

Análise Comparativa de Modelos de Previsão: Aplicação do *Model Confidence Set* para Preços de Alumínio

AUTORES

JOÃO BOSCO BARROSO DE CASTRO

Universidade de São Paulo
joaobosco.castro@uol.com.br

ALESSANDRA DE AVILA MONTINI

Universidade de São Paulo
amontini@usp.br

Commodities primárias, tais como metais, petróleo e de agricultura, constituem matérias-primas fundamentais para a economia mundial. Dentre os metais, destaca-se o alumínio, usado em uma ampla gama de indústrias, e que detém o maior volume de contratos da *London Metal Exchange* (LME). Como o preço não está diretamente relacionado aos custos de produção, em momentos de volatilidade ou choques econômicos, o impacto na indústria global de alumínio é significativo. Previsão de preços do alumínio é fundamental, portanto, para definição de política industrial, bem como para produtores e consumidores. Dadas as limitações dos métodos tradicionais para seleção de modelos de previsão, que não corrigem efeitos de *data snooping*, este trabalho aplicou o *Model Confidence Set* (MCS), introduzido por Hansen, Lunde e Nason (2011), para determinar o melhor conjunto de modelos de previsão de preços de alumínio. O MCS corrige efeitos de *data snooping* e introduz o conceito de nível descritivo para comparação múltipla de modelos. Foram desenvolvidos 3 modelos: ARFIMA, estrutural e mudança de regime markoviana, utilizando a base de dados de janeiro de 1980 a abril de 2012. Para cada modelo, foram geradas 60 previsões fora da amostra por meio de *rolling regressions* para estimativas de 1, 3, 6, 12 e 24 meses à frente. O modelo de mudança de regime apresentou melhor acuracidade de previsão em todos os horizontes de tempo estimados. Para previsão um mês à frente, o modelo ARFIMA apresentou resultados equiparáveis ao de mudança de regime para nível descritivo de 0,1. Dessa forma, obtém-se um intervalo de previsão de preços de acuracidade superior aos indicados pelos métodos tradicionais.

Palavras-Chave: Seleção de Modelos de Previsão; *Model Confidence Set*; Preço de *Commodities*

Primary commodities, including metals, oil and agricultural products are key raw materials for the world economy. Among metals, aluminum stands out for its large use in several industrial applications and for holding the largest contract volume on the London Metal Exchange (LME). As the price is not directly related to production costs, during volatility periods or economic shocks, the impact on the global aluminum industry is significant. Aluminum price forecasting, therefore, is critical for industrial policy as well as for producers and consumers. Given limitations of traditional methods for forecasting model selection, that do not treat data snooping effects, this work has applied the Model Confidence Set (MCS), proposed by Hansen, Lunde and Nason (2011), in order to determine the best set of models for aluminum price forecasting. The MCS approach treat data snooping and introduces the concept of descriptive level for multiple model comparisons. Three models were developed: ARFIMA, structural and Markov regime switching, using monthly data from January 1980 to April 2012. For each model, 60 out-of-sample forecasts were generated through rolling regressions for 1, 3, 6, 12 and 24 monthly steps ahead. The Markov regime switching presented the best forecast accuracy results for all time horizons. For 1 month ahead

forecasting, ARFIMA has showed results comparable to regime switching within a confidence interval at 0.1 MCS p-value. As a result, this approach provides an interval for aluminum price forecasting superior to those indicated by traditional methods.

Key Words: Forecasting Model Selection; Model Confidence Set; Commodity Prices

1. Introdução

Commodities primárias, tais como metais, petróleo e de agricultura, constituem matérias-primas fundamentais dos processos produtivos da economia mundial. Dentre os metais, o alumínio destaca-se por ser o elemento mais abundante na crosta terrestre (8,1%). Após o oxigênio e o silício, é o terceiro elemento (entre metálicos e não metálicos) mais abundante. Apesar de ser um metal relativamente recente (com pouco mais de 100 anos desde sua primeira comercialização), o seu uso supera o de qualquer outro metal, exceto aço. O alumínio é usado virtualmente em todos os segmentos da economia mundial, desde transportes, construção, setor elétrico até embalagens, equipamentos e indústria aeroespacial. Caracteriza-se por ser um produto leve (um terço da densidade do aço), anti-corrosivo, flexível, de boa condutividade elétrica (1 kg de alumínio conduz a mesma quantidade de eletricidade que 2 kg de cobre), refletor de calor irradiante, transmissor de calor por convecção, além de ser 100% reciclável. A sua principal fonte de obtenção é a bauxita, que necessita ser transformada em alumina, a partir da qual se produz alumínio.

O Brasil destaca-se na indústria global do alumínio uma vez que reúne características para isso: possui a terceira maior reserva de bauxita, é o terceiro maior produtor de bauxita e alumina e o sexto maior produtor de alumínio no mundo. A cadeia do alumínio no país atingiu faturamento de US\$ 13,3 bilhões em 2009 (equivalente a 3,9% do PIB industrial), investimentos de US\$ 1,2 bilhões, produção de alumínio primário de 1,5 milhões de toneladas e de produtos transformados de 1,1 milhões de toneladas, os quais incluem chapas, folhas, perfis, tubos, fundidos, fios e cabos para uma ampla gama de aplicações industriais. O Brasil reciclou 385 mil toneladas de alumínio em 2009, correspondente a 38,3% do consumo interno, e lidera mundialmente desde 2001 a reciclagem de latas de alumínio para bebidas, atingindo 98,2% do total comercializado em 2009.

O alumínio é uma *commodity* negociada no mundo inteiro, com base na cotação diária da *London Metal Exchange* (LME), principal bolsa mundial para metais não ferrosos, e que introduziu em 1978 contratos à vista e a termo (3 meses). O alumínio representa o maior contrato da LME, tanto em contratos futuros como opções. Como o preço não está diretamente relacionado aos custos de produção, em momentos de volatilidade de mercado ou de choques econômicos, o impacto na indústria global, nos países e empresas pode ser significativo.

