



CENTRO UNIVERSITÁRIO SENAI CIMATEC

**PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
COMPUTACIONAL E TECNOLOGIA INDUSTRIAL**

Doutorado em Modelagem Computacional e Tecnologia Industrial

Tese de Doutorado

**Modelo Computacional para Análise de Movimentos
e Co-movimentos de Mercados Financeiros**

Apresentada por: Everaldo Freitas Guedes
Orientador: Dr. Ivan Costa da Cunha Lima
Co-orientador: Dr. Gilney Figueira Zebende

Abril de 2019

Everaldo Freitas Guedes

Modelo Computacional para Análise de Movimentos e Co-movimentos de Mercados Financeiros

Tese de Doutorado apresentada ao Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial, Curso de Doutorado em Modelagem Computacional e Tecnologia Industrial do CENTRO UNIVERSITÁRIO SENAI CIMATEC, como requisito parcial para a obtenção do título de **Doutor em Modelagem Computacional e Tecnologia Industrial**

Área de conhecimento: Interdisciplinar

Orientador: Dr. Ivan Costa da Cunha Lima

CENTRO UNIVERSITÁRIO SENAI CIMATEC

Co-orientador: Dr. Gilney Figueira Zebende

UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Salvador
CENTRO UNIVERSITÁRIO SENAI CIMATEC
2019

Ficha catalográfica elaborada pela Biblioteca do Centro Universitário SENAI CIMATEC

G924m Guedes, Everaldo Freitas

Modelo computacional para análise de movimentos e co-movimentos de mercados financeiros / Everaldo Freitas Guedes. – Salvador, 2019.

124 f. : il. color.

Orientador: Prof. Dr. Ivan Costa da Cunha Lima.

Coorientador: Prof. Dr. Gilney Figueira Zebende.

Tese (Doutorado em Modelagem Computacional e Tecnologia Industrial) – Programa de Pós-Graduação, Centro Universitário SENAI CIMATEC, Salvador, 2019.

Inclui referências.

1. Efeito contágio. 2. Crises financeiras. 3. Eficiência de mercado. 4. Séries temporais. I. Centro Universitário SENAI CIMATEC. II. Lima, Ivan Costa da Cunha. III. Zebende, Gilney Figueira. IV. Título.

CDD: 620.00113

Nota sobre o estilo do PPGMCTI

Esta tese de doutorado foi elaborada considerando as normas de estilo (i.e. estéticas e estruturais) propostas aprovadas pelo colegiado do Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial e estão disponíveis em formato eletrônico (*download* na Página Web http://ead.fieb.org.br/portal_faculdades/dissertacoes-e-teses-mcti.html ou solicitação via e-mail à secretaria do programa) e em formato impresso somente para consulta.

Ressalta-se que o formato proposto considera diversos itens das normas da Associação Brasileira de Normas Técnicas (ABNT), entretanto opta-se, em alguns aspectos, seguir um estilo próprio elaborado e amadurecido pelos professores do programa de pós-graduação supracitado.

Centro Universitário SENAI CIMATEC

Doutorado em Modelagem Computacional e Tecnologia Industrial

A Banca Examinadora, constituída pelos professores abaixo listados, leu e aprovou a Tese de doutorado, intitulada "**Modelo computacional para Análise de Movimentos e Co-movimentos de Mercados Financeiros**", apresentada no dia 12 de abril de 2019, como parte dos requisitos necessários para a obtenção do Título de Doutor em Modelagem Computacional e Tecnologia Industrial.

Orientador:

Prof. Dr. Ivan Costa da Cunha Lima
SENAI CIMATEC

Coorientador:

Prof. Dr. Gilney Figueira Zebende
UEFS

Membro Interno:

Prof. Dr. Alex Alisson Bandeira Santos
SENAI CIMATEC

Membro Interno:

Prof. Dr. Renelson Ribeiro Sampaio
SENAI CIMATEC

Membro Externo:

Prof. Dr. Juan Alberto Leyva Cruz
UEFS

Membro Externo:

Prof. Dr. Paulo Jorge Canas Rodrigues
UFBA

*Dedico este trabalho a toda minha família,
em especial às minhas avós **Cremilda,**
Maria Helena e Zenaide.*

Agradecimentos

Antes de tudo, quero agradecer a **Deus**, por ter abençoado todos os dias da minha vida, por iluminar meu caminho e me dar forças para seguir sempre em frente.

A minha família, em especial a minha mãe **Eliana**, por todo o incentivo e apoio dado desde o início do curso e pela compreensão do tempo de convívio muitas vezes sacrificado para a realização deste trabalho.

Ao meu orientador e amigo professor **Dr. Gilney Figueira Zebende** que, sempre de forma amigável, orientou-me na realização desta tese. Agradeço pela confiança, amizade, conselhos e paciência. Saiba que és muito mais que um orientador, pois além de sabedoria e competência possuis uma grande determinação, dinamismo e carisma, características que o tornam uma pessoa muito especial e faz com que todos queiram estar a tua volta.

Ao professor **Dr. Ivan Costa da Cunha Lima**, pela ajuda, disponibilidade e amizade.

Aos professores membros da banca, **Dr. Alex Álisson Bandeira Santos**, **Dr. Renelson Ribeiro Sampaio**, **Dr. Paulo Jorge Canas Rodrigues** e **Dr. Juan Alberto Leyva Cruz**, pelas valiosas sugestões para a melhoria deste trabalho.

Aos amigos **Dr. Aloísio Machado da Silva Filho**, **Dr. Arleys Pereira Castro** e **Dr. Florêncio Mendes Oliveira Filho** pelo apoio e incentivo.

Aos docentes do Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial do Centro Universitário SENAI CIMATEC.

Aos meus colegas de curso, por serem grandes companheiros durante esta jornada. Obrigado pela consideração, cumplicidade e linda amizade que construímos, ano após ano.

Por fim, agradeço a todos, que de um modo geral contribuíram de forma direta ou indireta para a realização deste trabalho.

A **FAPESB**, pelo auxílio financeiro concedido para a realização deste trabalho.

Resumo

O mercado financeiro desempenha um papel importante na alocação dos recursos de qualquer economia, pois é um ponto de encontro entre os agentes que detêm a poupança e aqueles que apresentam necessidades de financiamento. No entanto, tem sido o palco em que frequentemente ocorrem turbulências que causam desordem no mercado e podem levar economias à recessão, causando grandes impactos econômicos e sociais, como desemprego, redução do consumo e de investimentos e fechamento de empresas. As crises financeiras marcaram a história do capitalismo. Com o passar do tempo, crises de grande escala, como a bolha do Subprime que surgiu nos Estados Unidos, em 2007 e 2008, foram sentidas em praticamente todos os países do mundo. Nesta tese, propomos um modelo computacional que permite o monitoramento dos movimentos e co-movimentos de indicadores de mercado, considerando as hipóteses teóricas de eficiência, interdependência e de contágio. Por esse objetivo, medimos dinamicamente a autocorrelação em séries temporais para avaliar a autorregulação do mercado, bem como mensuramos a correlação cruzada, de maneira dinâmica, na tentativa de avaliar a interdependência entre dois mercados e desenvolvemos um teste estatístico que permite avaliar, de maneira significativa, a hipótese de contágio. Acreditamos que esta pesquisa pode contribuir para o desenvolvimento da economia, especialmente no desenvolvimento de métodos computacionais.

Palavras chave: Crises financeiras, efeito contágio, eficiência de mercado, séries temporais.

Abstract

The financial market plays an important role in the allocation of the resources of any economy, as it is a meeting point between the agents who hold the savings and those who present financing needs. However, it is the scenario in which turbulence often occurs that causes disruption in the market and can lead to economies of scale, causing great economic and social impacts, such as unemployment, reduction of consumption and investment, and closure of companies. Financial crises marked the history of capitalism. Over time, larger-scale crises, such as the Subprime bubble that emerged in the United States in 2007 and 2008, have been felt in virtually every country in the world. In this thesis, we propose a computational model that allows the monitoring of the movements and co-movements of market indicators, considering the theoretical hypotheses of efficiency, interdependence and of contagion. With this aim, we dynamically measure the autocorrelation in time series to evaluate market self-regulation, as well as cross-correlation, in a dynamic way, in the attempt to evaluate the interdependence between two markets and we developed a statistical test that allows significant evaluation , the hypothesis of contagion. We believe that this research can contribute to the development of economics, especially in the development of computational methods.

keywords: Financial crisis, contagion effect, market efficiency, time series.

Sumário

1	Introdução	1
1.1	Definição do problema	3
1.2	Objetivos	3
1.3	Importância da pesquisa	4
1.4	Hipóteses	5
1.5	Aspectos metodológicos	5
1.6	Organização da Tese de Doutorado	6
2	Fundamentação teórica	7
2.1	Crises financeiras: breve discussão	7
2.1.1	Grandes crises econômicas da história	11
2.2	A hipótese de mercados eficientes	13
2.3	Contágio	15
2.4	Análise de séries temporais	22
2.4.1	Processos estocásticos	24
2.4.1.1	A função de autocorrelação	30
2.4.2	Detrended Fluctuation Analysis	33
2.4.3	Detrended Cross-Correlation Analysis	35
3	Resultados	38
3.1	Janelas deslizantes para analisar ações bancárias da UE	38
3.2	Correlação Cruzada ρ_{DCCA} em Empresas Blue-Chips da Zona do Euro	53
3.3	Coefficiente ρ_{DCCA} com janela deslizante	65
3.4	Teste estatístico para $\Delta\rho_{DCCA}$	78
3.5	Teste estatístico para $\Delta\rho_{DCCA}$: Métodos e dados	86
4	Considerações finais	91
4.1	Conclusões	91
4.2	Sugestões para trabalhos futuros	94
A	Outros Trabalhos	95
A.1	Programas de computador registrados	95
	Referências	98

Lista de Tabelas

2.1	Principais Crises da História	12
2.2	Condições para análise do ρ_{DCCA}	19

Lista de Figuras

2.1	Níveis de correlação cruzada entre os índices Dow Jones e Nasdaq - 02/janeiro/2001 a 16/janeiro/2018. Elaborado pelo autor.	19
2.2	Correlação cruzada entre o Dow Jones e Nasdaq. Fonte: Guedes et al. (2018a)	21
2.3	$\Delta\rho_{DCCA}(n)$ entre o Dow Jones e Nasdaq. Fonte: Guedes et al. (2018a)	21
2.4	Índice de fechamento dos mercados Dow Jones e Nasdaq - 02/janeiro/2001 a 16/janeiro/2018. Elaborado pelo autor.	22
2.5	Ilustração de um processo estocástico.	25
2.6	Simulação de um ruído branco	28
2.7	Simulação de um processo ARMA.	29
2.8	Simulação de um processo ARFIMA.	30
2.9	Simulação dos processos estocásticos: Ruído Branco (Figura 2.9 (a)), ARMA (Figura 2.9 (c)) e ARFIMA (Figura 2.9 (e)) e suas respectivas função de autocorrelação (Figura 2.9 (b), 2.9 (d) e 2.9 (f)). Fonte: Elaborado pelo autor.	32
2.10	Rentabilidades e séries integradas dos mercados Dow Jones e Nasdaq - 02/janeiro/2001 a 16/janeiro/2018. Elaborado pelo autor.	36
2.11	Divisão dos sinais integrados R_k e R'_k em $(N-n)$ <i>boxes</i> com superposição de tamanho $n=4$, cada um contendo $n+1$ valores. Fonte: Silva-Filho (2014)	37
3.1	União Europeia. Fonte: Comissao-Europeia (2018)	38
3.2	Zona do Euro. Fonte: Comissao-Europeia (2018)	53
3.3	Ilustração da Janela Deslizante.	65
3.4	Algoritmo do teste do $\Delta\rho_{DCCA}$. Fonte: Guedes et al. (2018b)	78

Lista de Siglas

ARCH.....	Heteroscedasticidade Condicional Autorregressiva
ARMA	Autorregressivo e de Média Móvel
ARIMA	Autorregressivo e Integrado de Média Móvel
AFIRMA ...	Autorregressivo Fracionário e Integrado de Média Móvel
ADF	Teste Dickey Fuller Aumentado
DFA	<i>Detrended Fluctuation Analysis</i>
DCCA	<i>Detrended Cross-Correlation Analysis</i>
DPCCA	<i>Detrended Partial-Cross-Correlation Analysis</i>
DMCA	<i>Detrending Moving-Average Cross-Correlation Analysis</i>
DMC	<i>Detrended Multiple Cross-Correlation Coefficient</i>
DNA	Ácido Desoxirribonucleico
EUA	Estados Unidos da América
FAC	Função de Autocorrelação
EMH	Hipótese de Eficiência de Mercado
FMH	Hipótese de Mercado Fractal
FMI	Fundo Monetário Internacional
FR	Teste de Forbes e Rigobon
GARCH	Heteroscedasticidade Condicional Autorregressiva Generalizada
IBOVESPA .	Índice da Bolsa de Valores de São Paulo
JB	Teste Jarque-Bera
RB	Ruído Branco
ρ_{DCCA}	Coefficiente de Correlação Cruzada
UE	União Europeia

Introdução

A propagação das crises por todo sistema financeiro é um tema que tem despertado o interesse de pesquisadores (ver, por exemplo, os trabalhos sobre as crises da Ásia (Orlov (2009), Khan e Park (2009), Choe et al. (2012), Li e Zhu (2014)) e do Subprime (Kalbaska e Gatkowski (2012), Preis et al. (2012), Olbrys e Majewska (2014), Li e Zhu (2014), Stove, Tjostheim e Hufthammer (2014), Luchtenberg e Vu (2015), Flavin e Sheenan (2015), Ma, Li e Li (2016), Mollah, Quoreshi e Zafirov (2016), Silva et al. (2016), Deltuvaite (2016), Wang et al. (2017), Anastasopoulos (2018)), formuladores de políticas e órgãos reguladores, a exemplo do FMI (Schinasi (2004)) e do Banco Mundial (Ishihara (2005)) e de investidores, uma vez que desequilíbrios iniciados em um país podem ser sentidos em outros países.

Uma possível explicação para esse fenômeno é apresentada por Kaminsky, Reinhart e Vegh (2003), ao abordar que uma crise iniciada em um país faz com que investidores passem a analisar os fundamentos econômicos e financeiros de outros países. Caso descubram que também estejam desequilibrados, a crise também tomará lugar nesses outros países. O comportamento de manada dos investidores, choques de liquidez e a existência de equilíbrios múltiplos são fatores que podem esclarecer a concorrência de contágio. Assim, a transmissão pode ser de maneira direta, por meio de ativos podres ou pelo elevado grau de endividamento externo de bancos e empresas, ou indireta, por meio dos preços dos ativos (do mercado de capitais ou de câmbio), mercado interno (empréstimos interbancários), pelo sistema bancário (devido à rigidez nas condições financeiras ou a problemas em filiais estrangeiras) ou por meio de choques nas exportações de manufaturas e *commodities* (CHAINED, 2013).

Se por um lado, a integração financeira proporcionada pela globalização e pelo avanço das tecnologias possibilitou o aumento da mobilidade de capitais pelo mundo, fazendo com que os participantes do mercado tenham cada vez mais recursos para acompanhar seus investimentos e tomar decisões de forma mais ágil, por outro, ampliou os canais de transmissão, devido, principalmente, à ausência parcial ou total de mecanismos de controle regulatório internacional (BRESSER-PEREIRA, 2010; KIESEL; KOLARIC; SCHIERECK, 2016; ALEXAKIS; PAPPAS, 2018). O que fez com que os países fossem considerados como similares em risco (VIDAL, 2011; CURVO, 2011; CHAINED, 2013; WANG et al., 2017).

Um importante exemplo foi a crise do *Subprime* desencadeada nos EUA, em 2007-08, que, além de se propagar em praticamente todas as regiões do mundo¹, prolongou-se por

¹A velocidade e intensidade de propagação dessa crise, após a quebra do banco Lehman Brothers - quarto

mais tempo, afetando a capacidade do sistema financeiro global de manter sua estabilidade financeira². Evento que trouxe sérias dificuldades para as economias dos países, reduzindo a atividade econômica, independentemente da proximidade geográfica (CURVO, 2011; CHAINE, 2013; LUCHTENBERG; VU, 2015).

De acordo com Tabak e Souza (2009), Subprime é um tipo de crédito concedido a pessoas com maus históricos de pagamento. Devido às baixas taxas de juros decorrentes de grande liquidez do mercado internacional, a demanda por casas hipotecadas nos EUA, financiadas por créditos subprime, aumentou, fazendo com que o preço das casas aumentasse e houvesse refinanciamento de casas. O problema deu-se quando a taxa de juros aumentou e o preço das casas diminuiu. Pessoas que haviam contraído empréstimos não conseguiram pagar. Uma vez que as casas eram dadas como garantia e o preço delas estava diminuindo, os emprestadores não eram capazes de recuperar seus investimentos.

Obviamente, o contágio pode ser considerado um evento que causa grande preocupação global (MISSIO; WATZKA, 2011; CONSTANCIO, 2012). Embora existam muitos conceitos sobre esse assunto na literatura especializada (ver, por exemplo, Bae, Karolyi e Stulz (2000), Albert (2001), Pritsker (2001), Forbes e Rigobon (2002), Kaminsky, Reinhart e Vegh (2003), Pericoli e Sbracia (2003), Bergmann et al. (2010)), a definição proposta por Forbes e Rigobon (2002) é a mais utilizada. Para os autores, o contágio é definido como o aumento ou a diminuição significativa das interações entre dois mercados, enquanto a inexistência de contágio é entendida como interdependência. Alguns autores, a exemplo de Dungey e Martin (2001), Khalid e Rajaguru (2006) e Masson (1998), ainda utilizaram o termo *spillovers* para definir os efeitos defasados de um choque ocorrido em outros países.

Face ao exposto, compreender como os mercados interagem e como se dão os mecanismos de propagação é de extrema importância, principalmente na gestão de medidas políticas capazes de conter e mitigar o contágio. No que tange aos governos, a adoção de medidas para amenizar os efeitos de crises dependem de como estas foram transmitidas (HAILE; POZO, 2008; MISSIO; WATZKA, 2011; CONSTANCIO, 2012). Além disso, planos de ajuda e crédito dependem da existência de mecanismos de transmissão, a exemplo do contágio e investidores têm os resultados oriundos da diversificação de suas carteiras comprometidos devido a elevados níveis de correlação entre mercados (HORTA; MENDES; VIEIRA, 2008).

Uma das várias maneiras de medir o contágio é analisar a correlação cruzada entre séries temporais do mercado financeiro (ver, por exemplo, os trabalhos sobre as crises de Hong Kong (Corsetti, Pericoli e Sbracia (2005)), da Rússia (Sojli (2007), Jokipii e Lucey (2007)) e do Subprime (Li e Zhu (2014), Stove, Tjostheim e Hufthammer (2014), Hui e Chan

maior banco de investimentos dos Estados Unidos na época e maior investidor do subprime - ao menos em parte, podem ser vistas como consequência da globalização, uma vez que, após ela, os mercados se tornaram cada vez mais interligados, isto é, mais correlacionados.

²A estabilidade financeira é crucial para apoiar o desenvolvimento econômico de países individuais, a fim de que eles sejam mais competitivos nos mercados regionais e globais (SCHINASI, 2004).

(2014), Mollah, Quoreshi e Zafirov (2016), Silva et al. (2016), Anastasopoulos (2018), Guedes et al. (2017)). Existem vários métodos que objetivam quantificar o nível de correlação cruzada entre séries temporais, tais como os coeficientes: de Pearson (STIGLER, 1989; EDWARDS, 1993; STANTON, 2001), de Spearman (SPEARMAN, 1904), ρ_{DCCA} (ZEBENDE, 2011), DPCCA (YUAN et al., 2015) e DMC (ZEBENDE; SILVA-FILHO, 2018). Geralmente, a abordagem linear é a mais empregada. Baseia-se na comparação dos coeficientes de correlação linear do período que antecede a crise com o período da crise (FORBES; RIGOBON, 2002; LI; ZHU, 2014). No entanto, métodos lineares, como o de Pearson, não são apropriados para séries com características não lineares, como a volatilidade.

Sabendo desse problema, Silva et al. (2016) idealizaram um novo método para medir o contágio denominado $\Delta\rho_{DCCA}$. Esse método deriva do coeficiente ρ_{DCCA} e é obtido por meio da diferença das correlações entre o pré e o pós-crise. Apesar da robustez do ρ_{DCCA} em reproduzir o fenômeno observado com determinado nível de aproximação (ver, por exemplo, os trabalhos de Wang et al. (2013), Kristoufek (2014), Piao e Fu (2016)), a significância estatística do $\Delta\rho_{DCCA}$ não é avaliada. Fato que pode proporcionar o aparecimento de questionamentos, principalmente, do ponto de vista da inferência estatística. Aliado a esse fato, não identificamos na literatura um método que seja utilizado para acompanhar movimentos e co-movimentos dos mercados.

1.1 Definição do problema

É possível monitorar os movimentos e co-movimentos de mercados financeiros?

1.2 Objetivos

Objetivo geral

Propor um modelo computacional que possibilite o monitoramento de movimentos e co-movimentos de mercados financeiros, no que tange às hipóteses teóricas de eficiência, de interdependência e de contágio.

Objetivos específicos

1. Propor método computacional para avaliar, de maneira dinâmica, a eficiência de mercado na forma fraca;
2. Compreender o comportamento dos mercados financeiros antes, durante e após a

crise do Subprime;

3. Desenvolver método computacional para avaliar, de maneira dinâmica, a hipótese de interdependência e de contágio;
4. Desenvolver método computacional para avaliar a significância estatística do $\Delta\rho_{DCCA}$;

1.3 Importância da pesquisa

As crises desempenham um importante papel na economia e política dos países, criando condições que afetam substancialmente o mercado de trabalho, no qual as firmas perdem capital e passam por uma difícil fase, principalmente na procura por fundos adicionais, levando-as a reduzir a mão de obra a fim de minimizar custos (BLANTON; BLANTON; PEKSEN, 2015). Ademais, turbulências financeiras podem alterar a situação existente e forçar governos e investidores a tomarem decisões cruciais que terão impacto na estrutura de outros países, o que pode causar grandes impactos sociais e econômicos, uma vez que diminuem os recursos disponíveis, reduzem as fontes de financiamentos e provocam movimentação dos investidores para aplicações mais seguras.

O reflexo pode ser sentido em praticamente todos os setores econômicos. No entanto, o setor industrial é um dos mais afetados (AKINLO; LAWAL, 2015; ROSSI, 2012). Estudos recentes, a exemplo de Guedes, Zebende e Lima (2017), demonstraram a existência de uma relação inversa entre a taxa de câmbio e a produção industrial do Estado da Bahia, onde os segmentos industriais Minerais Não Metálicos, Metalurgia, Borracha e Plástico e Alimentos e Bebidas são os mais influenciados pelas altas do Dólar Americano em longo prazo.

A compreensão da natureza e da extensão do contágio após um acidente financeiro é crucial para a elaboração de políticas que visam ao seu gerenciamento, principalmente, no sentido conter e mitigar sua disseminação (MISSIO; WATZKA, 2011; CONSTANCIO, 2012).

Apesar do grande número de publicações sobre a temática, percebe-se que existe uma carência de métodos adequados para medir o contágio, pois as medidas mais utilizadas são baseadas em abordagens tradicionais de características lineares. O que, face a natureza das variáveis em estudo, tem revelado inúmeros problemas de viesamentos quanto ao nível da estimação, principalmente diante da não estacionariedade das séries utilizadas.

Daí a necessidade de utilizar medidas e abordagens gerais que permitam capturar a não-linearidade global existente nos dados em estudo, independentemente da sua forma. É nesse contexto que surge a importância da utilização das medidas oriundas da física-estatística e econofísica, denominada análise das flutuações retirando a tendência (De-

trended FA e o coeficiente de correlação cruzada $\rho_{DCCA}(n)$).

A econofísica, de acordo com Mantegna e Stanley (2007), é um campo interdisciplinar que descreve as atividades dos físicos que estão trabalhando em problemas econômicos para testar uma variedade de novas abordagens conceituais decorrentes das ciências físicas. Também incluem incertezas ou processos dinâmicos estocásticos e não lineares. Assim, no que se refere aos benefícios, acreditamos que o presente estudo irá possibilitar reflexões sobre o desenvolvimento de novos métodos voltados para a modelagem de séries temporais, corroborando no desenvolvimento da econofísica.

1.4 Hipóteses

- H_1 : A dinâmica dos preços e índices bolsistas se aproxima da eficiência após períodos turbulentos;
- H_2 : A mensuração de autocorrelação e de correlação cruzada, de maneira dinâmica, poderá servir como ferramenta para o monitoramento da eficiência, da interdependência e do contágio;
- H_3 : As crises financeiras afetam as economias com menor grau de desenvolvimento, de modo, a alterar o comportamento das ações (*blue-chips*³) com os seus respectivos índices bolsistas;
- H_4 : O desenvolvimento de um teste de hipóteses para o $\Delta\rho_{DCCA}$ possibilitará a identificação, de maneira mais precisa, do contágio entre dois mercados;

1.5 Aspectos metodológicos

A metodologia adotada, além de simulações em laboratório, consiste em modelar indicadores do mercado financeiro (preços de ações e índices bolsistas), na forma de séries temporais, a partir de duas perspectivas: autocorrelação e correlação cruzada. Para a autocorrelação, utilizou-se o método *Detrended Fluctuation Analysis* (Subseção 2.4.2) para avaliar a hipótese teórica de eficiência de mercado enquanto que para a correlação cruzada, utilizou-se o coeficiente ρ_{DCCA} (Subseção 2.3) para avaliar a hipótese teórica de interdependência e contágio.

³O termo *blue-chips* é utilizado para nomear as ações que possuem ótima reputação, alta liquidez e elevado grau de confiabilidade e, geralmente, estão associados à empresas de grande porte (SILVA et al., 2015).

1.6 Organização da Tese de Doutorado

Esta pesquisa está dividida em quatro capítulos e estruturada da seguinte forma:

- **Capítulo 1 - Introdução** - Neste capítulo, apresentamos uma contextualização do objeto de estudo, contendo problema, os objetivos gerais e específicos, a importância, as hipóteses e os aspectos metodológicos desta pesquisa e sua organização.
- **Capítulo 2 - Fundamentação Teórica** - Neste capítulo, expomos, em uma breve discussão, os conceitos de crises financeiras, seus desenhos, classificações, bem como listamos as maiores crises econômicas da história e discorremos sobre as hipóteses teóricas de eficiência de mercado, interdependência e de contágio. Por fim, abordamos os principais conceitos da análise de séries temporais.
- **Capítulo 3 - Resultados** - Neste capítulo, apresentamos os resultados desta tese de doutorado, os quais estão relacionados com cada um dos objetivos específicos listados na Subseção 1.2 do Capítulo 1. Por opção metodológica, expomos os resultados em formato de artigo (publicados e submetidos), que obedecem a ordem dos objetivos específicos.
- **Capítulo 4 - Considerações Finais** - Neste capítulo, apresentamos as conclusões, contribuições e algumas atividades de pesquisa a serem desenvolvidas no futuro.

Fundamentação teórica

2.1 Crises financeiras: breve discussão

O termo crise financeira é definido por [Portes \(1999, p. 471\)](#) como uma perturbação dos mercados financeiros que interrompe a capacidade do mercado de alocar capital de maneira eficiente. A extensa literatura apresenta duas abordagens diferentes para crises financeiras ([ANTCZAK, 2000](#); [RACICKAS; VASILIAUSKAITE, 2012](#)). A primeira delas, associa as crises ao pânico bancário e seu impacto no fornecimento de dinheiro. Os pioneiros dessa abordagem foram [Friedman e Schwartz \(1963\)](#) que se referem às crises financeiras apenas nos casos em que o pânico bancário surge, causando uma repentina diminuição da oferta monetária e da atividade econômica do país.

A segunda abordagem, defendida inicialmente por [Minsky \(1970\)](#) e depois por [Kindleberger e Aliber \(2005\)](#), explica que as crises fazem parte do ciclo econômico e a principal causa da instabilidade financeira são os problemas de fluxo de informações que causam estrangulamentos no funcionamento eficiente dos mercados financeiros. Dessa forma, tais fenômenos são o resultado da desordem nos mercados denominada ruptura, quando os problemas de seleção adversa¹ e de risco moral² tornam-se tão complexos que os mercados não podem efetivamente alocar recursos financeiros para aqueles por os quais as oportunidades de investimento são de maior retorno ([ANTCZAK, 2000](#)). Essa compreensão, além do pânico bancário, inclui, por exemplo, bolhas especulativas, *crashes* (uma queda acentuada nos preços dos ativos), colapso de instituições financeiras e não financeiras, problemas de mercados cambiais ou uma combinação desses eventos.

De acordo com [Curvo \(2011\)](#), as crises podem apresentar um dos três desenhos básicos:

- i) Em **U** – A economia desacelera lentamente e depois se recupera lentamente;
- ii) Em **V** – A economia desacelera rapidamente, porém se recupera rapidamente. Uma crise em forma de **V** pode virar em um **W**, caso os problemas estruturais não venham a ser enfrentados e dirimidos;
- iii) Em **L** – A economia despenca (podendo conter cenário de pânico) e se mantém em baixo nível de atividade por período relativamente longo. A recuperação é difícil,

¹Uma situação na qual uma parte na transação possui mais informações que a outra (Assimetria da Informação).

²Se refere à possibilidade de que um agente econômico mude seu comportamento de acordo com os diferentes contextos nos quais ocorre uma transação econômica. Por exemplo, o caso do seguro de automóveis. Quando o cliente faz um seguro para proteger seu carro, há a possibilidade de que ele se descuide do veículo, uma vez que, se algo acontecer, a conta é da seguradora.

principalmente depois de instaurada a depressão ou grande recessão econômica. Segundo o autor, esse é o formato da crise de 1929.

Além disso, segundo [Racickas e Vasiliauskaite \(2012\)](#), podem ser classificadas em:

Crise de moeda: É uma queda súbita no valor da moeda, apesar das garantias governamentais que em nenhuma circunstância permitirá a depreciação da moeda nacional ([RACICKAS; VASILIAUSKAITE, 2012](#)). Ela ocorre, quando um ataque especulativo sobre o valor cambial da moeda corrente resulta na desvalorização (ou depreciação acentuada) da moeda, que força as autoridades a defenderem a moeda por meio do gasto de grandes volumes de reservas internacionais ou aumentando acentuadamente as taxas de juros.

Para [Qian, Reinhart e Rogoff \(2010\)](#), as crises cambiais podem ser:

- i. Choque de moeda: depreciação anual em relação ao dólar dos EUA (ou a moeda âncora relevante) de 15% ou mais.
- ii. Desvalorização da moeda: redução das moedas em circulação de 5% ou mais ou reforma monetária em que nova moeda substitui uma moeda anterior muito depreciada em circulação.

Crise bancária: É uma crise financeira que, de acordo com [Sahiti et al. \(2013\)](#), afeta a atividade dos bancos na forma como gerenciam ativos, passivos e capitais próprios em sua posse. Nesse sentido, [Ishihara \(2005\)](#) defini as crises bancárias como um período em que um segmento significativo do sistema bancário torna-se ilíquido ou insolvente³. Para o autor, uma crise bancária envolve uma disputa pelo público quanto aos meios de pagamento que, a menos que sejam impedidos por um credor de último recurso, levem ao colapso monetário e à recessão.

[Reinhart e Rogoff \(2008\)](#), marcam uma crise bancária por dois tipos de eventos:

- i. Operações bancárias que levam ao encerramento, fusão ou aquisição pelo setor público de uma ou mais instituições financeiras;
- ii. Ausência de operações, fechamento, fusão, aquisição ou assistência governamental em larga escala a uma instituição financeira importante (ou grupo de instituições), que marca o início de uma série de resultados semelhantes em outras instituições financeiras.

³Refere-se a uma situação em que o passivo do banco excede suas expectativas em valor presente e o banco está efetivamente falido ([ISHIHARA, 2005](#)).

Crise da dívida pública: É uma situação em que, segundo [Antczak \(2000\)](#), o país não pode atender suas obrigações nacionais ou estrangeiras, sejam elas soberanas ou privadas. Nessa perspectiva, [Reinhart e Rogoff \(2008\)](#) e [Qian, Reinhart e Rogoff \(2010\)](#) abordam que a crise da dívida é uma situação em que o devedor não consegue atender o interesse e o pagamento do principal conforme previsto, prejudicando assim a saúde financeira do credor.

Crise da balança de pagamentos: É um desequilíbrio estrutural entre o *déficit* em conta corrente e a conta capital e financeira, que após o esgotamento das reservas internacionais, leva a uma crise monetária ([ANTCZAK, 2000](#); [RACICKAS; VASILIAUSKAITE, 2012](#)).

Crise de inflação: De acordo com [Racickas e Vasiliauskaite \(2012\)](#), é um aumento inesperado da inflação. Segundo [Qian, Reinhart e Rogoff \(2010\)](#), esse tipo de crise ocorre quando a taxa de inflação anual de um país é maior do que 20%. A inflação faz com que todos os mutuários (incluindo o governo) paguem suas dívidas na moeda nacional, cujo poder de compra agora é muito menor do que era quando o empréstimo se realizou ([REINHART; ROGOFF, 2008](#)).

Crise financeira sistêmica: São perturbações potencialmente graves dos mercados financeiros que, ao prejudicar a capacidade do mercado de funcionar efetivamente, podem trazer grandes efeitos adversos na economia real ([RACICKAS; VASILIAUSKAITE, 2012](#)). Segundo [Antczak \(2000\)](#), essas crises podem envolver os tipos crises supramencionadas que não são mutuamente exclusivas, mas qualquer uma dessas crises não leva necessariamente a uma crise financeira sistêmica em grande escala.

Uma crise sistêmica é caracterizada por [Laeven e Valencia \(2008\)](#) como eventos em que os setores corporativos e financeiros de um país experimentam um elevado grau de inadimplência e instituições financeiras e corporações enfrentam grandes dificuldades para reembolsar contratos a tempo. Como resultado, os empréstimos inadimplentes aumentam acentuadamente e a totalidade ou a maior parte do capital do sistema bancário agregado está esgotada. Essa situação pode ser acompanhada de preços de ativos deprimidos, aumento acentuado das taxas de juros reais e desaceleração ou reversão dos fluxos de capital.

Crise induzida pela política macroeconômica: De acordo com [Racickas e Vasiliauskaite \(2012\)](#), uma crise da balança de pagamentos (desvalorização da moeda, perda de reservas cambiais, colapso de um regime de taxa de câmbio fixo) ocorre quando os bancos

centrais implementaram a política de expansão do crédito doméstico que é incompatível com o regime de câmbio fixo. Para o autor, a expansão do crédito é o resultado da monetização do déficit orçamentário. As reservas de divisas vão diminuindo gradualmente, enquanto o banco central se torna vulnerável a um súbito ataque especulativo à moeda nacional que esgota as reservas de moeda estrangeira remanescentes e obriga o país a ir ao regime de taxa de câmbio flutuante.

Pânico financeiro: É o resultado de um saldo negativo quando os credores de curto prazo (por exemplo, os depositantes) de repente retiram seus empréstimos de devedores solventes (por exemplo, bancos) (RACICKAS; VASILIAUSKAITE, 2012). Grosso modo, pode-se definir o pânico como uma fuga de ativos considerados de alto risco para ativos que se acredita mais seguros. Geralmente, o pânico pode ocorrer nas seguintes três condições:

- i. o débito dos devedores em curto prazo excedem os atuais ativos em curto prazo;
- ii. nenhum credor do mercado privado é capaz de fornecer o montante desejado do empréstimo necessário para cobrir todas as obrigações de curto prazo do devedor; e
- iii. não há possibilidade de usar o credor como último recurso.

Nesse caso, Portes (1999) explica que o pânico financeiro é o cerco do banco ou uma situação similar na escala global. Assim, nem a maior transparência bancária e nem a apresentação de informações adequadas permitirão evitar o comportamento das multidões, condicionado por problemas de ação coletiva.

Colapso da bolha: Pode-se definir uma bolha quando os preços de determinados ativos crescem de forma abrupta e excessiva, associado a um processo especulativo (BLANCHARD; WATSON, 1982).

Uma bolha financeira estocástica ocorre quando os especuladores compram um ativo financeiro abaixo do seu valor intrínseco e esperam lucrar com as mudanças no valor desse ativo. Em cada período, a bolha pode continuar a crescer ou estourar. O estouro da Bolha (*crash*) é a queda ou colapso dos preços dos ativos que formavam a bolha. No entanto, parcialmente causado pelos próprios jogadores do mercado, uma vez que eles estão conscientes da existência da bolha e da probabilidade de sua explosão (BLANCHARD; WATSON, 1982; RACICKAS; VASILIAUSKAITE, 2012).

Crise de risco moral: De acordo com Akerlof e Romer (1994), ocorre porque os bancos podem contrair empréstimos de mercados especificados ou indefinidos na base do quadro

de seguro de depósitos. Se os bancos são muito pouco ajustáveis ou o nível de sua capitalização é muito baixo, eles podem atrair fundos para projetos excessivamente arriscados. Dessa forma, para [Portes \(1999\)](#), as garantias de apoio financeiro em caso de perda de fundos podem levar à ocorrência de perdas morais e levar a uma crise financeira.

Treino desordenado: De acordo com [Portes \(1999\)](#), o treino desordenado ocorre quando um devedor ilíquido ou insolvente (banco) provoca seus credores para retirarem seus fundos e, portanto, força a liquidação, mesmo que o devedor seja mais útil como a empresa existente. Geralmente, o treino desordenado é a consequência da falta de regulamentação das empresas ilíquidas e insolventes.

Ataque especulativo sobre a taxa de câmbio: Um ataque especulativo contra uma moeda cuja taxa de câmbio é fixa ou que segue uma flutuação suja (*crawling peg*⁴) é caracterizado por [Portes \(1999\)](#) como uma súbita e maciça reestruturação das carteiras por meio da qual os agentes procuram prevenir prejuízos ou angariar lucros decorrentes da previsão de mudança da política cambial.

2.1.1 Grandes crises econômicas da história

A história do capitalismo tem sido marcada por crises financeiras ([SORNETTE, 2003](#); [VER-SIGNASSI, 2015](#)) (ver a Tabela 2.1). Apesar de acontecerem em épocas diferentes e sobre ativos diferentes, os fundamentos das crises financeiras se repetem. Por exemplo, crises geralmente acontecem após períodos de amplo desenvolvimento econômico, abundância de crédito e expectativas de retornos anormais infinitos ([REINHART; ROGOFF, 2008](#); [REINHART; ROGOFF, 2010](#)).

As crises com proporções que afetam países individuais ou bloco de países são chamadas de recessão e depressão. Os países que se enquadram em recessão ou depressão econômica, além do crescimento econômico negativo, também experimentaram o aumento da taxa de desemprego em todos os seus setores econômicos. As crises, geralmente, provocam escassez de crédito, redução dos investimentos e ainda podem causar grandes impactos econômicos e sociais ([KINDLEBERGER; LAFFARGUE, 1982](#); [ALLEN; BABUS; CARLETTI, 2009](#); [GOLDSTEIN; RAZIN, 2013](#); [DETZER; HERR, 2014](#)).

⁴É um sistema de ajustes de taxa de câmbio em que uma moeda com taxa de câmbio fixa pode flutuar dentro de uma faixa de taxas. O valor nominal da moeda declarada e a faixa de taxas também podem ser ajustados com frequência, particularmente em épocas de alta volatilidade da taxa de câmbio. *Pegs* de rastreamento são frequentemente usados para controlar movimentações de moeda quando há uma ameaça de desvalorização devido a fatores como inflação ou instabilidade econômica ([CRAWLING-PEG, 2018](#)).

De acordo com [Sahiti et al. \(2013\)](#), as crises com as maiores dimensões são a grande depressão dos anos 1930 e a crise da hipoteca (2007-2008), ambas nos Estados Unidos da América (EUA). A Tabela 2.1 resume algumas grandes crises da história.

Tabela 2.1: Principais Crises da História

Tempo	Nome	Região	Principais características
1636	A bolha da Tulipa Holandesa	Holanda	Especulação nos contratos futuros de bulbos de Tulipa
1720	A bolha Mar do Sul	Grã Bretanha	Especulação na dívida pública
1720	A bolha Mississípi	França	Especulação na dívida pública
1792	Pânico de 1792	Estados Unidos	Especulação em ações de bancos e dívida do governo
1825	Crise Latino-Americana	América Latina	Especulação sobre o crescimento futuro de novos países independentes da América Latina
1837	Crise do Algodão	Estados Unidos	Queda nos preços do algodão, bolha nos preços da terra, crise de crédito
1857	Crise Ferroviária	Estados Unidos	Especulação em ganhos futuros de empresas ferroviárias
1873	Depressão Longa	Europa e Estados Unidos	Depressão na Europa após a guerra franco-prussiana e especulação em empresas ferroviárias nos Estados Unidos
1890	Crise Baring	Argentina e Inglaterra	Especulação em títulos argentinos
1907	Pânico em Wall Street	Estados Unidos	Especulação em ações de empresas fiduciárias
1929	Crash de 1929 e Grande Depressão	Estados Unidos e Mundo	Queda em Wall Street e início da Grande Depressão
1970	Crise do Petróleo	Economias avançadas	Colapso do sistema de Bretton Woods e crise do petróleo
1980	Crise da dívida na América Latina	América Latina	Surge em empréstimos bancários para o México e outros países latino-americanos na década de 1970 e início de 1980

Tempo	Nome	Região	Principais características
1987	Segunda-feira Negra	Estados Unidos e Mundo	Queda do mercado de ações
1991	Crise Japonesa	Japão	Bolha no setor imobiliário e ações em 1985-89
1991	Crise Escandinava	Finlândia, Noruega e Suécia	Bolha no setor imobiliário e ações em 1985-89 seguida por crises cambiais e bancárias
1994	Crise Tequila	México	O aumento do investimento estrangeiro no México de 1990 a 1993
1997	Crise Asiática	Países Asiáticos	Bolha no mercado imobiliário e estoques seguido por crises cambiais e bancárias
2001	Crise Argentina Tripla	Argentina	Crises bancárias, cambiais e da dívida
2001	Dotcom crash	Estados Unidos	Bolha nos estoques de telecomunicações e internet no varejo (OTC) nos Estados Unidos em 1995 - 2000
2008	Crise do subprime	Estados Unidos	Bolha no mercado imobiliário e títulos lastreados em hipotecas
2009 e 2013	Crise de débito	Europa	Crise da dívida em vários estados membros da União Europeia

Fonte: [Zanalda \(2015\)](#) e [Curvo \(2011\)](#). Elaborado pelo autor.

