

Turbulência e Acoplagem como Medidores de Risco

por

Gustavo Rodriguez Peçanha

Trabalho de fim de curso submetido ao
Instituto de Matemática Pura e Aplicada

Rio de Janeiro

Novembro/2012

Turbulência e Acoplagem como Medidores de Risco

por

Gustavo Rodriguez Peçanha

Métodos Matemáticos em Finanças

Orientadores:

Prof. Dr. Jorge Passamani Zubelli
Instituto de Matemática Pura e Aplicada

Prof. Dr. Alexandre Lowenkron
Fundação Getúlio Vargas

Rio de Janeiro

Novembro/2012

Assinatura:

Turbulência e Acoplagem como Medidores de Risco

Gustavo Rodriguez Peçanha

Trabalho de fim de curso submetido ao Mestrado Profissional em Finanças do Instituto de Matemática Pura e Aplicada, como parte dos requisitos necessários à obtenção do grau de Mestre.

Aprovada por:

Dr. Jorge Passamani Zubelli

Dr. Alexandre Lowenkron

Dra. Beatriz Vaz de Melo Mendes

Dr. Paulo Cezar Pinto Carvalho

Agradecimentos

Agradeço a Deus e a todos que me ajudaram nesta caminhada até aqui. Agradeço a todos que tiveram paciência e entenderam que para conseguir algumas coisas é preciso abrir mão de outras. Em especial agradeço a meu pai, minha mãe, minha namorada, Julia, meu irmão e aos que sempre estarão comigo, mesmo que não fisicamente. Agradeço ao Banco BBM por incentivar a realização deste trabalho, bem como ao IMPA que vem sendo grande responsável pelo desenvolvimento do estudo de finanças no Brasil.

Resumo

A modelagem de risco, em especial de crises, é um desafio ainda não superado no estudo de finanças. Neste trabalho foi feita uma abordagem em linha com o trabalho de Mark Kritzman, utilizando duas medidas: acoplagem e turbulência. A primeira é baseada em análise de componentes principais e a segunda na distância de Mahalanobis, que mostra quanto um grupo de retornos se afasta da média levando em conta as correlações entre os ativos. Mostrou-se que a métrica com acoplagem e turbulência apresenta resultados por vezes melhores, por vezes piores que a média móvel exponencialmente ponderada (Exponentially Weighted Moving Average, EWMA) e que em conjunto tem-se o melhor resultado no que tange a previsão de crises, segundo o critério adotado.

Abstract

Risk modelling, specially crisis, is still a challenge in financial studies. The present work is based on an approach similar to the one used by Mark Kritzman, using two measures: coupling and turbulence. The first one is based on principal components analysis and the second one on Mahalanobis distance. The latter shows how far from its mean a group of returns is, taking into consideration correlation among assets. It is shown that the coupling and turbulence metric results are sometimes better, sometimes worse than the Exponentially Weighted Moving Average (EWMA), but when used together a better result is achieved regarding crisis prediction, according to the chosen criteria.

Índice

1	Introdução	5
2	Revisão Bibliográfica	8
2.1	Turbulência Financeira	8
2.1.1	Distância de Mahalanobis	8
2.1.2	Aplicação da Métrica ao Mercado Financeiro	10
2.1.3	Outras Métricas para Turbulência	11
2.2	Razão de Absorção	11
3	Metodologia	13
3.1	Tratamento dos Dados	14
3.2	Acoplagem	18
3.3	Turbulência	20
3.4	Modelo de Volatilidade EWMA	21
4	Análise de Resultados	24
4.1	Acoplagem e Turbulência Isoladamente	24
4.1.1	Séries Temporais e Eventos	24
4.1.2	Previsibilidade de Eventos de Cauda	27
4.2	Acoplagem e Turbulência em Conjunto com EWMA	33
4.2.1	Comportamento do EWMA nos Mapas de AT	33
4.2.2	Análise da AT e EWMA com Filtros Condicionais	39
5	Conclusões e Sugestões	44
A	Figuras	49

B Tabelas**97****C Códigos Fonte****100**

Nomenclatura

Letras Latinas

R^n	Conjunto das n-uplas ordenadas de reais
G	Grau de Acoplagem
T	Nível de Turbulência
x, y	Pontos do Espaço
x_i	Componente i do vetor x
d_e	Distância segundo a métrica de Euclides
s_i	Componente i do desvio-padrão de um grupo de pontos
d_n	Distância normalizada por desvio-padrão
d_k	Distância de Mahalanobis
RA	Razão de Absorção
u	Retorno

Letras Gregas

λ	Coefficiente de Alisamento Exponencial
σ	Desvio-Padrão
σ^2	Variância
Σ	Matriz de Covariância
∇^2	Laplaciano
ξ	Importância percentual da direção i em uma transformação linear
μ	Média dos retornos de um dado período
ρ	Excesso de retorno em relação à média
Δ	Distância de Mahalanobis

Siglas

EWMA	<i>Exponentially Weighted Moving Average</i>
CDS	<i>Credit Default Swap</i>
VIX	<i>Volatility S&P 500 Index</i>
VaR	<i>Value at Risk</i>
ARCH	<i>Autoregressive Conditional Heteroskedasticity</i>
GARCH	<i>Generalized Autoregressive Conditional Heteroskedasticity</i>
SWARCH	<i>Switching Autoregressive Conditional Heteroskedasticity</i>
PCA	<i>Principal Component Analysis</i>
TED	<i>T-Bill - EuroDolar</i>

Capítulo 1

Introdução

A crise do mercado financeiro em 2008 foi um marco na economia mundial. É difícil precisar uma data de ocorrência mas a quebra do banco Lehman Brothers é para muitos o marco temporal da mesma. A própria história do homem é evidência contundente de que a economia de qualquer país, e hoje mais do que nunca do mundo como um todo, é cíclica, i.e., há períodos de grande pujança e outros de crises. A palavra por si só inspira temor; em meio a crises é relativamente fácil perceber que ela existe mas é muito difícil perceber que ela está por começar, apesar dos muitos ensinamentos que história já deu ao homem. Há sempre algo novo, não visto ou ao menos que passa despercebido e acaba prejudicando as economias. Até hoje sempre conseguiu-se contornar os efeitos negativos que acompanham este movimento, mas evitar os mesmos seria certamente melhor.

