

***INSTITUTO TECNOLÓGICO DE AERONÁUTICA***



Álvaro Pereira Giarola e Silva

Aplicação de Técnicas de Inteligência Artificial ao Estudo de  
Séries Temporais

*Trabalho de Graduação*  
2009

***Civil***

**Álvaro Pereira Giarola e Silva**

**Aplicação de Técnicas Inteligência Artificial ao Estudo de Séries  
Temporais**

Orientador  
Prof. Dr. Marcos Antonio Botelho (ITA)

**Divisão de Engenharia Civil**

SÃO JOSÉ DOS CAMPOS  
COMANDO-GERAL DE TECNOLOGIA AEROESPACIAL  
INSTITUTO TECNOLÓGICO DE AERONÁUTICA

2009

**Dados Internacionais de Catalogação-na-Publicação (CIP)**  
**Divisão de Informação e Documentação**

Silva, Álvaro  
Aplicação de Técnicas de Inteligência Artificial ao Estudo de Séries Temporais / Álvaro Pereira Giarola e Silvas.  
São José dos Campos, 2009.  
Número de folhas no formato 33f.

Trabalho de Graduação – Divisão de Engenharia Civil-Aeronáutica –  
Instituto Tecnológico de Aeronáutica, 2009. Orientadores: Prof. Dr. Marcos Botelho (ITA)

1. O que é Arbitragem Estatística. 2. Amostragem. 3. Identificação das Distorções. 4. Modelando as Distorções. 5. Teste Padrão. 6. Teste com Otimização. 7. Conclusão e Sugestões

Comando-Geral de Tecnologia Aeroespacial. Instituto Tecnológico de Aeronáutica. Divisão de Engenharia Civil-Aeronáutica. Aplicação de Inteligência Artificial ao Estudo de Séries Temporais

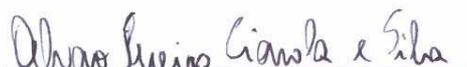
**REFERÊNCIA BIBLIOGRÁFICA**

Silva, Álvaro. **Aplicação de Técnicas de Inteligência Artificial ao Estudo de Séries Temporais**. 2009. 33f. Trabalho de Conclusão de Curso. (Graduação) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

**CESSÃO DE DIREITOS**

NOME DO AUTOR: Álvaro Pereira Giarola e Silva  
TÍTULO DO TRABALHO: Aplicação de Técnicas de Inteligência Artificial ao Estudo de Séries Temporais  
TIPO DO TRABALHO/ANO: Graduação / 2009

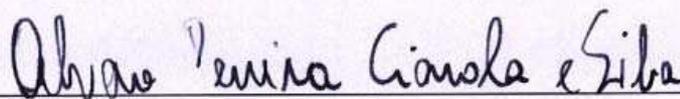
É concedida ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias deste trabalho de graduação e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta monografia de graduação pode ser reproduzida sem a autorização do autor.



Álvaro Pereira Giarola e Silva  
H8-A, Apto 135 CTA  
São José dos Campos - SP  
CEP 12.228-460

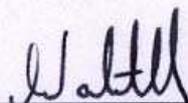
# Aplicação de Inteligência Artificial ao Estudo de Séries Temporais

Essa publicação foi aceita como Relatório Final de Trabalho de Graduação



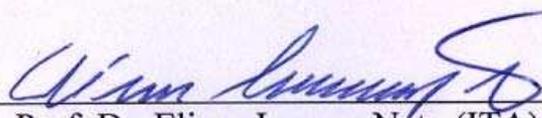
Alvaro Pereira Giarola e Silva

Autor



Prof. Dr. Marcos Antonio Botelho (ITA)

Orientador



Prof. Dr. Eliseu Lucena Neto (ITA)

Coordenador do Curso de Engenharia Civil

# Dedicatória

Dedico este trabalho à minha família,  
Alvaro, Janette, Renata e Rodrigo,  
ao meus amigos, Luiz, Victor e Rogério,  
ao mestre, Jonas,  
aos meus amigos do ITA,  
e aos meus professores, Eliseu, Marcos Botelho e Íria.

# Agradecimentos

Agradeço ao mestre Jonas e ao Victor por terem me dado a primeira oportunidade.

Ao professor Cláudio Jorge pela oportunidade de me dedicar a atividades não relacionadas ao ITA.

Ao professor Eliseu e a professora Íria pelo apoio provido durante a graduação.

Ao professor Marcos Botelho pelas orientações providas.

Frase célebre:

De grão em grão a galinha enche o papo.

# Resumo

Este trabalho visa aplicar técnicas de inteligência artificial à construção de um sistema de arbitragem estatística inteligente para detecção de distorções no preço de pares de ações. O sistema proposto é baseado numa classe de modelos de redes neurais e modelos de auto-regressão da volatilidade que visam capturar efetivamente a dinâmica do processo de distorção dos preços ativos. A performance do sistema proposto foi medida adequadamente pela utilização de métricas e pela adição do diagrama de ganhos e perdas, enquanto que algoritmos genéticos foram utilizados para a otimização do processo decisório.

# **Abstract**

This work aims to building an intelligent statistical arbitrage system with the use of artificial intelligence techniques. The proposed system is based on neural networks and autoregressive models with the purpose to effectively capture the distortion process of the synthetic asset. The performance of the system is measured by a set of proposed metrics and by the profit and loss diagram. Also, an optimization routine is presented in order to improve the performance by changing the trading parameters of the system.

# Sumário

|  |    |
|--|----|
| Lista de Figuras.....                                | 11 |
| Lista de Abreviações.....                            | 12 |
| Capítulo 1 Introdução.....                           | 13 |
| Capítulo 2 Coleta de dados históricos.....           | 17 |
| Capítulo 3 Identificação das distorções.....         | 18 |
| Capítulo 4 Modelando as distorções.....              | 22 |
| 4.1 Preditor do preço do ativo sintético.....        | 23 |
| 4.2 Preditor da volatilidade do ativo sintético..... | 24 |
| Capítulo 5 Teste padrão - Simulação.....             | 25 |
| Capítulo 6 Teste com Otimização - Simulação.....     | 28 |
| Capítulo 7 Conclusão e sugestões.....                | 32 |
| Referências Bibliográficas.....                      | 33 |