2.2 A hipótese de mercados eficientes

A hipótese de mercados eficientes (EMH), desenvolvida por [Fama \(1970\)](#), é um dos assuntos mais importantes dentro da teoria de finanças. Um mercado é considerado eficiente quando os preços das ações refletem plenamente toda a informação disponível, levando a uma alocação eficiente do capital. Essa hipótese pressupõe que os agentes, sem distinção, absorvem as informações disponíveis de forma linear e imparcial, de modo que, a reação de cada agente às novas informações divulgadas é constante e todas essas informações são instantaneamente precificadas. Assim, não há possibilidade de um agente obter ganhos adicionais ao elaborar uma estratégia de investimento baseada em informações que estão disponíveis ao mercado, pois os preços dos ativos já refletem essas informações e nenhum movimento futuro de preços seria influenciado por informações passadas. Dessa maneira, as flutuações dos preços devem ser imprevisíveis e independentes dos preços passados, isto é, as séries temporais dos preços não podem apresentar memória ([DEGUTIS; NOVICKYT, 2014](#); [STASZKIEWICZ; STASZKIEWICZ, 2015](#)).

Desde a sua elaboração, a EMH tem sido tema de intensa discussão pela literatura especializada, e considerada por muitos pesquisadores, a exemplo de [Busse e Green \(2002\)](#),

Malkiel (2003), Shiller (2003), Galam (2011), Lim e Brooks (2011), Sewell (2012), Degutis e Novicky (2014), Titan (2015), como um dos tópicos mais controversos da economia. Questões como a existência de anomalias e a ocorrência de grandes crises tem esquentado o debate e servido de argumento para muitos autores sobre a ineficiência dos mercados financeiros, uma vez que, acredita-se, esses eventos só poderiam ser causados por eventos externos, mas não pela dinâmica do próprio mercado.

Fama (1991) promoveu aperfeiçoamentos em sua própria teoria desenvolvida em 1970, ao introduzir as seguintes categorias de eficiência:

- i **Fraca:** Nessa forma, nenhum investidor consegue obter retornos anormais por meio da análise dos preços passados. As informações contidas nos preços passados não são úteis ou relevantes na obtenção de retornos extraordinários;
- ii **Semi-forte:** Nessa forma, nenhum investidor consegue obter retornos anormais baseados em qualquer informação publicamente disponível. Qualquer nova informação seria rapidamente incorporada aos preços dos ativos, impossibilitando que os investidores se utilizassem da informação para obter retornos anormais;
- iii **Forte:** Nessa forma, nenhum investidor consegue obter retornos anormais usando qualquer tipo de informação, até mesmo as confidenciais, que não são de conhecimento público;

Os três tipos de eficiência informacional são complementares, a rejeição da hipótese de eficiência fraca implica em rejeição das demais, assim como a rejeição da hipótese de eficiência semiforte implica a rejeição da hipótese de eficiência forte.

Existem evidências empíricas da existência de comportamentos anormais nos retornos dos ativos financeiros (anomalias) (ver, por exemplos os trabalhos empíricos relacionados com os mercados: Asiático (Lim, Brooks e Kim (2008)), Americano (Alvarez-Ramirez et al. (2008)), Euro-Asiático (Sensoy (2013)), de energia (Alvarez-Ramirez, Alvarez e Rodriguez (2008), Aloui et al. (2012), Mensi, Beljid e Managi (2014), Sensoy e Hacihasanoglu (2014)), Europeu (Fortune (1991), Tabak e Cajueiro (2006), Cajueiro, Gogas e Tabak (2009), Sensoy e Tabak (2013), Sensoy e Tabak (2015)), Turquia (Rizvi e Arshad (2016)), diversos (Laffont e Maskin (1990), Dowd e Gorton (1997), Sensoy e Tabak (2016)), moedas digitais (Charfeddine e Khediri (2016)), países membros da Organização da Conferência Islâmica (Arshad et al. (2016)) e Chinês (Fifield e Jetty (2008), Guangxi, Yan e Weijun (2014), Beltratti, Bortolotti e Caccavaio (2016))). Além disso, a presença de memória longa pode trazer vários problemas, como por exemplo, o horizonte de investimento preferido dos investidores torna-se um fator de risco; os métodos usados para precificar derivativos financeiros podem não mais ser válidos e os testes usuais baseados no Modelo de Preci-

ificação de Ativos de Capital (CAPM) não podem ser aplicados a séries temporais com memória longa ([TITAN, 2015](#)).

A hipótese de mercados fractais (FMH), desenvolvida por [Peters \(1994\)](#), surge como uma alternativa à hipótese de eficiência de mercado. Essa hipótese considera que o mercado se estabiliza⁵ sozinho, quando há investidores com horizontes temporais diferentes compartilhando do mesmo risco.

A FMH considera que o investidor de curto prazo possui uma parcela maior de aleatoriedade por trabalhar em intervalos menores para análise das informações disponíveis. Por outro lado, em escalas maiores de tempo, na qual estão os investidores de longo prazo, tem-se uma característica mais determinística, não sendo drasticamente impactados com oscilações isoladas, mas sim pelo resultado das oscilações diárias ajustadas para o seu tempo de retorno esperado. Os fractais⁶ seguem a aleatoriedade local e o determinismo global sendo, no caso do mercado, a escala determinada pelo tempo.

Assim, espera-se que investidores de longo prazo estejam mais preocupados com fatores econômicos e resultados das empresas. Já investidores de curto prazo utilizam análises técnicas, de tendência e de liquidez das ações. Em momentos de crise, os investidores de longo prazo participam das transações de curto prazo, aumentando a necessidade de liquidez do mercado e quebrando o equilíbrio.

2.3 Contágio

O termo contágio, de acordo com [Bergmann et al. \(2010\)](#), tornou-se conhecido a partir da análise das crises da década de 1990, quando choques originados em determinado mercado estenderam-se a vários mercados de outros países e dificilmente conseguiam ser explicados por mudanças nos fundamentos macroeconômicos.

A vasta literatura apresenta algumas definições sobre contágio, os quais refletem os diversos canais pelo qual pode ser transmitido. Por exemplo, [Albert \(2001\)](#) descreve o contágio como uma rápida transmissão de um mercado para outro, que apresenta preços declinantes, diminuição de liquidez, aumento da volatilidade e da correlação. [Bae, Karolyi e Stulz \(2000\)](#) definem contágio como eventos em excesso em uma região que não são explicados pelas suas próprias co-variáveis, mas que são explicados pelos excessos de outras regiões.

⁵Pode-se dizer que um mercado estável se mantém com investidores de vários horizontes de investimento. As perdas daqueles que negociam em curto prazo são sobrepostas por investidores de longo prazo que têm interesse em manter suas perspectivas futuras e não consideram as perdas de curtíssimo prazo como algo fora do normal ([PETERS, 1994](#)).

⁶Os fractais são formas geométricas que podem ser separadas em partes, cada uma sendo a versão reduzida em escala do todo ([MANDELBROT, 1997](#)).

Kaminsky, Reinhart e Vegh (2003) definem contágio como um episódio no qual, após um evento, ocorrem efeitos imediatos significantes em vários países, ou seja, quando as consequências de um evento são rápidas e agressivas. Constancio (2012) refere-se ao contágio como um dos mecanismos pelos quais a instabilidade financeira se torna tão generalizada que a crise atinge dimensões sistêmicas. Forbes e Rigobon (2002) definem o contágio como o aumento significativo nas correlações entre dois mercados em momentos de crise, devido à transmissão da volatilidade. É justamente a definição de contágio adotada em nossa pesquisa.

Em outras palavras, de acordo com a abordagem de Forbes e Rigobon (2002), haverá contágio se a correlação entre mercados aumentar ou diminuir significativamente em períodos turbulentos. Por outro lado, se a correlação não aumentar ou diminuir significativamente, esse movimento entre os mercados financeiros é chamado de interdependência.

A literatura especializada apresenta inúmeros trabalhos que utilizaram alterações nas correlações como indicativo de contágio. Geralmente, estes estudos empíricos comparam as correlações entre um período relativamente estável e um período turbulento (ver, por exemplo, as análises das crises do Leste Asiático de 1997, do México em 1994 e no Crash de 1987 (Forbes e Rigobon (2002), Choe et al. (2012), Li e Zhu (2014)), crise de Hong Kong (Corsetti, Pericoli e Sbracia (2005)), crise da Rússia (Sojli (2007)), Subprime (Jokipii e Lucey (2007), Tabak e Souza (2009), Li e Zhu (2014), Stove, Tjostheim e Hufthammer (2014), Hui e Chan (2014), Mollah, Quoreshi e Zafirov (2016), Silva et al. (2016), Deltuvaite (2016), Wang et al. (2017)). Contudo, existem outros métodos para este fim, como técnicas de co-integração (Vo (2009)); modelos da família ARCH e GARCH (Marais e Bates (2006)) e modelos da família Logit e Probit (Eichengreen, Rose e Wyplosz (1996)). Porém, não encontramos na literatura especializada consenso acerca do melhor método, todos eles são largamente utilizados.

A seguir, apresentamos duas abordagens que são utilizadas para capturar mudanças de correlação e, portanto, identificar do efeito contágio.

Abordagem proposta por Forbes e Rigobon (2002): O coeficiente de Pearson definido por

$$\rho_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.1)$$

onde, x_1, x_2, \dots, x_n e y_1, y_2, \dots, y_n são os valores medidos de ambas as variáveis e $\bar{x} = \frac{1}{n} \cdot \sum_{i=1}^n x_i$ e $\bar{y} = \frac{1}{n} \cdot \sum_{i=1}^n y_i$ são as médias aritméticas de ambas as variáveis. O coeficiente

de correlação produto-momento de Pearson é uma medida de dependência linear entre duas variáveis x e y , que situa-se entre -1 e $+1$, de modo que, -1 indica correlação linear negativa perfeita, 0 sinaliza inexistência correlação linear e $+1$ indica correlação linear positiva perfeita (FIGUEIREDO-FILHO; SILVA-JUNIOR, 2009).

De posse dos coeficientes de correlação linear entre o pré e a crise entre dois mercados e considerando-se a correlação é uma função linear positiva do nível de volatilidade, Forbes e Rigobon (2002)⁷ propuseram o coeficiente de correlação ajustado denotado por

$$\rho_{pos}^* = \frac{\rho}{\sqrt{1 + \delta(1 - \rho^2)}} \quad (2.2)$$

em que, ρ_{pos}^* é o coeficiente de correlação ajustado do período pós-crise, ρ é o coeficiente de correlação ($\rho_{x,y}$) não ajustado, $\delta = (\frac{\sigma_{pos}^2}{\sigma_{pre}^2} - 1)$ da variável explicada no período pré e pós-crise, ρ_{pre} é o coeficiente de correlação do período pré-crise. A avaliação da hipótese de interdependência e de contágio é realizada por meio dos testes FR_1 , FR_2 e FR_3 descritas a seguir:

O teste FR_1 é denotado por

$$FR_1 = \frac{\rho_{pos}^* - \rho_{pre}}{\sqrt{1/N_{pos} + 1/N_{pre}}} \sim N(0, 1) \quad (2.3)$$

O teste FR_2 é denotado por

$$FR_2 = \frac{\frac{1}{2} \ln\left(\frac{1+\rho_{pre}}{1-\rho_{pre}}\right) - \frac{1}{2} \ln\left(\frac{1+\rho_{pos}^*}{1-\rho_{pos}^*}\right)}{\sqrt{\frac{1}{N_{pre}-3} + \frac{1}{N_{pos}-3}}} \sim N(0, 1) \quad (2.4)$$

em que N_{pre} e N_{pos} representam respectivamente o número de observações dos períodos pré e pós-crise.

O teste FR_3 é denotado por

$$FR_3 = \left(\frac{\rho_{pos}^* - \rho_{pre}}{\sqrt{Var(\rho_{pos}^* - \rho_{pre})}} \right)^2 \sim \chi_1^2 \quad (2.5)$$

⁷A abordagem considera a inexistência de endogeneidade ($E(x_t \varepsilon_t) = 0$), variáveis omissas ($E(\varepsilon_t) = 0$) e a existência de independência.

em que

$$\sqrt{\text{Var}(\rho_{pos}^* - \rho_{pre})} = \frac{(1 + \delta)^2}{2(1 + \delta(1 - \rho_{pos}^2))^3} (\gamma_1 + \gamma_2 + \gamma_3 - \gamma_4) \quad (2.6)$$

sendo

$$\gamma_1 = \frac{(2 - \rho_{pos}^2)(1 - \rho_{pos}^2)^2}{N_{pos}} \quad (2.7)$$

$$\gamma_2 = \frac{\rho_{pos}^2(1 - \rho_{pos}^2)^2}{N_{pre}} \quad (2.8)$$

$$\gamma_3 = \frac{(1 - \rho_{pre}^2)^2}{N_{pre}} \quad (2.9)$$

$$\gamma_4 = \frac{\rho_{pos}\rho_{pre}(1 - \rho_{pos}^2)(1 - \rho_{pre}^2)(1 + \delta)}{N_{pre}\sqrt{(1 + \delta(1 + \rho_{pos}^2))^3}} \quad (2.10)$$

1. $H_0 : \rho_{pos}^* = \rho_{pre}$, não há evidência de contágio;
2. $H_1 : \rho_{pos}^* \neq \rho_{pre}$, há evidência de contágio;

A distribuição dos testes é aproximadamente normal, e os resultados, robustos a não normalidade do coeficiente de correlação (FORBES; RIGOBON, 2002; TABAK; SOUZA, 2009; FRY; MARTON; TANG, 2010). Maiores detalhes sobre as distribuições normal padrão Z e χ^2 poderão ser encontrados em Magalhaes e Lima (2005).

Abordagem proposta por Silva et al. (2016): O coeficiente de correlação cruzada ρ_{DCCA} (Zebende (2011)) é denotado por

$$\rho_{DCCA}(n) = \frac{F_{DCCA}^2(n)}{F_{DFA[Y_i]}(n) F_{DFA[Y'_i]}(n)} \quad (2.11)$$

Em que $F_{DCCA}^2(n)$ é a função de covariância sem tendência do método DCCA (Seção 2.4.3) e $F_{DFA}(n)$ é a função de variância sem tendência do método DFA (Seção 2.4.2).

Assim como o coeficiente de Pearson, o ρ_{DCCA} é adimensional e possui campo de variação entre $-1 \leq \rho_{DCCA} \leq 1$, de modo que, -1 indica anticorrelação cruzada perfeita, 0 significa correlação cruzada inexistente e 1 sinaliza correlação cruzada perfeita. No entanto, de acordo com [Silva et al. \(2016\)](#), é possível analisá-lo por categorias, conforme Tabela 2.2.

Tabela 2.2: Condições para análise do ρ_{DCCA} .

ρ_{DCCA}		
Fraco	Médio	Forte
0.000 - 0.333	0.333 - 0.666	0.666 - 1.000

Fonte: [Silva et al. \(2016\)](#).

A Figura 2.1 apresenta correlação cruzada positiva forte entre o Dow Jones e Nasdaq, independentemente da escala observada.

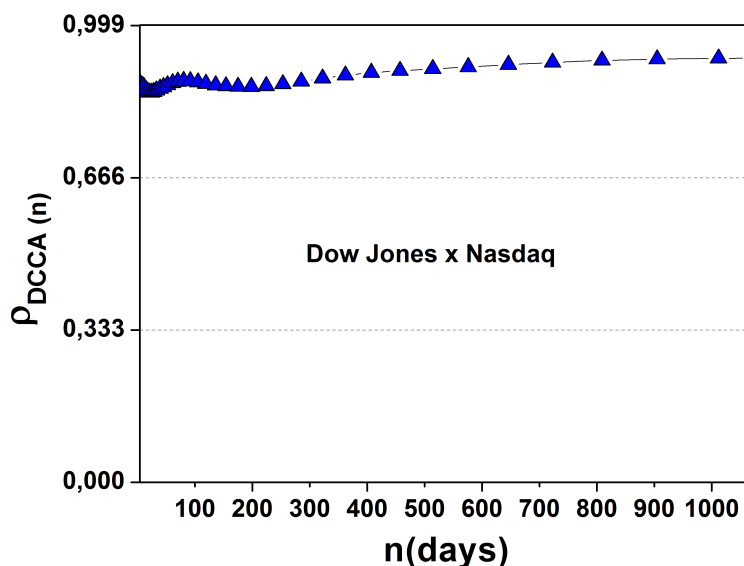


Figura 2.1: Níveis de correlação cruzada entre os índices Dow Jones e Nasdaq - 02/janeiro/2001 a 16/janeiro/2018. Elaborado pelo autor.

Numa revisão da literatura, observamos que o ρ_{DCCA} foi aplicado em estudos de:

- climatologia - na compreensão do comportamento da relação entre a temperatura e umidade relativa do ar - ([Vassoler e Zebende \(2012\)](#), [Yuan e Fu \(2014\)](#), [Zebende et al. \(2018\)](#));
- geologia - na análise de poços de petróleo - ([Marinho, Sousa e Andrade \(2013\)](#));
- indicadores criminalidade - no estudo da relação entre homicídios e tentativas de homicídio - ([Filho, Silva e Zebende \(2014\)](#)); e

• economia - em análises de preços e outros indicadores do mercado financeiro - (Wang e Xie (2012), Wang et al. (2013), Wang et al. (2014), Wang et al. (2013), Wang et al. (2014), Reboredo, Rivera-Castro e Zebende (2013), Balocchi, Varanini e Macerrata (2013), Silva, Castro e Silva-Filho (2014), Guedes, Zebende e Machado (2015), Bashir et al. (2016), Hussain et al. (2017), Silva et al. (2015), Silva et al. (2016), Guedes et al. (2017), Guedes, Zebende e Lima (2017), Ferreira, Dionisio e Zebende (2016), Ferreira (2016), Blythe, Nikulin e Muller (2016), Ferreira et al. (2017), Ferreira e Dionisio (2017), Ferreira e Kristoufek (2017), Lin et al. (2017), Bashir et al. (2018), Ferreira et al. (2018));

Além de ser utilizado para mensuração de correlação linear e não linear, o ρ_{DCCA} se mostrou mais eficiente quando comparado com o coeficiente de correlação de Pearson, principalmente no estudo de séries temporais não estacionárias (WANG et al., 2013; SILVA-FILHO; SILVA; ZEBENDE, 2014; PIAO; FU, 2016; ZHAO; SHANG; HUANG, 2017).

De posse dos valores $\rho_{DCCA}(n)$ de antes e de depois de uma turbulência financeira, Silva et al. (2016) propuseram uma nova variável denominada $\Delta\rho_{DCCA}(n)$ para mensurar o efeito contágio entre dois mercados, que será denotada por

$$\Delta\rho_{DCCA}(n) = \rho_{DCCA}^{after}(n) - \rho_{DCCA}^{before}(n) \quad (2.12)$$

Em que, $\rho_{DCCA}^{before}(n)$ e $\rho_{DCCA}^{after}(n)$ representam respectivamente a correlação pré- crise e pós- crise entre duas economias após um acidente financeiro, conforme ilustramos na Figura 2.2. O $\Delta\rho_{DCCA}(n)$ possui campo de variação entre $-2 \leq \rho_{DCCA} \leq 2$, de modo que: [i.] $\Delta\rho_{DCCA}(n) = 0$, não há evidência de contágio, [ii.] $\Delta\rho_{DCCA}(n) > 0$, há evidência de contágio com ampliação das interações e [iii.] $\Delta\rho_{DCCA}(n) < 0$, há evidência de contágio com redução das interações.

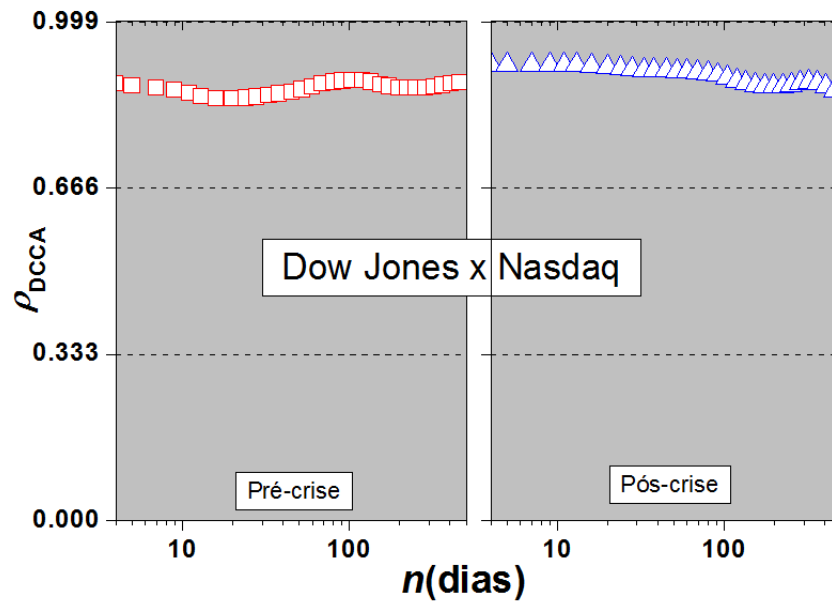


Figura 2.2: Correlação cruzada entre o Dow Jones e Nasdaq. Fonte: [Guedes et al. \(2018a\)](#).

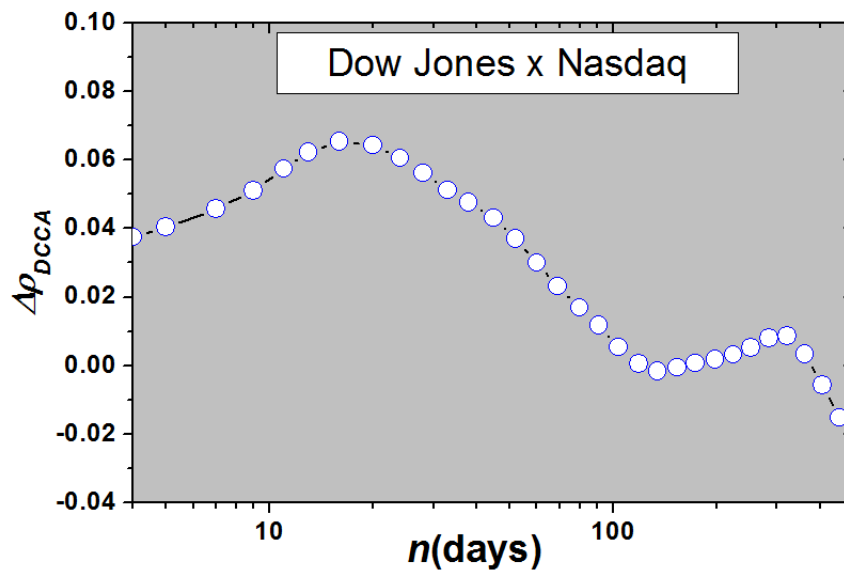


Figura 2.3: $\Delta\rho_{DCCA}(n)$ entre o Dow Jones e Nasdaq. Fonte: [Guedes et al. \(2018a\)](#).

É possível observar na Figura 2.3 que para escalas de tempo inferiores a 100 dias, a diferença é positiva. Isso significa que houve contágio com ampliação das interações entre os dois índices.

Embora recente, o $\Delta\rho_{DCCA}(n)$ foi utilizado em análises visando a identificação de contágio da crise do Subprime na Zona do Euro por [Ferreira, Dionisio e Zebende \(2016\)](#) e [Guedes et al. \(2017\)](#).

2.4 Análise de séries temporais

Uma série temporal é definida como qualquer conjunto de observações ordenadas no tempo (MORETTIN; TOLOI, 2006; WEI, 2006; BISGAARD; KULAHCI, 2011; SHUMWAY; STOFFER, 2011). Na Figura 2.4, apresentamos a evolução dos índices de fechamento dos mercados Dow Jones (Figura 2.4 (a)) e Nasdaq (Figura 2.4 (b)) na forma de séries temporais.




Figura 2.4: Índice de fechamento dos mercados Dow Jones e Nasdaq - 02/janeiro/2001 a 16/janeiro/2018. Elaborado pelo autor.

Para exemplificação, as séries temporais serão aqui denotadas por um conjunto de observações $[Y_t, t \in T]$ de uma variável Y , onde T refere-se ao tempo⁸. Assim, podemos classificá-las em:

1. Discretas: quando as observações são feitas em tempos específicos, geralmente espaçados, $T = \{1, 2, \dots, N\}$. Por exemplo, as séries cronológicas mostradas na Figura 2.4. É importante ressaltar que as séries discretas são o foco de nossa investigação.
2. Contínuas: quando as observações são realizadas continuamente no tempo, $T = [t : t_1 < t < t_2]$. Por exemplo, um registro de marés no Porto de Salvador (MORETTIN; TOLOI, 2006, p. 1).

⁸Segundo Pereira, Zanusso e Sales (1986, p. 1), a variável tempo pode ser substituída por uma outra, como por exemplo, espaço e profundidade.

3. Multivariadas: quando a série temporal (ex: discreta) é representada por um vetor \tilde{t} , $T = [Y_{1t}, \dots, Y_{kt}, \tilde{t} \in T]$ (AIUBE, 2013, p. 44). Por exemplo: vendas (Y_{1t}) e gastos com propaganda semanais de um produto (Y_{2t}); pressão uterina da parturiente (Y_{1t}) e batidas do coração do feto em trabalho de parto (Y_{2t}).
4. Multidimensional: quando se tem $[Y_t, \tilde{t} \in T]$ e \tilde{t} é um vetor com dimensão superior a 1 (AIUBE, 2013, p. 44). Por exemplo, $[Y_{(t,r,l)}, \tilde{t} \in T]$ onde Y é a altura de um ponto no oceano, t é o tempo, r a latitude e l a longitude.

Além de prever valores futuros com base em valores passados, o estudo de séries temporais objetiva:

- explicação - utilizar a variação de uma série para explicar a variação de outra série;
- controle de processos - controlar a qualidade de uma série temporal é importante por permitir ajustar o modelo à série de dados, possibilitando tomar medidas corretivas nas séries para evitar que a qualidade se afaste de um nível estabelecido;
- descrição - identificar propriedades da série, a exemplo de tendência, sazonalidade, *outliers*, alterações estruturais e etc.

Obviamente, uma investigação pode-se explorar mais de um dos objetivos supracitados. Contudo, Pereira, Zanusso e Sales (1986, p. 17) explicam que o objetivo global do estudo de séries é sumarizar as propriedades da série e caracterizar seu comportamento, identificando ou sugerindo um modelo⁹ adequado.

A maneira clássica de decomposição de series (ver Milone (2006, p. 315)) baseia-se nos modelos:

Aditivo:

$$Y_t = T + C + S + A \quad (2.13)$$

Multiplicativo:

$$Y_t = TCSA \quad (2.14)$$

⁹Assim como em Milone (2006, p. 17), modelo será aqui interpretado como uma representação, em escala reduzida ou por meio de relações matemáticas, de um objeto, evento ou fenômeno.

Mistos:

$$Y_t = T + CSA \quad \text{ou} \quad Y_t = TC + SA \quad \text{ou} \quad Y_t = TCS + A \quad (2.15)$$

Em que, Y_t , T , C , S e A representam respectivamente a série e as componentes tendência, ciclo, sazonal e aleatória, descritas a seguir.

- a. Tendência: Representa a componente macro de uma série temporal, pois indica a direção global dos dados (crescimento/decrécimo linear ou não-linear).
- b. Cíclica: Representa as oscilações de longo prazo ou aos desvios em torno de uma reta ou curva de tendência, podendo ser ou não periódicos.
- c. Sazonal: Representa padrões idênticos, ou quase, que uma série temporal parece obedecer durante uma determinada época do ano. Esse movimento refere-se aos ciclos de curto prazo (não maiores que um ano) em torno da tendência.
- d. Aleatória: Refere-se aos deslocamentos esporádicos das séries temporais, provocados por eventos casuais. A importância dessa componente vincula-se ao poder de alterar tanto a direção da tendência quanto à amplitude dos ciclos existentes.

Segundo [Milone \(2006, p. 316\)](#), o modelo aditivo é aplicado às séries cujas taxas de variação são constantes e o multiplicativo àquelas em que as taxas são crescentes ou decrescentes. Embora o modelo aditivo seja mais fácil de lidar, o multiplicativo é o mais usado. Já os modelos mistos unem as condições de aditividade e multiplicidade, logo, são de uso restrito e raro.

Os modelos utilizados na análise de séries temporais podem ser paramétricos ou não paramétricos. Nos paramétricos, a análise é realizada no domínio do tempo, são os modelos regressão, modelos autoregressivos e de médias móveis (ARMA), modelos autoregressivos integrados e de médias móveis (ARIMA) e modelos autoregressivos fracionário integrados de média móvel (ARFIMA) mais empregados. Por outro lado, nos não paramétricos, a análise é geralmente conduzida no domínio de frequências, a função de autocovariância (autocorrelação) e a análise espectral (transformada de Fourier) são os mais usuais.

2.4.1 Processos estocásticos

Os modelos utilizados na representação dos fenômenos com comportamentos aleatórios investigados na forma de séries temporais são ditos processos estocásticos ([MORETTIN;](#)

TOLOI, 2006).

Os processos estocásticos são uma família de $[Y_t, t \in T]$, tal que, para cada $t \in T, Y$ é uma variável aleatória. Assim, um processo estocástico será considerado uma família de variáveis aleatórias definidas em um mesmo espaço amostral de probabilidades (Ω). Portanto, para cada $t \in T, Y$ é uma variável aleatória real definida sobre Ω ; além de ser uma função de dois argumentos, $Y(t, \omega), t \in T, \omega \in \Omega$.




Figura 2.5: Ilustração de um processo estocástico.
 Fonte: Adaptado de Morettin e ToloI (2006, p. 20).

A Figura 2.5 revela que para cada $t \in T$, tem-se uma variável aleatória $Y_{(t,\omega)}$, com distribuição de probabilidades associada. Portanto, é possível que a função de densidade de probabilidade $f_y (Y)$ no instante t_1 seja diferente de $f_y (Y)$ no segundo instante t_2 .

Usualmente, descreve-se um processo estocástico por meio de suas funções média, autocovariância e variância. O valor esperado é denotado por

$$E\{Y_t\} = \mu_t, \tag{2.16}$$

A autocovariância entre Y_{t_1} e Y_{t_2} é denotada por

$$\gamma_{(t_1,t_2)} = Cov\{Y_{t_1}, Y_{t_2}\} = E\{[(Y_{t_1} - \mu_{t_1})][(Y_{t_2} - \mu_{t_2})]\}, \tag{2.17}$$

sendo t_1 e t_2 dois instantes distintos. Ou ainda, se $t_1 = t_2 = t$, (2.17) têm se

$$\gamma_{(t,t)} = \sigma^2 = \text{Var}\{Y_t\} = E\{Y_t^2\} - E^2\{Y_t\}, \quad (2.18)$$

representando a variância do processo Y .

Existem processos estocásticos com comportamentos específicos, a exemplo de processos estacionários, não estacionários e com comportamentos específicos, a exemplo de Ruído Branco, ARMA e ARFIMA.

Processos estacionários: Quando o processo estocástico é invariante no tempo diz-se que é estacionário. Os processos estocásticos podem apresentar estacionariedade *forte* (estrita) ou *fraca* (de segunda ordem). Um processo estocástico $\{Y_t, t \in T\}$ será estritamente estacionário¹⁰ se todas as distribuições finito dimensionais permanecem as mesmas sob translações do tempo, isto é

$$F(Y_1, \dots, Y_n; t_1 + \tau, \dots, t_n + \tau) = F(Y_1, \dots, Y_n; t_1, \dots, t_n) \quad (2.19)$$

para quaisquer t_1, \dots, t_n, τ de T . Por outro lado, o processo estocástico será considerado fracamente estacionário se e somente se

- (i) $E\{Y_t\} = \mu(t) = \mu$, constante, para todo $t \in T$;
- (ii) $E\{Y_t^2\} < \infty$, para todo $t \in T$;
- (iii) $\gamma_{(t_1, t_2)} = \text{Cov}\{Y_{t_1}, Y_{t_2}\}$ é uma função de $|t_1 - t_2|$.

Nessas condições, será fracamente estacionário se as médias e variâncias forem constantes ao longo do tempo e se a sua função de autocovariância depender somente da defasagem (*lag*) $|t_1 - t_2|$.

A maioria dos modelos estatísticos de análise de séries temporais supõem que as séries sejam estacionárias, caso não ocorra, poderá se transformar em estacionária ao ser diferenciada em uma quantidade finita de vezes n

$$\Delta^n Y_t = \Delta[\Delta^{n-1} Y_t]. \quad (2.20)$$

¹⁰Segundo Morettin e Tolo (2006, p. 23), um processo Y é estritamente estacionário se as distribuições unidimensionais são invariantes no tempo, ou seja, se a média e a variância forem constantes.

Geralmente, no máximo duas diferenças são suficientes para tornar a série temporal estacionária. No entanto, quando for suficiente, costuma-se aplicar antes das diferenças, uma transformação não linear nos dados, como por exemplo, a transformação logarítmica ou a transformação de Box-Cox (Equação 2.21) (ver Box e Cox (1964)).

$$Y_t^{(\lambda)} = \begin{cases} \frac{Y_t^\lambda - c}{\lambda}, & \text{se } \lambda \neq 0, \\ \log Y_t, & \text{se } \lambda = 0 \end{cases} \quad (2.21)$$

Em linhas gerais, aplica-se uma transformação na série temporal no intuito de alcançar a estabilidade da variância e/ou simetria dos dados, ou ainda, em séries sazonais, tornar o efeito sazonal aditivo.

Ruído Branco: Um processo estocástico $\{\varepsilon_t\}$ é especificado como ruído branco¹¹ ou sequência aleatória se

- (i) $E[\varepsilon_t] = 0$, constante, para todo $t \in T$;
- (ii) $\text{Var}[\varepsilon_t] = \sigma_\varepsilon^2$, para todo $t \in T$;
- (iii) $\gamma(\varepsilon_{t_1}, \varepsilon_{t_2}) = \text{Cov}[\varepsilon_{t_1}, \varepsilon_{t_2}] = 0$, para todo $t_1 \neq t_2$.

O ruído branco (ver Figura 2.6) é temporalmente homogêneo, estacionário e sem dependência temporal, que resulta de um processo estocástico em que todas as variáveis aleatórias seguem uma distribuição normal de média zero, variância e covariâncias nulas (vide a Figura 2.6). Usualmente, esse processo estocástico é denotado por

$$\varepsilon_t \sim RB(0, \sigma_t^2). \quad (2.22)$$

¹¹O ruído branco consiste num distúrbio que afeta e que pode distorcer a informação, originando um sinal aleatório com propriedades estatísticas conhecidas de amplitude, distribuição e densidade espectral.

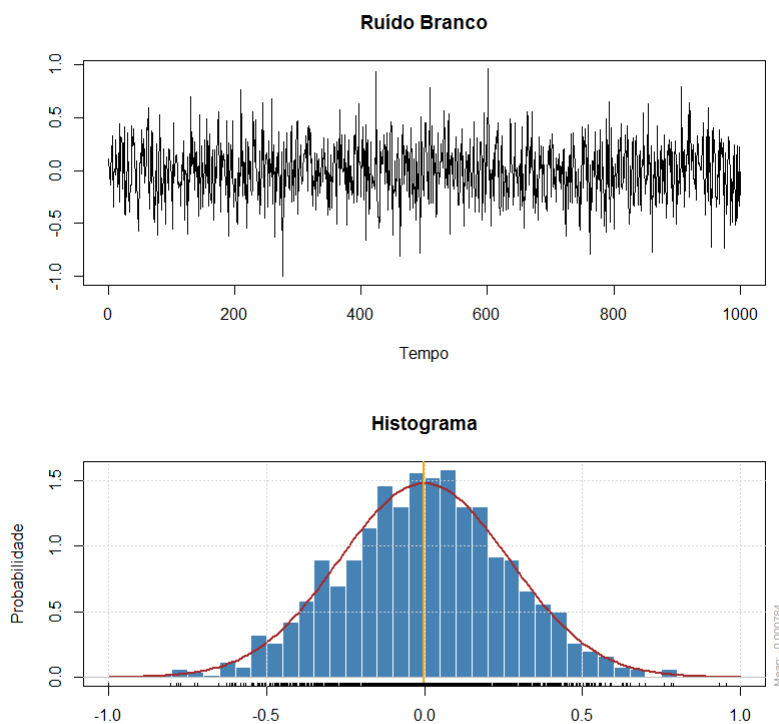


Figura 2.6: Simulação de um ruído branco
 Fonte: [Ligges et al. \(2014\)](#). Elaborado pelo autor.

ARMA: Um processo $\{Y_t, t \in Z\}$ é um processo ARMA (p, q) se, para cada t , é a solução da equação

$$\phi(B)(Y_t - \mu) = \theta(B)\varepsilon_t, \quad \varepsilon_t \sim RB(0, \sigma^2), \quad (2.23)$$

onde μ é uma constante, $\phi(\cdot)$ e $\theta(\cdot)$ são dois polinômios de graus p (autorregressivo) e q (média móvel), respectivamente, tais que

$$\phi(B) = 1 - \phi_1(B) - \dots - \phi_p(B)^p \text{ e } \theta(B) = 1 + \theta_1(B) + \dots + \theta_q(B)^q$$

e B é o operador de atraso (*backshift*) tal que

$$B^k Y_t = Y_{t-k}, \quad k = 0, 1, \dots \quad (2.24)$$

De acordo com as definições anteriores, o processo $\{Y_t\}$ pode ser escrito na forma

$$Y_t - \mu = \phi_1(Y_{t-1} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + \varepsilon_t + \theta_1\varepsilon_{t-1} + \dots + \theta_q\varepsilon_{t-q} \quad (2.25)$$

Dado um processo $\{Y_t, t \in Z\} \sim ARMA(p, q)$ cujos polinômios $\phi(\cdot)$ e $\theta(\cdot)$ não têm raízes comuns, mostra-se que o processo é, simultaneamente, estacionário (ver Figura 2.7) e invertível se e somente se os dois polinômios não têm raízes dentro do círculo unitário.

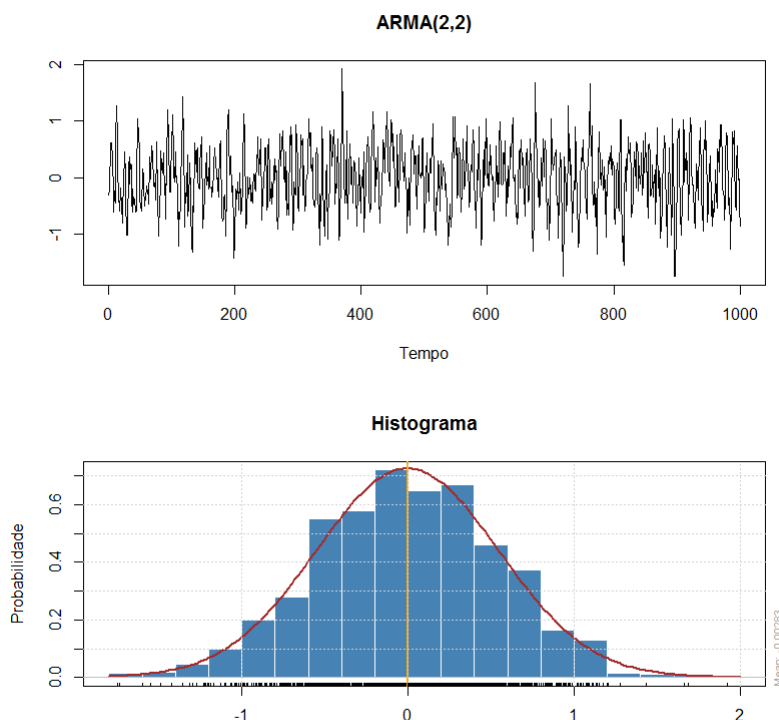


Figura 2.7: Simulação de um processo ARMA.
 Fonte: [Veenstra \(2012\)](#). Elaborado pelo autor.

ARFIMA: Considere qualquer número real, $d > -1$, define-se o operador de diferença fracionária

$$\nabla^d = (1 - B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-B)^k = 1 - dB + \frac{1}{2!}d(d-1)B^2 - \frac{1}{3!}d(d-1)(d-2)B^3 + \dots \quad (2.26)$$

Um processo $\{Y_t, t \in Z\}$ é dito ARFIMA(p, d, q), se para cada t é a solução da equação

$$\phi(B) \nabla^d (Y_t - \mu) = \theta(B)\varepsilon_t, \quad \varepsilon_t \sim RB(0, \sigma^2), \quad (2.27)$$

onde μ é uma constante, $\phi(\cdot)$ e $\theta(\cdot)$ são dois polinômios de graus (autorregressivo) e q (média móvel), respectivamente, e B é o operador de atraso, definidos previamente. O processo $\{Y_t\}$ pode ser escrito na forma

$$\nabla^d (Y_t - \mu) = \phi_1 \nabla^d (Y_{t-1} - \mu) + \cdots + \phi_p \nabla^d (Y_{t-p} - \mu) + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q} \quad (2.28)$$

Por outras palavras, um dado processo $\{Y_t, t \in Z\}$ é um processo ARFIMA(p, d, q) (Figura 2.8), se e somente se o processo $\nabla^d Y_t$ é um processo ARMA(p, q) causal (estacionário) e invertível (se os dois polinômios não têm raízes dentro do círculo unitário e $-0,5 < d < 0,5$)

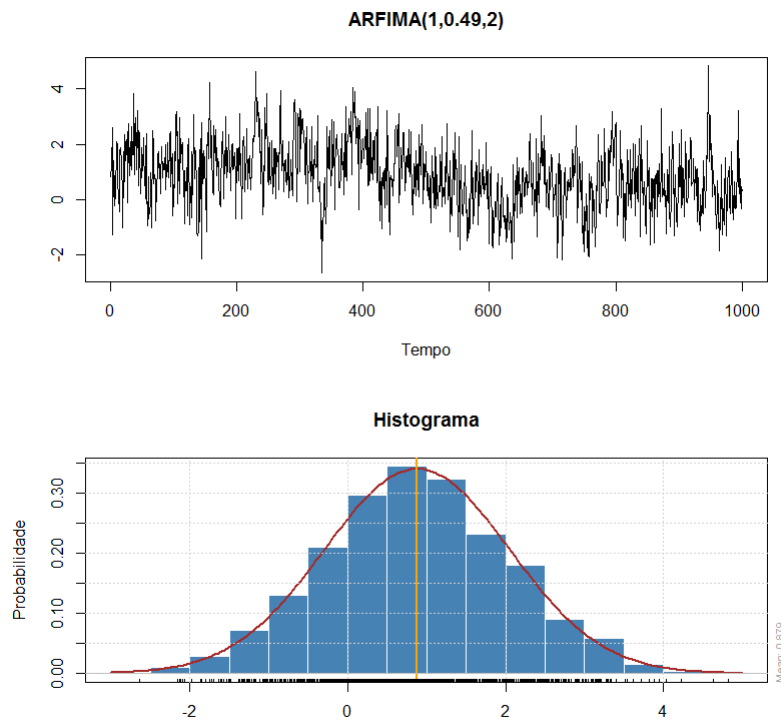


Figura 2.8: Simulação de um processo ARFIMA.
Fonte: [Veenstra \(2012\)](#). Elaborado pelo autor.

