação de rentabilidades modelo de redes neurais versus ativos individuais | 104 |
| Gráfico 7 | Comparação de rentabilidades modelo de redes neurais versus ativos individuais | 105 |
| Gráfico 8 | Comparação de rentabilidades modelo de redes neurais versus ativos individuais | 106 |
| Gráfico 9 | Comparação de rentabilidades modelo de redes neurais versus ativos individuais | 107 |
| Gráfico 10 | Rentabilidade de fundos de ações e modelo de redes neurais..... | 108 |

LISTA DE QUADROS

| | | |
|----------|---|----|
| Quadro 1 | Comparação entre ser humano, sistemas inteligentes e convencionais..... | 43 |
| Quadro 2 | Amostra da pesquisa | 53 |
| Quadro 3 | Arranjos das redes neurais testadas..... | 64 |
| Quadro 4 | Resumo dos resultados das simulações..... | 93 |

LISTA DE TABELAS

| | | |
|-----------|---|-----|
| Tabela 1 | Estatística descritiva dos ativos pesquisados | 72 |
| Tabela 2 | Coeficiente de Hurst dos ativos | 74 |
| Tabela 3 | Resultados das simulações das redes do ativo PETR4 | 76 |
| Tabela 4 | Resultado das redes selecionadas do ativo PETR4..... | 81 |
| Tabela 5 | Resultado dareprodução das redes simuladas do ativo PETR4 | 81 |
| Tabela 6 | Resultados da Simulação 1 | 84 |
| Tabela 7 | Sinais de compra da Simulação 1 | 85 |
| Tabela 8 | Resultado Simulação 2..... | 86 |
| Tabela 9 | Sinais de compra da Simulação 2 | 87 |
| Tabela 10 | Resultado da Simulação 3..... | 89 |
| Tabela 11 | Sinais de compra da Simulação 3 | 90 |
| Tabela 12 | Resultado da Simulação 4..... | 91 |
| Tabela 13 | Sinais de compra da Simulação 4 | 92 |
| Tabela 14 | Distribuição dos sinais de compra da PETR4 para as simulações 2 e 4..... | 97 |
| Tabela 15 | Simulação de investimentos em ativos individuais..... | 102 |

LISTA SIGLAS

| | |
|-----------------|---|
| CAPM | <i>Capital asset pricing model</i> |
| EMA | Média móvel exponencial |
| IA | Inteligência artificial |
| IBOVESPA | Índice da bolsa de valores de São Paulo |
| HME | Hipótese de mercado eficiente |
| MA | Média móvel |
| MACD | Média móvel convergente e divergente |
| RN | Redes neurais |
| RSI | Índice de força relativa |

SUMÁRIO

| | | |
|---------|---|-----|
| 1 | INTRODUÇÃO..... | 15 |
| 2 | REFERENCIAL TEÓRICO..... | 19 |
| 2.1 | Teoria da especulação..... | 19 |
| 2.1.1 | <i>Random walk</i> | 24 |
| 2.2 | Análise técnica..... | 31 |
| 2.2.1 | Origem da análise técnica..... | 33 |
| 2.2.2 | Gráficos de <i>candlesticks</i> | 35 |
| 2.2.3 | Indicadores técnicos..... | 37 |
| 2.2.3.1 | Média móvel..... | 38 |
| 2.2.3.2 | Média móvel convergente e divergente..... | 40 |
| 2.2.3.3 | Índice de força relativa..... | 40 |
| 2.3 | Sistemas inteligentes..... | 41 |
| 2.3.1 | Redes neurais..... | 44 |
| 2.3.1.1 | <i>Perceptron</i> de múltiplas camadas..... | 49 |
| 3 | MATERIAL E MÉTODOS..... | 52 |
| 3.1 | Amostra e dados..... | 52 |
| 3.2 | Análise das séries financeiras: aleatórias ou previsíveis?..... | 54 |
| 3.3 | Modelo de compra e venda de ações..... | 58 |
| 3.3.1 | Previsão baseada na técnica de redes neurais..... | 59 |
| 3.3.1.1 | Janela do estudo..... | 59 |
| 3.3.1.2 | Variáveis de entrada e saída..... | 60 |
| 3.3.1.3 | Arranjos das redes neurais..... | 63 |
| 3.3.1.4 | Outras configurações das redes neurais..... | 66 |
| 3.3.1.5 | Seleção e reprodução do melhor arranjo de rede neural..... | 68 |
| 3.3.2 | Parâmetros gerais do modelo de decisão de compra e venda..... | 69 |
| 4 | RESULTADOS E DISCUSSÃO..... | 71 |
| 4.1 | Hipótese de <i>random walk</i> | 71 |
| 4.2 | Implementação da rede neural..... | 74 |
| 4.3 | Simulações do modelo..... | 82 |
| 4.3.1 | Simulação 1..... | 83 |
| 4.3.2 | Simulação 2..... | 86 |
| 4.3.3 | Simulação 3..... | 88 |
| 4.3.4 | Simulação 4..... | 90 |
| 4.3.5 | Análise das simulações..... | 92 |
| 4.4 | Desempenho comparativo..... | 101 |
| 5 | CONCLUSÃO..... | 110 |
| | REFERÊNCIAS..... | 114 |

1 INTRODUÇÃO

Muito se questiona sobre a real possibilidade e a capacidade de prognosticar preços futuros de um ativo financeiro tendo como ponto de partida seus dados históricos. A temática, inevitavelmente, é um dos assuntos mais instigantes no estudo das finanças.

Inúmeros pesquisadores já se dedicaram à procura de dados passados que permitissem explicar e inferir valores futuros do mercado acionário, possibilitando, assim, ganhos extraordinários.

Contudo, a *mainstream* da teoria financeira repousa sobre os fundamentos da Hipótese de Mercado Eficiente (HME) que, por sua vez, defende que a tarefa de prever preços futuros, tendo como base comportamentos passados de um ativo financeiro, é um procedimento ineficaz, pois a distribuição de uma série financeira advém de um movimento *browniano*, que é concebido por características randômicas e independentes. Alexander, Sharper e Bailey (2000, p. 73) complementam afirmando que “*a market is efficient with respect to particular set of information if it is impossible to make abnormal profits (others than by chance) by using this set of information to formulate buying and selling decisions*”.

Porém, na contramão da concepção de mercado eficiente, alguns estudos defendem que o mercado acionário, na verdade, não se firma como aleatório e que as séries financeiras têm memória de longo-prazo. Dessa forma, desde que identificados padrões de comportamento, torna-se factível delinear algum modelo de previsibilidade.

Frente a essas lacunas e desafios, têm se destacado, nos últimos anos, importantes avanços no ramo das finanças computacionais, mostrando ser uma linha de pesquisa promissora.

Assim, modelos baseados em técnicas de inteligência artificial apresentam-se como bastante interessantes, graças à sua capacidade de tratar dados complexos, imprecisos e volumosos. Com o propósito de explorar seus conceitos, na presente pesquisa propõe-se explorar o uso da técnica de redes neurais artificiais.

A rede neural artificial é uma técnica de inteligência artificial que estrutura sua dinâmica de processamento de dados inspirada na arquitetura do cérebro humano. Os estudos dessa técnica, em questões no âmbito das finanças, têm se mostrado bastante eficientes, principalmente em decorrência da possibilidade de trabalhar com dados ruidosos (incompletos, inconsistentes e ambíguos), além de prever sistemas não lineares.

[...] o modelo linear pode não ser preciso o bastante para aplicação em mercados financeiros voláteis, nos quais podem ocorrer processos não lineares na evolução de dados. Movimentos lentos com aumento consistente dos preços dos ativos, seguidos por colapsos repentinos conhecidos como bolhas especulativas, são comuns de acontecer. Dessa forma, o modelo linear pode falhar em capturar ou prever pontos de mudança acentuada nos dados (LIMA et al., 2009, p. 38).

Mas, o êxito dessa ferramenta oriunda da corrente teórica denominada de inteligência artificial, que propõe métodos computacionais inspirados na “máquina” humana, depende inexoravelmente da qualidade das variáveis de entrada, pois, como mencionado anteriormente, a previsão de preços futuros de ativos financeiros, tendo como base o passado, dependerá da capacidade de identificar padrões de comportamento. Frente a este cenário, na presente tese almeja-se responder ao seguinte questionamento: é possível estruturar um modelo baseado na técnica de redes neurais que seja capaz de tomar decisões de compra e venda de ativos financeiros do mercado de capitais brasileiro, com fins de possibilitar níveis de rentabilidade atrativos para um investidor?

Para tanto, pretende-se utilizar conceitos da análise técnica que, apesar de toda a polêmica que paira sobre sua proposta teórica, identifica-se como coerente com os argumentos até aqui utilizados e defendidos. Ou seja, buscou-se, por meio de indicadores técnicos, “alimentar” o modelo decisório proposto com informações que permitissem traduzir o comportamento do mercado financeiro.

Assim, quando se alega coerência entre a análise técnica e as bases do presente estudo, deve-se enfatizar que a concepção da análise gráfica defende que há uma relação de dependência no *continuum* da série histórica dos ativos que permite identificar padrões de tendência a partir do comportamento passado. De acordo com Fama (1965, p. 55), “*the basic assumption of all the chartist or technical theories is that history tends to repeat itself, i.e., past patterns of price behavior in individual securities will tend to recur in the future*”.

Dessa forma, o objetivo geral, no presente trabalho, foi estruturar um modelo baseado na técnica de redes neurais para a tomada de decisão de compra e venda de ativos financeiros do mercado de capitais brasileiro, explorando, para tanto, conhecimentos da análise técnica.

Como desdobramento do objetivo geral, definiu-se os seguintes objetivos específicos:

- a) investigar se as séries temporais dos retornos das principais ações do mercado brasileiro apresentam existência de memória de longo prazo, a fim de confirmar ou descartar a hipótese de *random walk*;
- b) construir um modelo baseado em redes neurais artificiais para auxiliar na tomada de decisão de compra e venda de ativos financeiros do mercado de capitais brasileiro;

- c) comparar a rentabilidade provida pelo modelo delineado na presente tese com outros possíveis investimentos disponíveis no mercado brasileiro.

Por fim, ressalta-se que esta pesquisa poderá contribuir com a discussão histórica a respeito da pertinência ou não do uso de dados passados para prever preços futuros do mercado financeiro, mais especificamente do mercado brasileiro. É esperado reforçar o discurso da necessidade de repensar as bases dos principais modelos da teoria das finanças modernas, que estão arraigados na proposta da hipótese de mercado eficiente que, por sua vez, tem um papel determinante na concepção dos decisores-chave do processo de investimento: risco e retorno.

Ao reafirmar que há uma importante lacuna que separa o teórico do empírico, é esperado que a comunidade acadêmica empreenda esforços para desenvolver alicerces mais coerentes com o real comportamento do mercado financeiro, a fim de refinar os padrões de gestão do risco e retorno.

Assim, uma vez que as séries históricas dos ativos e períodos pesquisados apresentem padrões de memória longa persistente, isso somente reforçará o discurso da pertinência de buscarem-se modelos que identifiquem padrões de comportamento na cotação dos preços desses ativos financeiros.

Aliado a isso, apresentam-se os avanços computacionais ocorridos nas últimas décadas, servindo de estímulo para o desenvolvimento de modelos de previsão arraigados nesse tipo de tecnologia e que façam uso também de técnicas de sistemas inteligentes, dada a capacidade destas de gerir melhor sistemas com arquiteturas complexas.

2 REFERENCIAL TEÓRICO

2.1 Teoria da especulação

O título desta seção nada tem a ver com a concepção negativa e pejorativa que a palavra especulação adquire em diversas situações. Na verdade, trata-se de uma alusão à tese de doutorado em Matemática de um homem que esteve à frente de sua época. Mas, antes de debater a respeito do seu trabalho, recorre-se, aqui, ao dicionário para destacar o real significado que se pretende abordar no emprego da palavra especulação. Assim, define-se a mesma como “Examinar com atenção; averigar minuciosamente; observar; indagar; pesquisar. [...] Operar na bolsa, jogando na alta ou na baixa dos títulos” (FERREIRA, 1988, p. 566).

Feito o devido destaque, para que não haja qualquer ruído na proposta do texto, ressalta-se que a atual corrente dominante da Administração Financeira, denominada Moderna Teoria Financeira, teve seu início em 29 de março de 1900. Naquele ano, o francês Louis Jean-Baptiste Alphonse Bachelier defendeu sua tese de doutorado em Matemática, intitulada “*Théorie de la Spéculation*”.

Infelizmente, Bachelier não gozou em vida do justo reconhecimento¹ da importância que seus estudos tiveram para o desenvolvimento da Administração Financeira. Numa vã tentativa de justificar o porquê da sua teoria não ter sido, a contento da sua época, laureada por suas significativas contribuições para o mundo científico, Mandelbrot e Hudson (2004) citam que, em se tratando de um

¹ Segundo Bernstein (1992), a tese de Bachelier esteve “ignorada” até que Jimmie Savage, um estatístico matemático de Chicago, redescobriu-a acidentalmente, na década de 1950. Savage, então, chamou a atenção do economista Paul Samuelson sobre o trabalho de Bachelier, que foi encontrar um exemplar da sua tese na biblioteca do MIT. A partir deste momento, o mundo acadêmico despertou para as contribuições de Bachelier no âmbito econômico.

doutoramento em matemática, o objeto de estudo não despertava, para aquele período histórico, nenhum interesse entre os matemáticos, pois não abordava uma discussão de números complexos, teoria das funções, equações diferenciais ou algum outro assunto considerado de relevância. Isso acabou por refletir no conceito da avaliação da sua tese, que foi classificada pela banca como honrosa.

Contudo, esse conceito não tinha o “peso” necessário para credenciar um recém-doutor a ocupar uma “cadeira” em alguma universidade francesa. Segundo Taqqu (2001, p. 7), uma tese que recebia a menção de honrosa enseja, em linhas gerais, a seguinte mensagem: *that's very good, mister, so long*. Apenas as teses com o conceito muito honroso oportunizavam que os seus autores pleiteassem uma vaga na academia. Prova disso é que somente no ano de 1927 Bachelier conseguiu ocupar um posto de professor efetivo na Universidade de Besançon.

Mas, afinal do que se tratava a tese de Bachelier e quais foram as suas contribuições para a moderna teoria financeira? De acordo com Mandelbrot e Hudson (2004), Bachelier “aventurou-se” a escrever sobre o mercado acionário francês, o que se constituiu numa proposta um tanto quanto arrojada, pois a temática mercado financeiro nem mesmo ostentava o *status* de disciplina acadêmica, apesar de já existirem algumas pouquíssimas opções bibliográficas. Época, aliás, em que as bolsas de valores já ocupavam uma posição de destaque para a saúde financeira das economias mundiais, haja vista que, naquela época, a Bolsa de Valores de Paris transacionava títulos da dívida pública do governo francês, sendo estes, por sua vez, uma das principais fontes de financiamento dos projetos daquele governo. Para que se tenha uma ideia, no ano de 1900, o governo francês já havia lançado no mercado um total de 26 bilhões de francos em títulos de renda, contra um orçamento público anual de 4 bilhões (TAQQU, 2001).

Nesse contexto, a proposta de Bachelier foi a de investigar as flutuações dos títulos do governo francês. Seu estudo centrava-se em associar as leis da probabilidade aos movimentos dos preços desses títulos. A sua hipótese resumiu-a se em: *“prices are not predictable, but their fluctuations can be described by the mathematical laws of chance. Therefore, their risk is measurable, and manageable”*(MANDELBROT; HUDSON, 2004, p. 9).

Conforme Taqqu (2001), os resultados alcançados por Bachelier devem-se, em grande parte, à notoriedade dos seus professores, que estiveram presentes na sua formação acadêmica na Sorbonne, Paris/França, desde os tempos de graduação, entre eles, destaque para Charles Émile Picard², Joseph Valentin Boussinesq³ e Jules Henri Poincaré⁴ (seu orientador de doutorado). É perceptível a presença, na sua tese, da interdisciplinariedade de assuntos abordados na física e na matemática, assuntos estes os quais os professores destacados lecionavam e pesquisavam.

The influences which determine fluctuations on the Exchange are innumerable; past, present, and even discounted future events are reflected in market price, but often show no apparent relation to price changes.

[...]The determination of these fluctuations depends on an infinite number of factors; it is, therefore, impossible to aspire to mathematical prediction of it. Contradictory opinions concerning these changes diverge so much that at the same instant buyers believe in a price increase and sellers in a price decrease.

² Charles Émile Picard: matemático francês (24/07/1856 – 11/12/1941), cujas principais contribuições foram nas áreas de análise, teoria da função, equações diferenciais e geometria analítica.

³ Joseph Valentin Boussinesq: matemático e físico francês (13/03/1842 – 19/02/1929) que fez importantes contribuições para as teorias da hidrodinâmica, vibração, luz e calor.

⁴ Jules Henri Poincaré: Matemático francês (29/04/1854 – 17/07/1912), foi responsável por uma série de inovações profundas na geometria, a teoria de equações diferenciais, eletromagnetismo, topologia, e a filosofia da matemática. Considerado um dos maiores matemáticos e físicos matemáticos do final do século XIX.

The calculus of probabilities, doubtless, could never be applied to fluctuations in security quotations, and the dynamics of the Exchange will never be an exact science.

But it is possible to study mathematically the static state of the market at a given instant, to establish the law of probability of price changes consistent with the market at that instant. If the market, in effect, does not predict its fluctuations, it does assess them as being more or less likely, and this likelihood can be evaluated mathematically (BACHELIER, 1900, p. 18).

A proposta de Bachelier fundamentou-se na ideia de que os preços dos títulos têm uma série temporal de estado independente e de distribuição normal. Conforme Andreasen, Jensen e Poulsen (1999), Bachelier defendeu que as flutuações dos títulos comercializados na bolsa de valores podem ser retratadas a partir de um processo aleatório, em que seus movimentos são erráticos e imprevisíveis, podendo, assim, ser descritas partir das leis matemáticas de probabilidade.

Dessa forma, Bachelier (1900) destacou que o processo de flutuação de preços dos títulos é passível de ser descrito pelas leis da probabilidade e que existem apenas duas situações que retratam seu estado de mudança: valorização ou desvalorização. Pode-se aferir então, que este processo de flutuação, por sua vez, é análogo a um jogo honesto de moeda, em que o seu lançamento resultará em apenas uma face descoberta: “cara” ou “coroa”. Assim, tal como numa situação em que repetidas vezes uma moeda é lançada, o resultado ora é cara, ora é coroa.

No mercado financeiro, segundo a teoria de Bachelier, firmada nas ideias do movimento browniano, o resultado esperado⁵ por um especulador, após n períodos de tempo, sempre será zero. Ou seja, entre contínuos e descontínuos

⁵ O resultado esperado por um especulador pode ser representado pela medida estatística conhecida como média. Sua fórmula é $\left(\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i\right)$.

resultados de alta e de baixa dos preços dos títulos, haverá um momento em que estes se equilibram e se anulam, estabelecendo uma distribuição que segue os preceitos do teorema do limite central⁶.

Uma vez que a série de flutuações dos títulos segue a uma distribuição normal (Gaussianna), infere-se que o desvio padrão⁷ descreverá a dispersão da distribuição. Em atenção a todas essas condições, tem-se que 68% das observações (ganho e perda) encontram-se entre o deslocamento de um desvio padrão em relação à média; 95% das observações são apontadas entre dois desvios padrões da média e 99,7% entre três desvios padrões da média (GUJARATI, 2006), o que está graficamente representado pela Figura 1.

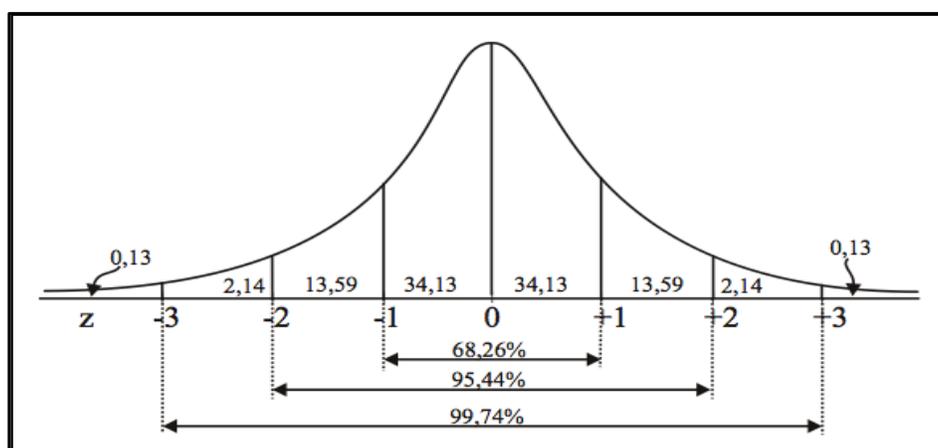


Figura 1 Áreas da curva normal

Fonte: Adaptada de Gujarati (2006)

⁶ O teorema do limite central apregoa que, havendo um grande número de variáveis aleatórias independentes e com distribuição idêntica, a soma da sua distribuição tenderá à normalidade.

⁷ Desvio padrão: trata-se de uma medida de dispersão que objetiva apresentar o quanto de dispersão há em relação à média. Tradicionalmente, é a medida utilizada para

avaliar o risco. Sua fórmula é

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$$

2.1.1 *Random walk*

Inegavelmente, um dos grandes legados da obra de Bachelier para a Administração Financeira foi discutir que os retornos das ações seguem o movimento browniano, ou seja, que as variações de preços das ações podem ser descritas por um comportamento de *random walk* (caminho aleatório).

Contudo, conforme já citado anteriormente, apesar da importância das ideias apresentadas por Bachelier, pois sustentam, direta ou indiretamente, todas as “grandes” teorias da Moderna Administração Financeira, elas apenas se tornaram conhecidas do grande público acadêmico a partir da década de 1950. Este período coincide com um dos principais estudos da mencionada corrente que, ainda hoje, tem seus conceitos propagados de forma dominante.

Um dos primeiros e mais impactantes estudos dessa nova era é atribuído às pesquisas de Harry Max Markowitz. Em sua tese de doutorado em economia, Markowitz propôs um modelo de diversificação de ações, a partir do binômio risco-retorno, traduzidas pelas medidas média e variância. A distribuição gaussiana e o comportamento aleatório das ações são pressupostos básicos e essenciais para a teoria de diversificação.

Numa sequência histórica, tem-se o desenvolvimento da teoria denominada como *capital asset pricing model* (CAPM), sendo William Forsyth Sharpe o principal nome desse constructo teórico, mas que recebeu expressivas colaborações de James Tobin, John Virgil Lintner e Jan Mossin. O CAPM apresenta uma forma simplificada e prática de projetar a expectativa de ganho de um investidor. Segundo Peters (1991), o CAPM é também uma ferramenta bastante útil para o processo decisório de análise de investimentos em ativos permanentes. Mais uma vez, atribuir à série histórica de uma ação a lógica de uma distribuição gaussiana e um comportamento aleatório é básico e fundamental.

Outro estudo de destaque remonta às pesquisas de Fischer Sheffey Black, Myron Samuel Scholes e Robert C. Merton, que propõem um modelo capaz de precificar opções.

Assim, de acordo com Volchan (1999), o desenvolvimento dos citados modelos financeiros contribuíram fortemente para a dominação dos processos estocásticos no âmbito das discussões financeiras, sendo que a teoria dos processos estocásticos firma-se como um tópico central da teoria da distribuição probabilística. Conforme Gujarati (2006, p. 638), “um processo aleatório ou estocástico é um conjunto de variáveis aleatórias ordenadas no tempo”.

Segundo Dixit e Pindyck (1994), pode-se representar uma estrutura básica de *random walk* por meio da seguinte equação:

$$y_t = y_{t-1} + \delta_t \quad (1)$$

Em que: $y_t = \ln P_t$

$$y_{t-1} = \ln P_{t-1}$$

P_t = preço da ação no tempo t

$$t \in \mathbb{Z}$$

δ_t = componente aleatório

A partir desta equação é possível perceber que o preço de ação no tempo t é dado pelo preço desta mesma ação no tempo $t-1$ mais um choque aleatório

(δ_t) . Esta variável aleatória também é conhecida como ruído branco⁸ (*white noise*). De acordo com Bueno (2011), uma série temporal será considerada estocástica se a variável aleatória tiver média zero, variância constante e autocorrelação igual a zero (série não correlacionada). Ou seja, uma série temporal corresponderá a um processo *random walk* se e somente se uma sequência de variáveis aleatórias assumir as seguintes condições:

$$\begin{aligned} E(\delta_t) &= 0; \forall t \\ E(\delta_t^2) &= \sigma^2; \forall t \\ E(\delta_t \delta_{t-j}) &= 0, \text{ todo } j \neq 0 \end{aligned}$$

Em relação à teoria financeira, Volchan (1999) expõe que as investigações que centram seus esforços em entender como os indivíduos aplicam seus recursos monetários irão delinear seus modelos econométricos conforme os fatores: tempo (discreto ou contínuo)⁹, natureza (estocástico ou determinístico)¹⁰ e estado das variáveis (estacionário ou não estacionário)¹¹.

⁸ É chamado ruído branco porque sua função densidade espectral é horizontal como a luz branca e o processo provoca alterações na série assim como as ondas eletromagnéticas produzem ruídos na sintonização de um rádio (BUENO, 2011, p. 19).

⁹ Fator tempo: 1) Discreto: trata-se de uma variável em que o valor a ela atribuído poderá ser contado, isto é, é aquela para a qual um determinado conjunto é finito ou infinito enumerável; 2) Contínuo: pode receber qualquer valor numérico em um determinado intervalo.

¹⁰ Natureza: 1) Estocástico: é assim considerado quando o estado atual do processo não determina completamente o seu estado seguinte. As variáveis que compõem esse modelo são de características aleatórias; 2) Determinístico: tem-se, aqui, a possibilidade de explicar as variações espaço-temporais a partir das relações funcionais unívocas de um número limitado de variáveis.

