

5. Resultados

5.1. Séries Log-preço

Para verificar se as séries logaritmo neperiano dos preços (log-preço) à vista e futuro e as séries logaritmo neperiano dos retornos (log-retorno) à vista e futuro do índice Dow Jones Industrial Average possuem raízes unitárias, rodamos um teste de Dickey-Fuller Aumentado. Os resultados das séries log-preço do índice futuro e à vista encontram-se a seguir:

Tabela 1 - Teste de Dickey-Fuller para série log-preço futuro

	Estatística t	P-valor
Teste ADF	0,9454	99,61%

Tabela 2 - Teste de Dickey-Fuller para série log-preço à vista

	Estatística t	P-valor
Teste ADF	0,8244	99,45%

Como podemos verificar, o p-valor do teste de Dickey-Fuller Aumentado para a série log-preço do índice futuro foi de 99,61%, o que indubitavelmente não rejeita a hipótese nula de raiz unitária, sendo assim, podemos afirmar que a série log-preço do índice futuro é não estacionária. O mesmo podemos afirmar da série log-preço do índice à vista, dado que apresentou um p-valor de 99,45% no teste de Dickey-Fuller Aumentado.

5.2. Séries Log-retorno

A seguir apresentamos os resultados dos testes de Dickey-Fuller Aumentado para as séries log-retorno dos índices futuro e à vista:

Tabela 3 - Teste de Dickey-Fuller para série log-retorno futuro

	Estatística t	P-valor
Teste ADF	44,7960	1,73%

Tabela 4 - Teste de Dickey-Fuller para série log-retorno à vista

	Estatística t	P-valor
Teste ADF	44,1200	0,19%

Como podemos verificar, o p-valor do teste de Dickey-Fuller Aumentado para a série log-retorno do índice futuro foi de 1,73%, o que implica na rejeição da hipótese nula de raiz unitária com um grau de confiança de 95%, sendo assim, podemos afirmar que a série log-retorno do índice futuro é estacionária. O mesmo podemos verificar para a série log-retorno do índice à vista, dado que apresentou um p-valor de 0,19% no teste de Dickey-Fuller Aumentado.

5.3. Co-integração por Engle-Granger

Em seguida, verificamos a existência de uma relação de co-integração entre as séries de log-preço dos índices futuro e à vista utilizando a metodologia de Duas Etapas de Engle-Granger. Assim sendo, rodamos uma regressão simples

utilizando o Modelo de Mínimos Quadrados Ordinários com o log-preço do índice à vista sendo a variável dependente e o log-preço do índice futuro sendo a variável independente. Os resultados encontram-se a seguir:

Tabela 5 - Regressão por OLS com log-preço à vista sendo a variável dependente

Dependent Variable: LNSPOTPRECO
Method: Least Squares
Date: 10/30/08 Time: 19:55
Sample: 1 7949
Included observations: 7949

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.0249	0.0023	-0.0160	0.9873
LNFUTPRECO	0.9992	0.0005	1958.2053	0
R-squared	0.9979	Mean dependent var		4.5260
Adjusted R-squared	0.9979	S.D. dependent var		0.0930
S.E. of regression	0.0042	Akaike info criterion		-8.0931
Sum squared resid	0.1422	Schwarz criterion		-8.0913
Log likelihood	32167.959	F-statistic		3834567.8
Durbin-Watson stat	0.0476	Prob(F-statistic)		0

Podemos verificar que o coeficiente angular log-preço do índice futuro tende a um (coeficiente=0,999) o que seria esperado numa relação de “lead-lag” onde o índice futuro antecipa os movimentos do índice à vista. Outro fator relevante que podemos evidenciar no resultado acima é o R^2 e o R^2 Ajustado com valores significantemente altos (ambos com 99,79%), o que demonstra que o índice futuro tem um grande grau de explicação sobre os movimentos do índice à vista.

Uma vez rodada a regressão, testamos seu resíduo para garantir que seja uma $I(0)$, ou seja, não possua raiz unitária. O resultado do teste de Dickey-Fuller Aumentado para o resíduo da regressão encontra-se a seguir:

Tabela 6 - Teste de Dickey-Fuller para a regressão com log-preço à vista sendo a variável dependente

	Estatística t	P-valor
Teste ADF	-2,0928	3,49%

Podemos verificar que o resíduo da regressão se trata de uma variável estacionária com um grau de confiança de 95%, dado que encontramos um p-valor de 3,49%, logo, podemos afirmar que há uma relação de co-integração entre as séries log-preço do índice futuro e à vista.