Nos estudos de finanças quantitativas, grande atenção é dada à modelagem de eventos que sejam potencialmente prejudiciais aos investimentos. Não tem sido diferente com o estudo de crises financeiras. Entretanto, tem-se percebido que é muito difícil matematizar a palavra crise (aqui tratada no contexto econômico-financeiro). Cada momento na história do homem é um novo momento; o que é considerado bom para uma certa época não necessariamente será em outra. Assim sendo, é fácil fixar conceitos que definam crise, mas talvez os conceitos que definiriam uma crise em 1929 não sejam os mesmos que definiriam uma crise nos dias atuais. Naturalmente, há algumas características gerais que são bons indicadores de que uma crise já está instaurada. Diversos índices macroeconômicos costumam ser usados com esse fim pois, em se tratando de crise, estamos falando de uma grande parcela da

população ou de agentes econômicos sendo afetados. Desemprego alto, queda no consumo e na produção, entre outros, são alguns dos fatores verificados nas baixas dos ciclos econômicos.

Sendo considerado o pior momento da economia desde 1929, a catástrofe de 2008, assim como a anterior, chegou sem avisar. Há hoje alguns que alegam que já haviam previsto o problema, mas pouca credibilidade há de fato em alegações posteriores. Fato é que nenhuma destas pessoas ganhou enormes quantidades de dinheiro com a crise em si e se de fato confiassem em suas previsões, seria relativamente fácil ganhar muito. Neste colapso econômico mundial, grandes empresas, fundos e mesmo economias inteiras perderam quantidades gigantescas de dinheiro. Em última instância a população é quem acaba sofrendo os efeitos dessas perdas em forma de pior qualidade de vida, poder de compra reduzido, etc. A fim de evitar estes efeitos os governos incentivaram a ação de órgãos reguladores que cada vez mais estão implementando medidas restritivas às negociações financeiras com intuito de evitar grandes choques na economia mundial. Diante de um cenário de estabilidade econômica é mais fácil para os agentes econômicos fazer planejamentos e o nível de qualidade de vida da população tende a aumentar. Deste modo, é bastante clara a necessidade de conseguir antever a proximidade de crises, mesmo que seja impossível acertar completamente em tais previsões.

Em se falando de previsibilidade de movimentos financeiros críticos, o conceito de risco aparece naturalmente. É característico do homem aprender com a experiência e daí tentar antever eventos. É tendência natural um pensamento da maioria dos homens que as coisas se reverterem à média. Assim, datam de muito tempo os estudos estatísticos de desvio da média de acontecimentos [24] e a preocupação com a grandeza em questão quando estes ocorrem. Com o passar do tempo estes estudos foram se tornando mais importantes e a capacidade previsiva de eventos melhorou consideravelmente. O próprio comércio evoluiu em relação às antigas trocas, com aparecimento de moeda, criação de mercados organizados, produtos padronizados até os dias atuais em que o mercado financeiro é quase todo baseado em registros eletrônicos. Markowitz foi o primeiro a formalizar uma teoria que tinha preocupação clara com o risco envolvido para dado retorno. Em 1989 o banco J.P. Morgan inovou com a criação do VaR, uma medida matemática, dada a história dos retornos dos ativos, de quanto estava sendo posto em risco para uma carteira de apostas. É claro que antes disso já havia preocupações com a volatilidade de cada ativo individualmente; existiam também índices que se preocupavam com

a volatilidade do mercado como um todo como, por exemplo, o VIX.

Entretanto, as metodologias existentes não foram suficientemente boas para prever a chegada da crise de 2008. Passado o auge do evento muito já se tentou estudar a respeito, ao menos para explicar o porquê do ocorrido, de forma a evitar cometer outra vez os mesmos deslizes que levaram àquela situação. O objetivo deste trabalho foi estudar uma nova forma de mensurar o risco de catástrofes financeiras.

Para esse fim, fizemos um estudo bastante abrangente das métricas de turbulência e acoplagem. Estas já tinham sido usadas em separado [1],[13]. As principais diferenças deste trabalho em relação aos anteriores são: o uso em conjunto da acoplagem e da turbulência, a análise separada por mercados (CDS bancários, CDS soberanos, Moedas, *Commodities* e Índices de Bolsa) e a utilização comparada a outra métrica já consagrada.

Assim, analisamos o comportamento da métrica proposta de diferentes maneiras, concluindo que a mesma melhora as previsões da volatilidade EWMA, uma metodologia comumente empregada como modo de antever riscos.

Capítulo 2

Revisão Bibliográfica

Com intuito de antever crises financeiras ou possíveis quedas extremas de preços, diversos estudos já foram feitos. Há também diferentes abordagens para medir o que se chama de turbulência financeira. Outros estudos foram feitos no sentido de mensurar risco sistêmico; neste trabalho analisamos algum destes e procuramos aprofundar os estudos de Kritzman [1, 13].

2.1 Turbulência Financeira

Mark Kritzman em [1] propôs uma forma de mensurar a turbulência financeira, em especial para o mercado americano. A ideia sustentada em seu trabalho é a de que o indicador, conforme foi proposto, é capaz de antecipar grandes movimentos na série de retornos de um ativo. A espinha dorsal de seu trabalho [1] é o uso de uma métrica proposta por Mahalanobis [4]. Kritzman faz uma aplicação da mesma ao mercado financeiro analisando estatisticamente o comportamento do retorno de determinados ativos. A partir deste estudo ele mostra como a métrica mencionada acima pode ser usada para gerenciar o risco e melhorar a performance de um portfólio.

2.1.1 Distância de Mahalanobis

Mahalanobis foi um cientista indiano e grande estudioso da área de estatística aplicada. Uma de suas grandes contribuições foi a criação daquilo que veio a se chamar distância de Mahalanobis. O desenvolvimento desta métrica iniciou-se em 1922 em seu primeiro trabalho, classificando grupos raciais segundo a distribuição estatística da altura de indivíduos. Nos

trabalhos iniciais já havia a preocupação em adimensionalizar as medidas tomadas nas amostras segundo os desvios-padrões, de acordo com a análise em questão. A seguir, seus trabalhos passaram a estudar crânios humanos com o objetivo de classificá-los quanto a população-grupo étnico ao qual eles pertenciam. A medida proposta evoluiu conforme mais trabalhos eram feitos mas só em 1936 ela passou a considerar a correlação entre os valores medidos.

Assim, havia crânios pertencentes a grupos étnicos conhecidos, dos quais foram medidas algumas dimensões lineares -e.g., altura do crânio e altura da fossa nasal. Dado então um crânio desconhecido, efetuavam-se estas medidas. Pode-se imaginar que estas medidas determinam um ponto no espaço R^n onde n é o número de grandezas medidas. A seguir mede-se a distância desse novo ponto ao ponto que representa o valor esperado de cada população-grupo étnico. A medida é feita segundo a métrica de Mahalanobis e não a de Euclides.