A crise financeira global de 2008/2009, por exemplo, causou uma queda do preço do alumínio de cerca de US\$ 3.071 por tonelada em julho de 2008 para \$1.330 por tonelada em fevereiro de 2009. Ao mesmo tempo, os estoques mundiais de alumínio aumentaram continuamente, passando de 11,4 milhões de toneladas em julho de 2008 para 46 milhões de toneladas em setembro de 2009. Esta situação levou ao corte de capacidade produtiva de 3 milhões de toneladas em 2008/2009, sendo 1,9 milhões de toneladas na China e 1,1 milhões de toneladas na Europa e Estados Unidos. Em dezembro de 2011, os estoques ainda continuavam no patamar elevado de 47,9 milhões de toneladas e o preço em torno de US\$ 2.000 por tonelada. Desde então, os preços continuam baixos, oscilando em torno de US\$ 2.000 a \$2.300 por tonelada, em comparação a uma média histórica de 11 anos (2000-2011) de US\$ 2.500/tonelada, a valores constantes de 2010. A indústria voltou a fazer cortes em 2010 e houve fechamento adicional de capacidade em 2011 e 2012.

A possibilidade de que preços sejam frequentemente aleatórios introduz uma parcela importante de risco e incerteza no processo de análise de mercado e de previsão do preço do alumínio. Esta aleatoriedade pode ser melhor compreendida a partir de sua dinâmica de curto, médio e longo prazo.

No curto prazo, choques de mercado tendem a estar associado a fatores financeiros, principalmente à especulação e *hedging* em mercados futuros, opções e derivativos; uma ampla literatura existe para análise no curto prazo, incluindo séries temporais para dados de

alta frequência (Barkoulas et al., 1997; Adams e Vial, 1988). No médio prazo, previsão de preços e sua interrelação com ciclos da indústria, influenciados por forças de mercado e condições econômicas nacionais, têm sido aspectos preponderantes. Métodos econométricos utilizam análise espectral e de séries temporais, incluindo modelos estruturais de séries de tempo, os quais incorporam análise de componentes cíclicos (Harvey, 1999). No longo prazo, análise de tendência e de cenários de preços são importantes para avaliar investimentos de longa maturação de uma indústria de base, acima de 20 anos. Métodos econométricos de interesse têm incluído choques estruturais, subidas e quedas bruscas de preços e movimentos de reversão (Cashin e McDermott, 2002; Andrews, 1993; Perron, 1989). Neste contexto, um entendimento melhor da dinâmica de preço do alumínio, sujeito a ciclos de negócio, é extremamente desejável, tanto do ponto de vista de diretriz econômica, quando na ótica dos produtores e consumidores. O propósito deste trabalho é avançar na análise da dinâmica de curto e médio prazos para determinar o melhor conjunto de modelos de previsão de preços de alumínio, utilizando o *Model Confidence Set*. Para isso, foram desenvolvidos 3 modelos: ARFIMA, estrutural e mudança de regime markoviana, utilizando uma base de dados de janeiro de 1988 a abril de 2012. Para cada modelo, foram geradas 60 previsões fora da amostra por meio de *rolling regressions* para estimativas de 1, 3, 6, 12 e 24 meses à frente.

O trabalho apresenta no item 2 o referencial teórico sobre métodos de seleção de modelos, incluindo abordagens tradicionais, a metodologia de Diebold e Mariano (1995) e o *Model Confidence Set (MCS)*, introduzido por Hansen, Lunde e Nason (2011). No item 3, apresentam-se as bases teóricas dos modelos de previsão utilizados. O item 4 descreve a série de preços de alumínio e apresenta os modelos desenvolvidos. O item 5 apresenta os resultados da seleção dos modelos de previsão por meio da aplicação do MCS e o item 6 conclui.

2. Métodos para Seleção de Modelos de Previsão

2.1. Abordagens Tradicionais para Seleção de Modelos

As abordagens tradicionais para seleção do melhor modelo de previsão baseiam-se geralmente em medidas associadas aos erros de previsão. No entanto, tais medidas podem levar a conclusões errôneas decorrente do fato de existir apenas uma realização do processo estocástico. Um modelo pode ter um desempenho de previsão aparentemente superior a outro simplesmente por um resultado do acaso do que, de fato, possuir melhor poder preditivo. Isso está associado ao problema de *data snooping*, que ocorre quando um conjunto de dados é usado mais de uma vez para fins de inferência e de seleção de modelos (White, 2000).

Sejam $\{\hat{y}_{it}\}_{t=1}^T$ e $\{\hat{y}_{jt}\}_{t=1}^T$ duas previsões de uma série temporal $\{y_t\}_{t=1}^T$ e os erros de previsão $\{\hat{e}_{it}\}_{t=1}^T$ e $\{\hat{e}_{jt}\}_{t=1}^T$, onde $\hat{e}_{it} = (y_t - \hat{y}_{it})$ e $\hat{e}_{jt} = (y_t - \hat{y}_{jt})$.

Medidas associadas aos erros de previsão usualmente incluem:

- *Mean Absolute Error (MAE)*

$$MAE = \frac{\sum_{t=1}^T |\hat{e}_{it}|}{T}$$

- *Mean Square Error (MSE)*

$$MAE = \frac{\sum_{t=1}^T \hat{e}_{it}^2}{T}$$

- *Root Mean Square Error (RMSE)*

$$RMSE = \sqrt{RMSE}$$

- *Mean Absolute Percentage Error* (MAPE)

$$\text{MAPE} = \frac{\sum_{t=1}^T |\hat{e}_{it}/y_t|}{T}$$

- *Mean Square Percentage Error* (MSPE)

$$\text{MSPE} = \frac{\sum_{t=1}^T \left(\frac{\hat{e}_{it}}{y_t}\right)^2}{T}$$

- *Root Mean Square Percentage Error* (RMSPE)

$$\text{RMSPE} = \sqrt{\text{MSPE}}$$

O problema de *data snooping* é inevitável em análise de séries temporais pelo fato de se trabalhar com apenas uma série histórica para estimar o modelo de previsão. Apesar de ser um problema geral e reconhecido por pesquisadores, ainda rotineiramente utilizam-se as abordagens tradicionais. Leamer (1978, 1983) foi um dos primeiros a apontar tais problemas e indicar as fragilidades dos métodos tradicionais. Outros trabalhos relevantes incluem os de Mayer (1980), Miller (1981), Cox (1982), Lovell (1983). Lo e McKinley (1990) chamaram a atenção deste fato para uma ampla audiência e de forma bem documentada.

Nenhuma desses trabalhos, porém, resultou em um método rigoroso para avaliar se um modelo, de fato, possuía melhor poder preditivo do que outros, levando em conta os efeitos de *data snooping*. Em 1995, Mariano e Diebold propuseram um método formal para solucionar este problema, mas considerando apenas dois conjuntos de modelos, o qual será discutido a seguir.