5.4. Testando a Teoria Inversa

Uma vez evidenciado que o índice futuro antecipa os movimentos do índice à vista, resolvemos testar a relação inversa, ou seja, verificar se existe algum grau de antecipação dos movimentos do índice futuro pelo índice à vista. Para tanto, refizemos a regressão simples utilizando o Modelo de Mínimos Quadrados Ordinários com o log-preço do índice futuro sendo a variável dependente e o log-preço do índice à vista sendo a variável independente. Os resultados encontram-se a seguir:

Tabela 7 - Regressão por OLS com log-preço futuro sendo a variável dependente

Dependent Variable: LNFUTPRECO

Method: Least Squares

Date: 12/05/08 Time: 19:07

Sample: 1 7949

Included observations: 7949

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.0094	0.0023	4.0735	0.0315
LNSPOTPRECO	0.9987	0.0005	1958.2053	0
R-squared	0.9979	Mean dependent var		4.5298
Adjusted R-squared	0.9979	S.D. dependent var		0.0930
S.E. of regression	0.0042	Akaike info criterion		-8.0935
Sum squared resid	0.1421	Schwarz criterion		-8.0918
Log likelihood	32169.685	F-statistic		3834567.8435
Durbin-Watson stat	0.0476	Prob(F-statistic)		0

Podemos verificar que o coeficiente angular log-preço do índice à vista tende a um (coeficiente=0,998) e obtivemos um R^2 e um R^2 Ajustado com valores significantemente altos (ambos com 99,79%), o que implica que o índice à vista tem um alto grau de explicação sobre os movimentos do índice futuro.

A seguir testamos o resíduo dessa regressão para verificar se é uma série estacionária e, assim, concluirmos a existência de uma relação de co-integração entre as séries log-preço do índice à vista e futuro. Os resultados do teste de Dickey-Fuller Aumentado encontram-se a seguir:

Tabela 8 - Teste de Dickey-Fuller para a regressão com log-preço futuro sendo a variável dependente

	Estatística t	P-valor
Teste ADF	-1,9902	4,46%

Podemos concluir observando os resultados que o resíduo da regressão é uma série estacionária com um grau de confiança de 95%, dado que encontramos um p-valor de 4,46%, o que implica na existência de uma relação de co-integração entre as séries log-preço do índice à vista e futuro.

5.5. Teste de Causalidade de Granger

O resultado exposto acima não era um resultado que esperávamos encontrar, no entanto, os resultados evidenciados são inegáveis. Assim sendo, optamos por rodar o Teste de Causalidade de Granger para verificar se de fato existe uma relação de causalidade bi-direcional entre o índice à vista e o índice futuro. Os resultados encontram-se a seguir:

Tabela 9 - Teste de Causalidade de Granger

Hipótese Nula	Estatística F	P-valor
Log-retorno à vista não causa log-retono futuro	15,4864	0,00%
Log-retorno futuro não causa log-retono à vista	5,0957	0,00%

Podemos concluir que a hipótese nula em ambos os casos foram rejeitadas com um grau de confiança de 99%, dado os p-valores tendendo a zero, ou seja, ficou evidenciado que tanto o índice futuro implica no índice à vista como o à vista implica no futuro. Uma possível explicação para esse resultado de causalidade bi-direcional seria que na verdade um terceiro fator exógeno a ambas as séries estariam causando os movimentos delas e pelo fato de ambas as séries se moverem simultaneamente respondendo a esse estímulo externo, ao analisarmos somente as duas séries e omitirmos o fator exógeno, encontramos um alto grau de causalidade bi-direcional.

5.6. Refazendo a Regressão por TSLS

Como os resultados apresentados anteriormente demonstraram haver uma relação de causalidade bi-direcional entre as séries log-preço do índice à vista e futuro, os resultados gerados pela regressão utilizando o Modelo dos Mínimos Quadrados Ordinários (OLS) ficam comprometidos, pois há um problema de simultaneidade entre as variáveis da regressão. Assim sendo, optamos por refazer a análise de estacionaridade dos resíduos da regressão utilizando o Modelo de Mínimos Quadrados em Dois Estágios (TSLS) que leva em consideração a simultaneidade das variáveis. O resultado da regressão encontra-se a seguir:

Tabela 10 - Regressão por Mínimos Quadrados em Dois Estágios

Dependent Variable: LNSPOTPRECO

Method: Two-Stage Least Squares

Date: 12/17/08 Time: 19:16

Sample: 1 7949

Included observations: 7949

Instrument list: LNSPOTPRECO LNFUTPRECO

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.0249	0.0023	-0.0160	0.9873
LNFUTPRECO	0.9992	0.0005	1958.2053	0
R-squared	0.9979	Mean dependent var		4.5260
Adjusted R-squared	0.9979	S.D. dependent var		0.0930
S.E. of regression	0.0042	Sum squared resid		0.1422
Durbin-Watson stat	0.0476	Second-stage SSR		0.1422