2.4.1.1 A função de autocorrelação

A função autocorrelação (FAC) apresenta-se como um relevante instrumento para análise de séries temporais devido ao fato de poder mensurar a interdependência de uma série temporal. A quantificação da dependência entre as instâncias de tempo da série é obtida por meio da autocovariância e/ou da autocorrelação amostral. A FAC na defasagem k ,

indicada por $\rho_{\hat{k}}$, é definida como

$$\rho_{\hat{k}} = \frac{\gamma_{\hat{k}}}{\gamma_{\hat{0}}} = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y}_t)(Y_{t+k} - \bar{Y}_t)}{\sum_{t=1}^n (Y_t - \bar{Y}_t)^2} \quad (2.29)$$

em que, $\gamma_{\hat{k}}$ é a covariância na defasagem k ($k = 0, 1, 2, \dots$); $\gamma_{\hat{0}}$ é a variância amostral, ao considerar séries estacionárias; e \bar{Y}_t é a média da série temporal.

De acordo com [Tsay \(2010, p. 31\)](#), a covariância e a variância apresentam as mesmas unidades de medida e, portanto, os valores de $\rho_{\hat{k}}$ são adimensionais, possuindo campo de variação entre -1 a 1, de modo que, i) $0 < \rho_{\hat{k}} \leq 1$ a série possui autocorrelação positiva; ii) $\rho_{\hat{k}} = 0$ não existe autocorrelação na série; e iii) $-1 \leq \rho_{\hat{k}} < 0$ a série possui autocorrelação negativa.

O correlograma é a representação gráfica das autocorrelações, no qual esboçam-se os primeiros valores $\rho_{\hat{k}}$ contra as defasagens k . Essa representação pode ser utilizada para a identificação de características de uma série temporal, como por exemplo, estacionariedade e o tipo de memória.

A significância estatística de qualquer $\rho_{\hat{k}}$ pode ser julgada por seu erro padrão. Segundo [Gujarati \(2000, p. 722\)](#), se uma série for puramente aleatória (subseção [2.4.1](#)), os coeficientes de autocorrelação amostral serão aproximadamente distribuídos normalmente com média zero e variância $1/N$, em que N é o tamanho da amostra. Então, ao seguir as propriedades da distribuição normal padrão, o intervalo de confiança de 95% para qualquer $\rho_{\hat{k}}$ será $\pm 1.96 * \frac{1}{\sqrt{N}}$, em ambos os lados de zero.

A [Figura 2.9](#) apresenta a simulação de alguns processos estocásticos e suas respectivas função de autocorrelação. Destacamos que as linhas tracejadas em azul nos correlogramas representam a significância estatística de qualquer $\rho_{\hat{k}}$.

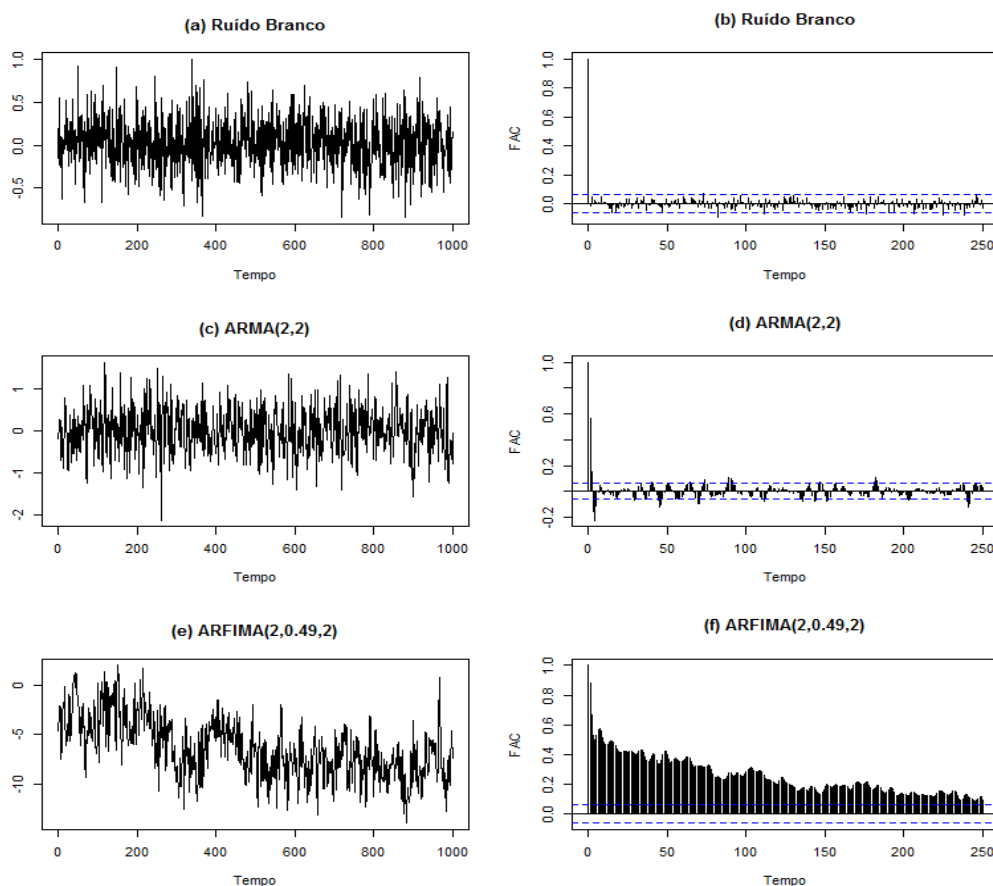


Figura 2.9: Simulação dos processos estocásticos: Ruído Branco (Figura 2.9 (a)), ARMA (Figura 2.9 (c)) e ARFIMA (Figura 2.9 (e)) e suas respectivas função de autocorrelação (Figura 2.9 (b), 2.9 (d) e 2.9 (f)). Fonte: Elaborado pelo autor.

É possível perceber na Figura 2.9 (b) que a função de autocorrelação do ruído branco decai rapidamente para zero indicando a inexistência de memória. Por outro lado, o correlograma da série do tipo ARMA - Figura 2.9 (d) - apresenta um decaimento rápido, com memória curta, enquanto a Figura 2.9 (f), correlograma da série ARFIMA, mostra um decaimento lento para zero, o que sinaliza memória longa.

Memória de Curto Alcance: Um processo estacionário é dito de memória curta se a respectiva função de autocorrelação $\hat{\rho}_{(\cdot)}$ satisfaz

$$|\hat{\rho}_{(k)}| \leq cr^k, \quad k = 0, 1, \dots, \tag{2.30}$$

onde c e r são duas constantes tais que $c > 0$ e $0 < r < 1$. Essa desigualdade indica que a função $\hat{\rho}_{(\cdot)}$ tende para o decaimento exponencial limitado por uma sucessão geométrica.

Memória de Longo Alcance: um processo estacionário é dito de memória longa se a respectiva função de autocorrelação $\hat{\rho}_{(\cdot)}$ verifica¹²

$$\hat{\rho}_{(k)} \sim ck^{2d-1}, k \rightarrow \infty, \quad (2.31)$$

onde c e d são duas constantes tais que $c > 0$ e $0 < d < 0.5$. Essa equação mostra que a função $\hat{\rho}_{(\cdot)}$ tende para zero muito lentamente com decaimento hiperbólico.

Por vezes, aplicam-se expressões memória longa antipersistente quando $d < 0$, dado que, $\sum_{k=-\infty}^{\infty} |\hat{\rho}_{(k)}| < \infty$ ou memória longa persistente quando $0 < d < 0.5$, dado que, $\sum_{k=-\infty}^{\infty} |\hat{\rho}_{(k)}| = \infty$.

Os modelos de memória longa são de grande relevância no estudo de séries reais e têm sido utilizados desde, pelo menos, os anos 50. As áreas de aplicação desses processos englobam a Hidrologia (HURST, 1951), economia (GRANGER, 1980), entre outras. Estes modelos com dependência de longo alcance são muitas vezes formulados em termos de processos autosimilares, que permitem extrapolar em escalas de tempo e distinguir o comportamento de longo alcance de um comportamento de curto alcance, o que é mais facilmente observado.

Para Diniz (2008), os processos autorregressivos de médias móveis, designados por ARMA (Section 2.4.1), constituem exemplos importantes de processos de memória curta enquanto processos do tipo ARFIMA são de memória longa. Os processos do tipo ruído branco são exemplos de séries descorrelacionadas.

Uma série temporal será considerada persistente se os valores adjacentes estiverem correlacionados positivamente. A série será considerada antipersistente se os valores adjacentes estiverem correlacionados inversamente, ou seja, se existir a tendência de valores grandes serem seguidos por valores pequenos ou vice-versa.

2.4.2 Detrended Fluctuation Analysis

Desenvolvido por Peng et al. (1994) para analisar sequências gênicas de DNA, o método *Detrended Fluctuation Analysis* (DFA) é um método de análise de escala utilizado para estimar expoentes que caracterizam as correlações de longo alcance em séries temporais não estacionárias.

¹²Mais geralmente, um processo estacionário diz-se um processo de memória longa se $\hat{\rho}_{(k)} \sim ck^{2d-1}\ell_1(k)$, $k \rightarrow \infty$, onde $\ell_1(\cdot)$ é uma função de variação lenta, isto é, para cada $a > 0$, $\ell_1(ak)/\ell_1(k) \rightarrow 1$, $k \rightarrow \infty$. (ver Palma (2007, p. 40))

O DFA tem sido modelado em análises de diferentes áreas do conhecimento, como por exemplo, Astronomia - no estudo do brilho das estrelas e de manchas solares - (Moret (2014), Zebende, Fernandez e Pereira (2017)); Segurança Pública - indicadores de criminalidade - (Filho, Silva e Zebende (2014)); Sinais biológicos e processamento de imagens (Peng et al. (1994), Stanley et al. (1999), Perazzo, Fernandez e Willshaw (2004), Diniz (2008), Galhardo et al. (2009), Almeida, Soares e Carvalho. (2013), Zebende, Oliveira-Filho e Leyva-Cruz (2017)) e Finanças - na avaliação da eficiência de mercado - (Carbone, Castelli e Stanley (2004), Alvarez-Ramirez et al. (2008), Alvarez-Ramirez, Alvarez e Rodriguez (2008), Lim, Brooks e Kim (2008), Sensoy e Hacihasanoglu (2014), Sensoy e Tabak (2016), Sukpitak e Hengpunya (2016), Ferreira e Dionisio (2017)).

A partir de uma série temporal discreta $Y_i = \{Y_1, \dots, Y_N\}$ de tamanho N , o passo inicial da modelagem pelo método DFA consiste em determinar o desvio de cada observação em relação a média \bar{Y} , conforme a Equação 2.32. Dessa forma, obtém-se a série integrada que será aqui denotada por $y_{(k)}$.

$$y_{(k)} = \sum_{i=1}^k (Y_i - \bar{Y}), \quad (2.32)$$

$$\bar{Y} = \frac{1}{N} \sum_{i=1}^N Y_i \quad (2.33)$$

A série integrada $y_{(k)}$ é dividida em intervalos (*box*) de igual comprimento n . Em cada intervalo de comprimento n , é ajustado um polinômio de grau ≥ 1 a série $y_{(k)}$. Esse ajuste representa a tendência local “ $y_n(k)$ ” no *box* de tamanho n obtida pelo método dos mínimos quadrados. Por conseguinte, a série integrada $y_{(k)}$ é subtraída da série ajustada $y_n(k)$ em cada intervalo de tamanho n . Após, para cada *box* de tamanho n será calculado a raiz quadrática média $F_{DFA(n)}$ denotada por

$$F_{DFA(n)} = \sqrt{\frac{1}{N} \sum_{k=1}^N [y_{(k)} - y_n(k)]^2}, \quad (2.34)$$

O cálculo supracitado é repetido para diferentes *boxes* de comprimento n , isto é, $4 \leq n \leq N/4$. Por último, verifica-se se a função $F_{DFA(n)}$ apresenta um comportamento ou não do tipo lei de potência¹³, ou seja,

¹³Na física, uma lei é dita lei de potência se entre dois escalares x e y é, tal que, a relação pode ser escrita na forma: $y = \alpha x^k$, onde α (α constante de proporcionalidade e k (o expoente) são constantes.

$$F_{DFA(n)} \sim n^{\alpha_{DFA}} \quad (2.35)$$

em que, o α_{DFA} será o indicador de correlação de longo alcance. Esse expoente é obtido por meio de uma relação linear entre o $\log F_{DFA(n)}$ e o $\log(n)$, de modo que, o α_{DFA} é o coeficiente de inclinação da reta. Assim, o α_{DFA} poderá apresentar os seguintes comportamentos:

- $0, 0 \leq \alpha_{DFA} < 0, 5$, em que a série é dita antipersistente;
- $\alpha_{DFA} = 0, 50$, ruído branco; e se
- $\alpha_{DFA} > 0, 5$, a série é dita persistente.

O DFA possibilita a detecção de correlações de longo alcance e auto-afinidade¹⁴ embutidas em séries aparentemente não estacionárias e também evita a detecção espúria de correlações de longo alcance (PREIS, 2011; ZEBENDE; FERNANDEZ; PEREIRA, 2017). Além disso, o expoente obtido é semelhante ao expoente de Hurst (1951), exceto que o DFA também pode ser aplicado a séries temporais cujas estatísticas subjacentes (como média e variância) ou dinâmica não sejam estacionárias (mudando com o tempo).

2.4.3 Detrended Cross-Correlation Analysis

Desenvolvido por Podobnik e Stanley (2008), o método *Detrended Cross-Correlation Analysis* (DCCA) é uma generalização do método DFA, que se propõe a estimar o expoente que caracteriza a correlação cruzada de longo alcance entre duas séries temporais não estacionárias de mesmo tamanho N .

O DCCA foi utilizado em análises de diversos campos do conhecimento, a exemplo de Astronomia - no estudo de manchas solares - (Hajian e Movahed (2010)); Sinais biológicos - no estudo de funções cerebrais - (Ursulean e Lazar (2009)); Transportes - no estudo do tráfego de passageiros e de veículos do sistema Ferry Boat e no estudo do tráfego rodoviário - (Zebende e Machado-Filho (2009), Xu, Shang e Kamae (2010)); Economia e Finanças - na análise das interações entre os mercados - (Podobnik et al. (2009), Lin, Shang e Zhao (2011)).

¹⁴Em matemática, a auto-afinidade se refere a um fractal cujas partes são diferentes na direção x , y e z . Isto significa que, para observar a auto-semelhança desse fractal, é necessário redimensioná-lo usando uma transformação anisotrópica. Já em uma série temporal existe auto-afinidade quando são mantidas as propriedades estatísticas observadas em diferentes escalas (FEDER, 1988).

Para proceder a aplicação do método DCCA, considere duas séries temporais não estacionárias $\{Y_i\}$ e $\{Y'_i\}$, em que $i = 1, 2, \dots, N$. Assim como no método DFA, essas séries serão integradas e, em seguida, representadas por $R_k = \{Y_1 + Y_2 + \dots + Y_K\}$ e $R'_k = \{Y'_1 + Y'_2 + \dots + Y'_K\}$, sendo $K = 1, 2, \dots, N$.

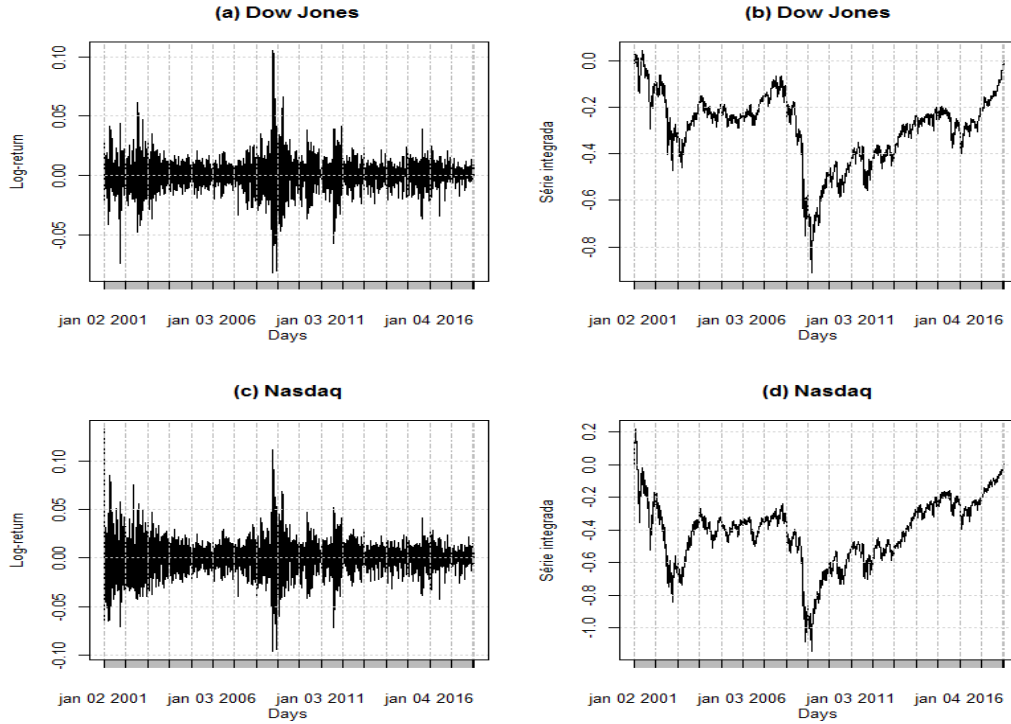


Figura 2.10: Rentabilidades e séries integradas dos mercados Dow Jones e Nasdaq - 02/janeiro/2001 a 16/janeiro/2018. Elaborado pelo autor.

As séries integradas R_k e R'_k são divididas em $N-n$ *boxes* de tamanho n com superposição, cada um contendo $n+1$ valores (Figura 2.11). Em cada *box* que inicia em i e termina em $i+n$, computam-se as tendências locais $\tilde{R}_{k,i}$ e $\tilde{R}'_{k,i}$ ($i \leq K \leq i+n$) como sendo a ordenada do ajuste linear obtida por Mínimos Quadrados (MQ) da série somada.

A partir do cálculo anterior, calcula-se a covariância dos resíduos em cada intervalo, isto é,

$$f_{DCCA}^2(n, i) = \frac{1}{n+1} \sum_{k=i}^{i+n} (R_k - \tilde{R}_{k,i})(R'_k - \tilde{R}'_{k,i}) \quad (2.36)$$

Determina-se a função de correlação (*detrended covariance*):

$$F_{DCCA}^2(n) = \frac{1}{N-n} \sum_{i=1}^{N-n} f_{DCCA}^2(n, i) \quad (2.37)$$




Figura 2.11: Divisão dos sinais integrados R_k e R'_k em $(N-n)$ boxes com superposição de tamanho $n=4$, cada um contendo $n+1$ valores. Fonte: [Silva-Filho \(2014\)](#).

O cálculo supramencionado é repetido para diferentes boxes de tamanho n , isto é, $4 \leq n \leq N/4$. Em seguida, verifica-se se a função $F_{DCCA}^2(n)$ apresenta um comportamento do tipo lei de potência

$$F_{DCCA(n)}^2 \sim n^{2\lambda_{DCCA}} \quad (2.38)$$

em que, o λ_{DCCA} será o indicador de correlação cruzada de longo alcance. Este expoente é obtido por meio de uma relação linear entre o $\log F_{DCCA}^2(n)$ e o $\log(n)$, de modo que, o λ_{DCCA} é o coeficiente de inclinação da reta.

Nesta tese, a hipótese EMH será avaliada na sua forma fraca por meio do método DFA (Subseção 2.4.2) e a hipótese de interdependência e de contágio será avaliada por meio da abordagem proposta por [Silva et al. \(2016\)](#), a qual inclui o coeficiente de correlação cruzada $\rho_{DCCA}(n)$ e o $\Delta\rho_{DCCA}(n)$ (Subseção 2.3).

Resultados

3.1 Janelas deslizantes para analisar ações bancárias da UE

Neste artigo, avaliamos dinamicamente a forma fraca de eficiência (Subseção 2.2) em 63 ações de bancos da União Europeia. Um mercado obedece à forma fraca de eficiência quando incorpora, integralmente, toda a informação contida em preços passados, somente.

A União Europeia é uma região que possui união econômica e política, sendo constituída por 28 países. Foi criada com o objetivo de por fim às frequentes guerras entre países, que culminaram na Segunda Guerra Mundial. Atualmente, é considerada como principal bloco comercial do mundo, o é o maior exportador mundial de bens e serviços e o maior mercado de importação para mais de 100 países.



Figura 3.1: União Europeia. Fonte: [Comissao-Europeia \(2018\)](#).

Aplicamos o método DFA (Subseção 2.4.2) com a abordagem de janela deslizante pro-

posta por [Almeida, Soares e Carvalho. \(2013\)](#). Com esta abordagem é possível obter várias subamostras sucessivas de uma série temporal e assim, mensurar a autocorrelação e identificar o tipo de comportamento em vários trechos da série.

Além do α_{DFA} é possível obter as características do dados, a exemplo de média, desvio padrão e os coeficiente de assimetria e curtose, a entropia de Shanon e até mesmo resultados de testes estatísticos como o JB ([Jarque e Bera \(1980\)](#)) e de raiz unitária ADF ([Fuller \(1996\)](#)).

Desafios superados: Para estar em conformidade com os padrões exigidos pelo periódico e, portanto, ser publicado, foram necessários revisões sucessivas contendo a inclusão de novas referências bem como a melhoria da resolução das figuras e a criação de uma tabela contendo as estatísticas descritivas (média, coeficientes de assimetria e curtose e do tamanho a amostra) de cada série temporal.



Contents lists available at ScienceDirect

Physica A

journal homepage: www.elsevier.com/locate/physa

A sliding windows approach to analyse the evolution of bank shares in the European Union



Paulo Ferreira^{a,b,c,*}, Andreia Dionísio^a, Everaldo Freitas Guedes^d,
Gilney Figueira Zebende^e

^a CEFAGE-UE, IIFA, Universidade de Évora, Largo dos Colegiais 2, 7000 Évora, Portugal

^b Departamento de Ciências Agrárias e Veterinárias, Escola Superior Agrária de Elvas, Instituto Politécnico de Portalegre, Portugal

^c Universidade Europeia, Laureate International Universities, 1500-210 Lisboa, Portugal

^d Computational Modeling Program, SENAI CIMATEC, Bahia, Brazil

^e Department of Physics, State University of Feira de Santana, Bahia, Brazil

HIGHLIGHTS

- We use DFA with sliding windows to analyse European Union Banks.
- We use two different crisis periods do compare the evolution of efficiency.
- Most banks changed from an anti-persistent to a persistent behaviour.
- Some Non-Eurozone banks show the same results than Eurozone banks.

ARTICLE INFO

Article history:

Received 12 April 2017

Received in revised form 19 July 2017

Available online 14 September 2017

Keywords:

Crisis

Detrended fluctuation analysis

Efficiency

Sliding windows

ABSTRACT

Both sub-prime and Eurozone debt crisis problems caused severe financial crisis, which affected European markets in general, but particularly the banking sector. The continuous devaluation of bank shares in the financial sector caused a great decrease in market capitalization, and in citizen and investor confidence. Panic among investors led them to sell shares, while other agents took the opportunity to buy them. Therefore, the study of bank shares is important, particularly of their efficiency. In this paper, adopting a sliding windows detrended fluctuation approach, we analyse the efficiency concept dynamically with 63 European banks (both in and outside the Eurozone). The main results show that the crisis had an effect on changing the efficiency pattern.

© 2017 Elsevier B.V. All rights reserved.

1. Introduction

Firstly, the sub-prime crisis and secondly, the Eurozone debt crisis caused turmoil in the European financial markets and particularly in the banking sector, due to many Eurozone banks' excessive exposure to public debt. Besides affecting the financial markets, that crisis also brought severe consequences for the economic wealth of European countries, mainly for those countries directly involved in excessive public debt (see, for example, [1] or [2], among others).

As a direct result of the crisis, the financial system as a whole came to be seen with some distrust by investors. Some banks suffered bankruptcy processes and those which remained in the market saw their share prices suffer severe devaluation. As

* Corresponding author at: CEFAGE-UE, IIFA, Universidade de Évora, Largo dos Colegiais 2, 7000 Évora, Portugal.

E-mail address: pjsf@uevora.pt (P. Ferreira).

Table 1

Bank shares and starting date.

Eurozone banks			Non-Eurozone banks		
Bank	Code	Start date	Bank	Code	Start date
ErsteGroupBank	AUT01	4-Jan-1999	Central CooperativeBank	BUL01	11-Oct-2000
KBC Group	BEL01	4-Jan-1999	KomercniBanka	CZE01	3-May-2004
Nordea Bank	FIN01	4-Jan-1999	Erste Group Bank	CZE02	3-May-2004
BNP Paribas	FRA01	4-Jan-1999	DanskeBank	DEN01	4-Jan-1999
SocieteGenerale	FRA02	4-Jan-1999	Nordea Bank	DEN02	19-Apr-2000
CreditAgricole	FRA03	14-Dec-2001	JyskeBank	DEN03	4-Jan-1999
Natixis	FRA04	4-Jan-1999	OTP Bank	HUN01	3-May-2004
DeutscheBank	GER01	4-Jan-1999	FHB	HUN02	3-May-2004
Commerzbank	GER02	4-Jan-1999	PKO Bank	POL01	9-Nov-2004
AlphaBank	GRE01	4-Jan-1999	BANK Pekao	POL02	3-May-2004
NationalBankofGreece	GRE02	4-Jan-1999	BankZachodni	POL03	3-May-2004
EurobankErgasias	GRE03	4-Jan-1999	MBank	POL04	3-May-2004
Bankof Piraeus	GRE04	4-Jan-1999	Banca Transilvania	ROM01	1-Jan-2007
BankofIreland	IRE01	4-Jan-1999	BRD Group	ROM02	1-Jan-2007
IntesaSanpaolo	ITA01	4-Jan-1999	Nordea Bank	SWE01	4-Jan-1999
Unicredit	ITA02	4-Jan-1999	Sewdbank	SWE02	4-Jan-1999
UnionediBancheltalian	ITA03	1-Jul-2003	Handelsbanken	SWE03	4-Jan-1999
Mediobanca	ITA04	4-Jan-1999	SEB	SWE04	4-Jan-1999
Banco Popolare	ITA05	4-Jan-1999	Lloyds	UK01	4-Jan-1999
Banca Popolare di Milano	ITA06	4-Jan-1999	HSBC	UK02	4-Jan-1999
Banca PPO EmiliaRomagna	ITA07	4-Jan-1999	RoyalBankScotland	UK03	4-Jan-1999
Banca Monte dei Paschi	ITA08	25-Jun-1999	StandardChartered	UK04	4-Jan-1999
Banca Mediolanum	ITA09	4-Jan-1999	Barclays	UK05	4-Jan-1999
IngGroep	NET01	4-Jan-1999	SiauliuBankas	LIT01	4-Jan-1999
BCP	POR01	4-Jan-1999	VseobecnaUverovaBanka	SLK01	4-Jan-1999
BPI	POR02	4-Jan-1999	OTP BankaSlovensko	SLK02	4-Jan-1999
Banco Santander	SPA01	4-Jan-1999			
BBVA	SPA02	4-Jan-1999			
Banco Sabadell	SPA04	18-Apr-2001			
Banco Popular Español	SPA05	4-Jan-1999			
Bankinter	SPA06	4-Jan-1999			
BankofCyprus	CYP01	2-Jan-2008			
HellenicBank	CYP02	2-Jan-2008			
BankofValletta	MAL01	2-Jan-2008			
HSBC Bank Malta	MAL02	2-Jan-2008			
Fimbank	MAL03	2-Jan-2008			
LombardBank	MAL04	2-Jan-2008			

usual, in these cases some agents try to seize the opportunity to gain profits in their investment strategies. In this aspect, it is interesting to analyse how shares behave, aiming to determine their continuous efficiency.

The financial literature contains many studies on the efficiency of financial markets. After the seminal work of Fama [3,4] devoted to the efficiency of financial markets, when he identified the Efficiency Market Hypothesis (EMH), many studies analysed the behaviour of stock markets. The development of econometric and statistical methodologies also led to the appearance of many studies, some devoted to general markets (for example, using stock market indices), others dedicated to specific sectors.

Regarding the particular case of the banking sector, the study by Ferreira [5] is probably the only example of more recent work. In this study, the author analysed the cross-correlations between Eurozone banks and the respective national stock markets. Dividing the sample before and after the Eurozone crisis, the author found that most of the banks changed their correlations with national indices. More than half of the analysed banks showed an increase in the correlation, interpreted as an increase in market risk, if another crisis occurs.

With data about Eurozone banks, here we perform a different analysis. We will continue to observe the evolution of the efficiency of European bank stocks, which will enable us to analyse whether both crises had any effect on the efficiency pattern of those shares. In this context, we use Detrended Fluctuation Analysis (DFA), because its exponent is able to capture the existence of long-term memory of a given time series. According to theory, financial assets should not show any kind of memory, so this methodology is suitable for the purpose. Because we want to analyse the continuous existence of efficiency, we apply a sliding windows analysis.

As explained in the next section, some studies apply DFA sliding windows, but none to this specific topic, which makes this study innovative. Furthermore, the study is important because banking is one of the most important economic sectors, as the recent European crisis proved.

Therefore, this paper is organized as follows: Section 2 presents the methodology and data used in our analysis, Section 3 shows the results, and Section 4 concludes the paper.

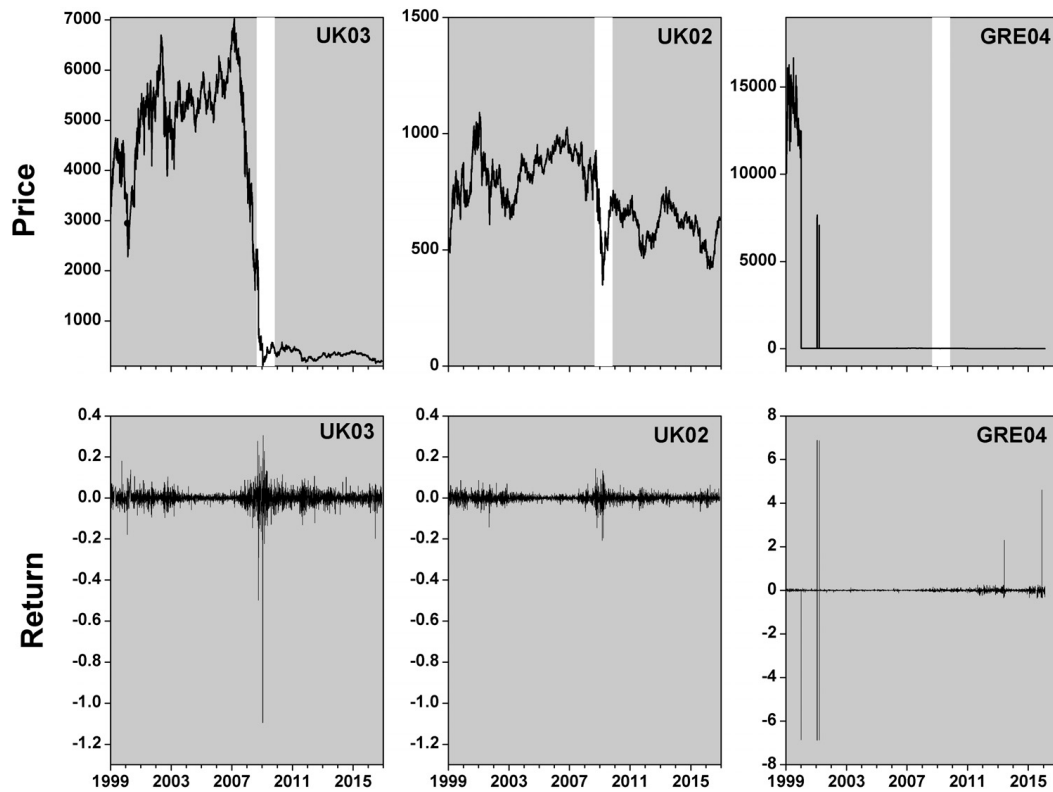


Fig. 1. Time series of the prices for Royal Bank Scotland (UK03), HSBC (UK02), and Bank of Piraeus (GRE04), in the top figure. The bottom figure presents the return of the price for UK03, UK02, and GRE04. The dashed area (top figure) represents the period between the sub-prime crisis (09/15/2008) and the beginning of the Eurozone crisis (10/20/2009).

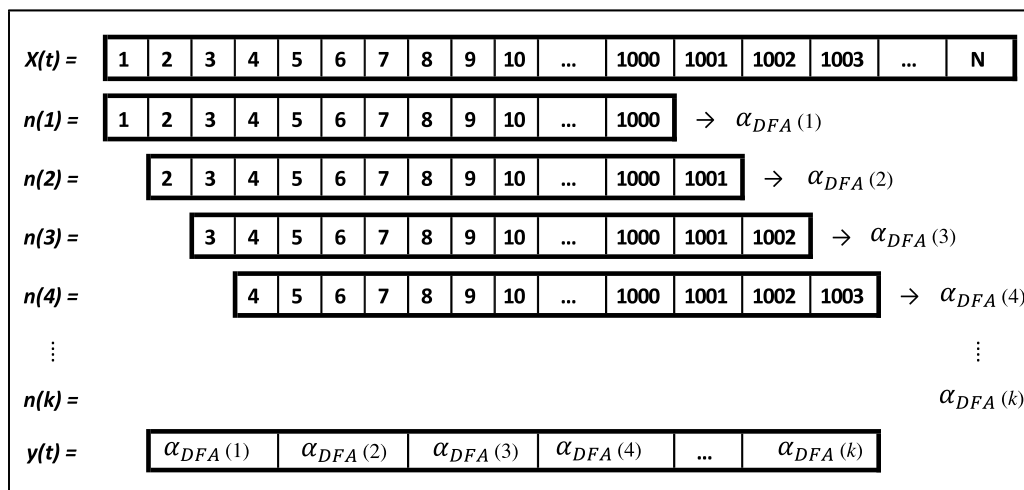


Fig. 2. Exemplification of the sliding windows procedure.

2. Methodology and data

The objective of this paper is to analyse, dynamically, the efficiency of European banks and identify whether both crises had an effect on the behaviour of that efficiency. We were able to retrieve data from 66 banks, from 23 countries (the remaining EU countries do not have banks listed in their stock indices). Due to the non-availability of data, we eliminate three, the Austrian Raiffeisen Bank, because data starts only on 26th April 2005, the Spanish Caixabank, whose data starts on 11th October 2007, and the Bulgarian Fibank, whose data starts on 3rd September 2007.

Table 1 presents the list of banks used in this paper, where the second column represents the code applied for each one, and the last column shows the starting date of the time series. Although banks have different sample dimensions, we decided to keep all the banks under analysis. As the methodology used allows the continuous evaluation of time series dependence

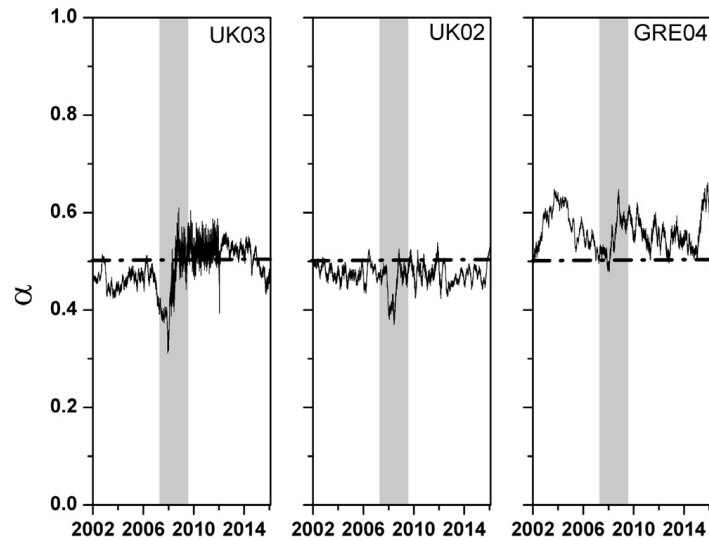


Fig. 3. Evolution of the DFA exponent (sliding windows with 1000 observations) as a function of time for Royal Bank Scotland (UK03), HSBC (UK02), and Bank of Piraeus (GRE04). The horizontal axis represents the time (in days). The dashed area represents the time between the crises.

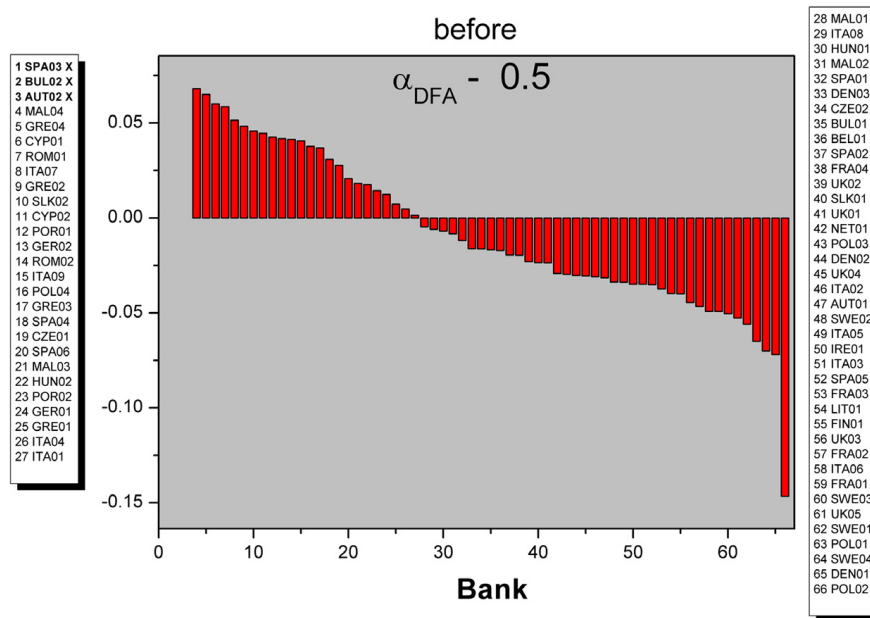


Fig. 4. The value of $\alpha - 0.5$ (test of the efficiency hypothesis) for all banks before the crisis. SPA05, BUL02, and AUT02 have no data for this period.

over time, the use of different samples is not a problem. The left of Table 1 shows banks that belong to Eurozone countries with non-Eurozone banks on the right.

In Tables A.1 and A.2 from the appendix, it is possible to find some descriptive statistics for all the banks, namely the mean, skewness, kurtosis, the coefficient of variation (given by the ratio between standard deviation and mean) and the number of observations. It is possible to see that most of the Eurozone banks suffered losses during the sample under analysis, contrarily from what happens in non-Eurozone banks. Greek banks were those with higher mean losses. The coefficient of variation is a relative measure of dispersion. For this indicator, most of the banks show higher levels, which is relatively expected in turmoil moments. Regarding skewness, most indices show a negative value, which means that more extremely negative outcomes occurred than positive ones. The kurtosis levels are over the limits of the expected for a normal distribution, which is a common feature in the financial literature.

Assuming that the weak form of efficiency is based on the historical independence of returns, we base our analysis on DFA, a method proposed by Peng et al. [6], originally to analyse DNA behaviour. This method has been widely used in other research areas, including finance. There have been several applications to this research field, with several types of data: stock indices (see, for example, [7] or [8]), exchange rates (see [9] among others), derivatives (see, for example, [10,11]), specific markets such as football [12] or technology [13], among other examples. Although, it is possible to find several applications

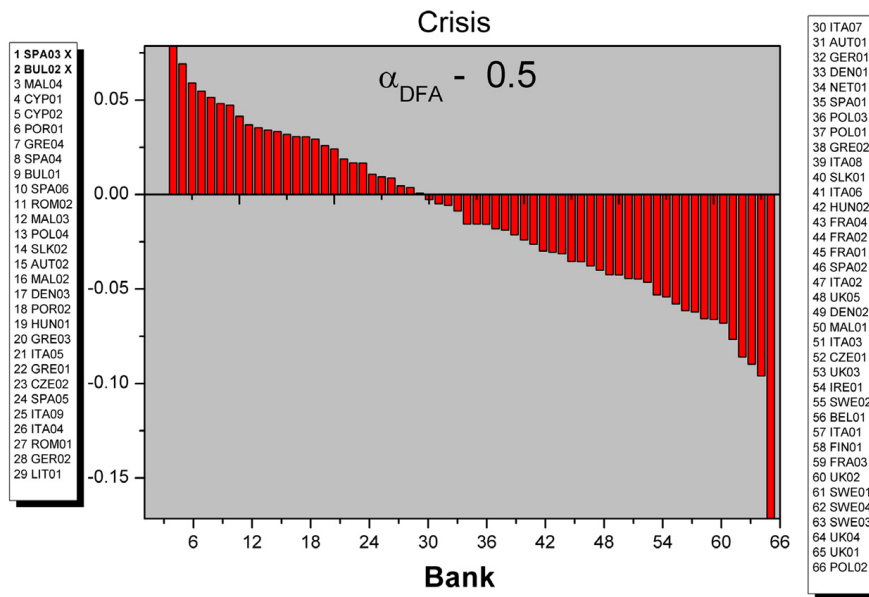


Fig. 5. The value of $\alpha-0.5$ (test of the efficiency hypothesis) for all banks during the crisis. SPA05, and BUL02 have no data for this period.

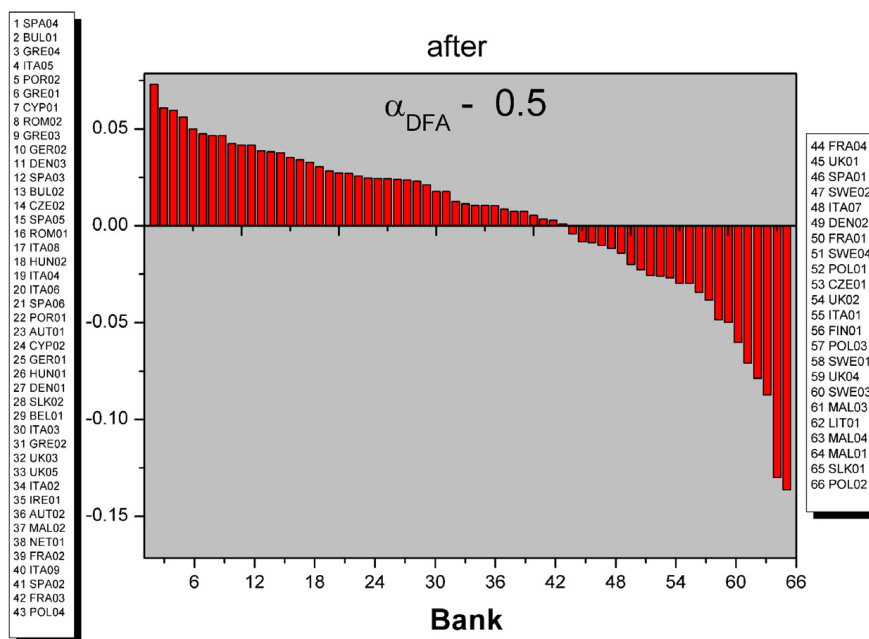


Fig. 6. The value of $\alpha-0.5$ (test of the efficiency hypothesis) for all banks after the crisis.

not related with economics or finance (see, for example, the study of Machado et al. [14], applied to criminology). In fact, DFA is part of several methodologies used originally in physics, which were then used in economics and finance. The huge amount of literature using these methodologies was responsible for creating a new field of research called Econophysics.