¹¹ Estado: 1) Estacionário: as medidas “média”, “variância” e “autovariância” permanecem constantes, não importando em qual ponto está sendo mensuradas, ou seja, não variam com o tempo; 2) Não estacionário: nesse caso haverá uma média que varia ou uma variância que varia com o tempo, ou ambas as situações.

Especificamente o modelo abordado por Bachelier (1900) está apoiado na concepção de processo estocástico não estacionário de tempo contínuo. Ou seja, Bachelier (1900) propôs um modelo no qual os preços do mercado mobiliário evoluíam ao longo do tempo de maneira correlata ao movimento browniano.

O nome de movimento browniano advém da homenagem que se faz ao botânico escocês Robert Brown que, em 1827, por meio de um estudo microscópico, constatou que minúsculos grãos de pólen em suspensão em um líquido se movimentavam de forma errática. Ele apurou também que quanto menores as partículas de pólen mais rápido era o seu deslocamento, e que os movimentos também eram influenciados pelo calor e viscosidade do líquido (WIERSEMA, 2008).

Há que se ressaltar que Bachelier (1900) foi pioneiro no uso das ideias de Brown e que o seu propósito era de aplicação do modelo e não de aperfeiçoá-lo nas conclusões do evento físico de que trata a experiência de Robert Brown. De acordo com Volchan (1999), o rigor matemático e estatístico da experiência das partículas de grão de pólen seria mais tarde explicado por Albert Einstein, em 1905, por Marian Smoluchowski, em 1906 e, principalmente, por Norbert Wiener, em 1923.

Segundo Wiersema (2008), a análise física do modelo browniano sugere que:

- a) trata-se de um evento contínuo;
- b) os deslocamentos temporais de uma partícula são independentes;
- c) cada evento de deslocamento é causado por um bombardeamento independente de um grande número de moléculas em que, de acordo com o teorema do limite central da probabilidade, a soma de um

grande número de variáveis aleatórias idênticas e independentemente distribuídas (*i.i.d.*) pressupõe uma distribuição normal;

- d) o movimento ocorre de maneira irregular, sem assumir qualquer direção preferida;
- e) em decorrência da posição da partícula se “espalhar” com o tempo, assume-se que a variância do evento é proporcional ao comprimento do tempo em que o movimento é observado.

Assim, de acordo com Dixit e Pindyck (1994), o movimento browniano fundamenta-se em três pressupostos básicos: a) processo de Markov; b) incrementos independentes e c) distribuição normal.

a) Processo de Markov

Segundo o processo de Markov, o valor de uma variável em t dependerá, única e exclusivamente, do valor da mesma variável em $t-1$. Os valores em $t-2$, $t-3$ e $t-n$ são irrelevantes nesse processo, uma vez que se conhece o valor em $t-1$. Ou seja, entende-se que basta a informação atual para prever a trajetória futura do processo. A ideia apregoada é a de que os preços das ações são frequentemente modelados como processos de Markov, com o fundamento de que a informação pública é rapidamente incorporada no preço atual da ação, de modo que o padrão de preços do passado não tem valor de preditório. Tal descrição foi, então, utilizada para a fundamentação da hipótese de mercado eficiente (HME).

Segundo Fama (1991), a hipótese de mercado eficiente se comprova quando os preços das ações refletem toda a informação disponível¹². Alexander, Sharper e Bailey (2000, p. 73) completam afirmando que “*a market is efficient with respect to particular set of information if it is impossible to make abnormal profits (others than by chance) by using this set of information to formulate buying and selling decisions*”.

Ross, Westerfield e Jaffe (2002) condensam os dois pensamentos anteriores, afirmando que, devido ao fato de os preços das ações refletirem as informações disponíveis, os investidores não devem esperar mais que uma taxa de retorno normal. O conhecimento da informação não capacita nenhum investidor a conseguir taxas melhores de retorno. O preço ajusta-se antes que se negocie a ação de posse da informação; os tomadores de recursos devem esperar receber o preço justo dos títulos que vendem, ou seja, o preço que é recebido pela venda dos títulos deve ser igual ao seu valor presente. Portanto, em mercados eficientes de capitais não aparecem oportunidades valiosas de financiamento decorrentes de se enganar os investidores.

De acordo com Brealey e Myers (1998, p. 323), caso o mercado de capitais seja eficiente, “a compra ou venda de qualquer valor mobiliário ao preço vigente no mercado nunca será uma transação com valor presente líquido positivo”.

¹² Segundo Fama (1991), alguns tipos de informações afetam os preços das ações em *timing* diferente, para lidar com estas diferentes reações, ele classificou a HME em três tipos distintos, a depender da influência da informação:

- a) Forma fraca: este tipo de eficiência reflete apenas informações de preços passados; não incorpora qualquer outro tipo de informação;
- b) Forma semiforte: neste tipo, os preços dos títulos refletem qualquer tipo de informação disponível ao público;
- c) Forma forte: os preços refletem todas as informações, as publicamente disponíveis e, inclusive, as não disponíveis.

b) Incrementos independentes

A sinalização de que o movimento browniano tem incrementos independentes significa que a distribuição de probabilidade, para a alteração no processo por meio de qualquer intervalo de tempo, é independente de qualquer outro intervalo de tempo (não sobrepostas).

A distribuição de probabilidade depende apenas do espaçamento de tempo e é a mesma para todos os intervalos de tempo que têm o mesmo comprimento. À medida que o desvio padrão no tempo t é \sqrt{t} , quanto mais tempo o processo tenha sido executado, mais espalhada é a densidade, tal como ilustrado na Figura 2.

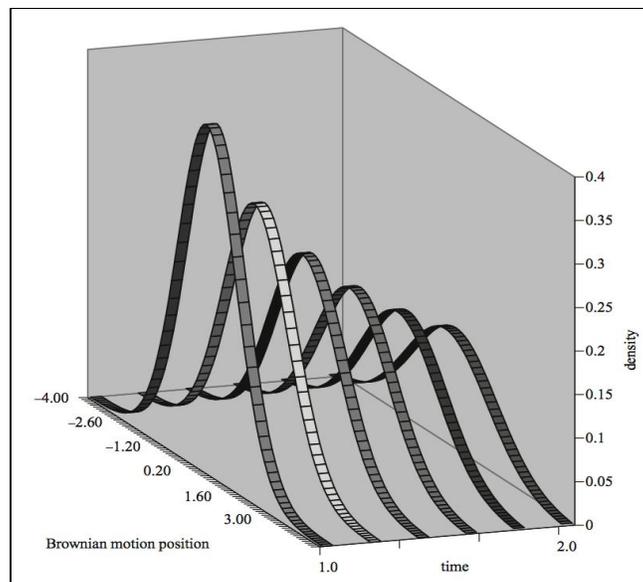


Figura 2 Densidade do movimento browniano

Fonte: Wiersema (2008, p. 4)

c) Distribuição normal

A última propriedade que um movimento browniano precisa atender refere-se à necessidade de que as alterações no processo, frente a qualquer

intervalo de tempo finito, devem ser normalmente distribuídas, com uma variância que aumenta linearmente com o intervalo de tempo. De acordo com Costa (2012), as propriedades de uma distribuição normal são as seguintes:

- a) a variável aleatória δ pode assumir todo e qualquer valor do conjunto de números reais;
- b) o formato da distribuição normal assemelha-se ao formato de um sino;
- c) a área total limitada pela curva e pelo eixo da abscissa é igual a 1;
- d) a curva normal é assintótica em relação ao eixo da abscissa, contudo, não chega a tocá-la;
- e) o formato simétrico da curva em torno da média indica que a probabilidade de surgir um valor maior que a média é igual à probabilidade de ocorrer um valor menor do que a média.

Assim, tem-se que a variável aleatória responde à distribuição normal padrão, desde que $\delta \sim N(0,1)$.

2.2 Análise técnica

Diferentemente da corrente teórica do *random walk*, que estabelece que há uma relação de independência entre as mudanças sucessivas dos preços das ações, bem como rechaça a ideia de que preços passados podem ser utilizados para prever valores futuros, a análise técnica, ou análise gráfica, firma-se com concepções opostas, uma vez que crê existir uma relação de dependência no *continuum* da série histórica dos ativos. Sendo assim, é possível identificar padrões de tendência a partir do comportamento passado que corroborarão com a definição de investimentos futuros.

De acordo com Fama (1965, p. 55), *“the basic assumption of all the chartist or technical theories is that history tends to repeat itself, i.e., past patterns of price behavior in individual securities will tend to recur in the future”*.

Para tanto, a análise técnica tem como foco de estudo a tendência do mercado. Segundo Pring (2002, p. 3), *“the art of technical analysis, for it is an art, is to identify trend changes at an early stage and to maintain an investment position until the weight of the evidence indicates that the trend has reversed”*. Assim, é possível inferir que a análise técnica tem como indicativo de decisão fatores concernentes à predição e à reação.

Dessa forma, a análise técnica apresenta-se sob uma perspectiva contrária à teoria fundamentalista, dado o fato de que ela ignora totalmente as possíveis justificativas econômicas e financeiras que se propõem a explicar um determinado preço de um ativo financeiro e suas oscilações. O que importa para ela é a força imprimida pelos investidores vendedores e compradores, ou seja, o comportamento dos agentes econômicos sob a luz da demanda e da oferta de títulos mobiliários é o que realmente importa. Observações baseadas nesses comportamentos, alcançados por meio de movimentos de preços e volumes negociados passados, permitirão prever se o movimento futuro de um ativo tenderá a ser de alta, de baixa ou lateral.

Corroborando esse pensamento, de acordo com Brum (2006), a análise técnica fundamenta-se em três concepções básicas que são:

- a) o preço das ações traduz todos os sentimentos do mercado: o preço diário do ativo nada mais é que um holograma das expectativas e comportamento dos investidores;

- b) o preço das ações move-se por meio de tendências: o investidor deverá operar a partir da identificação da tendência que o gráfico de um ativo está apontando;
- c) o futuro com base em estudos passados: o mercado tem memória dos acontecimentos passados; assim, acredita-se que comportamentos passados tendem a se repetir no futuro. Dessa forma, o passado pode guardar a resposta para tendências futuras.

Nesse sentido, é importante ressaltar que a análise técnica é vista sob forte suspeição entre os membros da academia. Conforme Fama (1965), a análise técnica ostenta certo grau de misticismo, quase que uma extensão da astrologia. Contudo, um grande número de profissionais do mercado financeiro refuta essa concepção. Eles dizem conseguir bons resultados operando sob os fundamentos técnicos.

Vale frisar que essa repulsa pela análise técnica é até certo ponto natural, dado que ela se ancora numa posição oposta aos preceitos do mercado eficiente, que, por sua vez, sustentam a maioria das teorias da administração financeira moderna.

2.2.1 Origem da análise técnica

Por falta de registros históricos, não há uma defesa conclusiva a respeito da verdadeira origem da análise técnica. A maioria dos pesquisadores que já se prestaram a pesquisar a temática restringe-se a apontar sua origem a partir do caso de sucesso mais longínquo de que se tem conhecimento. Este, por sua vez, é atribuído a Sokyo Honma, que conseguiu acumular riqueza operando no mercado japonês de *commodities* durante o século XVIII (NISON, 1991).

Segundo Kirkpatrick e Dahlquist (2009), Honma deixou registradas

algumas regras que o ajudaram a construir sua fortuna. Entre elas, podem-se citar: estudar os preços de hoje na tentativa de prever o preço de amanhã; avaliar os preços do arroz de três dias, com a intenção de aferir o preço do quarto dia, além de construir uma taxa de análise de mudança. Contudo, há quem defina essas regras como puramente de negociação, em vez de regras técnicas, pois, conforme consta, elas tinham muito mais a intenção de limitar perdas e definição do *timing* para sair de um negócio. Porém, por considerar que os métodos continham um forte apelo técnico para o seu período, dá-se o crédito aos mesmos como sendo o ponto de partida da análise técnica.

Mas, conforme Kirkpatrick e Dahlquist (2009), apesar das suspeitas, a falta de registros consistentes impede que se atribua a origem da análise técnica ao período de intercâmbios na Europa Medieval ou, mesmo, ao Japão, no que tange ao período do comércio de prata, por volta de 1870, tendo envolvimento de um cidadão de origem inglesa.

No entanto, embora não haja plena certeza da origem da análise técnica, quanto ao título de pai da “moderna teoria técnica” para Charles H. Dow não há quem discuta. Ressalta-se, ainda, ao que tudo indica, que ele nunca teve a intenção de desenvolver uma teoria formal sobre análise técnica. Mas, seus conjuntos de textos publicados no *The Wall Street Journal*, focados nos movimentos do mercado e na elaboração de suas médias, o credenciaram a tanto (SEETHER, 2009).

Contudo, pode-se dizer que a teoria da análise técnica desenvolvida por Charles Dow, entre o final do século XIX e o início do século XX, evoluiu consideravelmente, principalmente com o advento da popularização do acesso aos microcomputadores, a propagação das informações via rede mundial de computadores e a incorporação, pelos mercados ocidentais, da técnica de gráficos de *candlesticks*.

2.2.2 Gráficos de *candlesticks*

De acordo com Rhoads (2008), o estudo dos preços passados de ativos financeiros na forma de gráficos de *candlesticks* poderá possibilitar ao investidor prever acontecimentos futuros, pois os analistas gráficos acreditam que histórias passadas tendem a se repetir e que a leitura de gráfico de *candlesticks* torna essa assimilação mais ágil e fácil, dada a pretensa simplicidade que ele sustentaria. Porém, ainda conforme Rhoads (2008), as decisões ancoradas com o uso dos *candlesticks* não garantem a plena certeza de rendimentos futuros de investimentos.

Segundo Nison (1991), o estudo dos gráficos de *candlestick* poderá auxiliar o investidor a reconhecer padrões de mudança da tendência e de comportamentos de base emocional do mercado. Para Pring (2002), o movimento dos preços de uma ação apresenta tendências relacionadas a esperança, medo, conhecimento, otimismo e ganância dos participantes do mercado. A soma total dessas emoções se expressa no nível de preços.

Ou seja, o foco dos *candlesticks* repousa numa proposta de identificação de reversão de padrão do preço de uma ação, tentando, assim, reconhecer possíveis movimentos ascendentes (*bull*) ou descendentes (*bear*), e que, por consequência, desencadeariam decisões de compra ou venda dessa ação.

Para elaborar o gráfico de *candlesticks* serão necessários, de acordo com Murphy (1999), informações relativas a abertura, fechamento, máximo e mínimo da ação. Estas informações deverão ser apresentadas na escala temporal que se deseja trabalhar. De posse dessas informações, é traçada uma linha vertical, sendo o seu comprimento determinado pelos valores de máximo e de mínimo. Para demarcar as posições de abertura e de fechamento, faz-se uma linha de espessura maior, a fim de frisar essas posições. O seu tamanho dependerá dos valores de abertura e de fechamento. Essa marcação receberá o nome de

“corpo”, sendo que, por convenção geral, quando o “corpo” do *candle* estiver hachurado, indicará que o preço de abertura da ação foi superior ao do fechamento. Quando o corpo for transparente, tem-se o contrário, valor do fechamento maior que o da abertura. Com relação às linhas de espessuras mais finas, presentes entre o “corpo” do *candle* e os valores de máximo e mínimo, denominam-se as mesmas como “sombra superior” e “sombra inferior”. Para visualizar a construção do *candle*, vide Figura 3.

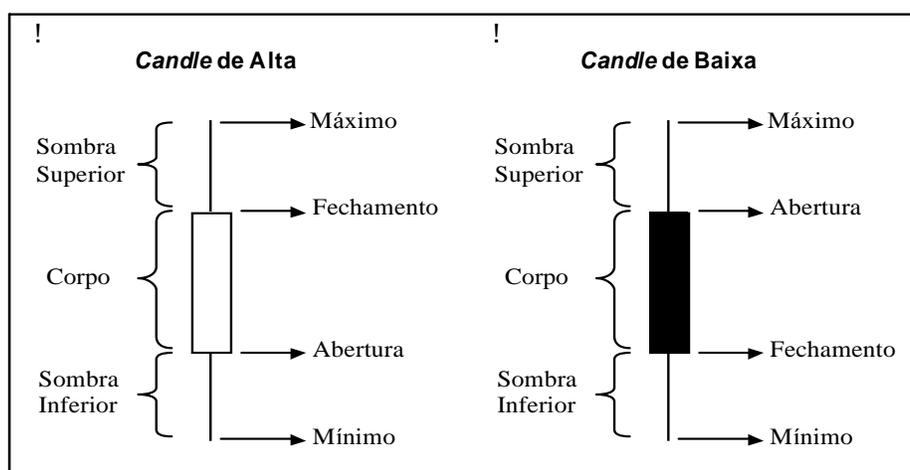


Figura 3 Construção de um *candle*

Uma vez construído o gráfico de *candlestick*, é necessário que se identifiquem os *candles*, bem como sua sequência, pois, em determinadas situações, a sequência de *candles* tem uma capacidade de informação mais eficaz para a tomada de decisão, do que se estes fossem avaliados isoladamente. Bulkowski (2008), Edwards, Magee e Bassetti (2007), Morris (2006), Nison (1991), Pring (2002) e Rhoads (2008) têm trabalhos que são referência sobre *candles*, nos quais eles nomeiam e indicam as características e os prognósticos de comportamento (tendência) do preço futuro de uma ação.

Bulkowski (2008) elaborou um extenso trabalho sobre a eficácia da resposta de cada padrão de *candle*. Sua pesquisa consistiu em catalogar aproximadamente 100 tipos de diferentes de *candles* para, na sequência, explorar os dados das 500 ações que compunham o índice Standard & Poors 500 (S&P 500) para um período de 10 anos.

Para concretizar o árduo exercício de nomear os diferentes formatos e composições dos *candles*, pode-se perceber que algumas características são determinantes para o êxito de tal proposta, como tamanho do *candle*, tamanho do corpo do *candle*, tamanho da sombra do *candle*, *candle* de alta ou baixa, *gap* em relação ao *candle* anterior, quando é interrompido o *gap*, posição do corpo em relação às sombras superiores e inferiores, e linha de tendência, sendo que diversas estruturas de *candles*, para serem definidas, dependerão de composição conjunta, como, por exemplo, dos últimos três *candles*.

Contudo, há um grau elevado de dificuldade em ponderar estas características listadas, pois nem todas são definidas por variáveis dicotômicas e quantitativas. Não há definição, na literatura, de qual seria o parâmetro métrico para se considerar, por exemplo, um corpo de um *candle* longo ou curto.

2.2.3 Indicadores técnicos

Em complemento ao uso dos *candlesticks*, a análise técnica faz o uso de vários indicadores, com o propósito de melhor detectar o comportamento do mercado financeiro, os quais têm um grau relevante de variação de complexidade de aplicação e de adeptos.

Definiu-se aqui por fazer um “recorte” e apresentar apenas alguns dos indicadores que os operadores do mercado utilizam. São eles:

- a) média móvel (MA);
- b) média móvel convergente e divergente (MACD);
- c) índice de força relativa (IFR).

2.2.3.1 Média móvel

De acordo com Kirkpatrick e Dahlquist (2009), a média móvel talvez seja um dos indicadores técnicos mais antigos e populares entre os investidores. Seu uso é motivado pela possibilidade de suavizar dados erráticos, tornando-se mais fáceis de visualizar a verdadeira tendência subjacente do movimento do preço da ação. Charles Dow defendia que o estudo das médias é capaz de traduzir o movimento da tendência do mercado.

Segundo Pimenta e Lima (2010), o uso da média móvel como rastreador de tendência poderá adotar perfis diferentes, variando conforme o tamanho do passo da medida e a estratégia de acompanhar o preço de forma mais próximo ou afastado. Kirkpatrick e Dahlquist (2009) afirmam que os tamanhos dos passos na média móvel são totalmente arbitrados e os mais populares junto aos investidores são de 10, 20, 30, 50, 60 e 200 dias.

Entre as diversas variações de médias móveis possíveis de serem utilizadas, Pring (2007) cita que as mais comuns são média móvel simples e média móvel exponencial.

a) Média móvel simples

A média móvel simples ou *simple moving average* (SMA) trata-se do modelo mais popular de média móvel. Seu cálculo consiste em somar os valores de ocorrência do conjunto de dados e dividir pelo número de observações.

$$SMA_n = \sum_{i=1}^n \frac{data_i}{n} \quad (2)$$

Em que $data_i$ = preço da ação, ou o volume de negociações, ou o número de transações, etc.;

n = número de observações.

De acordo com Pring (2007), o alerta de inversão de tendência deverá ser identificado a partir do cruzamento das linhas do gráfico de cotação de uma ação com a da média móvel simples, nunca por uma inversão da direção do movimento da média móvel simples.

Ainda segundo Pring (2007), geralmente, as médias móveis são calculadas utilizando-se os dados de fechamento, pois estes tendem a refletir posições mais confiáveis que os investidores estão dispostos a assumir durante o *after market*.

b) Média móvel exponencial

A média móvel exponencial, ou *exponentially moving average (EMA)*, se diferencia da média móvel simples por atribuir um maior peso ao preço mais recente no seu cálculo. O fator que motiva esse comportamento está relacionado à tentativa de ter uma média capaz de sinalizar com maior rapidez um possível comportamento de tendência.

O seu cálculo é feito da seguinte forma:

$$EMA_{day\ i} = K_n \times data_{day\ i} + (1 - K_n) \times EMA_{day\ i-1} \quad (3)$$

Sendo:

$$K_n = \frac{2}{n + 1}$$

n = número de observações.

Conforme Pring (2007), tal como ocorre com a *SMA*, os sinais de compra e venda, ou seja, de reversão do mercado, serão reproduzidos a partir do cruzamento das linhas do gráfico de cotação de uma ação com a linha que representa a *EMA*.

2.2.3.2 Média móvel convergente e divergente

A média móvel convergente e divergente, ou *moving average convergence-divergence (MACD)*, é uma ferramenta que visa sinalizar a inversão de movimento do preço da ação em estudo. Ela foi criada na década de 1970, por Gerald Appel, tendo se tornado um dos indicadores mais populares da análise técnica (APPEL, 2005).

O *MACD* é calculado a partir da subtração entre a média móvel exponencial de 12 dias e de 26 dias, ou seja,

$$MACD = EMA_{12} - EMA_{26} \quad (4)$$

Segundo Pimenta e Lima (2010), a decisão de compra ou venda apoiada no *MACD* ocorre sempre quando há transposição de sinal do indicador, e o sinal de compra será dado quando o valor do *MACD* passar de negativo para positivo e o de venda, quando o contrário acontecer.

2.2.3.3 Índice de força relativa

O índice de força relativa, ou *relative strength index (RSI)*, foi desenvolvido na década de 1970, por Welles Wilder, com o objetivo de identificar cenários sobrecomprados ou sobrevendidos. Wilder baseou seu índice na suposição de que os níveis de sobrecomprado ocorrem, geralmente, depois

que o mercado avançou por um número desproporcional de dias e que os níveis de sobrevendido geralmente seguem um número significativo de dias de quedas. O *RSI* é considerado uma medida simples que expressa a força relativa de um movimento de preços (KIRKPATRICK; DAHLQUIST, 2009).

O cálculo é alcançado da seguinte forma:

$$RSI = 100 - \frac{100}{(1+U/D)} \quad (5)$$

Em que:

U = média das cotações dos últimos 14 dias em que a cotação subiu;

D = média das cotações dos últimos 14 dias em que a cotação desceu.

Sugere-se, para cálculo do *RSI*, um período de 14 dias e seu resultado varia de 0 a 100. Segundo Appel (2005), o valor do *RSI* de uma ação aproximando de 100 indicará que este ativo encontra-se numa posição de sobrecompra e valores próximos a 0 indicarão uma situação de sobrevenda. Ou seja, valores próximos a 100 significam que o ativo deve ser vendido, e próximos a 0, que se deve comprar. Bibliografias sugerem que níveis acima de 70 e abaixo de 30 são bons parâmetros de sobrecompra e de sobrevenda, respectivamente.

2.3 Sistemas inteligentes

A complexidade de problemas que emanam da tomada de uma decisão com opções excedentes, aliada aos avanços da área computacional de processamento de dados, tem estimulado o desenvolvimento de pesquisas que abordam técnicas de inteligência artificial (IA) que, por sua vez, têm

apresentado resultados bastante significativos, com aplicação em diversas áreas do conhecimento.

É importante ressaltar que, apesar de o nome “inteligência computacional” instigar a suspeita de leitores não familiarizados com a temática, trata-se de uma abordagem teórica recente, que significa uma ideia de visão futurista. Esclarece-se que as primeiras pesquisas na referida área remontam à década de 1940, quando estudos iniciais a respeito de máquinas de aprendizagem contribuíram para a primeira representação do neurônio artificial e a criação da regra de aprendizagem, que culminaram na criação das redes neurais artificiais.

Segundo Narain e Narain (2002), o conceito de rede neural foi desenvolvido nas décadas de 1940 e 1950, porém, ele apenas foi apresentado à comunidade científica em 1956, na Dartmouth Conference. Apesar de John McCarthy ser considerado o “pai” da teoria das redes neurais, credita-se ao matemático inglês Alan Turing o primeiro trabalho de impacto nesta área.

Mas, por que o termo inteligência artificial? De acordo com Negnevitsky (2005), inteligência artificial, ou IA, é uma ciência que se dedica a construir hardware e software com capacidade de processamento e tomada de decisão inteligente, com desempenho similar ao de um ser humano. Assim, inteligente refere-se à habilidade para aprender e entender determinada situação. Krishnamoorthy e Rajjev (1996) complementam afirmando que a IA tem por objetivo fornecer técnicas para o desenvolvimento de programas de computador, com foco na realização de uma variedade de tarefas análogas à forma inteligente com a qual os seres humanos solucionam seus problemas, salientando que os problemas que os seres humanos resolvem no seu dia a dia são de grande variedade e complexidade. Dessa forma, a IA visa proporcionar um conjunto de formalismo para representar os problemas e também as técnicas para a sua resolução.