Assim como na regressão utilizando o Modelo de Mínimos Quadrados Ordinários, a regressão com o Modelo de Mínimos Quadrados em Dois Estágios apresentou o coeficiente angular log-preço do índice futuro tendendo a um (coeficiente = 0,999), o que é um resultado que deveríamos esperar caso haja uma relação de “lead-lag” entre as duas variáveis analisadas na regressão. E assim

como anteriormente, o R^2 e o R^2 Ajustado da nova regressão apresentada acima tem valores significantemente altos (ambos com 99,79%), o que implica que o índice futuro tem um grande grau de explicação sobre os movimentos do índice à vista.

Uma vez rodada a regressão, testamos seu resíduo para garantir que seja uma $I(0)$, ou seja, não possua raiz unitária. O resultado do teste de Dickey-Fuller Aumentado para o resíduo da regressão utilizando o Modelo de Mínimos Quadrados em Dois Estágios encontra-se a seguir:

Tabela 11 - Teste de Dickey-Fuller para o resíduo da regressão por TSLS

	Estatística t	P-valor
Teste ADF	-2,0928	3,49%

Podemos verificar que o resíduo da regressão utilizando o Modelo de Mínimos Quadrados em Dois Estágios se trata de uma variável estacionária com um grau de confiança de 95%, dado que encontramos um p-valor de 3,49%, logo, podemos afirmar que há uma relação de co-integração entre as séries log-preço do índice futuro e à vista.

5.7. Co-integração por Johansen

Outra metodologia de análise da relação de co-integração é o modelo de Johansen que utilizamos para verificar se existe uma relação de co-integração entre as séries log-preço do índice à vista e futuro. Os resultados do Teste de Johansen encontram-se a seguir:

Tabela 12 - Teste de Co-integração de Johansen

Sample (adjusted): 6 7949

Included observations: 7944 after adjustments

Trend assumption: No deterministic trend

Series: LNFUTPRECO LNSPOTPRECO

Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.1 Critical Value	Prob.**
None *	0.0011	11.5476	10.4746	0.0671
At most 1	0.0003	2.4349	2.9762	0.1401

Trace test indicates 1 cointegrating eqn(s) at the 0.1 level

* denotes rejection of the hypothesis at the 0.1 level

**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.1 Critical Value	Prob.**
None	0.0011	9.1127	9.4748	0.1150
At most 1	0.0003	2.4349	2.9762	0.1401

Max-eigenvalue test indicates no cointegration at the 0.1 level

* denotes rejection of the hypothesis at the 0.1 level

**MacKinnon-Haug-Michelis (1999) p-values

Podemos verificar pelos resultados acima que para um grau de confiança de 90%, confirma-se uma relação de co-integração entre as séries log-preço do índice à vista e futuro através do teste Trace com um p-valor de 6,71%. O teste Maximum Eigenvalue não confirma a existência de uma relação de co-integração entre as séries, todavia, isso ocorre com um valor muito próximo da confirmação, isto é, o p-valor encontrado no teste de Maximum Eigenvalue foi de 11,49%, o que por pouco também não confirma uma relação de co-integração com um grau de confiança de 90%.

5.8. Análise Intertemporal (VECM)

Uma vez que verificamos a relação de co-integração entre as séries do índice à vista e futuro, tanto pelo Método de Duas Etapas de Engle-Granger, como pelo Teste de Co-integração de Johansen, utilizamos o Modelo Vetorial de Correção de Erro para analisar a relação intertemporal entre as séries do índice à vista e futuro e assim, podermos verificar como cada série é influenciada pelo seu próprio resultado passado e pelo resultado passado da outra série. Rodamos o Modelo Vetorial de Correção de Erro para seis períodos passados, ou seja, até uma hora de defasagem e os resultados encontram-se a seguir:

Tabela 13 - Teste Vetorial de Correção de Erro

Vector Error Correction Estimates

Date: 12/17/08 Time: 19:02

Sample (adjusted): 8 7949

Included observations: 7942 after adjustments

Standard errors in () & t-statistics in []