Given the number of studies on the subject, it would be extremely difficult to give an entire notion about the state-of-the-art. A thorough review of the literature in this field can be found, for example, in [15], [16], [17] or [18]. We will focus only on recent work, since our goal in this paper is to apply sliding windows in the time series of returns of European bank share prices.

Fig. 1 shows, as an example, the time series (shares) of three banks and their respective returns, defined by $r(t) \equiv \ln(P_t) - \ln(P_{t-1})$. Here P_t is the price of the share at time t .

From Fig. 1, we can see that a deeper study of these non-stationary data is quite appropriate. Thus, considering a time series of return $r(t)$, with $t = 1, \dots, N$ equidistant observations, the DFA method was chosen for data analysis.

The first step of DFA is the integration of return, i.e., $x(k) = \sum_{t=1}^k r(t) - \langle r \rangle$, being $\langle r \rangle$ the average of r (see, for example, [14]). This new series is divided in N/s mutual exclusive boxes of equal dimension s and, for each segment i , the trend $z_i(t)$

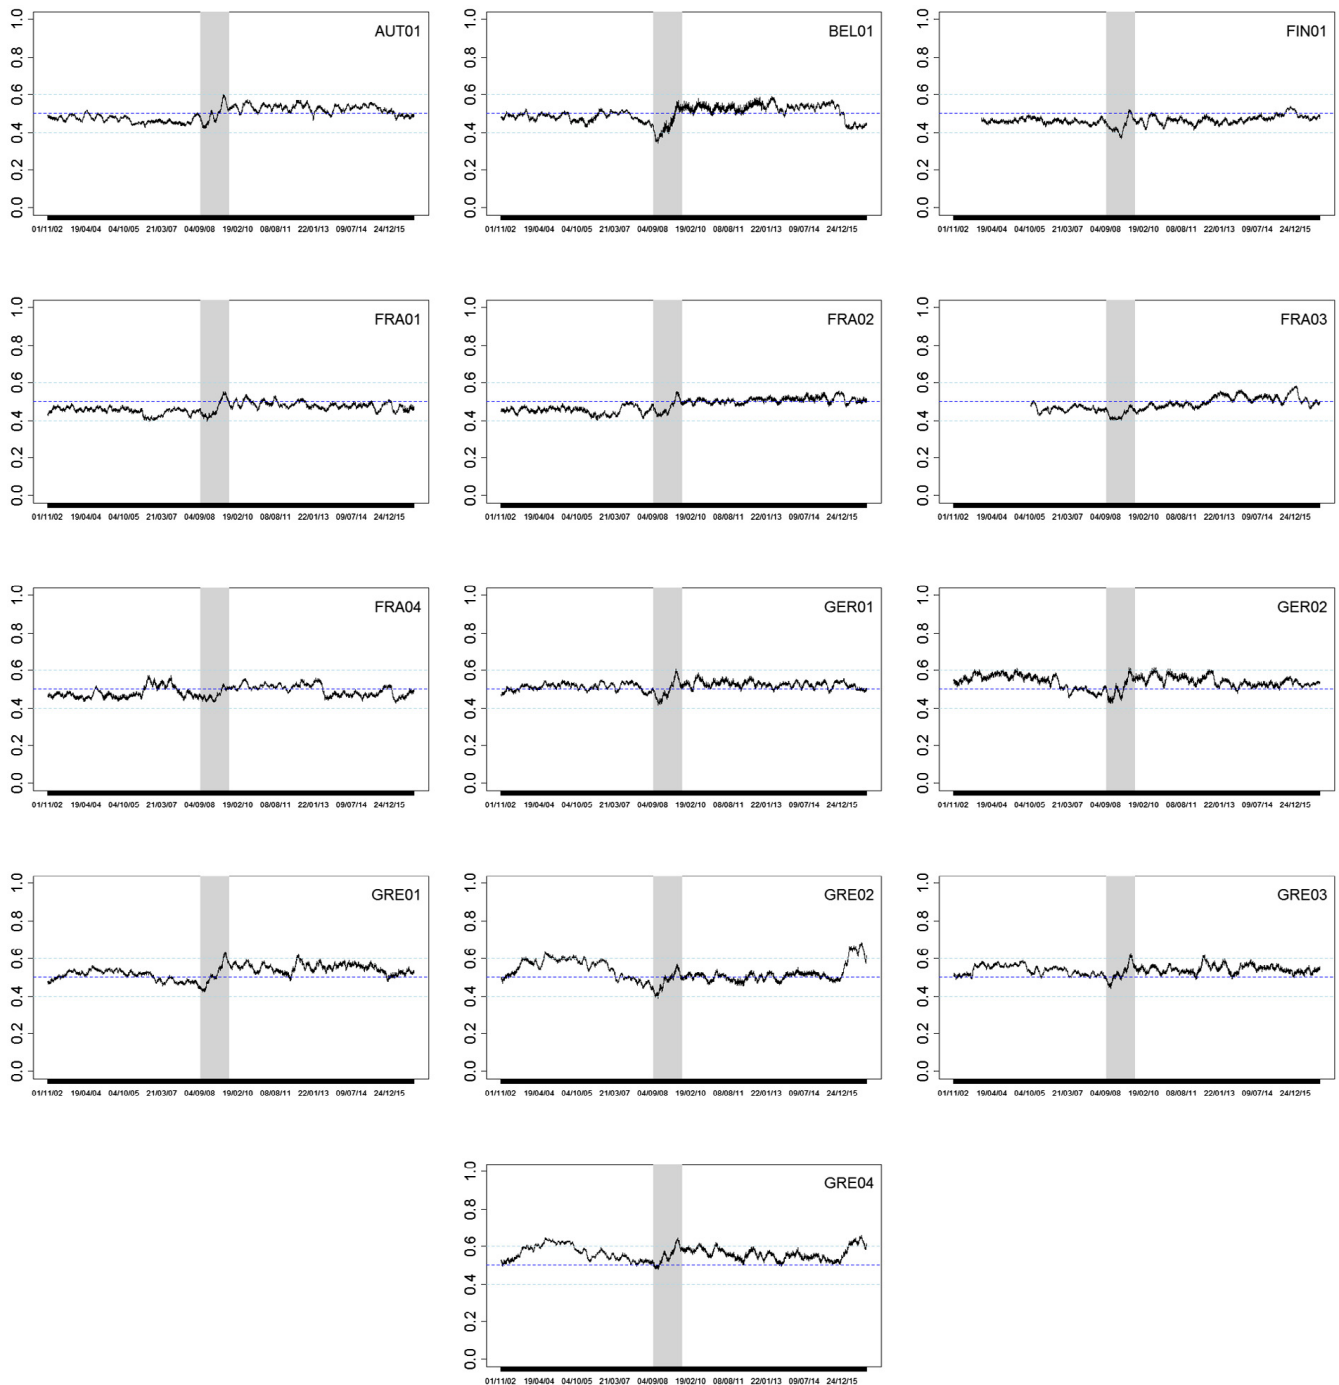


Fig. A.1. Evolution of the exponent of the DFA method with sliding windows for Austrian, Belgian, Finnish, French, Greek and German banks. In the vertical axis we have the Hurst exponent. The horizontal axis represents the time (in days). The shaded area represents the time between both crises.

is obtained with an ordinary least squares estimation, used to detrend the previous series, e.g., $x_s(t) = x(k) - z_i(t)$. This allows calculation of the DFA function given by $F(s) = \sqrt{\frac{1}{N} \sum_{t=1}^N [x_s(t)]^2}$. This procedure is repeated for all different values of s (box), and the results show a power-law behaviour, $F(s) \propto s^\alpha$. The long-range power-law exponent α gives information about the efficiency of the time series. If $\alpha = 0.5$, the time series is represented by a random walk, which means that it has no long memory, if $0.5 < \alpha < 1$, the time series is persistent (has a positive long-range dependence), and if $\alpha < 0.5$, the time series is anti-persistent (has a negative long-range dependence). Financial theory argues that efficient assets should behave like a random walk (no memory). Note that it is possible to find $\alpha > 1$, which means that a given process is non-stationary. Although not common in the analysis of financial returns, it could be verified in other research fields (see, for example, [19] or [20]).

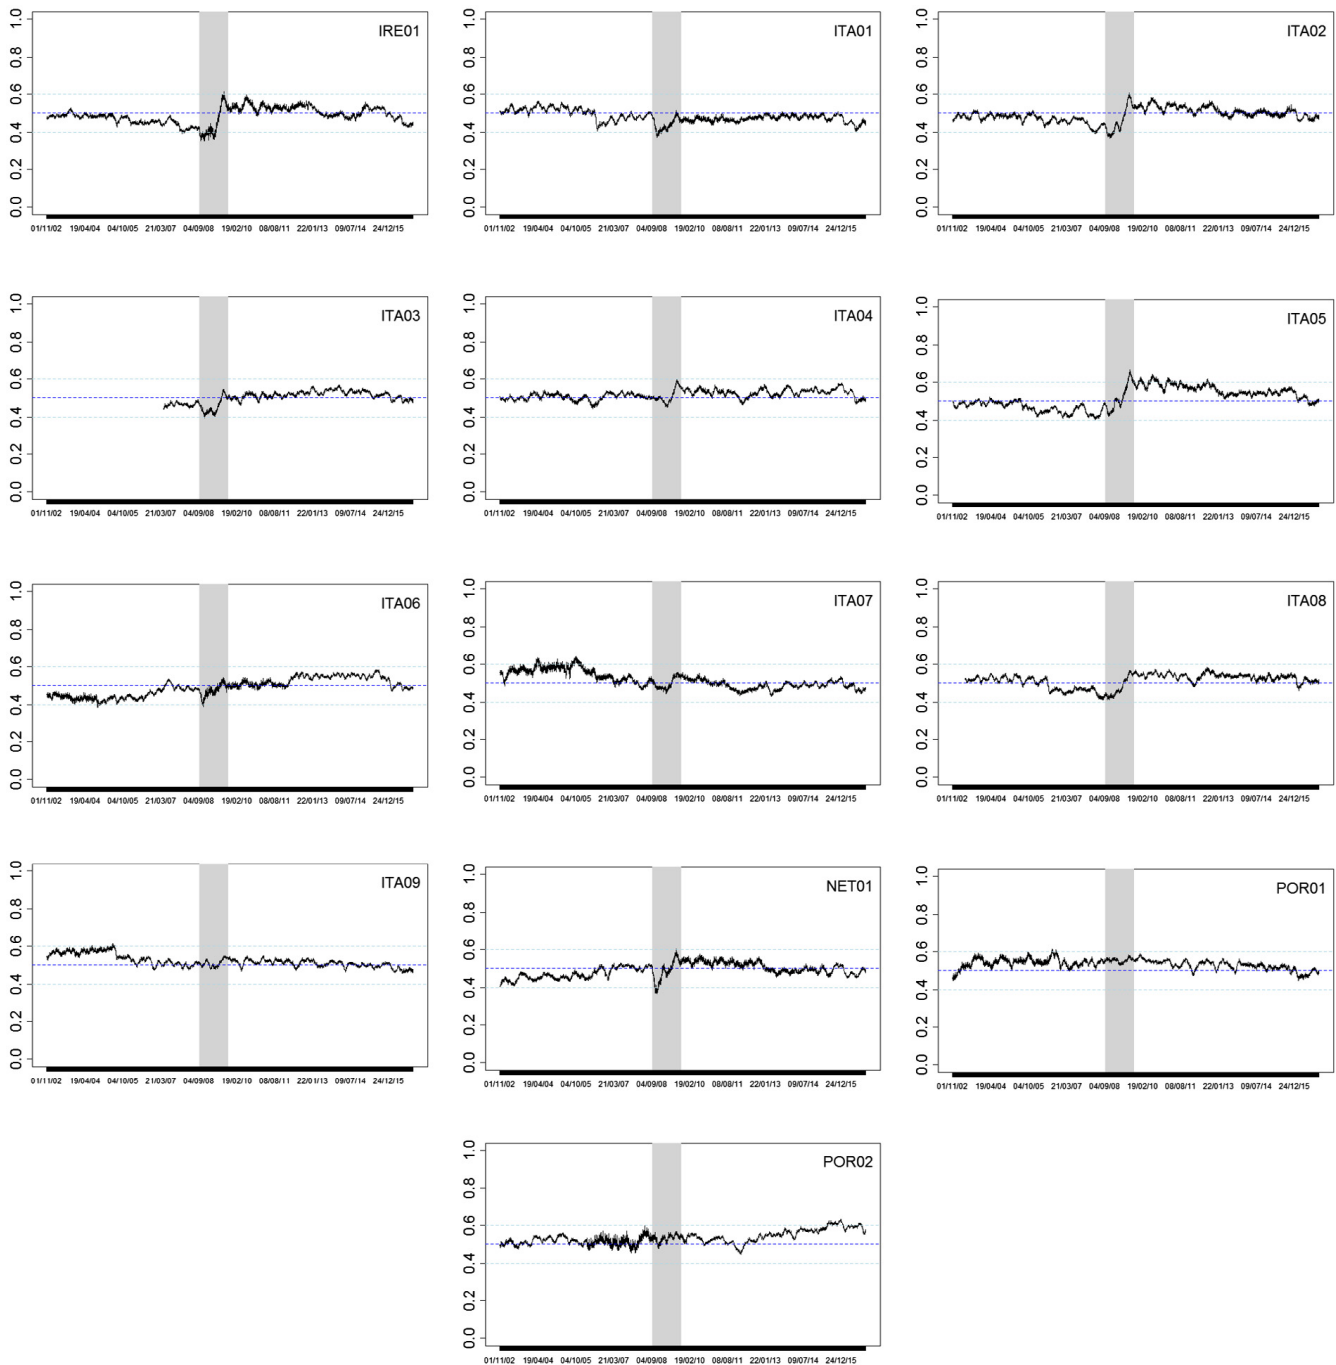


Fig. A.2. Evolution of the exponent of the DFA method with sliding windows for Irish, Italian, Dutch and Portuguese banks. In the vertical axis we have the Hurst exponent. The horizontal axis represents the time (in days). The shaded area represents the time between both crises.

As our objective is to analyse efficiency dynamically, we will calculate not the static DFA, but with a sliding windows approach. This approach is relatively common in the financial literature, because it provides a dynamic analysis of efficiency. Some applications to stock markets can be seen in [21–24] and others, but it has never been applied to bank data.

The application of sliding windows will smooth trend signal and eliminate the discontinuities in the detrended signal (see, for example, [25]). Furthermore, it will allow us to analyse the evolution of the Hurst exponent, i.e., the level of dependence, over time. The fact that we have to limit the size of windows could be understood as a limitation, because it just covers a part of the sample.

The calculations were based on a window of 1000 observations (about 4 years), which is the most common value (see, for example, [26]). This means that we start analysing the α exponent from $t = 1, \dots, 1000$. Next, we apply the DFA from $t = 2, \dots, 1001, t = 3, \dots, 1002$, and so on, as described in Fig. 2.

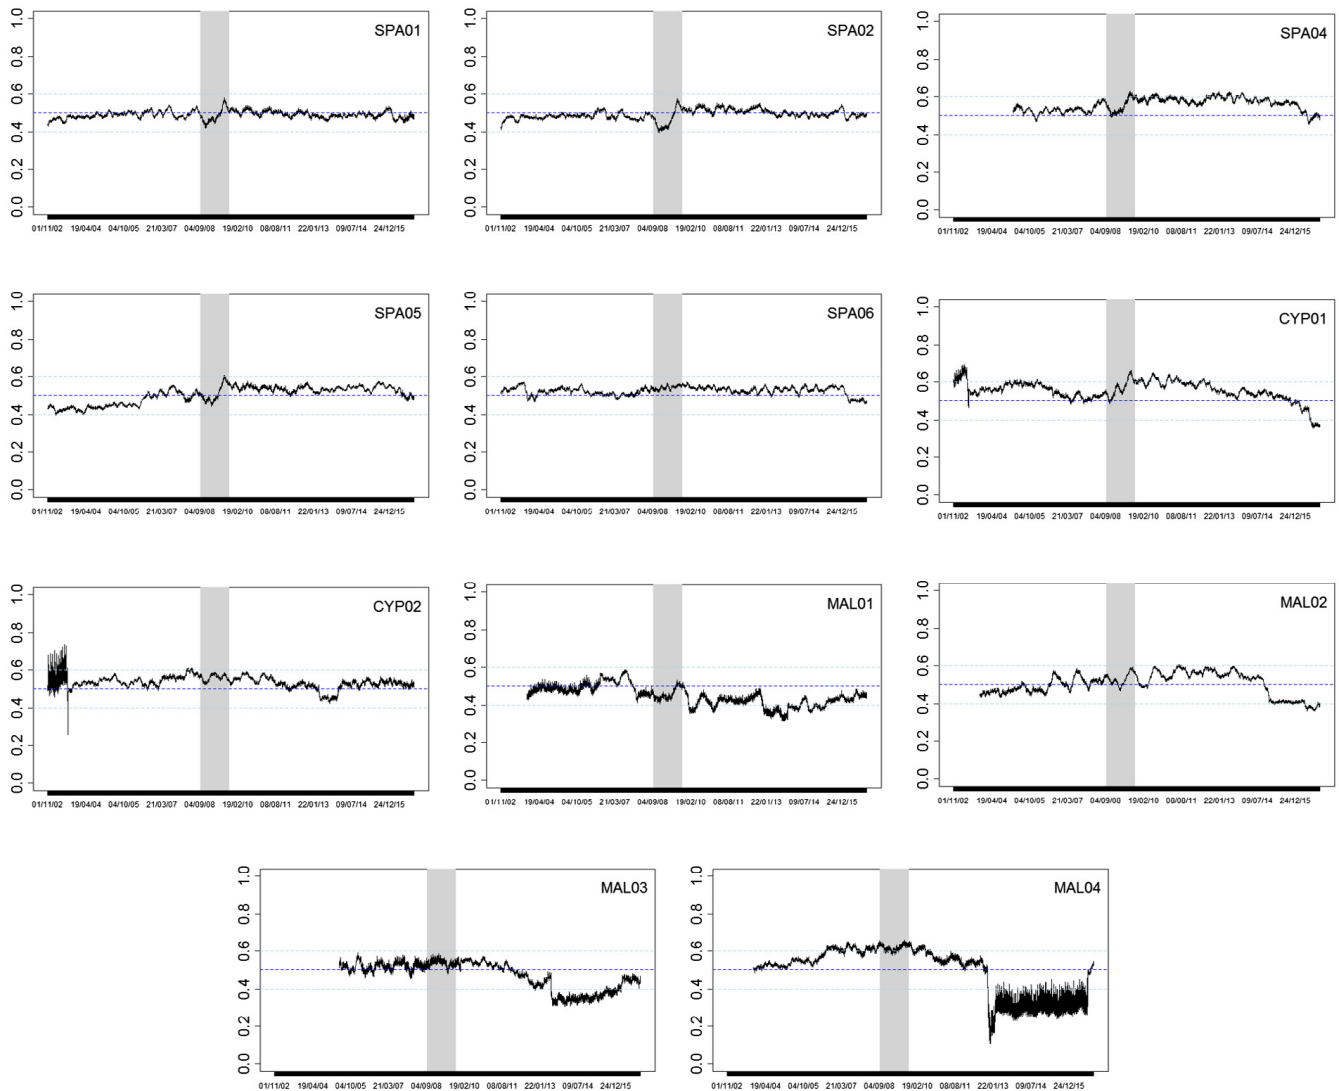


Fig. A.3. Evolution of the exponent of the DFA method with sliding windows for Spanish, Cypriot and Maltese banks. In the vertical axis we have the Hurst exponent. The horizontal axis represents the time (in days). The shaded area represents the time between both crises.

With this procedure we have a wide set of exponents, as in Fig. 3. We estimated all exponents α for the 63 banks, and these are presented in Appendix.

3. Results

Now, thinking in terms of the recent economic crises, the dynamic DFA exponents for our 63 Eurozone banks can be present in three different moments, the period:

- (i) Before the beginning of the sub-prime crisis;
- (ii) Between the end of (i) and the beginning of the Eurozone crisis (15/09/2008 to 20/10/2009);
- (iii) After 20/10/2009.

Considering market efficiency, Figs. 4–6 present the results for DFA sliding windows (average in a respective period) for all 63 banks. Because we are testing the efficiency hypothesis, we define $eff \equiv \alpha - 0.5$, meaning that:

$$\begin{aligned}
 eff > 0 & \quad \text{share with persistent behaviour;} \\
 eff = 0 & \quad \text{share with no memory;} \\
 eff < 0 & \quad \text{share with anti – persistent behaviour.}
 \end{aligned}$$

Note that eff is only valid when DFA exponents range from 0 to 1, which is usual in financial data, and happens for all our exponents.

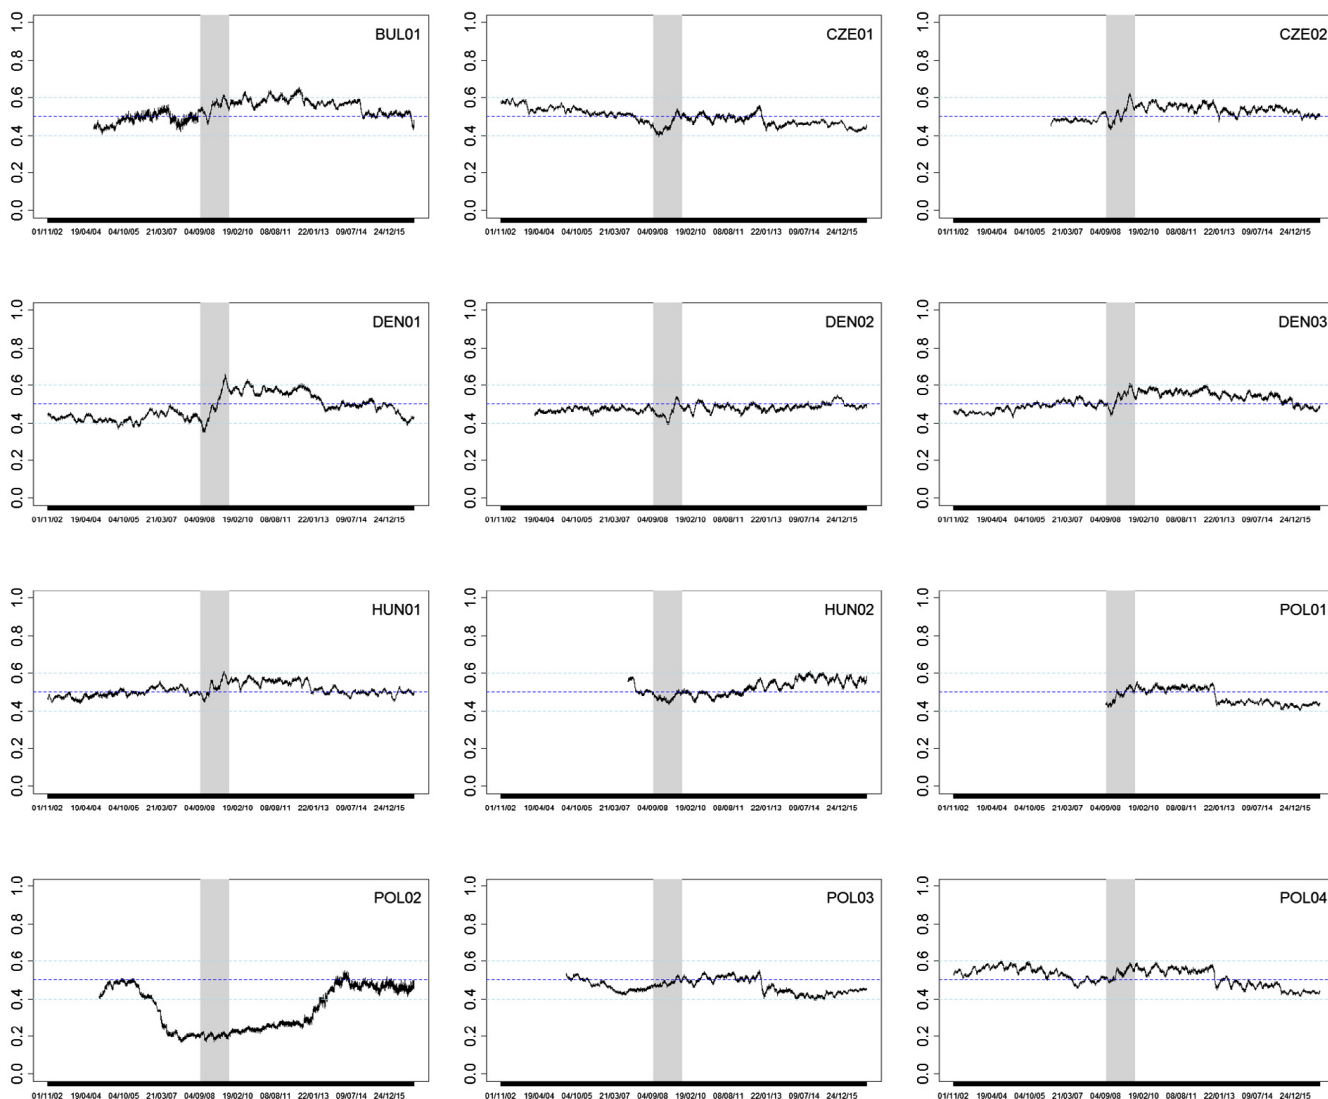


Fig. A.4. Evolution of the exponent of the DFA method with sliding windows for Bulgarian, Czech, Danish, Hungarian and Polish banks. In the vertical axis we have the Hurst exponent. The horizontal axis represents the time (in days). The shaded area represents the time between both crises.

Thus, for each time period, we take the average value of $\alpha - 0.5$ (efficiency hypothesis) and we place these values in descending order in Figs. 4–6.

Therefore, it is now possible to identify which banks have the greatest deviations from zero (no-memory level). For clarity, we placed on the left of these figures banks that had a persistent value, $\alpha > 0.5$, while on the right of the figure we have banks with $\alpha < 0.5$.

Interestingly, we can see there is a clear shift between the α exponents, that is, the order in which the banks appear depends specifically on the time period. Regarding the Eurozone banks, most of them had highly instable coefficients between the crises, because the value of $\alpha_{DFA} - 0.5 \neq 0$. It is even possible to find an increase of exponents over time, with several banks, for example, changing from an anti-persistent behaviour (right of Fig. 4) to a persistent one (left of Fig. 6).

Almost all countries have banks showing this behaviour and this happens in countries which were subject to financial intervention (for example, Cyprus, Greece, Ireland and Spain), but also in countries without this problem (Austria, Belgium, France, Germany, Italy and the Netherlands). The remaining three Eurozone countries studied do not have evidence of that pattern in any bank: Finland, Malta and Portugal, curiously as the last-named was subject to financial intervention. But if for example Finland and Portugal show some stability, in the case of Maltese banks, all of them show great instability in the exponents and all became anti-persistent after the Eurozone crisis.

These results complement the previous conclusions of Ferreira [5]. In that study, the author finds that most of the banks show, after the crisis, an increase in the relationship with the national stock, and argues that this could be seen as a risky pattern. The fact that after the crisis many banks constantly show persistent behaviour could also be seen as risky. In fact, persistence means that a given result is more likely to be repeated, which in the case of a crisis or a decrease in share prices could mean that in the future this could happen again.

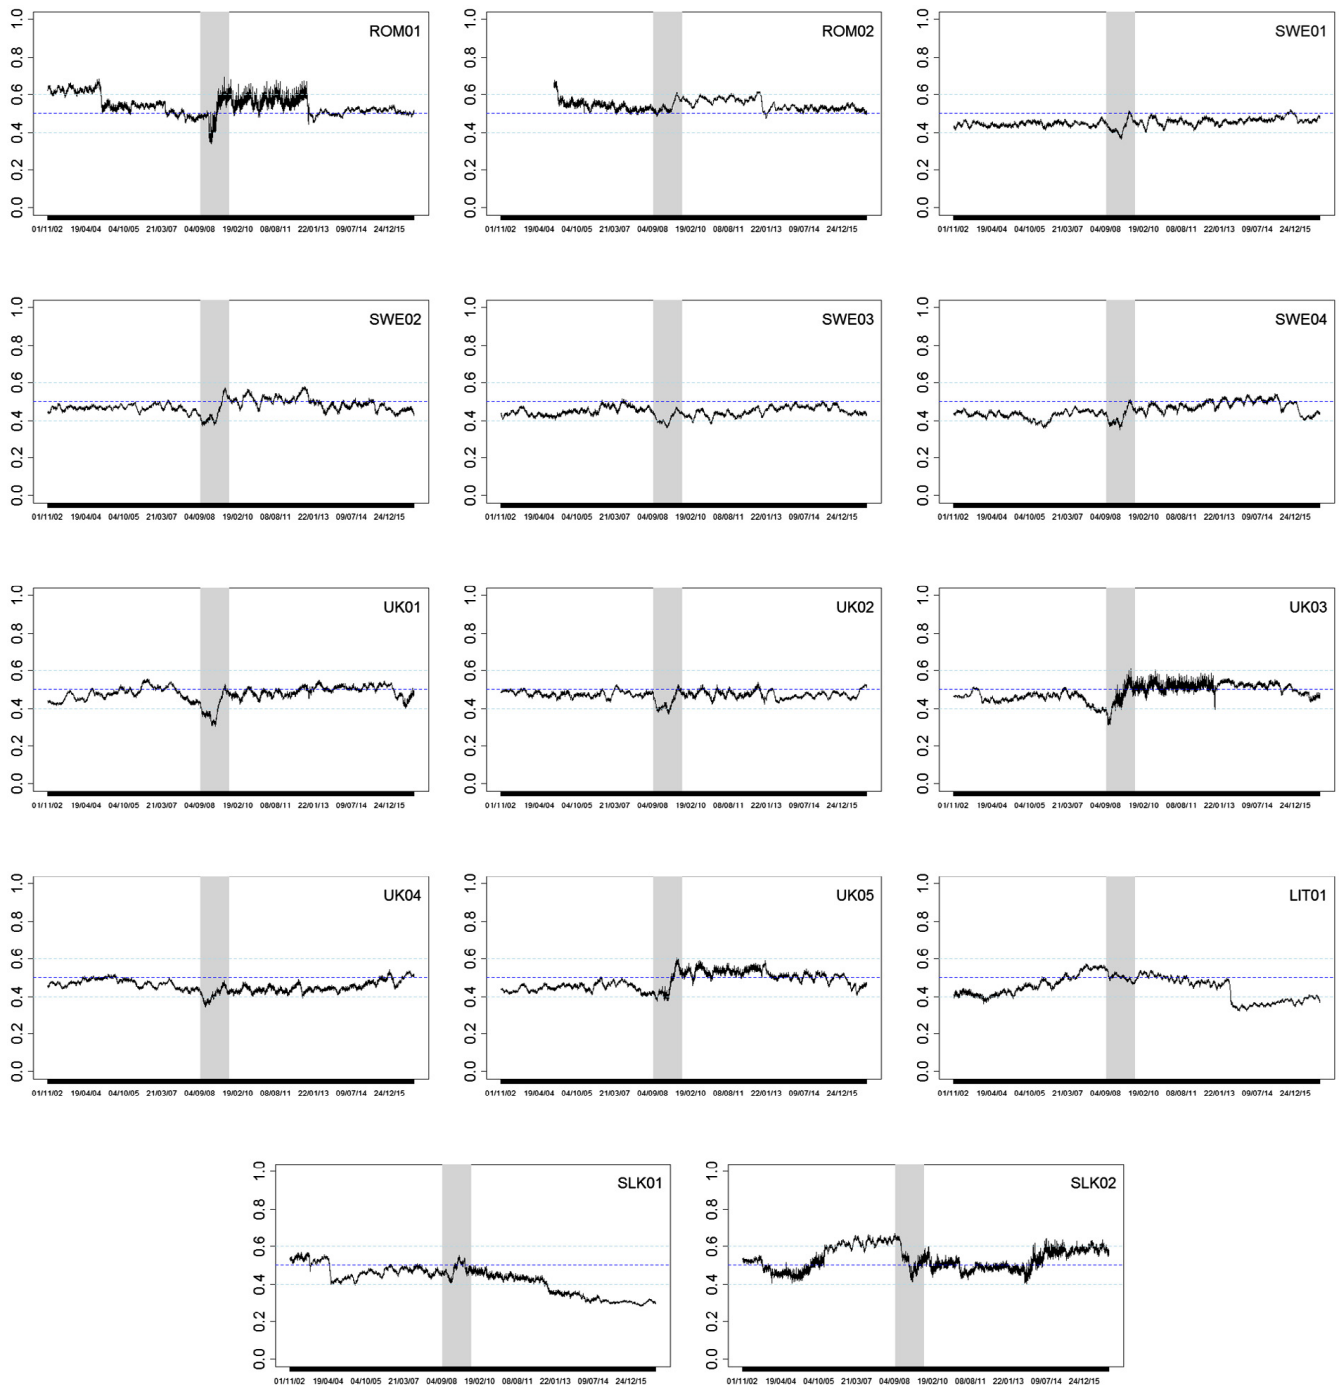


Fig. A.5. Evolution of the exponent of the DFA method with sliding windows for Romanian, Swedish, British, Lithuanian and Slovakian banks. In the vertical axis we have the Hurst exponent. The horizontal axis represents the time (in days). The shaded area represents the time between both crises.

Besides the increase of the coefficients in most banks over time, another interesting fact is that at the end of the sample, for Eurozone banks most of the shares became more centred on the zero level, which means they tend to be efficient (see Figs. A.1–A.3). Some exceptions are the Belgian bank, one French bank, two Greek banks, one Italian bank, one Portuguese bank, one Cypriot bank and Maltese banks. However, for some of these banks market conditions could explain the behaviour: Greece continues to be subject to financial aid; Italian and Portuguese financial systems are also “under fire” (in fact, after the end of the sample, one of the Portuguese banks was sold) and Cyprus and Malta have a high share of financial services in their economies.

Generally, it is possible to conclude that the crises had impacts on the dynamics of bank share efficiency in Europe. Firstly, the crisis led to some instability in the DFA coefficients, mainly causing some persistence in share returns which, complemented with the results of Ferreira [5], shows that it could have increased the risk levels in financial systems.

Table A.1
Descriptive statistics for Eurozone banks.

Bank code	Mean	Skewness	Kurtosis	Coeff. variation	n
AUT01	0.0002	−0.272	7.619	130.06	4675
BEL01	0.0000	−0.044	20.482	−833.25	4675
FIN01	0.0002	0.302	6.036	123.44	4394
FRA01	0.0001	0.157	8.308	235.33	4675
FRA02	0.0001	−0.092	7.040	451.04	4675
FRA03	−0.0001	0.200	6.477	−297.22	3906
FRA04	0.0001	0.569	16.020	258.80	4675
GER01	−0.0002	0.166	7.760	−109.81	4675
GER02	−0.0007	−0.064	8.461	−41.08	4675
GRE01	−0.0010	−0.230	11.309	−39.85	4675
GRE02	−0.0019	−1.140	14.148	−23.45	4675
GRE03	−0.0022	−0.752	12.381	−21.92	4675
GRE04	−0.0022	−1.075	13.761	−20.98	4675
IRE01	−0.0007	−1.281	44.239	−57.95	4675
ITA01	−0.0002	−0.260	7.065	−153.40	4675
ITA02	−0.0005	−0.226	7.928	−49.65	4675
ITA03	−0.0005	−0.248	5.190	−48.17	3504
ITA04	−0.0001	−0.245	6.746	−198.71	4675
ITA05	−0.0007	−0.177	6.885	−40.60	4675
ITA06	−0.0004	−0.236	7.876	−66.19	4675
ITA07	−0.0002	−0.180	11.674	−135.10	4675
ITA08	−0.0013	0.000	14.625	−23.79	4551
ITA09	0.0000	0.123	3.380	−18 406.07	4675
NET01	−0.0001	−0.044	13.292	−298.38	4675
POR01	−0.0010	0.239	7.743	−26.26	4675
POR02	−0.0002	0.722	9.753	−95.37	4675
SPA01	0.0000	−0.073	7.696	−595.20	4675
SPA02	−0.0001	0.128	6.048	−172.48	4675
SPA04	−0.0002	0.294	11.392	−93.63	4078
SPA05	−0.0006	−0.260	12.886	−38.29	4675
SPA06	0.0001	0.450	4.066	157.73	4675
CYP01	−0.0005	2.639	55.499	−53.84	4675
CYP02	−0.0005	23.508	1128.512	−70.70	4675
MAL01	0.0001	0.864	65.277	141.37	4413
MAL02	0.0000	−0.186	8.157	624.87	4413
MAL03	0.0001	0.578	148.759	112.00	4026
MAL04	0.0001	−5.131	778.671	124.78	4413

However, the last coefficients show some stability around the value considered as a sign of efficiency. Probably, the worst of the financial system crisis has passed.

Regarding non-Eurozone banks (Figs. A.4 and A.5), some of them show the pattern previously described, an increase of the exponent. That pattern can be seen in the following cases: the Bulgarian bank analysed, the Czech banks, two Danish banks, one Romanian bank, one Swedish bank and two British banks. The similarity of results, in terms of financial structure and these countries' financial integration with Eurozone countries, is found in previous studies (see, for example, [27,28] or [29]). For the remaining countries, the Hungarian banks show some stability in their exponents while banks of Poland, Lithuania and Slovakia have no defined patterns, showing great instability. The fact that economic and financial systems are different in these countries could explain the differences.

Finally, and now looking specifically at Figs. 3 and 5, it is noted that after both crises, there is a smaller number of banks showing anti-persistence (fewer banks on the left of the figure). Furthermore, and comparing both figures, just five banks changed from persistent to anti-persistent behaviour (ITA 07, CZE01, ITA01, MAL03 and MAL04). The remaining changes were in the opposite direction. Moreover, after the Eurozone crisis, most of the anti-persistent shares are in non-Eurozone countries. Another interesting result is the fact that the most inefficient shares (i.e., those which are more distant from the no-memory level) are mostly non-Eurozone banks. Once again, this could be interpreted as a good sign for the stability of the common currency.

4. Conclusions

During the last decade, the world in general and the European Union in particular experienced two different crises: first the sub-prime crisis, originating in the United States, and secondly the Eurozone debt crisis, which had severe effects on the foundations of the common currency, but also on the financial system in general and the banking system in particular.

Aiming to study continuously the dynamics of bank share efficiency, we performed a sliding windows DFA, allowing us to understand how banks behave, regarding efficiency, before both crises, in the period between the crises and after the start of the second crisis. Without finding a definite pattern, some general results arise. Firstly, after the sub-prime crisis, most banks

Table A.2

Descriptive statistics for non-Eurozone banks.

Bank code	Mean	Skewness	Kurtosis	Coeff. variation	n
BUL01	0.0005	0.777	24.037	59.91	4213
CZE01	0.0006	-0.215	9.121	39.82	4675
CZE02	0.0001	-0.437	11.150	204.95	3698
DEN01	0.0002	-0.086	5.988	96.91	4675
DEN02	0.0001	0.270	6.144	141.88	4337
DEN03	0.0004	0.074	5.413	49.55	4675
HUN01	0.0004	-0.047	6.291	56.40	4675
HUN02	0.0000	0.170	8.948	749.84	3399
POL01	0.0000	-0.045	2.858	473.26	3148
POL02	0.0002	1.020	68.440	349.56	4161
POL03	0.0005	0.042	2.597	44.26	4024
POL04	0.0003	-0.030	4.107	71.83	4675
ROM01	0.0009	-7.916	257.925	31.03	4675
ROM02	0.0003	-1.313	32.180	77.20	4144
SWE01	0.0002	0.266	5.168	113.30	4675
SWE02	0.0001	-0.201	9.315	173.27	4675
SWE03	0.0003	0.133	5.480	70.41	4675
SWE04	0.0002	0.070	10.626	134.30	4675
UK01	-0.0004	-0.957	36.507	-69.06	4675
UK02	0.0001	-0.258	11.784	288.24	4675
UK03	-0.0005	-7.800	248.973	-62.16	4675
UK04	0.0000	0.228	9.203	800.27	4675
UK05	-0.0001	1.079	37.537	-434.02	4675
LIT01	0.0002	0.185	18.292	112.17	4675
SLK01	0.0004	-1.712	23.210	72.30	4675
SLK02	-0.0002	-1.226	170.074	-252.59	4675

changed from anti-persistent to persistent behaviour. This could have an influence in the future, because a given pattern of returns is more likely to be repeated. Another interesting result is that some non-Eurozone banks showed a similar effect to Eurozone ones, a result that complements the evidence in other papers. A conclusion can be drawn, because after the debt crisis, most banks are now near to the efficiency level, which could be a good indicator of a stable financial system.

Further papers should focus on studying the efficiency behaviour of stocks around the crisis periods, in order to understand if there is any general behaviour that could give the authorities some information about the possibility of certain events, including possible crashes associated with bubbles.

Acknowledgements

Paulo Ferreira and Andreia Dionísio are pleased to acknowledge financial support from Fundação para a Ciência e a Tecnologia (grant UID/ECO/04007/2013) and FEDER/COMPETE (POCI-01-0145-FEDER-007659). Everaldo Guedes thanks the FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia) (Grant BOL 0976/2016) and Gilney Zebende thanks the CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) (Grant 309288/2013-4), Brazilian agencies.

Appendix

See Tables A.1 and A.2.

References

- [1] S. Ardagna, F. Caselli, The political economy of the greek debt crisis: A tale of two bailouts, *Amer. Econ. J.: Macroecon.* 6 (4) (2014) 291–323.
- [2] V. Acharya, S. Steffen, The “greatest” carry trade ever? Understanding eurozone bank risks, *J. Financ. Econ.* 115 (2) (2015) 215–236.
- [3] E. Fama, Mandelbrot and the stable paretian hypothesis, *J. Bus.* 36 (4) (1963) 420–429.
- [4] E. Fama, Efficient capital markets: A review of theory and empirical work, *J. Finance* 25 (1970) 383–417.
- [5] P. Ferreira, Does the euro crisis change the cross-correlation pattern between bank shares and national indexes, *Physica A* 463 (2016) 320–329.
- [6] C. Peng, S. Buldyrev, S. Havlin, M. Simons, E. Stanley, A. Goldberger, Mosaic organization of DNA nucleotides, *Phys. Rev. E* 49 (1994) 1685–1689.
- [7] G. Cao, M. Zhang, Extreme values in the Chinese and American stock markets based on detrended fluctuation analysis, *Physica A* 436 (15) (2015) 25–35.
- [8] P. Anagnostidis, C. Varsakelis, C. Emmanouilides, Has the 2008 financial crisis affected stock market efficiency? The case of Eurozone, *Physica A* 447 (2016) 116–128.
- [9] J. López, J. Contreras, Performance of multifractal detrended fluctuation analysis on short time series, *Phys. Rev. E* 87 (2013) 022918.
- [10] Y. Wang, Y. Wei, C. Wu, Analysis of the efficiency and multifractality of gold markets based on multifractal detrended fluctuation analysis, *Physica A* 390 (5) (2011) 817–827.
- [11] Y. Wang, Y. Wei, C. Wu, Detrended fluctuation analysis on spot and futures markets of West Texas Intermediate crude oil, *Physica A* 390 (5) (2011) 864–875.
- [12] P. Ferreira, L. Loures, J. Nunes, A. Dionísio, The behaviour of share returns of football clubs: An econophysics approach, *Physica A* 472 (2017) 136–144.
- [13] P. Ferreira, Apple, alphabet or microsoft: which is the most efficient share? *Econom. Res. Finance* 1 (2) (2016) 67–79.

