

# ANÁLISE DE LUCROS EM INVESTIMENTOS A PARTIR DO MACD COM O EMPREGO DE ALGORITMOS GENÉTICOS E LÓGICA FUZZY

Frederico C. R. Marques<sup>1</sup>, Rogério Martins Gomes<sup>1</sup> e Paulo E. M. de Almeida<sup>1</sup>

<sup>1</sup>Laboratório de Sistemas Inteligentes - CEFET-MG, Av. Amazonas, 7675 - Belo Horizonte - MG - Brasil - CEP 30510-000

Emails: [frederico@lsi.cefetmg.br](mailto:frederico@lsi.cefetmg.br); [rogerio@lsi.cefetmg.br](mailto:rogerio@lsi.cefetmg.br); [pema@lsi.cefetmg.br](mailto:pema@lsi.cefetmg.br)

**Abstract** – A new methodology for the parameterization of the technical analysis of the financial market indicator coined Moving Average Convergence-Divergence (MACD) is presented in this paper. The architecture of the MACD involves the use of exponential moving averages that in turn use different time windows, tracking securities prices trends and signalling the right moment to purchase and sale shares. By using genetic algorithms, it was possible to establish an optimal value for the time window which could yield higher profits, when compared to the time window used in literature. The use of fuzzy logic indicates the best moment for purchasing and sale of shares, raising the security of each transaction, thus resulting in the increase of the success rate. The methodology proposed was validated by taking into account the Petrobras shares (PETR4) in the period between February 2005 and August 2008, achieving a profit higher than that in the usual parameterisation.

**Keywords** – Genetic Algorithm, Fuzzy Logic, Financial Time Series.

**Resumo** – Uma nova metodologia de parametrização do indicador de análise técnica do mercado financeiro chamado Moving Average Convergence-Divergence (MACD) é apresentada neste artigo. A composição do MACD envolve o uso de médias móveis exponenciais que, por sua vez, utilizam janelas temporais diferentes, acompanhando a tendência dos preços dos valores mobiliários e indicando o melhor momento de compra e venda. Com o uso da técnica de algoritmos genéticos foi possível a escolha de janelas temporais que gerassem melhores lucros, quando comparados às janelas temporais utilizadas em diversas literaturas. A utilização de lógica fuzzy possibilitou a classificação das ordens de compra elevando a segurança de cada operação, traduzida no aumento da taxa de acerto. Para o trabalho aqui proposto entende-se com taxa de acerto a percentagem de operações de compra e venda que geraram rentabilidade positiva. A metodologia proposta foi validada utilizando as ações da Petrobras PETR4 no período entre novembro de 2006 e agosto de 2008, alcançando um lucro superior a parametrização usual.

**Palavras-chave** – Algoritmo Genético, Lógica Fuzzy, Séries Temporais Financeiras.

## 1. Introdução

A predição de dados em séries temporais é de extrema relevância para diversas áreas do conhecimento científico e vem sendo estudada desde o início do século XX quando alguns modelos matemáticos foram empregados. Até 1920, a predição de dados em séries temporais era basicamente realizada através da extrapolação dos dados por meio de um ajuste global no domínio do tempo. Entretanto, somente a partir de 1926 é que iniciou-se o que poderíamos chamar de moderna predição de séries, quando a técnica auto-regressiva foi publicada por Yule [1].

Na área financeira, a análise de séries temporais tem grande importância no estudo dos fenômenos sócio-econômicos [2] nos quais não se é possível determinar a dinâmica de evolução dos processos envolvidos em sua composição.

Muitos estudos têm sido desenvolvidos nesta área. Chen e colaboradores propuseram um modelo baseado em lógica fuzzy utilizando a sequência de Fibonacci e Ondas de Elliot na análise de duas séries temporais financeiras, a TSMC (Taiwan Semiconductor Manufacturing Company) e TAIEX (Taiwan Stock Exchange Capitalization Weighted Stock Index) [3]. Yu e colaboradores aplicaram técnicas de redes neurais artificiais e lógica fuzzy na previsão de valores da série de preços TAIEX [4]. Huang e colaboradores descreveram em seu artigo a utilização de redes neurais artificiais na previsão de preços em uma série temporal financeira e as vantagens em se acoplar outros métodos de análise de séries temporais [5]. Rojas e colaboradores estudaram uma metodologia híbrida acoplando redes neurais artificiais e o modelo de séries temporais ARMA (Autoregressive Moving Average Model) [6].