Cointegrating Eq:	CointEq1	
LNSPOTPRECO(-1)	1	
LNFUTPRECO(-1)	-0.9994	
	0.0004	
	[-2668.05]	
Error Correction:	D(LNSPOTPRECO)	D(LNFUTPRECO)
CointEq1	0.0075	0.0119
	0.0081	0.0082
	[0.93418]	[1.46065]
D(LNSPOTPRECO(-1))	-0.0515	0.6989
	0.0478	0.0483
	[-1.0789]	[14.4621]
D(LNSPOTPRECO(-2))	-0.0600	0.5167
	0.0587	0.0594
	[-1.0232]	[8.7017]
D(LNSPOTPRECO(-3))	0.0391	0.4440
	0.0632	0.0640
	[0.6183]	[6.9402]
D(LNSPOTPRECO(-4))	-0.0481	0.2319
	0.0633	0.0641
	[-0.7595]	[3.6187]
D(LNSPOTPRECO(-5))	-0.1456	0.0445
	0.0587	0.0594
	[-2.4796]	[0.7493]
D(LNSPOTPRECO(-6))	-0.1621	-0.0409
	0.0478	0.0484
	[-3.3885]	[-0.8450]

Continuação da Tabela 13 - Teste Vetorial de Correção de Erro

D(LNFUTPRECO(-1))	-0.0076 0.0472 [-0.1616]	-0.7498 0.0478 [-15.6853]
D(LNFUTPRECO(-2))	0.0489 0.0581 [0.8424]	-0.5212 0.0588 [-8.8675]
D(LNFUTPRECO(-3))	-0.0787 0.0625 [-1.2595]	-0.4768 0.0633 [-7.5372]
D(LNFUTPRECO(-4))	0.1117 0.0625 [1.7875]	-0.1723 0.0632 [-2.7261]
D(LNFUTPRECO(-5))	0.1641 0.0579 [2.8354]	-0.0204 0.0585 [-0.3484]
D(LNFUTPRECO(-6))	0.1694 0.0467 [3.6283]	0.0416 0.0472 [0.8817]
R-squared	0.0131	0.0395
Adj. R-squared	0.0116	0.0380
Sum sq. resids	0.0748	0.0766
S.E. equation	0.0031	0.0031
F-statistic	8.7513	27.1403
Log likelihood	34686.8468	34593.4967
Akaike AIC	-8.7318	-8.7083
Schwarz SC	-8.7203	-8.6968
Mean dependent	-0.0355	-0.0358
S.D. dependent	0.0031	0.0032
Determinant resid covariance (dof adj.)		0.0000
Determinant resid covariance		0.0000
Log likelihood		80743.4001
Akaike information criterion		-20.3262
Schwarz criterion		-20.3016

Podemos verificar pelo resultado apresentado acima que a série do índice à vista influencia a série do índice futuro com até quatro níveis de defasagem, ou seja, com até quarenta minutos de defasagem, sendo que quanto maior o nível de defasagem, menor o grau da influência. A exceção ocorre com o período presente,

isto é, a série do índice à vista sem defasagem não influencia a série do índice futuro contemporânea.

Já a série do índice futuro influencia a série do índice à vista a partir de quatro níveis de defasagem até seis níveis, ou seja, a influência ocorre a partir de quarenta minutos até uma hora de defasagem que foi até onde fizemos o teste por se tratar de uma análise de alta frequência.

Apesar de o resultado parecer contraditório ao que propomos evidenciar neste trabalho, devemos observar que a estatística do R^2 e o R^2 ajustado da análise acima apresentaram valores muito baixos, o que compromete a acuracidade dos resultados inferidos.

5.9. Teste de Auto-correlação

Para verificar se existe auto-correlação dos erros, optamos por rodar um Teste de Heterocedasticidade de White, tanto para os resíduos da regressão utilizando o Modelo de Mínimos Quadrados Ordinários como para o resíduo da regressão utilizando o Modelo de Mínimos Quadrados em Dois Estágios. A seguir apresentamos os resultados do Teste de White para a regressão OLS e TSLS, respectivamente:

Tabela 14 - Teste de Heterocedasticidade de White para a regressão por OLS

White Heteroskedasticity Test:

F-statistic	762.2516	Prob. F(2,7946)	0.0000
Obs*R-squared	1279.5810	Prob. Chi-Square(2)	0

Tabela 15 - Teste de Heterocedasticidade de White para a regressão por TSLS

White Heteroskedasticity Test:

F-statistic	762.2516	Prob. F(2,7946)	0.0000
Obs*R-squared	1279.5810	Prob. Chi-Square(2)	0

Podemos verificar que o Teste de Heterocedasticidade de White apresentou o mesmo resultado para o resíduo de ambas as regressões. Com um p-valor tendendo a zero, o teste rejeitou a hipótese nula de resíduos homocedásticos com um grau de confiança de 99%. Assim sendo, fica evidenciado que as variâncias dos resíduos das regressões não são constantes.

