

Análise de Séries Temporais Aplicadas ao Mercado Financeiro com o uso de Algoritmos Genéticos e Lógica Nebulosa

Frederico C. R. Marques¹, Rogério Martins Gomes¹

¹Laboratório de Sistemas Inteligentes – CEFET-MG
Av. Amazonas, 7675 - Belo Horizonte - MG - Brasil - CEP 30510-000

{frederico, rogerio}@lsi.cefetmg.br

Abstract. *This paper presents a new methodology for parameterization of the indicator of technical analysis of the financial market called moving Average Convergence-Divergence (MACD) based on genetic algorithms and fuzzy logic. This indicator, developed by Gerald Appel, is used by financial market analysts, when applied to the price of securities, to signalize the best moment of purchase and sale of shares. The proposed methodology was validated using the shares of Petrobras PETR4 in the period between February 2005 and August 2008, achieving a profit of over 70%.*

Resumo. *Este artigo apresenta uma nova metodologia de parametrização do indicador de análise técnica do mercado financeiro chamado Moving Average Convergence-Divergence (MACD) utilizando algoritmos genéticos e lógica nebulosa. Esse indicador, desenvolvido por Gerald Appel, é utilizado por analistas do mercado financeiro, quando aplicado ao preço de valores mobiliários, para indicar o melhor momento de compra e venda das ações. A metodologia proposta foi validada utilizando as ações da Petrobras PETR4, no período entre fevereiro de 2005 e agosto de 2008, alcançando um lucro superior a 70%.*

1. Introdução

Ações são valores mobiliários definidos e regulamentados pelas leis número 6.385 de 7 de Dezembro de 1976 e 10.303 de 31 de Outubro de 2001 e constituem-se em títulos representativos da menor fração do capital de uma empresa (sociedade anônima, sociedade por ações ou companhia). O acionista, portador do título, não se torna um credor da empresa a que se refere o título, na verdade, passa a ser coproprietário com direito a participação nos lucros. Não existe data de resgate para a ação que pode ser convertida em dinheiro a qualquer momento mediante a negociação no mercado. Dessa forma, a escolha do melhor momento de compra e de venda dessas ações torna-se de fundamental importância na determinação do lucro ou prejuízo para o portador desses títulos.

Com base nisso, analistas do mercado financeiro, usualmente, desenvolvem e utilizam ferramentas que auxiliam na tarefa de prever o *timing* do mercado, isto é, o melhor momento de compra ou venda de um valor mobiliário.

Uma das escolas, a tecnicista [Cavalcante 2005], advoga que os preços de valores mobiliários se movimentam dentro de padrões preestabelecidos e que toda informação necessária à previsão de preços futuros está incorporada nos preços passados desses valores. Esses analistas utilizam ferramentas que auxiliam no entendimento e acompanhamento de padrões no decorrer da trajetória dos preços (tendências). Com o intuito de prever o início dessas tendências, é praticável analisar os preços das ações como séries temporais e aplicar uma modelagem adequada. Essa modelagem pode ser dividida em dois grandes grupos [Huang et al. 2007], [Chen et al. 2007]:

- Modelos lineares: baseados nos sistemas lineares clássicos onde os dados da série são ajustados a partir de uma equação linear. Apesar do mercado financeiro apresentar um comportamento não linear, esses modelos podem ser utilizados para caracterizar o tipo da série temporal. Exemplos: *Box-jenkins*, *kalman filter*, *Brown's theory of exponential smoothing e piecewise regression* [Huang and Tzeng 2008], [Chen et al. 2008a], [Gardner Jr. and Diaz-Saiz 2008], [Huang et al. 2007].
- Modelos não lineares: os preços são formados a partir de vários fatores que se relacionam de forma não linear. Desta forma, técnicas de caracterização e modelagem avançadas são necessárias para se obter resultados mais satisfatórios no que diz respeito à previsão destes valores. São exemplos: Taken's Theorem e Mackey-Glass equation [Huang et al. 2007], [Chen et al. 2008a].