- [14] A. Machado, M. Silva, G. Zebende, Autocorrelation and cross-correlation in time series of homicide and attempted homicide, *Physica A* 400 (2014) 12–19.
- [15] M. Gallegati, Beyond econophysics (not to mention mainstream economics), *Eur. Phys. J. Spec. Top.* 225 (17–18) (2016) 3179–3185.
- [16] F. Jovanovic, C. Schinckus, Breaking down the barriers between econophysics and financial economics, *Int. Rev. Financ. Anal.* 47 (2016) 256–266.
- [17] C. Schinckus, 1996–2016: Two decades of econophysics: Between methodological diversification and conceptual coherence, *Eur. Phys. J. Spec. Top.* 225 (17) (2016) 3299–3311.
- [18] E. Pereira, M. Silva, H. Pereira, Econophysics: Past and present, *Physica A* 473 (2017) 251–261.
- [19] J. Walleczel, *Self-Organized Biological Dynamics and Nonlinear Control: Toward Understanding Complexity, Chaos and Emergent Function in Living Systems*, first ed., Cambridge University Press, Cambridge, 2000.
- [20] C. Galhardo, T. Penna, M. Menezes, P. Soares, Detrended fluctuation analysis of a systolic blood pressure control loop, *New J. Phys.* 11 (2009) 103005 2009.
- [21] D. Cajueiro, B. Tabak, The Hurst exponent over time: Testing the assertion that emerging markets are becoming more efficient, *Physica A* 336 (3–4) (2004) 521–537.
- [22] D. Cajueiro, B. Tabak, Evidence of long range dependence in Asian equity markets: The role of liquidity and market restrictions, *Physica A* 342 (3–4) (2004) 656–664.
- [23] D. Cajueiro, B. Tabak, Testing for predictability in equity returns for European transition markets, *Econ. Syst.* 30 (1) (2006) 56–78.
- [24] D. Cajueiro, B. Tabak, Testing for time-varying long-range dependence in real estate equity returns, *Chaos Solitons Fractals* 38 (1) (2008) 293–307.
- [25] D. Almeida, F. Soares, J. Carvalho, A sliding window approach to detrended fluctuation analysis of heart rate variability, in: 35th Annual International Conference of the IEEE EMBS, 2013.
- [26] A. Carbone, G. Castelli, H. Stanley, Time dependent Hurst exponent in financial time series, *Physica A* 344 (2004) 267–271.
- [27] P. Ferreira, A. Dionísio, C. Pires, Adopt the Euro? The GME approach, *J. Econ. Interact. Coord.* 5 (2) (2010) 231–247.
- [28] P. Ferreira, A. Dionísio, G. Zebende, Why does the Euro fails? The DCCA approach, *Physica A* 443 (2016) 543–554. <http://dx.doi.org/10.1016/j.physa.2015.10.013>.
- [29] P. Ferreira, A. Dionísio, Revisiting covered interest parity in the European Union: the DCCA approach, *Int. Econ. J.* 29 (4) (2015) 597–615. <http://dx.doi.org/10.1080/10168737.2015.1081260>.

Desafios superados: Para estar em conformidade com os padrões exigidos pelo periódico e, portanto, ser publicado, foram necessários revisões sucessivas contendo a inclusão de novas referências, do inglês bem como a melhoria da introdução e das conclusões.



DCCA cross-correlation in blue-chips companies: A view of the 2008 financial crisis in the Eurozone



E. Guedes^a, A. Dionísio^b, P.J. Ferreira^{b,c,d}, G.F. Zebende^{e,*}

^a Computational Modeling Program of SENAI CIMATEC, Bahia, Brazil

^b CEFAGE-UE, IIFA, University of Évora, Portugal

^c Escola Superior Agrária de Elvas, Instituto Politécnico de Portalegre, Portugal

^d Universidade Europeia, Portugal

^e Department of Physics, State University of Feira de Santana, Bahia, Brazil

HIGHLIGHTS

- We analyze by DCCA cross-correlation coefficient the blue-chips companies in the Eurozone.
- With the DCCA coefficient, we qualify and quantify how each blue-chip is adherent to its country index.
- From this analysis, we can construct an adhesion map of each company with respect to the global index.

ARTICLE INFO

Article history:

Received 13 October 2016

Received in revised form 27 January 2017

Available online 6 March 2017

Keywords:

Financial crisis

Eurozone

Blue-chips

DCCA cross-correlation coefficient

Econometric

ABSTRACT

In this paper we analyze the blue-chips (up to 50% of the total index) companies in the Eurozone. Our motivation being analysis of the effect of the 2008 financial crisis. For this purpose, we apply the DCCA cross-correlation coefficient (ρ_{DCCA}) between the country stock market index and their respective blue-chips. Then, with the cross-correlation coefficient, we qualify and quantify how each blue-chip is adherent to its country index, evaluating the type of cross-correlation among them. Subsequently, for each blue-chip, we propose to study the 2008 financial crisis by measuring the adherence between post and pre-crisis. From this analysis, we can construct an adhesion map of each company with respect to the global index. Our database is formed of 12 Eurozone countries.

© 2017 Elsevier B.V. All rights reserved.

1. Introduction

The economy can be understood as a complex system. Complex systems are dynamic, non-linear, adaptive, not-deterministic, and can create emergent behavior with self organized criticality [1–4]. Knowing that we have economic data as a time series, one way to study those time series is by trying to understand auto and cross-correlations arising from these systems [5]. Considering that in general, the relations that move financial markets are still mysterious, cross-correlation analysis between financial time series can be of great importance in understanding the links between these different markets [6–10].

When we have different financial time series, it is possible to analyze their individual behavior. For example, this analysis allow us to identify the dependence of a given time series. This could be done through linear or non-linear approaches. [11]

* Corresponding author.

E-mail address: gfbende@hotmail.com (G.F. Zebende).

applied different methodologies for this purpose. In the presence of many series, it is possible to study the relationship between them. In this particular context, one possible topic of study is the analysis of market integration between those series. The occurrence of market integration could have some consequences. Clearly, it means that the considered assets are more related. Increase market integration could have positive impacts on economies, namely on growth and on better allocation of savings, due to specialization (see, for example, [12] or [13]). In the context of the analysis between individual shares and the respective indexes, it means that the behavior of both series become more similar. This feature implies the reduction of diversification possibilities which could be understood as an increase in risk (see, for example, [14]).

Using data from 12 of the 19 Eurozone countries, we analyze the cross-correlation between Eurozone blue-chips and the respective national index. The sample was divided into before and after the Euro debt crisis. The objective is to analyze how the blue-chips behave between these two different periods. A decrease in the correlation implies that the blue-chips and the index are less integrated. On the contrary, an increase in the correlation implies that the individual share is more integrated with the respective market which, as previously referred, could be risky.

The Eurozone indexes used are the following:

- **Austria—ATX** Vienna Stock Exchange Index, is a major stock market index which tracks the performance of all companies listed in Austria, representing around 60% of Austrian stock trade.
- **Belgium—BEL20** is the benchmark stock market index of Euronext Brussels. It tracks the performance of the 20 most capitalized and liquid stocks traded in Belgium.
- **Finland—OMX Helsinki** is a major stock market index which tracks the performance of the 25 most heavily traded companies in the Helsinki Stock Exchange. It limits each company to a maximum weight of 10%.
- **France—CAC40** the most widely used indicator of the Paris market, reflects the performance of the 40 largest equities listed in France, measured by free-float market-capitalization and liquidity.
- **Germany—DAX30** German Stock Index, is a total return index of 30 selected German blue-chip stocks traded on the Frankfurt Stock Exchange. The equities use free float shares in the index calculation.
- **Greece—ATHEX** Athens Stock Exchange General Index, is a major stock market index which tracks the performance of Greece stocks listed on the Athens Stock Exchange.¹
- **Ireland—ISEQ20** Ireland Stock Exchange Overall Index (ISEQ), is a major stock market index which tracks the performance of all (excluding UK registered) companies listed on the Irish Stock Exchange.
- **Italy—FTSEMIB30** is a major stock market index which tracks the performance of the 40 leading and most liquid and companies listed in Milano (Italy).
- **Luxembourg—SELUXX** The LuxX Price is the main stock market index of the Luxembourg Stock Exchange, the stock exchange based in Luxembourg City, in southern Luxembourg.
- **Netherlands—AEX** is a major stock market index, which tracks the performance of the leading stocks traded on the Amsterdam Exchange.
- **Portugal—PSI20** Portuguese Stock Index, is a benchmark stock market index which tracks the performance of the 20 companies with the largest market capitalization and share turnover in the Euronext Lisbon Stock Exchange.
- **Spain—IBEX35** is a benchmark stock market index which tracks the performance of the 35 most liquid stocks traded on the Continuous market in Madrid (Spain).

The paper is organized as follows. In Section 2, we apply the methodology, in Section 3 we show data and results, while in Section 4 presents the conclusions. References and Appendix are found at the end of the paper.

2. Methodology

Initially, we take the closing index of the Eurozone countries as a function of time. In Fig. 1 the period is divided into three parts, which are:

- Before—from the start of Eurozone (January/01/1999) to December/31/2007, with 2346 observations;
- 2008—for the whole of 2008, with 262 observations. It includes the moments associated with the Lehman Brother crisis;
- After—from January/01/2009 to March/11/2016, with 1877 observations.

Independent of the country, the index in 2008 (red line) shows a great decline, which justified our choice of the crisis period (see Fig. 1). We can see in this figure that Germany (DAX) was the only country to recover the pre-crisis index value. For Greece (ATHEX) and Portugal (PSI-20) the indexes are still in decline. Note that these two countries suffered severe crisis, requiring international financial aid. Other countries, like Belgium (BEL-20), France (CAC-40), and Ireland (ISEQ) show an increase in the post-crisis.

We know that each index is composed of a set of companies that reflect the most heavily traded ones on the respective stock exchange. On this list there are also the blue-chips, companies with greater importance for the final value of the index, with excellent reputation, high liquidity and high degree of reliability [9]. In this paper we will consider as blue-chips the set of companies with 50% of the index (see Table 3).

¹ Greece only joined the Euro formally in 2001. However, it is used from the beginning of the sample.

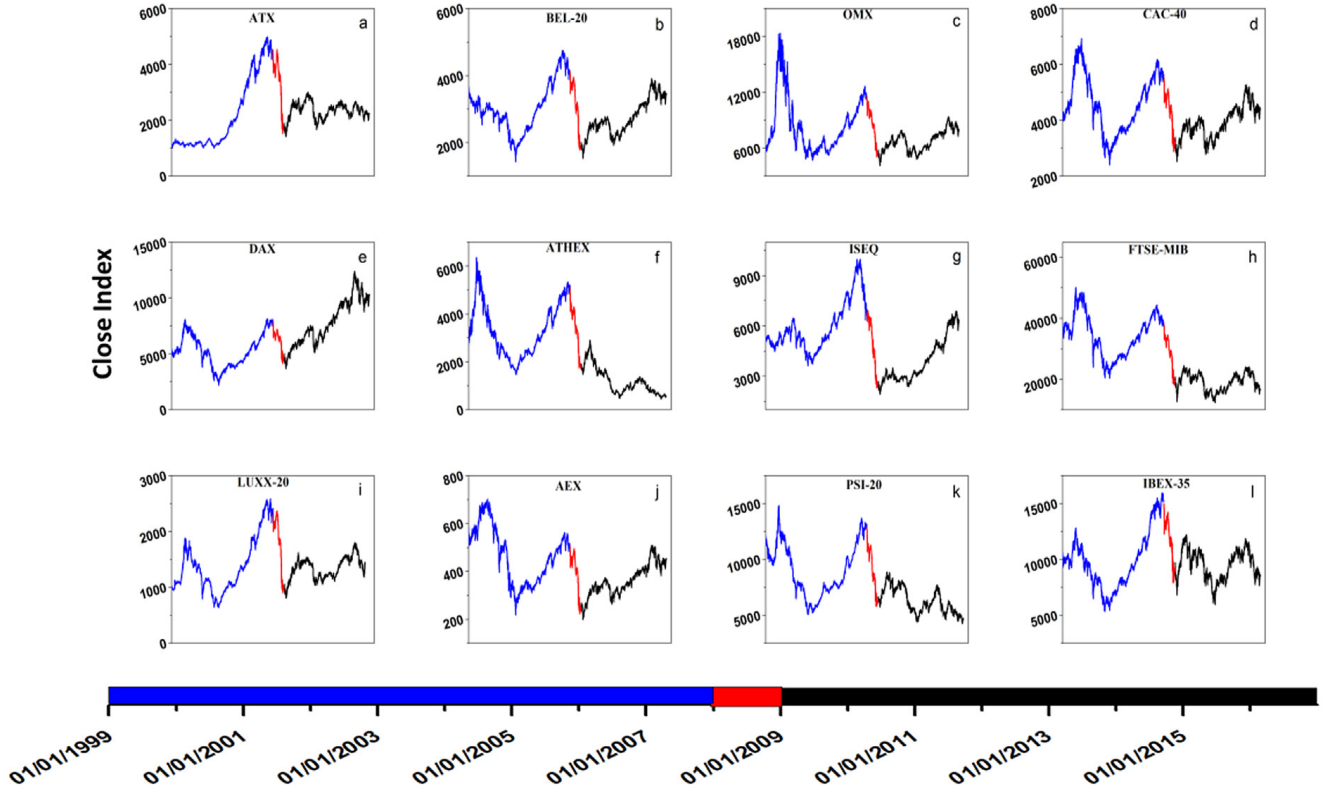


Fig. 1. The closing value of the stock market index in the Eurozone. Pre-crisis represent the period from January/01/1999 to December/31/2007 (blue), 2008 represent the crisis period (red), and post-crisis is the period from January/01/2009 to March/11/2016 (black). (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)

Thus, we analyze the cross-correlations between the return rates of each blue-chip and the respective stock index. Therefore, with the index (S_t) we calculated the return of values, given by

$$r_t \equiv \frac{S_t - S_{t-1}}{S_{t-1}}. \quad (1)$$

With the return, we will obtain the descriptive statistics and the DCCA cross-correlation coefficient. For this purpose, we introduced a brief theoretical description of the ρ_{DCCA} cross-correlation coefficient.

2.1. ρ_{DCCA} coefficient

The detrended cross-correlation coefficient is a new method to quantify the level of cross-correlation between two non-stationary time series [15]. This method is based on detrended fluctuation analysis (DFA) [16] and detrended cross-correlation analysis (DCCA) [17]. See these papers for more details [18–22].

For better understanding of ρ_{DCCA} , we present the algorithm in five steps:

Step I: considering two time series, $\{x_t\}$ and $\{y_t\}$, with $t = 1, 2, \dots, N$ (time series length). Then we integrated these time series, obtaining two new series:

$$xx_k = \sum_{t=1}^k x_t \quad \text{and} \quad yy_k = \sum_{t=1}^k y_t, \quad k = 1, 2, \dots, N. \quad (2)$$

Step II: we divide these two integrated time series, $\{xx_t\}$ and $\{yy_t\}$, into $(N - n)$ overlapping boxes of equal length n , with $4 \leq n \leq \frac{N}{4}$.

Step III: we calculate the local trend of each box by a least-squares fit of each series, $xP_i(k)$ and $yP_i(k)$, and we calculate the covariance of the residuals in each box by:

$$f_{xy}^2(n, i) = \frac{1}{(n+1)} \sum_{k=i}^{i+n} (xx_k - xP_i(k))(yy_k - yP_i(k)). \quad (3)$$

Table 1
Detrended cross-correlation conditions for analysis.

ρ_{DCCA}		
Weak	Medium	Strong
0.000 \mapsto 0.333	0.333 \mapsto 0.666	0.666 \mapsto 1.000




Fig. 2. (Color on-line) Descriptive statistics: Blue before, red 2008, and black after crisis.

Step IV: the average over all $(N - n)$ overlapping boxes is calculated to obtain the new covariance function:

$$F_{xy}^2(n) = \frac{1}{(N - n)} \sum_{i=1}^{N-n} f_{xy}^2(n, i). \tag{4}$$

Step V: finally, we calculate the cross-correlation coefficient ρ_{DCCA} defined by:

$$\rho_{DCCA}(n) = \frac{F_{xy}^2(n)}{F_{xx}(n)F_{yy}(n)}. \tag{5}$$

This cross-correlation coefficient, as we can see, depends on the box length n (time scale). One of the advantages of this cross-correlation coefficient is that it measures the correlations between two non-stationary time series at different time scales. The DCCA cross-correlation coefficient ranges from $-1 \leq \rho_{DCCA} \leq 1$. The value $\rho_{DCCA} = 1$ means a perfect cross-correlation, whereas $\rho_{DCCA} = -1$ means a perfectly anti cross-correlation, $\rho_{DCCA} = 0$ means there is no cross-correlation between the series. ρ_{DCCA} was applied in climatological data [23], criminality [24], economy [5,25–35], among others. Detrended cross-correlation coefficient is more robust than Pearson coefficient [31], mainly in the case of non-stationary time series [36]. In this paper ρ_{DCCA} analysis was performed considering the Table 1, suggested in [5]:

With the detrended cross-correlation coefficient defined, we describe our data and results in next section.

3. Data and results

We start our results with the descriptive statistics. See Table 2 and Fig. 2.

In Table 2 and Fig. 2 we present the standard deviation, the Skewness, and the Kurtosis of the return. These coefficients were estimated by Eqs. (6) and (7) [37–40]:

$$Skewness = \frac{1}{n} \sum_{i=1}^n \left(\frac{r_i - \bar{r}}{\sigma} \right)^3; \tag{6}$$

$$Kurtosis = \frac{1}{n} \sum_{i=1}^n \left(\frac{r_i - \bar{r}}{\sigma} \right)^4. \tag{7}$$

Table 2Descriptive statistics: Mean values of the blue-chips companies shown in Table 3. The return has a mean value of $\langle r \rangle = 0.00$.

	Country	Before			2008			After		
		sd	Sk	Kurt	sd	Sk	Kurt	sd	Sk	Kurt
1	Austria	0.02	-0.11	5.86	0.05	0.22	5.47	0.02	-0.07	6.10
2	Belgium	0.02	0.71	18.70	0.04	0.49	8.69	0.02	0.21	7.27
3	Finland	0.02	-0.03	8.98	0.03	0.17	4.75	0.02	0.11	9.34
4	France	0.02	0.17	6.92	0.03	0.42	6.11	0.02	0.17	6.77
5	Germany	0.02	0.48	12.36	0.03	0.46	7.50	0.02	-0.15	5.45
6	Greece	0.02	0.26	6.96	0.03	-0.11	5.19	0.04	0.11	7.02
7	Ireland	0.02	-0.15	9.50	0.03	-0.01	4.99	0.02	0.01	5.90
8	Italy	0.02	0.18	7.56	0.03	0.29	6.30	0.02	0.06	5.90
9	Luxembourg	0.02	2.18	69.99	0.06	3.42	55.57	0.02	0.16	6.14
10	Netherlands	0.02	0.06	8.42	0.03	0.29	5.15	0.02	0.09	6.52
11	Portugal	0.02	0.55	12.00	0.03	0.03	8.87	0.02	0.03	5.82
12	Spain	0.02	0.37	11.39	0.03	0.39	6.84	0.02	0.43	8.93

Legend: (sd)–Standard Deviation, (Sk.)–Skewness and (Kurt.) = Kurtosis.

Table 2 reveals that the financial crisis contributed significantly to the behavior of stock markets in the Eurozone. For example, before the crisis all countries present $sd \approx 0.02$, but in the crisis, stock markets record greater volatility, especially for Luxembourg ($sd = 0.06$), Austria ($sd = 0.05$), and Belgium ($sd = 0.04$). In the post-crisis, sd returned to levels before the crisis, except to Greece ($sd = 0.04$). We observe asymmetric distributions for all periods regarding the Skewness. Furthermore, before the crisis, countries like Luxembourg, Belgium, Portugal, Germany, Spain, and Greece recorded high Skewness compared to others. At the crisis, all countries recorded positive Skewness, except Greece and Ireland. Luxembourg presented the greatest value of Skewness at the crisis $Sk = 3.42$. In the post-crisis stock markets showed Skewness closer to zero, representing a more adjusted stock market. We can see that the returns are characterized by tail distributions before, during and after the crisis, because kurtosis is greater than tree. Belgium, Germany, Portugal, and Spain reported the highest Kurtosis before the crisis, while Luxembourg shows higher Kurtosis before and during the crisis [41,42]. See Fig. 2 for more details.

However, in this paper we are interested in analyzing the relationship between the main index and its blue-chips.² For this purpose, the DCCA cross-correlation coefficient, ρ_{DCCA} , which quantifies the level of cross-correlation between these time series was applied [15]. Fig. 3 (before crisis), 4 (2008), and 5 (after crisis) shows the results of ρ_{DCCA} . In these figures we can prove that the value of ρ_{DCCA} is always positive, independently of the cross time series, which proves the robustness of ρ_{DCCA} .

For example, we can identify that the ρ_{DCCA} showed a larger dispersion in the pre-crisis period Fig. 3, except for Germany, with values ~ 0.666 (between medium and strong cross-correlation). For Finland the blue-chips FIN01, FIN03, and FIN04 registered weak to medium cross-correlations, while FIN02 presented strong cross-correlation, $\rho_{DCCA} \cong 1$. Later, in the post-crisis, ρ_{DCCA} tends towards 0.666 for Finland, Fig. 5. We identified that the crisis caused regrouping in the cross-correlation coefficient around 0.666, except for Ireland, Italy, and Spain (see Fig. 5).

Given that we have two very characteristic periods (before and after crisis), we can compare ρ_{DCCA} after with ρ_{DCCA} before the 2008 financial crisis. In this way we can define $\Delta\rho_{DCCA}$, namely [5],

$$\Delta\rho_{DCCA}(n) \equiv \rho_{DCCA}^{after}(n) - \rho_{DCCA}^{before}(n). \quad (8)$$

Here $\Delta\rho_{DCCA}$ will measure the adhesion (regarding the crisis) of each blue-chip in relation to its master index. In this sense, we formulate the following hypothesis:

- (i) $\Delta\rho_{DCCA} = 0$, no change in the stock market;
- (ii) $\Delta\rho_{DCCA} > 0$, there was an increase in ρ_{DCCA} if we compare the “before” with the “after”, there is adherence in the return;
- (iii) $\Delta\rho_{DCCA} < 0$, there was a decrease in ρ_{DCCA} , if we compare the “before” with the “after”, there is anti-adherence in the return.

Fig. 6 presents the results of $\Delta\rho_{DCCA}$ in function of the time scale n for all countries. Specifically we can see that:

Austria: In general $\Delta\rho_{DCCA}$ was positive, except to AUTO3 company in 100 days. Thus, this result indicates that there was an adherence of the blue-chips to the ATX index.

Belgium: $\Delta\rho_{DCCA}$ for small time scale was positive for BELO2, BEI03, while for BELO5 was negative. For large time scale $\Delta\rho_{DCCA}$ tends to 0.

Finland: The value of $\Delta\rho_{DCCA}$ was positive for all blue-chips, except for FIN02. This means that there was an increase in adherence for FIN01, FIN03, and FIN04. While for FIN02 the value was always negative (see the values of ρ_{DCCA}), representing a considerable anti-adherence.

² The code presented in the figures are listed in the Table 3.

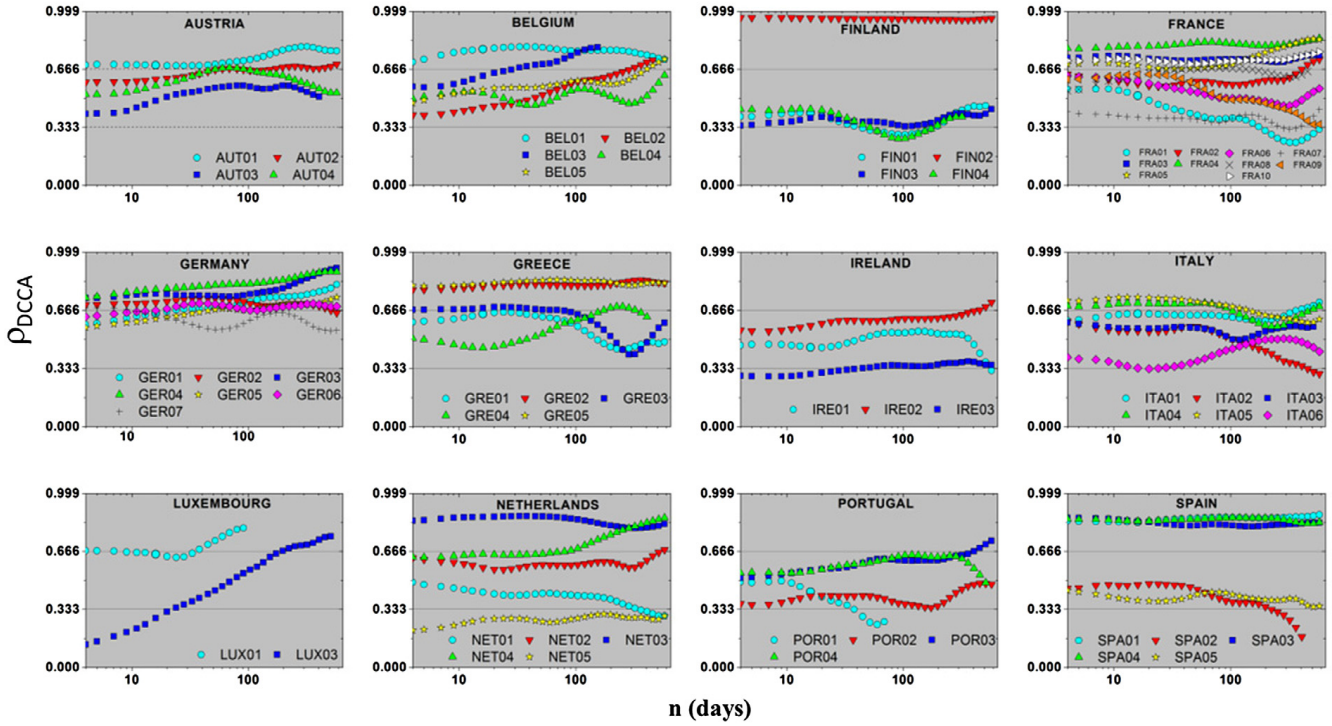


Fig. 3. (Color on-line) Detrended cross-correlation coefficient ρ_{DCCA} as a function of time scale n , here for period before 2008 financial crisis.

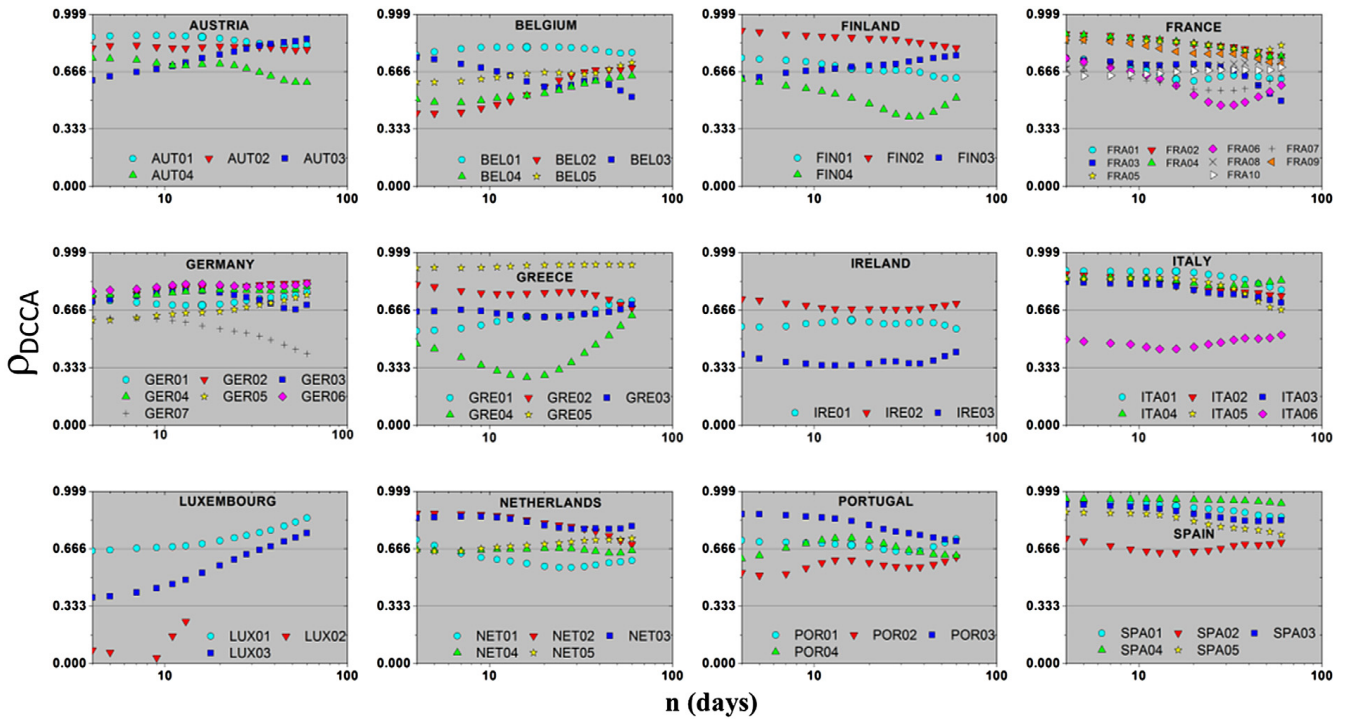


Fig. 4. (Color on-line) Detrended cross-correlation coefficient ρ_{DCCA} as a function of time scale n regarding to 2008.

France: This is the country that has more blue-chips in the global index. In this case $\Delta\rho_{DCCA}$ was positive for all blue-chips in small time scale, ~ 20 days. If we look a time scale greater than 20 days, FRA05 and FRA08 had a negative value.

Germany: Given that, before the crisis blue-chips were characterized by $\rho_{DCCA} \sim 0.666$, and that the same behavior continued in the post-crisis (with a small addition), thus $\Delta\rho_{DCCA} \geq 0$, indicating in general that there was little adherence of blue-chips relative to the index.

Greece: We realize that there is dispersion of results of $\Delta\rho_{DCCA}$, in small and large time scale. For GRE03 and GRE04 $\Delta\rho_{DCCA} > 0$. GRE02 and GRE05 recorded $\Delta\rho_{DCCA} \leq 0$. Whereas GRE01 is negative for small time scale and positive for large time scale.

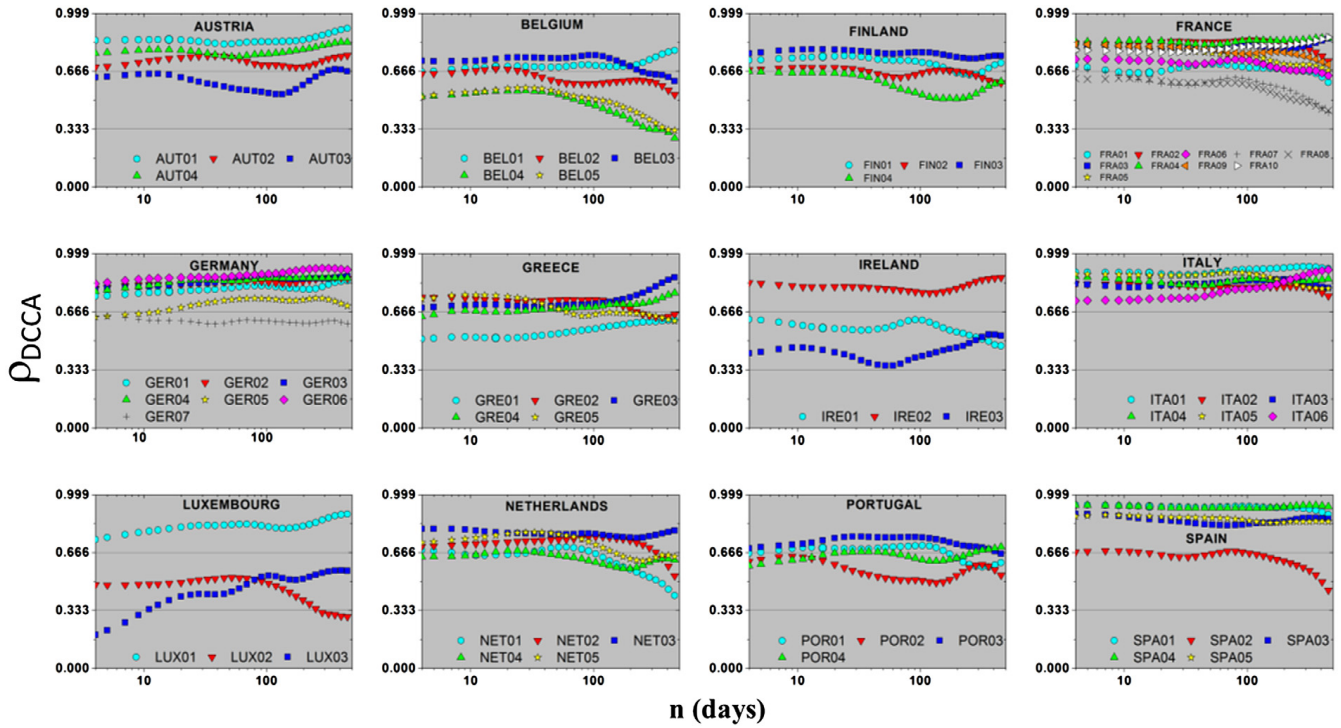


Fig. 5. (Color on-line) Detrended cross-correlation coefficient ρ_{DCCA} as a function of time scale n , for period after 2008 financial crisis.

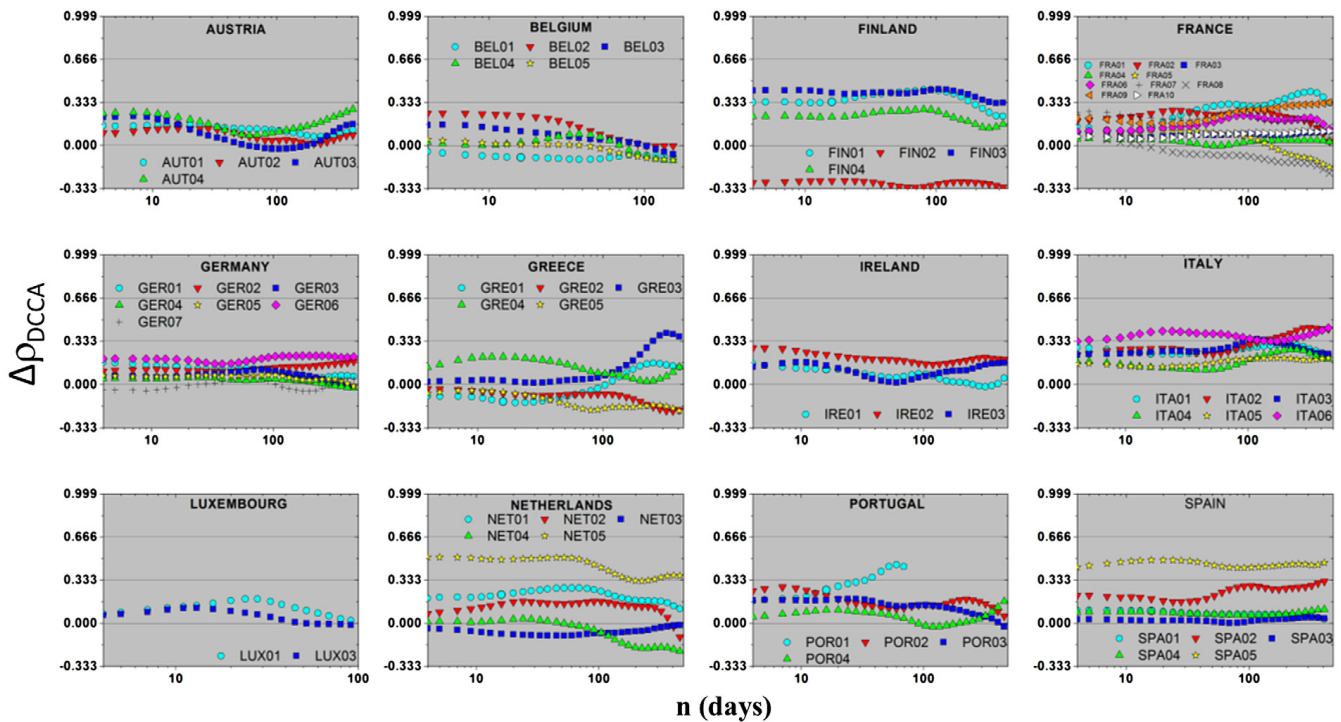


Fig. 6. $\Delta\rho_{DCCA}$ as an function of time scale n .

Ireland: Here exist three blue-chips in the index, and in general $\Delta\rho_{DCCA} \geq 0$ for these three companies.

Italy: In the pre-crisis, $0.333 \leq \rho_{DCCA} \leq 0.666$, but in the post-crisis, $0.666 \leq \rho_{DCCA} \leq 0.999$, which leads to positive $\Delta\rho_{DCCA}$. This result points that there was an adhesion of the blue-chip in relation to FTSEMIB30 return index.

Luxembourg: This is an index with less number of stocks, so we just have two blue-chips. For these two $\Delta\rho_{DCCA} \geq 0$.

Netherlands: $\Delta\rho_{DCCA}$ has positive values for NET01, NET02, and NET05 (most adherent blue-chips), and negative values for NET03.

Portugal: This country shows in general positive $\Delta\rho_{DCCA}$, except for POR04 about 100 days.

Spain: There was an increase in adhesion because $\Delta\rho_{DCCA} > 0$, except for SPA04 where the value is approximately zero.

In this case is possible to conclude that almost all countries face an increase in the correlations between blue-chips and the respective index. As previously mentioned, it means that the shares are now more integrated with the market than in the first sub-period. This could be understood as a risky pattern, because if a negative event occurs in the market or in the particular share, it could imply negative behavior by the other party. In fact, it could be understood in the light of the diversification effect problem, where an increase in the positive correlation brings a higher exposition to risk and potential losses. The exceptions are German shares and Belgian shares (for these, in particular, in the longer scales). In these cases, the evidence is for the maintenance of the cross-correlation coefficients.

4. Conclusions

We observed that European stock returns are characterized by non-zero Skewness (positive and negative) mainly before the crisis, presenting non-Gaussian distribution (long tail) with Kurtosis more than three (see the descriptive statistics presented in Table 2). The ρ_{DCCA} is always positive, which clearly demonstrates the adhesion of each blue-chip to the master index. However, the cross-correlation coefficient changes with the time period. This fact has given us the opportunity to study the effect of the 2008 financial crisis by the estimate of the ρ_{DCCA} difference. Of course, for a stable stock market $\Delta\rho_{DCCA}$ should be 0. But, when we look at the results, $\Delta\rho_{DCCA} \neq 0$ in many cases, with positive values (in general). This can be interpreted as an increase of the relationship between blue-chips and the respective national index. During the crisis, this can involve a risk, because any disturbance in the blue-chip may cause a high influence on the index.

The results point towards an increase in the cross-correlation of blue-chips and the respective national index, for almost all countries. Germany and Belgium are the exceptions, showing correlations that are similar in both countries. In the other countries, the shares increased their correlations, which mean more market integration and, consequently, a possible increase of risk in those countries.

Finally, whereas there is no thorough analysis about cross-correlation in the Eurozone, this paper studies blue-chips companies in the Eurozone, because they are the most representative and that best describe the stock market. The blue-chips are important to investors and can be used in the construction of representative portfolios. Here, we propose a new way to analyze the adherence of blue-chips companies in relation to its master index at the Eurozone.

Acknowledgments

Everaldo Guedes thanks the FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia) (Grant BOL 0976/2016) and Gilney Zebende thanks the CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) (Grant 309288/2013-4), Brazilian agencies.

Paulo Ferreira and Andreia Dionísio are pleased to acknowledge financial support from Fundação para a Ciência e a Tecnologia (Grant UID/ECO/04007/2013) and FEDER/COMPETE (POCI-01-0145-FEDER-007659).

Appendix

See Table 3.

Table 3

Main index and the respective blue-chips. Last column represent the weight percent of the main index.