Sabemos que a norma de Euclides para distância entre dois pontos de um espaço p -dimensional $x = (x_1, x_2, \dots, x_p)$ e $y = (y_1, y_2, \dots, y_p)$ é definida por

$$d_e(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_p - y_p)^2} = \sqrt{(x - y)'(x - y)} \quad (2.1)$$

Se tomarmos o conjunto de todos os pontos x que equidistam de y dado, temos uma esfera de centro em $y = (y_1, y_2, \dots, y_p)$ definida pela equação:

$$(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_p - y_p)^2 = c^2 \quad (2.2)$$

Nos trabalhos iniciais de Mahalanobis redimensionavam-se as distâncias de acordo com sua variabilidade:

$$u = \left(\frac{x_1}{s_1}, \frac{x_2}{s_2}, \dots, \frac{x_p}{s_p} \right)$$

e

$$v = \left(\frac{y_1}{s_1}, \frac{y_2}{s_2}, \dots, \frac{y_p}{s_p} \right)$$

onde s_i são os desvios-padrão de cada componente. Assim define-se uma nova distância

$$\begin{aligned} d_n(x, y) = d_e(u, v) &= \sqrt{\left(\frac{x_1 - y_1}{s_1}\right)^2 + \left(\frac{x_2 - y_2}{s_2}\right)^2 + \dots + \left(\frac{x_p - y_p}{s_p}\right)^2} = \\ &= \sqrt{(x - y)^t D^{-1} (x - y)} \end{aligned} \quad (2.3)$$

onde $D = \text{diag}(s_1^2, s_2^2, \dots, s_p^2)$.

Essa distância dividida pelo número de componentes, p , foi a medida introduzida no paper clássico de 1925 por Mahalanobis. Aqui, o conjunto dos pontos x que equidistam de um ponto y dado é um elipsóide:

$$\left(\frac{x_1 - y_1}{s_1}\right)^2 + \left(\frac{x_2 - y_2}{s_2}\right)^2 + \dots + \left(\frac{x_p - y_p}{s_p}\right)^2 = c^2 \quad (2.4)$$

Notamos que este elipsóide tende a ser mais alongado nas direções de maior variabilidade. Entretanto, apesar de considerar o efeito da dispersão de cada medida, $d_n(x, y)$ não leva em conta os efeitos cruzados que uma medida pode ter sobre outra. Somente em 1936 Mahalanobis conseguiu formular uma métrica incluindo os efeitos de correlação que, já em 1930 ele havia percebido ser o principal ponto fraco de sua medida anterior. A nova métrica é definida como:

$$\Delta^2 = \frac{1}{p}(x - \bar{x})\Sigma^{-1}(x - \bar{x})' \quad (2.5)$$

em que Σ^{-1} é a inversa da matriz de dispersão ou covariância. Note-se que a distância de Mahalanobis (que é uma métrica) pode ser vista como um caso particular da distância de Bregman ($\Delta^2 = \frac{1}{p}(x - \bar{x})\nabla^2\varphi(\tilde{x})(x - \bar{x})$, sendo $\varphi(\tilde{x})$ convexa - no caso geral não é uma métrica pois não respeita desigualdade triangular) que também é alvo de estudos para tratamento de grandes volumes de dados e análises de clusterização [19].

Vale observarmos que a distância definida por (2.5) é uma generalização natural da Euclidiana e já havia sido estudada extensivamente em Geometria Diferencial.

2.1.2 Aplicação da Métrica ao Mercado Financeiro

Kritzman adaptou esta ideia da métrica para o mercado financeiro. Ao invés de crânios em grupos, deseja-se classificar o estado atual do mercado financeiro em turbulento ou não turbulento. Para isso as diversas medidas utilizadas são os retornos de diferentes tipos de ativos. As medidas conhecidas são os retornos passados destes ativos. De posse destes, pode-se medir o quão distante está o estado atual da média dos anteriores. Um estado (conjunto de retornos de um dia, para um dado grupo de ativos) é classificado como turbulento se estiver

muito distante (na nova métrica) do estado médio anterior (sendo o período sobre o qual se define essa média um parâmetro a ser estabelecido). Kritzman apenas abandonou a divisão por p da Equação (2.5), possivelmente por manter constante o número de ativos em sua análise, e chama de distância (turbulência) o quadrado desta medida:

$$d_K = (x - \bar{x})\Sigma^{-1}(x - \bar{x})' \quad (2.6)$$

sendo Σ^{-1} a inversa da matriz de covariância dos retornos dos ativos em questão. Neste trabalho, visto que variamos o número de ativos, utilizamos o termo p , portanto

$$d_K = \frac{1}{p}(x - \bar{x})\Sigma^{-1}(x - \bar{x})' \quad (2.7)$$

2.1.3 Outras Métricas para Turbulência

Além de Kritzman, outros autores fizeram propostas para medir a turbulência financeira. Uma delas foi a análise econométrica tanto do TED *spread* (diferença entre as taxas da *Treasury* americana e a *libor*), quanto do *swap* de euro-dolar da *Forex* e do *VIX*. O trabalho foi realizado por González- Hermsillo e Hesse [16] com uso de metodologia tipo *SWARCH* (*ARCH* Markov-Switching model) e concluiu que o modelo já indicava, antes da crise do *Lehman*, período de alta volatilidade, apesar de ruidosa, o que poderia indicar aumento de risco sistêmico. Análise similar foi feita por Ang e Bekaert [15] conforme citação de Kritzman. Das e Uppal [17] propuseram um modelo de mistura com difusão por saltos. Em uma linha diferente, Los [18] fez uma complexa análise e modelou a turbulência através de equações de difusão, resolvendo as mesmas com diferenças finitas, métodos espectrais e elementos finitos. Em especial foi usado o método de Galerkin [21] e focando-se a análise no domínio das frequências.

2.2 Razão de Absorção

Kritzman, em seu trabalho sobre turbulência [1], também ressaltou o fato conhecido de que diversas vezes, em períodos de grande turbulência, ativos que historicamente mostram correlação alta perdem correlação e ativos de baixa correlação ficam altamente correlacionados. Desta forma, uma ideia que faz sentido é a de buscar medir quão correlacionados estão os ativos em dado momento, de forma a ajudar na previsão de períodos turbulentos, em função do aumento da correlação de ativos sabidamente pouco correlacionados ou do oposto. A

grandeza para medir quão correlacionados estão os ativos foi denominada pelo autor de “grau de acoplagem” ou “razão de absorção” [13]. Kritzman optou por quantificar esta grandeza através da Análise de Componentes Principais (PCA) [22].