2.2. O Método de Diebold e Mariano

Para cada período t e para um modelo i , seja uma função de perda $g(y_t, \hat{y}_{it})$, que, em geral, está associada diretamente ao erro de previsão, ou seja:

$$g(y_t, \hat{y}_{it}) = g(e_{it})$$

A hipótese nula do método proposto por Diebold e Mariano (1995) é:

$$H_0: E[g(e_{it})] = E[g(e_{jt})],$$

ou seja, a função de perda dos dois modelos que geram as previsões \hat{y}_{it} e \hat{y}_{jt} não seria estatisticamente diferente.

Fazendo $d_t = [g(e_{it}) - g(e_{jt})]$, onde a d_t é a perda diferencial amostral, a hipótese nula é reescrita como:

$$H_0: E[d_t] = 0$$

As hipóteses alternativas são dadas por duas situações:

$$H_a: E[d_t] > 0, \text{ onde o modelo } j \text{ possui melhor poder preditivo que o modelo } i$$

$$H_a: E[d_t] < 0, \text{ onde o modelo } i \text{ possui melhor poder preditivo que o modelo } j$$

Seja $\bar{d} = \frac{\sum_{t=1}^T d_t}{T}$ a perda média de previsão amostral. A estatística do teste é de Diebold

e Mariano (1995) é dada por:

$$S = \frac{\bar{d}}{\sqrt{\widehat{LRV}_d}},$$

onde \widehat{LRV}_d é um estimador consistente da variância assintótica de $d\sqrt{T}$. Diebold e Mariano (1995) demonstram que:

$$S \sim N(0,1)$$

Portanto, utilizando testes usuais da normal padrão, pode-se determinar, entre dois modelos, o que apresenta melhor acuracidade de previsão.

2.3. Model Confidence Set (MCS)

O objetivo do *Model Confidence Set* (MCS), introduzido por Hansen, Lunde e Nason (2011), é determinar o conjunto de modelos M^* , que contenha o(s) melhor(es) modelo(s) de uma coleção de modelos M^0 , em que o conceito de “melhor” é definido a partir de um critério associado à performance de previsão. O MCS estima um conjunto \widehat{M}^* , que é o conjunto que contém os melhores modelos para um dado nível descritivo.

Uma contribuição importante do MCS é que esta abordagem reconhece as limitações dos dados e corrige efeitos de *data snooping*. Dados com mesma capacidade informacional resultam em um \widehat{M}^* que contém apenas um modelo. Dados com menor capacidade informacional resultam em um conjunto de modelos com performance de previsão equiparáveis, a um dado nível de significância. Portanto, o MCS difere dos métodos de seleção de modelos convencionais, que determinam apenas um modelo como o melhor entre todos os ajustados, com base em apenas um critério, independentemente da natureza dos dados.

O método de seleção pelo MCS é baseado em um teste de equivalência, δ_M e uma regra de eliminação e_M . O teste de equivalência é aplicado para o conjunto $M = M^0$. Se δ_M é rejeitado, então há evidência de que os modelos não apresentam o mesmo poder preditivo e e_M é utilizada para eliminar os modelos com baixa performance de previsão. Esse procedimento é repetido até que δ_M é aceito e o \widehat{M}^* é definido para um conjunto dos melhores modelos. Utilizando um nível descritivo α em todos os testes, o método assegura que $\lim_{n \rightarrow \infty} (M^* \subset \widehat{M}^*_{1-\alpha}) \geq 1 - \alpha$. Quando \widehat{M}^* contém apenas um modelo, tem-se o caso forte em que $\lim_{n \rightarrow \infty} (M^* = \widehat{M}^*_{1-\alpha}) = 1$.

O MCS também gera níveis descritivos para cada modelo comparado. Para um dado modelo $i \in M^0$, o nível descritivo \hat{p}_i é o *threshold* para o qual $i \in \widehat{M}^*_{1-\alpha}$, se e somente se $\hat{p}_i > \alpha$. Dessa forma, um modelo com baixo nível descritivo o torna improvável de estar entre os melhores de acuracidade de previsão.

O algoritmo do MCS baseia-se nos seguintes passos: (i) inicialmente, fazer $M = M^0$. Testar a hipótese $H_{0,M}$ usando δ_M ao nível descritivo α . Se $H_{0,M}$ é aceita, então definimos $\widehat{M}^*_{1-\alpha} = M$, caso contrário, usamos e_M para eliminar o modelo de baixa performance e repete-se a rotina. Esse algoritmo foi implementado no software *Ox Metrics* por Doornik através do pacote MULCOM e que é aplicado no desenvolvimento do presente trabalho para a seleção dos melhores modelos de previsão de preço de alumínio.

2.2. Abordagens para Previsão de Preços de Commodities

2.2.1. ARFIMA

O modelo ARFIMA foi introduzido por Granger e Joyeux (1980), no sentido de captar efeito de memória longa através de uma diferenciação fracionária. A razão da escolha desse processo para modelar séries com memória longa é que o efeito do parâmetro d em observações distintas decai hiperbolicamente à medida que a distância aumenta, enquanto os efeitos de ϕ_p e de θ_q decaem exponencialmente. O parâmetro d deve ser escolhido para explicar a estrutura de correlações de ordens elevadas da série, enquanto ϕ_p e θ_q explicam as correlações de baixa ordem.

A expressão geral do modelo SARIMA (Box e Jenkins, 2008) é dada pela expressão abaixo, onde B representa o operador de defasagem e $\{Z_t\} \sim N(0, \sigma^2)$ é um ruído branco. Dessa forma, se a série X_t é fracionalmente diferenciada por d maior que $-0,5$ e menor que $0,5$ no componente $(1 - B^d)$, segue-se um modelo ARFIMA(p, d, q).

$$(1 - \phi_1 B^1 - \dots - \phi_p B^p) (1 - \Phi_1 B^s - \dots - \Phi_p B^{sP}) (1 - B^d) (1 - B^S)^D X_t = (1 + \theta_1 B^1 + \dots + \theta_q B^q) (1 + \Theta_1 B^s + \dots + \Theta_Q B^{sQ}) Z_t$$

2.2.4 Modelo Estrutural

Formalmente proposto por Harvey (1989), o modelo estrutural modela uma série temporal em função de seus componentes não observáveis: tendência; sazonalidade; componente cíclico, segundo um abordagem linear. A denominação estrutural decorre do fato de se buscar uma modelagem por meio de componentes com uma clara interpretação da realidade.