É nesse contexto, que o presente trabalho propõe um método de parametrização, por meio de algoritmo genético, do indicador de análise técnica do mercado financeiro MACD (Moving Average Convergence-Divergence) e a utilização de um sistema de inferência fuzzy que possa maximizar o lucro de investimentos nas ordens de compra e venda desse indicador. 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 [7] [8].

De uma forma geral esse artigo está organizado da seguinte forma: a subseção 2.1 apresenta o indicador de análise técnica do mercado financeiro MACD. A subseção 2.2 apresenta os detalhes de construção do algoritmo genético utilizado na parametrização do tamanho das janelas de tempo do MACD. A subseção 2.3, por sua vez, mostra como um sistema de inferência fuzzy foi utilizado para classificar as ordens de compra, permitindo a realização de operações mais seguras e intuitivas e maximizando os lucros. A validação do modelo proposto foi realizada utilizando-se os valores de fechamento diário dos preços da ação preferencial da Petrobras PETR4 e é apresentada na seção 3. A seção 4 discute os resultados obtidos e, por fim, a seção 5 conclui o artigo e apresenta as perspectivas de trabalhos futuros.

## 2. Metodologia

### 2.1 – MACD

De acordo com o Chen e colaboradores [7] e Alexander Elder [8] 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 longa (26 dias) da média móvel curta (12 dias), obtendo-se como resultado 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, significando uma tendência de aumento dos valores das ações.
- 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 [7]:

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

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  $\alpha$  é um fator de amortização que varia entre 0 e 1.

Esse fator  $\alpha$  pode ser 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. Vale ressaltar que neste trabalho  $P$  não será tratado como período em dias, uma vez que poderá assumir valores reais.

O ajuste do MACD ocorre no fator  $\alpha$ . Quando se utiliza um  $\alpha$  com valor mais próximo de 1, 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  $\alpha$  maior responde com maior velocidade a pequenas variações na série de preços. No entanto, ao se utilizar um  $\alpha$  mais próximo de 0 (zero), 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 [7].

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:

- 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 [9]. Entretanto, os períodos de 12, 26 e 9 dias são os mais utilizados [10].

Desta forma, esse artigo, estuda o ajuste desses três parâmetros utilizados na construção do MACD por meio de algoritmos genéticos, como apresentado na próxima subseção.

## 2.2 - Codificação do Problema por Meio de Algoritmos Genéticos

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). A estrutura do algoritmo genético utilizada nesse trabalho pode ser generalizada por meio do pseudocódigo apresentado abaixo e o significado e os valores dos parâmetros utilizados podem ser vistos na Tabela 1:

- 1 - **[Início]** Gere uma população aleatória de  $P$  indivíduos:  $X_{ki}, i = 1, 2, \dots, P$ , onde  $k$  é o número de variáveis de cada indivíduo.
- 2 - **[Adequação]** Avalie a adequação  $f(x)$  de cada indivíduo  $X_{ki}, i = 1, 2, \dots, P$ .
- 3 - **[Nova população]** Repita esta geração até o seu término: (limite de tempo, adequação alcançada, etc): Crie uma nova população repetindo os passos seguintes até que uma nova população esteja completa:
  - 3.1 – **Seleção:** Selecione de acordo com sua adequação (quanto melhor adequação, maiores serão as chances de ser selecionado)  $s$  indivíduos para a reprodução.
  - 3.2 – **Cruzamento:** Com a probabilidade  $c$  de cruzamento cruze os pais para formar uma nova geração.
  - 3.3 – **Mutação:** com a probabilidade de mutação  $m$  altere os cromossomas dos indivíduos.
  - 3.4 – **Substituição:** Substitua os indivíduos menos adaptados da população pelos os novos indivíduos.