O método de Análise de Componentes Principais é um dos mais comumente utilizados para extração de fontes de variação de sistemas multicorrelacionados. Essas fontes de variação não são, em grande parte das vezes explícitas. Tratam-se de combinações das fontes de variação originalmente expressas na matriz de covariância. O método faz a decomposição espectral desta matriz e com seus autovetores e autovalores consegue capturar em quais direções as variações da transformação original são mais acentuadas: quanto maior o valor do autovalor associado à direção do respectivo autovetor, tanto mais importante é aquela direção na explicação dos movimentos descritos pela matriz original. Pode ser demonstrado que se quisermos reduzir as dimensões de um problema na busca por invariantes (fenômenos que se repetem identicamente ao longo da história), a melhor aproximação que se consegue para estes invariantes é a advinda de PCA [23]. Quanto mais se reduzem as dimensões, mais informação se perde, porém até certo ponto, eliminam-se ruídos e há ganhos computacionais no trabalho com dimensões menores.

Em seu trabalho, Kritzman, aplicando PCA, avaliou a matriz de covariância dos ativos em cada instante de tempo e verificou, de um instante para o instante seguinte, dado um número de autovetores desta matriz, quanto do vetor retorno dos ativos como um todo pode ser explicado por um certo número de direções principais. Assim, definiu

$$RA = \frac{\sum_{i=1}^n \sigma_{Ei}^2}{\sum_{j=1}^N \sigma_{Aj}^2} \quad (2.8)$$

onde N é o número de ativos, n é o número finito de autovetores escolhido, σ_{Ei}^2 é a variância do i -ésimo autovetor, também chamado de autoportfolio e σ_{Aj}^2 a variância do j -ésimo ativo.

Neste trabalho optamos por seguir a mesma linha do trabalho de Kritzman com algumas modificações que serão descritas no próximo capítulo.

Capítulo 3

Metodologia

Como dito anteriormente, este estudo segue em linhas gerais o de Kritzman. Entretanto, há algumas diferenças que tornam este trabalho complementar. A primeira delas diz respeito ao espectro da análise. Enquanto o anterior foi centrado no mercado norte-americano, aqui fizemos uma análise global. Assim, conforme veremos adiante, foram considerados ativos de vários países englobando América do Norte, Europa, América do Sul e Ásia. Outra diferença fundamental é que a análise de Kritzman engloba diferentes classes de ativos em um só índice de turbulência enquanto que optamos por analisar inicialmente os ativos por grupos em separado. Foram escolhidos os seguintes grupos de ativos:

- Índices de Bolsa
- CDSs de Bancos
- CDSs soberanos
- *Commodities*
- Moedas

Após o estudo de cada grupo individualmente também foi feita a análise de todos os ativos em conjunto.

3.1 Tratamento dos Dados

Em se tratando de mercado financeiro há diversas fontes possíveis de dados. Para este trabalho optamos por usar os dados da Bloomberg[®] ¹ disponíveis para assinantes do serviço. Assim, foram levantadas as séries temporais de preços diários por grupo descritas na tabela B.

Apesar de bastante completo e confiável em seu histórico mais recente, o banco da Bloomberg[®] também apresenta suas limitações. A principal das limitações diz respeito à ausência de dados. Apesar das séries temporais terem poucas ausências quando a data em questão é recente, o início das séries é consideravelmente errático e pouco confiável. Deste modo, precisamos tratar tais informações antes de usá-las.

Primeiro escolhemos a data a partir da qual iríamos usar de fato as informações. A seguir, quando havia janelas² de dados ausentes, procuramos preenchê-las como descrevemos adiante.

Deste modo, adotou-se um procedimento de corte no início das séries temporais, para todos os ativos selecionados. Este consistiu em inicialmente determinar os locais em que ocorriam janelas de período maior ou igual a 10 dias seguidos. A seguir determinou-se qual a mais recente destas. Descartou-se toda parte da série anterior ao dia seguinte deste última janela. Vale ressaltar que não usamos nenhum critério quantitativo para esta escolha. Apenas entendeu-se que, diante do tamanho das séries temporais envolvidas, o preenchimento de janelas maiores que estas utilizando qualquer método, introduziria excessivas alterações na série, possivelmente distorcendo a informação existente. Não pretende-se aqui afirmar que 10 dias é o número mais adequado a ser adotado, mas algo superior a isso parece excessivo. Ao adotar este procedimento, via de regra, as janelas remanescentes eram de 1 ou 2 dados ausentes. Tentou-se obter todas as séries desde 01/01/2000. Após este corte inicial, naturalmente a data

¹Bloomberg[®] é uma empresa especializada em fornecer dados, análises e outras informações do mercado financeiro, principalmente através de uma rede à qual pode ter acesso qualquer pessoa que assinar os serviços. É uma das fontes de informação mais utilizadas em todo o mercado, senão a mais.

²Janela, neste contexto, corresponde a ausência de dados em uma série temporal, que pode ser de dados isolados, ou contíguos.

inicial utilizada na maioria das séries mudou. A Tabela B indica a data inicial adotada para cada série temporal após o uso deste procedimento. Para fins dessa análise, escolheu-se como último dia de todas as séries temporais o dia 29/11/2011.

Contornado este problema, passou-se ao estudo de como tratar os dados ausentes que permaneceram nas séries após o descarte do início errático das mesmas. As maiores janelas que precisaram ser tratadas foram nas séries de CDSs Soberanos de Malásia, Brasil e México, todas de 9 dias, ocorrendo uma vez. A maioria dos casos de lacunas, todavia, era de apenas 2 ou 3 dias conforme pode ser visto na tabela B.

Passamos então a uma revisão da literatura sobre métodos disponíveis para preencher lacunas em séries temporais. Dado que nossa análise se basearia tanto em informações contidas nas séries individualmente como nas correlações das séries (em função do uso da métrica de Mahalanobis), nosso interesse era o de preencher essas janelas com dados que distorcessem o menos possível a informação originalmente fornecida pela própria série bem como a informação relativa à correlação entre as séries.