Neste trabalho foi utilizado o indicador de análise técnica do mercado financeiro chamado *Moving Average Convergence/Divergence* (MACD). O MACD foi desenvolvido na década de 60 por Gerald Apple e é formado pela subtração de duas médias móveis exponenciais com janelas de tempo diferentes. Essa linha é chamada *linha do MACD* e permite a leitura da tendência dos preços do valor mobiliário avaliado. Também faz parte do indicador MACD uma linha formada pela média móvel exponencial do próprio valor do MACD, chamada *linha do Sinalizador*. Essa linha permite a visualização do melhor momento de compra ou venda (Figuras 1 e 3).

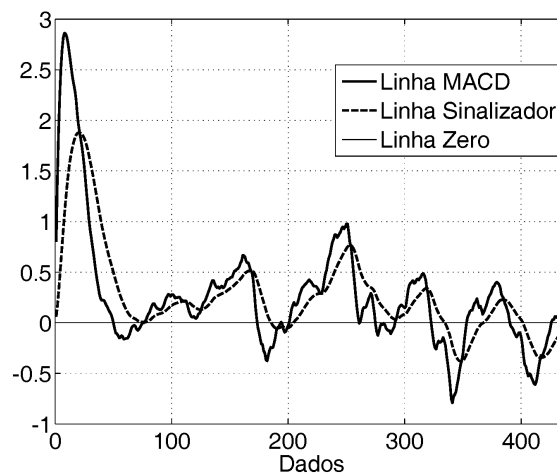


Figura 1. Moving average convergence divergence (MACD).

Para tanto, foram utilizados a teoria de algoritmos genéticos e a de lógica nebulosa, sendo que o algoritmo genético foi utilizado no intuito de se encontrar a configuração mais lucrativa para as janelas de tempo presentes na construção do *MACD* e a lógica nebulosa, por sua vez, foi utilizada na classificação das ordens de compra. A inserção da lógica nebulosa no algoritmo genético favoreceu a busca por soluções de configurações para as janelas de tempo que apresentaram maior lucro, uma vez que, as compras classificadas como inseguras foram descartadas.

O restante deste artigo é organizado como a seguir: na seção 2 é apresentado o modelo MACD com as suas possíveis configurações e leituras. A seção 3 apresenta detalhes sobre a construção e codificação do algoritmo genético. A seção 4 descreve a construção da função nebulosa utilizada para classificar as ordens de compra. A seção 5 apresenta simulações e resultados. A seção 6 apresenta a conclusão e propostas de trabalhos futuros.

2. MACD

De acordo com o Chen e colaboradores [Chen et al. 2008b] e Alexander Elder [Elder 1993] o MACD é construído como a seguir:

- Média móvel exponencial de 26 dias do preço das ações, chamada de *média longa*.
- Média móvel exponencial de 12 dias do preço das ações, chamada de *média curta*.
- Média móvel exponencial de 9 dias do próprio MACD, chamada de *linha de sinalização*.

A linha do MACD é obtida por meio da subtração da média móvel curta (12 dias) da média móvel longa (26 dias) e o resultado obtido será um valor que oscilará em torno de zero. As seguintes leituras podem ser extraídas desse resultado:

- MACD maior que zero: Neste caso a média móvel de 12 dias é maior que a média de 26. Isso significa que as expectativas mais recentes são mais favoráveis para alta das ações que as anteriores.
- MACD menor que zero: Neste cenário a média de 12 dias é menor que a de 26, mostrando um panorama mais relacionado a uma situação de baixa dos valores das ações.

As médias móveis podem ser representadas pela equação a seguir [Chen et al. 2008b]:

$$E[i] = (1 - \alpha)E[i - 1] + \alpha O[i], \quad (1)$$

onde $E[i]$ é o valor atual da média, $E[i - 1]$ é o último valor obtido, $O[i]$ é o preço atual do valor mobiliário e α é um fator de amortização que varia entre 0 e 1. Esse fator α é representado pela equação a seguir:

$$\alpha = \frac{2}{P + 1}, \quad (2)$$

onde P é o período. Para o MACD, P representa as janelas de tempo 12, 26 e 9.