O modelo geral linear aditivo é expresso por

$$X_t = \mu_t + \gamma_t + \omega_t + Z_t, \tag{3}$$

onde μ_t , γ_t , ω_t são os componentes estocásticos de tendência, sazonalidade e cíclica e Z_t é um ruído branco, conforme descritos na seção 2.2.1. Os componentes μ_t , γ_t , ω_t seguem as leis de formação abaixo. Os parâmetros a serem estimados são $\sigma_v^2, \sigma_\eta^2, \sigma_\phi^2, \sigma_\psi^2, \sigma_\xi^2$. O componente sazonal requer geralmente $(s-1)$ equações de estado, onde s é o período sazonal; no caso abaixo, consideramos $s = 4$.

(i) Tendência

$$\mu_t = \mu_{t-1} + \beta_t + v_t, v_t \sim NI(0, \sigma_v^2)$$

$$\beta_t = \beta_{t-1} + \eta_t, \eta_t \sim NI(0, \sigma_\eta^2)$$

(ii) Sazonalidade

$$\gamma_{1t} = -\gamma_{1t-1} - \gamma_{2t} - \gamma_{3t} + \phi_t, \phi_t \sim NI(0, \sigma_\phi^2)$$

$$\gamma_{2t} = \gamma_{2t-1}$$

$$\gamma_{3t} = \gamma_{3t-1}$$

(iii) Ciclo

$$\omega_t = \lambda_t \psi_t, \psi_t \sim NI(0, \sigma_\psi^2)$$

$$\psi_t = \psi_{t-1} + \xi_t, \xi_t \sim NI(0, \sigma_\xi^2)$$

2.2.5 Modelo de Mudança de Regime

O modelo de mudança de regime foi proposto por Hamilton (1994) para explicar a dinâmica de evolução do PIB norte-americano. O modelo de mudança de regime é uma abordagem não linear e considera que a série é governada por processos auto-regressivos distintos.

No caso de um modelo com dois regimes, X_t seguem os seguintes processos:

$$\begin{aligned} X_t &= \mu_1 + \rho_1 X_{t-1} + Z_{1t}, \text{ para regime 1} \\ X_t &= \mu_2 + \rho_2 X_{t-1} + Z_{2t}, \text{ para regime 2} \end{aligned}$$

onde $\{Z_{1t}\} \sim N(0, \sigma^2)$ e $\{Z_{2t}\} \sim N(0, \sigma^2)$ são ruídos brancos.

Não se conhece o processo que rege X_t , mas assume-se que existe uma matriz de probabilidades que governa a mudança de regime, dada por:

$$P = \begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix},$$

onde p_{ij} é a probabilidade de X_t passar para o regime i , dado que está no regime j .

3. Série de Preços de Alumínio e relação com Preço de Petróleo Brent

O conjunto de dados utilizados consiste na série mensal de preço à vista de alumínio, de janeiro de 1988 a março de 2012. A série foi obtida a partir dos dados diários de fechamento de preço de venda de alumínio à vista, diretamente da *London Metal Exchange*, desde 2 de janeiro de 1980 até 30 de abril de 2012, durante os dias úteis de funcionamento da LME.

A série de preço de alumínio está apresentada na Figura 1, onde se observa um pico de preço de US\$ 3645/t em junho de 1988. Entre 1990 e 2005, os preços oscilaram em torno de US\$ 2500/t, notando-se um aumento significativo até meados de 2008, principalmente em função da demanda da China. A queda do preço do alumínio de cerca de US\$ 3.071 por tonelada em julho de 2008 para \$1.330 por tonelada em fevereiro de 2009 é explicada pela crise financeira global de 2008/09. Observa-se uma recuperação do preço até o primeiro trimestre de 2011, quando os efeitos da crise da Europa, associados a uma crescimento menor da demanda China (em torno de 8% a 9% comparado a uma taxa acima de 10% em períodos anteriores) levaram a uma nova queda de preços em um patamar que permanece em torno de US\$ 2.000 por tonelada.

A aplicação dos testes de raiz unitária indica que a série de preço de alumínio não é estacionária a 5% tanto pelo ADF como pelo KPSS, pois há aceitação da hipótese nula do teste ADF de que a série não é estacionária (possui raiz unitária) e rejeição da hipótese nula do KPSS de estacionariedade, conforme indicado na Tabela 1.

Isso significa que os preços de alumínio apresentam tendência e, portanto, para as abordagens ARFIMA e de mudança de regime, será necessário fazer a diferenciação da série, antes de identificar o melhor modelo ajustado. A Tabela 2 mostra o teste ADF com a série em primeira diferença – a estatística t é -14,651, bem acima do valor crítico de -3,455 para 1% de nível descritivo, indicando que a série torna-se estacionária.

**Figura 1a - Preço de alumínio (cash - US\$/t)
Jan/1980 – Abr/2012**



**Figura 1a - Log-retornos de alumínio
Jan/1980 – Abr/2012**

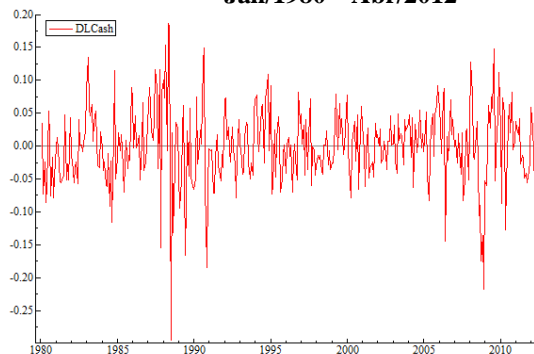


Figura 2 - Preço de alumínio (cash - US\$/t), petróleo Brent (US\$/bbl) e câmbio (USD/GBP)

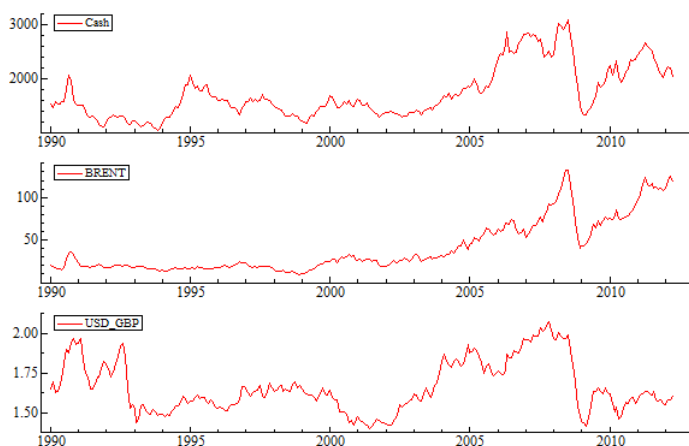


Tabela 1 - Resultados dos Testes de Raiz Unitária - ADF e KPSS

	Teste	Estatística observada	Nível Descritivo
Preço alumínio (US\$/t)	ADF	-2,456 (estatística t)	0,1274
	KPSS	0,635 (estatística LM)	-
Câmbio (US\$/£)	ADF	-3,102 (estatística t)	0,0275
	KPSS	0,181 (estatística LM)	-
Preço petróleo (US\$/barril)	ADF	-0,657 (estatística t)	0,8541
	KPSS	1,573 (estatística LM)	-