Parâmetros	Significado	Valor
$k$	Número de variáveis	5
$p$	Número de indivíduos	100
$g$	Número de gerações	500
$s$	Taxa de seleção	100%
$c$	Taxa de crossover	60%
$m$	Taxa de mutação	35%

**Tabela 1** – Parâmetros do algoritmo genético utilizado neste trabalho com seus respectivos significados e valores.

Nesse artigo, cada candidato a solução pode ser representada como na Figura (1), na qual os índices **MC**, **ML** e **MS** são, respectivamente, os parâmetros do MACD para média curta, longa e de sinalização. Já os genes **a** e **c** são utilizados para ajuste das funções de pertinência fuzzy, como será apresentado na subseção 2.3 [10].



**Figura 1** – Representação do cromossomo: **MC** representa o parâmetro para a média curta, **ML** média longa e **MS** média da linha do sinalizador. Os parâmetros **a** e **c** são referentes ao sistema de inferência fuzzy que será descrito na próxima seção.

A função objetivo do algoritmo genético implementado foi a maximização da expressão (3):

$$L[Total] = \sum_{i=1}^{op} L[i] \quad (3)$$

$$L[i] = \frac{(PV - PC) 100}{PC} \quad (4)$$

Na expressão (3) foram somados os rendimentos percentuais obtidos em cada operação de compra e venda realizada de acordo com o MACD, utilizando cada um dos parâmetros fornecidos por cada um dos indivíduos gerados em cada geração do algoritmo genético. Logo  $op$  é o número de operações realizadas ao longo da série estudada. Por sua vez, os rendimentos percentuais de cada operação, realizada ao longo da série de treinamento, são obtidos na equação (4), onde  $PV$  é o preço de venda e  $PC$  é o preço de compra do ativo mobiliário.

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 fuzzy.

## 2.3 - Filtragem de Operações com Emprego de lógica Fuzzy

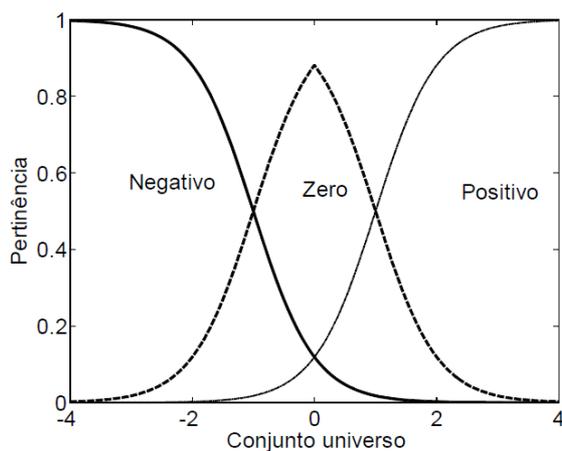
A teoria dos conjuntos fuzzy tem como objetivo principal a solução de problemas que envolvem termos linguísticos [11]. Nos conjuntos fuzzy cada elemento é definido por uma função que descreve o grau de pertinência desse elemento em um conjunto contido dentro de um universo de discurso pré-dado.

No que diz respeito ao problema de otimização do MACD, a teoria dos conjuntos fuzzy foi utilizada como um filtro, cuja função é a de classificar as ordens de compra emitidas pelo indicador de análise técnica. Assim, as ordens de compra com um grau de segurança abaixo do valor especificado pelo investidor não serão realizadas, criando uma possibilidade de ajuste entre o rendimento e a taxa de segurança. Entende-se como taxa de acerto o percentual de operações de compra e venda que obtiveram rendimento positivo.

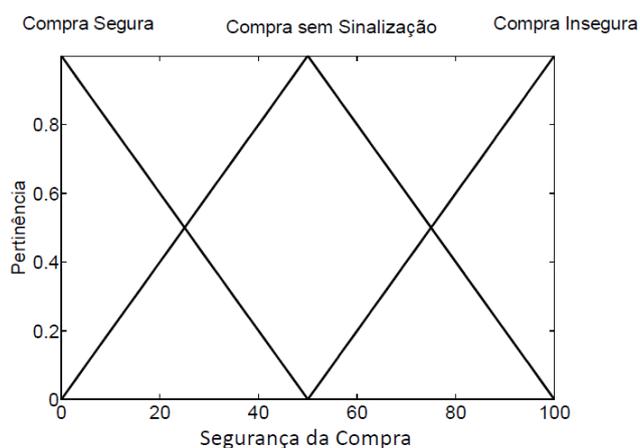
Esta classificação é possível depois de observar as seguintes cinco fases:

- Definição das partições fuzzy no conjunto universo (conjuntos fuzzy de classificação da tendência).
- Conversão escalar-fuzzy das observações da série temporal.
- Definição dos conjuntos fuzzy de classificação das ordens de compra.
- Definição das relações entre os conjuntos fuzzy representantes da classificação das tendências e representantes da classificação das ordens de compra.
- Conversão fuzzy-escalar e avaliação do resultado da máquina de inferência fuzzy.

Para a utilização do sistema fuzzy aqui proposto, se faz necessário a definição dos intervalos linguísticos que definem as partições fuzzy no conjunto universo. Essas partições classificam a tendência dos preços na serie temporal e são apresentadas nas Figuras 2(a) e 2(b). Os termos linguísticos foram definidos conforme as indicações do próprio MACD em: Negativo, Zero e Positivo.



(a)



(b)

**Figura 2a e 2b** – Partições fuzzy definidas no conjunto universo para as variáveis de entrada e saída, respectivamente.

A função de pertinência escolhida foi do tipo sigmóide, devido à sua flexibilidade de modificação do espaço que cada partição ocupa no conjunto universo de discussão. Isso ocorre com a modificação dos parâmetros  $a$  e  $c$  presentes na equação (5). A escolha desses parâmetros é descrita na seção 2.2r e é uma das funções do algoritmo genético.

$$\mu(MACD) = \frac{1}{1 + e^{-a(MACD - c)}} \quad (5)$$

A resposta desse processo de classificação de tendência, também chamado de fuzzificação, é um vetor com as pertinências, dado um valor de MACD, em cada um dos conjuntos na Figura 2(a).

Dando seguimento a metodologia aqui proposta, foram definidas três partições para a variável de saída:

- Compra segura.
- Compra sem sinalização.
- Compra insegura.

As funções de pertinência utilizadas nesta etapa foram triangulares, devido a simplicidade de implementação e estão representadas na Figura 2(b).

As regras da máquina de inferência fuzzy são:

- SE MACD = negativo ENTÃO Compra = segura.
- SE MACD = zero ENTÃO Compra = sem sinalização.
- SE MACD = positivo ENTÃO compra = insegura.

A defuzzificação utilizada foi do tipo centróide e pode ser demonstrada na equação 6.

$$C = \frac{PMCS * ACS + PMCSS * ACSS + PMCI * ACI}{ACS + ACSS + ACI} \quad (6)$$

onde

- $C$  = centróide;
- $PMCS$  = ponto médio da compra segura;
- $ACS$  = área da compra segura;
- $PMCSS$  = ponto médio da compra sem sinalização;
- $ACSS$  = área da compra sem sinalização;
- $PMCI$  = ponto médio da compra insegura;
- $ACI$  = área da compra insegura.

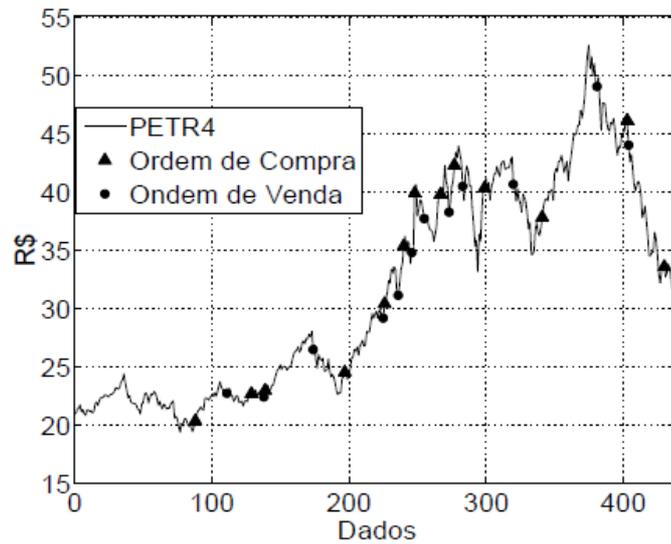
A equação (6) retorna um valor entre 0 e 100. A compra é avaliada de modo que só será efetuada se o valor do centróide for menor que um parâmetro pré-estabelecido sendo esse valor, estudado empiricamente. Com o intuito de melhor avaliar a contribuição efetiva do sistema fuzzy foi analisado também o fator de acerto. Entende-se por acerto como sendo qualquer operação de compra e venda que gere lucro positivo. Logo a taxa de acerto pode ser representada pela equação (7):