A parametrização do MACD ocorre no fator α . Quando se utiliza um α com valor maior, o preço atual de fechamento diário do valor mobiliário influenciará de forma mais significativa o resultado obtido pela equação (1). Dessa forma, o indicador será mais ágil no que diz respeito ao acompanhamento da tendência de preços. Isto significa que a linha composta com um α maior responde mais rapidamente a pequenas variações na série de preços. No entanto, ao se utilizar um α menor, uma maior ênfase será dada ao último valor obtido da média, tornando a média mais estável em relação a perturbações oriundas da série de preços [Chen et al. 2008b].

A linha de sinalização, por sua vez, é uma referência para se definir a entrada ou saída do mercado de ações (*timing*). A leitura desse indicador pode ser feita como a seguir (Figura 1):

- Sinal de compra: Um sinal de compra é gerado sempre que o MACD cruza para cima sua linha de sinalização.
- Sinal de venda: É gerado sempre que o MACD cruza para baixo sua linha de sinalização.

É importante ressaltar que o investidor poderá escolher qualquer período para as médias móveis que compõe o MACD [Debastiani 2008]. Entretanto, os períodos de 12, 26 e 9 dias são os mais utilizados [Correia 2008].

Desta forma, esse artigo estuda a parametrização desses três períodos utilizados na construção do MACD por meio de algoritmos genéticos, como apresentado na próxima seção.

3. Algoritmo Genético - Codificação do Problema

Para a realização da tarefa de parametrização das médias móveis que compõe o MACD, utiliza-se neste trabalho uma abordagem baseada em algoritmo genético (AG). Os algoritmos genéticos surgiram a partir de tentativas de modelar e aplicar os mecanismos da biologia evolutiva como hereditariedade, mutação, seleção natural e recombinação (ou crossing over) no desenvolvimento de uma ferramenta computacional capaz de achar soluções aproximadas em problemas de otimização e busca, como os propostos nesse artigo [Rojas et al. 2008] [Engelbrecht 2007].

A estrutura de um algoritmo genético pode ser generalizada por meio do Algoritmo 1 e o significado e os valores dos parâmetros utilizados nesse trabalho podem ser vistos na Tabela 1.

Algoritmo 1 Algoritmo Genético

- 1 [Início]** Gere uma população aleatória de p cromossomas \hat{x}_k^i , $i = 1, \dots, p$, onde k é o número de variáveis de cada cromossomo ou genes.
 - 2 [Adequação]** Avalie a adequação $f(x)$ de cada cromossoma \hat{x}_k^i , $i = 1, \dots, p$.
 - 3 [Nova população]** Crie uma nova população repetindo os passos seguintes até que uma nova população esteja completa:
 - 3.1 Seleção** Selecione de acordo com sua adequação (melhor adequação, mais chances de ser selecionado) s cromossomas para a recombinação.
 - 3.2 Cruzamento** Com a probabilidade c de cruzamento cruze os pais para formar a nova geração.
 - 3.3 Mutação** Com a probabilidade de mutação m , altere os cromossomas da nova geração.
 - 3.4 Aceitação** Insira a nova descendência na população.
 - 4 [Substituição]** Utilize a nova população gerada para a próxima rodada do algoritmo.
 - 5 [Teste]** Se a condição final foi atingida, pare, e retorne a melhor solução da população atual.
 - 6 [Repita]** Vá para o passo 2.
-

A evolução geralmente se inicia a partir de um conjunto de soluções criadas aleatoriamente (população) e é realizada por meio de gerações. A cada geração, a adaptação de cada uma das soluções existente na população é avaliada sendo alguns desses indivíduos selecionados para reprodução. Os indivíduos selecionados são, então, recombinados e/ou mutados para formar uma nova população que será utilizada como entrada para a próxima iteração do algoritmo [Darwin 2004].

Nesse artigo, cada candidato a solução pode ser representado pela Figura 2, onde os índices MC, ML e MS são, respectivamente, período da média curta, longa e do sinalizador que compõem a construção do MACD.