Index/share	Code	Beginning	Weight
ATX (Austria)	AUT00	4th January 1999	51.49%
Erste Group Bank	AUT01	4th January 1999	18.91%
OMV	AUT02	4th January 1999	12.63%
Andritz	AUT03	25th June 2001	10.49%
Voestalpine	AUT04	4th January 1999	9.46%
BEL20 (Belgium)	BEL00	4th January 1999	53.34%
KBC Group	BEL01	4th January 1999	12.8%
AB Inbev	BEL02	1st December 2000	12.5%
Engie	BEL03	8th July 2005	10.8%
UCB	BEL04	4th January 1999	10.5%
Delhaize Group	BEL05	4th January 1999	9.26%
OMX Helsinki (Finland)	FIN00	4th January 1999	54.53%
Nordea Bank	FIN01	1st February 2000	18.49%
Nokia	FIN02	4th January 1999	15.55%
Sampo	FIN03	4th January 1999	11.43%
TeliaSonera	FIN04	10th December 2002	9.06%

(continued on next page)

Table 3 (continued)

Index/share	Code	Beginning	Weight
CAC40-France	FRA00	4th January 1999	52.57%
Sanofi	FRA01	4th January 1999	9.63%
Total	FRA02	4th January 1999	9.31%
BNP Paribas	FRA03	4th January 1999	5.74%
AXA	FRA04	4th January 1999	5.12%
LVMH	FRA05	4th January 1999	4.2%
L'Oral	FRA06	4th January 1999	4.06%
Danone	FRA07	4th January 1999	3.81%
Airbus Group	FRA08	11th July 2000	3.8%
Air Liquide	FRA09	4th January 1999	3.7%
Societe General	FRA10	4th January 1999	3.2%
DAX30-Germany	GER00	4th January 1999	55.92%
Bayer	GER01	4th January 1999	9.41%
Daimler	GER02	4th January 1999	8.82%
Allianz	GER03	4th January 1999	8.48%
Siemens	GER04	4th January 1999	7.96%
SAP	GER05	4th January 1999	7.79%
BASF	GER06	4th January 1999	7.43%
Deutsche Telekom	GER07	4th January 1999	6.02%
ATHEX-Greece	GRE00	4th January 1999	56.15%
Coca-Cola HBC	GRE01	4th January 1999	18.98%
Alpha Bank	GRE02	4th January 1999	12.81%
Hellenic Telecom	GRE03	4th January 1999	10.08%
OPAP	GRE04	25th April 2001	7.32%
National Bank of Greece	GRE05	4th January 1999	6.96%
ISEQ-Ireland	IRE00	4th January 1999	50.77%
Ryanair	IRE01	4th January 1999	18.50%
CRH	IRE02	4th January 1999	17.89%
Kerry Group	IRE03	4th January 1999	14.38%
MIB30-Italy	ITA00	4th January 1999	52.84%
Intesa Sanpaolo	ITA01	4th January 1999	12.59%
ENI	ITA02	4th January 1999	11.51%
ENEL	ITA03	2nd November 1999	9.05%
Unicredit	ITA04	4th January 1999	8.51%
Assicurazioni Generali	ITA05	4th January 1999	7.22%
Atlantia	ITA06	4th January 1999	3.96%
SELUX-Luxembourg	LUX00	5th January 1999	61.62%
ArceLormittal	LUX01	2nd August 2006	20.98%
Reinet Investments	LUX02	22nd October 2010	20.71%
RTL Group	LUX03	20th December 1999	19.93%
AEX-Netherlands	NET00	4th January 1999	55.68%
Unilever	NET01	4th January 1999	16.66%
Royal Dutch Shell	NET02	4th January 1999	12.64%
Ing Groep	NET03	4th January 1999	12.49%
ASML	NET04	4th January 1999	7.91%
Unibail-Rodamco	NET05	4th January 1999	5.98%
PSI20-Portugal	POR00	4th January 1999	51.77%
Galp Energia	POR01	25th October 2006	14.59%
Jernimo Martins	POR02	4th January 1999	13.26%
EDP	POR03	4th January 1999	12.32%
NOS	POR04	17th November 1999	11.6%
IBEX35-Spain	SPA00	4th January 1999	54.61%
Banco Santander	SPA01	4th January 1999	13.96%
Inditex	SPA02	23rd May 2001	12.38%
Telefonica	SPA03	4th January 1999	10.61%
BBVA	SPA04	4th January 1999	9.22%
Iberdrola	SPA05	4th January 1999	8.44%

References

- [1] IPEA (Ed.), Modelagem de sistemas complexos para políticas públicas, IPEA, 2015.
- [2] I.G. Tuluzov, S.I. Melnyk, Physical methodology for economic systems modeling, *Electron. J. Theor. Phys. (EJTP)* 7 (24) (2010) 57–78.
- [3] J. Ladyman, J. Lambert, K. Wiesner, What is a complex system? *Eur. J. Philos. Sci.* 3 (1) (2013) 33–67.
- [4] R. Albert, A.-L. Barabási, Statistical mechanics of complex networks, *Rev. Modern Phys.* 74 (2002) 47–97.
- [5] M.F. Da Silva, E.J.d.A.L.a. Pereira, A.M. da Silva Filho, A.P.N. de Castro, J.G.V. Miranda, G.F. Zebende, Quantifying the contagion effect of the 2008 financial crisis between the G7 countries (by GDP nominal), *Physica A* 453 (C) (2016) 1–8.
- [6] K.J. Forbes, R. Rigobon, No contagion, only interdependence: Measuring stock market comovements, *J. Finance* 57 (5) (2002) 2223–2260.
- [7] G. Corsetti, M. Pericoli, M. Sbracia, Some contagion, some interdependence: More pitfalls in tests of financial contagion, *J. Int. Money Finance* 24 (8) (2005) 1177–1199.
- [8] R. Mantegna, H.E. Stanley, *An Introduction to Econophysics: Correlations and Complexity in Finance*, Cambridge University Press, 2007.

- [9] M.F. da Silva, J.d.A.L. Pereira, A.M. da Silva Filho, A.P. Nunes de Castro, J.G.V. Miranda, G.F. Zebende, Quantifying cross-correlation between Ibovespa and Brazilian blue-chips: The DCCA approach, *Physica A* 424 (C) (2015) 124–129.
- [10] P. Ferreira, Does the euro crisis change the cross-correlation pattern between bank shares and national indexes? *Physica A* 463 (2016) 320–329.
- [11] P. Ferreira, A. Dionísio, Revisiting serial dependence in the stock markets of the G7 countries, Portugal, Spain and Greece, *Appl. Financ. Econ.* 24 (5) (2014) 319–331.
- [12] M. Obstfeld, Risk-taking, global diversification, and growth, *Amer. Econ. Rev.* 84 (5) (1994) 1310–1329.
- [13] G. Bekaert, C.R. Harvey, C. Lundblad, Does financial liberalization spur growth? *J. Financ. Econ.* 77 (1) (2005) 355.
- [14] M. Beine, A. Cosma, R. Vermeulen, The dark side of global integration: Increasing tail dependence, *J. Bank. Finance* 34 (1) (2010) 184–192.
- [15] G.F. Zebende, Dcca cross-correlation coefficient: Quantifying level of cross-correlation, *Physica A* 390 (4) (2011) 614–618.
- [16] C.-K. Peng, S.V. Buldyrev, S. Havlin, M. Simons, H.E. Stanley, A.L. Goldberger, Mosaic organization of DNA nucleotides, *Phys. Rev. E* 49 (1994) 1685–1689.
- [17] B. Podobnik, H.E. Stanley, Detrended cross-correlation analysis: A new method for analyzing two nonstationary time series, *Phys. Rev. Lett.* 100 (2008) 1–4.
- [18] S. Drozd, J. Kwapien, P. Oswiecimka, R. Rak, Quantitative features of multifractal subtleties in time series, *Europhys. Lett.* 88 (6) (2009) 60003.
- [19] D. Horvatic, H.E. Stanley, B. Podobnik, Detrended cross-correlation analysis for non-stationary time series with periodic trends, *Europhys. Lett.* 94 (1) (2011) 18007.
- [20] B. Podobnik, D. Horvatic, A.M. Petersen, H.E. Stanley, Cross-correlation between volume change and price change, *Proc. Natl. Acad. Sci.* 106 (52) (2009) 22079–22084.
- [21] B. Podobnik, I. Grosse, D. Horvatic, S. Ilic, C.P. Ivanov, E.H. Stanley, Quantifying cross-correlations using local and global detrending approaches, *Eur. Phys. J. B* 71 (2) (2009) 243–250.
- [22] B. Podobnik, Z.-Q. Jiang, W.-X. Zhou, H.E. Stanley, Statistical tests for power-law cross-correlated processes, *Phys. Rev. E* 84 (2011) 066118.
- [23] R.T. Vassoler, G.F. Zebende, Dcca cross-correlation coefficient apply in time series of air temperature and air relative humidity, *Physica A* 391 (7) (2012) 2438–2443.
- [24] A. Machado Filho, M.F. da Silva, G.F. Zebende, Autocorrelation and cross-correlation in time series of homicide and attempted homicide, *Physica A* 400 (2014) 12–19.
- [25] M. Hussain, G.F. Zebende, U. Bashir, D. Donghong, Oil price and exchange rate co-movements in Asian countries: Detrended cross-correlation approach, *Physica A* 465 (1) (2016) 338–346.
- [26] U. Bashir, Y. Yu, M. Hussain, G.F. Zebende, Do foreign exchange and equity markets co-move in Latin American region? Detrended cross-correlation approach, *Physica A* 462 (2016) 889–897.
- [27] P. Ferreira, A. Dionísio, G.F. Zebende, Why does the Euro fail? the dcca approach, *Physica A* 443 (2016) 543–554.
- [28] J.C. Reboredo, M.A. Rivera-Castro, G.F. Zebende, Oil and US dollar exchange rate dependence: A detrended cross-correlation approach, *Energy Econ.* 42 (c) (2013) 132–139.
- [29] E.F. Guedes, G.F. Zebende, A. Machado, Análise temporal dos indicadores da indústria de transformação da Bahia: uma abordagem com métodos da mecânica estatística, *Conjuntura Planejamento* 186 (2015) 34–43.
- [30] E.L. Siqueira Junior, T. Stošić, L. Bejan, B.B. Stošić, Correlations and cross-correlations in the Brazilian agrarian commodities and stocks, *Physica A* 389 (14) (2010) 2739–2743.
- [31] G.-J. Wang, C. Xie, S. Chen, J.-J. Yang, M.-Y. Yang, Random matrix theory analysis of cross-correlations in the US stock market: Evidence from Pearson's correlation coefficient and detrended cross-correlation coefficient, *Physica A* 392 (17) (2013) 3715–3730.
- [32] G.-J. Wang, C. Xie, Cross-correlations between WTI crude oil market and US stock market: A perspective from econophysics, *Acta Phys. Pol.-Ser. B Elem. Part. Phys.* 43 (10) (2012) 2021–2036.
- [33] G.-J. Wang, C. Xie, Y.-J. Chen, S. Chen, Statistical properties of the foreign exchange network at different time scales: Evidence from detrended cross-correlation coefficient and minimum spanning tree, *Entropy* 15 (5) (2013) 1643–1662.
- [34] G.-J. Wang, C. Xie, S. Chen, F. Han, Cross-correlations between energy and emissions markets: New evidence from fractal and multifractal analysis, *Math. Probl. Eng.* 2014 (197069) (2014) 1–13.
- [35] G.-J. Wang, C. Xie, L.-Y. He, S. Chen, Detrended minimum-variance hedge ratio: A new method for hedge ratio at different time scales, *Physica A* 405 (2014) 70–79.
- [36] L. Kristoufek, Measuring cross-correlation between non-stationary series with dcca coefficient, *Physica A* 402 (2014) 291–298.
- [37] D.N. Joanes, C.A. Gill, Comparing measures of sample skewness and kurtosis, *J. Roy. Statist. Soc.: Ser. D (Statist.)* 47 (1) (1998) 183–189.
- [38] J.B. Cromwell, W.C. Labys, M. Terraza, *Univariate Tests for Time Series Models*, in: *Quantitative Applications in the Social Sciences*, vol. 99, Sage Publications, California - EUA, 1994.
- [39] M.R. Spiegel, L.J. Stephens, *Schaum's Outlines*, third ed., McGraw-Hill, 1998.
- [40] R Core Team, *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria, 2014, URL <http://www.R-project.org/>.
- [41] R. Cont, Empirical properties of asset returns: stylized facts and statistical issues, *Quant. Finance* 1 (2001) 223–236.
- [42] D.R. Parisi, D. Sornette, D. Helbing, Financial price dynamics and pedestrian counterflows: A comparison of statistical stylized facts, *Phys. Rev. E* 87 (1) (2013) 012804.

3.3 Coeficiente ρ_{DCCA} com janela deslizante

Neste artigo, implementamos o coeficiente de correlação cruzada DCCA ρ_{DCCA} (Subseção 2.3) com a abordagem de janelas deslizantes para medir a correlação cruzada à medida que o tempo passa. Nesta abordagem, o ρ_{DCCA} é executado em uma janela de tamanho fixo (w) e desliza na série com um contador (T), sendo o modelo denotado por

$$\rho_{DCCA}(w, T, n) = \frac{F_{DCCA}^2(w, T, n)}{F_{DFA_{\{x_t\}}}(w, T, n)F_{DFA_{\{y_t\}}}(w, T, n)} \quad (3.1)$$

Em que, w é a janela de tamanho fixo que pode assumir qualquer valor entre $250 \leq w \leq \frac{N}{2}$ e T é definido por $N - w$ (caixas sobrepostas, vide a Figura 3.3) ou $\frac{N}{w}$ (caixas não sobrepostas). A Figura 3.3 ilustra o método proposto com janelas sobrepostas de tamanho 1000, conforme a literatura especializada [Carbone, Castelli e Stanley \(2004\)](#), [Ferreira et al. \(2018\)](#).

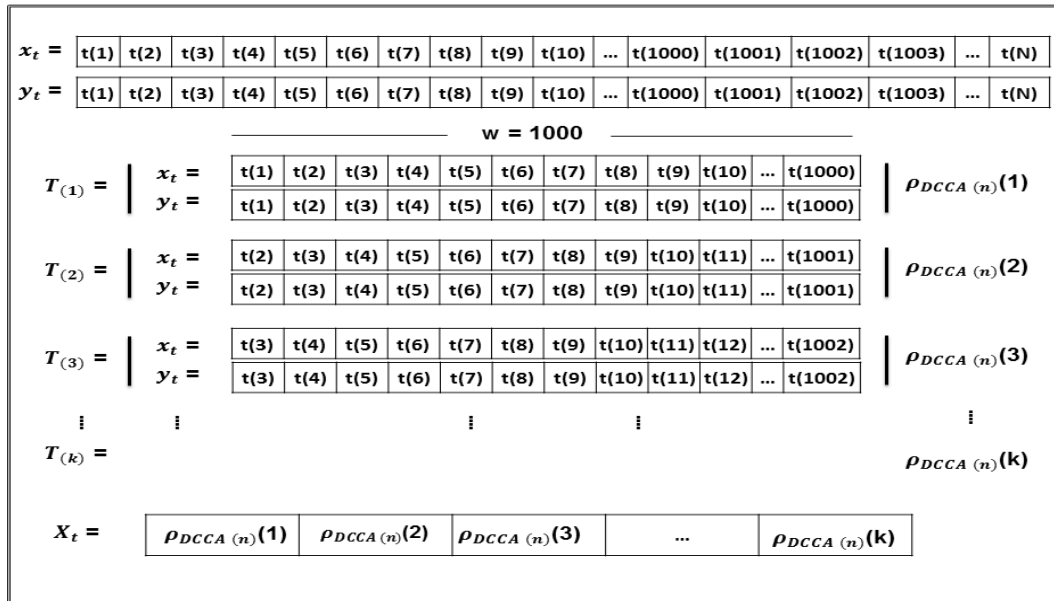


Figura 3.3: Ilustração da Janela Deslizante.

O *paper* supracitado encontra-se submetido e está em fase de revisão pelo periódico *Physica A*.

DCCA cross-correlation coefficient with sliding windows approach

E. F. Guedes^a, G. F. Zebende^b

^a*Department of Statistics, Federal University of Bahia, Bahia, Brazil*

^b*State University of Feira de Santana, Bahia, Brazil*

Abstract

We have implemented in this paper the DCCA cross-correlation coefficient, ρ_{DCCA} , with sliding windows approach to measure cross-correlation as a function of time. Thereby, from two non-stationary time series a fixed size window will be defined by w , and the coefficients ρ_{DCCA} calculated for different time scales ($4 \leq n \leq \frac{w}{4}$). Following this procedure it was possible to set up a cross-correlation color map of ρ_{DCCA} , which was tested in this paper for a simulated (random) and an empirical (econometric) case. This new color map with sliding windows shows the time scale and the current time for a cross-correlation analysis. In this way, it is possible to analyze the complete cross-correlation between two variables in different areas of knowledge, such as economics, our case of study.

Keywords: DCCA cross-correlation coefficient, times series, sliding windows.

1. Introduction

In many occasions when we correlate two time series, we try to understand how the fluctuations of one variable can influence another or how these variables behave oneseft in face of external events. In this point of view, cross-correlation analysis plays an important part for understanding the scope of such influences, for example: study of EEG signs of young and old healthy subjects [1], analysis of geological structures of oil wells [2], cross-correlation between air temperature and relative humidity [3], analysis of the exchange

Email address: gfzebende@hotmail.com (G. F. Zebende)

rate and the industrial production of Bahia Brazil [4], the study of the 2008 financial crisis [5], and others [6, 7, 8, 9, 10, 11]. The term cross-correlation emerged by Francis Galton and Karl Pearson (~ 1880), where the Pearson's cross-correlation coefficient was proposed [12, 13, 14]. The literature presents other methods to quantify the cross-correlation between two time series, such as, Spearman's coefficient [15], DCCA cross-correlation coefficient [16], Detrending Moving-Average coefficient [17], among others [18, 19, 20, 21, 22]. Currently, the Pearson's coefficient is the most used one, but the DCCA cross-correlation coefficient, ρ_{DCCA} , Zebende (2011) [16], is more appropriate to measure linear and non-linear cross-correlation in non-stationary time series [23, 24, 25, 26], and because its algorithm takes into account the temporal order of the data, quantifying the level of intensity of the association at different time scales [27].

In this paper, we propose to apply ρ_{DCCA} with sliding windows approach to measure the cross-correlation between two time series dynamically. This implementation will make possible to obtain the relations between two time series at different scales and as a function of time, which may be of great relevance for analysis of time series with complex behavior [28, 29]. To implement this idea, the paper is organized as follows: Section 2 introduce the methodology and presents the data; Section 3 exhibit the results; Section 4 announces the conclusions, as we will see below.

2. Methodology

2.1. ρ_{DCCA} cross-correlation coefficient

The ρ_{DCCA} is based on the ratio between the detrended covariance function F_{xy}^2 of the Detrended Cross-Correlation Analysis method [30] and the variance function without trend F_{zz} (with $z = x$ or $z = y$) of the Detrended Fluctuation Analysis method [31], it is shown in five steps bellow:

Step I: Starting from two time series, $\{x_i\}$ and $\{y_i\}$, with $i = 1, 2, \dots, N$ (time series length), two new integrated time series are obtained:

$$X_k = \sum_{i=1}^k [x_i - \langle x \rangle] \quad \text{and} \quad Y_k = \sum_{i=1}^k [y_i - \langle y \rangle] \quad (1)$$

where $\langle x \rangle$ and $\langle y \rangle$ represent the mean value of each time series, and $k = 1, \dots, N$.

Step II: We divide these two integrated time series, $\{X_k\}$ and $\{Y_k\}$, into $(N - n)$ overlapping boxes of equal length n , where $4 \leq n \leq \frac{N}{4}$.

Step III: After this previous step, the polynomials (order one here) that best adjusts the points (by least-squares fit) in each box of each series, $\{\tilde{X}_{k,i}\}$ and $\{\tilde{Y}_{k,i}\}$, are calculated and therefore the covariance of the residuals in each box (length n):

$$f_{xy}^2(n, i) = \frac{1}{(n+1)} \sum_{k=i}^{i+n} (X_k - \tilde{X}_{k,i})(Y_k - \tilde{Y}_{k,i}) \quad (2)$$

Step IV: The mean over all $(N - n)$ overlapping boxes is calculated in order to obtain the detrended covariance function:

$$F_{xy}^2(n) = \frac{1}{(N-n)} \sum_{i=1}^{N-n} f_{xy}^2(n, i) \quad (3)$$

Step V: Finally, ρ_{DCCA} can be calculated by:

$$\rho_{DCCA}(n) = \frac{F_{xy}^2(n)}{F_{xx}(n) F_{yy}(n)} \quad (4)$$

The functions F_{xx} and F_{yy} are respectively the root mean square fluctuation of each time series $\{x_t\}$ and $\{y_t\}$ separately. $\rho_{DCCA}(n)$ ranges from: $-1 \leq \rho_{DCCA}(n) \leq 1$. When $\rho_{DCCA}(n) = 1$ this means a perfect cross-correlation, $\rho_{DCCA}(n) = 0$ there is no cross-correlation, and $\rho_{DCCA}(n) = -1$ means a perfect anti cross-correlation. In this paper we also consider the levels of cross-correlations proposed by [32], see Table 1. The DCCA cross-

Table 1: Detrended cross-correlation conditions for analysis.

	ρ_{DCCA}	
weak	medium	strong
$\pm 0.000 \mapsto \pm 0.333$	$\pm 0.333 \mapsto \pm 0.666$	$\pm 0.666 \mapsto \pm 1.000$

correlation coefficient has the advantage of measure cross-correlations between two non-stationary time series at different time scales (see [23, 33, 34, 35, 36]), and it can be used with sliding windows.

2.2. Sliding Windows Approach

Based on [37, 38, 39], our proposal in this paper is to take $\rho_{DCCA}(n)$ (Eq. 4) with sliding windows approach, with windows of size w . Fig. 1 present $\rho_{DCCA}(n, w, T)$:

$$\rho_{DCCA}(n, w, T) \equiv \frac{F_{xy}^2(n, w, T)}{F_{xx}(n, w, T)F_{yy}(n, w, T)} \quad (5)$$

where $4 \leq n \leq \frac{w}{4}$ (time scale), $250 \leq w \leq \frac{N}{2}$ (windows size), and $1 \leq T \leq (N - w)$ (time period). As illustration of this procedure, we fixed $w = 1000$

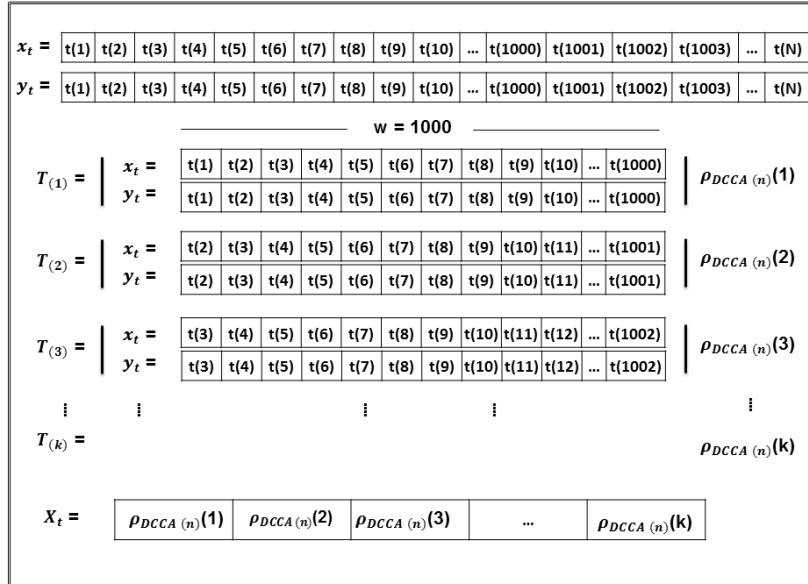


Figure 1: Procedure for DCCA cross-correlation coefficient with sliding windows (overlapping).

and calculated $\rho_{DCCA}(n, w, T)$ for a simulated case and an empirical case, as it is shown in the next section.

3. Results

3.1. Simulated Case

In order to simulate the sliding windows with ρ_{DCCA} we initially proposed the study of the null hypothesis for $\rho_{DCCA}(n, w, T)$. In other words, we

generate a pair of random time series, Ran01 and Rand01, with $N = 2000$ for the sliding windows DCCA cross-correlation coefficient calculation. For this example, we expect to find for any window $\rho_{DCCA} \simeq 0$. The results for this simulation can be found in Fig. 2, introduced by the ρ_{DCCA} color map (see [40]). Considering the Table 1, $\rho_{DCCA} \simeq 0$ (black and gray scales) for




Figure 2: (color on-line) ρ_{DCCA} with sliding windows approach for two random (Ran01 and Rand02) time series of size $N = 2000$ points.

all time scales n , and for all time period T as expected, which validates the null hypothesis.

3.2. Empirical Case

For this empirical study we select five stock market index, with the closed index value for:

1. New York Stock Exchange (**NYSE**);
2. National Association of Securities Dealers Automated Quotations (**NASDAQ**);
3. Deutsche Boerse AG German Stock Index (**DAX**);
4. São Paulo Exchange Index (**IBOVESPA**);

5. Shanghai Stock Exchange Index (SSE).

These data contain values from Jan/03/2001 to Jun/22/2018 (see Fig. 3 left panel). If we are interested in the fluctuations, we calculate for each

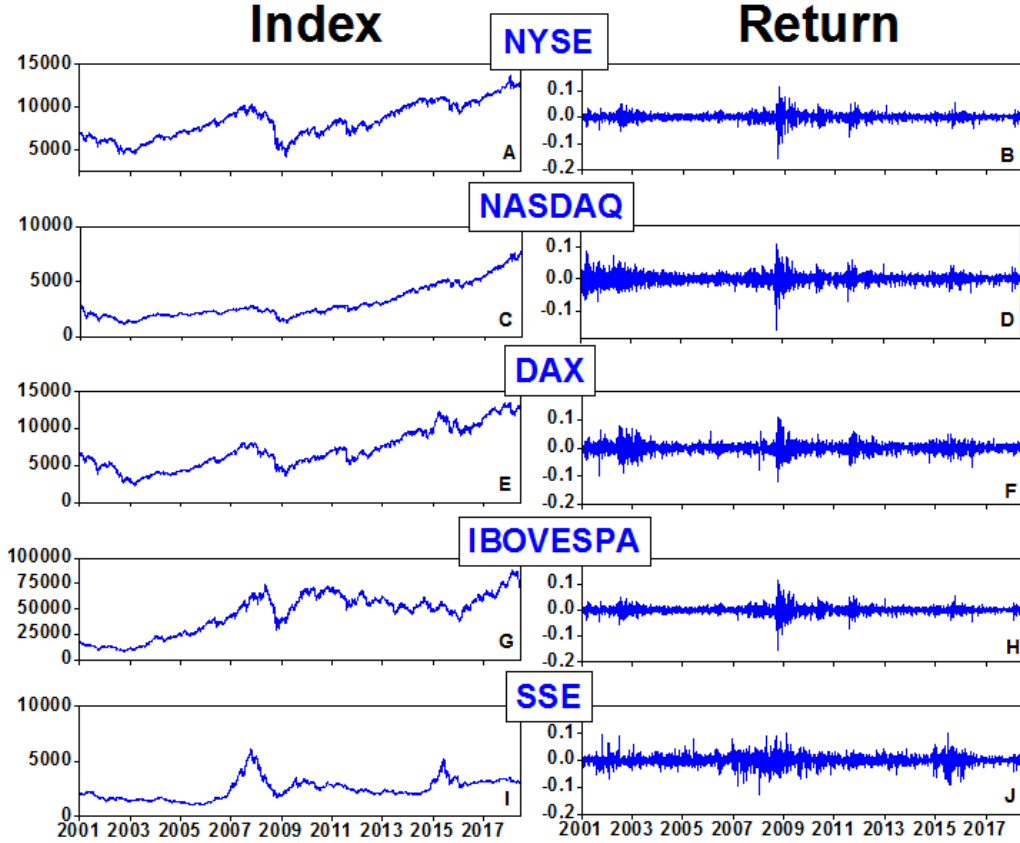


Figure 3: (color on-line) Time series of **NYSE**, **NASDAQ**, **DAX**, **IBOVESPA**, and **SSE** index from Jan/03/2001 to Jun/22/2018. The right panel represents the log returns of these time series.

index the log returns, $r_t \equiv \ln\left(\frac{S_t}{S_{t-1}}\right)$ (see Fig. 3 right panel). Thus, for r_t we cross (by their importance) **NYSE** with the other log return time series, and the results are found in the Fig. 4. This figure show cross-correlations always positive, changing with time period T [41, 28]. Specifically, we have identified that for all time scales n and time period T there is a strong cross-correlation, $\rho_{DCCA} \geq 0.666$, between **NYSE** \times **NASDAQ** (Fig. 4A),




Figure 4: (color on-line) ρ_{DCCA} with sliding windows approach for cross-correlation between: A) **NYSE** \times **NASDAQ**, B) **NYSE** \times **DAX**, C) **NYSE** \times **IBOVESPA**, and D) **NYSE** \times **SSE**.

probably explained by the proximity between the American indexes. For **NYSE** \times **DAX** (Fig. 4B) there is a strong cross-correlation, however for T between 2005 and 2009, the cross-correlation was medium in small time scales n . This pattern of medium cross-correlation was repeated between 2017 and 2018 to small and great time scales, that is, we can see small islands of $0.3333 \leq \rho_{DCCA} \leq 0.666$. Other types of cross-correlations patterns can be seen in **NYSE** \times **IBOVESPA** (Fig. 4C), because ρ_{DCCA} change. See $T = 2007$ and $T = 2014$, there is a medium/strong and of strong/medium transition in ρ_{DCCA} . Lastly, for **NYSE** \times **SSE** (Fig. 4D) the results shows cross-correlations oscillating between weak and medium values, for T and n , evidencing a different behavior of the previous analyzes.

4. Conclusions

Given that the ρ_{DCCA} is used as statistical tool to analyze associations between non-stationary time series, in this paper we propose to apply ρ_{DCCA} with sliding windows approach to measure cross-correlation as a function of time period. In order to present this new procedure, we have tested ρ_{DCCA} with sliding windows for a simulated case (random) and for an empirical case (stock market index), and this procedure was presented on a cross-correlation map.

First, for the simulated case which tested the null hypothesis of ρ_{DCCA} , we could verify that in all scales the value of the cross-correlation coefficient oscillated around zero, $\rho_{DCCA} \simeq 0$. After, for an empirical case, we could verify the relationship between the indexes, that is, with a strong value for ρ_{DCCA} if we consider the relation between the indexes **NYSE** \times **NASDAQ** and **NYSE** \times **DAX** (with small islands of medium value). This pattern is quite different for the case between **NYSE** \times **IBOVESPA** and mainly **NYSE** \times **SSE**. Thus, our results showed that it is possible to measure cross-correlation and identify phase transition as a function of the time periods. Finally, we believe that with ρ_{DCCA} sliding windows is possible to analyze cross-correlation phenomena in different areas of knowledge, such as the one presented here in economics indexes.

5. Acknowledgments

Guedes thank the FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia) (Grant BOL 0976/2016) and Gilney Zebende thanks CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) (Grant 304362/2017-4), Brazilian agencies.

6. Reference

References

- [1] W. Jun, Z. Da-Qing, Detrended cross-correlation analysis of electroencephalogram, Chinese Physics B 21 (2) (2012) 028703.
- [2] E. Marinho, A. Sousa, R. Andrade, Using detrended cross-correlation analysis in geophysical data, Physica A 392 (2013) 2195–2201.

- [3] R. T. Vassoler, G. F. Zebende, DCCA cross-correlation coefficient apply in time series of air temperature and air relative humidity, *Physica A* 391 (7) (2012) 2438–2443.
- [4] E. F. Guedes, G. F. Zebende, I. C. da Cunha Lima, Quantificação dos efeitos do câmbio na produção da indústria de transformação baiana: uma abordagem via coeficiente de correlação cruzada rho decca, *Conjuntura & Planejamento* 1 (192) (2017) 75 – 89.
- [5] E. Guedes, A. Dionísio, P. Ferreira, G. Zebende, DCCA cross-correlation in blue-chips companies: A view of the 2008 financial crisis in the Eurozone, *Physica A* 479 (2017) 38 – 47.
- [6] M. KozakI, W. KrzanowskiII, M. Tartanus, Use of the correlation coefficient in agricultural sciences: problems, pitfalls and how to deal with them, *Annals of the Brazilian Academy of Sciences* 84 (4) (2012) 1147 – 1156.
- [7] L. Piao, Z. Fu, Quantifying distinct associations on different temporal scales: comparison of DCCA and Pearson methods, *Scientific Reports* 6 (36759) (2016) 1 – 11.
- [8] X.-Y. Qian, Y.-M. Liu, Z.-Q. Jiang, B. Podobnik, W.-X. Zhou, H. Stanley, Detrended partial cross-correlation analysis of two nonstationary time series influenced by common external forces, *Physical review. E, Statistical, nonlinear, and soft matter physics* 91 (2015) 062816.
- [9] Horvatic, D., Stanley, H. E., Podobnik, B., Detrended cross-correlation analysis for non-stationary time series with periodic trends, *EPL* 94 (1) (2011) 18007.
- [10] B. Podobnik, D. Horvatic, A. M. Petersen, H. E. Stanley, Cross-correlations between volume change and price change, *Proceedings of the National Academy of Sciences* 106 (52) (2009) 22079–22084. arXiv:<https://www.pnas.org/content/106/52/22079.full.pdf>.
- [11] B. Podobnik, I. Grosse, D. Horvatić, S. Ilic, C. P. Ivanov, E. H. Stanley, Quantifying cross-correlations using local and global detrending approaches, *The European Physical Journal B* 71 (2) (2009) 243–250.

- [12] K. Pearson, Notes on regression and inheritance in the case of two parents, *Proceedings of the Royal Society of London* 58 (1895) 240–242.
- [13] S. M. Stigler, Francis Galton’s Account of the Invention of Correlation, *Statistical Science* 4 (1) (1989) 73–79.
- [14] J. M. Stanton, Galton, Pearson, and the Peas: A Brief History of Linear Regression for Statistics Instructors, *Journal of Statistics Education* 9 (3).
- [15] C. Spearman, The proof and measurement of association between two things, *The American Journal of Psychology* 15 (1) (1904) 72–101.
- [16] G. F. Zebende, DCCA cross-correlation coefficient: Quantifying level of cross-correlation, *Physica A* 390 (4) (2011) 614–618.
- [17] L. Kristoufek, Detrending moving-average cross-correlation coefficient: Measuring cross-correlations between non-stationary series, *Physica A* 406 (2014) 169–175.
- [18] L. Kristoufek, Detrended fluctuation analysis as a regression framework: Estimating dependence at different scales, *Phys. Rev. E* 91 (2015) 022802.
- [19] L. Kristoufek, Scaling of dependence between foreign exchange rates and stock markets in central europe, *Acta Physica Polonica A* 129 (5) (2016) 908–912.
- [20] L. Kristoufek, Fractal approach towards power-law coherency to measure cross-correlations between time series, *Communications in Nonlinear Science and Numerical Simulation* 50 (2017) 193 – 200.
- [21] X.-Y. Qian, Y.-M. Liu, Z.-Q. Jiang, B. Podobnik, W.-X. Zhou, H. E. Stanley, Detrended partial cross-correlation analysis of two nonstationary time series influenced by common external forces, *Phys. Rev. E* 91 (2015) 062816.
- [22] F. Wang, L. Wang, Y. Chen, A dfa-based bivariate regression model for estimating the dependence of pm2.5 among neighbouring cities, *Scientific Reports* 8.

- [23] L. Kristoufek, Measuring cross-correlation between non-stationary series with DCCA coefficient, *Physica A* 402 (2014) 291–298.
- [24] X. Zhao, P. Shang, J. Huang, Several fundamental properties of DCCA cross-correlation coefficient, *Fractals* 25 (2017) 1750017.
- [25] U. Bashir, Y. Yu, M. Hussain, G. F. Zebende, Do foreign exchange and equity markets co-move in Latin American region? detrended cross-correlation approach, *Physica A* 462 (2016) 889 – 897.
- [26] U. Bashir, G. F. Zebende, Y. Yu, M. Hussain, A. Ali, G. Abbas, Differential market reactions to pre and post brexit referendum, *Physica A*.
- [27] E. Guedes, A. Brito, F. O. Filho, B. Fernandez, A. de Castro, A. da Silva-Filho, G. Zebende, Statistical test for DCCA cross-correlation coefficient, *Physica A* 501 (2018) 134 – 140.
- [28] T. Preis, D. Y. Kenett, H. E. Stanley, D. Helbing, E. Ben-Jacob, Quantifying the behavior of stock correlations under market stress, *Scientific Reports* (2012) 1 – 5.
- [29] N. Yuan, Z. Fu, H. Zhang, L. Piao, E. Xoplaki, J. Luterbacher, Detrended partial-cross-correlation analysis: A new method for analyzing correlations in complex system, *Scientific Reports* 5 (8143).
- [30] B. Podobnik, H. E. Stanley, Detrended cross-correlation analysis: A new method for analyzing two nonstationary time series, *Phys. Rev. Lett* 100 (2008) 1–4.
- [31] C.-K. Peng, S. V. Buldyrev, S. Havlin, M. Simons, H. E. Stanley, A. L. Goldberger, Mosaic organization of dna nucleotides, *Phys. Rev. E* 49 (1994) 1685–1689.
- [32] M. F. da Silva, E. J. de Area Leão Pereira, A. M. da Silva-Filho, A. P. N. de Castro, J. G. V. Miranda, G. F. Zebende, Quantifying the contagion effect of the 2008 financial crisis between the G7 countries (by GDP nominal), *Physica A* 453 (2016) 1 – 8.
- [33] B. Podobnik, Z.-Q. Jiang, W.-X. Zhou, H. E. Stanley, Statistical tests for power-law cross-correlated processes, *Phys. Rev. E* 84 (2011) 066118.

- [34] R. Balocchi, M. Varanini, A. Macerrata, Quantifying different degrees of coupling in detrended cross-correlation analysis, *Europhysics Letters* 101 (2013) 20011.
- [35] G.-J. Wang, C. Xie, S. Chen, J.-J. Yang, Ming-YanYang, Random matrix theory analysis of cross-correlations in the US stock market: Evidence from Pearson's correlation coefficient and detrended cross-correlation coefficient, *Physica A* 392 (17) (2013) 3715–3730.
- [36] G.-J. Wang, C. Xie, Y.-J. Chen, S. Chen, Statistical properties of the foreign exchange network at different time scales: evidence from detrended cross-correlation coefficient and minimum spanning tree, *Entropy* 15 (5) (2013) 1643–1662.
- [37] A. Carbone, G. Castelli, H. Stanley, Time-dependent hurst exponent in financial time series, *Physica A* 344 (2004) 267 – 271.
- [38] P. Ferreira, A. Dionisio, E. F. Guedes, G. F. Zebende, A sliding windows approach to analyse the evolution of bank shares in the European Union, *Physica A* 490 (2018) 1355 – 1367.
- [39] J. A. Matos, S. M. Gama, H. J. Ruskin, A. A. Sharkasi, M. Crane, Time and scale hurst exponent analysis for financial markets, *Physica A: Statistical Mechanics and its Applications* 387 (15) (2008) 3910 – 3915.
- [40] G. Zebende, A. Brito, A. S. Filho, A. Castro, ρ_{DCCA} applied between air temperature and relative humidity: An hour/hour view, *Physica A: Statistical Mechanics and its Applications* 494 (2018) 17 – 26.
- [41] T. Preis, Econophysics – complex correlations and trend switchings in financial time series, *The European Physical Journal-Special Topics* 194 (1) (2011) 5–86.

3.4 Teste estatístico para $\Delta\rho_{DCCA}$

Neste *paper*, propomos um teste estatístico para o $\Delta\rho_{DCCA}$ (Silva et al. (2016)), tendo como base o teste para o ρ_{DCCA} criado por Podobnik et al. (2011). A partir de duas séries temporais de mesmo comprimento, o primeiro passo consisti na divisão das séries ao meio. Em seguida, as séries são embaralhadas e os valores de ρ_{DCCA} e de $\Delta\rho_{DCCA}$ são computados. Por conseguinte, o procedimento é repetido 10 mil vezes e a função de distribuição de probabilidade (PDF) é obtida. Por fim, os valores críticos são obtidos (ver a Figura 3.4).



Figura 3.4: Algoritmo do teste do $\Delta\rho_{DCCA}$. Fonte: Guedes et al. (2018b).

Desafios superados Para estar em conformidade com os padrões exigidos pelo periódico e, portanto, ser publicado, foram necessários revisões sucessivas contendo a inclusão de novas referências bem como a melhoria da metodologia.



Statistical test for $\Delta\rho_{DCCA}$ cross-correlation coefficient

E.F. Guedes^a, A.A. Brito^{a,b}, F.M. Oliveira Filho^{a,c}, B.F. Fernandez^d,
A.P.N. de Castro^e, A.M. da Silva Filho^f, G.F. Zebende^{f,g,*}

^a Computational Modeling Program, SENAI CIMATEC, Salvador, Bahia, Brazil

^b Federal Institute of Paulo Afonso, Bahia, Brazil

^c Estácio de Sá University, Gilberto Gil Campus, Salvador, Bahia, Brazil

^d Municipal Foundation Egberto Costa, Feira de Santana, Bahia, Brazil

^e Jorge Amado University Center, Bahia, Brazil

^f Earth Sciences and Environment Modeling Program, State University of Feira de Santana, Bahia, Brazil

^g Department of Physics, State University of Feira de Santana, Bahia, Brazil



HIGHLIGHTS

- We proposed a new statistical test for $\Delta\rho_{DCCA}$.
- We have analyzed simulated and real time series.
- We define a new critical value for this dependency at specific confidence level.

ARTICLE INFO

Article history:

Received 2 June 2017

Received in revised form 13 November 2017

Available online 15 March 2018

Keywords:

Time series

DCCA cross-correlation coefficient

Statistical test

ABSTRACT

In this paper we propose a new statistical test for $\Delta\rho_{DCCA}$, Detrended Cross-Correlation Coefficient Difference, a tool to measure contagion/interdependence effect in time series of size N at different time scale n . For this proposition we analyzed simulated and real time series. The results showed that the statistical significance of $\Delta\rho_{DCCA}$ depends on the size N and the time scale n , and we can define a critical value for this dependency in 90%, 95%, and 99% of confidence level, as will be shown in this paper.

© 2018 Elsevier B.V. All rights reserved.

1. Introduction

The Detrended cross-correlation coefficient, ρ_{DCCA} , proposed by Zebende [1] intended to measure the level of cross-correlation between two non-stationary times series of size N . Since its implementation, ρ_{DCCA} has become an important tool for cross-correlation analysis and has been applied in many areas of knowledge, such as: climatology [2–4], crime indicators [5,6], economy [7–20], in geology [21], among others.

Unlike other statistical methods (like Pearson correlation coefficient or [22,23]), ρ_{DCCA} algorithm takes into account the temporal order of data, which does not contradict the basic principle of time series analysis, e.g., the temporal dependence between the variables. In this way, ρ_{DCCA} has some advantages over other cross-correlation coefficients, such as:

- measures cross-correlation between two time series at different time scales n [9];
- is a robust tool for nonlinear time series analyses [6,24].

* Corresponding author.

E-mail address: gzebende@pq.cnpq.br (G.F. Zebende).

In this sense, Podobnik et al. developed a statistical test based on the ρ_{DCCA} , this test assesses the null hypothesis for this coefficient [25]:

$$\begin{aligned} H_0 : \rho_{DCCA} &= 0 \\ H_1 : \rho_{DCCA} &\neq 0. \end{aligned} \quad (1)$$

This statistical test shows that, ρ_{DCCA} depend on the long-range auto-correlation α_1 and α_2 (for series 1 and 2), n (time scale), and N (size of the series). Considering ρ_{DCCA} , da Silva et al. [18] defined a new variable recently in order to measure contagion/interdependence,¹ namely:

$$\Delta\rho_{DCCA}(n) \equiv \rho_{DCCA}^{after}(n) - \rho_{DCCA}^{before}(n). \quad (2)$$

Such, $\rho_{DCCA}^{after}(n)$ is the detrended cross-correlation after the crisis and $\rho_{DCCA}^{before}(n)$ is the detrended cross-correlation before the crisis. $\Delta\rho_{DCCA}$ introduces a new way to analyze the effects of interdependence and contagion in economic index, see [26,19].

Thus, from the results of $\Delta\rho_{DCCA}(n)$ we ask, how much $\Delta\rho_{DCCA}$ is statistically significant? In order to answer this question, we propose a statistical test for $\Delta\rho_{DCCA}$. To present this proposal, we divide this paper in methodology (2), results (3), and conclusions (4).