Assim, verificamos na literatura diversos trabalhos que tratam da interpolação de dados. Entre eles os de King [8, 9] tratam de preenchimento múltiplo, i.e., as lacunas existentes na série temporal são simultaneamente preenchidas com dados aleatórios. Basicamente, supõe-se que a distribuição dos dados ausentes é normal multi-variada. Os parâmetros dessa normal vêm de uma estimação de máxima vero-similhança a posteriori que são realimentados na pre-estimativa até convergência. Faz-se então um sorteio aleatório e depois trata-se o número sorteado com uma equação vinda de análise assintótica para introduzir erro na medida. Os resultados são, em princípio, melhores que os métodos normalmente usados (completamente aleatórios, médias simples, etc).

Ryan e Giles [11], em trabalho que avalia potência do teste de raiz unitária, preenchem

as lacunas fazendo interpolações lineares ou repetindo o último valor conhecido. Os autores concluíram que esse procedimento torna o teste mais potente.

Entre os trabalhos pesquisados, merece destaque o de Musial, Verstraete e Gorbon [6]. Neste, os autores fazem um estudo de diferentes métodos de interpolação comparando sua efetividade. Para tal são tomadas diferentes séries temporais entre as quais dados de “fração de radiação ativa fotossinteticamente absorvida”, número de manchas solares, concentração de gás carbônico no ar atmosférico e também uma série temporal do índice Dow Jones. Estas séries escolhidas não têm, originalmente, lacunas. A seguir, aleatoriamente, são criadas lacunas nessas séries pela omissão de alguns dados. Nas novas séries com lacunas são testados diferentes métodos de interpolação e as séries interpoladas são comparadas com as originais, sem lacunas. A efetividade do método é avaliada pela menor soma de erros quadráticos entre as séries. Nesta avaliação foram testados os métodos de Lomb-Scargle que se baseia na estimativa do periodograma da série para pontos não necessariamente igualmente espaçados, de Kondrashov e Ghil, baseado em PCA e *splines* cúbicos. Cada método mostrou ter seus pontos fortes e fracos. O de Lomb-Scargle se mostrou eficiente quando a série temporal tem componentes periódicos. O de Kondrashov e Ghil teve bons resultados em grande variedade de séries sendo bastante adequado quando a tamanho da janela de dados ausentes seguidos é grande; neste usamos informações da série temporal como um todo para estimar os dados da janela. O *cubic spline* foi o que obteve os melhores resultados em termos do menor erro quadrático quando a janela de dados ausentes era pequena. Entretanto, o método depende da presença de pontos ao redor da lacuna para estimar uma adequada solução local, não sendo portanto o mais indicado para janelas grandes. É importante ressaltar que os métodos foram aplicados nas séries individualmente, ou seja, nenhum efeito de correlação foi considerado na análise.

Não conseguimos encontrar na literatura nenhum método que tratasse da interpolação de valores em uma série levando explicitamente em consideração sua correlação conhecida com outras séries. Implicitamente, o método de Kondrashov e Ghil o faz. Todavia o método é bastante custoso computacionalmente. Assim, por serem pequenas as janelas a interpolar e por

não ser o cerne do trabalho a interpolação per si, utilizamos um outro método mais simples, por nós proposto, que utiliza explicitamente o valor de correlação conhecido. O método deve ser investigado com mais rigor, mas sempre tendo em vista se há ganho em refinar o método de interpolação. Em uma análise mais aprofundada pode-se estudar a sensibilidade do valor final das séries de acoplagem/turbulência ante os valores preenchidos.

O primeiro passo do método consistiu em interpolar cada série temporal individualmente, utilizando *splines* cúbicos, na linha dos resultados de Musial, Verstraete e Gorbon [6]. Para uma dada série j em um dado dia d_t que fosse uma lacuna na série temporal, chamemos o valor assim encontrado de r_t^{1j} .

A seguir, para este dia d_t , verificamos as informações disponíveis nas demais séries, dentro de um mesmo grupo de ativos. Digamos que sejam $n - 1$ ativos; então, para cada uma das $n - 1$ séries, avaliamos qual o retorno esperado para a série j , dados os retornos da série j até então e, dado o retorno da série i para o dia d_t , do seguinte modo:

$$E[r_t^j / r_1^j, r_2^j, \dots, r_{t-1}^j, r_1^i, r_2^i, \dots, r_t^i] = \sum (r_{t_m}^j) / s \quad (3.1)$$

sendo $m \in \{k / r_{t_k}^i = r_t^i \pm 0.001, k \in 1, 2, \dots, t\}$ e $s = \#\{k / r_{t_k}^i = r_t^i \pm 0.001, k \in 1, 2, \dots, t\}$.

A intuição aqui é a de que, para cada série utilizada em um dado grupo de ativos, baseados em uma outra série do mesmo grupo, temos para cada lacuna um valor esperado em função do comportamento que a outra série demonstrou.

Tendo os valores esperados de acordo com cada uma das $n-1$ séries do mesmo grupo, calculamos a média ponderada destes retornos esperados, usando como ponderador a correlação entre as séries:

$$\tilde{r}_t^{2j} = \frac{\sum_{\substack{i=1 \\ i \neq j}}^n \rho_{ji} * E[r_t^j / r_1^j, r_2^j, \dots, r_{t-1}^j, r_1^i, r_2^i, \dots, r_t^i]}{\sum_{\substack{i=1 \\ i \neq j}}^n \rho_{ji}} \quad (3.2)$$

Com isso, tem-se várias estimativas para o valor que ocuparia a lacuna da série, de acordo com a informação disponível até então em cada uma das demais séries disponíveis no grupo. Usando a correlação da série em que temos a lacuna com as demais, ponderamos estas estimativas, dando portanto, mais peso à estimativa quanto mais correlacionadas fossem a série com janela e a outra série em questão.

Por fim, para o valor final usamos tanto o resultado vindo da série isolada via *cubic spline* quanto a informação de retorno esperado, vinda das outras séries em conjunto com as correlações, do seguinte modo:

$$r_t^j = \frac{r_t^{1j} + r_t^{2j}}{2} \quad (3.3)$$

A ponderação é o artifício que permite usar ambos os modos de interpolar no resultado final. Em trabalhos futuros seria importante testar a robustez e adequação deste modo de preencher lacunas em séries temporais. Feito este procedimento com todas as lacunas de todas as séries, passou-se ao cálculo da acoplagem e da turbulência.

3.2 Acoplagem

O grau de acoplagem dos ativos, também chamado de taxa de absorção, é uma métrica que busca inferir ao longo do tempo se o nível de correlação entre os ativos está se mantendo constante, aumentando ou diminuindo. O fundamento teórico para o uso dessa medida é o de que historicamente os retornos dos ativos têm um grau de correlação que é relativamente estável. Em períodos turbulentos da economia, entretanto, essa correlação pode sofrer grandes

alterações na margem, havendo evidências [13] de aumento da correlação num movimento generalizado de queda de preços na maioria das vezes.