$$TA = \frac{QA}{QT} \quad (7)$$

onde,  $TA$  é a taxa de acerto,  $QA$  é a quantidade de operações de compra e venda realizadas com rendimento positivo e  $QT$  é a quantidade total de operações realizadas ao longo da série de dados.

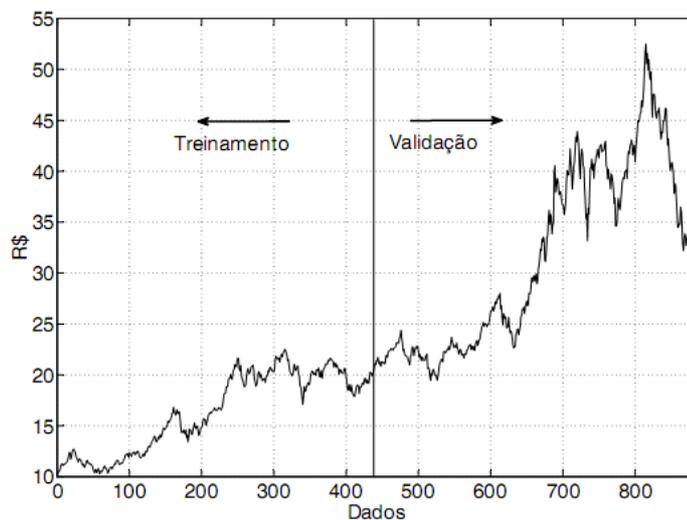
### 3. Resultados

Para demonstrar a eficiência da metodologia aplicada ao problema de maximização de lucro em questão, 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, conforme detalhamento de operações apresentado na Figura (3).



**Figura 3** – Representação das ordens de compra e venda indicadas ao longo da serie de dados.

A série original apresentada na Figura (3) foi dividida em duas partes, sendo, a primeira parte utilizada para treinamento e a segunda parte utilizada para validação do modelo conforme mostrado na Figura (4).



**Figura 4** – Série dos preços de fechamento diário da ação da Petrobras, PETR4, dividida em treinamento e validação.

A primeira simulação efetuada utilizou um algoritmo genético sem a restrição imposta pela lógica fuzzy. A Tabela 2 apresenta os resultados obtidos.

### Resultados do Treinamento - Algoritmo Genético Sem Inferência Fuzzy

Conjunto de Iterações	Média curta	Média longa	Média sinalização	Centróide	Rendimento (%)	Número de operações	Taxa de acerto (%)
1	17.38	25.76	15.85	100	91.28	6	83.33
2	16.88	25.95	16.23		91.28	6	83.33
3	15.11	21.35	22.03		90.93	6	83.33
4	15.20	24.97	18.65		91.28	6	83.33
5	18.58	25.25	15.13		91.28	6	83.33
6	16.70	25.07	17.07		91.28	6	83.33
7	17.66	25.38	15.82		91.28	6	83.33
8	15.28	19.07	24.50		91.28	6	83.33
9	17.92	25.35	15.59		91.28	6	83.33
10	17.86	25.53	15.56		91.28	6	83.33
Média	16.86	24.37	17.64	100	91.24	6	83.33
Desvio padrão	1.20	2.16	3.01	0	0.10	0	0

### Resultados da Validação

Conjunto de Iterações	Média curta	Média longa	Média sinalização	Centróide	Rendimento (%)	Número de operações	Taxa de acerto (%)
1	16.86	24.37	17.64	100	66.67	10	40.00
2	17.38	25.76	15.85	100	72.29	10	40.00
3	15.28	19.07	24.50	100	72.29	10	40.00