# Lista de Figuras

|   |    |
|---|----|
| Figura 2-1 Bandas de entrada, saída e stop .....  | 14 |
| Figura 4-1 Evolução dos preços de PETR3 e PETR4 .....                                       | 18 |
| Figura 4-2 Evolução dos preços de VALE3 e VALE5 .....                                       | 19 |
| Figura 6-1 Resultado do <i>back test</i> PETR3 e PETR4 .....                                | 26 |
| Figura 6-2 Resultado do <i>back test</i> VALE3 e VALE5 .....                                | 26 |
| Figura 7-1 Resultados do <i>back test</i> PETR3 e PETR4 com parâmetros otimizados .....     | 30 |
| Figura 7-2 Resultados do <i>back test</i> para VALE3 e VALE5 com parâmetros otimizados..... | 30 |

# Lista de Abreviações

|     |                                |
|-----|--------------------------------|
| AE  | Arbitragem estatística         |
| SRM | Sharpe Ratio modificado        |
| GA  | Algoritmo genético             |
| FT  | Função de transferência        |
| VPT | Vetor de parâmetros de trading |

## Capítulo 1 **Introdução**

A busca pela “fórmula mágica” de se ganhar dinheiro da dinâmica infundável dos preços nos mercados financeiros tem sido alvo de inúmeras pesquisas. Muito foi estudado e muito foi desenvolvido na tentativa de “ganhar” do mercado. Sistemas seguidores de tendência, sistemas de reversão à média, sistema de negociação de volatilidade e sistemas de arbitragem pura são todos exemplos destes desenvolvimentos. Dentre eles, está a estratégia chamada de arbitragem estatística (AE), a qual será o tema deste trabalho.

AE deve ser entendida como a tentativa de explorar a má precificação de um conjunto de ativos cuja combinação dos preços apresentem sinais claros de reversão à média. Ao contrário da arbitragem determinística, a AE tem risco. Porém esse risco é diluído pela execução de milhares de operações que possuem valor esperado positivo, o que faz com que a estratégia seja na maioria das vezes lucrativa e tenha um risco baixo. Essa relação risco/retorno será discutida e adequadamente medida no presente trabalho.

AE, se comparada com outras metodologias de trading, é altamente quantitativa e muito dependente de técnicas computacionais. São utilizadas técnicas de *data mining*, e também sistemas computadorizados de *trading*. Recentemente, um vasto número de técnicas de inteligência artificial tem sido usadas no desenvolvimento de modelos de predição de séries temporais de forma a explorar a dinâmica dos mercados financeiros. A maioria dos modelos de inteligência computacional baseia-se no treinamento de redes neurais do tipo *feedforward*, *radial basis function* ou redes neurais recorrentes [4]. Ainda, outras formas técnicas como *lógica fuzzy* [5] e *algoritmos genéticos* também são abundantes.

Estudos anteriores indicam que a precisão na predição de séries temporais pode ser melhorada pela combinação de diferentes ativos, ao invés de utilizarmos uma única série de preços. Tal combinação de ativos é chamada nesse trabalho de ativo sintético. Mais precisamente, dado um conjunto de ativos com retornos  $(X_1, \dots, X_n)$ , dizemos que temos um *ativo sintético sujeito a distorções no seu valor* se a combinação linear

$$w_1X_1 + w_2X_2 + \dots + w_nX_n$$

tem média zero e variância finita.

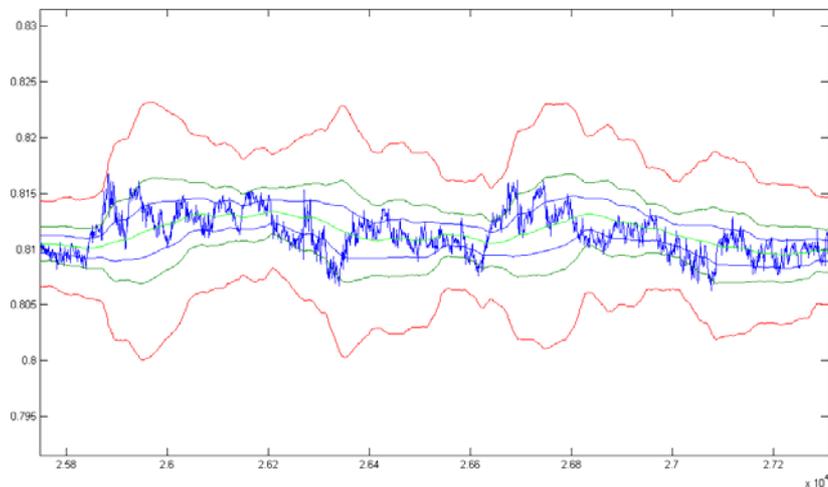
O vetor  $w = (w_1, \dots, w_n)$  representa a proporção de ativos a ser mantida na carteira quando mantemos uma posição *comprada* no ativo sintético. No caso de posição ser *vendida*, devemos manter em os ativos na proporção  $-w$ .

É necessário frisar que o processo acima necessariamente deve apresentar reversão à média, de maneira que distorção seja corrigida e não cresça indefinidamente, o que tornaria impossível controlar o risco do portfólio.

Para tornar o sistema de trading completamente automático, o sistema de decisão deve ser capaz de lidar com as seguintes situações:

- Não há posição nenhuma montada e o sistema de decisão indica que é hora de montar posição .
- Há posição montada e o sistema indica que é hora de desmontar a posição e auferir o lucro.
- Há posição montada e o sistema indica que é hora de desmontar a posição e admitir o prejuízo de uma operação mal sucedida.

Para tal é necessário determinar o ponto de entrada - *entry*, saída com lucro - *exit* e saída com prejuízo - *stop* para posição comprada e vendida no ativo sintético. Portanto é necessário determinar, para cada instante, três pares de pontos que, se traçados em função do tempo, fornecem três pares de curvas, chamadas aqui de bandas de trading. A figura 2-1 ilustra o traçado das bandas.



**Figura 1-1 Bandas de entrada, saída e stop**

De maneira geral, as bandas de trading são determinadas da seguinte maneira:

- Traça-se uma linha central que é uma média móvel de tamanho arbitrário. Essa média pode ser aritmética, exponencial ponderada...
- Calcula-se a banda de entrada – *entry* - , somando-se e subtraindo-se da média móvel uma medida de dispersão multiplicada por um fator  $\tau_{en}$  .
- Calcula-se a banda de saída com lucro – *exit* - , somando-se e subtraindo-se da média móvel uma medida de dispersão multiplicada por um fator  $\tau_{ex}$  .
- Calcula-se a banda de saída com prejuízo – *stop* - , somando-se e subtraindo-se da média móvel uma medida de dispersão multiplicada por um fator  $\tau_{st}$  .