Assim sendo, buscamos analisar uma “evolução histórica” da matriz de correlação. Uma escolha arbitrária foi a de quantos dias seguidos da série temporal de retornos seriam utilizados para o cálculo da matriz de correlações. Optamos por 200 dias. Desse modo, criamos uma série de matrizes de correlação por grupo de ativos a cada 200 dias de dados, a partir dos primeiros duzentos dias de cada grupo de séries. Para cada uma destas matrizes foi feita uma análise de componentes principais. Esta extrai da transformação linear (matriz) as direções principais de variação (autovetores) bem como um peso para a variação em cada direção (autovalor). De posse de todos os autovalores pode-se estipular percentualmente que em dada transformação linear, a direção x^i tem importância ξ_i dada por:

$$\xi_i = \frac{\alpha_i}{\sum_{j=1}^n \alpha_j} \quad (3.4)$$

onde α_i é o autovalor correspondente ao autovetor x^i e n é o número de dimensões da matriz. Neste ponto introduzimos o que chamamos de grau de acoplagem (G):

$$G = \sum_{i=1}^k \Xi_i \quad (3.5)$$

onde k é um inteiro arbitrário tal que $1 \leq k \leq n$, Ξ_i pertencente ao conjunto das ξ_i ordenado de modo decrescente.

Assim, dado k , o grau de acoplagem equivale ao percentual da transformação linear que pode ser explicado pela direção dos k primeiros autovetores (em ordem decrescente de explicação). Obviamente, $0 \leq ga_t \leq 1$.

A ideia é que se o padrão de correlação entre os ativos mudar, será necessário um número diferente de direções (mais ou menos) para explicar satisfatoriamente (algum percentual

arbitrário) o movimento do conjunto de ativos linearmente. O que fizemos então foi fixar $k = 3$ e verificar então quantos por cento do movimento do conjunto poderiam ser explicados pela direção de 3 autovetores. Utilizou-se esta quantidade de autovetores em função trabalho de Litterman e Scheinkman [7], que com este mesmo número de autovetores mostraram ser possível explicar mais de 95% dos movimentos da curva de títulos do Tesouro Americano. Fizemos isso para os cinco grupos de ativos analisados obtendo assim cinco séries temporais de graus de acoplagem.

3.3 Turbulência

Conforme vimos anteriormente, existem diversos tipos de abordagem que buscam quantificar o nível de turbulência que existe no mercado financeiro. A métrica usada neste trabalho busca avaliar quão afastado de um grupo de estados anteriores está um determinado estado. Assim, seja x_t^{ij} o retorno de um determinado ativo i do grupo j no dia t . Chamaremos de estado o vetor $v_t^j = (x_t^1, x_t^2, \dots, x_t^n)^{j'}$ onde n é o número de ativos que compõem o grupo j e o sobrescrito $'$ indica transposição.

Seja

$$\mu_t^i = \frac{\sum_{k=t-199}^t x_k^i}{200} \quad (3.6)$$

onde μ_t^i é a média de retornos do dia considerado e dos 199 dias anteriores, para cada ativo de cada grupo.

Seja o vetor de excesso de retornos definido por

$$\rho_t^j = v_t^j - (\mu_t^1, \mu_t^2, \dots, \mu_t^n)^{j'} \quad (3.7)$$

Definimos como nível de turbulência no dia t para o grupo j em relação a k estados anteriores, o escalar

$$T_t^j = \rho_t^j * (\Sigma^{-1})_t^j * \rho_t^{j'} \quad (3.8)$$

onde $(\Sigma^{-1})_t^j$ é a inversa da matriz de covariância dos ativos j calculada com base no estado atual e nos 199 estados imediatamente anteriores a v_t^j , i.e., $v_{t-1}^j, v_{t-2}^j, \dots, v_{t-199}^j$, sendo a matriz de covariância definida por

$$\Sigma_t^{ab} = \frac{\sum_{m=t-199}^t (x_m^a - \mu_t^a)(x_m^b - \mu_t^b)}{n - 1} \quad (3.9)$$

Deste modo, tal como com os graus de acoplagem, obtivemos uma série temporal de turbulência para cada grupo analisado. Percebemos que a Equação (3.8) é análoga à Equação (2.5). O indicador que chamaremos de *turbulência* é a distância de Mahalanobis ao quadrado. Portanto, a métrica de turbulência indica em termos de distâncias de Mahalanobis, quão afastado está um grupo de retornos num determinado dia, daquilo que se esperava para aquele grupo, levando em conta as covariâncias entre os ativos.

3.4 Modelo de Volatilidade EWMA

Sabemos que a volatilidade é a mais comum das medidas de risco. Todavia, existem várias maneiras de se medir a volatilidade, que se dividem em dois grandes grupos: os métodos de volatilidade histórica e os métodos de volatilidade implícita. Os métodos de volatilidade implícita refletem o pensamento a cada instante do mercado sobre a volatilidade, partindo do pressuposto que os modelos de precificação são aceitos. Em outras palavras, é o valor de volatilidade que, seguindo os modelos de precificação aceitos, faz com que o preço calculado pelo modelo seja igual ao preço negociado no mercado. Já os modelos históricos levam em consideração os retornos passados do ativo. O uso desse tipo de modelagem de volatilidade

assume que o passado permite prever o futuro, ao passo que o uso da volatilidade implícita considera a visão estratégica do mercado incluindo sua avaliação de risco dos diferentes instrumentos. Os modelos de volatilidade histórica se baseiam no cálculo dos retornos passados e na atribuição de diferentes pesos a estes retornos, na expectativa de prever a faixa de variação do retorno seguinte. Ao passo que a variância dá um peso igual ao quadrado dos retornos, a média móvel exponencialmente ponderada, através de seu fator de alisamento, dá mais peso aos quadrados dos retornos mais recentes e exponencialmente menos peso aos quadrados dos retornos passados. Isto é feito do seguinte modo:

$$\begin{aligned}
 & u_t^2 \cdot (1 - \lambda) \cdot \lambda^0 \\
 & u_{t-1}^2 \cdot (1 - \lambda) \cdot \lambda^1 \\
 & u_{t-2}^2 \cdot (1 - \lambda) \cdot \lambda^2 \\
 & \vdots \\
 & u_{t-(n-1)}^2 \cdot (1 - \lambda) \cdot \lambda^{n-1}
 \end{aligned} \tag{3.10}$$

sendo u_t o retorno no tempo t e λ o fator de alisamento exponencial.