Nota: ADF - t crítico de -3,453 a 1% nível descritivo, -2,871 a 5% e -2,572 a 10%
KPSS - t crítico de 0,739 a 1% nível descritivo, 0,463 a 5% e 0,347 a 10%

Tabela 2 – Teste ADF para a Série de Preço de Alumínio em Primeira Diferença

	t-Statistic	Prob.
Augmented Dickey-Fuller test statistic	-14.651	0.0000
Test critical values:		
1% level	-3.455	
5% level	-2.872	
10% level	-2.573	

A Figura 2 mostra também a série da taxa de câmbio em termos de dólar norte-americano por libra esterlina e de preços de petróleo Brent desde janeiro de 1990 a abril de

2012, uma vez que são variáveis que influenciam as margens da indústria de alumínio. O câmbio utilizado foi a libra esterlina por dólar norte-americano porque corresponde à única taxa continuamente cotada para fechamentos de contratos de alumínio, desde que foram introduzidos pela LME. A série de câmbio mostra uma forte desvalorização do dólar no início dos anos 90, seguido de período relativamente estável até 2005, apreciação e posterior queda em função da crise de 2008/09. Sua recuperação não volta aos níveis de 2006 a meados de 2008. O preço de petróleo apresenta contínuo aumento a partir de 2009, atingindo US\$ 125 por barril em março de 2012, tendo como um dos fatores importantes o agravamento do contexto político no Oriente Médio. Conforme indicado na Tabela 1, a série de câmbio é estacionária a 5% e a série de preço de petróleo não é estacionária nem a 10% de nível descritivo.

Foi realizado o teste de Engle e Granger a fim de determinar se a série de preço de alumínio apresenta uma relação de longo prazo com taxa de câmbio (US\$/£) e com preço de petróleo. Para isso, foi realizada inicialmente uma regressão da série de preço de alumínio com as outras duas. Com base nos resíduos obtidos, foi feito o teste de cointegração, utilizando os valores críticos de McKinnon. As Tabelas 3a e 3b mostram as regressões do preço do alumínio contra câmbio e preço de petróleo, respectivamente. A Tabela 4 mostra o resultado do teste ADF dos resíduos obtidos das regressões.

Tabela 3a - Regressão do preço de alumínio contra taxa de câmbio (US\$/£)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1078,593	264,5168	-4,077596	0,000
USD_GBP	1711,437	158,1718	10,82012	0,000

Tabela 3b - Regressão do preço de alumínio contra preço de petróleo

Variável	Coeficiente	Erro-padrão	Estatística-t	Prob.
C	1336,300	35,43407	37,71230	0,0000
BRENT	11,30267	0,727477	15,53680	0,0000

Tabela 4 - Teste ADF dos resíduos das regressões

Regressão (y vs x)	Estatística-t	Prob.*
Preço de alumínio vs câmbio	-2,642	0,086
Preço de alumínio vs preço de petróleo	-2,960	0,004

Comparando as estatísticas t com os valores críticos de McKinnon para cointegração do teste de Engle e Granger, quais sejam, -3,434 a 1%; -2,862 a 5% e -2,57 a 10%, conclui-se que há uma relação de longo prazo entre preço de alumínio e preço de petróleo a 5% de nível descritivo, mas não entre preço de alumínio e câmbio.

Como extensão do trabalho, é sugerido um modelo VAR/VEC, que pode ser refinado com inclusão de mudança de regime, dado o impacto que a volatilidade de mercado e de choques econômicos causam nos preços de ambas *commodities*.

O período considerado para previsão fora da amostra foi de 60 meses, de maio de 2007 a abril de 2012. Foi utilizado o OxMetrics para estimação dos modelos e o pacote MULCOM, também do OxMetrics, para a aplicação do MCS.

4. Modelos Desenvolvidos para Previsão de Preços de Alumínio

4.1. ARFIMA

As Tabelas 5a e 5b mostram os resultados da estimação e estatísticas de teste do modelo ARFIMA. Todos os coeficientes foram significativos a um nível descritivo de 5%. No entanto, observou-se correlação serial e efeitos de heterocedasticidade nos resíduos a partir da quinta defasagem, sugerindo que modelos de mudança de regime, estrutural ou de volatilidade possam ser mais adequados para os dados em questão.

De fato, a partir do estabelecimento da LME como referência para preços e comercialização de contratos futuros de alumínio, o mercado global de alumínio passou a ser visto como uma alternativa de investimento financeiro pelos diversos agentes de mercado. Investidores acompanham de perto os desenvolvimentos dos mercados de commodities, bem como mercados financeiros. Assim, a negociação no mercado global de alumínio tende a seguir padrões similares aos mercados financeiros.

Os preços de ativos financeiros usualmente apresentam variância dependente do tempo e os investidores precisam projetar a volatilidade desses ativos para tomar posições no mercado. O fato de que os mercados de commodities também são utilizados como especulação e *hedging* torna relevante a adotar outras abordagens, incluindo modelos de volatilidade. Neste contexto, optou-se pela utilização de modelos de mudança de regime e estrutural, cujos resultados serão discutidos a seguir.