O vetor formado pelos fatores supracitados será chamado neste trabalho de *vetor de parâmetros de trading* (VPT)  $\mathbf{p} = (\tau_{en}, \tau_{ex}, \tau_{st})$ . Sistemas menos robustos simplesmente arbitram tais valores conforme a preferência do operador. Uma análise mais algorítmica nos levou a propor um método para otimizar tais valores de forma a maximizar uma função performance, que nesse trabalho será o *Sharpe Ratio* modificado (SRM). Para tal utilizaremos algoritmos genéticos (GA). Entraremos em detalhes no capítulo 6.

No traçado das bandas, utiliza-se uma medida de dispersão. A medida mais utilizada pelos praticantes do mercado é a volatilidade (desvio padrão dos retornos). Essa abordagem deixa a desejar porque ignora previsibilidade da heterocetasticidade dos preços de ativos financeiros e a *clusterização* da volatilidade. Há um velho ditado do mercado que enuncia “dias nervosos tendem a ser seguidos por dias nervosos e dias calmos tendem ser seguidos por dias calmos”. Esse comportamento foi incorporado ao sistema proposto pela utilização de um estimador da volatilidade que fornece uma boa previsão da volatilidade futura a partir das volatilidades realizadas. Isso permite ao sistema alargar ou estreitar as bandas conforme o mercado se estressa ou acalma. Este assunto será detalhado no capítulo 4.

Sistemas mais simples indicam o momento de entrada a partir do momento que a banda de entrada tem seus limites extrapolados pelo valor do ativo sintético. O sistema proposto inclui também uma rede neural para estimar o valor futuro do ativo sintético. Tal instrumento tem por finalidade autorizar a montagem de posições quando houver sinais de reversão à média, e evitando a entrada prematura no mercado. Entraremos em mais detalhes no capítulo 4.

Nesse trabalho, propõe-se a construção de sistema inteligente de arbitragem estatística que disporá de:

- uma métrica apropriada para medir o valor do ativo sintético;
- um estimador para o preço do ativo sintético;

- um estimador para a volatilidade do ativo sintético;
- um rotina de otimização dos parâmetros de trading.

O sistema proposto será também testado por meio de uma simulação histórica com dados reais. Entraremos em mais detalhes sobre o processo de coleta e ajuste de dados no capítulo 3.

## Capítulo 2 **Coleta de dados históricos**

Escolhemos as ações ordinárias e preferenciais da Petrobrás (PETR3 e PETR4) e da Vale (VALE3 e VALE5) para a validação do modelo. Tais ações apresentam boa liquidez, o que permite montar e desmontar posições de tamanho razoável sem que provoquemos distorções nos preços. A idéia principal do modelo é capturar as distorções do mercado devido a uma momentânea falta de liquidez e não criá-las.

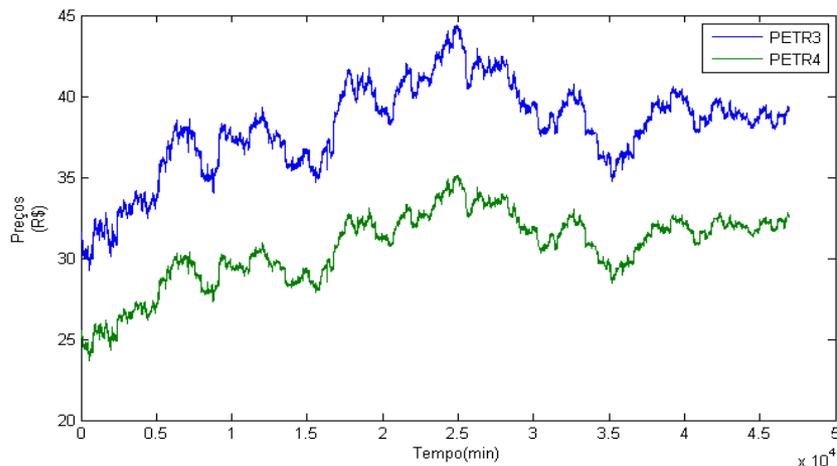
As ações citadas são comercializadas entre 10:00 AM até 17:00 PM no horário de Brasília na bolsa de valores. A *Nova Bolsa*, a bolsa de valores do Brasil, é eletrônica, o que permite a execução de ordens por algoritmos computacionais. Em outras palavras, podemos construir um robô que pode operar solidário ao sistema de negociação da ações. Utilização de algoritmos computacionais é necessária devido à velocidade com que as distorções surgem e desaparecem, o que tornaria ineficiente a execução manual do algoritmo de zeragem.

A análise descrita nesse trabalho foi feita a partir de dados coletados de minuto a minuto entre os dias 02/03/2009 e 20/8/2009. Os dados foram coletados entre as 10:15 e 16:45 com o propósito de se eliminar períodos de baixa liquidez e distorção exagerada dos preços encontrados no início e no fim do pregão . É necessário ajustar a série histórica de preços coletadas de forma a incluir os eventos corporativos que causem mudança no preço da ações, tais como pagamento de dividendos, desdobramentos, juros sobre capital próprio.

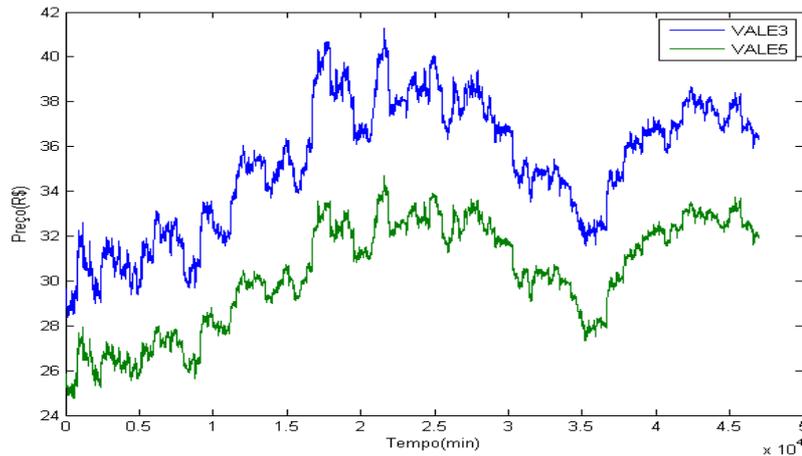
## Capítulo 3 Identificação das distorções

Nesse capítulo propõe-se um novo método de identificação das distorções que será composto por uma rede neural para modelar o comportamento do ativo sintético e por um estimador de volatilidade. O método proposto permite a alocação de diferentes montantes de capital nas ações que serão compradas e vendidas. O método tradicional, chamado aqui de *método padrão*, muito usado pelos operadores locais, usa quantidades iguais de capital alocadas igualmente na venda e na compra de cada ação que compõe o ativo sintético.