A soma destas parcelas pode ser expressa pela seguinte fórmula de recorrência que caracteriza o EWMA:

$$\sigma_{t_{EWMA}}^2 = \lambda \sigma_{t-1_{EWMA}}^2 + (1 - \lambda) u_{t-1}^2 \tag{3.11}$$

sendo σ_t^2 o valor da variância no tempo t .

Convém lembrar que o modelo GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*) também amplamente utilizado no mercado, é uma generalização do modelo EWMA, porém de implementação mais complexa. Em nosso trabalho, utilizamos EWMA com $\lambda = 0.94$ que foi o valor empregado na Riskmetrics, comumente usado pelo

mercado. Considerando que a métrica do EWMA é de fato muito utilizada, é natural questionar se a métrica proposta apresenta previsões melhores que o EWMA ou tem algo a acrescentar a estas previsões. A resposta a esta indagação é objeto do próximo capítulo. Neste, mostraremos que com a nova métrica somos capazes de melhorar as previsões do EWMA.

Capítulo 4

Análise de Resultados

A análise dos dados gerados com este trabalho teve, principalmente dois objetivos: verificar se as métricas de turbulência e acoplagem são indicativos significantes de possíveis crises e/ou movimentos bruscos de preço e, em caso positivo, verificar se, tendo conhecimento de acoplagem e turbulência diariamente, é possível agregar informação na previsão de eventos de cauda ao EWMA. O conceito de evento de cauda utilizado ao longo deste trabalho é o de qualquer evento de uma determinada distribuição que se localize abaixo do percentil 10% ou acima do percentil 90% da distribuição.

4.1 Acoplagem e Turbulência Isoladamente

4.1.1 Séries Temporais e Eventos

Iniciamos a análise de resultados observando o comportamento, para cada grupo, das séries temporais de acoplagem e turbulência. Nesta primeira análise fizemos uma inspeção do macro comportamento destas séries para cada um dos grupos de ativos.

Quanto às séries de acoplagem procuramos entender se o comportamento faz sentido com o que se conhece da classe de ativos e de história do mercado. Um alto grau de acoplagem indica que movimentos de preço advindos de fatores não particulares de cada ativo do grupo tendem a se disseminar rapidamente no dado mercado. Por outro lado a variabilidade grande,

isto é, hora os ativos do grupo estão muito acoplados, hora pouco acoplados, mostra um mercado possivelmente pouco uniforme, i.e, apesar dos ativos serem semelhantes em suas características do ponto de vista dos instrumentos financeiros, seus movimentos são difíceis de explicar em conjunto. Possivelmente, se a variabilidade é grande, há ativos com macro movimentos distintos do grupo.

Nesse aspecto, a série de acoplagem de CDSs de bancos é bastante interessante. Como pode-se notar na Fig. 4.1 a seguir, a partir de julho de 2007 há uma abrupta mudança de patamar na série temporal que antes vinha decaindo e após o salto de nível permanece estável em patamar muito mais elevado.




Figura 4.1: Comportamento das séries de acoplagem e turbulência para o grupo de CDSs de Bancos

Se lembrarmos a história ao redor desta época veremos que faz sentido este comportamento. O ano de 2007 foi marcado pelo acirramento da crise do subprime com o reflexo final afetando diretamente diversos bancos e instituições financeiras. Em 31 de julho de 2007 o Bear Sterns se viu obrigado a liquidar dois *hedge-funds* que tinham investimentos em diversos tipos de hipotecas. Em 9 de agosto de 2007 o BNP Paribas, maior banco da França, determinou que

estavam proibidos os resgates de três fundos. Em 14 de setembro de 2007 foi aprovado a ajuda do banco central britânico ao Northern Rock, um banco da Grã-Bretanha que concentrava seus negócios principalmente em empréstimos a indivíduos que queriam financiar a compra da casa própria. No dia seguinte ao recebimento do dinheiro foram sacados mais de 2 bilhões de dólares do banco, uma das maiores fugas de capital da Grã-Bretanha. A esta altura, diversos outros bancos já apresentavam graves problemas de liquidez e estavam com seus balanços contaminados por ativos de valor superestimado.

Quanto à metodologia utilizada, vale ressaltar que a partir de agosto de 2004 o número de ativos permanece constante no grupo. Antes desse período, em algumas datas são adicionados ativos conforme os dados são disponibilizados pela Bloomberg. Os “dentes” de queda na acoplagem no início da série se devem a este efeito. Nas outras séries, A.1 ,A.2, A.3 , A.4, A.5 , respectivamente, CDS Soberanos, Commodities, Moedas, Índices e Todos, comportamento similar pode ser observado. Na Tab. 4.1 a seguir indicamos as datas, para cada grupo, a partir das quais não há mais variação na quantidade de séries de ativos analisadas no grupo.

Tabela 4.1: Datas para Número de Ativos Constante por Grupo

Grupo	Data	Total de Ativos
CDSs Bancos	20/08/2004	28
CDSs Soberanos	10/05/2010	32
Commodities	28/12/2000	17
Índices	27/12/2000	14
Moedas	28/12/2000	13
Todos	10/05/2010	104

Nas séries de turbulência, percebe-se a existência de uma espécie de ruído de alta frequência e baixa amplitude ao longo das séries de todos os grupos. Ocasionalmente ocorrem picos de amplitude, indicando comportamento anômalo. Buscamos então, nestas datas de comportamento anômalo, checar a história do mercado averiguando se há correspondência com notícias, fatos relevantes etc.

Na Fig. 4.1 acima pode-se observar, além da acoplagem, a série temporal de turbulência para o grupo de CDSs de bancos. Nota-se que a mudança de patamar da acoplagem é acompanhada pelo período de maior turbulência da série o que também é coerente com a história que foi descrita desta época. Especificamente, o valor mais alto desta série ocorreu no dia 30/07/2007, véspera de um problema notório que vinha ocorrendo com o Bear Sterns tornar-se de conhecimento público. Seguiu-se um período com outros picos; mas adiante no tempo se destaca um pico em 17/09/2008, dois dias após a quebra do banco Lehman Brothers e véspera do anúncio do programa de ajuda do governo americano, *Quantitative Easing 1*. Assim, a série de turbulência apresentou bom comportamento, estável e de pouca amplitude na maior parte do tempo, com picos localizados que fazem sentido histórico. As demais séries de turbulência dos grupos de CDSs soberanos, *Commodities*, Índices e Moedas estão junto com as séries de turbulência no Apêndice A. Adicionalmente, incluímos uma tabela no Apêndice B com as datas de três picos em destaque na série de turbulência para cada grupo, de modo a facilitar a localização histórica.