Tabela 5a - Modelo ARFIMA: Resultados da Estimação

	1 mês à frente			3 meses à frente			6 meses à frente		
	Coefficient	Std. Error	t-Statistic	Coefficient	Std. Error	t-Statistic	Coefficient	Std. Error	t-Statistic
d	0.264	0.069	3.81	0.263	0.069	3.80	0.263	0.069	3.82
AR(1)	0.922	0.035	26.70	0.922	0.034	26.90	0.922	0.034	27.10
Constant	7.413	0.177	41.80	7.412	0.177	41.80	7.407	0.178	41.60

	12 meses à frente			24 meses à frente		
	Coefficient	Std. Error	t-Statistic	Coefficient	Std. Error	t-Statistic
d	0.258	0.069	3.74	0.260	0.069	3.77
AR(1)	0.927	0.034	27.30	0.924	0.034	27.00
Constant	7.423	0.184	40.30	7.403	0.182	40.60

Tabela 5b - Modelo ARFIMA: Estatísticas de teste

Horizonte (meses à frente)					
	1	3	6	12	24
log-likelihood	558.79	554.97	550.05	538.89	521.28
AIC	-2.88	-2.88	-2.87	-2.87	-2.86
Q(5)	8.6868	8.6325	8.8704	8.6765 [0.0339]	10.527 [0.0146]
ARCH (lag 5)	13.011	12.980	12.898	12.204 [0.0000]	12.589 [0.0000]
	[0.0000]	[0.0000]	[0.0000]		

4.2. Modelo Estrutural

A Tabela 6 mostra os resultados da estimação do modelo estrutural, realizados com base no logaritmo natural dos preços do alumínio. O modelo incluiu componentes de nível, tendência, sazonalidade e ciclos de 5, 10 e 20 anos. Os resultados indicam que a variância do nível é a mais relevante para explicar a variabilidade dos dados para 1, 3, 12 e 24 meses à frente, seguida pela variância da tendência. Para 6 meses à frente, o componente cíclico é o mais significativo, seguido pela variância da tendência e do nível.

Tabela 6 – Modelo Estrutural sem AR(1): Variâncias(q-ratio)

Horizonte	Nível	Tendência	Sazonal	Irregular
1 mês	0.001 (1.000)	9.62e-5 (0.065)	0.000 (0.000)	9.15e-6 (0.006)
6 meses	1.98e-5 (0.012)	3.70e-5 (0.023)	0.000 (0.000)	0.000 (0.000)
12 meses	0.002 (1.000)	0.001 (0.085)	0.000 (0.000)	0.000 (0.000)
24 meses	0.002 (1.000)	0.002 (0.093)	0.000 (0.000)	0.000 (0.000)
<i>Ciclos - Variâncias(q-ratio)</i>				
	Cycle 1	Cycle 2	Cycle 3	
1 mês	7.37e-5 (0.051)	9.65e-5(0.066)	1.34e-6(0.001)	
6 meses	1.26e-6 (0.001)	0.002 (1.000)	8.09e-7 (0.001)	
12 meses	3.80e-8 (2.12e-5)	9.15e-7 (0.001)	4.27e-8 (2.38e-5)	
24 meses	2.74e-10 (1.57e-7)	1.35e-8 (7.77e-6)	0.000 (0.000)	

4.3. Modelo de Mudança de Regime Markoviana

Modelagem por mudança de regime requer que a série de dados seja estacionária. Dessa forma, o ajuste foi realizado com base nos log-retornos do preço de alumínio, que se mostrou uma série estacionária, conforme demonstrado no item 3. Utilizou-se mudança na variância em dois regimes, onde o log-retorno com uma defasagem e o componente sazonal foram incluídos como variáveis independentes, mas sem operar em mudança de regime. Os coeficientes de ambos regressores foram significativos a 5% de nível descritivo. As matrizes de transição mostram baixa probabilidade de mudança do regime 0 (preços desfavoráveis) para o regime 1 (preços favoráveis) e vice-versa, enquanto indicam elevada probabilidade de manutenção dos preços no regime corrente. As Tabelas 7a e 7b mostram os resultados das estimações e principais estatísticas de teste. A Figura 3 mostra que o regime de preços desfavoráveis ocorreu principalmente no final da década de 90 (com a sobre-oferta de alumínio pela antiga União Soviética) e em 2008/09, decorrente da crise financeira internacional.


Tabela 7a - Modelo de Mudança de Regime Markoviana: Resultados da Estimação

	1 mês à frente			3 meses à frente			6 meses à frente		
	Coef.	Std. Error	t-stat	Coef.	Std. Error	t-stat	Coef.	Std. Error	t-stat
DLCash_1	0.250	0.050	4.990	0.250	0.050	4.990	0.250	0.050	4.990
Cseasonal	0.021	0.008	2.580	0.021	0.008	2.580	0.021	0.008	2.580
sigma(0)	0.093	0.009	10.500	0.093	0.009	10.500	0.093	0.009	10.500
sigma(1)	0.040	0.002	18.000	0.040	0.002	18.000	0.040	0.002	18.000
p_{00}	0.931	0.040	23.400	0.931	0.040	23.400	0.931	0.040	23.400
p_{01}	0.018	0.012	1.550	0.018	0.012	1.550	0.018	0.012	1.550
Transition Matrix		Reg. 0, t	Reg. 1, t		Reg. 0, t	Reg. 1, t		Reg. 0, t	Reg. 1, t
	Reg. 0, t+1	0.931	0.018	Reg. 0, t+1	0.931	0.018	Reg. 0, t+1	0.931	0.018
	Reg. 1, t+1	0.069	0.982	Reg. 1, t+1	0.069	0.982	Reg. 1, t+1	0.069	0.982
	12 meses à frente			24 meses à frente					
	Coef.	Std. Error	t-stat	Coef.	Std. Error	t-stat			
DLCash_1	0.250	0.050	4.990	0.250	0.050	4.990			
Cseasonal	0.021	0.008	2.580	0.021	0.008	2.580			
sigma(0)	0.093	0.009	10.500	0.093	0.009	10.500			
sigma(1)	0.040	0.002	18.000	0.040	0.002	18.000			
p_{00}	0.931	0.040	23.400	0.931	0.040	23.400			
p_{01}	0.018	0.012	1.550	0.018	0.012	1.550			
Transition Matrix		Reg. 0, t	Reg. 1, t		Reg. 0, t	Reg. 1, t			
	Reg. 0, t+1	0.931	0.018	Reg. 0, t+1	0.931	0.018			
	Reg. 1, t+1	0.069	0.982	Reg. 1, t+1	0.069	0.982			

Tabela 7b - Modelo de Mudança de Regime: Estatísticas de teste

Horizonte (meses à frente)	1	3	6	12	24
log-likelihood	593.83	599.67	593.83	582.01	563.23
AIC	-3.09	-3.10	-3.09	-3.08	-3.08
Q(10)	10.655 [0.3001]	10.668 [0.2992]	11.087 [0.2698]	10.871 [0.2846]	11.442 [0.2466]
Q(36)	37.353 [0.3615]	37.082 [0.3731]	37.046 [0.3747]	37.830 [0.3413]	39.153 [0.2887]
Q ² (10)	5.8435 [0.8282]	5.8816 [0.8251]	6.1097 [0.8060]	6.4672 [0.7746]	6.9031 [0.7346]
Q ² (36)	33.595 [0.5835]	33.031 [0.6105]	33.146 [0.6051]	32.947 [0.6146]	32.003 [0.6592]

Figura 3 – Modelo de Mudança de Regime



5. Seleção dos Modelos de Previsão por meio do Model Confidence Set

Para a aplicação do MCS, foram consideradas 60 previsões de maio de 2005 a abril de 2012, com um nível descritivo de 0,1 para comparação múltipla de modelos. Os resultados da comparação dos modelos pelo MCS estão indicados na Tabela 8.