No Quadro 1 apresentam-se algumas características da mente humana que inspiraram pesquisadores a se dedicarem ao estudo da IA. Faz-se também um paralelo entre os sistemas inteligentes *versus* sistemas convencionais.

| SER HUMANO | SISTEMAS INTELIGENTES | SISTEMAS CONVENCIONAIS |
|---|--|--|
| Utiliza o conhecimento sob a forma de regras ou heurísticas para resolver problemas em um domínio restrito. | Processa o conhecimento sob a forma de regras e usa o raciocínio simbólico para resolver problemas. | Processa dados com o uso de algoritmos, criando uma série de operações bem definidas, afim de solucionar questões numéricas. |
| No cérebro humano, o conhecimento existe em uma forma compilada (simplificada). | Separa conhecimento do processamento. | Não sabe separar a estrutura de controle para processar o conhecimento. |
| Capaz de explicar a linha de raciocínio seguida e fornecer os detalhes. | Define a resolução de problemas e explica como uma determinada conclusão foi alcançada. | Não explica como um determinado resultado foi obtido e por que dados de entrada eram necessários. |
| Melhora a qualidade de resolução de problemas por meio de anos de aprendizado e treinamento prático. Esse processo é lento, ineficiente e caro. | Melhora a qualidade de resolução de problemas por meio da adição de novas regras ou adapta as antigas na base de conhecimento. Quando os novos conhecimentos são adquiridos, as mudanças são fáceis. | Melhora a qualidade de resolução de problemas alterando o código do programa, que afeta o conhecimento e seu processamento, tornando difícil qualquer modificação. |

Quadro 1 Comparação entre ser humano, sistemas inteligentes e convencionais

Fonte: Adaptado de Negnevitsky (2005, p. 35)

Entre os sistemas inteligentes, encontram-se as redes neurais artificiais, que procuram emular a “máquina humana” para processar problemas de alto

grau de complexidade. De acordo com Mandelbrot e Hudson (2004), as finanças “pós-modernas”, baseadas na inteligência do silício, têm, ainda, um longo caminho a percorrer na busca de soluções convincentes.

2.3.1 Redes neurais

De acordo com Tofoli et al. (2008), a técnica de redes neurais objetiva simular o funcionamento do cérebro humano, no que tange à sua dinâmica de processamento de dados, sendo ela capaz de reconhecer padrões, extrair regularidades e detectar relações subjacentes em um conjunto de dados aparentemente desconexos, além de possuir habilidades para operar com dados ruidosos, incompletos ou imprecisos e de prever sistemas não lineares, o que torna a sua aplicação no setor financeiro bastante eficiente.

Swales e Yoon (1992, p. 82) destacam que, justamente por comporem o rol de técnicas de inteligência artificial, um dos principais pontos fortes das redes neurais artificiais é a habilidade para aprender, *“learning is a function of iterative processing aimed at minimizing predictive errors”*. Os erros constituem a diferença entre as saídas atuais e as saídas projetadas.

De acordo com Haykin (2001, p. 23), redes neurais podem ser definidas como:

[...] um processador maciçamente e paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela assemelha-se ao cérebro humano em dois aspectos: (1) o conhecimento adquirido pela rede, a partir de seu ambiente, através de um processo de aprendizagem; (2) as forças de conexão entre neurônios (os pesos sinápticos) são utilizadas para armazenar o conhecimento adquirido.

Segundo Freitas (2001), tal como o cérebro humano, as redes neurais são formadas a partir de um conjunto de unidades de processamento interligadas entre si, conhecidas como neurônios. Cada neurônio tem uma função de ativação, permitindo que, a partir de um valor recebido como entrada e do valor já armazenado internamente, seja gerado um valor de saída, que será transmitido ao neurônio seguinte. Em uma rede neural, a cada conexão que liga um neurônio a outro é atribuído um peso, chamado de peso sináptico. Durante o processo de aprendizagem, os pesos dados a cada conexão vão se ajustando até que se chegue a um conjunto de valores de pesos que, aplicados aos valores de entrada de cada neurônio, resultem em respostas satisfatórias ao problema estudado. Em um neurônio artificial também é comum a presença de um parâmetro, conhecido como *bias*, que permite a calibragem do sinal de saída. Pode-se visualizar este esquema na Figura 4.

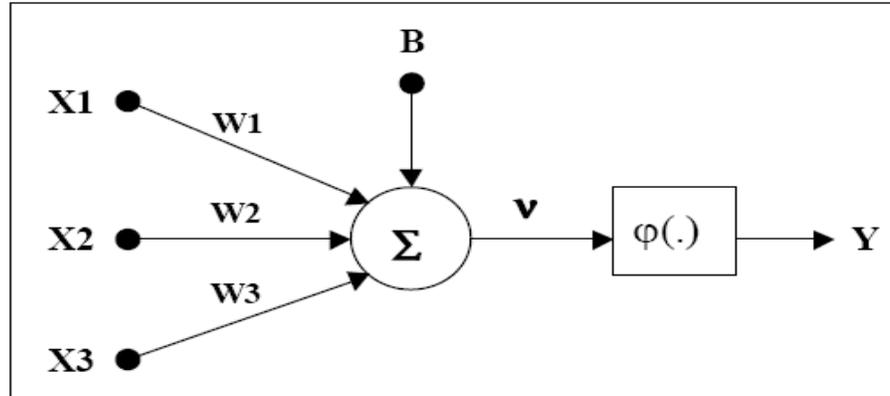


Figura 4 Modelo de neurônio artificial

Fonte: Freitas (2001, p. 35)

Obs.: $X_1 = X_2 = X_3$: valores de entradas (*input*);

Y_i : valor de saída (*output*); $w_1 = w_2 = w_3$: pesos sinápticos;

B : *bias*; v : potencial de ativação; $\phi(\cdot)$: função de ativação.

Matematicamente, o funcionamento de um neurônio pode assim ser descrito:

$$Y_i = \prod(u + B) \quad (6)$$

Sendo que:

$$u = \sum_{j=i}^m (w_j \times X_j); v = u + B$$

Existem diferentes topologias de redes neurais e entre as principais estão as seguintes:

- a) **redes alimentadas adiante com camada única:** essa estrutura consiste num modelo de camada única, apenas a saída. Não significa que não há neurônios de entrada, mas esses não são efetivamente contabilizados como camada, uma vez que não há transformações computacionais nesta fase. Sua maior aplicabilidade centra no reconhecimento de padrões linearmente separáveis, o que acaba por restringir bastante o seu uso;
- b) **redes alimentadas diretamente com múltiplas camadas:** como o próprio nome sugere, esse tipo de rede é caracterizado por utilizar uma ou mais camadas ocultas (*hidden layer*) de neurônios. A principal função dos neurônios ocultos é intervir no ajuste da entrada, no intuito de produzir uma saída mais fidedigna da realidade;
- c) **redes recorrentes:** esse modelo se distingue dos demais por receber um sinal de entrada advindo das saídas, ou seja, tem-se aqui um processo de realimentação. De acordo com Haykin (2001), o

processo de autorrealimentação delinea uma situação em que a saída de um neurônio é reaproveitada no processo recorrente de entrada.

Outro ponto que merece ser explicitado refere-se aos modelos de função de ativação (Figura 5), que são: função linear, sigmoideal logística, tangente hiperbólica e degrau.

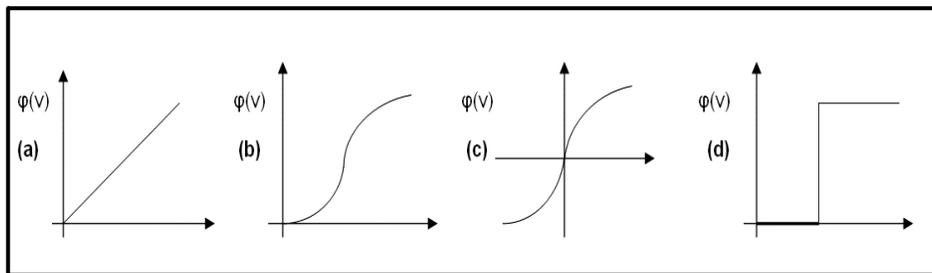


Figura 5 Exemplos de funções de ativação

Fonte: Adaptado de Haykin (2001)

Nota: (a) função linear; (b) função sigmoideal logística; (c) função tangente hiperbólica, (d) função degrau.

Com a utilização das funções de ativação, com exceção da função linear, o Y_i passa por mais uma transformação numérica da seguinte forma:

Função degrau

Se $X_i > 1$, $Y_i = 1$;

Se $X_i < 1$, $Y_i = 0$.

Função tangente hiperbólica

$$Y_i = \frac{1 - e^{-X_i}}{1 + e^{-X_i}}$$

Função sigmoideal logística

$$Y_i = \frac{1}{1 - e^{-X_i}}$$

De acordo com Másson e Wang (1990 apud MUELLER, 1996), a função de ativação corresponde a um limiar que restringe a propagação do impulso nervoso à transposição de um certo nível de atividade, entre a saída do sinal de uma camada para outra. Seu papel será mapear e filtrar o potencial da unidade de processamento (v) para um intervalo pré-especificado de saída.

Outro ponto de destaque, talvez o mais importante na estrutura teórica das redes neurais, refere-se à habilidade de aprender. Nenhuma rede neural nasce pronta; seu desempenho dependerá, obviamente, dos códigos de programação que a compõem, até porque ele é que determinará todo o fluxo de ação e estrutura, mas o processo de aprendizado é item determinante para a acurácia das saídas. O resultado final dessa rede será potencializado por meio do aprendizado. Segundo Haykin (2001, p. 75), “aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida”.

De acordo com Braga, Carvalho e Ludermir (2007), o processo de aprendizagem divide-se em dois grandes paradigmas: aprendizagem supervisionada e não supervisionada, os quais são descritos a seguir.

a) Aprendizagem supervisionada: esse nome surgiu por existir um agente externo (denominado como professor) que fornece os dados de entrada e de saída para a rede aprender. Com isso, a rede recebe um importante indicativo: se o seu desempenho tem alcançado níveis satisfatórios, pois há a possibilidade de comparar os resultados projetados com os reais. Dessa forma, a rede inicia

um processo de ajuste dos pesos, a fim de minimizar a medida de erro destacado como parâmetro ótimo. Conforme Valença (2009), o processo de ajuste de pesos pode assumir duas diferentes formas: *on line* e *off-line*. No treinamento *on line*, a atualização dos pesos sempre ocorrerá quando houver apresentação de um novo conjunto de treinamento. Para que esse método apresente estabilidade, é necessário utilizar taxas de aprendizagem pequenas. Já no treinamento *off-line*, a atualização dos pesos só é feita após a apresentação de todos os exemplos de treinamento que compõem o ciclo. Este tipo de estrutura é mais estável do que o modo padrão, por trabalhar com o gradiente médio.

b) Aprendizagem não supervisionada: ao contrário da dinâmica anterior, na aprendizagem não supervisionada não haverá a figura do “professor”. Para esse tipo de estrutura são fornecidos apenas os dados de entrada da rede. Segundo Haykin (2001), o objetivo aqui será estabilizar regras estatísticas para uma melhor adequação das saídas. Uma regra bastante utilizada nesse tipo de estrutura é a regra competitiva, em que os neurônios competem entre si a fim de firmar características presentes nos dados de entrada.

Em síntese, o uso do conceito de redes neurais para a solução de um problema requer, antes de qualquer coisa, que se defina a arquitetura que esta rede irá trabalhar. Para Braga, Carvalho e Ludermir (2007), definir a arquitetura de uma rede neural significa determinar a estrutura sobre a qual os neurônios da rede estarão organizados.

2.3.1.1 Perceptron de múltiplas camadas

A discussão da rede neural de múltiplas camadas será abordada com mais detalhes, haja vista que esse foi o modelo utilizado na presente pesquisa. Assim, conforme já destacado, a rede de camadas múltiplas, ou *multilayer*

perceptron (MLP), tem, além dos neurônios de entrada e saída, uma ou mais camadas ocultas (Figura 6).

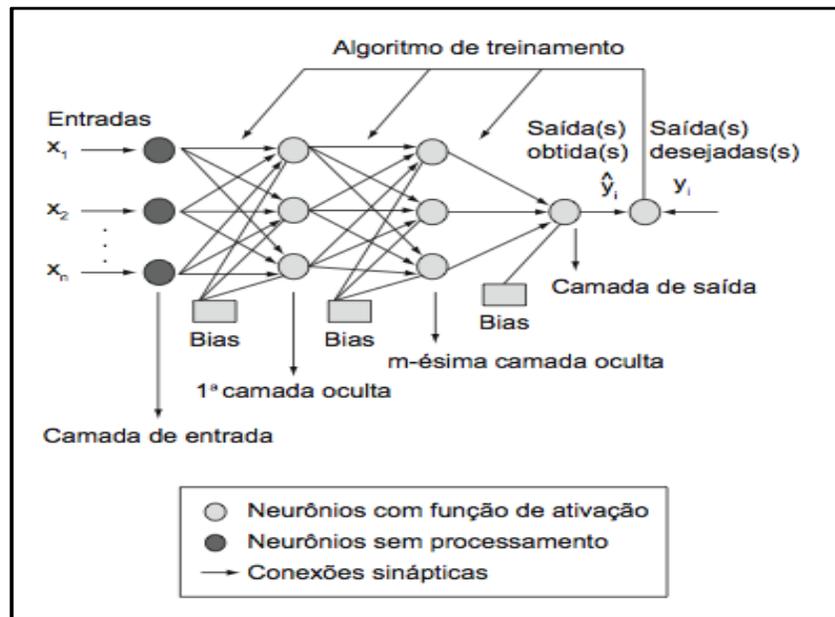


Figura 6 Representação da arquitetura da MLP

Fonte: Coelho, Santos e Costa Júnior (2008, p. 637)

A existência da camada escondida torna o treinamento da rede mais difícil, pois não se sabe o erro médio quadrático (*EMQ*) associado aos pesos a cada camada. Para o treinamento dessa rede, utiliza-se um algoritmo conhecido como *backpropagation*. Esse algoritmo baseia-se na regra de aprendizagem por correção de erro, em que o valor do *EMQ* encontrado na camada de saída é propagado para a camada de entrada, por meio de cálculo da sensibilidade, no intuito de ajustar os pesos na camada intermediária. Portanto, o cálculo de uma saída para a MLP se dá em duas etapas, a primeira com a propagação normal (da camada de entrada para a camada de saída) e a segunda, a de retropropagação do erro (da camada de saída para a camada de entrada) (BRAGA; CARVALHO;

LUDEMIR, 2007). Utiliza-se a equação de ajuste a seguir, em que δ_j é a sensibilidade em função da agora saída calculada y ; η é a constante de *momentum* que auxilia no aumento da velocidade de aprendizagem e α é a taxa de aprendizagem e t o ciclo.

$$w_{ij}(t+1) = w_{ij}(t) + \eta\delta_j(t) + \alpha(w_{ij}(t) - w_{ij}(t-1)) \quad (7)$$

A determinação de pesos ótimos para qualquer problema estudado caracteriza o *fit*, que significa dar a modelagem mais precisa possível ao problema estudado, observada sua complexidade. Dessa forma, *overfitting* e *underfitting* são modelagens que superestimam a complexidade do problema, retornando pesos com excessiva precisão e que subestimam a complexidade do problema, retornando pesos com baixa precisão, respectivamente. Ambos os casos, *overfitting* e *underfitting*, são modelagens enviesadas do problema.

Em síntese, Haykin (2001) destaca três as características marcantes da rede MLP. São elas:

- a) o uso de funções de ativação não lineares, funções estas não lineares suaves, não havendo transmissão abrupta de sinal;
- b) o uso de uma ou mais camadas ocultas de neurônios, habilitando a rede, por sua vez, a aprender tarefas mais complexas;
- c) rede com alto grau de conectividade, determinada pelas sinapses da estrutura.

3 MATERIAL E MÉTODOS

Para a classificação da pesquisa, foram tomados como base os critérios apresentados por Vergara (1998), que qualifica a pesquisa em relação a duas vertentes: quanto aos fins e quanto aos meios. Quanto aos fins, consistiu de uma pesquisa conclusiva, pois é um tipo de pesquisa que testa hipóteses e examina relações específicas entre variáveis.

Quanto aos meios, trata-se de uma pesquisa *ex-post-facto* e bibliográfica. A investigação é *ex-post-facto* por se referir a um fato já ocorrido. Conforme Vergara (1998), esse tipo de investigação é recomendado quando o pesquisador não pode controlar ou manipular variáveis porque suas manifestações já ocorreram, pois as variáveis não são controláveis. Para Gil (1989), na pesquisa *ex-post-facto*, a manipulação das variáveis independentes é impossível, pois estas chegam até o pesquisador já prontas. É também bibliográfica porque recorreu-se ao uso de materiais acessíveis ao público em geral, como livros, artigos, notícias, cotações de ações e índices de mercado.

A essência investigativa do presente trabalho é a pesquisa quantitativa que, segundo Alves-Mazzotti e Gewandsznajder (2001), é um método de investigação que torna os conceitos mais precisos, além de dar mais informações sobre os fenômenos, devido ao rigor estatístico na análise dos dados coletados.

3.1 Amostra e dados

A amostra foi composta por empresas que tinham participação no Índice da Bolsa de Valores de São Paulo (IBOVESPA) em 30/05/2012. Para um segundo recorte, no intuito de refinar o grupo de empresas que participariam da pesquisa, definiu-se por utilizar apenas as séries históricas daquelas empresas que tiveram negociação em, no mínimo, 98% dos pregões da Bolsa de Valores

de São Paulo, no período de 3 de janeiro de 2000 a 9 de fevereiro de 2012. Esse critério deveu-se a um extenso número de observações necessárias para realizar o teste de aleatoriedade das séries temporais. O tema será abordado com mais detalhes na próxima seção.

Quanto às informações necessárias para a realização da pesquisa, estas foram obtidas por meio do banco de dados da Economática, tendo as cotações diárias sido ajustadas (dividendos, bonificações, *split* e *inplit*). Para os ativos que não tiveram negociação em datas específicas, mas que atendiam ao critério de participação em 98% dos pregões, optou-se por se reproduzir a cotação do dia anterior mais próximo. Após o filtro, chegou-se a um número de 28 ativos a serem investigados, os quais estão listados no Quadro 2.

| Cód. Ativo | Empresa | Cód. Ativo | Empresa |
|-------------------|-----------------|-------------------|----------------------|
| BBDC4 | Bradesco | LAME4 | Lojas Americanas |
| BBAS3 | Banco do Brasil | OIBR4 | Oi |
| BRKM5 | Braskem | PCAR4 | Pão de Açúcar |
| CMIG4 | Cemig | PETR3 | Petrobrás |
| CPLE6 | Copel | PETR4 | Petrobrás |
| ELET3 | Eletrobrás | SBSP3 | Sabesp |
| ELET6 | Eletrobrás | CSNA3 | Siderúrgica Nacional |
| EMBR3 | Embraer | CRUZ3 | Souza Cruz |
| GGBR4 | Gerdau | VIVT4 | Telefônica Brasil |
| GOAU4 | Gerdau | TIMP3 | Tim |
| ITSA4 | Itaú | TRPL4 | Transmissão Paulista |
| ITUB4 | Itaú Unibanco | USIM5 | Usiminas |
| KLBN4 | Klabin | VALE3 | Vale |
| LIGT3 | Light | VALE5 | Vale |

Quadro 2 Amostra da pesquisa

3.2 Análise das séries financeiras: aleatórias ou previsíveis?

Segundo os preceitos teóricos da HME, a tarefa de prever preços futuros tendo como base comportamentos passados de um ativo financeiro é um procedimento ineficaz, pois a distribuição de uma série financeira denota um movimento browniano, que é concebido por características randômicas e independentes. Na contramão da concepção de mercado eficiente, apresentam-se os que defendem que o mercado acionário, na verdade, não se firma como aleatório, ou seja, as séries financeiras têm memória de longo prazo.

Dessa forma, buscou-se avaliar se os ativos ora selecionados para participar da pesquisa tinham séries temporais com comportamento de aleatoriedade ou não. Para alcançar esse objetivo, definiu-se por calcular o coeficiente de Hurst (H) das séries.

O coeficiente de Hurst foi desenvolvido pelo hidrólogo Harold E. Hurst que, na época, teve, originalmente, como cenário de discussão as cheias do rio Nilo. Seu objetivo foi verificar se havia um padrão de memória ligado a esses eventos ou se esses acontecimentos não passavam de eventos aleatórios independentes. Esses estudos, então, culminaram no desenvolvimento da estatística conhecida como coeficiente de Hurst.

A utilização do coeficiente de Hurst no mercado financeiro remonta aos estudos de Mandelbrot na década de 1960, quando o mesmo questionou o movimento browniano clássico, propondo o movimento browniano fractal. Segundo Peters (1991), H tem uma vasta aplicabilidade para análises de séries temporais, dado que o mesmo a considera legitimamente robusta. Ele é capaz de distinguir uma série aleatória a partir de uma série não aleatória, mesmo que a série aleatória seja não gaussiana.

Sua operacionalização em séries temporais financeiras deverá atender aos passos indicados a seguir, conforme apregoa Peters (1994).

1º. Calcular o retorno logarítmico da série financeira:

$$N_i = \ln \left(\frac{M_{it}}{M_{it-1}} \right) \quad (8)$$

Em que:

M_{it} = representa o preço da ação i ao final do período t ;

M_{it-1} = representa o preço da ação i no início do período t .

2º. Particionar a série financeira em frações temporais e calcular a média de cada conjunto de dados:

$$e_a = \left[\left(\frac{1}{n} \right) \times \sum_{k=1}^n N_{k,a} \right] \quad (9)$$

Em que:

e_a = valor médio do retorno logarítmico do ativo financeiro;

n = número de elementos por partição

3º. Calcular o desvio acumulado de cada série particionada:

$$X_{k,a} = \sum_{j=1}^k (N_{j,a} - e_a) \quad (10)$$

Em que cada retorno de uma série particionada (I_a) tem um grupo de retornos do ativo, representado por $k = 1, 2, 3, \dots, n$.

$X_{k,a}$ = desvios acumulados em relação a e_a

4º. Verificar quais são os pontos máximos e mínimos do conjunto I_a , seguido da diferença entre eles:

$$R_{Ia} = \max(X_{k,a}) - \min(X_{k,a}) \quad (11)$$

Enquanto que $1 \leq k \leq n$.

5º. Calcular o desvio padrão de cada partição:

$$S_{Ia} = \left[\left(\frac{1}{n} \right) \times \sum_{k=1}^n (N_{k,a} - e_a)^2 \right]^{\frac{1}{2}} \quad (12)$$

Em que S_{Ia} = desvio padrão de cada partição

6º. Normalizar a série A e os valores R_{Ia} , dividindo estes valores de amplitude pelos correspondentes desvios padrões S_{Ia} :

$$\left(\frac{R}{S} \right)_n = \left(\frac{1}{A} \right) \times \sum_{a=1}^A \left(\frac{R_{Ia}}{S_{Ia}} \right) \quad (13)$$

7º. Para concluir o processo de mensuração do expoente de Hurst, deve-se calcular uma regressão linear simples, atribuindo como variável dependente $\ln R/S_n$ e, como variável independente, $\ln(a)$. Os passos de 1 a 6 devem ser repetidos várias vezes, mas com tamanhos de partições diferentes, até que haja um número suficiente de dados para calcular a regressão e que a série tenha sido calculada numa ordem decrescente de partições, até o momento em que toda a série limite-se a 2 partições apenas:

$$\ln(R/S)_n = \ln(a) + b \times \ln(n) \quad (14)$$

Em que:

$\ln(a)$ = intercepto;

b = coeficiente de Hurst

Calculado o coeficiente de Hurst, ter-se-ão as seguintes possibilidades de resultado:

- a) $0 < H < 0,5$: série antipersistente, ou simplesmente significa comportamento de reversão. Ou seja, há uma probabilidade maior que 50% de um valor negativo ser precedido de um positivo. A força desse comportamento dependerá do quão próximo de zero seja o H ;
- b) $H = 0,5$: série apresenta uma distribuição aleatória. Assim, a variação dos desvios cumulativos devem aumentar proporcionalmente à raiz quadrada da variável tempo;
- c) $H > 0,5$: série persistente; há uma probabilidade acima de 50% que ocorra a repetição de um valor. Sendo assim, justifica-se precificar ativos financeiros com base em dados históricos, quando o coeficiente de Hurst indicar um valor diferente de 0,5.

Para fins desta pesquisa, o cálculo do expoente de Hurst utilizou séries financeiras de 3.000 observações, acolhendo, assim, recomendações de Feder (1988), que sugere uma quantidade mínima de 2.500 observações. Assim, a série dos ativos contempla o período de 03/01/2000 a 09/02/2012.

3.3 Modelo de compra e venda de ações

O modelo proposto nesta pesquisa tem como pilar principal a qualidade das previsões dos preços futuros das ações. Para a realização dessas previsões, valeu-se da técnica de redes neurais, pois, segundo Burrell e Folarin (1997), o uso da técnica de redes neurais em problemas da área financeira tem um vasto e importante potencial de possíveis aplicações, uma vez que essa técnica de inteligência artificial consegue lidar com dados com estruturas de conexões complexas e de difícil entendimento dos níveis de dependência.

Dessa forma, apresenta-se na Figura 7 a síntese da estrutura básica do modelo de decisão de compra e venda de ativos financeiros. As etapas elencadas no modelo são discutidas nas próximas seções.