As figura 3-1 e figura 3-2 mostram o evolução dos preços ajustados por dividendos e desdobramentos da ações PETR3/PETR4 e VALE3/VALE5 entre os dias 02/03/2009 e 20/8/2009. As ações apresentam sinais visíveis de *co-integração* e correlação altíssima.



**Figura 3-1 Evolução dos preços de PETR3 e PETR4**



**Figura 3-2** Evolução dos preços de VALE3 e VALE5

As séries de resíduos  $Z_t$  padrão são construídas a partir do *método padrão* pela seguinte definição:

$$Z_t = \frac{P_{1t}}{P_{2t}} - \frac{1}{w} \sum_{j=t-w}^{t-1} \frac{P_{1j}}{P_{2j}}$$

A series de resíduos proposta define os resíduo  $Z_t$  proposto pela seguinte expressão:

$$Z_t = \frac{P_{1t}^\beta}{P_{2t}} - \frac{1}{w} \sum_{j=t-w}^{t-1} \frac{P_{1j}^\beta}{P_{2j}}$$

onde  $\beta$  é obtido fazendo-se uma simples regressão linear dos retornos diários das ações. Seu uso visa garantir a neutralidade da posição em relação à direção predominante do mercado e seu valor deve ser recalculado periodicamente.

Para simplificar a notação, vamos definir  $S_t$ , o valor do ativo sintético em  $t$ , pondo

$$S_t = \frac{P_{1t} \wedge \beta}{P_{2t}}$$

Assim, podemos escrever:

$$S_t = Z_t + \frac{1}{w} \sum_{j=t-w}^{t-1} \frac{P_{1j} \wedge \beta}{P_{2j}}$$

o que pode ser expresso numa notação simplificada como

$$S_t = Z_t + \varphi \cdot S_t \quad (3.1)$$

Seja  $P_t$  a série de preços do ativo de interesse, registrados periodicamente (em intervalos iguais). A série de retorno do ativo  $N_t$ , é definida pela equação 3.2. A volatilidade realizada do ativo de interesse é definida em 3.3.

$$N_t = \log P_t - \log P_{t-1} \quad (3.2)$$

$$\sigma_{t:Rv} = \frac{1}{m-1} \sqrt{\sum_{i=0}^{m-1} (N_{t-1} - \bar{N})^2} \quad (3.3)$$

Dado que temos a volatilidade realizada de  $S_t$ , podemos medir a “distância” entre  $S_t$  e sua média usando  $\sigma_t$  como unidade. Tal modo de se mensurar o afastamento entre a média e valor atual do ativo sintético é utilizado rotineiramente pelos praticantes do mercado

No capítulo 4 abordaremos os seguintes aspectos fundamentais da modelagem:

- I. será apresentada uma técnica de estimação da volatilidade futura que permitirá ao sistema adiantar-se ou atrasar-se na montagem da posição, dado que os pontos de entrada e saída são definidas pela multiplicação de  $\sigma_{t+1}$  por uma constante.
- II. será usado um estimador não-linear para estimar o valor  $S_{t+1}$ . Tal estimador é composto por um fator que depende da média das últimas observações e também de um resíduo,  $Z_{t+1}$  que será estimado por uma rede neural.

## Capítulo 4 Modelando as distorções

Nesse capítulo, estaremos descrevendo o modelo para medição das distorções, usando um modelo auto-regressivo que estima o valor futuro do ativo sintético de  $S_{t+1}$  a partir de  $\mathbf{Z}_t = (Z_{t-1}, \dots, Z_{t-w})$  e  $\mathbf{S}_t = (S_{t-1}, \dots, S_{t-w})$ , utilizando-se uma rede neural do tipo *feedforward* com uma camada escondida de  $n$  neurônios.

Estima-se também a volatilidade de  $S_t$  e de  $X_t$  a partir de um modelo auto-regressivo com suavização exponencial. Este modelo, que estima o valor futuro de  $X_{t+1}$  a partir de  $\mathbf{X}_t = (X_{t-1}, \dots, X_{t-w})$  e  $\mathbf{R}_t = (R_{t-1}, \dots, R_{t-w})$ , é formalizado conforme as equações 4.1 e 4.2:

$$Z_t = S_t - \phi \cdot S_t$$

$$S_t = \phi \cdot S_t + f(\mathbf{Z}_t; \theta) + \varepsilon_t \quad (4.1)$$

$$\varepsilon_t \sim N(0, \sigma_t^2)$$

$$f(\mathbf{Z}_t; \theta) = \sum_{j=1}^l \alpha_j \mathbf{F}(w_j \mathbf{Z}_t - c_j)$$

$$R_t = X_t - \eta \cdot X_t$$

$$\log(\sigma_t : R_t) = X_t = \eta \cdot X_t + g(\mathbf{R}_t; \theta) + \delta_t \quad (4.2)$$

$$\delta_t \sim N(0, \rho_t^2)$$

$$\phi, \phi, \eta, w_j \in \mathbb{R} \text{ e } \alpha_j, c_j \in \mathbb{R}^n$$

A seguir, faremos uma breve explicação a respeito da origem das equações 4.1 e 4.2 que estimam o valor futuro do preço do ativo sintético e da volatilidade do ativo sintético.

#### 4.1 Preditor do preço do ativo sintético

A equação 3.1 enuncia que o preço do ativo sintético pode ser decomposto em duas partes: a média (no caso, foi utilizada a média aritmética) e o resíduo. Assumindo que a média para o próximo instante  $t+1$  não vai se alterar muito, podemos aproximar o valor do ativo sintético para  $t+1$  como sendo a média no instante  $t$  somada ao resíduo em  $t+1$ . Como não sabemos qual será valor do resíduo no futuro, calibraremos uma rede neural do tipo *feedforward* com uma camada de neurônios escondida para tentar fornecer uma predição desse resíduo a partir seus valores passados.