Figura 2. Cromossomo

A função objetivo do algoritmo genético implementado foi a maximização da expressão 3.

$$L_{Total} = \sum_{i=1}^{op} L_i \quad (3)$$

$$L_i = \frac{(PV - PC) * 100}{PC}, \quad (4)$$

onde op é a quantidade de operações de compra e venda realizadas no decorrer da série de dados e L_i é o retorno financeiro de um ativo em cada operação (Figura 3). L_i é representado na expressão 4 onde PC é o preço do valor mobiliário no momento da compra e PV é o preço no momento da venda. A estratégia utilizada pelo programa foi a compra e venda simples, ou seja, após a emissão da ordem de compra o retorno financeiro de um ativo só é computado quando a ordem de venda for emitida.

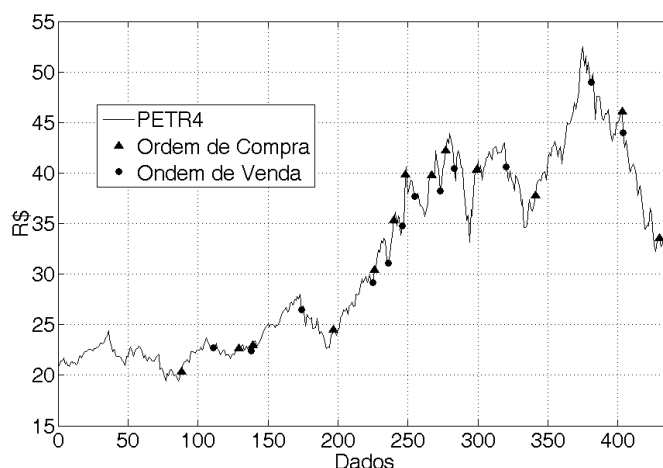


Figura 3. Ordens de Compra e Venda

Esse artigo propõe ainda, a partir da parametrização dos intervalos das médias móveis do MACD, a filtragem das operações de compra de ações classificadas como inseguras por meio da teoria dos conjuntos nebulosos. Dessa forma, os indivíduos que apresentem um valor maior de compras seguras serão privilegiados no decorrer das gerações do algoritmo genético.

4. Lógica nebulosa - Teoria dos conjuntos nebulosos

A teoria dos conjuntos nebulosos foi criada por Lotfi Zadeh, professor na Universidade da Califórnia em Berkeley [Zadeh 1965]. Um conjunto nebuloso A em um universo Ω é inteiramente representado por uma função de pertinência:

$$\mu_A : \Omega \rightarrow [1, 0] \quad (5)$$

Neste contexto, a função 5 faz o mapeamento de cada elemento do conjunto A em um conjunto dentro do intervalo fechado entre 0 e 1, descrevendo assim o grau de pertinência de cada elemento a propriedade que classifica o conjunto A .

A maior dificuldade na construção de um conjunto nebuloso se encontra na definição dos termos linguísticos e regras que controlam o conjunto. Nesta etapa de construção o conhecimento sobre o problema em questão é de extrema importância.

Para o problema de otimização do $MACD$ foram definidos 3 termos linguísticos para classificar o intervalo de dados:

- Tendência de Baixa.
- Movimento Lateral.
- Tendência de Alta.

A função de pertinência utilizada foi a trapezoidal e a relação dos termos linguísticos pode ser representada pela Figura 4.

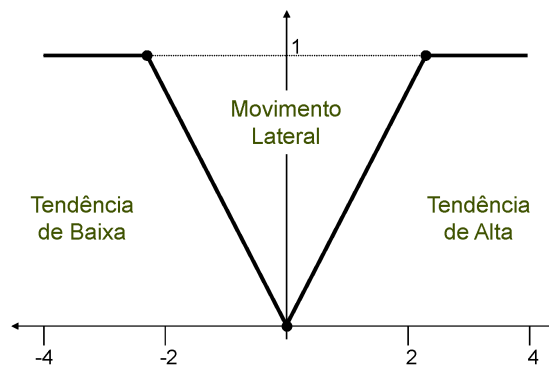


Figura 4. Função de Pertinência

Ao final, o programa classifica a compra em três categorias:

- *Compra segura*: Compras emitidas quando o $MACD$ está indicando tendência de baixa ou início de uma tendência de alta apresentam maior lucro. Esse comportamento pode ser explicado pela teoria Dow [Abe 2009] que diz que a movimentação dos preços de ativos tem o comportamento de repetir padrões históricos. Essa tendência poderia ser dividida em três partes: primária ou maior, secundária ou menor, e terciária. Os preços dos ativos têm esse comportamento devido à velocidade de difusão das informações relevantes. Para explicar a compra no início de uma tendência de alta, basta entender que os preços nesta fase da tendência estão influenciados por investidores "inteligentes" que têm informações privilegiadas. Quando o $MACD$ indica compra nessa fase, os lucros são maiores por acompanharem todo o movimento ascendente dos preços dos ativos. Para explicar o privilégio dado às ordens de compra do $MACD$ quando em tendência de baixa, seguimos outro princípio: A tendência é válida até ser revertida. Na verdade, a ordem de compra indicada pelo $MACD$ é vista como um padrão de reversão, pois, indica a mudança de interesse entre compradores e vendedores.
- *Sem inferência*: O $MACD$ está muito próximo do zero, significando que o mercado está apresentando um movimento lateral.
- *Compra insegura*: Ordens de compra emitidas em tendência de alta não apresentam uma boa lucratividade e, também, um maior risco.

Dessa forma, os indivíduos que apresentaram compras mais seguras ou sem interferência foram privilegiados no decorrer das gerações do algoritmo genético, bloqueando, portanto, as compras que foram classificadas como inseguras.

5. Simulações e Resultados

Para demonstrar a eficiência da metodologia aplicada ao problema de otimização do MACD, utilizou-se, no processo de validação do sistema implementado, os preços de fechamento diário da ação preferencial da Petrobras PETR4, no período entre fevereiro de 2005 e agosto de 2008 (Figura 5).

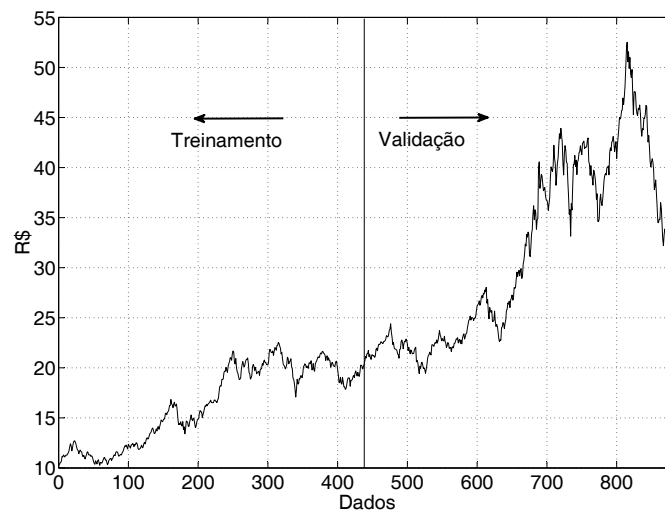


Figura 5. Série PETR4

A série da Petrobras, composta por um conjunto de 885 pontos, foi particionada em dois subconjuntos, S_1 e S_2 . O subconjunto S_1 , composto pelos 440 pontos iniciais da série (Dados de 02/02/2005 a 06/11/2006), foi utilizado no processo de treinamento do sistema, enquanto o restante dos 445 pontos, que compõem o subconjunto S_2 (Dados de 07/11/2006 a 29/08/2008), foram utilizados no processo de validação (Figura 5).

O algoritmo genético utilizado com o intuito de se encontrar a configuração mais lucrativa para as janelas de tempo presentes na construção do *MACD* foi construído de acordo com o pseudo-código apresentado na seção 3 e o significado e os valores dos principais parâmetros utilizados nesse pseudo-código podem ser vistos na Tabela 1.

Parâmetros	Significado	Valor
k	Número de variáveis	3
p	Número de indivíduos	50
g	Número de gerações	100
s	Taxa de seleção	100%
c	Taxa de crossover	0,65%
m	Taxa de mutação	0,1%

Tabela 1. Parâmetros de treinamento Algoritmo Genético.