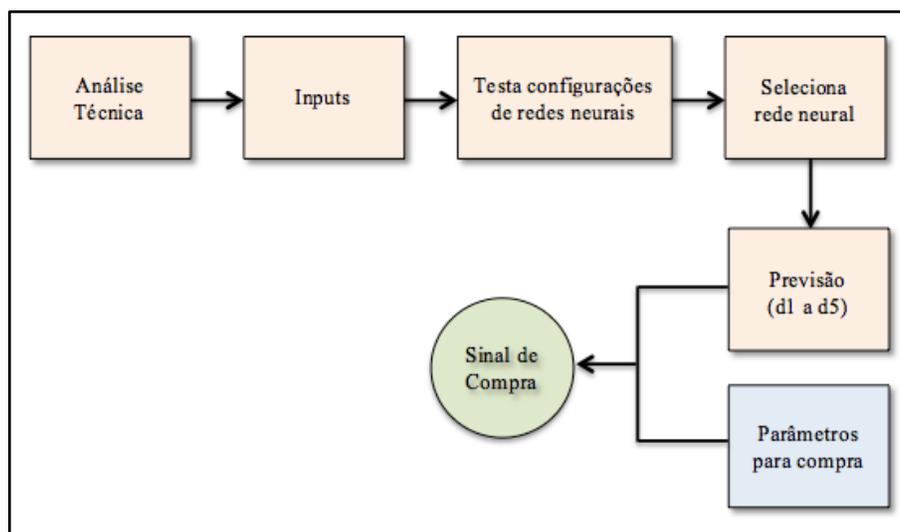


Figura 7 Modelo empírico da pesquisa

3.3.1 Previsão baseada na técnica de redes neurais

Uma rede neural pode ser estruturada com um número infinito de possibilidades. Dessa forma, a sua configuração por alguém que detenha um conhecimento refinado na área objeto da pesquisa contribui e facilita sensivelmente o alcance de um resultado esperado mais justo. Pode-se concluir, então, que várias convicções e direções a serem tomadas na construção de um modelo baseado na técnica de rede neural é de responsabilidade do pesquisador.

Destaca-se que, para a construção do modelo de tomada de decisão, foi fundamental que fosse delineado um modelo de previsão que aproxima ao máximo os dados projetados dos observados.

3.3.1.1 Janela do estudo

O primeiro passo consistiu em definir o tamanho da série temporal a ser utilizada no trabalho. Dado o amadurecimento de pesquisas realizadas anteriormente (HANAOKA et al., 2011; PAIVA et al., 2011a, 2011b), tinha-se a convicção de que não era conveniente utilizar um período tão extenso como aquele praticado no cálculo do coeficiente de Hurst. Ao mesmo tempo, buscou-se simular dados mais atuais possíveis e que tivessem um horizonte que permitisse extrair algumas conclusões sobre a potencialidade ou não do modelo.

Dessa forma, definiu-se que o modelo de decisão seria testado para o período de 02/01/2013 a 15/10/2013, ou seja, 198 dias de pregões na bolsa de valores.

Uma vez definido o período em que os dados (previsão) que “alimentariam” o modelo seriam testados, buscou-se definir a janela dos dados que seriam utilizados para aprendizado da rede neural. Mas, antes que fosse definido o tamanho dessa janela, ponderou-se que a construção de uma única

rede para ser utilizada para prever 198 dias de pregão poderia ser pouco prudente, pois o mercado financeiro é muito dinâmico e facilmente poderia haver alterações na forma como as variáveis (*inputs*) interagem, comprometendo, assim, as previsões a serem realizadas.

Assim sendo, definiu-se que a projeção dos 198 dias seria particionada em 3 blocos de redes diferentes. A forma como estes dados foram divididos é apresentada na Figura 8.

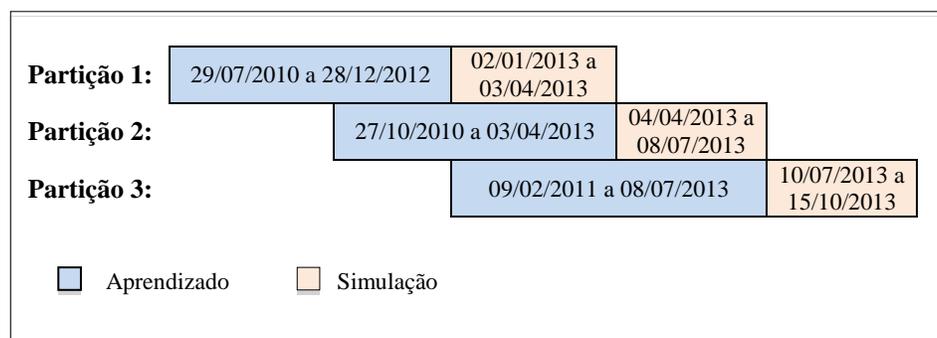


Figura 8 Janelas para aprendizado e simulação da rede neural

3.3.1.2 Variáveis de entrada e saída

Na sequência, definiu-se que a variável *target* do modelo seria o preço de abertura para $d+1$, $d+2$, $d+3$, $d+4$ e $d+5$. Quanto às variáveis que poderiam ser utilizadas como *inputs*, essas perfizeram um total de dezesseis variáveis que são: cotações diárias de abertura, fechamento, mínima e máxima; tamanho proporcional das sombras superior e inferior e do corpo; quantidade de negociações diária do ativo; variação diária do preço de fechamento; variação do preço de fechamento de 5 dias; variação do preço de fechamento de 14 dias; RSI; MACD; média móvel de 10 dias da rentabilidade diária do preço de fechamento; Ibovespa e variação diária do Ibovespa.

a) Cotação de abertura (Cab):

$$Cab = Ln \text{ preço de abertura} \quad (15)$$

b) Cotação de fechamento ($Cfech$):

$$Cfech = Ln \text{ preço de fechamento} \quad (16)$$

c) Cotação mínima (Cmn):

$$Cmn = Ln \text{ preço mínimo} \quad (17)$$

d) Cotação máxima (Cmx):

$$Cmx = Ln \text{ preço máximo} \quad (18)$$

e) Sombra superior ($Ssup$):

$$\text{Se } Cab \geq Cfech, \text{ então, } Ssup = \frac{Cmx - Cab}{Cmx - Cmn} \quad (19)$$

$$\text{Se } Cab < Cfech, \text{ então, } Ssup = \frac{Cmx - Cfech}{Cmx - Cmn} \quad (20)$$

f) Sombra inferior ($Sinf$):

$$\text{Se } Cab \geq Cfech, \text{ então, } Sinf = \frac{Cfech - Cmn}{Cmx - Cmn} \quad (21)$$

$$\text{Se } Cab < Cfech, \text{ então, } Sinf = \frac{Cab - Cmn}{Cmx - Cmn} \quad (22)$$

g) Corpo (Co):

$$Co = \left| \frac{Cab - Cfech}{Cmx - Cmn} \right| \quad (23)$$

h) Quantidade negociações do ativo (*Quant_Neg*):

$$Quant_Neg = Ln \text{ Número diário de negociações do ativo} \quad (24)$$

i) Rentabilidade diária do ativo (*Rent_1d*):

$$Rent_1 = Cfech_i - Cfech_{i-1} \quad (25)$$

j) Rentabilidade de 5 dias do ativo (*Rent_5d*):

$$Rent_5 = Cfech_i - Cfech_{i-5} \quad (26)$$

l) Rentabilidade de 14 dias do ativo (*Rent_14d*):

$$Rent_14 = Cfech_i - Cfech_{i-14} \quad (27)$$

m) Índice de força relative (*RSI*):

$$RSI = 100 - \frac{100}{(1 + U/D)} \quad (28)$$

Em que:

U = média das cotações dos últimos 14 dias em que a cotação subiu;

D = média das cotações dos últimos 14 dias em que a cotação desceu.

n) Média móvel convergente e divergente (MACD):

$$MACD = EMA_{12} - EMA_{26} \quad (28)$$

Em que:

$$EMA_{day\ i} = K_n \times data_{day\ i} + (1 - K_n) \times EMA_{day\ i-1}$$

$$K_n = \frac{2}{n + 1}$$

o) Média móvel de 10 dias da rentabilidade diária (MM10_Rent):

$$MM10_Rent = \frac{Rent_1d_{i-10} + Rent_1d_{i-9} + \dots + Rent_1d_i}{10} \quad (29)$$

p) Ibovespa (Ibov):

$$Ibov = Ln\ Pontos\ Ibovespa \quad (30)$$

q) Rentabilidade diária Ibovespa (Rent_Ibov):

$$Rent_Ibov = Ibov_i - Ibov_{i-1} \quad (31)$$

3.3.1.3 Arranjos das redes neurais

Definidas as variáveis de entrada e saída da rede neural, a próxima etapa consistiu em estabelecer alguns arranjos de redes a serem testados, variando o número de neurônios da camada oculta e os *inputs*. Como se sabe, a melhor

configuração para uma rede neural é atingida apenas num trabalho de tentativa e erro.

Dessa forma, definiram-se 50 arranjos diferentes para serem testados (Quadro 3). Cada arranjo foi testado para uma das partições de dados e para cada alvo (d+1, d+2, d+3, d+4 e d+5). Além disso, em virtude do fato de os dados serem embaralhados e os pesos, inicialmente, da rede serem atribuídos de forma aleatória, realizou-se o número de 30 iterações para cada arranjo testado.

| Arranjo | Neurônios | Inputs |
|---------|-----------|---------------------|
| 1 | 6 x 4 x 4 | 2, 16 |
| 2 | 6 x 4 x 3 | 2, 16 |
| 3 | 6 x 4 x 3 | 2, 15 |
| 4 | 6 x 3 x 3 | 2, 14, 16 |
| 5 | 6 x 3 x 3 | 2, 5, 6, 7 |
| 6 | 6 x 4 x 4 | 2, 5, 6, 7 |
| 7 | 6 x 3 x 3 | 2, 12, 13, 16 |
| 8 | 6 x 4 x 4 | 2, 12, 13, 16 |
| 9 | 6 x 3 x 3 | 1, 5, 6, 7, 8 |
| 10 | 6 x 4 x 3 | 2, 12, 13, 16 |
| 11 | 6 x 3 x 3 | 1, 12, 13, 16 |
| 12 | 6 x 3 x 3 | 2, 12, 13, 14 |
| 13 | 6 x 3 x 3 | 5, 6, 7, 8 |
| 14 | 6 x 3 x 3 | 2, 5, 6, 7, 8 |
| 15 | 6 x 3 x 3 | 1, 5, 6, 7, 16 |
| 16 | 6 x 3 x 3 | 5, 6, 7, 12, 13 |
| 17 | 8 x 4 x 4 | 5, 6, 7, 12, 13 |
| 18 | 8 x 4 x 4 | 2, 5, 6, 7, 14, 16 |
| 19 | 8 x 4 x 4 | 2, 5, 6, 7, 12, 13 |
| 20 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7 |
| 21 | 6 x 3 x 3 | 2, 3, 4, 5, 6, 7 |
| 22 | 8 x 4 x 4 | 5, 6, 7, 12, 13, 16 |

Quadro 3 Arranjos das redes neurais testadas

(...continua...)

“Quadro 3, conclusão”

| Arranjo | Neurônios ocultos | Inputs |
|---------|-------------------|--|
| 23 | 8 x 6 x 4 | 2, 3, 4, 5, 6, 7, 16 |
| 24 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7, 16 |
| 25 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7, 8 |
| 26 | 8 x 6 x 4 | 2, 3, 4, 5, 6, 7, 10, 16 |
| 27 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7, 10, 16 |
| 28 | 8 x 6 x 4 | 2, 3, 4, 5, 6, 7, 10, 16 |
| 29 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 16 |
| 30 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7, 8, 13, 16 |
| 31 | 6 x 3 x 3 | 2, 3, 4, 5, 6, 7, 8, 13, 16 |
| 32 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7, 8, 13, 15 |
| 33 | 8 x 6 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 13, 16 |
| 34 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 12, 16 |
| 35 | 10 x 6 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 13, 14, 16 |
| 36 | 10 x 4 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 13, 14, 16 |
| 37 | 12 x 8 x 6 | 2, 3, 4, 5, 6, 7, 8, 10, 13, 14, 16 |
| 38 | 8 x 4 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 13, 14, 16 |
| 39 | 12 x 6 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 12, 13, 14, 16 |
| 40 | 10 x 6 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 12, 13, 14, 16 |
| 41 | 14 x 8 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 14, 16 |
| 42 | 12 x 6 x 4 | 2, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 14, 16 |
| 43 | 16 x 12 x 8 | 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 16 |
| 44 | 14 x 10 x 6 | 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 16 |
| 45 | 14 x 8 x 4 | 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 16 |
| 46 | 12 x 6 x 4 | 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, |
| 47 | 14 x 10 x 4 | 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, |
| 48 | 14 x 6 x 4 | 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, |
| 49 | 14 x 10 x 8 | 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, |
| 50 | 16 x 12 x 8 | 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, |

Os códigos atribuídos à coluna *input* foram assim trabalhados:

| | |
|----------------------|-----------------------|
| 1 = <i>Cab</i> | 9 = <i>Rent_1d</i> |
| 2 = <i>Cfech</i> | 10 = <i>Rent_5d</i> |
| 3 = <i>Cmn</i> | 11 = <i>Rent_14d</i> |
| 4 = <i>Cmx</i> | 12 = <i>RSI</i> |
| 5 = <i>Ssup</i> | 13 = <i>MACD</i> |
| 6 = <i>Sinf</i> | 14 = <i>MM10_Rent</i> |
| 7 = <i>Co</i> | 15 = <i>Ibov</i> |
| 8 = <i>Quant_Neg</i> | 16 = <i>Rent_Ibov</i> |

3.3.1.4 Outras configurações das redes neurais

Conforme se pode observar a partir da seção anterior, todos os arranjos de redes foram delineados sob a perspectiva da metodologia de *multilayer perceptron*, com três camadas ocultas de neurônios. A taxa de aprendizagem adotada foi de 0,1 e o número de épocas foi igual a 100.

Com relação às funções de ativação entre as camadas de neurônios, utilizaram-se sigmoideal logística, tangente hiperbólica e linear, na ordem em que elas foram citadas.

As séries utilizadas para aprendizado foram subdivididas para compor as fases de treinamento, teste e validação, e os percentuais das observações dedicados a cada uma dessas etapas foram de 75%, 15% e 15%, respectivamente.

Para a etapa de aprendizado da rede, a medida de desempenho utilizada para convergência da mesma foi o erro médio quadrático (*EMQ*):

$$EMQ = \frac{1}{n} \sum_{i=1}^n (d_i - y_i)^2 \quad (32)$$

Em que:

d_i = valor desejado

y_i = valor previsto

Com base no aprendizado adquirido, as redes, então, processaram simulações com os dados separados para tal. Para esta etapa de simulação empregou-se um arcabouço maior de medidas para avaliar a qualidade das projeções, a fim de se apurar o quanto ajustada a rede ficou para tomar decisões assertivas, pois, segundo Amorim Neto (2008), o EMQ não fornece uma visão

completa e livre de dúvidas sobre o desempenho do modelo. Sendo assim, é importante avaliar um modelo com outras métricas que possibilitem melhores visões e conclusões. Os indicadores utilizados foram *U-Theil*, *percentage of change in direction (POCID)*, coeficiente de explicação (R2), além do *EMQ*.

O teste *U-Theil* indica o quanto os resultados estão melhores que a previsão trivial, que diz que a melhor estimativa para o preço de amanhã é o preço de hoje (ABELÉM, 1994). Qualquer valor inferior a 1 indica que é melhor usar a projeção do que se ater à previsão trivial:

$$U = \frac{\sqrt{\sum_{i=1}^n (d_i - y_i)^2}}{\sqrt{\sum_{i=1}^n (d_i - d_{i-1})^2}} \quad (33)$$

O cálculo do *POCID* mede a previsão em termos de mudanças de sinais. Não deve ser confundido com uma medida de exatidão da previsão, mas deve ser visto como uma indicação do quanto a previsão acompanhou a tendência da série real (ABELÉM, 1994). Amorim Neto (2008) afirma que essa métrica de desempenho é de grande importância para as aplicações feitas no mercado de ações, pois pode-se, assim, medir as subidas e as descidas das cotações. Quanto mais próximo de 1, mais similares são os movimentos entre real e previsto.

$$POCID = \frac{1}{n} \sum_{i=1}^n a_i \quad (34)$$

Em que:

$$a_i = 1, \text{ se } (y_i - y_{i-1}) \times (d_i - d_{i-1}) > 0$$

$$a_i = 0, \text{ se } (y_i - y_{i-1}) \times (d_i - d_{i-1}) < 0$$

O cálculo do R^2 indica o quanto as previsões estão próximas dos valores reais; quanto mais próximo de 1, melhor é a previsão realizada (VALENÇA, 2009).

$$R^2 = \left(\frac{COV_{d,y}}{\sigma_d \times \sigma_y} \right)^2 \quad (35)$$

Em que:

$COV_{d,y}$ = covariância entre valor desejado e o previsto;

σ_d = desvio padrão do valor desejado;

σ_y = desvio padrão do valor previsto.

3.3.1.5 Seleção e reprodução do melhor arranjo de rede neural

Uma vez processados todos os arranjos com as 30 iterações para cada, calculou-se a média entre os resultados das medidas de desempenho, bem como o desvio padrão e coeficiente de variação de Pearson, para verificar o quão confiável era a média dos resultados. Esta fase foi chamada de seleção da melhor rede para uma situação específica, pois, para cada projeção (d+1, d+2, d+3, d+4 e d+5) de cada ativo, a partir dos valores médios das medidas de desempenho foi selecionada uma rede com melhor resultado para ser utilizada para apurar as previsões que “alimentariam” o modelo de tomada de decisão.

Essa rede então selecionada como a melhor para a situação foco foi utilizada para a reprodução dos testes e o armazenamento das previsões, para que essas previsões fossem utilizadas como *inputs* no modelo de decisão de compra e venda de ativos financeiros.

3.3.2 Parâmetros gerais do modelo de decisão de compra e venda

O que se espera das previsões realizadas pelas redes neurais é que as mesmas consigam aproximar os seus valores previstos do reais, pois conseguir antever com 100% de precisão não passa de utopia. Entendendo que, caso esses valores se aproximem e que mantenham uma média de erros que não comprometa o desempenho global, é possível, então, delinear um modelo de decisão de compra e venda capaz de estabelecer ganhos atrativos.

Portanto, sabendo que não haverá uma assertividade pontual de valores, o modelo aqui proposto trabalhou com um intervalo de retorno exigido, para que as decisões de compra sejam adotadas somente se houver uma interseção entre a expectativa de ganho e o intervalo proposto.

Para que os resultados não sejam mascarados, dada a não incorporação dos altos custos envolvidos nas operações do mercado de capitais brasileiro, estes foram considerados na sua integralidade. São eles:

- a) custo por ordem de compra e venda: R\$ 15,00 por cada tipo de ordem;
- b) taxas e emolumentos: 0, 025% do valor da operação; para a definição da alíquota baseou-se naquela cobrada dos fundos e clubes de investimento;
- c) Imposto sobre Serviço (ISS): 5% sobre o valor da ordem de compra e venda;
- d) Imposto de Renda (IR): 15% aplicado somente sobre o ganho, se este tiver sido positivo.

Outro ponto que precisou ser definido, pois ele impacta diretamente na rentabilidade alcançada, conseqüentemente no processo de avaliação do modelo

aqui proposto, foi o valor que seria utilizado para simular o investimento. Definiu-se, de forma aleatória, que o valor total disponível para investimento seria de R\$ 1.000.000,00, com um limite diário a ser aplicado de R\$ 250.000,00, desde que algum sinal de compra surgisse, sendo que, caso houvesse mais de um sinal de compra entre os ativos, o limite diário disponível deveria ser dividido de forma equitativa entre o número de sinais. E, caso mais de um sinal fosse destacado para um mesmo ativo num mesmo dia de decisão, apenas aquele sinal com maior promessa de rentabilidade seria escolhido.

4 RESULTADOS E DISCUSSÃO

O estudo foi realizado com o objetivo principal de estruturar um modelo baseado na técnica de redes neurais para tomar decisão de compra e venda de ativos financeiros do mercado de capitais brasileiro, explorando, para tanto, conhecimentos da análise técnica.

Neste capítulo apresentam-se os resultados e discussão acerca dos dados empíricos da pesquisa. Inicialmente, é avaliado se as séries dos ativos estudados seguem um movimento browniano. Em seguida apresenta-se o modelo para tomada de decisão de compra e venda de ativos, construído a partir de previsões calculadas pela técnica de redes neurais. E para finalizar compara-se os resultados do modelo proposto com outras opções de investimentos disponíveis no mercado brasileiro.

4.1 Hipótese de *random walk*

Nesta seção busca-se atender ao objetivo específico de “investigar se as séries temporais dos retornos das principais ações do mercado brasileiro apresentam existência de memória de longo prazo, a fim de confirmar ou descartar a hipótese de *random walk*”. A confirmação ou não da premissa de *random walk* da série temporal dos ativos pesquisados contribuiu de forma incisiva com a proposta de estruturação de um modelo de previsão firmado em dados históricos.

Dessa forma, seguindo os passos previamente destacados no capítulo 3 do presente trabalho, coletou-se a base de dados necessária. Em seguida, como forma de apresentação de uma visão geral da série temporal a ser explorada, elaboraram-se gráficos de distribuição da cotação de fechamento diária e de \ln -retornos de cada um dos ativos do estudo.

Em seguida, utilizou-se algumas ferramentas da estatística descritiva para sumarizar cada uma das séries dos ativos da amostra. Assim sendo, na Tabela 1 apresentam-se algumas dessas estatísticas das séries *ln*-retornos diários. Destaca-se, aqui, que as médias de todas as séries são estatisticamente diferentes de zero, para um nível de significância de 5%. Com relação ao coeficiente de variação de Pearson, verificam-se índices bastante altos, sinalizando, assim, uma alta dispersão dos dados.

Quanto à assimetria dos dados da distribuição, infere-se que a maioria das séries tem uma assimetria positiva, sendo algumas num grau forte, tais como ITSA4, ITUB4, LAME4 e TRPL4. Destacam-se também os valores altos para os índices de curtose de Pearson dos ativos, colocando sob suspeita o padrão de distribuição das séries temporais. A fim de se confirmar a suspeita levantada anteriormente, recorreu-se ao teste de normalidade Jarque-Bera, em que é possível observar a rejeição, ao nível de confiança de 99%, da hipótese nula de normalidade. Foi possível, assim, comprovar que há indícios de que todas as séries não seguem uma distribuição gaussiana, o que confirma as características das séries financeiras apresentadas pelos valores de curtose e assimetria.

Tabela 1 Estatística descritiva dos ativos pesquisados

| Ativo | Média | Desvio Padrão | Coefic. Variação | Assimetria | Curtose | Jarque-Bera | |
|-------|-------|---------------|------------------|------------|---------|-------------|---------|
| | | | | | | Statistic | p-valor |
| BBDC4 | 0,081 | 2,408 | 29,728 | 0,274 | 3,492 | 1.558,960 | 0,000 |
| BBAS3 | 0,099 | 2,765 | 27,929 | 0,202 | 2,919 | 1.080,740 | 0,000 |
| BRKM5 | 0,039 | 2,850 | 73,077 | 0,218 | 2,463 | 778,027 | 0,000 |
| CMIG4 | 0,071 | 2,439 | 34,352 | 0,095 | 1,229 | 192,214 | 0,000 |
| CPL6 | 0,042 | 2,601 | 61,929 | 0,126 | 1,769 | 396,819 | 0,000 |
| CRUZ3 | 0,116 | 2,296 | 19,793 | 0,183 | 2,677 | 908,142 | 0,000 |
| CSNA3 | 0,111 | 2,869 | 25,847 | 0,048 | 3,476 | 1.504,590 | 0,000 |
| ELET3 | 0,019 | 2,899 | 152,579 | 0,087 | 1,798 | 405,785 | 0,000 |

“Tabela 1, conclusão”

| Ativo | Média | Desvio Padrão | Coefic. Variação | Assimetria | Curtose | Jarque-Bera | |
|-------|--------|---------------|------------------|------------|---------|-------------|---------|
| | | | | | | Statistic | p-valor |
| ELET3 | 0,019 | 2,899 | 152,579 | 0,087 | 1,798 | 405,785 | 0,000 |
| ELET6 | 0,034 | 2,793 | 82,147 | 0,195 | 1,871 | 454,333 | 0,000 |
| EMBR3 | 0,031 | 2,649 | 85,452 | -0,163 | 3,891 | 1.897,770 | 0,000 |
| GGBR4 | 0,091 | 2,774 | 30,484 | -0,033 | 2,396 | 714,696 | 0,000 |
| GOAU4 | 0,102 | 2,610 | 25,588 | 0,018 | 2,772 | 955,893 | 0,000 |
| ITSA4 | 0,091 | 2,351 | 25,835 | 0,414 | 5,014 | 3.215,050 | 0,000 |
| ITUB4 | 0,076 | 2,458 | 32,342 | 0,393 | 4,178 | 2.250,520 | 0,000 |
| KLBN4 | 0,072 | 2,832 | 39,333 | 0,258 | 2,065 | 563,345 | 0,000 |
| LAME4 | 0,124 | 2,989 | 24,105 | 0,470 | 4,893 | 3091,140 | 0,000 |
| LIGT3 | -0,017 | 3,143 | 184,882 | 0,229 | 4,620 | 2682,800 | 0,000 |
| OIBR4 | 0,014 | 2,807 | 200,500 | 0,240 | 3,832 | 1855,950 | 0,000 |
| PCAR4 | 0,033 | 2,303 | 69,788 | 0,185 | 2,156 | 595,198 | 0,000 |
| PETR3 | 0,075 | 2,423 | 32,307 | 0,051 | 3,580 | 1.596,290 | 0,000 |
| PETR4 | 0,068 | 2,302 | 33,853 | -0,099 | 3,556 | 1.578,860 | 0,000 |
| SBSP3 | 0,053 | 2,598 | 49,019 | 0,001 | 2,603 | 842,890 | 0,000 |
| TIMP3 | 0,035 | 3,492 | 99,771 | -0,045 | 5,048 | 3.173,580 | 0,000 |
| TRPL4 | 0,109 | 2,879 | 26,413 | 0,506 | 6,981 | 6.195,760 | 0,000 |
| USIM5 | 0,079 | 3,057 | 38,696 | 0,030 | 1,863 | 431,845 | 0,000 |
| VALE3 | 0,101 | 2,423 | 23,990 | -0,080 | 4,547 | 2.576,590 | 0,000 |
| VALE5 | 0,096 | 2,337 | 24,344 | -0,080 | 3,567 | 1.586,990 | 0,000 |
| VIVT4 | 0,051 | 2,140 | 41,961 | -0,260 | 5,100 | 3.271,640 | 0,000 |

O próximo passo foi, finalmente, verificar se as séries dos ativos pesquisados apresentam uma memória de longo prazo. Para tanto, conforme já destacado, utilizou-se o coeficiente de Hurst.