O objetivo da rede neural é estabelecer uma relação, linear ou não, entre um conjunto de dados de entrada e uma correspondente saída ou resposta. Para isto, são utilizadas transformações matemáticas na entrada, de modo a produzir a saída desejada. A rede realiza este trabalho "aprendendo" como o sistema em estudo se comporta e em seguida aplica este conhecimento a novos dados de entrada para predizer a saída apropriada.

*Função de transferência* (FT) é a representação matemática da relação entre a entrada e a saída de um sistema. Devemos determinar FT para o neurônios da rede neural. Para o modelo em questão, utilizou-se FT dada por  $\mathbf{F}$  como sendo do tipo *logística*, também chamada de *sigmoidal*.

$$\mathbf{F}(x) = \frac{1}{1 + e^{-x}}$$

Para a correta determinação do preditor do preço do ativo sintético devemos determinar:

- I. Tamanho do vetor de resíduos  $\mathbf{Z}_t$
- II. Tamanho do vetor valores passados do ativo sintético  $\mathbf{S}_t$
- III. Vetor  $\phi$
- IV. Número de neurônios na camada escondida e seus respectivos pesos

- V. Valores dos pesos atribuídos a cada ligação entre os neurônios (é feito na fase de treinamento da rede neural)

#### 4.2 **Preditor da volatilidade do ativo sintético**

Acurada predição da volatilidade é um fator crucial para sucesso da implementação de um sistema de AE. A seguir detalharemos a técnica de estimação da volatilidade usada no modelo proposto nesse trabalho.

O modelo de estimação da volatilidade é basicamente descrito pela suavização do logaritmo da volatilidade realizada por uma média exponencial, com modelagem do resíduo da volatilidade realizada por modelo linear auto-regressivo.

Analogamente ao procedimento usado na predição do valor futuro do ativo sintético, tentaremos estimar o valor futuro da volatilidade assumindo que média da volatilidade realizada (nesse caso usaremos a média exponencial) para  $t+1$  é igual à média em  $t$ . Por outro lado, o resíduo será estimado por um simples modelo auto-regressivo ao invés de uma rede neural.

Para a correta determinação do preditor da volatilidade do ativo sintético devemos determinar:

- I. Tamanho da janela de cálculo da volatilidade realizada
- II. Tamanho do vetor do logaritmo da volatilidade realizada  $\mathbf{X}_t$
- III. Vetores  $\eta$
- IV. Escolher a ordem  $n$  do modelo auto-regressivo,  $Ar(n)$ .
- V. Adequada calibração dos parâmetros do modelo auto-regressivo.

Em [1] e [3] recomenda-se a utilização do critério de informação de *Akaike* para determinar o número de neurônios na camada escondida e a ordem do modelo auto-regressivo.  $\phi, \eta$  são escolhidos de forma a termos uma média aritmética e média exponencial respectivamente (ver equações 4.3 e 4.4). O número de neurônios na camada escondida e a ordem do modelo auto-regressivo foram arbitrados em 20 e 5, respectivamente.

Nossa abordagem tenta modelar o comportamento não-linear e estacionário presente no comportamento das distorções e também no comportamento da volatilidade. Para tal, propõe-se uma classe de modelos de redes neurais com suavização exponencial da volatilidade. O modelo será chamado de NN-SM.

## Capítulo 5 Teste padrão - Simulação

Nesse capítulo descreveremos etapas do processo de exploração das distorções a partir de um modelo calibrado e os resultados obtidos na simulação. Dado que o modelo NN-SM esteja pronto, com todos os parâmetros corretamente estimados, partiremos para a próxima etapa, que é a definição do algoritmo de *trading* a ser descrito em seguida.

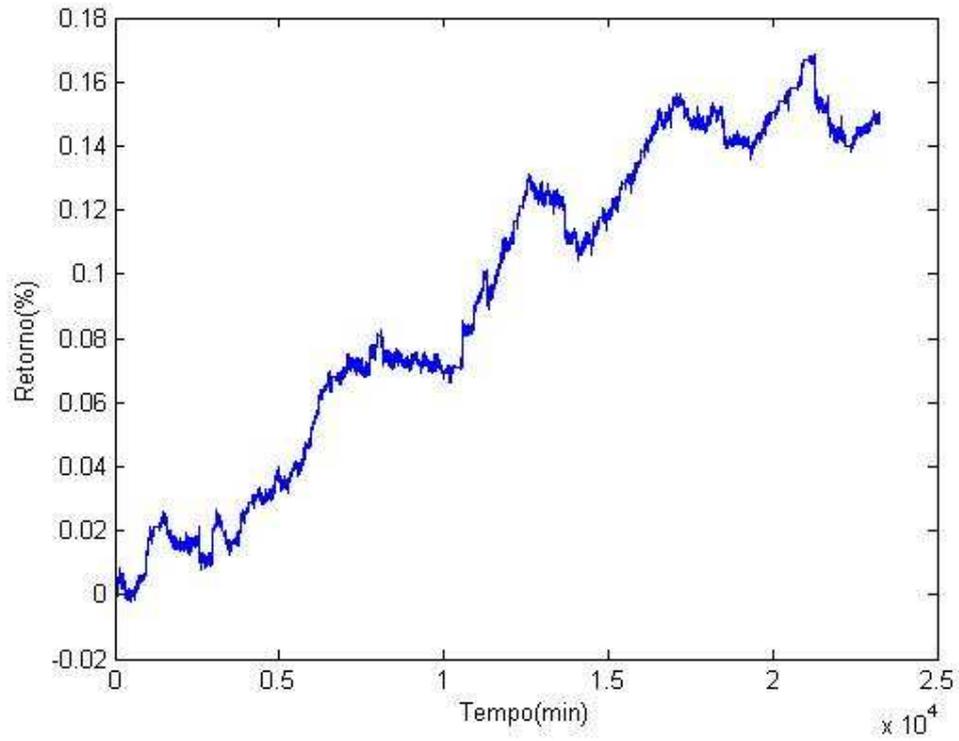
Deve-se:

- I. Estimar  $Z_{t+1}$  a partir de  $Z_t$ .
- II. Estimar de  $X_t$  dado  $X_t$  e, logo depois, obter  $\sigma_t$ .
- III. Se  $S_{t+1} < S_t$  e  $S_t > Z_t + \tau_{st}\sigma_t$ , monta-se uma posição vendida no ativo sintético com ponto de saída em  $exit = S_t - \tau_{ex}\sigma_t$  e *stop loss* em  $stop = S_t + \tau_{st}\sigma_t$ .  
Se  $S_{t+1} > S_t$  e  $S_t < Z_t - \tau_{st}\sigma_t$ , monta-se uma posição comprada no ativo sintético com ponto de saída em  $exit = S_t + \tau_{ex}\sigma_t$  e *stop loss* em  $stop = S_t - \tau_{st}\sigma_t$ .
- IV. Se o valor de  $S_t$  atingir o valor de *exit* ou *stop*, liquida-se a posição.