**Tabela 2** – Resultados obtidos na simulação sem a utilização da lógica fuzzy. Na parte de treinamento os campos intitulados Conjunto de Iterações representam cada um dos conjuntos de simulações realizadas. No primeiro conjunto de iterações da parte de validação foram utilizadas as médias das soluções encontradas em cada um dos conjuntos de iterações da fase de treinamento. No segundo conjunto de iterações foi escolhido, aleatoriamente, uma das melhores soluções encontradas no conjunto de iterações da fase de treinamento (Solução 1 da fase de treinamento). No terceiro conjunto de iterações da etapa de validação, foi utilizada a solução 8 da fase treinamento, que tem a particularidade de apresentar uma janela temporal para a média de sinalização maior que para a média longa. O parâmetro centróide indica a relação entre a lógica fuzzy e a segurança de compra.

A segunda simulação efetuada utilizou o algoritmo genético com a restrição imposta pela lógica fuzzy. A Tabela 3 apresenta os resultados obtidos.

### Resultados do Treinamento - Algoritmo Genético Com Inferência Fuzzy

Conjunto de Iterações	Média curta	Média longa	Média sinalização	Parâmetro a	Parâmetro c	Centróide	Rendimento (%)	Número de operações	Taxa de acerto (%)
1	49.86	49.85	50,00	2.74	3.37	50	65.90	4	100.00
2	49.83	49.71	49.94	1.52	3.52		64.94	4	100.00
3	49.27	49.26	49.68	3.24	2.87		75.06	6	100.00
4	49.88	49.37	49.84	2.26	1.83		64.94	4	100.00
5	49.42	49.08	49.92	2.28	2.01		61.29	4	100.00
6	49.33	47.20	49.20	1.86	2.60		59.77	4	100.00
7	49.94	49.88	49.90	2.16	2.56		64.94	4	100.00
8	48.99	48.98	49.74	3.69	2.06		63.47	4	100.00
9	50.00	49.10	49.94	1.59	2.46		64.94	4	100.00
10	49.62	49.45	49.96	1.75	3.51		64.94	4	100.00
Média	49.62	49.19	49.81	2.31	2.68	50	65.02	4.2	100.00
Desvio padrão	0.33	0.73	0.22	0.68	0.59	0	3.82	0.60	0

### Resultados da Validação - Algoritmo Genético Com Inferência Fuzzy

Conjunto de Iterações	Média curta	Média longa	Média sinalização	Parâmetro a	Parâmetro c	Centróide	Rendimento (%)	Número de operações	Taxa de acerto (%)
1	49.62	49.19	49.81	2.31	2.68	50	43.57	3	100.00
2	49.27	49.26	49.68	3.24	2.87	50	45.93	4	100.00

**Tabela 3** – Resultados obtidos na simulação com a utilização da lógica fuzzy. No primeiro conjunto de iterações da etapa de validação foram utilizadas as médias das soluções encontradas em cada um dos conjuntos de iterações da fase de treinamento. No segundo conjunto de iterações foi escolhida a melhor solução encontrada no conjunto de iterações da fase de treinamento.

## 4. Discussão

Para avaliar a metodologia proposta neste trabalho foram realizadas simulações com a configuração usual do MACD (MC=12, ML=26, MS=9), a configuração otimizada mostrada em [8] (MC=5, ML=34, MS=7) e com os melhores resultados obtidos nas Tabelas 2 e 3. Os resultados são apresentados na Tabela 4.

Avaliando os resultados referentes ao rendimento por operações é possível observar que a metodologia proposta nesse artigo foi mais viável que as configurações usuais do MACD, apresentando lucros de aproximadamente 7% por operação para o conjunto de iterações 3 e 11,5% para o conjunto de iterações 4 (Tabela 4). As configurações usuais, por sua vez, apresentaram lucros de aproximadamente 4,8% por operação para o conjunto de iterações 1 e 1,6% e para o conjunto de iterações 2 (Tabela 4). É importante ressaltar que este trabalho não considera as taxas de corretagem, entretanto, para operações reais quanto maior a lucratividade por operação, menor será o peso dos encargos inerentes às operações de compra e venda.