Como procedimento de mensuração do coeficiente de Hurst, a estatística R/S foi calculada para 29 variações simétricas de partições.

Em seguida, como etapa final, processou-se um modelo de regressão linear simples, resultando, assim, na indicação do coeficiente de Hurst de cada ativo, sendo que o \ln do número de observações por partição (n) assumiu o papel de variável independente e o \ln da estatística R/S, a variável dependente. O resultado do coeficiente de Hurst está apresentado na Tabela 2.

Tabela 2 Coeficiente de Hurst dos ativos

| Ativo | Coef. Hurst | Ativo | Coef. Hurst |
|-------|-------------|-------|-------------|
| BBDC4 | 0,5840 | LAME4 | 0,6393 |
| BBAS3 | 0,5741 | OIBR4 | 0,5665 |
| BRKM5 | 0,6565 | PCAR4 | 0,5921 |
| CMIG4 | 0,5645 | PETR3 | 0,5882 |
| CPLE6 | 0,5615 | PETR4 | 0,5908 |
| ELET3 | 0,5690 | SBSP3 | 0,5845 |
| ELET6 | 0,5614 | CSNA3 | 0,6157 |
| EMBR3 | 0,6015 | CRUZ3 | 0,5659 |
| GGBR4 | 0,6129 | VIVT4 | 0,5900 |
| GOAU4 | 0,6149 | TIMP3 | 0,5398 |
| ITSA4 | 0,5878 | TRPL4 | 0,5717 |
| ITUB4 | 0,5713 | USIM5 | 0,6229 |
| KLBN4 | 0,5806 | VALE3 | 0,5749 |
| LIGT3 | 0,5823 | VALE5 | 0,5711 |

Conforme se percebe na Tabela 2, todos os coeficientes de Hurst apresentaram valores estatisticamente acima de 0,50, para um nível de significância de 5%. Dessa forma, os resultados evidenciam que as séries dos ativos pesquisados têm características de memória de longo prazo. Ou seja, o impacto que ocorre no retorno de cada ativo tende a repercutir por vários dias.

Os resultados encontrados corroboram fortemente com a tese de construção de um modelo de previsão baseado em dados históricos, capaz de produzir resultados econômicos positivos no processo de compra e venda de ativos no curtíssimo prazo.

4.2 Implementação da rede neural

A presente seção firma-se em atender ao objetivo específico proposto de construir um modelo baseado em redes neurais artificiais para a tomada de decisão de compra e venda de ativos financeiros do mercado de capitais brasileiro. Dessa forma, seguindo os parâmetros elencados no capítulo 3, foram

realizados um grande número de simulações, ratificando que o processo de estruturação de uma rede neural requer um trabalho de tentativa e erro para o seu melhor ajuste na resposta a um problema. Não obstante, o responsável por projetar a rede tem um importante papel ao direcionar as infinitas possibilidades de parâmetros da mesma.

Assim, o passo inicial foi executar todos os 50 arranjos de redes neurais elencados no capítulo 3, para cada dia-alvo (d+1; d+2; d+3; d+4; d+5), entre as três partições temporais assumidas. Para isso, utilizaram-se o *software* Matlab e sua *toolbox* de redes neurais, tendo os comandos para a ativação da rede sido construídos utilizando-se a ferramenta *Editor*. A “função raiz” desenvolvida tem 200 linhas de comando em linguagem C++. Já os dados matriciados, utilizados para “alimentar” todos os testes, foram importados do *software* Excel, em que foram previamente preparados e calculados.

Para a execução do experimento, utilizaram-se computadores com a seguinte configuração básica: processador Intel *quad-core*, 8 MB de memória RAM e sistema operacional Microsoft Windows 2007. A realização completa dos testes, que suportariam a escolha do melhor arranjo para os dias-alvos para a sua respectiva partição de cada uma das ações estudadas, consumiu aproximadamente 69 horas de processamento computacionais. Ou seja, a realização da etapa aqui descrita, para todos os 28 ativos presentes na amostra do trabalho, demandou, aproximadamente, 1.932 horas computacionais.

O passo seguinte foi avaliar quais os arranjos de redes que se apresentaram entre os mais adequados para serem adotados na projeção dos dados a serem simulados, ratificando que, para cada arranjo de rede, foram feitas 30 iterações, dado que a rede neural inicia o processo de aprendizado a partir de um ponto e pesos aleatórios. Feitas as 30 iterações, calcularam-se a média, o desvio padrão e o coeficiente de variação de Pearson para as medidas de desempenho (erro médio quadrático, *POCID*, R^2 e *U-Theil*) selecionadas, para,

assim, direcionar a escolha do melhor arranjo de rede frente a um melhor conjunto de resultados das medidas de desempenho.

Para a escolha desse melhor arranjo de rede, utilizou-se uma avaliação multicritério (erro médio quadrático, quanto menor melhor; *POCID*, quanto mais próximo de 1 melhor; R^2 , quanto mais próximo de 1 melhor e *U-Theil*, quanto menor melhor), levando em consideração o coeficiente de variação dessas medidas. Como critério para seleção, adotaram-se, como ordem de prioridade, os resultados de *POCID*, R^2 e *U-Theil* erro médio quadrático. Não obstante, procurou-se avaliar o resultado do coeficiente de variação, no intuito de selecionar os arranjos de rede que apresentassem uma maior segurança na replicação da rede.

A fim de ilustrar o procedimento descrito acima, aleatoriamente, selecionaram-se os resultados do ativo PETR4, referentes aos testes para partição 1 com projeção d+1(Tabela 3).

Tabela 3 Resultados das simulações das redes do ativo PETR4

| Rede | Média | | | | Coef. de Variação | | | |
|-----------|---------|---------|--------|--------|-------------------|-------|--------|-------|
| | EMQ | Pocid | Utheil | R2 | EMQ | Pocid | Utheil | R2 |
| 4 | 0,00026 | 85,7971 | 0,8038 | 0,9521 | 34,6% | 2,4% | 17,5% | 1,3% |
| 12 | 0,00069 | 84,7101 | 1,1274 | 0,8956 | 192,7% | 4,7% | 63,2% | 14,6% |
| 2 | 0,00030 | 84,6377 | 0,8578 | 0,9384 | 37,5% | 2,4% | 19,7% | 2,2% |
| 7 | 0,00048 | 83,9855 | 0,9913 | 0,9078 | 127,8% | 5,3% | 49,3% | 10,9% |
| 1 | 0,00033 | 83,8406 | 0,8851 | 0,9326 | 45,3% | 3,2% | 22,0% | 4,1% |
| 3 | 0,00090 | 83,8406 | 1,3101 | 0,8900 | 150,9% | 6,4% | 59,5% | 17,7% |
| 5 | 0,00025 | 82,7536 | 0,7759 | 0,9531 | 24,0% | 3,6% | 11,8% | 1,0% |
| 8 | 0,00055 | 82,6087 | 1,0217 | 0,8968 | 188,0% | 8,1% | 60,5% | 16,4% |
| 10 | 0,00087 | 82,3913 | 1,1246 | 0,8879 | 265,7% | 5,6% | 89,7% | 17,3% |
| 14 | 0,00026 | 81,4493 | 0,7846 | 0,9504 | 42,3% | 4,6% | 19,2% | 2,1% |
| 18 | 0,00030 | 79,8551 | 0,8474 | 0,9481 | 46,9% | 4,7% | 21,9% | 1,3% |
| 6 | 0,00029 | 79,7826 | 0,8335 | 0,9433 | 37,7% | 6,1% | 17,7% | 2,2% |
| 31 | 0,00032 | 79,5652 | 0,8764 | 0,9311 | 43,7% | 5,8% | 21,2% | 3,7% |
| 21 | 0,00022 | 79,1304 | 0,7276 | 0,9516 | 19,8% | 6,5% | 10,5% | 0,9% |

“Tabela 3, conclusão”

| Rede | Média | | | | Coef. de Variação | | | |
|------|---------|---------|--------|--------|-------------------|-------|--------|--------|
| | EMQ | Pocid | Utheil | R2 | EMQ | Pocid | Utheil | R2 |
| 20 | 0,00029 | 78,4058 | 0,8368 | 0,9438 | 26,1% | 7,2% | 13,3% | 1,6% |
| 19 | 0,00141 | 78,1884 | 1,1969 | 0,9055 | 351,9% | 7,4% | 126,7% | 15,3% |
| 32 | 0,00037 | 78,0435 | 0,9529 | 0,9308 | 30,5% | 5,8% | 16,1% | 3,0% |
| 27 | 0,00032 | 77,6087 | 0,8772 | 0,9298 | 41,3% | 6,9% | 19,5% | 4,0% |
| 38 | 0,00029 | 77,5362 | 0,8387 | 0,9407 | 47,6% | 4,9% | 21,3% | 2,2% |
| 24 | 0,00032 | 77,3188 | 0,8786 | 0,9464 | 33,8% | 5,9% | 16,6% | 1,6% |
| 35 | 0,00033 | 76,6667 | 0,8944 | 0,9327 | 30,6% | 5,8% | 15,4% | 2,0% |
| 29 | 0,00026 | 76,6667 | 0,8063 | 0,9412 | 24,1% | 9,8% | 11,6% | 1,6% |
| 25 | 0,00027 | 75,8696 | 0,8118 | 0,9402 | 39,4% | 6,9% | 20,1% | 2,3% |
| 26 | 0,00032 | 75,7971 | 0,8747 | 0,9424 | 36,1% | 5,9% | 17,0% | 1,7% |
| 30 | 0,00029 | 75,6522 | 0,8411 | 0,9388 | 32,1% | 9,0% | 15,9% | 2,8% |
| 28 | 0,00033 | 75,4348 | 0,8534 | 0,9241 | 110,0% | 5,6% | 38,7% | 9,6% |
| 48 | 0,00047 | 75,1449 | 1,0645 | 0,9110 | 43,8% | 6,3% | 21,6% | 5,0% |
| 36 | 0,00036 | 75,0725 | 0,9427 | 0,9214 | 38,0% | 6,2% | 18,9% | 3,9% |
| 46 | 0,00042 | 75,0725 | 1,0057 | 0,9187 | 41,5% | 7,0% | 20,7% | 3,3% |
| 34 | 0,00032 | 74,9275 | 0,8720 | 0,9338 | 45,8% | 7,2% | 21,4% | 3,0% |
| 23 | 0,00053 | 74,5652 | 1,0405 | 0,9133 | 140,9% | 6,3% | 51,5% | 7,5% |
| 33 | 0,00033 | 74,1304 | 0,8967 | 0,9386 | 28,6% | 6,7% | 14,0% | 1,6% |
| 39 | 0,00038 | 74,0580 | 0,9603 | 0,9208 | 47,6% | 5,8% | 20,6% | 6,4% |
| 44 | 0,00044 | 73,3333 | 1,0314 | 0,9263 | 36,6% | 6,7% | 19,4% | 2,1% |
| 37 | 0,00037 | 73,2609 | 0,9538 | 0,9177 | 38,1% | 8,2% | 19,3% | 3,3% |
| 42 | 0,00040 | 73,0435 | 0,9933 | 0,9146 | 30,1% | 6,7% | 15,3% | 3,2% |
| 45 | 0,00047 | 72,8986 | 1,0583 | 0,9018 | 57,5% | 9,1% | 27,0% | 9,6% |
| 49 | 0,00051 | 72,7536 | 1,1081 | 0,8977 | 51,6% | 8,2% | 25,2% | 6,9% |
| 40 | 0,00037 | 72,6812 | 0,9533 | 0,9258 | 37,0% | 7,9% | 17,2% | 2,3% |
| 47 | 0,00084 | 72,6087 | 1,2846 | 0,8509 | 172,1% | 7,1% | 56,3% | 23,7% |
| 41 | 0,00042 | 71,4493 | 1,0023 | 0,9167 | 47,4% | 7,2% | 23,5% | 3,6% |
| 43 | 0,00047 | 71,4493 | 1,0733 | 0,9056 | 36,0% | 10,2% | 18,0% | 4,4% |
| 50 | 0,00054 | 70,5072 | 1,1555 | 0,8954 | 33,4% | 7,4% | 17,8% | 4,9% |
| 22 | 0,03595 | 56,2319 | 9,5824 | 0,3809 | 8,6% | 9,6% | 4,3% | 18,1% |
| 16 | 0,03480 | 54,7101 | 9,4322 | 0,4291 | 6,4% | 16,3% | 3,3% | 26,5% |
| 17 | 0,03361 | 51,8116 | 9,2643 | 0,3713 | 11,8% | 14,8% | 5,9% | 36,9% |
| 11 | 0,00110 | 47,4638 | 1,4411 | 0,8357 | 192,7% | 6,9% | 61,8% | 18,9% |
| 15 | 0,00064 | 46,1594 | 1,2412 | 0,8560 | 52,5% | 7,2% | 23,2% | 6,5% |
| 9 | 0,00086 | 44,6377 | 1,4541 | 0,8025 | 47,4% | 6,5% | 20,6% | 13,2% |
| 13 | 0,03570 | 43,9855 | 9,5773 | 0,0073 | 4,2% | 8,9% | 2,1% | 131,1% |

Analisando-se os resultados da Tabela 3, que foram organizados em ordem decrescente de *POCID*, pode-se perceber que, segundo os critérios adotados para a escolha do melhor arranjo de rede, a Rede 4 foi aquela que apresentou as melhores medidas de desempenho, frente às demais. Assim, para utilizar na simulação dos dados da primeira partição da projeção de $d+1$ do ativo PETR4, a Rede 4, que tem como característica utilizar três variáveis de *input* (*Cfech*; *MM10_Rent*; *Rent_Ibov*) e a arquitetura de neurônios ocultos de $6 \times 3 \times 3$, foi a escolhida.

Para uma visão geral de quais arranjos de redes foram escolhidos como melhores para cada ativo, dadas as três partições e as variações de dias simulados, elaborou-se o Gráfico 1.

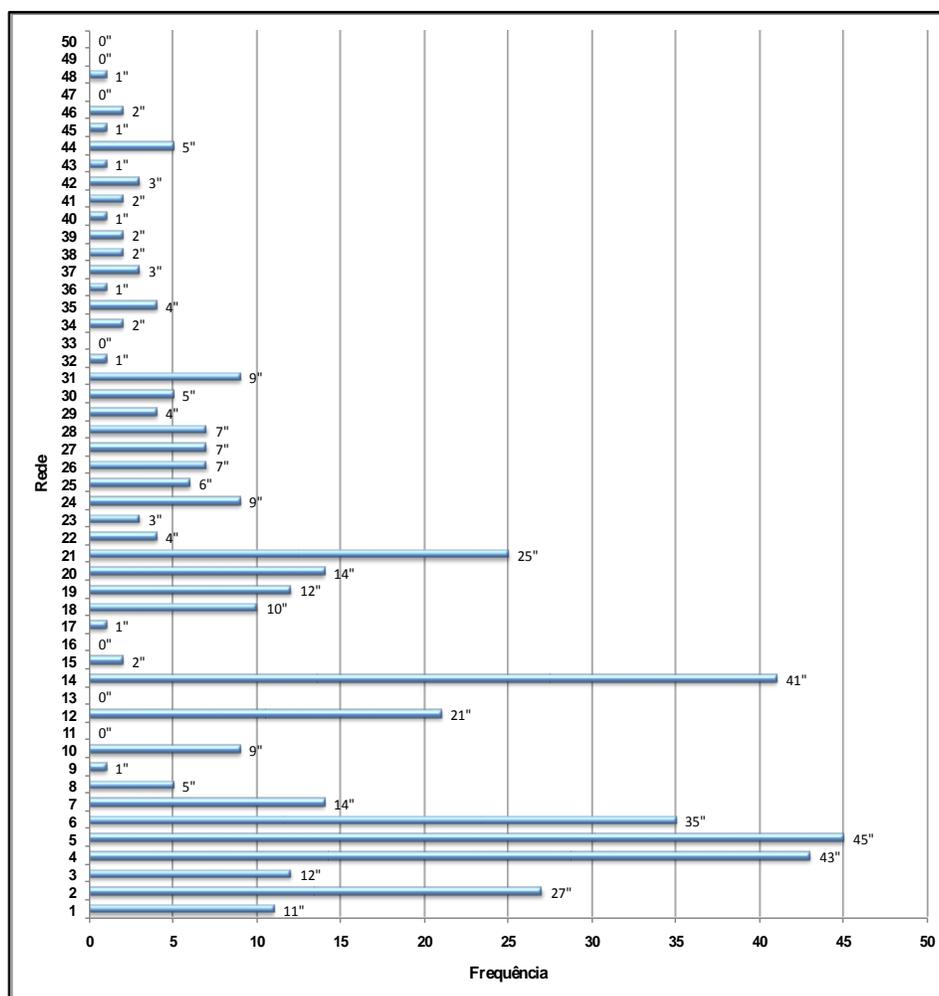


Gráfico 1 Distribuição dos arranjos das redes neurais selecionadas

Para analisar o Gráfico 1, ressalta-se que 420 arranjos de redes precisaram ser escolhidos, pois a amostra é composta por 28 ativos, tendo sido avaliadas três partições temporais para cinco dias de projeção. Assim sendo, pode-se perceber que as redes 5, 4, 14, 6, 2 e 21 são responsáveis por cerca de 52% do total das redes escolhidas. Entre essas redes que capitanearam um maior número de escolhas, alguns pontos são importantes de serem destacados: entre

as dezesseis variáveis possíveis para comporem os *inputs*, a rede com maior número de entradas tem seis variáveis (Rede 21), ou seja, houve uma melhor adequação entre o *target* (alvo) e o projetado para aquelas redes, com um número de neurônios mais reduzido. Percebe-se que pouco adianta “abastecer” a rede com um número excessivo de informações. Prova disso é que as redes com dez ou mais variáveis de entrada responderam, apenas, por, aproximadamente, 7% das redes escolhidas; outro ponto é que, das seis redes escolhidas como as de maiores frequência de escolha, apenas duas não têm na sua configuração os neurônios que representam a formação dos *candles*, o que faz com que o principal instrumento de trabalho da análise técnica seja observado como um ponto importante na projeção de cotações futuras.

Uma vez, então, que, para todas as simulações, os diversos arranjos de redes foram avaliados e selecionados aqueles de melhores desempenho, o próximo passo foi reproduzir o treinamento e a simulação dessas redes para seus respectivos ativos. A fim de armazenar os valores futuros simulados e verificar o quão adequados estes são para a configuração de um modelo de compra e venda de ativos financeiros, a seguir, ilustra-se esse procedimento por meio, novamente, da ação PETR4. Para tanto, apresentam-se a Tabela 4, na qual se indicam os resultados alcançados das redes escolhidas como as de melhores desempenho, e a Tabela 5, que se refere às medidas de desempenho das redes, para a fase de simulação.

Tabela 4 Resultado das redes selecionadas do ativo PETR4

| Partição | Projeção | Rede | EMQ | Pocid | Utheil | R2 |
|----------|----------|-----------|--------|---------|--------|--------|
| 1 | d+1 | 4 | 0,0003 | 85,7971 | 0,8038 | 0,9521 |
| | d+2 | 4 | 0,0012 | 60,1471 | 1,2603 | 0,7986 |
| | d+3 | 18 | 0,0019 | 54,7761 | 1,2924 | 0,6827 |
| | d+4 | 18 | 0,0023 | 58,2576 | 1,2096 | 0,5887 |
| | d+5 | 24 | 0,0033 | 59,4615 | 1,2782 | 0,5434 |
| 2 | d+1 | 14 | 0,0002 | 79,8551 | 0,6025 | 0,9817 |
| | d+2 | 14 | 0,0010 | 70,2206 | 0,9800 | 0,9102 |
| | d+3 | 14 | 0,0016 | 56,8657 | 0,9980 | 0,8559 |
| | d+4 | 14 | 0,0026 | 53,0303 | 1,0789 | 0,7726 |
| | d+5 | 14 | 0,0034 | 56,0769 | 1,0679 | 0,6978 |
| 3 | d+1 | 3 | 0,0001 | 85,5072 | 0,4470 | 0,9743 |
| | d+2 | 10 | 0,0006 | 59,1176 | 0,9044 | 0,8114 |
| | d+3 | 18 | 0,0010 | 52,2388 | 0,9458 | 0,6866 |
| | d+4 | 23 | 0,0010 | 56,0606 | 0,9310 | 0,6839 |
| | d+5 | 5 | 0,0010 | 53,7692 | 0,8759 | 0,6288 |

Tabela 5 Resultado dareprodução das redes simuladas do ativo PETR4

| Partição | Projeção | Rede | EMQ | Pocid | Utheil | R2 |
|----------|----------|-----------|--------|---------|--------|--------|
| 1 | D+1 | 4 | 0,0003 | 85,5072 | 0,7967 | 0,9240 |
| | D+2 | 4 | 0,0017 | 61,7647 | 1,5619 | 0,7783 |
| | D+3 | 18 | 0,0034 | 52,2388 | 1,7771 | 0,5460 |
| | D+4 | 18 | 0,0028 | 60,6061 | 1,3611 | 0,5969 |
| | D+5 | 24 | 0,0039 | 50,7692 | 1,3979 | 0,5740 |
| 2 | D+1 | 14 | 0,0001 | 79,7101 | 0,4838 | 0,9866 |
| | D+2 | 14 | 0,0009 | 69,1176 | 0,9539 | 0,9006 |
| | D+3 | 14 | 0,0012 | 58,2090 | 0,8954 | 0,8684 |
| | D+4 | 14 | 0,0027 | 50,0000 | 1,1017 | 0,7452 |
| | D+5 | 14 | 0,0033 | 50,7692 | 1,0503 | 0,7068 |
| 3 | D+1 | 3 | 0,0001 | 86,3014 | 0,5297 | 0,9650 |
| | D+2 | 10 | 0,0007 | 58,3333 | 0,9551 | 0,8354 |
| | D+3 | 18 | 0,0008 | 59,1549 | 0,8843 | 0,7682 |
| | D+4 | 23 | 0,0010 | 60,0000 | 0,9620 | 0,6863 |
| | D+5 | 5 | 0,0009 | 46,3768 | 0,8384 | 0,7033 |

Analisando-se as Tabelas 4 e 5, pode-se perceber que os valores da reprodução das redes, quando na fase de simulação, assemelham-se aos da fase de avaliação. Por isso, foi importante levar em consideração o coeficiente de variação no momento de escolha da melhor rede, para evitar grandes variações de resultados.

4.3 Simulações do modelo

Uma vez verificado quais os arranjos de redes que apresentavam melhor desempenho e reprocessados essas redes selecionadas, foram armazenadas todas as projeções de preços futuros, a fim de verificar como se estabeleceria um modelo de tomada de decisão de compra e venda de ações baseado na técnica de rede neural.

Um ponto importante na estruturação desse modelo foi definir quando é que seria tomada a decisão de compra e venda de ação, pois o simples fato de prever um preço futuro acima do preço disponível para compra não credenciaria uma possível decisão de compra de uma ação, uma vez que existem custos envolvidos numa operação de compra e venda de um ativo financeiro, custos estes destacados na Seção 3.3.3.

Assim, definiu-se por criar um critério de teto mínimo e máximo de ganho como intervalo para balizar uma decisão de compra. Quanto à decisão de venda do ativo, estabeleceu-se que, uma vez adquirido um ativo com a promessa de ganho para uma determinada data futura, essa venda seria executada independentemente de o retorno-alvo ter sido alcançado ou não.

É importante ressaltar que as previsões do preço de abertura de um determinado ativo para os próximos cinco dias só se realizariam após o fechamento do pregão. Ou seja, o valor de fechamento de ativo não poderia ser utilizado como balizador para testar o modelo, uma vez que, no momento em

que as previsões foram realizadas, esse passaria a ser um dado pretérito. Assim, adotou-se como premissa do modelo que o valor disponível para compra passaria a ser o preço de abertura do dia posterior ao da previsão. Dessa forma, quando o ativo fosse adquirido, o período temporal mais longínquo de previsão passaria a ser de quatro dias.

Estabelecidas essas condições gerais para testar o modelo, algumas variações nos parâmetros foram realizadas, a fim de verificar como seria o resultado alcançado frente a essas variações.

4.3.1 Simulação 1

Para realizar a primeira simulação, além das definições gerais citadas na seção anterior, ficaram estabelecidos os seguintes parâmetros específicos:

- a) teto mínimo para compra: 2,00%;
- b) teto máximo para compra: 10,00%.

Com base na definição das condições do modelo, e utilizando-se os valores projetados dos melhores arranjos de redes, o resultado alcançado para cada ativo é apresentado na Tabela 6.

Tabela 6 Resultados da Simulação 1

| Ativo | Retorno (R\$) | Ativo | Retorno (R\$) |
|--------------|----------------------|--------------|----------------------|
| BBAS3 | 2.476,25 | KLBN4 | -7.997,50 |
| BBDC4 | -1.453,55 | LAME4 | 6.736,34 |
| BRKM5 | 4.835,73 | LIGT3 | 9.299,96 |
| CMIG4 | 12.365,22 | OIBR4 | -18.868,44 |
| CPLE6 | 4.691,14 | PCAR4 | 15.001,24 |
| CRUZ3 | 7.654,52 | PETR3 | -28.262,64 |
| CSNA3 | -41.001,26 | PETR4 | -3.854,71 |
| ELET3 | 6.489,50 | SBSP3 | 13.055,11 |
| ELET6 | -4.185,53 | TIMP3 | 15.644,10 |
| EMBR3 | 12.357,42 | TRPL4 | -6.803,21 |
| GGBR4 | -11.618,41 | USIM5 | 7.483,81 |
| GOAU4 | 4.849,24 | VALE3 | -3.781,19 |
| ITSA4 | 3.263,47 | VALE5 | -24.018,60 |
| ITUB4 | -317,28 | VIVT4 | 3.220,56 |
| TOTAL | | | -22.738,69 |

Pode-se destacar, a partir de uma análise da Tabela 6, que o lucro máximo alcançado entre todos os 28 ativos foi com a ação TIMP3, no valor de R\$ 15.644,10. Já o maior prejuízo foi de R\$ 41.001,26, da CSNA3. Em 57% dos ativos obteve-se um resultado positivo. Contudo, apesar de ser minoria os ativos que tiveram resultado negativo, em valores monetários eles foram altos, acabando assim por comprometer o resultado global do modelo, gerando um prejuízo de R\$ 22.738,69.