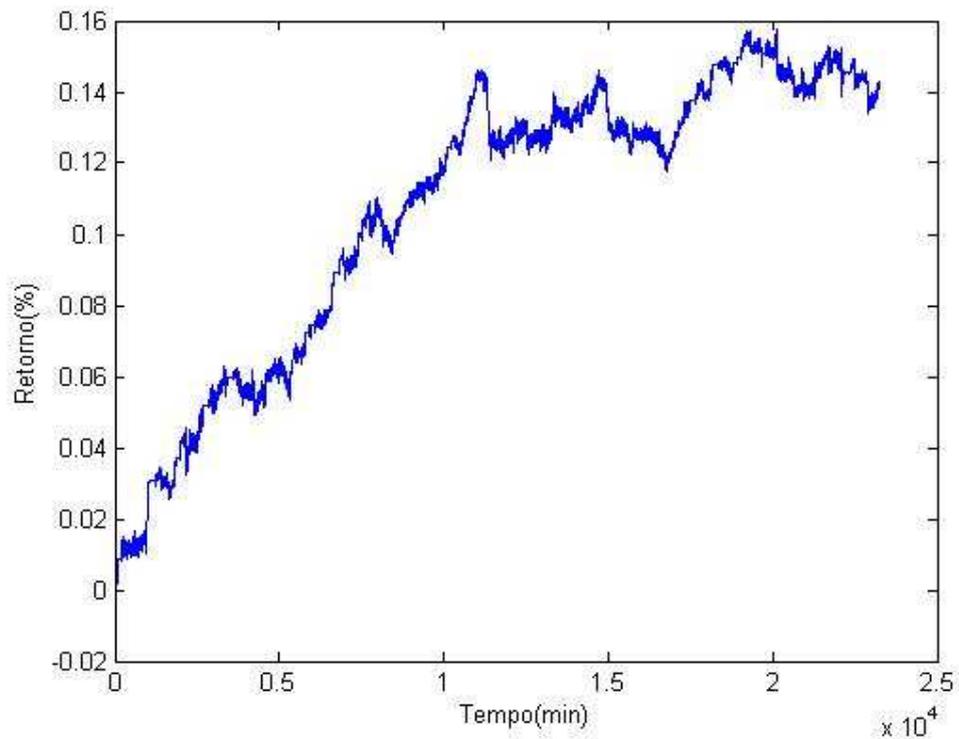
Devemos definir o VPT,  $\mathbf{p} = (\tau_{en}, \tau_{ex}, \tau_{st})$ . Para tal, utilizaremos outra ferramenta de inteligência artificial chamada de *algoritmo genético*, que será detalhada no próximo capítulo.

No primeiro teste usaremos  $\mathbf{p} = (2, 0, 5)$ , que será batizado de  $\mathbf{p}_{padrão}$ . Usaremos tal vetor para comparar os valores dos resultados obtidos antes e depois da otimização via algoritmo genético. Para realizar a comparação, deve-se definir uma métrica de performance adequada que leve em conta a relação risco e retorno. A métrica escolhida chama-se *índice Sharpe modificado*, que será detalhada no próximo capítulo.

Para a calibração dos parâmetros do modelo e teste, separa-se a série histórica de preços em duas metades. Usou-se a primeira metade da série para a calibração do modelo e a outra metade para a validação do sistema proposto (*backtest*). A figura 5.1 detalha a evolução do diagrama de perdas e ganhos na etapa de validação com a utilização de  $\mathbf{p}_{padrão}$  como o VPT.



**Figura 5-1 Resultados do *back test* PETR3 e PETR4**



**Figura 5-2 Resultados do *back test* VALE3 e VALE5**

O resultado da simulação indicou um lucro líquido de 15% para o par PETR3-PETR4 e 14% para o par VALE3-VALE5. Esses resultados serão usados como *benchmark* para comparação do resultados da simulação que será feita a partir da otimização do VPT.

No capítulo 7 iremos otimizar o VPT usando algoritmos genéticos. Para tal, devemos definir uma função performance ou objetivo. O investidor racional prefere lucro e está avesso ao risco. Portanto, deve-se procurar maximizar o retorno (média dos retornos) e minimizar risco/incerteza (desvio padrão dos retornos). Portanto utilizaremos o SRM, que é a razão entre a média e desvio padrão dos retornos, como função objetivo a ser maximizada.

## Capítulo 6 **Teste com Otimização - Simulação**

A otimização (matemática), também conhecida por programação matemática, é uma área da matemática que tem tido crescimento explosivo apesar de possuir uma história relativamente recente. Basicamente, diz respeito a esta área a caracterização e procura de minimizantes, ou maximizantes, de uma certa função num certo conjunto, geralmente definido por equações e inequações algébricas.

Nesse capítulo descreveremos uma rotina de otimização para o vetor VPT. Para tal serão utilizados algoritmos genéticos. Determinado o VPT otimizado, partiremos para o teste em dados reais em amostra *outsample*. Os resultados serão propriamente medidos e comparados com o resultado do teste padrão.

Um *algoritmo genético* (AG) é uma técnica de procura utilizada na ciência da computação para achar soluções aproximadas em problemas de otimização e busca, fundamentado principalmente pelo americano John Henry Holland. Algoritmos genéticos são uma classe particular de algoritmos evolutivos que usam técnicas inspiradas pela biologia evolutiva como hereditariedade, mutação, seleção natural e recombinação (ou *crossing over*).

Estes algoritmos são implementados como uma simulação de computador em que uma população de representações abstratas de solução é selecionada em busca de soluções melhores. A evolução geralmente se inicia a partir de um conjunto de soluções criado aleatoriamente e é realizada por meio de gerações. A cada geração, a adaptação de cada solução na população é avaliada, alguns indivíduos são selecionados para a próxima geração e recombinados ou mutados para formar uma nova população. A nova população então é utilizada como entrada para a próxima iteração do algoritmo.