Tabela 8 - Resultados do Model Confidence Set (p-value)

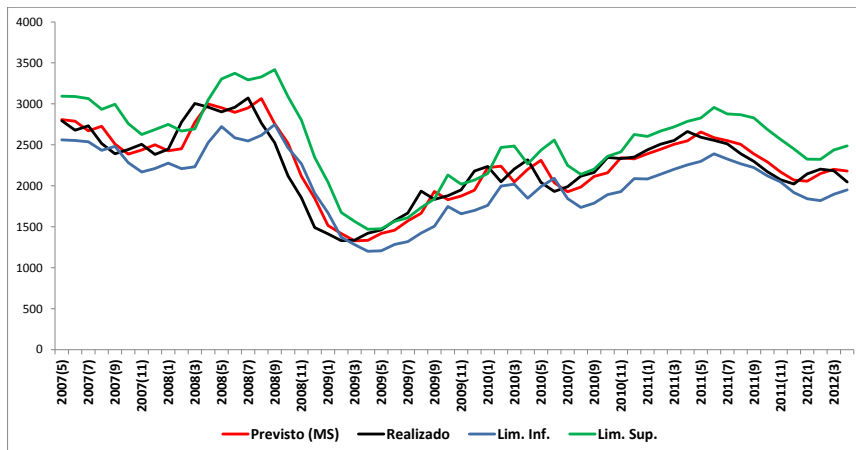
Meses à frente		1	3	6	12	24
Mudança de Regime	p-value	1.0000 *	1.0000 *	1.0000 *	1.0000 *	1.0000 *
	EQM (*10 ³)	18,917	21,612	21,701	21,700	21,642
ARFIMA	p-value	0.7573 *	0.0066	0.0025	0.0001	0.0000
	EQM (*10 ³)	19,146	94,096	253,864	343,589	446,521
Estrutural	p-value	0.0328	0.0021	0.0004	0.0000	0.0000
	EQM (*10 ³)	23,301	150,025	497,898	1,178,463	4,109,892

Os resultados mostram que o modelo de mudança de mudança de regime apresentou melhor acuracidade de previsão em todos os horizontes de tempo estimados. Para previsão um mês à frente, o modelo ARFIMA apresentou resultados equiparáveis ao de mudança de regime para nível descritivo de 0,1. O método tradicional, com base no erro quadrático médio, apontou resultados direcionalmente em linha com os do MCS. No entanto, para um mês à frente, não possui poder de informação para caracterizar os modelos de regime e ARFIMA como tendo previsão similares ao nível descritivo de 0,1.

A Figura 4 mostra os preços de alumínio realizados e os previstos pelo modelo de mudança de regime, para 60 meses fora da amostra, calculados ponto a ponto por meio de

rolling regressions para 24 meses à frente, de maio de 2007 a abril de 2012. Os resultados demonstram que 73% (correspondente a 44 dos 60 meses) dos preços observados ficaram dentro do intervalo de confiança, indicando boa qualidade do modelo estimado.

Figura 10 – Projeção de Preço de Alumínio pelo Modelo de Mudança de Regime para um intervalo de confiança com ± 2 erros-padrão (~95% confiança)



6. Conclusões

A contribuição do MCS em corrigir viés de *data snooping* da amostra, através de *bootstrap*, permite a obtenção de um conjunto de modelos equiparáveis em previsão para um dado nível descritivo. Caso todos os dados sejam tenham capacidade informacional, o MCS tende a gerar um modelo apenas como *benchmarking*.

Os resultados do MCS indicaram que o modelo de mudança de regime markoviana é o *benchmarking*, para 1, 3, 6, 12 e 24 meses à frente, com base em 60 previsões fora da amostra, de maio de 2007 a abril de 2012, por meio de *rolling regressions*. 73% dos preços observados ficaram dentro do intervalo de confiança, indicando a boa qualidade do modelo estimado. Os resultados podem sugerir que a capacidade do modelo de mudança de regime de captar ciclos resultaria em uma melhor acuracidade de previsão.

Para previsão um mês à frente, o modelo ARFIMA apresentou resultados equiparáveis ao de mudança de regime para nível descritivo de 0,1. O método tradicional, com base no erro quadrático médio, apontou resultados direcionalmente em linha com os do MCS. No entanto, para um mês à frente, não possui poder informacional para indicar os modelos de regime e ARFIMA como tendo previsão similares para um determinado descritivo. Dessa forma, obtém-se um intervalo de previsão de preços de acuracidade superior aos indicados pelos métodos tradicionais.

Adicionalmente, para um nível descritivo de 5%, determinou-se que preço de petróleo pode ter uma relação de longo prazo com preço de alumínio. Como extensão do trabalho, é sugerido um modelo VAR/VEC para previsão de preços, com inclusão de mudança de regime. Vale ressaltar que modelos de volatilidade tradicionais da família GARCH também apresentam limitações de poder preditivo sob quebra estrutural (Hwang e Valls Pereira, 2006). Assim, estudos futuros indicariam a aplicação do MCS para previsão de preços de commodities, incluindo VAR/VEC e modelos de volatilidade com mudança de regime.