5.10. Modelo GARCH

Como ficou evidenciado a existência de auto-correlação dos resíduos das regressões, optamos por rodar um modelo GARCH que trata de variáveis não-lineares e assim poderemos analisar a influência de resíduos e variâncias passadas na variância presente. O resultado do modelo GARCH encontra-se a seguir:

Tabela 16 - Teste GARCH

Dependent Variable: LNSPOTPRECO

Method: ML - ARCH (Marquardt) - Normal distribution

Date: 12/17/08 Time: 20:14

Sample (adjusted): 7 7949

Included observations: 7943 after adjustments

Convergence achieved after 7 iterations

Variance backcast: ON

GARCH = C(15) + C(16)*RESID(-1)^2 + C(17)*RESID(-2)^2 + C(18)

*RESID(-3)^2 + C(19)*RESID(-4)^2 + C(20)*RESID(-5)^2 + C(21)

*RESID(-6)^2 + C(22)*GARCH(-1) + C(23)*GARCH(-2) + C(24)

*GARCH(-3) + C(25)*GARCH(-4) + C(26)*GARCH(-5) + C(27)

*GARCH(-6)

	Coefficient	Std. Error	z-Statistic	Prob.
LNSPOTPRECO(-1)	0.2849	0.0046	61.9845	0
LNSPOTPRECO(-2)	0.1834	0.0012	148.2127	0
LNSPOTPRECO(-3)	0.1858	0.0126	14.8030	0
LNSPOTPRECO(-4)	0.1417	0.0121	11.7005	0
LNSPOTPRECO(-5)	0.1057	0.0142	7.4397	0
LNSPOTPRECO(-6)	0.0968	0.0114	8.4729	0
C	0.0005	0.0004	1.1787	0.2385
LNFUTPRECO	0.9604	0.0015	642.8113	0
LNFUTPRECO(-1)	-0.2561	0.0056	-45.5167	0
LNFUTPRECO(-2)	-0.1789	0.0033	-54.3903	0
LNFUTPRECO(-3)	-0.1885	0.0121	-15.6278	0
LNFUTPRECO(-4)	-0.1256	0.0119	-10.5469	0
LNFUTPRECO(-5)	-0.1179	0.0138	-8.5457	0
LNFUTPRECO(-6)	-0.0919	0.0115	-8.0053	0

Variance Equation

C	0.0012	0.0009	5.2446	0.0014
RESID(-1)^2	0.1037	0.0069	14.9694	0
RESID(-2)^2	0.0418	0.0170	2.4557	0.0141
RESID(-3)^2	0.0367	0.0112	3.2893	0.0010
RESID(-4)^2	0.0244	0.0186	1.3065	0.1914
RESID(-5)^2	0.0211	0.0139	1.5211	0.1282
RESID(-6)^2	0.0427	0.0135	3.1551	0.0016
GARCH(-1)	0.2731	0.1599	1.7080	0.0876
GARCH(-2)	0.0285	0.1389	0.2055	0.8372
GARCH(-3)	0.0288	0.1643	0.1751	0.8610
GARCH(-4)	0.0302	0.1413	0.2138	0.8307
GARCH(-5)	0.0332	0.1149	0.2886	0.7729
GARCH(-6)	0.0326	0.0917	0.3560	0.7218

R-squared	0.9999	Mean dependent var	4.5260
Adjusted R-squared	0.9999	S.D. dependent var	0.0930
S.E. of regression	0.0007	Akaike info criterion	-12.0763
Sum squared resid	0.0042	Schwarz criterion	-12.0526
Log likelihood	47988.220	F-statistic	4925211.2

Podemos verificar pelos resultados do modelo GARCH apresentados acima que fica claro a influência dos três primeiros resíduos passados e do sexto resíduo passado na variância do resíduo presente. Os resíduos passados com até três níveis de defasagem e o resíduo com seis níveis de defasagem apresentaram os p-valores abaixo de 5%, ou seja, podemos afirmar com um grau de 95% de confiança que esses resíduos influenciam a variância do resíduo presente.

No entanto, as variâncias dos resíduos passados não apresentam influência sobre a variância do resíduo presente com um grau de 95% de confiança. Já se utilizarmos um grau de confiança de 90% podemos verificar que a variância do resíduo passado com um nível de defasagem influencia a variância do resíduo presente, dado que apresentou um p-valor de 8,76%.