2. Methodology

2.1. The detrended cross-correlation coefficient, ρ_{DCCA}

The detrended cross-correlation coefficient is a new method to quantify the level of cross-correlation between two non-stationary time series [1]. This method is based on detrended fluctuation analysis (DFA) [27] and detrended cross-correlation analysis (DCCA) [28]. We present the algorithm of ρ_{DCCA} below in five steps:

Step I: considering two time series, $\{x_t\}$ and $\{y_t\}$, with $t = 1, 2, \dots, N$ (time series length). We integrated these time series, obtaining two new series

$$xx_k = \sum_{t=1}^k x_t \quad \text{and} \quad yy_k = \sum_{t=1}^k y_t, \quad k = 1, 2, \dots, N. \quad (3)$$

Step II: we divide these two integrated time series, $\{xx_t\}$ and $\{yy_t\}$, into $(N - n)$ overlapping boxes of equal length n , with $4 \leq n \leq \frac{N}{4}$

Step III: we calculate the local trend of each box by a least-squares fit of each series, $xP_i(k)$ and $yP_i(k)$, and the covariance of the residuals in each box by:

$$f_{xy}^2(n, i) = \frac{1}{(n+1)} \sum_{k=i}^{i+n} (xx_k - xP_i(k))(yy_k - yP_i(k)). \quad (4)$$

Step IV: the average over all $(N - n)$ overlapping boxes is calculated to obtain the new covariance function:

$$F_{xy}^2(n) = \frac{1}{(N-n)} \sum_{i=1}^{N-n} f_{xy}^2(n, i). \quad (5)$$

Step V: finally, the cross-correlation coefficient ρ_{DCCA} is define by:

$$\rho_{DCCA}(n) \equiv \frac{F_{xy}^2(n)}{F_{xx}(n)F_{yy}(n)}. \quad (6)$$

This cross-correlation coefficient, as we can see, depends on the box length n (time scale), as well as, the size of the series N . DCCA cross-correlation coefficient ranges from $-1 \leq \rho_{DCCA} \leq 1$, e.g.:

$$\begin{aligned} \rho_{DCCA} &= 1, \text{ means a perfect cross-correlation;} \\ \rho_{DCCA} &= 0, \text{ means there is no cross-correlation;} \\ \rho_{DCCA} &= -1, \text{ means a perfectly anti cross-correlation.} \end{aligned}$$

One of the advantages of this coefficient is to measure the cross-correlations between two non-stationary time series at different time scales [11,14,16,29–31,21,25,32,33], among others.

¹ **Interdependence**: if exit some cross-correlation between the variables, $\rho_{DCCA} \neq 0$, for the entire time series under analysis, and **contagion**: if after a specific data (before/after), the value of $\Delta\rho_{DCCA}$ is non-zero.




Fig. 1. (Color online) Probability distribution function (PDF) of $\Delta\rho_{DCCA}$ for $n = 4$ (time scale) with N equal to: 250 (\square blue), 500 (\circ yellow), 1000 (\triangle red), and 2000 ($*$ black). We make here $n = 4$ (time scale).

2.2. Statistical test for $\Delta\rho_{DCCA}$

The paper proposed by Podobnik et al. [25], “Statistical tests for power-law cross-correlated processes”, examines the statistical significance of the detrended cross-correlation coefficient, and tests the null hypothesis for ρ_{DCCA} (classical test). In this condition, for 10,000 pair of independent and identically distributed (*iid*) time series, with $\alpha_1 = \alpha_2 = 0.5$ (random variables, according to the DFA method), they calculated the probability distribution function (PDF) of the ρ_{DCCA} , for different values of n (time scale) and N (size of the series). In this case, ρ_{DCCA} will be normally distributed around zero with each PDF($\rho_{DCCA}(n, N)$) pointing to a specific critical value $\rho_c(\alpha_1 = 0.5, \alpha_2 = 0.5, n, N)$ with a specific confidence level (like 95%). Other papers performed the statistical test for ρ_{DCCA} [34–36,31].

But, if we have two distinct moments separated by some phenomenon, like an economic crisis, we can calculate $\Delta\rho_{DCCA}$ [18],

$$\Delta\rho_{DCCA}(n) \equiv \rho_{DCCA}^{after}(n) - \rho_{DCCA}^{before}(n) \quad (7)$$

where, $\rho_{DCCA}^{before}(n)$ and $\rho_{DCCA}^{after}(n)$ represents respectively the detrended cross-correlation coefficient before/after this moment. But, we realize that the $\Delta\rho_{DCCA}(n)$, as $\rho_{DCCA}(n)$, requires a statistical test. This test for $\Delta\rho_{DCCA}$ will be presented hereafter.

Like in [25], we also look at the area under the probability distribution function (PDF) of $\Delta\rho_{DCCA}(n)$, imagining this PDF to be normally distributed. For this purpose, we will follow the steps:

1. generate two times series with long-range cross-correlation by ARFIMA process [28];
2. split these time series into two (before/after) and shuffle these pairs;
3. estimate $\rho_{DCCA}(n)$ (each part) and their difference $\Delta\rho_{DCCA}(n)$;
4. repeat from Step 2 many (10,000) times;
5. obtain the distribution of $\Delta\rho_{DCCA}(n)$.

Fig. 1 shows an example of the PDF of $\Delta\rho_{DCCA}(n)$ for these surrogate time series with $N = 250$ (\square blue), 500 (\circ yellow), 1000 (\triangle red), and 2000 ($*$ black). By Fig. 1 and the descriptive statistics presented in Table 1, we can see that the PDF of $\Delta\rho_{DCCA}(n)$ converges to a normal distribution [37] with mean approximately equal to zero. In this perspective, we can test the null hypothesis against the alternative hypothesis, that is:

$$\begin{aligned} H_0 &: \Delta\rho_{DCCA}(n) = 0 \text{ (the differences are not significant);} \\ H_1 &: \Delta\rho_{DCCA}(n) \neq 0 \text{ (the differences are significant).} \end{aligned}$$

Therefore, for each PDF defined by N and n , we found the positive critical point $\Delta\rho_c(n)$ for: 90%, 95%, and 99% of confidence level, defined by:

$$\langle \Delta\rho_{DCCA} \rangle \pm z_{\alpha/2} \frac{SD}{\sqrt{N}} \quad (8)$$

where $\langle \Delta\rho_{DCCA} \rangle$ is the sample mean, $z_{\alpha/2}$ value for the desired confidence level α (see normal curve table), SD the standard deviation, and N the sample size. The results we present now in the next section.

Table 1
Descriptive summary of $\Delta\rho_{DCCA}(n)$ for $N = 250$, $N = 500$, $N = 1000$ and $N = 2000$.

Statistics	$n = 4$	$n = 8$	$n = 16$	$n = 32$	$n = 62$	$n = 125$	$n = 250$
$N = 250$							
Mean	0.00167	0.00146	0.00135	–	–	–	–
SD	0.14951	0.13975	0.13701	–	–	–	–
Skewness	–0.05398	–0.06067	–0.05388	–	–	–	–
Kurtosis	2.94602	2.89518	2.89326	–	–	–	–
$N = 500$							
Mean	0.00486	0.00354	0.00253	0.00208	0.00172	–	–
SD	0.10522	0.09778	0.09499	0.09495	0.09762	–	–
Skewness	0.00415	0.02124	0.01217	–0.00307	0.00229	–	–
Kurtosis	2.99898	2.99528	2.94897	2.93297	2.93753	–	–
$N = 1000$							
Mean	0.0004	0.0002	0.0003	0.0005	0.0005	0.0005	–
SD	0.0752	0.0697	0.0671	0.0663	0.0670	0.0697	–
Skewness	–0.0670	–0.0805	–0.0735	–0.0643	–0.0696	–0.0532	–
Kurtosis	2.9708	3.0022	3.0313	3.0319	3.0389	3.0424	–
$N = 2000$							
Mean	0.0001	–0.0003	–0.0005	–0.0005	–0.0005	–0.0006	–0.0007
SD	0.0532	0.0492	0.0475	0.0468	0.0467	0.0472	0.0490
Skewness	0.0414	0.0407	0.0513	0.0580	0.0603	0.0649	0.0690
Kurtosis	2.9519	2.9323	2.9463	2.9654	2.9677	2.9786	2.9955




Fig. 2. (Color online) $\Delta\rho_{DCCA}$ values as a function of n for 90%, 95%, and 99% of confidence levels. Here $N = 2000$.

3. Results

3.1. Simulated case

For 10,000 pairs of surrogate time series, following steps (recipe) presented in Section 2.2, we computed the probability distribution function (PDF) for $\Delta\rho_{DCCA}(n)$ with $N = 250, 500, 1000$, and 2000 . In this sense, Table 1 presents the descriptive statistics with: Mean, Standard Deviation (SD), Skewness, and Kurtosis for $\Delta\rho_{DCCA}$ in function of n

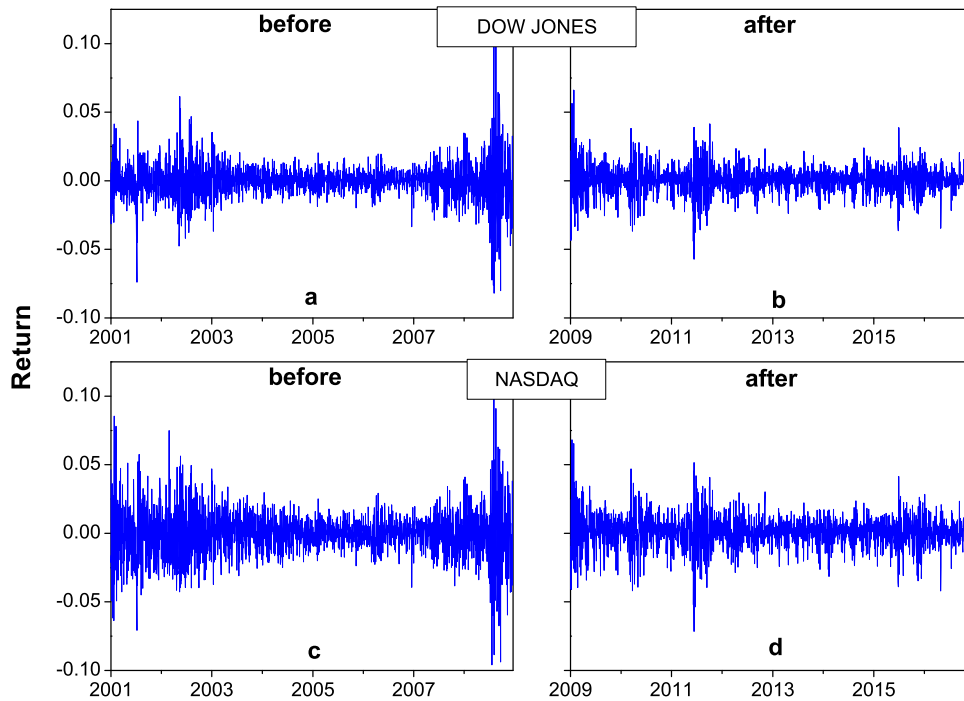
In general the descriptive statistical shows that the $\Delta\rho_{DCCA}(n)$ distribution has mean zero and is normally distributed, because $Kurtosis \approx 3$ and $Skewness \approx 0$. The standard deviation decreases if we increase the value of N .

But, our main contribution is presented in Table 2 (new), with the critical values $\Delta\rho_c(n)$ at 90%, 95%, and 99% of confidence level for different sizes N . We can see that, if N increases $\Delta\rho_c$ decreases and for a given N . This can be better introduced if we look at the figure of $\Delta\rho_c$ in function of n , see Fig. 2 with $N = 2000$ for example. This figure show $\Delta\rho_c$ at 90%, 95%, and 99% of confidence level. The lines are wide when confidence level is higher.

After this simulated case, we introduce now an empirical case.

Table 2Critical values of $\Delta\rho_{DCCA}$ with 90%, 95%, and 99% of confidence level (CL) at different sizes N .

Critical values	$n = 4$	$n = 8$	$n = 16$	$n = 32$	$n = 62$	$n = 125$	$n = 250$
CL = 90%							
$N = 250$	0.0025	0.0023	0.0023	–	–	–	–
$N = 500$	0.0017	0.0016	0.0016	0.0016	0.0016	–	–
$N = 1000$	0.0012	0.0011	0.0011	0.0011	0.0011	0.0011	–
$N = 2000$	0.0009	0.0008	0.0008	0.0008	0.0008	0.0008	0.0008
CL = 95%							
$N = 250$	0.0029	0.0027	0.0027	–	–	–	–
$N = 500$	0.0021	0.0019	0.0019	0.0019	0.0019	–	–
$N = 1000$	0.0015	0.0014	0.0013	0.0013	0.0013	0.0014	–
$N = 2000$	0.0010	0.0010	0.0009	0.0009	0.0009	0.0009	0.0010
CL = 99%							
$N = 250$	0.0038	0.0036	0.0035	–	–	–	–
$N = 500$	0.0027	0.0025	0.0024	0.0024	0.0025	–	–
$N = 1000$	0.0019	0.0018	0.0017	0.0017	0.0017	0.0018	–
$N = 2000$	0.0014	0.0013	0.0012	0.0012	0.0012	0.0012	0.0013

**Fig. 3.** (Color online) Return for Dow Jones (up panel) and Nasdaq (down panel), where (a,c) represents the period from March/13/2001 to February/25/2009 (before) and (b,d) represents the period from February/27/2009 to February/06/2017 (after).

3.2. Empirical case

We applied a statistical test proposed for $\Delta\rho_{DCCA}(n)$ to analyze the cross-correlation between Dow Jones and Nasdaq index, $S(t)$. We chose the daily closing index between March/13/2001 and February/06/2017. First, we calculated the returns by:

$$r(t) = \ln\left(\frac{S(t)}{S(t-1)}\right). \quad (9)$$

After, we split these new time series with the same size N into two (before/after), see Fig. 3. We can see a great volatility around 2008 for $r(t)$, because of the global financial crisis [18]. Thereafter, we calculate $\rho_{DCCA}(n)$ between the return of Dow Jones and Nasdaq (before/after period), Fig. 4. In this figure we can see that $\rho_{DCCA}(n)$ had a positive strong cross-correlation, for both periods before and after. However, $\Delta\rho_{DCCA}(n)$ Eq. (7), oscillates between positive (small time scale) and negative values (large time scale), see Fig. 5. Therefore, the question is, where $\Delta\rho_{DCCA}(n)$ is statistically significant? The answer is, for a specific confidence level, outside $\Delta\rho_c$, see Fig. 5 dashed line (red). The result of this empirical case clearly confirms the alternative hypothesis, e.g., $H_1 : \Delta\rho_{DCCA}(n) \neq 0$ (the differences are significant) between the periods before/after for almost time scales, excepting the period between 100 and 200 days.




Fig. 4. (Color online) ρ_{DCCA} as a function of n for Dow Jones and Nasdaq return index. (a) Before specific period and (b) after specific period.




Fig. 5. (Color online) $\Delta\rho_{DCCA}$ as a function of n . Dash lines denote the rejection limits of the null hypotheses at 95% of confidence level.

4. Conclusions

There are a great number of empirical results in many areas of knowledge that show cross-correlations between two non-stationary time series at different levels. However, it is important to have a robust and statistically well-tested tool to measure these cross-correlations, such as the detrended cross-correlation coefficient. Based on the null hypothesis of ρ_{DCCA} , a statistical test already exists in order to determine if there is significance in these cross-correlations [25].

Therefore, if we split these time series into two periods, called before/after, we can analyze the difference between the values of ρ_{DCCA} (after–before) and thus measure this new coefficient, defined by $\Delta\rho_{DCCA}(n) \equiv \rho_{DCCA}^{after}(n) - \rho_{DCCA}^{before}(n)$ [18]. But does result have statistical significance? In this paper we proposed a statistical test to answer this question. Our test was based on the null hypothesis for $\Delta\rho_{DCCA}$, if the differences are statistically significant then the null hypothesis is rejected. For this test we analyzed simulated and real time series. The results show that the statistical significance of $\Delta\rho_{DCCA}$ depends on the size N and the time scale n , and we define a critical value for this dependency $\Delta\rho_c$ at 90%, 95%, and 99% of confidence level. This test is summarized in Table 2, which contains $\Delta\rho_c$ for different N and n .

Finally, we intend to convert our entire statistical test as supplementary data in brief article for freely open access in Physica A.

Acknowledgments

Guedes and Brito thank FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia), Brazil (Grant BOL 0976/2016 and BOL 0262/2017) and Zebende thanks CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), Brazil (Grant 309288/2013-4), Brazilian agencies, Brazil. The authors also thank Chris Borges.

References

- [1] G.F. Zebende, DCCA cross-correlation coefficient: quantifying level of cross-correlation, *Physica A* 390 (4) (2011) 614–618.
- [2] R.T. Vassoler, G.F. Zebende, DCCA cross-correlation coefficient apply in time series of air temperature and air relative humidity, *Physica A* 391 (7) (2012) 2438–2443.
- [3] R. Balocchi, M. Varanini, A. Macerrata, Quantifying different degrees of coupling in detrended cross-correlation analysis, *Europhys. Lett.* 101 (2013) 20011.
- [4] N. Yuan, Z. Fu, Different spatial cross-correlation patterns of temperature records over China: A DCCA study on different time scales, *Physica A* 400 (2014) 71–79.
- [5] G.F. Zebende, M.F. Silva, A.M. Filho, DCCA cross-correlation coefficient differentiation: Theoretical and practical approaches, *Physica A* 392 (8) (2013) 1756–1761.
- [6] A. Machado Filho, M.F. da Silva, G.F. Zebende, Autocorrelation and cross-correlation in time series of homicide and attempted homicide, *Physica A* 400 (2014) 12–19.
- [7] G.-J. Wang, C. Xie, Cross-correlations between WTI crude oil market and US stockmarket: A perspective from econophysics, *Acta Phys. Polon. B* 43 (10) (2012) 2021–2036.
- [8] G.-J. Wang, C. Xie, L.-Y. He, S. Chen, Detrended minimum-variance hedge ratio: A new method for hedge ratio at different time scales, *Physica A* 405 (2014) 70–79.
- [9] G.-J. Wang, C. Xie, Y.-J. Chen, S. Chen, Statistical properties of the foreign exchange network at different time scales: evidence from detrended cross-correlation coefficient and minimum spanning tree, *Entropy* 15 (5) (2013) 1643–1662.
- [10] G.-J. Wang, C. Xie, S. Chen, F. Han, Cross-correlations between energy and emissions markets: New evidence from fractal and multifractal analysis, *Math. Probl. Eng.* 2014 (197069) (2014) 1–13.
- [11] J.C. Reboredo, M.A. Rivera-Castro, G.F. Zebende, Oil and US dollar exchange rate dependence: A detrended cross-correlation approach, *Energy Econ.* 42 (c) (2013) 132–139.
- [12] M.F. da Silva, A.P.N. de Castro, A.M. da Silva Filho, Quantificando a influência do mercado de câmbio nos preços do milho e da soja no município de Barreiras, *Rev. Conjuntura Planej.* 182 (2014) 42–49.
- [13] E.F. Guedes, G.F. Zebende, A. Machado, Análise temporal dos indicadores da indústria de transformação da Bahia: Uma abordagem com métodos da mecânica estatística, *Conjuntura Planej.* 186 (2015) 34–43.
- [14] U. Bashir, Y. Yu, M. Hussain, G.F. Zebende, Do foreign exchange and equity markets co-move in Latin American region? Detrended cross-correlation approach, *Physica A* 462 (2016) 889–897.
- [15] P. Ferreira, A. Dionísio, G.F. Zebende, Why does the Euro fail? The DCCA approach, *Physica A* 443 (2016) 543–554.
- [16] M. Hussain, G.F. Zebende, U. Bashir, D. Donghong, Oil price and exchange rate co-movements in Asian countries: Detrended cross-correlation approach, *Physica A* 465 (1) (2017) 338–346.
- [17] M.F. da Silva, Á.J.d.A.L. Pereira, A.M. da Silva Filho, A.P. Nunes de Castro, J.G.V. Miranda, G.F. Zebende, Quantifying cross-correlation between Ibovespa and Brazilian blue-chips: The DCCA approach, *Physica A* 424 (C) (2015) 124–129.
- [18] M.F. da Silva, E.J. de Area Leão Pereira, A.M. da Silva Filho, A.P.N. de Castro, J.G.V. Miranda, G.F. Zebende, Quantifying the contagion effect of the 2008 financial crisis between the G7 countries (by GDP nominal), *Physica A* 453 (2016) 1–8.
- [19] E. Guedes, A. Dionísio, P. Ferreira, G. Zebende, DCCA cross-correlation in blue-chips companies: a view of the 2008 financial crisis in the eurozone, *Physica A* 479 (2017) 38–47.
- [20] D.A.J. Blythe, V.V. Nikulin, K.-R. Muller, Robust statistical detection of power-law cross-correlation, *Nature* 6 (27089) (2016) 1–10.
- [21] E. Marinho, A. Sousa, R. Andrade, Using detrended cross-correlation analysis in geophysical data, *Physica A* 392 (2013) 2195–2201.
- [22] L. Kristoufek, Detrended fluctuation analysis as a regression framework: Estimating dependence at different scales, *Phys. Rev. E* 91 (2015) 022802.
- [23] P. Oświęcimka, L. Livi, S. Drożdż, Multifractal cross-correlation effects in two-variable time series of complex network vertex observables, *Phys. Rev. E* 94 (4) (2016) 042307.
- [24] L. Kristoufek, Rescaled range analysis and detrended fluctuation analysis: Finite sample properties and confidence intervals, *AUCO Czech Econ. Rev.* 4 (3) (2010) 315–329.
- [25] B. Podobnik, Z.-Q. Jiang, W.-X. Zhou, H.E. Stanley, Statistical tests for power-law cross-correlated processes, *Phys. Rev. E* 84 (2011) 066118.
- [26] P. Ferreira, Does the Euro crisis change the cross-correlation pattern between bank shares and national indexes? *Physica A* 463 (2016) 320–329.
- [27] C.-K. Peng, S.V. Buldyrev, S. Havlin, M. Simons, H.E. Stanley, A.L. Goldberger, Mosaic organization of DNA nucleotides, *Phys. Rev. E* 49 (1994) 1685–1689.
- [28] B. Podobnik, H.E. Stanley, Detrended cross-correlation analysis: A new method for analyzing two nonstationary time series, *Phys. Rev. Lett.* 100 (2008) 1–4.
- [29] L. Kristoufek, Measuring cross-correlation between non-stationary series with DCCA coefficient, *Physica A* 402 (2014) 291–298.
- [30] L. Kristoufek, Detrending moving-average cross-correlation coefficient: Measuring cross-correlations between non-stationary series, *Physica A* 406 (2014) 169–175.
- [31] L. Kristoufek, Testing power-law cross-correlations: rescaled covariance test, *Eur. Phys. J. B* 86 (2013) 418.
- [32] G.-J. Wang, C. Xie, S. Chen, J.-J. Yang, Ming-Yan Yang, Random matrix theory analysis of cross-correlations in the US stockmarket: Evidence from Pearson's correlation coefficient and detrended cross-correlation coefficient, *Physica A* 392 (17) (2013) 3715–3730.
- [33] X. Jin, Time-varying return-volatility relation in international stock markets, *Int. Rev. Econ. Finance* 51 (2017) 157–173.
- [34] D.A.J. Blythe, A Rigorous and Efficient Asymptotic Test for Power-Law Cross-Correlation, Cornell University, 2013, pp. 1–23.
- [35] G.-J. Wang, C. Xie, Cross-correlations between Renminbi and four major currencies in the Renminbi currency basket, *Physica A* 392 (2013) 1418–1428.
- [36] D.D. Kang, D.I. Lee, J.-W. Jung, K. Kim, Dynamical characteristics in time series between PM10 and wind speed, in: 2013 International Conference on Environment, Energy, Ecosystems and Development, 2013.
- [37] R.H. Shumway, D.S. Stoffer, *Time Series Analysis and Its Applications*, Springer-Verlag, New York, 2000.

3.5 Teste estatístico para $\Delta\rho_{DCCA}$: Métodos e dados

Após a publicação do teste estatístico pelo periódico *Physica A*, fomos convidados pela revista *Data in Brief* para publicar um artigo complementar, dando ênfase aos dados da simulação do teste estatístico.

Além do algoritmo do teste proposto, neste *paper* é disponibilizada uma base de dados para download, o que possibilitará a realização de novos estudos sobre a temática.



ELSEVIER

Contents lists available at ScienceDirect

Data in Brief

journal homepage: www.elsevier.com/locate/dib

Data Article

Statistical test for $\Delta\rho_{DCCA}$: Methods and data

E.F. Guedes^a, A.A. Brito^{a,b}, F.M. Oliveira Filho^{a,c},
 B.F. Fernandez^d, A.P.N. de Castro^e, A.M. da Silva Filho^f,
 G.F. Zebende^{g,f}

^a Computational Modeling Program, SENAI CIMATEC, Salvador, Bahia, Brazil^b Federal Institute of Paulo Afonso, Bahia, Brazil^c Estácio de Sá University, Gilberto Gil Campus, Salvador, Bahia, Brazil^d Municipal Foundation Egberto Costa, Feira de Santana, Bahia, Brazil^e Jorge Amado University Center, Bahia, Brazil^f Earth Science and Environment Modeling Program, State University of Feira de Santana, Bahia, Brazil^g Department of Physics, State University of Feira de Santana, Bahia, Brazil

ARTICLE INFO

Article history:

Received 24 February 2018

Received in revised form

10 March 2018

Accepted 16 March 2018

Available online 22 March 2018

ABSTRACT

In this paper the algorithm for $\Delta\rho_{DCCA}$ statistical test (Guedes et al., 2018) [1] is presented. Our test begins with the simulation of four time series pairs, by an ARFIMA process. These time series has $N = 250, 500, 1000,$ and 2000 points, see Guedes et al. (2018) [1]. The probability distribution function (PDF) is made available for all 10,000 samples, that start from the original time series, in supplementary material.

© 2018 The Authors. Published by Elsevier Inc. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

Specifications Table

Subject area	Physics and Astronomy
More specific subject area	General physics and methods
Method name	$\Delta\rho_{DCCA}$ Statistical test

DOI of original article: <https://doi.org/10.1016/j.physa.2018.02.148>E-mail address: gfzebende@pq.cnpq.br (G.F. Zebende).<https://doi.org/10.1016/j.dib.2018.03.080>2352-3409/© 2018 The Authors. Published by Elsevier Inc. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

Reference of the original paper
 Type of data
 Data format
 Data Accessibility

<https://doi.org/10.1016/j.physa.2018.02.148>
 Zip File (Deltarhodata.zip)
 ASCII (Raw and analyzed)
 Data are accessible within the article

Value of the data

- A robust test to analysis cross-correlation is important.
- However, for $\Delta\rho_{DCCA}$, there is not a statistical test.
- Here, we presented the algorithm to test the significance of $\Delta\rho_{DCCA}$.
- Finally, the probability distribution function (PDF) for this test is found, as a supplementary material (Deltarhodata.zip), and this PDF allows that other researchers extend yours analyses.

1. Data

The test starts with four time series pairs with $N = 250$, $N = 500$, $N = 1000$, and $N = 2000$ points, produced by an autoregressive integrated moving average process (ARFIMA) [2,3], see Fig. 1. These time series initially are useful in modeling time series with long memory, and are found in the supplementary material as ASCII file: {(af2501.txt; af2502.txt), (af5001.txt;af5002.txt), (af10001.txt; af10002.txt), (af20001.txt;af20002.txt)}. After this time series simulation the algorithm for statistical test is presented below in the Section 4.

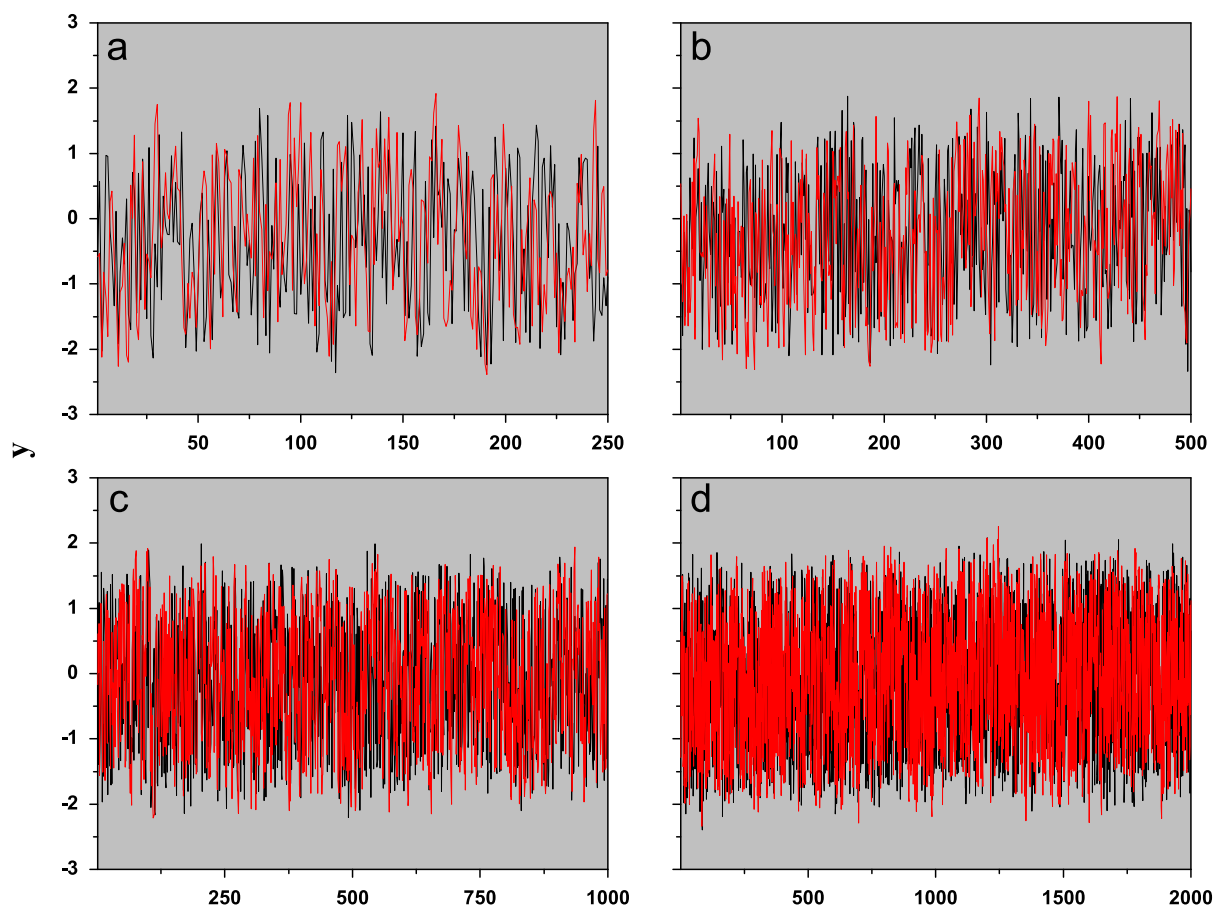


Fig. 1. Original time series (pairs) produced by an ARFIMA process, with: (a) $N = 250$, (b) $N = 500$, (c) $N = 1000$, and (d) $N = 2000$.

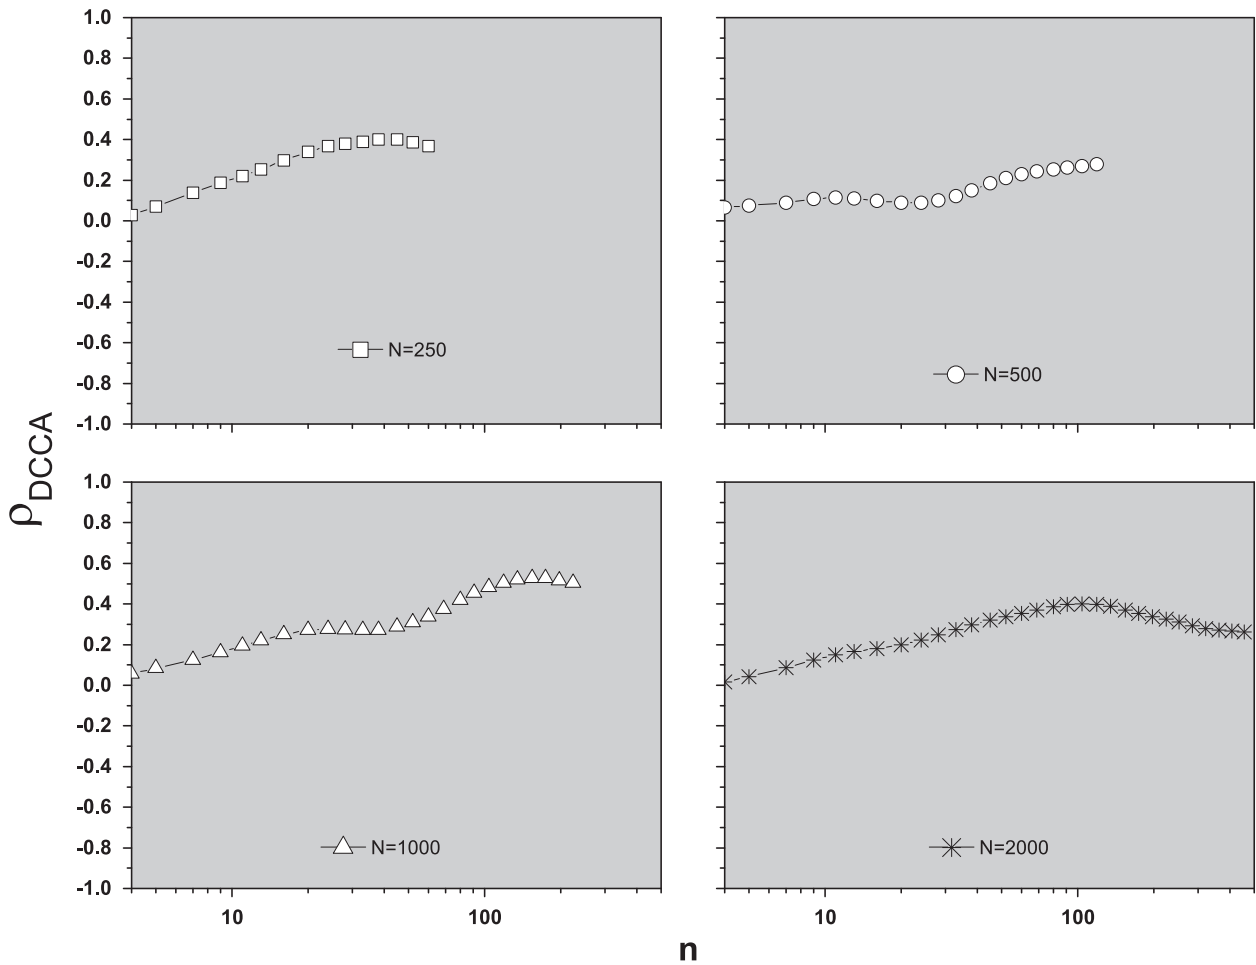


Fig. 2. ρ_{DCCA} as a function of n .

1	2	3	4	5	6	7	8	9	10	af101.txt
1	2	3	4	5	6	7	8	9	10	af102.txt

Step 1:

Before	After
--------	-------

Shuffle Randomly

2	3	5	4	1	6	7	9	10	8
×					×				
4	2	3	1	5	10	7	6	8	9

Step 2:

$$\rho_{DCCA}(b) \qquad \rho_{DCCA}(a)$$

$$\Delta\rho_{DCCA} = \rho_{DCCA}(a) - \rho_{DCCA}(b)$$

Step 3:

Repeat many times this procedure from Step 1.

Step 4:

Obtain the PDF function.

Fig. 3. The algorithm procedure.

2. Experimental design, materials, and methods

Initially, in the sense to verify the cross-correlation between these original time series (raw data), we applied the Detrended cross-correlation coefficient, ρ_{DCCA} [4], see Fig. 2.

Thereafter, from the original signal we:

- (a) Split these time series into two (before/after) and we shuffle randomly these pairs (see Fig. 3);
- (b) Estimate $\rho_{DCCA}(n)$ (each part) and their difference $\Delta\rho_{DCCA}(n)$ [1];
- (c) Repeat this procedure many (10,000) times from Step (a);
- (d) And, finally obtain the PDF function of $\Delta\rho_{DCCA}(n)$.

See the supplementary material (Deltarhodata.zip).

Acknowledgments

Guedes and Brito thanks FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia) (Grant BOL 0976/2016 and BOL 0262/2017) and Zebende thanks CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) (Grant 304362/2017-4), Brazilian agencies.

Appendix A. Transparency document

Supplementary data associated with this article can be found in the online version at <http://dx.doi.org/10.1016/j.dib.2018.03.080>.

Appendix B. Supporting Information

Supplementary data associated with this article can be found in the online version at <http://dx.doi.org/10.1016/j.dib.2018.03.080>.

References

- [1] E.F. Guedes, A.A. Brito, F.M.O. Filho, B.F. Fernandez, A.P.N. de Castro, A.M. da Silva Filho, G.F. Zebende, Statistical test for Delta-rho-DCCA cross-correlation coefficient, *Physica A* 501C (2018) 134–140.
- [2] J.R.M. HOSKING, Fractional differencing, *Biometrika* 68 (1) (1981) 165–176.
- [3] B. Podobnik, I. Grosse, D. Horvatić, S. Ilic, C.P. Ivanov, E.H. Stanley, Quantifying cross-correlations using local and global detrending approaches, *Eur. Phys. J. B* 71 (2) (2009) 243–250.
- [4] G.F. Zebende, DCCA cross-correlation coefficient: quantifying level of cross-correlation, *Phys. A* 390 (4) (2011) 614–618.

Considerações finais

4.1 Conclusões

A presente tese teve como objetivo principal propor um modelo computacional que permite o monitoramento da eficiência, da interdependência e de contágio de mercados financeiros. Com esse objetivo, implementamos a abordagem de janelas deslizantes junto aos métodos Detrended Fluctuation Analysis e coeficiente de correlação cruzada ρ_{DCCA} (ver, os certificados de registro de programas de computador no apêndice A.1) para avaliar, de maneira dinâmica, as hipóteses teóricas de eficiência (ver Subseção 2.2), de interdependência e de contágio (ver Subseção 2.3) e desenvolvemos um teste paramétrico para avaliar a significância estatística do $\Delta\rho_{DCCA}$ (ver Subseção 2.3).

Considerando os quatro objetivos específicos deste projeto, foram submetidos 5 artigos em revistas internacionais. No artigo *A sliding windows approach to analyse the evolution of bank shares in the European Union* publicado pelo periódico *Physica A*, utilizamos a abordagem de janela deslizante com o método DFA para investigar a forma fraca de eficiência de mercado (ver Subseção 2.2) em 63 títulos financeiros de bancos da União Europeia num período que abrange duas crises diferentes: primeiro a crise do Subprime e, em segundo lugar, a crise da dívida nos países da Zona do Euro.

A abordagem proposta permitiu entender como as ações de bancos se comportam, quanto à eficiência, antes das duas crises, no período entre as crises e após o início da segunda crise. Observamos que a maioria dos bancos mudou de comportamento antipersistente para persistente, após a crise do Subprime. Isso pode ter uma influência no futuro, porque é mais provável que um dado padrão de retorno seja repetido. Outro resultado interessante é que alguns bancos não pertencentes à Zona do Euro mostraram um efeito similar aos da Zona do Euro. Após a crise da dívida, a maioria dos bancos se aproximou do nível de eficiência ($\alpha_{DFA} = 0,5$), o que poderia ser um bom indicador de um sistema financeiro estável. Logo, acreditamos que é possível monitorar a forma fraca da eficiência de mercados.

No artigo *DCCA cross-correlation in blue-chips companies: A view of the 2008 financial crisis in the Eurozone* publicado no periódico *Physica A* em 2017, analisamos as interações entre as *Blue-Chips* de cada um dos mercados da Zona do Euro e o seu respectivo índice bolsista, antes e depois da crise do Subprime.

Aqui, encontramos distribuições assimétricas do tipo cauda longa. O ρ_{DCCA} é sempre

positivo, o que demonstra claramente a adesão de cada *blue-chip* ao índice mestre. O que pode ser interpretado como um aumento da relação entre as empresas *blue-chips* e o respectivo índice nacional. Durante a crise, isso pode envolver um risco, porque qualquer distúrbio nas *blue-chips* poderá causar uma alta influência no índice. Os resultados apontam para um aumento na correlação cruzada de *blue-chips* e do respectivo índice nacional, para quase todos os países. Alemanha e Bélgica são as exceções, mostrando correlações semelhantes nos dois países. Nos demais países, as ações aumentaram suas correlações, o que significa mais integração no mercado e, conseqüentemente, um possível aumento do risco nesses países. Ademais, observamos que o coeficiente de correlação cruzada muda com o período de tempo. Esse fato nos deu a oportunidade de estudar o efeito da crise financeira de 2008 pela estimativa da diferença $\Delta\rho_{DCCA}$.

No artigo *DCCA cross-correlation coefficient with sliding windows* submetido ao periódico *Physica A*, propomos a utilização do coeficiente ρ_{DCCA} com a abordagem de janela deslizante para medir correlação cruzada à media que o tempo passa. Testamos a abordagem proposta em um caso simulado (aleatório) e em um caso empírico (índices financeiros dos mercados NYSE e NASDAQ (USA), DAX (Germany), IBOVESPA (Brasil) e SSE (China)). Diante dos resultados, observamos que é possível medir a correlação cruzada e identificar a transição de fase em função do períodos de tempo. Portanto, acreditamos que também é possível acompanhar a interdependência "co-movimentos" de mercados.

No artigo *Statistical test for $\Delta\rho_{DCCA}$ cross-correlation coefficient* publicado na revista no periódico *Physica A* em 2018, desenvolvemos um teste estatístico para validar a hipótese de interdependência ou contágio (ver Subseção 2.3), agora sob a perspectiva do $\Delta\rho_{DCCA}$. Aqui, testamos a hipótese nula $H_0 : \Delta\rho_{DCCA} = 0$ (as diferenças não são significativas, ou seja, há interdependência) contra a hipótese alternativa $H_1 : \Delta\rho_{DCCA} \neq 0$ (as diferenças são significativas, ou seja, há contágio).

Após um convite, o artigo complementar intitulado *Statistical test for $\Delta\rho_{DCCA}$: Methods and data* foi publicado pelo periódico *Data in Brief* em 2018, agora enfatizando ao método computacional desenvolvido e os dados do teste proposto.

Entre as contribuições desta pesquisa é possível destacar o desenvolvimento de dois métodos computacionais, a saber:

- Coeficiente de correlação cruzada ρ_{DCCA} com janela deslizante; e
- Teste estatístico para o $\Delta\rho_{DCCA}$.