Na Tabela 7 apresentam-se, de forma detalhada, os sinais destacados para compra. Percebe-se que, ao longo dos 198 pregões, surgiram, ao todo, 1.666 sinais de compra. Contudo, 50,3% desses sinais resultaram em algum prejuízo dos valores investidos. O maior percentual de sinais corretos é do ativo BBAS3, em que 100% dos sinais para compra desta ação resultaram em lucro, enquanto que, para o ativo VALE5, foi observado o maior nível de erro. Ao final, apenas 37,93% dos sinais de compra resultaram em algum lucro.

Tabela 7 Sinais de compra da Simulação 1

| Ativo | Certo | | | Errado | | | R\$ Líquido |
|--------------|------------|--------|-------------------|------------|-------|--------------------|-------------------|
| | Quant. | % | R\$ | Quant. | % | R\$ | |
| BBAS3 | 5 | 100,00 | 2.476,25 | 0 | 0,00 | 0,00 | 2.476,25 |
| BBDC4 | 5 | 41,67 | 1.900,68 | 7 | 58,33 | -3.354,22 | -1.453,55 |
| BRKM5 | 12 | 57,14 | 8.461,60 | 9 | 42,86 | -3.625,87 | 4.835,73 |
| CMIG4 | 28 | 59,57 | 20.923,14 | 19 | 40,43 | -8.557,92 | 12.365,22 |
| CPLE6 | 29 | 53,70 | 20.120,16 | 25 | 46,30 | -15.429,03 | 4.691,14 |
| CRUZ3 | 20 | 76,92 | 13.067,95 | 6 | 23,08 | -5.413,43 | 7.654,52 |
| CSNA3 | 41 | 39,05 | 31.708,02 | 64 | 60,95 | -72.709,28 | -41.001,26 |
| ELET3 | 32 | 47,06 | 39.548,16 | 36 | 52,94 | -33.058,67 | 6.489,50 |
| ELET6 | 43 | 43,00 | 52.193,51 | 57 | 57,00 | -56.379,03 | -4.185,53 |
| EMBR3 | 32 | 64,00 | 20.806,58 | 18 | 36,00 | -8.449,16 | 12.357,42 |
| GGBR4 | 25 | 47,17 | 15.254,44 | 28 | 52,83 | -26.872,85 | -11.618,41 |
| GOAU4 | 33 | 55,00 | 22.539,68 | 27 | 45,00 | -17.690,44 | 4.849,24 |
| ITSA4 | 7 | 58,33 | 4.601,68 | 5 | 41,67 | -1.338,21 | 3.263,47 |
| ITUB4 | 5 | 71,43 | 537,08 | 2 | 28,57 | -854,36 | -317,28 |
| KLBN4 | 23 | 46,94 | 14.044,11 | 26 | 53,06 | -22.041,62 | -7.997,50 |
| LAME4 | 33 | 62,26 | 19.624,77 | 20 | 37,74 | -12.888,44 | 6.736,34 |
| LIGT3 | 65 | 51,18 | 52.178,68 | 62 | 48,82 | -42.878,72 | 9.299,96 |
| OIBR4 | 36 | 40,91 | 64.243,32 | 52 | 59,09 | -83.111,76 | -18.868,44 |
| PCAR4 | 36 | 64,29 | 23.764,81 | 20 | 35,71 | -8.763,57 | 15.001,24 |
| PETR3 | 47 | 41,59 | 30.800,94 | 66 | 58,41 | -59.063,58 | -28.262,64 |
| PETR4 | 51 | 48,57 | 37.437,15 | 54 | 51,43 | -41.291,86 | -3.854,71 |
| SBSP3 | 23 | 52,27 | 28.212,44 | 21 | 47,73 | -15.157,33 | 13.055,11 |
| TIMP3 | 15 | 65,22 | 19.698,19 | 8 | 34,78 | -4.054,09 | 15.644,10 |
| TRPL4 | 38 | 53,52 | 22.312,34 | 33 | 46,48 | -29.115,55 | -6.803,21 |
| USIM5 | 43 | 49,43 | 49.788,44 | 44 | 50,57 | -42.304,62 | 7.483,81 |
| VALE3 | 46 | 46,00 | 31.982,56 | 54 | 54,00 | -35.763,74 | -3.781,19 |
| VALE5 | 44 | 37,93 | 23.649,44 | 72 | 62,07 | -47.668,04 | -24.018,60 |
| VVIT4 | 11 | 78,57 | 4.108,89 | 3 | 21,43 | -888,33 | 3.220,56 |
| TOTAL | 828 | | 675.985,01 | 838 | | -698.723,72 | -22.738,71 |

Destaca-se, ainda, que, apesar da disponibilidade de R\$ 1.000.000,00 para investimento, o pico diário de recursos aplicados foi de R\$ 972.222,22, tendo sido mantida uma média diária de investimento na ordem de R\$ 745.104,60. Para efeitos de cálculo de rentabilidade, utilizou-se o valor que o investidor teria disponível para aplicar, que era R\$ 1.000.000,00. Assim, caso fosse utilizado o modelo aqui sugerido no período de análise, o investidor

alcançaria uma rentabilidade negativa de 2,27% para um período de 292 dias “corridos” ou uma rentabilidade anual equivalente de -2,80%.

4.3.2 Simulação 2

Já para a segunda simulação, estabeleceram-se os seguintes parâmetros específicos:

- a) teto mínimo para compra: 2,25%;
- b) teto máximo para compra: 12,00%.

Promovendo essas alterações de intervalo para estabelecer os sinais de compra, destaca-se, por meio da Tabela 8, o retorno para cada um dos ativos.

Tabela 8 Resultado Simulação 2

| Ativo | Retorno (R\$) | Ativo | Retorno (R\$) |
|--------------|----------------------|--------------|----------------------|
| BBAS3 | 960,96 | KLBN4 | -9.742,44 |
| BBDC4 | -1.088,78 | LAME4 | 6.520,15 |
| BRKM5 | 5.273,71 | LIGT3 | 21.793,32 |
| CMIG4 | 7.225,96 | OIBR4 | -20.786,17 |
| CPLE6 | 5.014,75 | PCAR4 | 16.066,79 |
| CRUZ3 | 10.725,94 | PETR3 | -27.695,81 |
| CSNA3 | -46.850,28 | PETR4 | 7.398,51 |
| ELET3 | 7.891,88 | SBSP3 | 11.592,27 |
| ELET6 | -4.720,71 | TIMP3 | 18.220,69 |
| EMBR3 | 12.762,13 | TRPL4 | -10.895,86 |
| GGBR4 | -10.933,42 | USIM5 | 6.413,20 |
| GOAU4 | 5.335,92 | VALE3 | -9.367,53 |
| ITSA4 | 4.778,24 | VALE5 | -21.328,10 |
| ITUB4 | 256,57 | VIVT4 | 3.579,63 |
| TOTAL | | | -11.598,49 |

Repetindo o ocorrido na Simulação 1, o modelo proposto para a Simulação 2 apresentou um resultado final insatisfatório, uma vez que produziu um prejuízo de R\$ 11.598,49. Destaca-se também que, na Simulação 2, o número de ativos que alçou algum lucro ao final foi de 64%. Contudo, tanto os tetos máximos de ganho quanto de perda aumentaram; o maior ganho foi de R\$ 21.793,32 e a maior perda de R\$ 46.850,28.

A rentabilidade da Simulação 2, tal como ocorreu na Simulação 1, foi negativa, tendo apresentado um resultado de -1,16% para o período analisado, ou uma rentabilidade anual equivalente de -1,43%.

Na Tabela 9 apresenta-se um resumo do nível de assertividade dos sinais de compra. Percebe-se que o nível de erros, apesar de ainda alto, apresentou uma pequena melhora no rendimento, se comparado à Simulação 1.

Tabela 9 Sinais de compra da Simulação 2

| Ativo | Certo | | | Errado | | | R\$ Líquido |
|-------|--------|--------|-----------|--------|-------|------------|-------------|
| | Quant. | % | R\$ | Quant. | % | R\$ | |
| BBAS3 | 3 | 100,00 | 960,96 | 0 | 0,00 | 0,00 | 960,96 |
| BBDC4 | 4 | 40,00 | 1.083,43 | 6 | 60,00 | -2.172,21 | -1.088,78 |
| BRKM5 | 9 | 60,00 | 8.705,68 | 6 | 40,00 | -3.431,97 | 5.273,71 |
| CMIG4 | 19 | 59,38 | 13.208,69 | 13 | 40,63 | -5.982,74 | 7.225,96 |
| CPLE6 | 25 | 58,14 | 18.361,46 | 18 | 41,86 | -13.346,70 | 5.014,75 |
| CRUZ3 | 13 | 86,67 | 13.572,42 | 2 | 13,33 | -2.846,48 | 10.725,94 |
| CSNA3 | 44 | 40,74 | 37.647,44 | 64 | 59,26 | -84.497,72 | -46.850,28 |
| ELET3 | 32 | 48,48 | 44.794,17 | 34 | 51,52 | -36.902,29 | 7.891,88 |
| ELET6 | 42 | 44,21 | 55.804,63 | 53 | 55,79 | -60.525,34 | -4.720,71 |
| EMBR3 | 28 | 65,12 | 20.784,51 | 15 | 34,88 | -8.022,38 | 12.762,13 |
| GGBR4 | 27 | 50,00 | 17.317,24 | 27 | 50,00 | -28.250,66 | -10.933,42 |
| GOAU4 | 31 | 56,36 | 24.672,46 | 24 | 43,64 | -19.336,53 | 5.335,92 |
| ITSA4 | 7 | 77,78 | 5.330,25 | 2 | 22,22 | -552,01 | 4.778,24 |
| ITUB4 | 3 | 100,00 | 256,57 | 0 | 0,00 | 0,00 | 256,57 |
| KLBN4 | 18 | 43,90 | 11.687,43 | 23 | 56,10 | -21.429,87 | -9.742,44 |
| LAME4 | 29 | 61,70 | 19.577,04 | 18 | 38,30 | -13.056,89 | 6.520,15 |
| LIGT3 | 63 | 55,26 | 55.816,63 | 51 | 44,74 | -34.023,31 | 21.793,32 |
| OIBR4 | 36 | 39,13 | 77.443,07 | 56 | 60,87 | -98.229,25 | -20.786,17 |
| PCAR4 | 29 | 64,44 | 22.907,52 | 16 | 35,56 | -6.840,73 | 16.066,79 |
| PETR3 | 46 | 41,44 | 35.502,53 | 65 | 58,56 | -63.198,35 | -27.695,81 |

“Tabela 9, conclusão”

| Ativo | Certo | | | Errado | | | R\$ Líquido |
|--------------|------------|-------|-------------------|------------|-------|--------------------|-------------------|
| | Quant. | % | R\$ | Quant. | % | R\$ | |
| PETR4 | 50 | 50,00 | 47.453,72 | 50 | 50,00 | -40.055,21 | 7.398,51 |
| SBSP3 | 20 | 50,00 | 26.625,06 | 20 | 50,00 | -15.032,80 | 11.592,27 |
| TIMP3 | 13 | 86,67 | 18.384,78 | 2 | 13,33 | -164,09 | 18.220,69 |
| TRPL4 | 34 | 53,13 | 21.574,13 | 30 | 46,88 | -32.469,99 | -10.895,86 |
| USIM5 | 41 | 52,56 | 48.983,25 | 37 | 47,44 | -42.570,06 | 6.413,20 |
| VALE3 | 39 | 42,39 | 29.197,27 | 53 | 57,61 | -38.564,80 | -9.367,53 |
| VALE5 | 43 | 39,09 | 28.351,29 | 67 | 60,91 | -49.679,40 | -21.328,10 |
| VVIT4 | 8 | 88,89 | 3.673,73 | 1 | 11,11 | -94,09 | 3.579,63 |
| TOTAL | 756 | | 709.677,36 | 753 | | -721.275,85 | -11.598,49 |

4.3.3 Simulação 3

Para a Simulação 3, definiu-se por utilizar também o resultado da medida de desempenho *U-Theil* para delinear melhor os sinais de compra. Assim, estabeleceu-se que apenas as previsões das redes que, na fase de seleção, apresentaram um valor de *U-Theil* inferior a 1 seriam utilizadas, decisão esta fundamentada na ideia de que quando o *U-Theil* é 1 ou maior, é preferível adotar decisões triviais do que utilizar o modelo ora construído. Dessa forma, além dos parâmetros indicados abaixo, apenas utilizaram-se as projeções no caso de redes que na fase de seleção apresentaram *U-Theil* inferior a 1.

- a) teto mínimo para compra: 2,00%;
- b) teto máximo para compra: 10,00%.

Frente às alterações propostas, pode-se verificar, a partir da Tabela 10, o resultado alcançado por ativo.

Tabela 10 Resultado da Simulação 3

| Ativo | Retorno (R\$) | Ativo | Retorno (R\$) |
|--------------|----------------------|--------------|----------------------|
| BBAS3 | 6.432,19 | KLBN4 | 1.454,01 |
| BBDC4 | 1.406,45 | LAME4 | 10.844,70 |
| BRKM5 | 10.803,51 | LIGT3 | 33.293,10 |
| CMIG4 | 39.520,39 | OIBR4 | 45.134,94 |
| CPLE6 | 17.334,80 | PCAR4 | 24.098,15 |
| CRUZ3 | 19.991,72 | PETR3 | 37,31 |
| CSNA3 | 24.081,33 | PETR4 | 17.691,08 |
| ELET3 | 23.158,68 | SBSP3 | 16.369,67 |
| ELET6 | 9.316,92 | TIMP3 | 25.417,59 |
| EMBR3 | 9.006,79 | TOTAL | 470.579,05 |
| GGBR4 | 2.422,96 | TRPL4 | 28.603,11 |
| GOAU4 | 24.666,76 | USIM5 | 51.656,34 |
| ITSA4 | 1.273,32 | VALE3 | 16.507,55 |
| ITUB4 | 871,88 | VALE5 | 4.051,98 |
| TOTAL | | | 470.579,05 |

O resultado melhorou consideravelmente a partir da proposta de uso do *U-Theil*. Ao contrário das simulações anteriores, nenhum dos ativos apresentou decisões que, ao final, culminaram em prejuízo. O lucro com os parâmetros aqui sugeridos foi de R\$ 470.579,05, indicando, assim, uma rentabilidade no período de 47,06% ou uma rentabilidade anual equivalente de 60,88%. O volume máximo de recursos investidos foi de R\$ 916.666,70, com média diária de R\$ 553.519,50.

Quanto aos 754 sinais de compra deflagrados durante o período avaliado, nota-se que aproximadamente 67% desses sinais resultaram em algum lucro, tendo o ativo com menor número de acertos sido ITSA4, com 50%. Para informações mais detalhadas, vide Tabela 11.

Tabela 11 Sinais de compra da Simulação 3

| Ativo | Certo | | | Errado | | | R\$ Líquido |
|--------------|------------|--------|-------------------|------------|-------|--------------------|-------------------|
| | Quant. | % | R\$ | Quant. | % | R\$ | |
| BBAS3 | 4 | 100,00 | 6.432,19 | 0 | 0,00 | 0,00 | 6.432,19 |
| BBDC4 | 1 | 100,00 | 1.406,45 | 0 | 0,00 | 0,00 | 1.406,45 |
| BRKM5 | 13 | 61,90 | 26.261,99 | 8 | 38,10 | -15.458,48 | 10.803,51 |
| CMIG4 | 28 | 60,87 | 63.436,78 | 18 | 39,13 | -23.916,39 | 39.520,39 |
| CPLE6 | 20 | 64,52 | 22.770,10 | 11 | 35,48 | -5.435,30 | 17.334,80 |
| CRUZ3 | 21 | 84,00 | 26.127,69 | 4 | 16,00 | -6.135,96 | 19.991,72 |
| CSNA3 | 15 | 88,24 | 24.673,50 | 2 | 11,76 | -592,17 | 24.081,33 |
| ELET3 | 20 | 74,07 | 32.472,57 | 7 | 25,93 | -9.313,88 | 23.158,68 |
| ELET6 | 20 | 54,05 | 19.800,71 | 17 | 45,95 | -10.483,78 | 9.316,92 |
| EMBR3 | 9 | 81,82 | 10.577,94 | 2 | 18,18 | -1.571,15 | 9.006,79 |
| GGBR4 | 12 | 63,16 | 12.594,31 | 7 | 36,84 | -10.171,35 | 2.422,96 |
| GOAU4 | 35 | 67,31 | 43.092,78 | 17 | 32,69 | -18.426,02 | 24.666,76 |
| ITSA4 | 3 | 50,00 | 2.027,84 | 3 | 50,00 | -754,52 | 1.273,32 |
| ITUB4 | 5 | 71,43 | 2.206,45 | 2 | 28,57 | -1.334,57 | 871,88 |
| KLBN4 | 15 | 60,00 | 14.037,02 | 10 | 40,00 | -12.583,01 | 1.454,01 |
| LAME4 | 15 | 65,22 | 16.565,59 | 8 | 34,78 | -5.720,88 | 10.844,70 |
| LIGT3 | 25 | 64,10 | 55.045,52 | 14 | 35,90 | -21.752,42 | 33.293,10 |
| OIBR4 | 24 | 75,00 | 72.436,91 | 8 | 25,00 | -27.301,97 | 45.134,94 |
| PCAR4 | 26 | 74,29 | 31.204,19 | 9 | 25,71 | -7.106,05 | 24.098,15 |
| PETR3 | 16 | 57,14 | 9.074,55 | 12 | 42,86 | -9.037,24 | 37,31 |
| PETR4 | 35 | 70,00 | 32.102,96 | 15 | 30,00 | -14.411,88 | 17.691,08 |
| SBSP3 | 21 | 52,50 | 37.691,98 | 19 | 47,50 | -21.322,32 | 16.369,67 |
| TIMP3 | 15 | 78,95 | 30.175,34 | 4 | 21,05 | -4.757,75 | 25.417,59 |
| TRPL4 | 20 | 76,92 | 43.049,03 | 6 | 23,08 | -14.445,92 | 28.603,11 |
| USIM5 | 44 | 63,77 | 85.935,50 | 25 | 36,23 | -34.279,16 | 51.656,34 |
| VALE3 | 21 | 65,63 | 30.506,36 | 11 | 34,38 | -13.998,81 | 16.507,55 |
| VALE5 | 13 | 61,90 | 8.645,06 | 8 | 38,10 | -4.593,08 | 4.051,98 |
| VVIT4 | 8 | 72,73 | 6.128,46 | 3 | 27,27 | -996,63 | 5.131,83 |
| TOTAL | 504 | | 766.479,76 | 250 | | -295.900,70 | 470.579,05 |

4.3.4 Simulação 4

Para a Simulação 4, foi mantido o uso do *U-Theil*, para definir quais projeções de redes seriam utilizadas. Assim, em relação à Simulação 3, fez-se alteração apenas nos parâmetros do intervalo mínimo e máximo, que servem de “gatilho” para os sinais de compra. Os valores do intervalo aqui estabelecidos são análogos à Simulação 2.

- a) Teto mínimo para compra: 2,25%;
- b) Teto máximo para compra: 12,00%.

A partir dos parâmetros propostos, pode-se verificar, por meio da Tabela 12, o resultado alcançado por ativo.

Tabela 12 Resultado da Simulação 4

| Ativo | Retorno (R\$) | Ativo | Retorno (R\$) |
|--------------|----------------------|--------------|----------------------|
| BBAS3 | 972,28 | KLBN4 | 4.152,56 |
| BBDC4 | 0,00 | LAME4 | 5.769,63 |
| BRKM5 | 15.532,14 | LIGT3 | 24.543,54 |
| CMIG4 | 35.267,98 | OIBR4 | 62.150,87 |
| CPLE6 | 37.620,40 | PCAR4 | 25.023,82 |
| CRUZ3 | 22.458,70 | PETR3 | 3.331,80 |
| CSNA3 | 33.088,50 | PETR4 | 16.687,46 |
| ELET3 | 22.594,42 | SBSP3 | 13.070,51 |
| ELET6 | 30.441,69 | TIMP3 | 32.238,54 |
| EMBR3 | 8.827,89 | TRPL4 | 23.730,91 |
| GGBR4 | 4.956,08 | USIM5 | 63.353,97 |
| GOAU4 | 30.097,84 | VALE3 | 16.901,66 |
| ITSA4 | 1.078,64 | VALE5 | 3.247,47 |
| ITUB4 | 665,13 | VIVT4 | 4.177,23 |
| TOTAL | | | 541.981,64 |

Diante de todos os resultados apresentados, nota-se que a Simulação 4 foi aquela que apresentou o melhor resultado, pois alcançou um lucro de R\$ 541.981,64 no período analisado, ou seja, uma rentabilidade de 54,98%, o que equivale 70,56% a.a. Quanto ao volume máximo de recursos investidos, averigou-se um montante de R\$ 916.666,70, com média/dia de R\$ 527.867,20.

A alteração dos patamares mínimos e máximos que provocam a decisão de compra repercutiu de forma positiva também, com relação ao nível de acertos dos sinais. Aproximadamente 69% dos sinais resultaram em lucro (Tabela 13).

Tabela 13 Sinais de compra da Simulação 4

| Ativo | Certo | | | Errado | | | R\$ Líquido |
|--------------|------------|--------|-------------------|------------|-------|--------------------|-------------------|
| | Quant. | % | R\$ | Quant. | % | R\$ | |
| BBAS3 | 2 | 100,00 | 972,28 | 0 | 0,00 | 0,00 | 972,28 |
| BBDC4 | 0 | 0,00 | 0,00 | 0 | 0,00 | 0,00 | 0,00 |
| BRKM5 | 10 | 66,67 | 37.389,49 | 5 | 33,33 | -21.857,35 | 15.532,14 |
| CMIG4 | 20 | 62,50 | 52.013,56 | 12 | 37,50 | -16.745,58 | 35.267,98 |
| CPLE6 | 17 | 70,83 | 41.083,62 | 7 | 29,17 | -3.463,23 | 37.620,40 |
| CRUZ3 | 13 | 86,67 | 25.554,54 | 2 | 13,33 | -3.095,84 | 22.458,70 |
| CSNA3 | 14 | 93,33 | 33.701,99 | 1 | 6,67 | -613,49 | 33.088,50 |
| ELET3 | 18 | 72,00 | 32.723,25 | 7 | 28,00 | -10.128,83 | 22.594,42 |
| ELET6 | 19 | 55,88 | 40.724,68 | 15 | 44,12 | -10.282,99 | 30.441,69 |
| EMBR3 | 7 | 77,78 | 10.479,27 | 2 | 22,22 | -1.651,38 | 8.827,89 |
| GGBR4 | 9 | 69,23 | 11.546,40 | 4 | 30,77 | -6.590,33 | 4.956,08 |
| GOAU4 | 31 | 65,96 | 48.911,56 | 16 | 34,04 | -18.813,72 | 30.097,84 |
| ITSA4 | 2 | 50,00 | 1.643,03 | 2 | 50,00 | -564,40 | 1.078,64 |
| ITUB4 | 3 | 100,00 | 665,13 | 0 | 0,00 | 0,00 | 665,13 |
| KLBN4 | 11 | 61,11 | 13.484,33 | 7 | 38,89 | -9.331,77 | 4.152,56 |
| LAME4 | 11 | 68,75 | 14.963,07 | 5 | 31,25 | -9.193,44 | 5.769,63 |
| LIGT3 | 18 | 72,00 | 30.428,52 | 7 | 28,00 | -5.884,98 | 24.543,54 |
| OIBR4 | 24 | 75,00 | 90.595,46 | 8 | 25,00 | -28.444,60 | 62.150,87 |
| PCAR4 | 20 | 80,00 | 29.035,20 | 5 | 20,00 | -4.011,38 | 25.023,82 |
| PETR3 | 13 | 61,90 | 10.395,76 | 8 | 38,10 | -7.063,95 | 3.331,80 |
| PETR4 | 33 | 71,74 | 35.658,31 | 13 | 28,26 | -18.970,84 | 16.687,46 |
| SBSP3 | 19 | 52,78 | 36.424,15 | 17 | 47,22 | -23.353,63 | 13.070,51 |
| TIMP3 | 11 | 84,62 | 32.383,36 | 2 | 15,38 | -144,82 | 32.238,54 |
| TRPL4 | 14 | 70,00 | 39.590,80 | 6 | 30,00 | -15.859,89 | 23.730,91 |
| USIM5 | 39 | 65,00 | 96.126,18 | 21 | 35,00 | -32.772,21 | 63.353,97 |
| VALE3 | 19 | 67,86 | 32.482,34 | 9 | 32,14 | -15.580,68 | 16.901,66 |
| VALE5 | 8 | 57,14 | 9.166,10 | 6 | 42,86 | -5.918,63 | 3.247,47 |
| VVIT4 | 5 | 83,33 | 4.271,32 | 1 | 16,67 | -94,09 | 4.177,23 |
| TOTAL | 410 | | 812.413,71 | 188 | | -270.432,07 | 541.981,64 |

4.3.5 Análise das simulações

Os testes com os melhores arranjos de redes subsidiaram as simulações do modelo proposto pelo presente trabalho. Realizadas quatro simulações, pode-se inferir que foram alcançados pares de resultados finais bastante díspares (Quadro 4).

| Simulação | Parâmetros específicos | Rentabilidade anual |
|-----------|--|---------------------|
| 1 | Teto mínimo para compra: 2,00%; Teto máximo para compra: 10,00%. | -2,80% |
| 2 | Teto mínimo para compra: 2,25%; Teto máximo para compra: 12,00%. | -1,43% |
| 3 | Teto mínimo para compra: 2,00%; Teto máximo para compra: 10,00%; Utilização apenas de redes que na fase de seleção obtiveram <i>U-Theil</i> menor que 1. | 60,88% |
| 4 | Teto mínimo para compra: 2,25%; Teto máximo para compra: 12,00%; Utilização apenas de redes que na fase de seleção obtiveram <i>U-Theil</i> menor que 1. | 70,56% |

Quadro 4 Resumo dos resultados das simulações

Conforme se percebe no Quadro 4, os intervalos para decisão de compra das simulações 1 e 3 são iguais, tal como os das simulações 2 e 4. Da mesma forma, pode-se notar que a utilização da estatística *U-Theil*, não apenas como medida de desempenho, mas também parâmetro do modelo, foi fundamental para o alcance das rentabilidades das simulações 3 e 4.