7. Referências Bibliográficas

- ADAMS, F., VIAL, J. (1988), Explaining Recent Metals Price Swings. *Resources Policy*, 14:85-96
- ANDREWS, D. (1993), “Tests for Parameter Instability and Structural Change with Unkown Change Point”, *Econometrica*, 71, 2:579-625
- BARKOULAS, J., LABYS, W., ONOCHIE, J. (1997), Fractional Dynamics in International Commodity Prices. *Journal of Future Markets*. 17:2:161-189
- BAXTER, M., AND R. G. KING (1999) “Measuring Business Cycles: Approximate Bandpass Filters for Economic Time Series,” *Review of Economics and Statistics*, 81, 575–593
- BOX, G., JENKINS, G., REINSEL, G. (2008), *Time Series Analysis*, Wiley, 2008
- CASHIN, P., McDERMOTT, C. (2002) , “Long Run Behavior of Commodity Prices: Small Trends and Big Variability”, *IMF Staff Papers*, 49, 2:175-199
- CHEN, Y., ROGOFF, K., ROSSI, B. (2010). Can Exchange Rates Forecast Commodity Prices, *The Quarterly Journal of Economics*, August 2010, 1145-1193
- COMMANDEUR, J., KOOPMAN, S. *State Space Time Series Analysis*, Oxford University Press, 2007
- DECOSTER, G., LABYS, W., MITCHELL, D. (1992) Evidence of Chaos in Commodity Futures Prices. *The Journal of Futures Markets*, 12, 3:291-305
- DIEBOLD, F. X., AND R. S. MARIANO (1995): “Comparing Predictive Accuracy,” *Journal of Business & Economic Statistics*, 13, 253–263
- CLEMENTS, K., FRY, R. (2008). Commodity currencies and currency commodities, *Resources Policy* 33 (2008) 55–73
- COX, D. R. (1982): "Statistical Significance Tests," *British Journal of Clinical Pharmacology*, 14, 325-331.
- DIEBOLD, F, MARIANO, R. S. (1995). Comparing Predictive Accuracy, *Journal of Business & Economic Statistics*, 13, 253-263
- ENGLE, R. F., AND S. J. BROWN (1985): “Model Selection for Forecasting,” *Journal of Computation in Statistics*, 51, 341–365
- GONÇALVES, S., WHITE, H. (2005), Bootstrap Standard Error Estimates for Linear Regression, *Journal of the American Statistical Association*, 100, 970–979
- GRANGER, C. W. J., KING, M. L., WHITE, H. (1995). Comments on Testing Economic Theories and the Use of Model Selection Criteria, *Journal of Econometrics*, 67, 173–187

- HAMILTON, J. Time Series Analysis (1994), Princeton University Press
- HANSEN, P., LUNDE, A., NASON, J. (2011), The Model Confidence Set, *Econometrica*, Vol. 79, N. 2, March, 2011, 453-497
- HANSEN, P. R. (2005): "A Test for Superior Predictive Ability," *Journal of Business & Economic Statistics*, 23, 365–380
- HARVEY, A. (1989), *Forecasting, Structural Time Series Models and the Kalman Filter*. Cambridge University Press
- HARVEY, A. (1994), *Time Series Models*, 2nd edition, Cambridge, The MIT Press
- HARVEY, A. (1989), *The Econometric Analysis of Time Series*, The MIT Press
- HARVEY, A., TODD, P. (1983), Forecasting Economic Time Series with Structural and Box-Jenkins Models: A Case Study, *Journal of Business and Economics Statistics*, 1:299-315
- HWANG, S, & VALLS PEREIRA, P. L. Small sample properties of GARCH estimates and persistence. *European Journal of Finance*, 12(6-7), p. 473-494, Oct, 2006.
- LABYS, W. (2008) *Modeling and Forecasting Primary Commodity Prices*, Ashgate Publishing, UK
- LABYS, W. (1999), *Modeling Mineral and Energy Markets*. Boston, Kluwer Publishing Company
- LABYS, W., KOUASSI, E., TERRAZA, M. (2000), Short-Term Cycles in Primary Commodity Markets, *Journal of Developing Economics*, 38, 3:330-342
- LABYS, W., NADIRI, M., DEL ARCO, J., *Commodity Markets and the Latin American Development: A Modeling Approach*, New York, National Bureau of Economic Research, Inc.
- LEAMER, E. (1978); *Specification Searches: Ad Hoc Inference with Nonexperimental Data*. New York: Wiley.
- LEE, K., NI, S. (2002), On the dynamic effects of oil price shocks: a study using industry level data, *Journal of Monetary Economics* 49 (2002) 823–852
- LO, A., AND C. MACKINLEY (1990): "Data Snooping Biases in Tests of Financial Asset Pricing Models," *Review of Financial Studies*, 3, 431-468.
- LOVELL, M. C. (1983): "Data Mining," *Review of Economics and Statistics*, 45, 1-12.
- MAYER, T. (1980): "Economics as a Hard Science: Realistic Goal or Wishful Thinking?" *Economic Inquiry*, 18, 165-178.
- MILLER, JR., R. G. (1981): *Simultaneous Statistical Inference*. New York: Springer-Verlag.
- PERRON, P. (2006). *Dealing with Structural Breaks*. *Handbook of Econometrics*, Vol.1,

Econometric Theory, New York, Palgrave

PERRON, P. (1989). The Great Crash, the Oil Price Shock and the Unit Root Hypothesis, *Econometrica*, 55:277-309

REINHARD, C., WICKHAM, P. (1994), Commodity Prices: Cyclical Weakness or Secular Decline?, Working Paper, International Monetary Fund, Washington, DC

ROMANO, J. P., AND M. WOLF (2005): “Stepwise Multiple Testing as Formalized Data Snooping,” *Econometrica*, 73, 1237–1282

SCHAEFFER, P. (2008). Commodity Modeling and Pricing, Wiley

STOFFER, D., SCHUMWAY, R., (2006). Time Series Analysis and Its Applications, Springer, 2006

STOCK, J. H., AND M. W. WATSON (1999): “Forecasting Inflation,” *Journal of Monetary Economics*, 44, 293–335

WEST, K. D. (1996): “Asymptotic Inference About Predictive Ability,” *Econometrica*, 64, 1067–1084

WEST, K. D., AND D. CHO (1995): “The Predictive Ability of Several Models of Exchange Rate Volatility,” *Journal of Econometrics*, 69, 367–391

WEST, K. D., AND M. W. MCCRACKEN (1998): “Regression Based Tests of Predictive Ability,” *International Economic Review*, 39, 817–840

WHITE, H. (1994): Estimation, Inference and Specification Analysis. Cambridge: Cambridge University Press

WHITE, H. (2000) Reality Check for Data Snooping, *Econometrica*, Vol. 68, No. 5 (Sep., 2000), pp. 1097-1126

ZIVOT, E., ANDREWS, D. (1992), Further Evidence of the Great Crash, the Oil Price Shock and the Unit Root Hypothesis. *Journal of Business and Economics Statistics*, 10:271-287