Resultados da Validação							
Conjunto de iterações	Média curta	Média longa	Média sinalização	Centróide	Rendimento (%)	Número de operações	Taxa de acerto (%)
1	12	26	9	100	57.94	12	50.00
2	5	34	7	100	32.37	20	45.00
3	15.28	19.07	24.50	100	72.29	10	40.00
4	49.27	49.26	49.68	50	45.93	4	100.00

**Tabela 4** – Comparação dos resultados obtidos. Primeiro conjunto de iterações: Resultados obtidos com a configuração usual do MACD apresentada em Correia (2003). Segundo conjunto de iterações: Resultados obtidos com a configuração usual do MACD apresentada em Elder (1993). Terceiro e quarto conjunto de iterações: Melhores resultados obtidos com o sistema proposto neste artigo.

Avaliando a taxa de acerto, que representa o percentual de operações de compra e venda que tiveram rendimento positivo, o sistema, utilizando algoritmos genéticos sem a inferência fuzzy, apresentou uma taxa de acerto menor que as apresentadas pelas outras configurações, demonstrando ser, apesar do maior lucro final, a metodologia mais arriscada na busca por melhores rendimentos. Já com o sistema de inferência fuzzy, o sistema se tornou mais seguro, acertando 100% das operações realizadas. Dessa forma, o sistema fuzzy age como um filtro permitindo que os investidores possam traçar graus de confiança no sistema.

## 5. Conclusão

Este artigo apresenta uma nova metodologia de parametrização do indicador técnico MACD por meio de algoritmos genéticos e lógica fuzzy. Os resultados obtidos revelam que essa metodologia pode ser usada com sucesso, gerando lucros superiores quando comparados às duas configurações usuais descritas na literatura [8][10]. Como trabalho futuro 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. Pretende-se também um estudo mais elaborado na parte do sistema fuzzy que proporcionará uma melhor regulação da relação entre lucratividade e segurança da operação.

**Agradecimentos:** Os autores agradecem a valiosa colaboração da FAPEMIG pelo apoio individual concedido, ao Laboratório de Sistemas Inteligentes – CEFETMG pelo suporte técnico e infra-estrutura disponibilizada e ao CEFETMG por tornar esse trabalho possível.

## Referências:

- [1] M. C. F. de Castro, Predição não-linear de séries temporais usando redes neurais RBF por decomposição em componentes principais, **Universidade Estadual de Campinas - UNICAMP**(2007).
- [2] C. W. S. Chen, F. C. Liu, and M. K. P. So, Heavy-tailed-distributed threshold stochastic volatility models in financial time series, **Australian & New Zealand Journal of Statistics**, 50(2008), 29-51.
- [3] T. L. Chen, C.-H. Cheng, and H. J. Teoh, Fuzzy time-series based on Fibonacci sequence for stock price forecasting, **Physica A**, 380(2007), 377-390.
- [4] T. H. K. Yu, and K. H. Huang, A bivariate fuzzy time series model to forecast the TAIEX, **Expert Syst. Appl.**, 34(2008), 2945-2952.
- [5] W. Huang, K. K. Lai, and Y. Nakamori, Neural networks in finance and economics forecasting, **International Journal of Information Technology & Decision Making**, 6(2007), 113-140.
- [6] I. Rojas, O. Valenzuela, F. Rojas, A. Guillén, L. J. Herrera, H. Pomares, L. Marquez, and M. Pasadas, Soft-computing techniques and ARMA model for time series prediction, **Neurocomputing**, 71(2008), 519-537.
- [7] Y.-M. Chen, T. Y. Chung, M.-Y. Lai, and C. H. Hsu, MACD-Based Motion Detection Approach in Heterogeneous Networks, **Journal of Comparative Neurology**, 2008(2008).
- [8] A. Elder, Wiley, J. (ed.) Trading for a living: psychology, trading tactics, money management, New York, 1993.
- [9] C. A. Debastiani, Novatec (ed.), Análise Técnica de Ações, Brasil, 2008.
- [10] J. S. Correia, Novatec (ed.), Operando na Bolsa de Valores Utilizando Análise Técnica, Brasil, 2008.
- [11] L. A. Zadeh, Fuzzy Sets, **Information and Control**, 1965, 338-353