Essa restrição, por utilizar apenas as redes neurais que, na fase de seleção obtiveram um *U-Theil* menor que 1 e que, obviamente, haviam sido selecionadas como melhor arranjo, reduziu as redes para tomada de decisão de 420 para 199. Ou seja, aproximadamente 53% das redes selecionadas como as de melhores desempenho têm *U-Theil* maior ou igual a 1.

A fim de exemplificar os reflexos que a decisão de uso do *U-Theil* impactou, foram gerados os Gráficos 2 e 3, que ilustram os pontos de compra para o Ativo PETR4, no caso das simulações 2 e 4, respectivamente. Ressalta-se que a Simulação 2 alcançou um lucro de R\$ 7.398,51 investindo em PETR4, enquanto na Simulação 4 o lucro foi de R\$ 16.687,46. Salienta-se, ainda, que, com a inserção da estatística *U-Theil*, bloqueou-se o uso das previsões para todos os dias da partição 1 e da partição 2 para as previsões de d+4 e d+5.

Para uma leitura correta dos Gráficos 2 e 3, ratifica-se que, apesar de as previsões das redes neurais alcançarem o horizonte temporal de até cinco dias, a compra de um ativo qualquer apenas seria exercido na abertura do próximo pregão, ou seja, caso seja realizada a compra de uma ação com a intenção de venda da mesma baseado na previsão de $d+5$, essa venda ocorreria dentro de quatro dias, pois um dia já haveria passado.

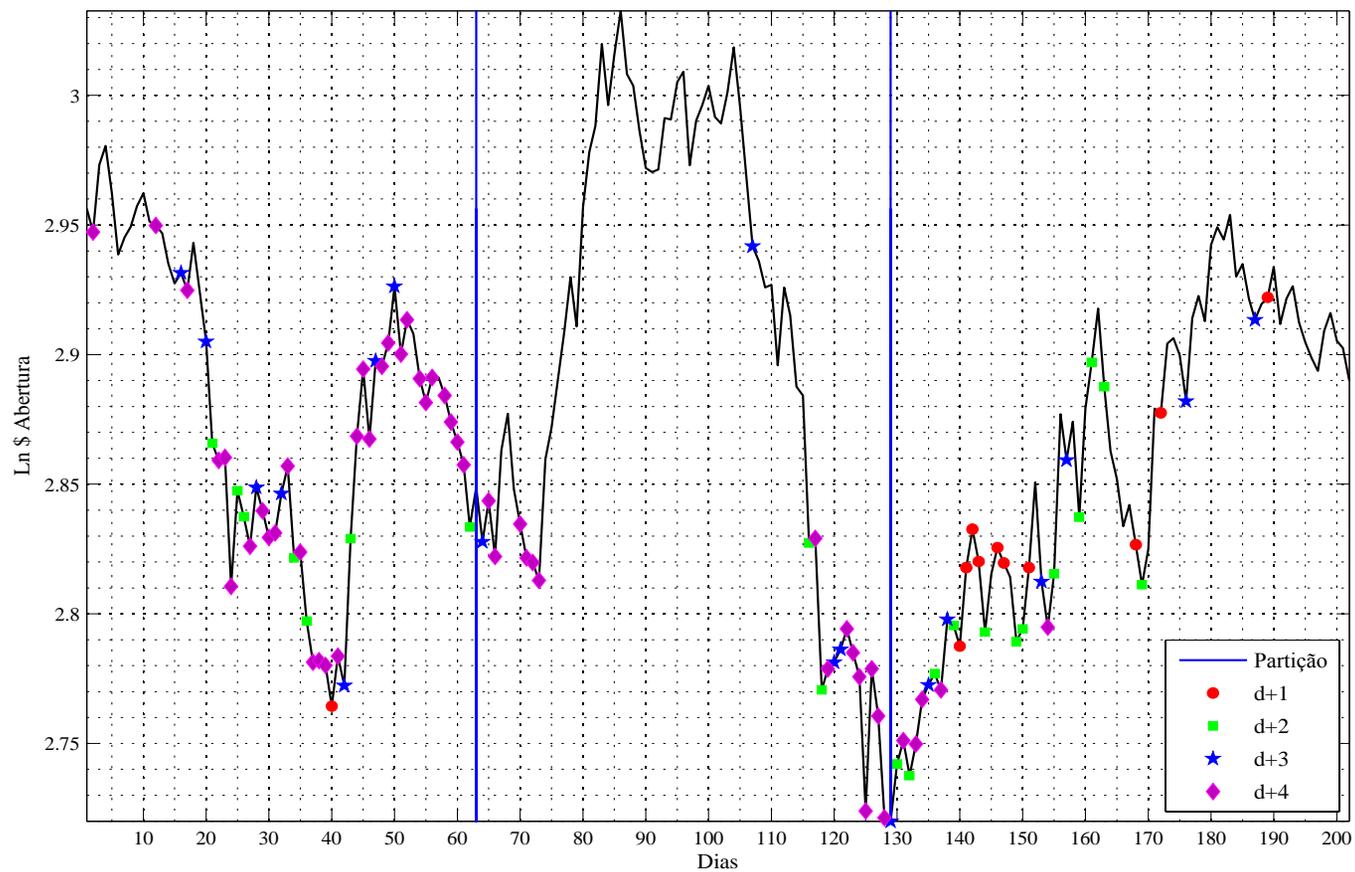


Gráfico 2 Sinais de compra do ativo PETR4 Simulação 2

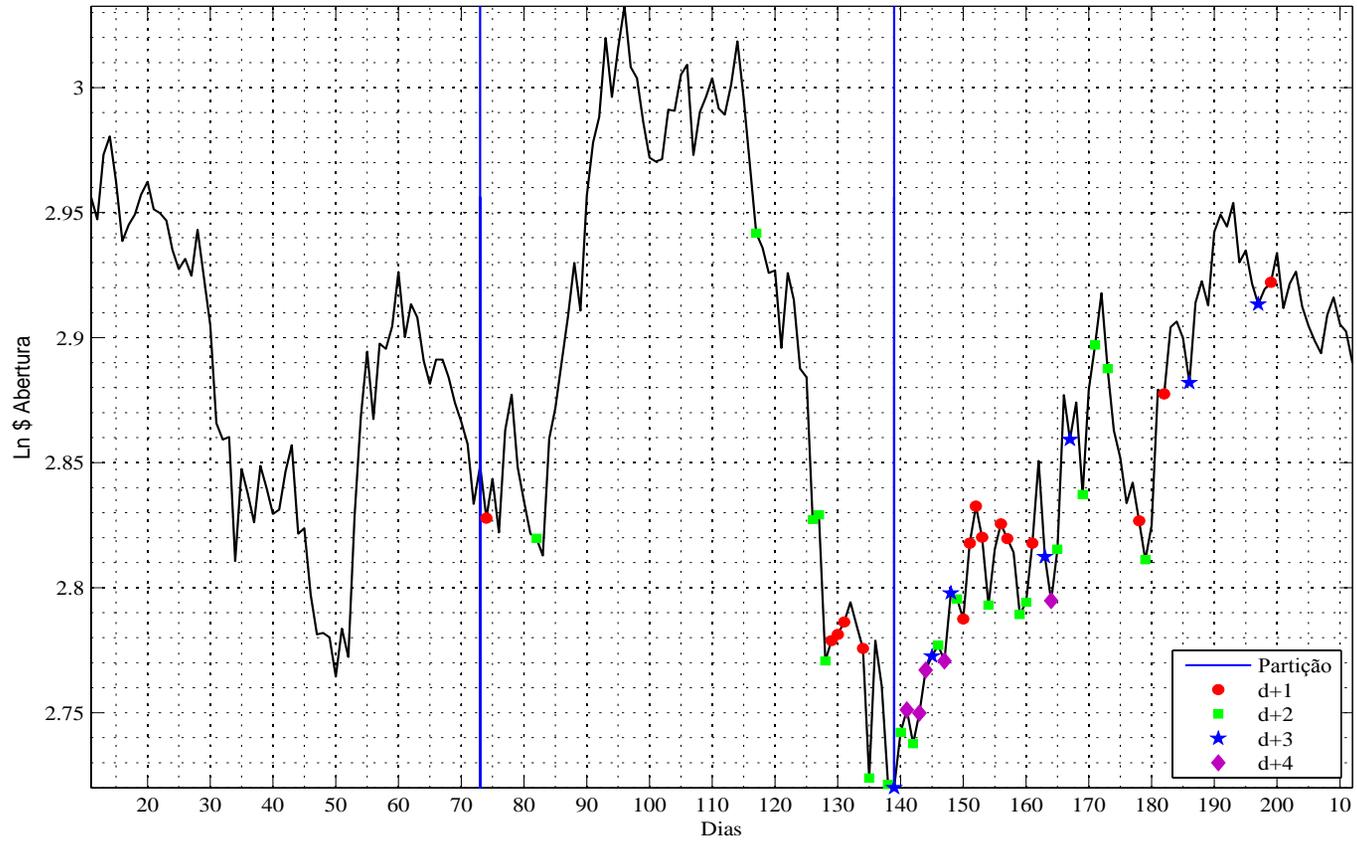


Gráfico 3 Sinais de compra do ativo PETR4 Simulação 4

Percebe-se, no Gráfico 2, que as principais decisões de compras foram realizadas com o objetivo de exercer a venda no quarto dia. A maioria das operações de compra na partição 1 foi ineficiente, pois algumas compras foram realizadas com o mercado em baixa e com continuidade desse movimento.

Já analisando-se o Gráfico 3, nota-se que, em decorrência do uso da estatística de *U-Theil*, houve um esvaziamento total de sinais de compra para a partição 1 e parcial na partição 2. Especificamente na partição 2, verificam-se algumas operações de compra executadas em momentos indevidos, pois o mercado não reverteu o movimento de baixa, conforme se previu. Pode-se verificar, ainda, que a maioria das decisões de compra, na Simulação 4, para o ativo PETR4, foi para exercer a venda em d+1 e d+2.

Deve-se reforçar que o mercado financeiro é altamente dinâmico e complexo, podendo ter ocorrido novos fatos após a previsão e que as variáveis aqui utilizadas na previsão também podem não ter conseguido captar alguma situação específica. Mas, acredita-se haver a possibilidade de delinear um modelo que sinaliza, em média, em mais decisões certas que em errôneas.

Algumas outras informações que complementam os Gráficos 2 e 3 podem ser alcançadas por meio da análise da Tabela 14, na qual se procurou pormenorizar as decisões por partições.

Tabela 14 Distribuição dos sinais de compra da PETR4 para as simulações 2 e 4

| Partição | Simulação 2 | | | Simulação 4 | | |
|--------------|-----------------|-----------------|----------------|------------------|-----------------|----------------|
| | Resultado | Sinais corretos | Sinais errados | Resultado | Sinais corretos | Sinais errados |
| 1 | -10.333,79 | 15 | 30 | 0,00 | 0 | 0 |
| 2 | -1.126,04 | 9 | 12 | -4.286,98 | 7 | 5 |
| 3 | 18.858,34 | 26 | 8 | 20.974,44 | 26 | 8 |
| Total | 7.398,51 | 50 | 50 | 16.687,46 | 33 | 13 |

Assim, conforme se verifica na Tabela 14, apenas metade das decisões de compra na Simulação 2 foi correta. As decisões geradas na partição 1, em decorrência do alto volume de erros, acabaram comprometendo o resultado final do investimento, ainda que este tenha sido positivo. Quanto à Simulação 4, atesta-se que o número de erros foi bem menor, um total de 28%. Os dados corroboram a análise realizada anteriormente do Gráfico 2, quando se destacaram algumas decisões de compra incorretas na partição 2. Mas, como resultado final, o lucro na Simulação 4 foi 125,55% maior do que o da Simulação 2.

Na sequência, buscou-se discutir um pouco mais do que representou a inserção da estatística do *U-Theil* para o modelo. Dessa forma, construiu-se o Gráfico 4 para indicar quais as redes foram efetivamente aproveitadas e com qual frequência.

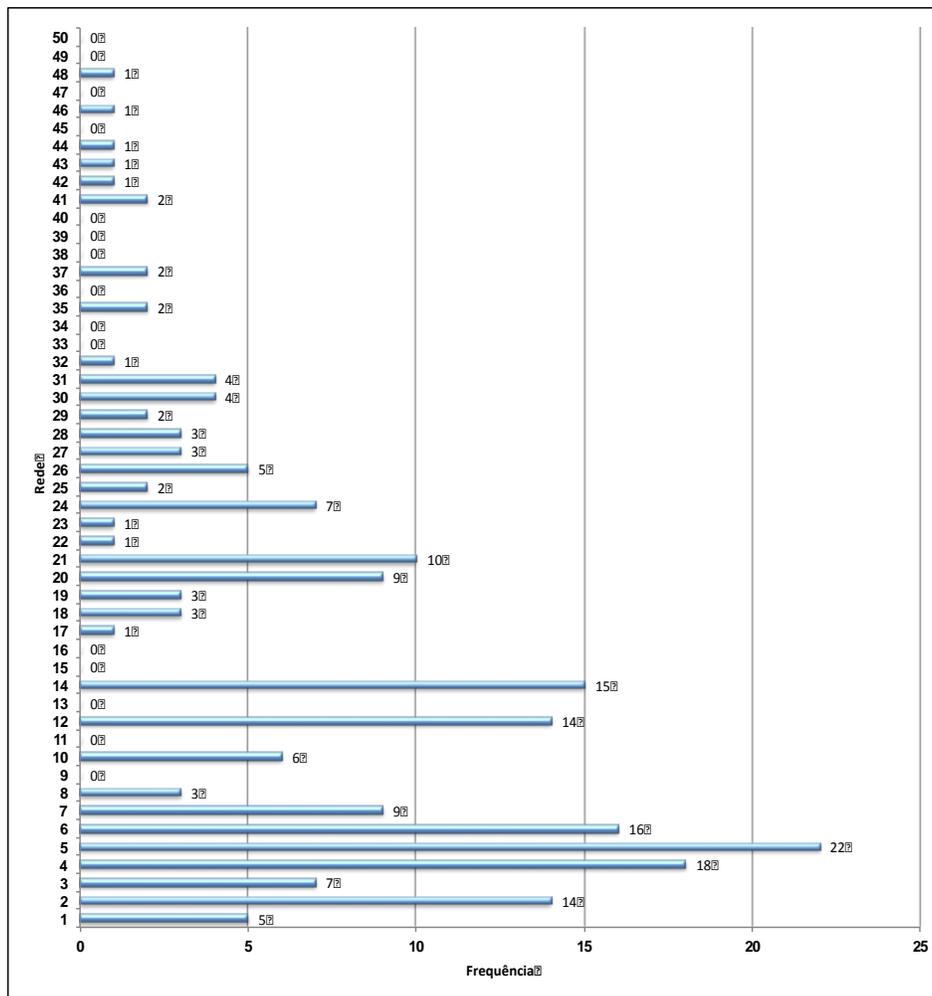


Gráfico 4 Distribuição dos arranjos das redes utilizadas nas simulações 3 e 4

Para avaliar os dados do Gráfico 4, resgata-se a informação de que nas Simulações 1 e 2, quando não se aplicou o conceito do resultado do *U-Theil* nas decisões de compra, os arranjos de redes mais utilizados foram 5, 4, 14, 6, 2 e 21. Com exceção da Rede 21, que foi substituída pelo arranjo da Rede 12, todas as demais configuram novamente entre as mais utilizadas para as simulações 3 e 4. De forma bem similar ao que ocorreu quando se utilizaram todas as redes sem

restrição ao *U-Theil*, as seis redes de maior frequência respondem por, aproximadamente, 50% do total. Outro ponto a ser observado é que, entre essas redes de maior utilização, a que tem maior número de variáveis de entrada é a Rede 14, com cinco variáveis. E, mais uma vez, as redes com dez ou mais variáveis de entrada são em número bem reduzido, respondendo apenas por cerca de 5,5% das redes selecionadas.

Outro ponto de destaque é a definição do intervalo para a tomada de decisão de compra. A simples variação nos intervalos mínimo e máximo das simulações 3 e 4 ocasionou uma diferença considerável de 9,68 pontos percentuais. É preciso reconhecer o quão complexo é prever um valor futuro de uma ação. No caso do presente estudo, tentou-se prever uma cotação com cinco dias de antecedência.

Assim, é importante salientar que o modelo firma-se em duas condições básicas. Primeiro, o quão fundamental é que a previsão seja capaz de acompanhar os movimentos dos valores reais, ou seja, se o preço de um ativo valoriza, provocando um movimento de alta, é essencial que a previsão acompanhe esse movimento de alta; segundo, sabe-se que modelo nenhum conseguirá antever o preço exato de uma ação, mas acredita-se ser possível, a partir de uma modelagem adequada, chegar bem próximo. Por isso, definir um intervalo para operar é essencial, eliminando erros de previsão que poderiam comprometer o resultado do modelo.

Apenas para ilustrar a importância da ideia defendida no parágrafo anterior, procedeu-se a uma quinta simulação, em que o teto mínimo para compra foi de 1,25% e o máximo mantido em 12%, além de aplicar a seleção de uso da rede por meio do *U-Theil*. Com essa flexibilização do nível de exigência para a compra de uma ação, a rentabilidade reduziria para 25,87% a.a. Apesar de manter uma rentabilidade ainda atrativa, a maior exposição ao risco não culminou numa rentabilidade maior.

4.4 Desempenho comparativo

A presente seção foi delineada com a motivação de atender a um dos objetivos específicos da pesquisa, que é comparar a rentabilidade provida pelo modelo sugerido com outros possíveis investimentos à disposição no mercado financeiro brasileiro.

Para realizar essa comparação de resultados, decidiu-se por utilizar os resultados da Simulação 4, pois, entre todas as simulações realizadas, foi aquela que apresentou melhor resultado, dadas as variações de parâmetros testados.

Como escopo para comparação, adotaram-se as premissas de que a Simulação 4 tinha disponível para investimento um capital de R\$ 1.000.000,00 e que, quando esse recurso não estivesse investido em alguma das 28 ações do portfólio da amostra, ele não renderia qualquer capital. Conforme apresentado na seção 4.3.4, o volume máximo de capital/dia investido na Simulação foi de 916.666,70, com uma média diária de aplicação de R\$ 527.867,20. Ou seja, a proposta de se calcular a rentabilidade do modelo a partir do capital de R\$ 1.000.000,00 é uma medida um tanto quanto conservadora.

A primeira comparação realizada foi de que, no período utilizado para a simulação do modelo construído, um investidor poderia ter tomado a decisão de aplicar (02/01/2013) todo o recurso disponível em um dos ativos, resgatando o mesmo ao final (15/10/2013) do período (Tabela 15).

Tabela 15 Simulação de investimentos em ativos individuais

| Ativo | Investimento (R\$) | Montante (R\$) | Lucro (R\$) |
|--------------|---------------------------|-----------------------|--------------------|
| BBAS3 | 1.000.000,00 | 1.153.406,10 | 153.406,10 |
| BBDC4 | 1.000.000,00 | 1.026.682,90 | 26.682,90 |
| BRKM5 | 1.000.000,00 | 1.404.454,09 | 404.454,09 |
| CMIG4 | 1.000.000,00 | 1.056.361,97 | 56.361,97 |
| CPLE6 | 1.000.000,00 | 1.000.981,75 | 981,75 |
| CRUZ3 | 1.000.000,00 | 856.866,08 | -143.133,92 |
| CSNA3 | 1.000.000,00 | 1.029.312,38 | 29.312,38 |
| ELET3 | 1.000.000,00 | 1.176.952,90 | 176.952,90 |
| ELET6 | 1.000.000,00 | 1.280.396,53 | 280.396,53 |
| EMBR3 | 1.000.000,00 | 1.179.771,30 | 179.771,30 |
| GGBR4 | 1.000.000,00 | 919.198,00 | -80.802,00 |
| GOAU4 | 1.000.000,00 | 939.809,84 | -60.190,16 |
| ITSA4 | 1.000.000,00 | 1.074.075,77 | 74.075,77 |
| ITUB4 | 1.000.000,00 | 1.102.845,04 | 102.845,04 |
| KLBN4 | 1.000.000,00 | 953.997,96 | -46.002,04 |
| LAME4 | 1.000.000,00 | 945.391,51 | -54.608,49 |
| LIGT3 | 1.000.000,00 | 893.613,83 | -106.386,17 |
| OIBR4 | 1.000.000,00 | 558.488,93 | -441.511,07 |
| PCAR4 | 1.000.000,00 | 1.167.474,71 | 167.474,71 |
| PETR3 | 1.000.000,00 | 850.572,35 | -149.427,65 |
| PETR4 | 1.000.000,00 | 935.426,29 | -64.573,71 |
| SBSP3 | 1.000.000,00 | 837.368,98 | -162.631,02 |
| TIMP3 | 1.000.000,00 | 1.415.379,69 | 415.379,69 |
| TRPL4 | 1.000.000,00 | 1.032.219,73 | 32.219,73 |
| USIM5 | 1.000.000,00 | 861.136,56 | -138.863,44 |
| VALE3 | 1.000.000,00 | 864.432,65 | -135.567,35 |
| VALE5 | 1.000.000,00 | 800.968,13 | -199.031,87 |
| VVIT4 | 1.000.000,00 | 1.033.323,51 | 33.323,51 |

Destaca-se que foram aplicados custos com ordem de compra e venda, taxas e emolumentos, imposto sobre serviço e imposto de renda, nos mesmos patamares dos imputados nas simulações do modelo. Pode-se aferir, analisando-se a Tabela 15, que apenas 53,57% dos ativos teriam proporcionado algum resultado positivo. A ação OIBR4 foi a que apresentou maior prejuízo (R\$ 441.511,07); já o maior lucro foi conferido ao ativo TIMP3 (R\$ 415.379,69).

A título de comparação das rentabilidades, calcularam-se as mesmas analisando-se seus resultados e disponibilizando-os no Gráfico 5 de forma crescente.

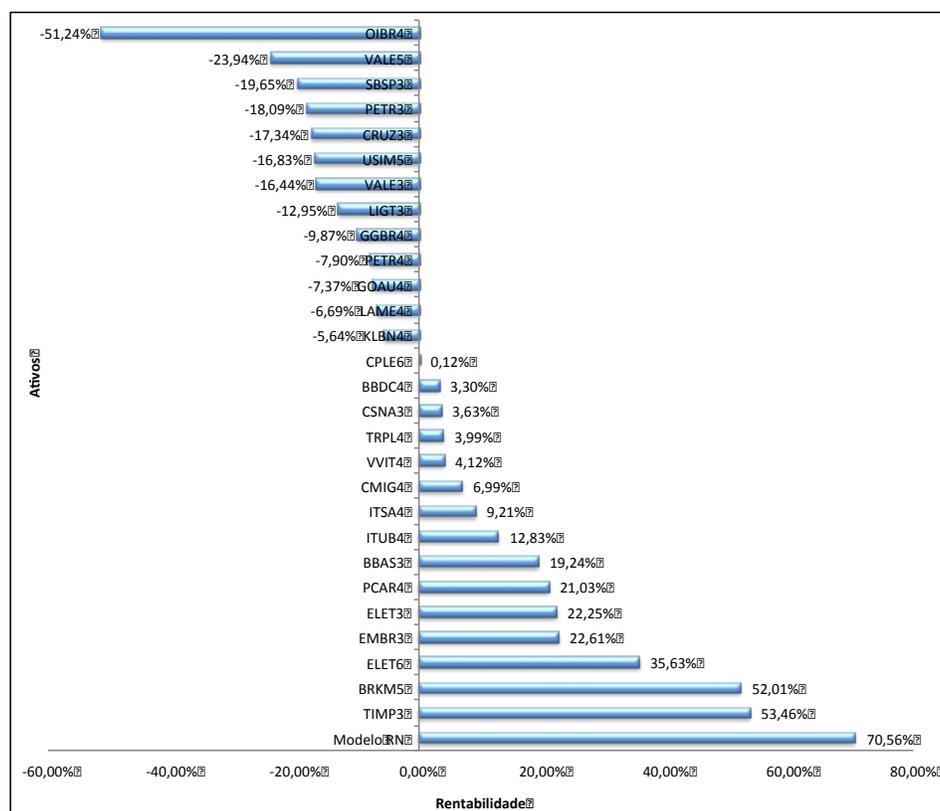


Gráfico 5 Rentabilidades anuais dos ativos e modelo de redes neurais

Com exceção dos ativos TIMP3 e BRKM5, todos os demais 26 ativos tiveram rentabilidades, no mínimo, 49% menor que o modelo proposto para compra e venda de ações, indicando, assim, um ótimo desempenho do modelo proposto na presente tese. A fim de ilustrar ainda melhor esse desempenho, criaram-se os Gráficos 6, 7, 8 e 9, apresentando o desempenho da rentabilidade dos ativos e do modelo proposto ao longo do período analisado.