Algoritmos genéticos diferem dos algoritmos tradicionais de otimização em basicamente quatro aspectos:

- I. Baseiam-se em uma codificação do conjunto das soluções possíveis, e não nos parâmetros da otimização em si;
- II. os resultados são apresentados como uma população de soluções e não como uma solução única;
- III. não necessitam de nenhum conhecimento derivado do problema, apenas de uma forma de avaliação do resultado;
- IV. usam transições probabilísticas e não regras determinísticas.

Serão utilizados AG para otimizar VPT dado por  $p = (\tau_{en}, \tau_{ex}, \tau_{st})$ . Para tal, deve-se determinar a função performance a ser minimizada, que será definida na equação 6.2.

Seja  $N = (N_{t-1}, \dots, N_{t-w})$  a série de retornos obtida em dado período de interesse, define-se o SRM da série de retorno conforme 6.1.

$$sh = \frac{mean(N)}{std(N)} \quad (6.1)$$

$$F = \frac{1}{sh} \quad (6.2)$$

O índice de Sharpe ou Sharpe Ratio, criado por William Sharpe, é um indicador que permite avaliar a relação entre o retorno e o risco. É intuitivo desejar que a média da série de retornos tenha média alta (retorno) e pequena variância (risco).

É interessante limitar o intervalo onde deseja-se procurar a solução ótima. Assim estaremos evitando que o AG procure soluções que não sejam típicas de problemas de reversão à média. Também, queremos que o intervalo entre o ponto de entrada seja muito estreito de forma a não poder ser aplicado na prática.

Neste problema de otimização, estaremos impondo as seguintes restrições ao AG descritas nas desigualdades 6.3, 6.4 e 6.5 :

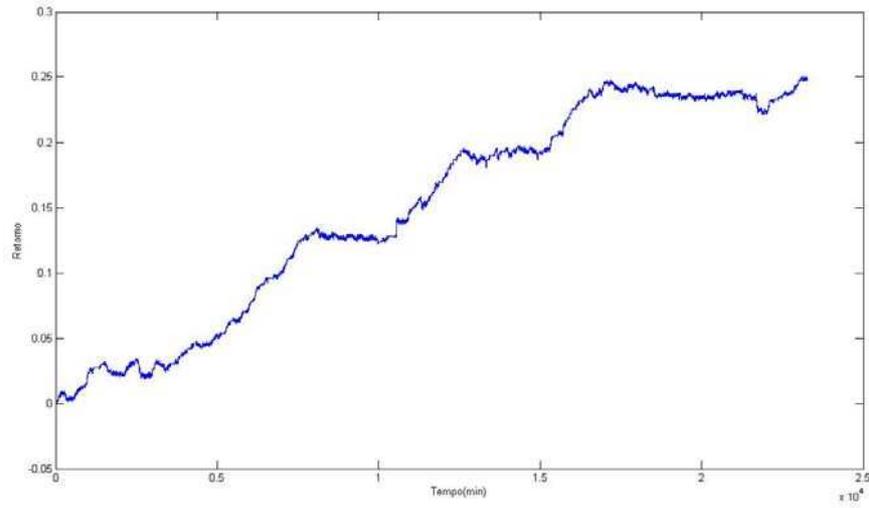
$$1.5 < \tau_{en} < \tau_{st} - 1 \quad (6.3)$$

$$0 < \tau_{ex} < \tau_{en} - 0.5 \quad (6.4)$$

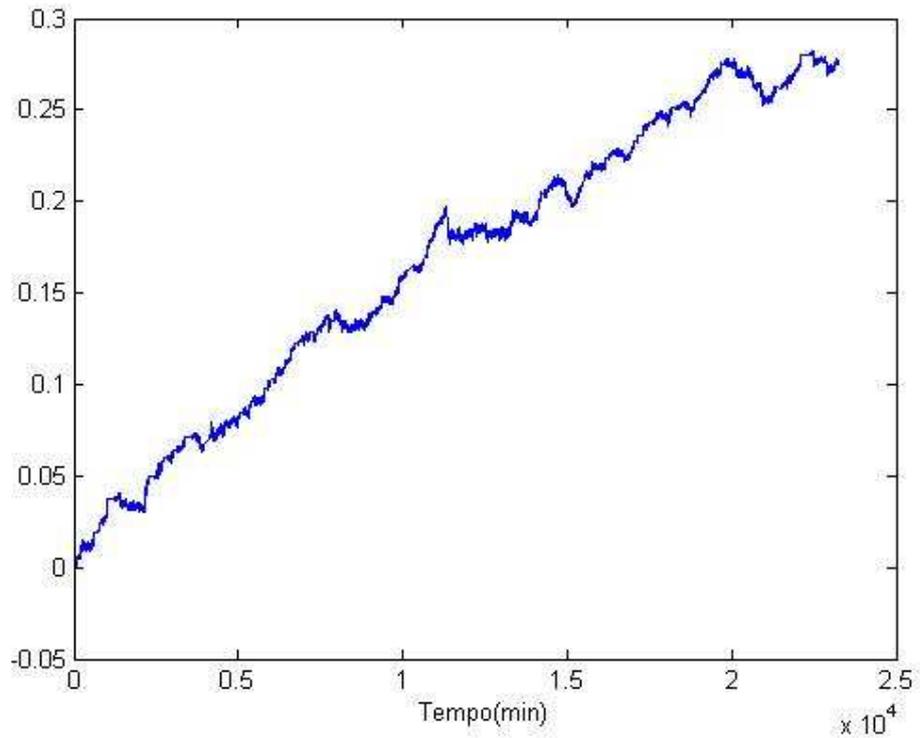
$$3 < \tau_{st} < 6 \quad (6.5)$$

A desigualdade 6.3 visa evitar que sejam feitas operações que não possam ser de reversão à média. Com 6.4 evita-se o término prematuro de uma posição sem que sejam auferidos lucros de tamanho insuficiente. Com, 6.5 evita-se que tenhamos um *stop loss* muito curto ou muito longo.

As figuras 7-1 e 7-2 mostram a evolução do lucro líquido em função do tempo.



**Figura 6-1 Resultados do *back test* PETR3 e PETR4 com parâmetros otimizados**



**Figura 6-2 Resultados do *back test* para VALE3 e VALE5 com parâmetros otimizados**

Lembremos que os lucros líquidos no teste padrão foram de 15% e 14% para os pares PETR3-PETR4 e VALE3-VALE5, respectivamente. A rotina de otimização se mostrou bastante eficiente na medida em que se pode constatar aumento significativo da performance absoluta, retorno, e relativa, SRM. Os lucros líquidos no teste com otimização foram de 25% e 27% .