Primeiramente, definiu-se que as variáveis que compõem um indivíduo serão representados por valores reais. As variáveis individuais de cada cromossomo são os valores de cada uma das janelas que compõem o *MACD* (Figura 2). Essa representação atua como

um genótipo (valores dos cromossomos) e é mapeada unicamente no domínio (fenótipo) da variável de decisão.

A etapa seguinte consistiu em criar uma população inicial p de 50 indivíduos. Cada uma das variáveis que compõem um indivíduo é formada por um número real uniformemente distribuído na faixa de 0 a 50.

Na fase seguinte, chamada seleção, um número de indivíduos são escolhidos para recombinação. O método da seleção usado nesse caso foi o da *roleta* com a seleção de toda a população ($s = 100\%$).

Após a fase de seleção, a operação de recombinação é executada. O tipo de *crossover* desenvolvido neste artigo foi a *recombinação intermediária*, considerando que a estrutura do cromossomo possui uma codificação de valor real. *Recombinação intermediária* é um método de produzir novos fenótipos em torno e entre os valores dos fenótipos dos pais [Mühlenbein and Schlierkamp-Voosen 1993]. Nessa operação, a prole é produzida de acordo com a regra:

$$F_1 = \alpha P_1 + (1 - \alpha)P_2 \quad F_2 = \alpha P_2 + (1 - \alpha)P_1 \quad (6)$$

onde α é um fator de escalonamento escolhido uniformemente de forma aleatória, sobre algum intervalo, tipicamente $[0, 1]$, P_1 e P_2 são os cromossomos pais e F_1 e F_2 são os filhos gerados.

Como na evolução natural, é necessário estabelecer um processo de mutação [Goldberg 1989]. Para populações de valor real, os processos de mutação são obtidos através da alteração do valor do gene ou fazendo uma seleção aleatória de novos valores dentro da faixa permitida [Janikow and Michalewicz 1991]. Uma mutação de valor real foi realizada com uma taxa de 0,1%.

Ao final do processo de mutação, a população será constituída de 100 indivíduos sendo que somente os 50 melhores serão escolhidos para formar a nova população.

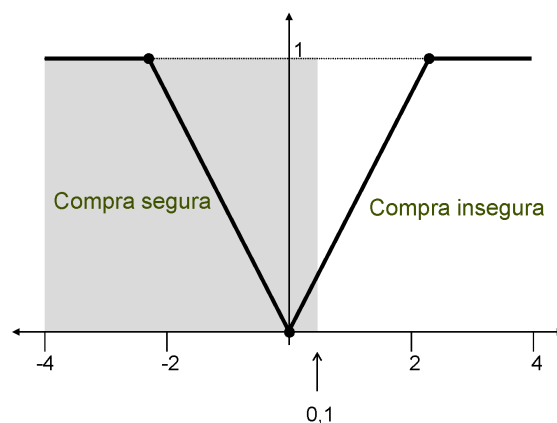


Figura 6. Região de compra segura

A simulação foi realizada utilizando o conceito de lógica nebulosa que atuará como um limitador na compra de ativos quando a função de pertinência aplicada ao valor do MACD, no ato da compra, for inferior a 0,1 referente a tendência de alta (Figura 6). Neste caso, a melhor configuração do *MACD* foi $[14.43, 20.73, 23.58]$ e o lucro obtido foi de 70,12%. É importante ressaltar a inversão ocorrida quanto a configuração das médias

curta e longa. Essa inversão seria descartada por qualquer *trader* (operador do mercado financeiro) que tivesse a intensão de otimizar a configuração do *MACD* de forma clássica [Elder 1993].

Para comparar a metodologia utilizada foi realizada uma simulação contendo a configuração usual do *MACD* [12, 26, 9] [Correia 2008] e a configuração otimizada mostrada por Alexander Elder [Elder 1993] que é [5, 34, 7]. Com a primeira configuração usual [12, 26, 9] o *MACD* gerou um lucro de 57,94%. Com a configuração [5, 34, 7] o lucro obtido, seguindo as indicações de compra e venda do *MACD*, foi de 29,46%. Os resultados de todas as simulações estão sumarizados na Tabela 2.