Gráfico 6 Comparação de rentabilidades modelo de redes neurais versus ativos individuais

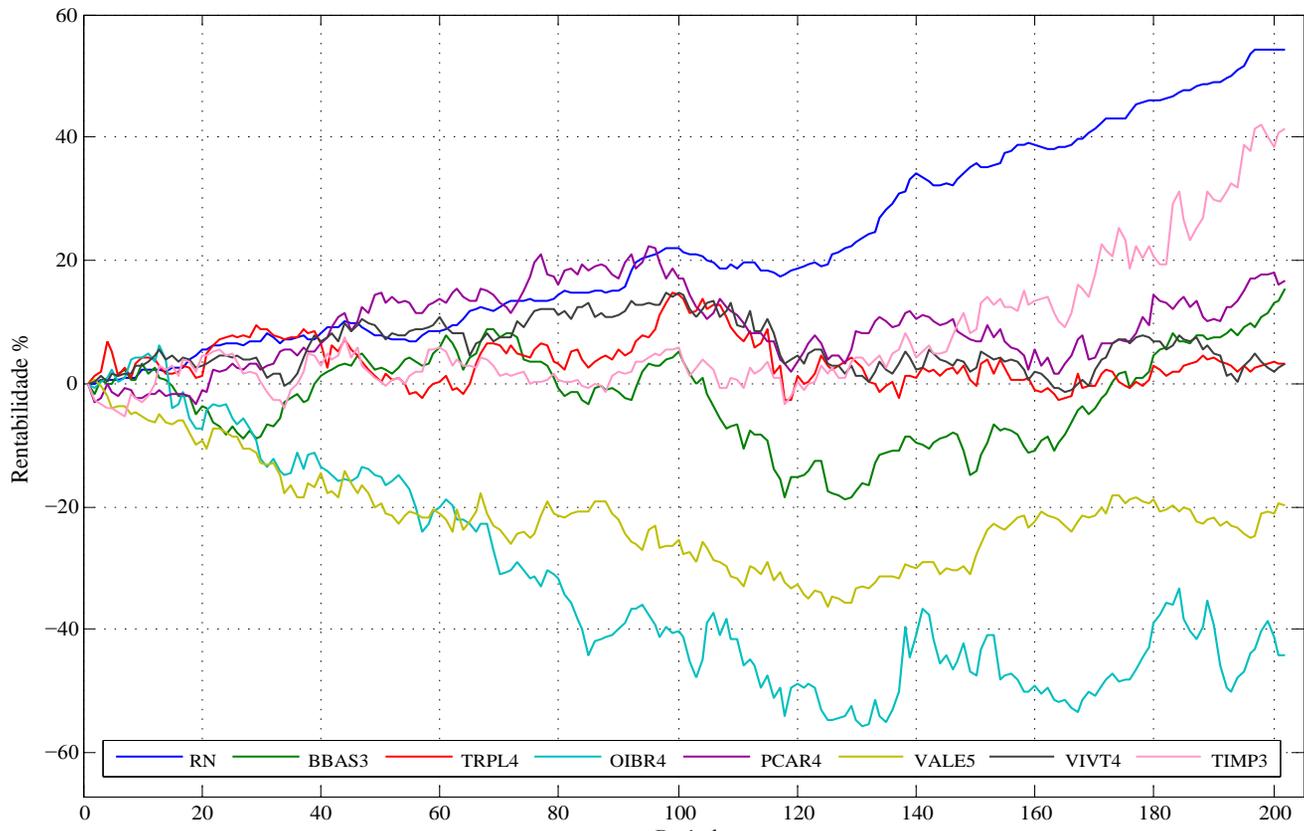


Gráfico 7 Comparação de rentabilidades modelo de redes neurais versus ativos individuais

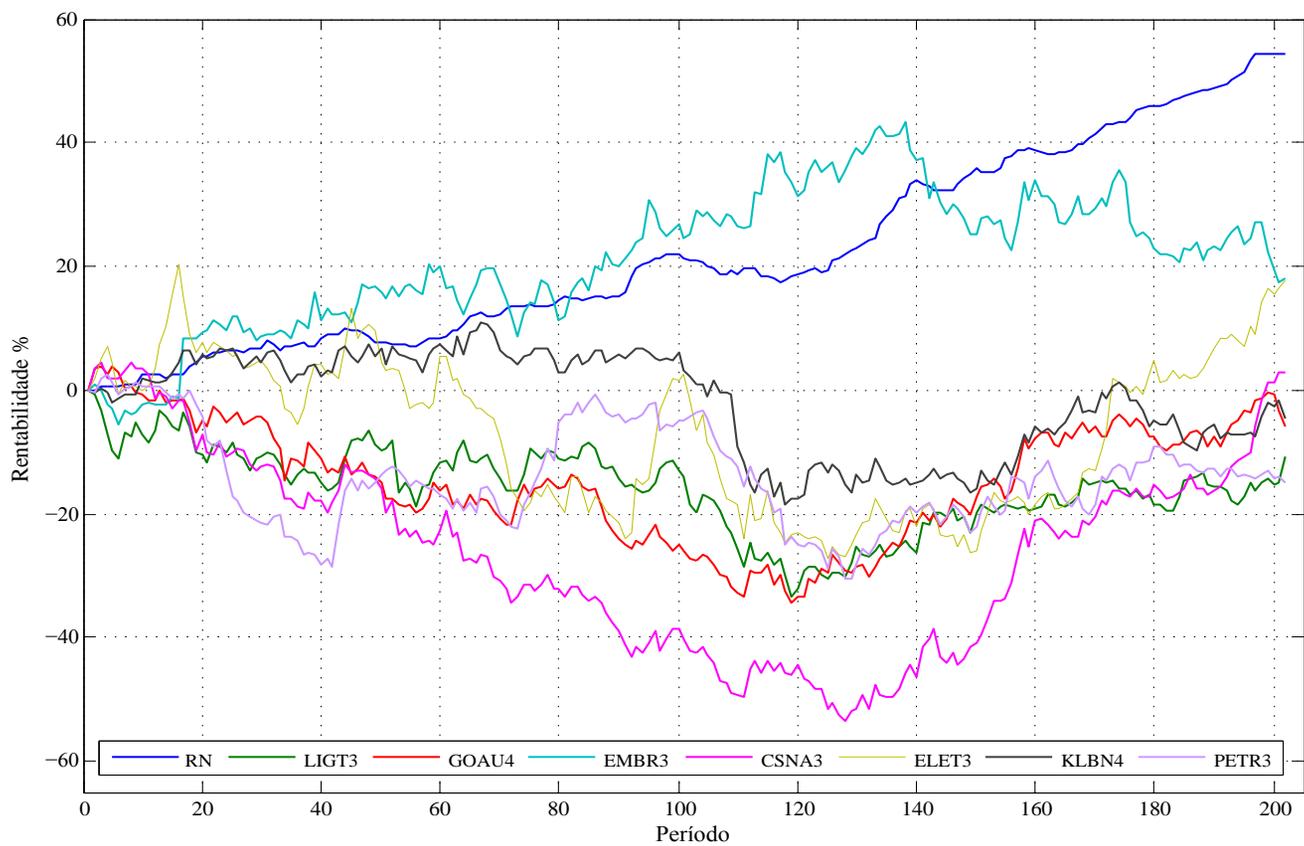


Gráfico 8 Comparação de rentabilidades modelo de redes neurais versus ativos individuais



Gráfico 9 Comparação de rentabilidades modelo de redes neurais versus ativos individuais

Percebe-se, analisando-se os Gráficos 6, 7, 8 e 9, que o modelo proposto apresenta uma rentabilidade crescente, praticamente ao longo de todo o período. Alguns pontos também chamaram atenção: o desempenho do ativo EMBR3 (Gráfico 8) foi a ação que permaneceu pelo maior tempo com rentabilidade superior ao modelo de redes neurais; o bom desempenho do ativo BRKM5 (Gráfico 6); a forte alta que o ativo TIMP3 deu-se, principalmente, no terço final do período (Gráfico 7) e a distância entre a rentabilidade do modelo com ativos fortíssimos no mercado, tais como VALE3 e PETR4 (Gráfico 9).

Outra comparação que se buscou fazer foi entre o desempenho do modelo proposto frente à rentabilidade do índice IBOVESPA e de fundos de ações, que a Revista Exame (RANKING..., 2014) listou como os que apresentaram maiores rentabilidades no ano de 2013 (Gráfico 10).

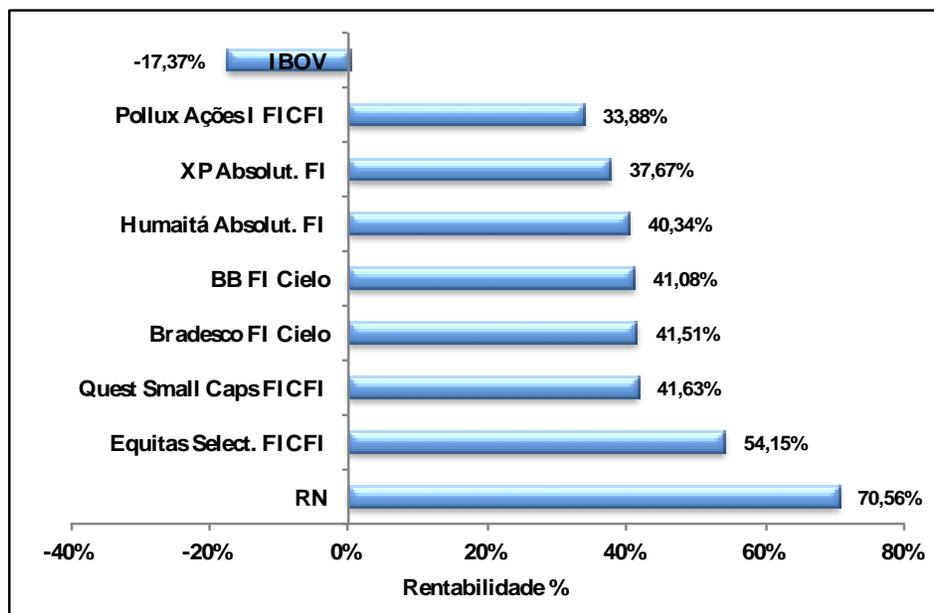


Gráfico 10 Rentabilidade de fundos de ações e modelo de redes neurais

Para todos os retornos apresentados no Gráfico 10 foi descontado o imposto de renda. Pode-se inferir que o modelo proposto, baseado em redes neurais, foi bem superior aos melhores fundos de ações no ano de 2013. Em comparação ao Equitas Selection FICFI de Ações, que tem um patrimônio líquido de R\$ 116.141.280,00 e que foi considerado o fundo mais rentável em 2013, o modelo alcançou um desempenho aproximadamente 30% superior ao mesmo, ou seja, um desempenho de quase 15 pontos percentuais a mais.

5 CONCLUSÃO

O presente estudo defendeu a tese sobre a viabilidade de estruturar um modelo baseado na técnica de redes neurais para a tomada de decisões de compra e venda de ativos financeiros no mercado de capitais brasileiro, com ganhos atrativos a investidores.

Assim, o primeiro desafio do trabalho foi questionar um dos pressupostos básicos da Moderna Teoria Financeira, que defende que séries temporais de ativos financeiros têm um comportamento browniano. Averiguar essa premissa, então, era ponto vital para a defesa dos argumentos sustentados nessa tese.

Com a finalidade de aceitar ou rechaçar a hipótese de aleatoriedade das séries dos 28 ativos financeiros, selecionados para participarem do estudo, calculou-se o coeficiente de Hurst dos mesmos. O resultado alcançado, então, corroborou a proposta do estudo, pois, para todas as séries, o coeficiente de Hurst foi estatisticamente maior que 0,5, indicando, assim, existir a presença de uma memória de longo de prazo no comportamento das séries. Ou seja, esse resultado sinaliza que é possível identificar padrões de comportamento nas séries dos ativos, estabelecendo, dessa forma, condições básicas e desejáveis para que se utilizem dados passados como estratégia de precificação de títulos mobiliários.

Após o teste de comportamento das séries dos ativos, o desafio passou a ser a estruturação do modelo de previsão. Optou-se pela técnica de redes neurais, dados o dinamismo e a complexidade do mercado acionário. Entendeu-se que a técnica de redes neurais tem condições plenas de manipular dados ruidosos, estabelecendo, assim, relações causais entre as variáveis do modelo.

Contudo, apesar do potencial que o rol das finanças computacionais apresenta para o enfrentamento de cenários empíricos, há uma dificuldade

enorme de estruturar de forma eficaz essas técnicas, dado o enorme conjunto de dados que podem ser utilizados e as infinitas configurações possíveis de serem assumidas. Assim, a preferência de uma configuração de rede neural à outra depende, essencialmente, da característica da série investigada e das convicções do responsável pelo projeto.

Dessa forma, para a construção do modelo baseado em redes neurais, utilizou-se do ferramental da análise técnica para “abastecer” o modelo de informações. O entendimento foi de que, uma vez que seriam utilizados dados passados para prever preços futuros e que as séries indicavam existir uma memória de longo prazo, nada mais coerente do que recorrer à corrente teórica que defende que comportamentos passados tendem a se repetir no futuro. Assim, os *inputs* do modelo neural basearam-se em indicadores da análise técnica.

No intuito de explorar as potencialidades e assegurar a qualidade dos resultados do modelo, foi realizado um número extenso de simulações. Ao todo, foram processados 630.000 simulações. Os resultados, então, foram analisados, para que, na sequência, fossem escolhidos os arranjos de redes neurais que melhor se adaptaram para um conjunto específico de dados. Esses arranjos de redes neurais selecionadas foram utilizados para prever as cotações dos ativos financeiros, para um horizonte de até cinco dias.

Uma vez realizadas as previsões das cotações, estas subsidiaram as decisões de compra e venda, sendo que, para delinear uma proposta de modelo, foram realizadas quatro simulações, variando alguns parâmetros decisórios específicos. Em síntese, esses parâmetros consistiram em definir um intervalo “seguro” para que fossem efetivadas as decisões de compras. Para tanto instituíram-se margens mínimas e máximas esperadas de ganho. Outro parâmetro instituído para a criação do modelo foi definir quando seriam utilizadas as previsões geradas pelas redes neurais. Assim, estabeleceu-se que, em algumas simulações, o uso das previsões somente seria efetivado quando as

redes neurais na fase de seleção tivessem gerado resultados da estatística de *U-Theil* inferior a 1. A definição desse último parâmetro fez com que os resultados alcançados pelo modelo apresentassem níveis de rentabilidade em patamares bastante significativos. Numa esfera comparativa, nenhum ativo individual alcançou, no período testado, rentabilidade superior à do modelo proposto, bem como nenhum fundo de investimento em ações, apontado pela Revista Exame como os melhores de 2013, alcançou rentabilidade próxima ao modelo proposto pelo presente estudo. A diferença entre a rentabilidade do modelo de redes neurais e o melhor fundo de investimento de 2013 foi de aproximadamente 30% (RANKING..., 2014).

Dessa forma, entende-se que a pesquisa tenha contribuído para a área de mercado de capitais por vários motivos. Primeiro, ao suscitar o debate sobre um dos principais pilares da Moderna Teoria Financeira, que é o movimento browniano das séries temporais de ativos financeiros. Testes empíricos comprovaram a necessidade latente de se discutir a temática, no intuito de aproximar o modelo teórico do prático.

Segundo, foi promovido um amplo estudo aplicado a respeito da modelagem, utilizando a técnica de inteligência computacional, denominada redes neurais, em conformidade com todos os preceitos científicos que um trabalho dessa envergadura exige, salientando que técnicas de finanças computacionais têm um vasto e rico campo de estudo. Assim, acredita-se que esta pesquisa colabora sensivelmente ao expor uma das potencialidades da técnica de redes neurais para a área financeira, bem como estimular, a partir dos resultados alcançados, novas possibilidades de aplicações, desenvolvimento e refinamento de modelos que utilizem técnicas de inteligência computacional.

Uma terceira contribuição, e mais significativa, refere-se à proposta do modelo de decisão de compra e venda de ações desenvolvido. Uma vez que se assumiu que as previsões geradas pelas redes neurais, por mais que tenham um

enorme potencial de aplicação e resposta para problemas tal como o proposto, foram tratadas com cautela e clarividência, ao reconhecer o alto grau de dificuldade em antever a cotação futura de uma ação, dados o dinamismo e a complexidade do mercado. Assim, delimitou-se uma faixa de ganhos esperados, além de utilizar a estatística *U-Theil* para selecionar quais previsões seriam passíveis de serem aproveitadas. Ambos os parâmetros propostos foram confirmados como primordiais para o sucesso dos resultados alcançados pelo modelo testado. Estes resultados mostraram-se mais atrativos (maior rentabilidade) que se o investimento tivesse sido realizado em ativos individuais ou em fundos de ações.

Como proposta para trabalhos futuros, sugere-se a construção de um modelo que explore mais a formação dos *candlesticks* como variável de entrada do modelo. Para tanto poder-se-iam utilizar técnicas como lógica *fuzzy* ou rede neural para reconhecimento de imagem. Outras possibilidades de trabalhos seriam inserir novas variáveis de entrada, novos arranjos, horizontes temporais maiores da variável de saída e otimização do intervalo de compra por ativo.

REFERÊNCIAS

ABELÉM, A. J. G. **Redes neurais artificiais na previsão de séries temporais**. 1994. 100 p. Dissertação (Mestrado em Engenharia Elétrica) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 1994.

ALEXANDER, G. J.; SHARPER, W. F.; BAILEY, J. V. **Fundamentals of investments**. 3rded. New Jersey: Prentice Hall, 2000. 781 p.

ALVES-MAZZOTTI, A. J.; GEWANDSZNAJDER, F. **O método nas ciências naturais e sociais: pesquisa quantitativa e qualitativa**. 3. ed. São Paulo: Pioneira, 2001. 211 p.

AMORIN NETO, M. C. de. **Previsão séries temporais usando séries exógenas e combinação de redes neurais aplicada ao mercado financeiro**. 2008. 78 p. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Pernambuco, Recife, 2008.

ANDREASEN, J.; JENSEN, B.; POULSEN, R. Eight valuation methods in financial mathematics: the black-sholes formula as an example. **Mathematical Scientist**, Melbourne, v. 23, n. 1, p. 18-40, June 1999.

APPEL, G. **Technical analysis: power tools for active investors**. Upper Saddle River: Financial Times Prentice Hall, 2005. 264 p.

BACHELIER, L. Théorie de la spéculation. **Annales Scientifique de l'École Normale Supérieure**, Paris, n. 17, p. 21-86, 1900.

BERNSTEIN, P. L. **Capital ideas: the improbable origins of modern wall street**. New York: Maxwell MacMillan International, 1992. 360 p.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2007. 248 p.

BREALEY, R. A.; MYERS, S. C. **Princípios de finanças empresariais**. 5. ed. Lisboa: McGraw-Hill, 1998. 911 p.

BRUM, C. **Aprenda a investir em ações e a operar na bolsa via internet**. São Paulo: Moderna, 2006. 212 p.

- BUENO, R. L. S. **Econometria de séries temporais**. São Paulo: Cengage Learning, 2011. 360 p.
- BULKOWSKI, T. N. **Encyclopedia of candlestick charts**. Hoboken: Wiley, 2008. 960 p.
- BURRELL, P. R.; FOLARIN, B. O. The impact of neural networks in finance. **Neural Computing and Applications**, London, v. 6, n. 4, p. 193-200, 1997.
- COELHO, L. dos S.; SANTOS, P. A. A. COSTA JÚNIOR, N. C. A. da C. Podemos prever a taxa de câmbio brasileira?: evidência empírica utilizando inteligência computacional e modelos econométricos. **Gestão da Produção**, São Carlos, v. 15, n. 3, p. 635-647, set./dez. 2008.
- COSTA, G. G. de O. **Curso de estatística inferencial e probabilidades**. São Paulo: Atlas, 2012. 370 p.
- DIXIT, A. K.; PINDYCK, R. S. **Investment under uncertainty**. Princeton: Princeton University, 1994. 476 p.
- EDWARDS, R. D.; MAGEE, J.; BASSETTI, W. H. C. **Technical analysis of stock trends**. 9thed. Saranac Lake: AMACOM, 2007. 840 p.
- FAMA, E. F. The behavior of stock market prices. **Journal of Business**, Chicago, v. 38, n. 1, p. 34-105, Jan. 1965.
- FAMA, E. F. Efficient capital markets II. **Journal of Finance**, Oxford, v. 46, n. 5, p. 1575-1617, Dec. 1991.
- FEDER, J. **Fractals**. New York: Plenum, 1988. 283 p.
- FERREIRA, A. B. de H. **Dicionário Aurélio básico da língua portuguesa**. Rio de Janeiro: Nova Fronteira, 1988. 704 p.
- FREITAS, S. O. **Utilização de um modelo baseado em redes neurais para a precificação de opções**. 2001. 50 p. Dissertação (Mestrado em Administração) - Universidade Federal de Minas Gerais, Belo Horizonte, 2001.
- GIL, A. C. **Como elaborar projetos de pesquisa**. 2. ed. São Paulo: Atlas, 1989. 173 p.

GUJARATI, D. **Econometria básica**. 4. ed. São Paulo: Makron Books, 2006. 812 p.

HANAOKA, G. P. et al. Estudo comparativo utilizando rede neural para previsão de tendências em uma série temporal financeira. In: ENCONTRO DE MODELAGEM COMPUTACIONAL, 14., 2011, Nova Friburgo. **Anais...** Nova Friburgo: CEFET, 2011. 1 CD-ROM.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

KIRKPATRICK, C. D.; DAHLQUIST, J. R. **Technical analysis: the complete resource for financial market technicians**. New Jersey: FT Press, 2009. 704 p.

KRISHNAMMORTHY, C. S.; RAJJEV, S. **Artificial intelligence and expert systems for engineers**. Boca Raton: CRC, 1996. 320 p.

LIMA, F. G. et al. Aplicação de redes neurais na análise e na concessão de crédito ao consumidor. **Revista Administração**, São Paulo, v. 44, n. 1, p. 34-45, 2009.

MANDELBROT, B.; HUDSON, R. L. **The (mis)behavior of markets: a fractal view of financial turbulence**. New York: Basic Books, 2004. 368 p.

MORRIS, G. L. **Candlestick charting explained: timeless techniques for trading stocks and futures**. New York: McGraw-Hill, 2006. 550 p.

MUELLER, A. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. 1996. 103 f. Dissertação (Mestrado em Engenharia da Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2006.

MURPHY, J. J. **Technical analysis of the financial markets: a comprehensive guide to trading methods and applications**. Paramus: New York Institute of Finance, 1999. 576 p.

NARAIN, L. S.; NARAIN, R. L. Stock market prediction: a comparative study of multivariate statistical and artificial neural network models. **Journal of Accounting and Finance Research**, London, v. 10, n. 2, p. 85-94, 2002.

NEGNEVITSKY, M. **Artificial intelligence: a guide to intelligent systems**. 2nd ed. Essex: Pearson, 2005. 504 p.

NISON, S. **Japanese candlestick charting techniques: a contemporary guide to the ancient investment techniques of the far east.** 2nded. New York: Institute of Finance, 1991. 299 p.

PAIVA, F. D. et al. Estudo de eventos baseado no modelo de redes neurais para cálculo do retorno normal: o case do efeito da divulgação das demonstrações financeiras sobre o preço das ações preferenciais da Petrobrás. In: ENCONTRO DE ENSINO E PESQUISA EM ADMINISTRAÇÃO E CONTABILIDADE, 35., 2011, Rio de Janeiro. **Anais...** Rio de Janeiro: ENANPAD, 2011a. Disponível em: <http://www.anpad.org.br/diversos/trabalhos/EnANPAD/enanpad_2011/FIN/2011_FIN3115.pdf>. Acesso em: 10 dez. 2013.

PAIVA, F. D. et al. Precificação de um ativo financeiro brasileiro baseado em redes neurais. In: SEMINÁRIO EM ADMINISTRAÇÃO, 14., 2011, São Paulo. **Anais...** São Paulo: FEA/USP, 2011b. Disponível em: <<http://www.ead.fea.usp.br/semead/14semead/resultado/trabalhosPDF/1125.pdf>>. Acesso em: 10 dez. 2013.

PETERS, E. E. **Chaos and order in the capital markets.** New York: Wiley, 1991. 288 p.

PETERS, E. E. **Fractal market analysis: applying chaos theory to investment and economics.** New York: Wiley, 1994. 336 p.

PIMENTA, T.; LIMA, F. G. **Aprenda a usar análise técnica para investir em ações.** Ribeirão Preto: Inside Books, 2010. 316 p.

PRING, M. J. **Technical analysis explained: the successful investor's guide to spotting investment trends and turning points.** 4thed. New York: McGraw-Hill, 2007. 832 p.

RANKING de fundos de investimento 2013. **Exame**, São Paulo, 2014. Número especial. Disponível em: <<http://exame.abril.com.br/mercados/ranking-de-fundos>>. Acesso em: 10 jan. 2014.

RHOADS, R. **Candlesticks charting for dummies.** Hoboken: Wiley, 2008. 360 p.

ROSS, S. A.; WESTERFIELD, R. W.; JAFFE, J. F. **Administração financeira.** São Paulo: Atlas, 2002. 778 p.

SETHER, L. (Org.). **Dow theory unplugged:** Charles Dow's original editorials & their relevance today. Cedar Falls: Wasendorf & Associates, 2009. 391 p.

SWALES, G. S.; YOON, Y. Applying artificial neural networks to investments analysis. **Financial Analysts Journal**, New York, v. 48, n. 5, p. 78-80, Sept./Oct. 1992.

TAQQU, M. S. Bachelier and his times: a conversation with Bernard Bru. **Finance and Stochastics**, Berlin, v. 5, n. 1, p. 3-32, Jan. 2001.

TOFOLI, E. T. et al. A tecnologia das redes neurais para o apoio à decisão na administração financeira. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 28., 2008, Rio de Janeiro. **Anais...** Rio de Janeiro: ABEPRO, 2008. p. 1-14.

VALENÇA, M. **Fundamentos das redes neurais:** exemplos em Java. 2. ed. Olinda: Livro Rápido, 2009. 382 p.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração.** São Paulo: Atlas, 1998. 94 p.

VOLCHAN, S. B. Modelos matemáticos em finanças: avaliação de opções. **Matemática Universitária**, Rio de Janeiro, n. 26/27, p. 67-121, jun./dez. 1999.

WIERSEMA, U. **Brownian motion calculus.** New York: Wiley, 2008. 330 p.