Uma reta com inclinação positiva tem SRM infinito, na medida que os retornos são constantes e positivos, o que torna a desvio padrão nulo. Percebe-se que o gráfico do lucro líquido para ambos os pares se aproximou mais de uma reta depois da otimização dos parâmetros, indicando um claro aumento no SRM para a série de retornos dos pares de ações escolhidos.

## Capítulo 7 Conclusão e sugestões

O sistema NN-SM proposto desempenhou satisfatoriamente na série histórica utilizada para o *back test*. Houve acréscimo de informação pela adição da rede neural que serviu de árbitro para a determinação do momento de entrada. O estimador da volatilidade acrescenta mais informação, na medida em que alarga as bandas de entrada nos momentos de grande “nervosismo”, evitando uma entrada prematura no mercado, o que poderia significar um perda por *stop* ou uma redução da lucratividade da operação.

Dado que os parâmetros do sistema NN-SM já estão determinados, foi proposto também uma rotina de otimização *vetor de parâmetros de trading*  $\mathbf{p} = (\tau_{en}, \tau_{ex}, \tau_{st})$ . Para tal utilizou-se algoritmos genéticos. Dada uma busca prévia na série histórica, obteve-se *vetor de parâmetros de trading* otimizado. O conjunto otimizado apresentou resultados absolutos, retorno, e resultado relativo, índice Sharpe, melhores do que os resultados obtidos com o conjunto que usou  $\mathbf{p} = (2, 0, 5)$ ,  $\mathbf{p}$  padrão.

Sugerimos para trabalhos futuros a utilização da transformada *wavelet* ou análise espectral com transformada rápida de Fourier para a escolha do comprimento da média móvel de  $S_t$ . Pretende-se com isso capturar as principais frequências de oscilação dos ativo sintético e assim melhorar o comportamento reversivo.

Poderíamos melhorar o sistema de decisão incluindo mais uma ferramenta de decisão que procuraria padrões na série histórica de dados vislumbrando uma possível modificação do comportamento observado nos momentos de “nervosismo” do mercado. Tal mudança de comportamento pode ser observada no comportamento da volatilidade histórica que passa a apresentar picos *clusterizados*. Os picos de volatilidade associados ao comportamento não reversivo são os responsáveis pelas perdas momentâneas do sistema. Uma ferramenta de *pattern search* agregaria mais informações, proibindo o sistema de operar em tais períodos de grande incerteza.

## Referências Bibliográficas

- [1] THOMAIDIS, N.; KONDAKIS, N. An intelligent statistical arbitrage trading system. In: ADVANCES IN ARTIFICIAL INTELLIGENCE', LECTURE NOTES IN ARTIFICIAL INTELLIGENCE, Grigoris Antoniou et al., ed., p. 3955, 2006
- [2] THOMAIDIS, N.; DOUNIAS,G. A General Class of Neural Network-GARCH Models for Financial Time Series Analysis, April 1, 2006.
- [3] DETTLING, M.; BULHLMANN, P. Volatility and risk estimation with linear and nonlinear methods based on high frequency data , Outubro 23, 2002.
- [4] ZHANG, G.; Eddy, B. 1998. Forecasting with artificial neural networks:: The state of the art. In: INTERNATIONAL JOURNAL OF FORECASTING. Elsevier, vol. 14(1), p.35-62.
- [5] FIORDALISO, A. A nonlinear forecasts combination based on Takagi-Sugeno fuzzy systems. In: INTERNATIONAL JOURNAL OF FORECASTING 14, 1998, p.367-379.
- [6] ZIMERMANN, H.J. Fuzzy Set Theory and Its Applications. Kluwer, Boston , 1985.

## FOLHA DE REGISTRO DO DOCUMENTO

|  |                                       |  |                            |
|--|---------------------------------------|--|----------------------------|
| 1. CLASSIFICAÇÃO/TIPO<br><br>TC  | 2. DATA<br><br>23 de novembro de 2009 | 3. DOCUMENTO N°<br><br>CTA/ITA/TC-160/2009 | 4. N° DE PÁGINAS<br><br>34 |
| 5. TÍTULO E SUBTÍTULO:<br><br>Aplicação de Técnicas de Inteligência Artificial ao Estudo de Séries Temporais   |                                       |  |                            |
| 6. AUTOR(ES):<br><br><b>Álvaro Pereira Giarola e Silva</b>   |                                       |  |                            |
| 7. INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES):<br><br>Instituto Tecnológico de Aeronáutica – ITA  |                                       |  |                            |
| 8. PALAVRAS-CHAVE SUGERIDAS PELO AUTOR:<br><br>Inteligência artificial; Arbitragem estatística; Amostragem; Identificação das Distorções; Modelando as Distorções; Teste Padrão; Teste com Otimização.   |                                       |  |                            |
| 9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO:<br><br>Análise de séries temporais; Médias móveis auto-regressivas; Redes neurais; Inteligência artificial; Amostragem; Otimização; Matemática   |                                       |  |                            |
| 10. APRESENTAÇÃO: <div style="text-align: right; margin-right: 100px;"> <input checked="" type="checkbox"/> <b>Nacional</b> </div> <div style="text-align: right; margin-right: 100px;"> <input type="checkbox"/> <b>Internacional</b> </div><br>ITA, São José dos Campos. Curso de Graduação em Engenharia Civil-Aeronáutica. Orientador: Marcos Botelho. Publicado em 2009.  |                                       |  |                            |
| 11. RESUMO:<br><br>Este trabalho visa aplicar técnicas de inteligência artificial na construção de um sistema de arbitragem estatística inteligente para detecção de distorções no preço de pares de ações. O sistema proposto é baseado numa classe de modelos de redes neurais e modelos de auto-regressão da volatilidade que visam capturar efetivamente a dinâmica do processo distorção dos preços ativos. A performance do sistema proposto foi medida adequadamente pela utilização de métricas, e pela adição do diagrama de ganhos e perdas. Propõe-se a utilização de algoritmos genéticos para a otimização do processo decisório. |                                       |  |                            |
| 12. GRAU DE SIGILO:<br><br><input checked="" type="checkbox"/> <b>OSTENSIVO</b> <input type="checkbox"/> <b>RESERVADO</b> <input type="checkbox"/> <b>CONFIDENCIAL</b> <input type="checkbox"/> <b>SECRETO</b>   |                                       |  |                            |