Característica	Configuração	Lucro
Configuração Usual (MACD)	[12, 26, 9]	57,94%
Configuração Usual [Elder 1993]	[5, 34, 7]	29,46%
Otimização GA/Nebulosa	[14.43, 20.73, 23.58]	70,12%

Tabela 2. Resultados Simulações.

6. Conclusões

Este artigo apresenta uma nova metodologia de parametrização do indicador técnico *MACD* por meio de algoritmos genéticos e lógica nebulosa.

Os resultados obtidos revelam que essa metodologia pode ser usada com sucesso, proporcionando lucros superiores a 70%, principalmente quando comparados às duas configurações usuais descritas em [Elder 1993] que apresentaram lucros de 57,94% e 29,46%.

Como trabalhos futuros, pretende-se acoplar outros indicadores de análise técnica, também parametrizados com essa metodologia, além de um estudo mais elaborado de estratégias de investimento, proporcionando a utilização deste sistema em situações de investimento real.

Finalmente, um novo encaminhamento desejado para este trabalho será a inclusão de algoritmos baseados em redes neurais artificiais para modelagem e previsão futura de valores de ativos para apoio à tomada de decisões de compra e venda.

Referências

- Abe, M. (2009). *Manual de Análise Técnica: Essência e Estratégias Avançadas*. Novatec, 1 edition.
- Cavalcante, F. (2005). *Mercado de capitais: o que é, como funciona*. Rio de Janeiro.
- Chen, C. W. S., Liu, F. C., and So, M. K. P. (2008a). Heavy-tailed-distributed threshold stochastic volatility models in financial time series. *Australian & New Zealand Journal of Statistics*, 50(1):29–51.
- Chen, T.-L., Cheng, C.-H., and Teoh, H. J. (2007). Fuzzy time-series based on fibonacci sequence for stock price forecasting. *Physica A*, 380:377–390.
- Chen, Y.-M., Chung, T.-Y., Lai, M.-Y., and Hsu, C.-H. (2008b). Macd-based motion detection approach in heterogeneous networks. *EURASIP Journal on Wireless Communications and Networking*, 2008.

- Correia, J. S. (2008). *Operando na Bolsa de Valores Utilizando Análise Técnica*. Brasil.
- Darwin, C. (2004). *A Origem Das Espécies*. Martin Claret.
- Debastiani, C. A. (2008). *Análise Técnica de Ações*. Brasil.
- Elder, A. (1993). *Trading for a living: psychology, trading tactics, money management*. New York.
- Engelbrecht, A. P. (2007). *Computational Intelligence: An Introduction*. John Wiley and Sons.
- Gardner Jr., E. S. and Diaz-Saiz, J. (2008). Exponential smoothing in the telecommunications data. *International Journal of Forecasting*, 24:170–174.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley.
- Huang, C.-Y. and Tzeng, G.-H. (2008). Multiple generation product life cycle predictions using a novel two-stage fuzzy piecewise regression analysis method. *Technological Forecasting & Social Change*, 75:12–31.
- Huang, W., Lai, K. K., and Nakamori, Y. (2007). Neural networks in finance and economics forecasting. *International Journal of Information Technology & Decision Making*, 6:113–140.
- Janikow, C. Z. and Michalewicz, Z. (1991). An experimental comparison of binary and floating point representations in genetic algorithms. In Belew, R. and Booker, L., editors, *Proceedings of the Fourth International Conference on Genetic Algorithms*, pages 31–36, San Mateo, CA. Morgan Kaufman.
- Mühlenbein, H. and Schlierkamp-Voosen, D. (1993). Predictive models for the breeder genetic algorithm: I. continuous parameter optimization. *Evolutionary Computation*, 1(1):25–49.
- Rojas, I., Valenzuela, O., Rojas, F., Guillén, A., Herrera, L. J., Pomares, H., Marquez, L., and Pasadas, M. (2008). Soft-computing techniques and arma model for time series prediction. *Neurocomputing*, 71(4-6):519–537.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, pages 338–353.