Além dos artigos supracitados e dos métodos desenvolvidos, durante o curso de doutorado os seguintes artigos foram publicados em:

• Periódicos:

1. GUEDES, E.F.; SILVA-FILHO, A.M.; ZEBENDE, G.F. Proposta de modelo preditivo de curto prazo para a produção da indústria de transformação da Bahia: uma abordagem estatística. *CONJUNTURA & PLANEJAMENTO*, v. 1, p. 37-46, 2016.
2. GUEDES, E.F.; ZEBENDE, GILNEY FIGUEIRA; LIMA, I. C. C. . Quantificação dos efeitos do câmbio na produção da indústria de transformação baiana: uma abordagem via coeficiente de correlação cruzada pDCCA. *CONJUNTURA & PLANEJAMENTO*, v. 1, p. 75-89, 2017.
3. SOARES, D.S.C. ; OLIVEIRA-FILHO, F.M. ; GUEDES, E. F. Análise do Comportamento da produção industrial de Alimentos no Brasil. *REVISTA CIÊNCIA (IN) CENA*, v. 1, p. 199-212, 2017.
4. SILVA-FILHO, A.M.; ZEBENDE, G.F.; GUEDES, E.F. Análise Temporal das Subtrações de Veículos em Salvador (BA). *CONJUNTURA & PLANEJAMENTO*, v. 2, p. 47-61, 2017.

• Eventos:

1. BRITO, A. A.; ZEBENDE, G. F.; GUEDES, E.F.; SILVA-FILHO, A.M.; CASTRO, A. P. N.; OLIVEIRA-Filho, F.M.; Fernandez, B.F. Encontro de Outono da Sociedade Brasileira de Física. Statistical test for DCCA cross-correlation coefficient: $\Delta\rho_{DCCA}$. 2018.
2. DIAS, R.S.P.; DA SILVA-FILHO, A.M; ARAUJO, E.M.; GUEDES, E.F. 63º Região Brasileira da Sociedade Internacional de Biometria (RBras). Análise temporal dos casos de Diabetes Mellitus na região de Feira de Santana no período de 1998 a 2016. 2018.
3. BRITO, F.B.S.; MONTEIRO, R.L.S.; GUEDES, E.F.; SANTOS, L.B. IV SIINTEC e VIII PTI 2018. ETANOL NO BRASIL: UMA ABORDAGEM PREDITIVA DE PREÇOS. 2018.
4. SILVA-FILHO, A.M.; ZEBENDE, G.F.; GUEDES, E.F. XV EMR - Escola de Modelos de Regressão - Em homenagem ao Prof. Francisco Cribari. Análise temporal das subtrações de veículos em Salvador-BA: Uma abordagem com o coeficiente de correlação sem tendência pDCCA. 2017.
5. SILVA-FILHO, A. M.; GUEDES, E.F.; TOLEDO, O.C.; OLIVEIRA, R.A.; Zebende, G.F. XX Encontro Nacional de Modelagem Computacional e o VIII Encontro de

Ciência e Tecnologia de Materiais. Diferenciação do Coeficiente de Correlação Cruzada Sem Tendência: um aplicação na série temporal de veículos furtados e veículos roubados em Salvador-BA. 2017.

6. SOARES, D.S.C.; OLIVEIRA FILHO, F.M.; GUEDES, E.F. XX Encontro Nacional de Modelagem Computacional e o VIII Encontro de Ciência e Tecnologia de Materiais. Análise do Comportamento da Produção Industrial de Alimentos no Brasil. 2017.

4.2 Sugestões para trabalhos futuros

Como uma possível continuidade da pesquisa, pretendemos desenvolver uma plataforma digital *online* que exibirá a aplicação dos métodos estudados para os maiores mercados mundiais. A ideia agora é utilizar os dados intradiários. Com esse objetivo, será desenvolvida uma ferramenta de coleta de dados *online* via *web scraping*, cuja finalidade será capturar dados intradiários para posterior aplicação dos métodos propostos nesta tese e, assim, mensurar o comportamento dos mercados no que tange à eficiência, interdependência e contágio.

Ademais, pretende-se incluir a entropia informação de Shannon para medir *online* a complexidade dos mercados.

Outros Trabalhos

A.1 Programas de computador registrados



IPI INSTITUTO
NACIONAL
DE PROPRIEDADE
INDUSTRIAL
Assinado
Digitalmente

REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DA ECONOMIA
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL
DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS INTEGRADOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512019000219-9**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 06/01/2019, em conformidade com o §2º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: Matriz_DFA_Sliding Windows (Calcula o método Detrended Fluctuation Analysis com abordagem de janela deslizante numa matriz de séries temporais)

Data de publicação: 06/01/2019

Data de criação: 03/11/2016

Titular(es): EVERALDO FREITAS GUEDES

Autor(es): GILNEY FIGUEIRA ZEBENDE; EVERALDO FREITAS GUEDES

Linguagem: R

Campo de aplicação: MT-06

Tipo de programa: SM-01

Algoritmo hash: SHA-512

Resumo digital hash:

b1c727a497a7c0525d000b4bf5b4e30e28faedb95fee8dffffe96a12e4546902f19af30910a71a12188394f9f0f6ba7dfd8a17f45b7c239929e4ec0590eb054f

Expedido em: 19/02/2019

Aprovado por:

Alexandre Gomes Ciancio

Diretor Substituto de Patentes, Programas de Computador e Topografias de Circuitos Integrados



IPI INSTITUTO
NACIONAL
DE PROPRIEDADE
INDUSTRIAL
Assinado
Digitalmente

REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DA ECONOMIA
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL
DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS INTEGRADOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512019000174-5**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 01/02/2019, em conformidade com o §2º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: PDCCA dinâmico

Data de publicação: 01/02/2019

Data de criação: 06/01/2019

Titular(es): EVERALDO FREITAS GUEDES

Autor(es): GILNEY FIGUEIRA ZEBENDE; EVERALDO FREITAS GUEDES

Linguagem: R

Campo de aplicação: MT-06

Tipo de programa: SM-01

Algoritmo hash: SHA-512

Resumo digital hash:

58a71eaf5f03f27a716dbff56dbe3182175d830505daac2ed179fadfbd6856da4c181b592a6addacf06bc4ac244ea1b71965
221fc5935ed5c02f9768562cd6b9

Expedido em: 05/02/2019

Aprovado por:

Liane Elizabeth Caldeira Lage

Diretora de Patentes, Programas de Computador e Topografias de Circuitos Integrados

Referências Bibliográficas

- AIUBE, F. A. L. *Modelos Quantitativos em Finanças com enfoque em commodities*. Porto Alegre: Bookman, 2013.
- AKERLOF, G. A.; ROMER, P. M. *Looting: The Economic Underworld of Bankruptcy for Profit*. [S.l.], 1994. (Reprint Series, 1869).
- AKINLO, O. O.; LAWAL, Q. A. Impact of exchange rate on industrial production in nigeria 1986 - 2010. *International Business and Management*, v. 10, n. 1, p. 104 – 110, 2015.
- ALBERT, K. Contagion as a wealth effect. *Journal of Finance*, v. 56, n. 4, p. 1401–1440, 2001.
- ALEXAKIS, C.; PAPPAS, V. Sectoral dynamics of financial contagion in Europe - the cases of the recent crises episodes. *Economic Modelling*, 2018.
- ALLEN, F.; BABUS, A.; CARLETTI, E. Financial crises: Theory and evidence. *Annual Review of Financial Economics*, v. 1, n. 1, p. 97–116, 2009.
- ALMEIDA, D. F. e; SOARES, F.; CARVALHO., J. L. A. A sliding window approach to detrended fluctuation analysis of heart rate variability. In: *35 th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. [S.l.: s.n.], 2013.
- ALOUI, C.; HAMDY, M.; MENSY, W.; NGUYEN, D. K. Further evidence on the time-varying efficiency of crude oil markets. *Energy Stud Rev*, v. 19, p. 38–51, 2012.
- ALVAREZ-RAMIREZ, J.; ALVAREZ, J.; RODRIGUEZ, E. Short-term predictability of crude oil markets: A detrended fluctuation analysis approach. *Energy Economics*, v. 30, n. 5, p. 2645 – 2656, 2008.
- ALVAREZ-RAMIREZ, J.; ALVAREZ, J.; RODRIGUEZ, E.; FERNANDEZ-ANAYA, G. Time-varying Hurst exponent for US stock markets. *Physica A*, v. 387, p. 6159 – 6169, 2008.
- ANASTASOPOULOS, A. Testing for financial contagion: New evidence from the Greek crisis and Yuan devaluation. *Research in International Business and Finance*, v. 45, p. 499 – 511, 2018.
- ANTCZAK, R. Theoretical aspects of currency crises. *Studies & Analyses CASE*, n. 211, p. 1 – 36, 2000.

- ARSHAD, S.; RIZVI, S. A. R.; GHANI, G. M.; DUASA, J. Investigating stock market efficiency: A look at {OIC} member countries. *Research in International Business and Finance*, v. 36, p. 402 – 413, 2016.
- BAE, K.-H.; KAROLYI, G. A.; STULZ, R. M. *A New Approach to Measuring Financial Contagion*. [S.l.], set. 2000.
- BALOCCHI, R.; VARANINI, M.; MACERRATA, A. Quantifying different degrees of coupling in detrended cross-correlation analysis. *Europhysics Letters*, v. 101, p. 20011, 2013.
- BASHIR, U.; YU, Y.; HUSSAIN, M.; ZEBENDE, G. F. Do foreign exchange and equity markets co-move in Latin American region? Detrended cross-correlation approach. *Physica A*, v. 462, p. 889 – 897, 2016.
- BASHIR, U. et al. Differential market reactions to pre and post brexit referendum. *Physica A*, 2018.
- BELTRATTI, A.; BORTOLOTTI, B.; CACCAVAIO, M. Stock market efficiency in china: Evidence from the split-share reform. *The Quarterly Review of Economics and Finance*, v. 60, p. 125 – 137, 2016.
- BERGMANN, D. R.; SAVOIA, J. R.; SAITO, A. T.; CONTANI, E. Contagion effects of the US subprime crisis on Latin American and European Union stock markets. In: *BALAS - The Business Association of Latin American Studies Conference*. Barcelona, Espanha: [s.n.], 2010.
- BISGAARD, S.; KULAHCI, M. *Time Series Analysis and Forecasting by Example*. New Jersey: John Wiley & Sons, 2011.
- BLANCHARD, O. J.; WATSON, M. W. *Bubbles, Rational Expectations and Financial Markets*. [S.l.], 1982. (Working Paper Series, 945).
- BLANTON, R. G.; BLANTON, S. L.; PEKSEN, D. Financial crises and labor: Does tight money loosen labor rights? *World Development*, v. 76, p. 1 – 12, 2015.
- BLYTHE, D. A. J.; NIKULIN, V. V.; MULLER, K.-R. Robust statistical detection of power-law cross-correlation. *Nature*, n. 27089, p. 1–10, 2016.
- BOX, G.; COX, D. R. An anaysis of transformations. *Journal of the Royal Statistical Society*, v. 26, n. 2, p. 211–252, 1964.
- BRESSER-PEREIRA, L. C. A crise financeira global e depois: um novo capitalismo? *Novos estudos CEBRAP*, p. 51 – 72, 03 2010.
- BUSSE, J. A.; GREEN, T. C. Market efficiency in real time. *Journal of Financial Economics*, v. 65, p. 417–437, 2002.

- CAJUEIRO, D. O.; GOGAS, P.; TABAK, B. M. Does financial market liberalization increase the degree of market efficiency? the case of the Athens stock exchange. *International Review of Financial Analysis*, v. 18, n. 1 – 2, p. 50 – 57, 2009.
- CARBONE, A.; CASTELLI, G.; STANLEY, H. Time-dependent hurst exponent in financial time series. *Physica A*, v. 344, p. 267 – 271, 2004.
- CHAINED, M. *Contágio como mecanismo de transmissão da crise financeira de 2008*. 97 f. — Dissertação (Mestrado) - Programa de Pós-Graduação em Economia, Faculdade de Ciências Econômicas, Universidade Federal do Rio Grande do Sul, Rio Grande do Sul, 2013.
- CHARFEDDINE, L.; KHEDIRI, K. B. Time varying market efficiency of the GCC stock markets. *Physica A*, v. 444, p. 487–504, 2016.
- CHOE, K.-i.; CHOI, P.; NAM, K.; VAHID, F. Testing financial contagion on heteroskedastic asset returns in time-varying conditional correlation. *Pacific-Basin Finance Journal*, v. 20, n. 2, p. 271–291, 2012.
- COMISSAO-EUROPEIA. *O que é a zona euro?* 2018. Disponível em: <https://ec.europa.eu/info/business-economy-euro/euro-area/what-euro-area_pt>.
- CONSTANCIO, V. Contagion and the European debt crisis. *Financial Stability Review*, n. 16, p. 109–121, 2012.
- CORSETTI, G.; PERICOLI, M.; SBRACIA, M. Some contagion, some interdependence: More pitfalls in tests of financial contagion. *Journal of International Money and Finance*, v. 24, n. 8, p. 1177–1199, 2005.
- CRAWLING-PEG. 2018. <https://www.investopedia.com/terms/c/crawlingpeg.asp>. Acesso em: 21 out. 2018.
- CURVO, R. M. C. *Comparação entre as Grandes Crises Sistêmicas do Sistema Capitalista (1873, 1929 e 2008)*. 235 f. Tese (Doutorado) — Programa de Pós-Graduação em Políticas Públicas, Estratégias e Desenvolvimento, Instituto de Economia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.
- DEGUTIS, A.; NOVICKYT, L. The efficient market hypothesis: A critical review of literature and methodology. *Ekonomika*, v. 93, n. 2, p. 7–23, 2014.
- DELTUVAITE, V. Transmission of shocks through stock markets channel: The case of the CEECs. *Procedia Economics and Finance*, v. 39, p. 292 – 297, 2016.
- DETZER, D.; HERR, H. Theories of financial crises - an overview. *Institute for International Political Economy Berlin*, v. 32, 2014.
- DINIZ, A. M. F. A. *Série Temporais de Memória Longa com Aplicações ao Controle Motor: Estudo de Tarefas de Tapping Repetido*. Tese (Doutorado) — Universidade Técnica de Lisboa. Faculdade de Motricidade Humana, 2008.

- DOWD, J.; GORTON, G. Stock market efficiency and economic efficiency: Is there a connection? *The Journal of Finance*, v. 52, n. 3, p. 4–6, 1997.
- DUNGEY, M.; MARTIN, V. L. Contagion across financial markets: An empirical assessment. *New York Stock Exchange Conference Paper*, p. 16 – 17, 2001.
- EDWARDS, A. W. F. Galton, karl pearson and modern statistical theory. In: _____. *Sir Francis Galton, FRS: The Legacy of His Ideas: Proceedings of the twenty-eighth annual symposium of the Galton Institute, London, 1991*. London: Palgrave Macmillan UK, 1993. p. 91–107.
- EICHENGREEN, B.; ROSE, A.; WYPLOSZ, C. Contagious currency crises: First tests. *The Scandinavian Journal of Economics*, v. 98, n. 4, p. 463–484, 1996.
- FAMA, E. Efficient capital markets: A review of theory and empirical work. *Journal of Finance*, v. 25, n. 2, p. 383–417, 1970.
- FAMA, E. F. Efficient capital markets: Ii. *The Journal of Finance*, v. 46, n. 5, p. 1575 – 1617, 1991.
- FEDER, J. *Fractals*. New York: Plenum Press, 1988.
- FERREIRA, P. Does the euro crisis change the cross-correlation pattern between bank shares and national indexes? *Physica A*, v. 463, p. 320–329, 2016.
- FERREIRA, P.; DIONISIO, A. Long range dependence in G7 stock market's return rates using mutual information and detrended cross-correlation analysis . *Studies in Economics and Econometrics*, v. 41, n. 1, p. 73–92, 2017.
- FERREIRA, P.; DIONISIO, A.; GUEDES, E. F.; ZEBENDE, G. F. A sliding windows approach to analyse the evolution of bank shares in the european union. *Physica A: Statistical Mechanics and its Applications*, v. 490, p. 1355 – 1367, 2018.
- FERREIRA, P.; DIONISIO, A.; ZEBENDE, G. F. Why does the Euro fail? the DCCA approach. *Physica A: Statistical Mechanics and its Applications*, v. 443, p. 543–554, 2016.
- FERREIRA, P.; KRISTOUFEK, L. What is new about covered interest parity condition in the European Union? Evidence from fractal cross-correlation regressions. *Physica A*, v. 486, p. 554 – 566, 2017.
- FERREIRA, P.; LOURES, L.; NUNES, J.; BRITO, P. Are renewable energy stocks a possibility to diversify portfolios considering an environmentally friendly approach? The view of DCCA correlation coefficient. *Physica A*, v. 512, p. 675 – 681, 2018.
- FERREIRA, P.; LOURES, L.; NUNES, J. R.; DIONISIO, A. The behaviour of share returns of football clubs: An econophysics approach. *Physica A*, v. 472, p. 136 – 144, 2017.

- FIFIELD, S. G.; JETTY, J. Further evidence on the efficiency of the chinese stock markets: A note. *Research in International Business and Finance*, v. 22, n. 3, p. 351 – 361, 2008. ISSN 0275-5319.
- FIGUEIREDO-FILHO, D. B.; SILVA-JUNIOR, J. A. da. Desvendando os mistérios do coeficiente de correlação de Pearson (r). *Revista Política Hoje*, v. 18, n. 1, 2009.
- FILHO, A. M.; SILVA, M. F. da; ZEBENDE, G. F. Autocorrelation and cross-correlation in time series of homicide and attempted homicide. *Physica A*, v. 400, p. 12–19, 2014.
- FLAVIN, T. J.; SHEENAN, L. The role of US subprime mortgage-backed assets in propagating the crisis: Contagion or interdependence? *The North American Journal of Economics and Finance*, v. 34, p. 167 – 186, 2015.
- FORBES, K. J.; RIGOBON, R. No contagion, only interdependence: Measuring stock market comovements. *The Journal of Finance*, v. 57, n. 5, p. 2223–2260, 2002.
- FORTUNE, P. Stock market efficiency: An autopsy? *New England Economic Review*, p. 17–40, 1991.
- FRIEDMAN, M.; SCHWARTZ, A. *A Monetary History of the United States, 1867 - 1960*. [S.l.]: Princeton University Press, 1963.
- FRY, R.; MARTON, V. L.; TANG, C. A new class of tests of contagion with applications. *Journal of Business & Economic Statistics*, v. 28, n. 3, p. 423–437, 2010.
- FULLER, W. A. *Intrduction to Statistical Time Series*. 2. ed. EUA: John Wiley & Sons, 1996.
- GALAM, S. Market efficiency, anticipation and the formation of bubbles-crashes. *arXiv preprint arXiv:1106.1577*, 2011.
- GALHARDO, C. E. C.; PENNA, T. J. P.; MENEZES, M. A.; SOARES, P. P. S. Detrended fluctuation analysis of a systolic blood pressure control loop. *New Journal of Physics*, v. 11, n. 103005, p. 1 – 14, 2009.
- GOLDSTEIN, I.; RAZIN, A. *Three Branches of Theories of Financial Crises*. [S.l.], 2013. (Working Paper Series, 18670).
- GRANGER, C. Long memory relationships and the aggregation od dynamic models. *Journal od Econometrics*, v. 14, n. 2, p. 227 – 238, 1980.
- GUANGXI, C.; YAN, H.; WEIJUN, C. Time-varying long memories of the chinese currency and stock markets based on the Hurst exponent. *Fluctuation and Noise Letters*, World Scientific, v. 13, n. 01, p. 1450007, 2014.
- GUEDES, E. et al. Statistical test for dcca cross-correlation coefficient. *Physica A*, v. 501, p. 134 – 140, 2018.

GUEDES, E. et al. Statistical test for dcca: Methods and data. *Data in Brief*, v. 18, p. 795 – 798, 2018.

GUEDES, E.; DIONISIO, A.; FERREIRA, P.; ZEBENDE, G. DCCA cross-correlation in blue-chips companies: A view of the 2008 financial crisis in the Eurozone. *Physica A*, v. 479, p. 38 – 47, 2017.

GUEDES, E. F.; ZEBENDE, G. F.; LIMA, I. C. da C. Quantificação dos efeitos do câmbio na produção da indústria de transformação baiana: uma abordagem via coeficiente de correlação cruzada pdcca. *Conjuntura & Planejamento*, v. 1, n. 192, p. 75 – 89, 2017.

GUEDES, E. F.; ZEBENDE, G. F.; MACHADO, A. Análise temporal dos indicadores da indústria de transformação da bahia: Uma abordagem com métodos da mecânica estatística. *Conjuntura & Planejamento*, v. 186, p. 34–43, 2015.

GUJARATI, D. *Econometria Básica*. 3. ed. São Paulo: Makron Books, 2000.

HAILE, F.; POZO, S. Currency crisis contagion and the identification of transmission channels. *International Review of Economics & Finance*, v. 17, n. 4, p. 572 – 588, 2008.

HAJIAN, S.; MOVAHED, M. S. Multifractal detrended cross-correlation analysis of sunspot numbers and river flow fluctuations. *Physica A*, v. 389, n. 21, p. 4942 – 4957, 2010.

HORTA, P.; MENDES, C.; VIEIRA, I. Contagion Effects of the US Subprime Crisis on Developed Countries. *CEFAGE-UE Working Paper*, v. 8, 2008.

HUI, E. C. man; CHAN, K. K. K. The global financial crisis: Is there any contagion between real estate and equity markets? *Physica A*, v. 405, p. 216 – 225, 2014.

HURST, H. E. Long-term storage capacity of reservoirs. *Transactions of American Society of Civil Engineers*, v. 116, p. 770–799, 1951.

HUSSAIN, M.; ZEBENDE, G. F.; BASHIR, U.; DONGHONG, D. Oil price and exchange rate co-movements in Asian countries: Detrended cross-correlation approach. *Physica A*, v. 465, n. 1, p. 338 – 346, 2017.

ISHIHARA, Y. *Quantitative Analysis of Crisis : Crisis Identification and Causality*. [S.l.], 2005.

JARQUE, C. M.; BERA, A. K. Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics Letters*, v. 255-259, n. 6, 1980.

JOKIPII, T.; LUCEY, B. Contagion and interdependence: Measuring CEE banking sector co-movements. *Economic Systems*, v. 31, n. 1, p. 71–96, March 2007.

- KALBASKA, A.; GATKOWSKI, M. Eurozone sovereign contagion: Evidence from the CDS market (2005 - 2010). *Journal of Economic Behavior & Organization*, v. 83, p. 657 – 673, 2012.
- KAMINSKY, G. L.; REINHART, C.; VEGH, C. A. The Unholy Trinity of Financial Contagion. *The Journal of Economic Perspectives*, v. 17, n. 4, p. 51 – 74, 2003.
- KHALID, A. M.; RAJAGURU, G. *Financial Market Contagion or Spillovers Evidence from Asian Crisis using Multivariate GARCH Approach*. 2006.
- KHAN, S.; PARK, K. W. K. Contagion in the stock markets: The Asian financial crisis revisited. *Journal of Asian Economics*, v. 20, p. 561 – 569, 2009.
- KIESEL, F.; KOLARIC, S.; SCHIERECK, D. Market integration and efficiency of {CDS} and equity markets. *The Quarterly Review of Economics and Finance*, v. 61, p. 209 – 229, 2016.
- KINDLEBERGER, C. P.; ALIBER, R. Z. *Manias, Panics and Crashes: A History of Financial Crises*. 5. ed. [S.l.]: John Wiley & Sons, 2005.
- KINDLEBERGER, C. P.; LAFFARGUE, J.-P. *Financial Crises: Theory, history, and policy*. [S.l.]: Cambridge University Press Cambridge, 1982.
- KRISTOUFEK, L. Measuring cross-correlation between non-stationary series with DCCA coefficient. *Physica A*, v. 402, p. 291–298, 2014.
- LAEVEN, L.; VALENCIA, F. *Systemic Banking Crises: A New Database*. [S.l.], 2008. Disponível em: <<https://www.imf.org/external/pubs/ft/wp/2008/wp08224.pdf>>.
- LAFFONT, J.-J.; MASKIN, E. S. The efficient market hypothesis and insider trading on the stock market. *The Journal of Political Economy*, v. 98, n. 1, p. 70–93, 1990.
- LI, F.; ZHU, H. Testing for financial contagion based on a nonparametric measure of the cross-market correlation. *Review of Financial Economics*, v. 23, n. 3, p. 141 – 147, 2014.
- LIGGES, U.; KREY, S.; MERSMANN, O.; SCHNACKENBERG, S. *tuneR: Analysis of music*. [S.l.], 2014. Disponível em: <<http://r-forge.r-project.org/projects/tuner/>>.
- LIM, K.-P.; BROOKS, R. The evolution of stock market efficiency over time: a survey of the empirical literature. *Journal of Economic Surveys*, v. 25, n. 1, p. 69–108, 2011.
- LIM, K.-P.; BROOKS, R. D.; KIM, J. H. Financial crisis and stock market efficiency: Empirical evidence from Asian countries. *International Review of Financial Analysis*, v. 17, n. 3, p. 571 – 591, 2008.
- LIN, A.; SHANG, P.; ZHAO, X. The cross-correlations of stock markets based on dcca and time-delay dcca. *Nonlinear Dynamics*, v. 67, p. 425 – 435, 2011.

- LIN, M.; WANG, G.-J.; XIE, C.; STANLEY, H. E. Cross-correlations and influence in world gold markets. *Physica A*, p. 504 – 512, 2017.
- LUCHTENBERG, K. F.; VU, Q. V. The 2008 financial crisis: Stock market contagion and its determinants. *Research in International Business and Finance*, v. 33, p. 178 – 203, 2015.
- MA, P.; LI, D.; LI, S. Efficiency and cross-correlation in equity market during global financial crisis: Evidence from China. *Physica A*, v. 444, p. 163 – 176, 2016.
- MAGALHAES, M. N.; LIMA, A. C. P. de. *Noções de Probabilidade e Estatística*. 6. ed. [S.l.]: Edusp, 2005.
- MALKIEL, B. G. The efficient market hypothesis and its critics. *Journal of Economic Perspectives*, v. 17, n. 1, p. 59–82, 2003.
- MANDELBROT, B. B. *Fractals and Scaling in Finance: discontinuity, concentration, risk*. New York - EUA: Springer, 1997.
- MANTEGNA, R.; STANLEY, H. E. *An Introduction to Econophysics: Correlations and Complexity in Finance*. [S.l.]: Cambridge University Press, 2007.
- MARAIS, E.; BATES, S. An empirical study to identify shift contagion during the Asian crisis. *Journal of International Financial Markets, Institutions and Money*, v. 16, n. 5, p. 468 – 479, 2006.
- MARINHO, E.; SOUSA, A.; ANDRADE, R. Using detrended cross-correlation analysis in geophysical data. *Physica A*, v. 392, p. 2195–2201, 2013.
- MASSON, P. R. Contagion: Monsoonal effects, spillovers, and jumps between multiple equilibria. *IMF Working Paper*, v. 98/142, p. 1 – 32, 1998.
- MENSI, W.; BELJID, M.; MANAGI, S. Structural breaks and the time-varying levels of weak-form efficiency in crude oil markets: Evidence from the hurst exponent and shannon entropy methods. *International Economics*, v. 140, p. 89 – 106, 2014.
- MILONE, G. *Estatística Geral e Aplicada*. São Paulo: Thomson Learning, 2006.
- MINSKY, H. P. Financial instability revisited: The economics of disaster. 1970. Disponível em: <http://digitalcommons.bard.edu/hm_archive/80>.
- MISSIO, S.; WATZKA, S. *Financial Contagion and the European Debt Crisis*. [S.l.], 2011.
- MOLLAH, S.; QUORESHI, A. S.; ZAFIROV, G. Equity market contagion during global financial and Eurozone crises: Evidence from a dynamic correlation analysis. *Journal of International Financial Markets, Institutions and Money*, v. 41, p. 151 – 167, 2016.

MORET, M. Self-affinity and nonextensivity of sunspots. *Physics Letters A*, v. 378, n. 5, p. 494 – 496, 2014.

MORETTIN, P. A.; TOLOI, C. M. C. *Análise de Séries Temporais*. 2. ed. São Paulo: Edgard Blucher/ABE-Projeto Fisher, 2006.

OLBRYNS, J.; MAJEWSKA, E. Direct identification of crisis periods on the CEE stock markets: The influence of the 2007 US subprime crisis. *Procedia Economics and Finance*, v. 14, p. 461 – 470, 2014. International Conference on Applied Economics, ICOAE 2014.

ORLOV, A. G. A cospectral analysis of exchange rate comovements during Asian financial crisis. *Journal of International Financial Markets, Institutions & Money*, v. 19, p. 742 – 758, 2009.

PALMA, W. *Time Series: Theory and Methods*. New Jersey - EUA: Wiley & Sons, 2007. (Wiley Series in probability and Statistics).

PENG, C.-K. et al. Mosaic organization of dna nucleotides. *Phys. Rev. E*, v. 49, p. 1685–1689, 1994.

PERAZZO, C. A.; FERNANDEZ, E. a.; WILLSHAW, Y. Determinación de correlaciones a largo plazo utilizando dfa. In: _____. Córdoba - Argentina: Universidad Católica de Córdoba, 2004. p. 297–312.

PEREIRA, B. de B.; ZANUSSO, M. B.; SALES, P. R. de H. *Análise Espectral de Séries Temporais - Uma Introdução para Economia, Engenharia e Estatística*. Rio de Janeiro: Eletrobrás S.A., 1986.

PERICOLI, M.; SBRACIA, M. A primer on financial contagion. *Journal of Economic Surveys*, v. 17, n. 4, p. 571 – 608, 2003.

PETERS, E. E. *Fractal market analysis: applying chaos theory to investment and economics*. [S.l.]: John Wiley, 1994.

PIAO, L.; FU, Z. Quantifying distinct associations on different temporal scales: comparison of DCCA and Pearson methods. *Scientific Reports*, v. 6, n. 36759, p. 1 – 11, 2016.

PODOBNIK, B.; HORVATIC, D.; PETERSEN, A. M.; STANLEY, H. E. Cross-correlations between volume change and price change. *Proceedings of the National Academy of Sciences*, v. 106, n. 52, p. 22079–22084, 2009.

PODOBNIK, B.; JIANG, Z.-Q.; ZHOU, W.-X.; STANLEY, H. E. Statistical tests for power-law cross-correlated processes. *Phys. Rev. E*, v. 84, p. 066118, 2011.

PODOBNIK, B.; STANLEY, H. E. Detrended cross-correlation analysis: A new method for analyzing two nonstationary time series. *Phys. Rev. Lett*, v. 100, p. 1–4, 2008.

- PORTES, R. *An Analysis of Financial Crisis: Lessons for the International Financial System. In The Asian Financial Crisis: Origins, Implications, and Solutions*. [S.l.]: Kluwer Academic Publishers, 1999.
- PREIS, T. Econophysics – complex correlations and trend switchings in financial time series. *The European Physical Journal-Special Topics*, Springer, v. 194, n. 1, p. 5–86, 2011.
- PREIS, T.; KENETT, D. Y.; STANLEY, H. E.; HELBING, D.; BEN-JACOB, E. Quantifying the behavior of stock correlations under market stress. *Scientific Reports*, p. 1 – 5, 2012.
- PRITSKER, M. The channels for financial contagion. In: S., F. K. C. (Ed.). *International Financial Contagion*. [S.l.]: Springer, 2001.
- QIAN, R.; REINHART, C. M.; ROGOFF, K. S. *On Graduation from Default, Inflation and Banking Crisis: Elusive or Illusion?* [S.l.], 2010. (Working Paper Series, 16168).
- RACICKAS, E.; VASILIAUSKAITE, A. Classification of financial crises and their occurrence frequency in global financial markets. *Socialiniai Tyrimai / Social Research*, v. 29, n. 4, p. 32 – 34, 2012.
- REBOREDO, J. C.; RIVERA-CASTRO, M. A.; ZEBENDE, G. F. Oil and US dollar exchange rate dependence: A detrended cross-correlation approach. *Energy Economics*, v. 42, n. c, p. 132–139, 2013.
- REINHART, C. M.; ROGOFF, K. S. *This Time is Different: A Panoramic View of Eight Centuries of Financial Crises*. [S.l.], March 2008. (Working Paper Series, 13882).
- REINHART, C. M.; ROGOFF, K. S. *Oito Séculos de Delírios Financeiros: desta vez é diferente*. 2. ed. Rio de Janeiro: Elsevier, 2010.
- RIZVI, S. A. R.; ARSHAD, S. How does crisis affect efficiency? An empirical study of East Asian markets. *Borsa Istanbul Review*, v. 16, n. 1, p. 1 – 8, 2016.
- ROSSI, P. L. *Taxa de câmbio no Brasil: dinâmicas da especulação e da arbitragem*. 207 f. Tese (Doutorado) — Programa de Pós-graduação em Ciências Econômicas, Universidade Estadual de Campinas, 2012.
- SAHITI, A.; MEROVCI, S.; KONXHELI, D.; SAHITI, A.; SHALA, A. Types of financial crisis. *Asian Journal of Business and Management Sciences*, v. 2, n. 12, p. 31 – 39, 2013.
- SCHINASI, G. J. *Defining Financial Stability*. [S.l.], 2004.
- SENSOY, A. Time-varying long range dependence in market returns of fea members. *Chaos, Solitons & Fractals*, v. 53, p. 39–45, 2013.
- SENSOY, A.; HACIHASANOGLU, E. Time-varying long range dependence in energy futures markets. *Energy Economics*, v. 46, p. 318–327, 2014.

- SENSOY, A.; TABAK, B. M. How much random does European Union walk? a time-varying long memory analysis. *Working Paper Series*, n. 342, p. 1–31, 2013.
- SENSOY, A.; TABAK, B. M. Time-varying long term memory in the European Union stock markets. *Physica A*, Elsevier, v. 436, p. 147–158, 2015.
- SENSOY, A.; TABAK, B. M. Dynamic efficiency of stock markets and exchange rates. *International Review of Financial Analysis*, v. 47, p. 353 – 371, 2016.
- SEWELL, M. The efficient market hypothesis: Empirical evidence. *International Journal of Statistics and Probability*, Canadian Center of Science and Education, v. 1, n. 2, p. 164, 2012.
- SHILLER, R. J. From efficient markets theory to behavioral finance. *Journal of Economic Perspectives*, v. 17, n. 1, p. 83–104, 2003.
- SHUMWAY, R. H.; STOFFER, D. S. *Times Series Analysis and Its Applications With R*. 2. ed. New York - EUA: Springer, 2011.
- SILVA-FILHO, A. M. *Autocorrelação e Correlação Cruzada: Teorias e Aplicações*. Tese (Doutorado) — Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial. Faculdade Senai Cimatec, 2014.
- SILVA-FILHO, A. M.; SILVA, M. da; ZEBENDE, G. Autocorrelation and cross-correlation in time series of homicide and attempted homicide. *Physica A*, v. 400, p. 12 – 19, 2014.
- SILVA, M. F. da; CASTRO, A. P. N. de; SILVA-FILHO, A. M. da. Quantificando a influência do mercado de câmbio nos preços do milho e da soja no município de Barreiras. *Revista Conjuntura & Planejamento*, n. 182, p. 42–49, 2014.
- SILVA, M. F. da et al. Quantifying the contagion effect of the 2008 financial crisis between the G7 countries (by GDP nominal). *Physica A*, v. 453, p. 1 – 8, 2016.
- SILVA, M. F. P. da et al. Quantifying cross-correlation between ibovespa and brazilian blue-chips: The DCCA approach. *Physica A*, v. 424, n. C, p. 124–129, 2015.
- SOJLI, E. Contagion in emerging markets: the Russian crisis. *Applied Financial Economics*, v. 17, n. 3, p. 197–213, 2007.
- SORNETTE, D. *Why Stock Markets Crash Critical Events in Complex Financial Systems*. [S.l.]: Princeton University Press, 2003.
- SPEARMAN, C. The proof and measurement of association between two things. *The American Journal of Psychology*, v. 15, n. 1, p. 72–101, 1904.
- STANLEY, H. et al. Statistical physics and physiology: Monofractal and multifractal approaches. *Physica A*, n. 270, p. 309–324, 1999.

- STANTON, J. M. Galton, Pearson, and the Peas: A Brief History of Linear Regression for Statistics Instructors. *Journal of Statistics Education*, Taylor & Francis, v. 9, n. 3, 2001.
- STASZKIEWICZ, P.; STASZKIEWICZ, L. Chapter 4 - hypothesis of informational efficiency of financial markets. In: *Finance*. San Diego: Academic Press, 2015. p. 61 – 71.
- STIGLER, S. M. Francis Galton's Account of the Invention of Correlation. *Statistical Science*, v. 4, n. 1, p. 73–79, 1989.
- STOVE, B.; TJOSTHEIM, D.; HUFTHAMMER, K. O. Using local gaussian correlation in a nonlinear re-examination of financial contagion. *Journal of Empirical Finance*, v. 25, p. 62 – 82, 2014.
- SUKPITAK, J.; HENGPUNYA, V. Efficiency of Thai stock markets: Detrended fluctuation analysis. *Physica A*, v. 458, p. 204 – 209, 2016.
- TABAK, B. M.; CAJUEIRO, D. O. Assessing inefficiency in euro bilateral exchange rates. *Physica A*, v. 367, p. 319–327, 2006.
- TABAK, B. M.; SOUZA, M. M. Testes de contágio entre sistemas bancários - a crise do subprime. *Trabalhos para Discussão*, n. 194, p. 1–36, 2009.
- TITAN, A. G. The efficient market hypothesis: Review of specialized literature and empirical research. *Procedia Economics and Finance*, v. 32, p. 442–449, 2015.
- TSAY, R. S. *Analysis of Financial Time Series*. 3. ed. New Jersey - EUA: John Wiley & Sons, 2010.
- URSULEAN, R.; LAZAR, A. Detrended cross-correlation analysis of biometric signals used in a new authentication method. *Elektronika ir Elektrotechnika*, p. 1392–1215, 01 2009.
- VASSOLER, R. T.; ZEBENDE, G. F. Dcca cross-correlation coefficient apply in time series of air temperature and air relative humidity. *Physica A*, v. 391, n. 7, p. 2438–2443, 2012.
- VEENSTRA, J. Q. *Persistence and Anti-persistence: Theory and Software*. Tese (Doutorado) — Western University, 2012.
- VERSIGNASSI, A. *CRASH: Uma breve história da economia - da Grécia antiga ao século XXI*. [S.l.]: Leya, 2015.
- VIDAL, T. L. *Crises financeiras: efeito contágio ou interdependência entre os países? Evidências utilizando uma abordagem multivariada*. 175 f. — Dissertação (Mestrado) - Programa de Pós-Graduação em Administração. Universidade de São Paulo, São Paulo, 2011.

- VO, X. V. International financial integration in asian bond markets. *Research in International Business and Finance*, v. 23, n. 1, p. 90 – 106, 2009.
- WANG, G.-J.; XIE, C. Cross-correlations between WTI crude oil market and US stock market: A perspective from econophysics. *Acta Physica Polonica-Series B Elementary Particle Physics*, v. 43, n. 10, p. 2021–2036, 2012.
- WANG, G.-J.; XIE, C.; CHEN, S.; YANG, J.-J.; MING-YANYANG. Random matrix theory analysis of cross-correlations in the US stock market: Evidence from Pearson correlation coefficient and detrended cross-correlation coefficient. *Physica A*, v. 392, n. 17, p. 3715–3730, 2013.
- WANG, G.-J.; XIE, C.; CHEN, S.; HAN, F. Cross-correlations between energy and emissions markets: New evidence from fractal and multifractal analysis. *Mathematical Problems in Engineering*, v. 2014, n. 197069, p. 1–13, 2014.
- WANG, G.-J.; XIE, C.; CHEN, Y.-J.; CHEN, S. Statistical properties of the foreign exchange network at different time scales: Evidence from detrended cross-correlation coefficient and minimum spanning tree. *Entropy*, v. 15, n. 5, p. 1643–1662, 2013.
- WANG, G.-J.; XIE, C.; HE, L.-Y.; CHEN, S. Detrended minimum-variance hedge ratio: A new method for hedge ratio at different time scales. *Physica A*, v. 405, p. 70–79, 2014.
- WANG, G.-J.; XIE, C.; LIN, M.; STANLEY, H. E. Stock market contagion during the global financial crisis: A multiscale approach. *Finance Research Letters*, v. 22, p. 163 – 168, 2017.
- WEI, W. W. S. *Time Series Analysis: univariate and multivariate methods*. EUA: Pearson, 2006.
- XU, N.; SHANG, P.; KAMAE, S. Modeling traffic flow correlation using DFA and DCCA. *Nonlinear Dynamics*, v. 61, p. 207 – 216, 2010.
- YUAN, N.; FU, Z. Different spatial cross-correlation patterns of temperature records over China: A DCCA study on different time scales. *Physica A*, v. 400, p. 71–79, 2014.
- YUAN, N. et al. Detrended partial-cross-correlation analysis: A new method for analyzing correlations in complex system. *Scientific Reports*, v. 5, n. 8143, 2015.
- ZANALDA, G. History of financial crises. In: *International Encyclopedia of the Social & Behavioral Sciences (Second Edition)*. Second edition. Oxford: Elsevier, 2015. p. 183 – 190.
- ZEBENDE, G.; BRITO, A.; SILVA-FILHO, A.; CASTRO, A. pDCCA applied between air temperature and relative humidity: An hour/hour view. *Physica A*, v. 1, n. 494, p. 17 – 26, 2018.

- ZEBENDE, G.; SILVA-FILHO, A. da. Detrended multiple cross-correlation coefficient. *Physica A*, v. 510, p. 91 – 97, 2018.
- ZEBENDE, G. F. DCCA cross-correlation coefficient: Quantifying level of cross-correlation. *Physica A*, v. 390, n. 4, p. 614–618, 2011.
- ZEBENDE, G. F.; FERNANDEZ, B. F.; PEREIRA, M. G. Analysis of the variability in the sdB star KIC 10670103: DFA approach. *Monthly Notices of the Royal Astronomical Society*, v. 464, p. 2638 – 2642, 2017.
- ZEBENDE, G. F.; MACHADO-FILHO, A. Cross-correlation between time series of vehicles and passengers. *Physica A*, v. 388, p. 4863–4866, 2009.
- ZEBENDE, G. F.; OLIVEIRA-FILHO, F. M.; LEYVA-CRUZ, J. Auto-correlation in the motor/imaginary human eeg signals: A vision about the fdFA fluctuations. *PLOS ONE*, v. 12, p. e0183121, 2017.
- ZHAO, X.; SHANG, P.; HUANG, J. Several fundamental properties of DCCA cross-correlation coefficient. *Fractals*, v. 25, p. 1750017, 03 2017.

*Modelo Computacional para Análise de Movimentos e Co-movimentos de Mercados
Financeiros*

Everaldo Freitas Guedes

Salvador, Abril de 2019.