4.1.2 Previsibilidade de Eventos de Cauda

No mercado financeiro, tanto *traders* quanto analistas de risco devem sempre preocupar-se com eventos de cauda. É claro que estes eventos podem ser positivos do ponto de vista da rentabilidade mas expor-se a eventos de cauda pode ter resultados catastróficos para o tomador de risco como mostra a história. Não é preciso ser um gestor de investimentos para saber que é uma tarefa difícil ganhar dinheiro. Como todas as pessoas, grosseiramente falando, querem aumentar seu capital, todos competem entre si nesta tarefa. São necessárias boas idéias, experiência, trabalho, dentre outras para se destacar um pouco que seja da média. Assim, investimentos que tem retornos excessivamente altos indicam, via de regra, níveis de exposição e/ou alavancagem altos, possivelmente aliados à má gestão de risco. Dizendo de outro modo, alguma estratégia pode ter dado certo em um primeiro momento mas ela tem potencial para dar errado. Se a exposição a ela é alta, pode-se acabar perdendo muito mais do que se ganhou. Sendo assim, via de regra, os gestores desejam fugir de eventos extremos, posto que são cheios de incertezas e o revés dos mesmos é muito desfavorável.

Deste modo precisamos inicialmente esclarecer que, quando falamos de evento de cauda, estamos implicitamente falando de uma distribuição, que, em nosso caso, é a do retorno de algum ativo. Os ativos escolhidos neste trabalho como *proxy* para verificar a existência de crise foram o índice Ibovespa, doravante chamado Ibov, e a cotação do dólar *spot* em reais. Assim procuramos verificar como se comportam a acoplagem e a turbulência, em especial nos momentos anteriores aos que ocorreram caudas nestes ativos, para verificar sua capacidade previsora.

Acoplagem/Turbulência explicando eventos de cauda

Inicialmente, quisemos verificar se a acoplagem e a turbulência são, de alguma maneira, relacionadas a eventos de cauda que sabidamente ocorreram nos dois ativos objeto, o dólar e o Ibov. Deste modo, relacionamos a ocorrência de eventos de cauda nestes ativos aos valores de acoplagem e turbulência anteriores. Pela metodologia exibida a seguir, nos parece claro que estes eventos de cauda estão sim relacionados a um aumento de acoplagem / turbulência.

O procedimento adotado para esta análise foi o de fazer uma contagem de eventos de cauda, considerando os retornos médios semanais, que ocorreram em determinadas faixas de acoplagem e turbulência na semana anterior para o grupo sendo analisado. Para facilitar a visualização da informação criamos o que chamamos de mapa de acoplagem e turbulência. Consiste em um retângulo dividido em 16 regiões conforme o percentil de acoplagem e turbulência referente ao dado que se vai contabilizar. A figura a seguir é um exemplo de um mapa.

A divisão observada na figura anterior segue os seguintes valores de percentis tanto para acoplagem quanto para turbulência: $P < 25\%$, $25\% \leq P < 50\%$, $50\% \leq P < 75\%$ e $75\% \leq P$. Estes percentis são condicionais, ou seja, a cada dia, para classificar em que percentil estava a acoplagem e a turbulência, só foram usadas informações conhecidas até aquele dia.




Figura 4.2: ibov CDSs Bancos - eventos de cauda

Precisamos definir, formalmente, o que chamamos de evento de cauda. Quer para a série de retornos diários do Ibov, quer do dólar *spot*, dizemos que um dia d_t foi dia de evento de cauda para alguma das duas séries se, para a dada série, dados os retornos de todos os dias anteriores ao d_t desde o primeiro dia de análise do grupo em estudo, o retorno do dia d_t está acima do percentil 90% ou abaixo do percentil 10% dos retornos anteriores.

Assim, dado um dia útil (D0), se o retorno médio da semana seguinte (D1-D5 útil) fosse um evento de cauda para o ativo considerado “benchmark” (Ibov ou dólar *spot*) então contabilizavamos o evento na região correspondente aos percentis de acoplagem e turbulência, referentes ao grupo estudado, no dia D0. Com esse estudo criamos a série de figuras A.6, A.15, A.24, A.33, A.42 e A.51 tendo o Ibov como base e a série de figuras A.60, A.69, A.78, A.87, A.96 e A.105 tendo a cotação do dólar em reais como base. O mapa que exibimos anteriormente retrata o caso quando o ativo objeto é o Ibov e o grupo estudado o de CDSs de Bancos.

Analisando a Figura 4.2, percebemos que há uma clara concentração de eventos de cauda na região de mais alta acoplagem e turbulência, conforme era esperado. Os demais mapas para este estudo se encontram no apêndice. Nestas figuras, tanto no caso do Ibov quanto do dólar, percebemos uma concentração em todos os grupos, exceto o de *commodities*, dos eventos de cauda no nível mais alto ($> P75$ - percentil 75%) da turbulência e também, em quase todos, no nível mais alto da acoplagem. Este comportamento está de acordo com as expectativas e significa que quando o retorno médio de uma semana foi um evento de cauda, a maioria das

vezes no último dia da semana anterior a turbulência e a acoplagem estavam em níveis altos. Note-se que isso não indica que turbulência e acoplagem altas na semana anterior aumentam a chance de evento de cauda na semana seguinte.

O grupo de *commodities* tem um comportamento significativamente diferente dos demais, tanto no estudo de caudas do Ibov quanto do dólar. Notamos em primeiro lugar que os eventos de cauda do dólar se concentram em níveis de acoplagem mínimos ($< P25$) do grupo de *commodities*. O mesmo ocorre com as caudas do Ibov, porém estas apresentam significativa concentração nos níveis mais altos ($> P75$). A turbulência do grupo de *commodities* não parece ter relação com as caudas do Ibov e do dólar na semana posterior; como se observa não é grande a concentração dos eventos em nenhuma região de turbulência no mapa, prevalecendo as regiões intermediárias.

Investigação de Assimetrias nas Caudas

A seguir, procuramos verificar se a métrica de acoplagem e turbulência tinha algum poder separatório nessa relação que já sabíamos existir entre eventos de cauda e aumento de acoplagem e turbulência. Com isso, queríamos verificar se a métrica estava mais relacionada com eventos de subida forte, com quedas acentuadas nos preços dos ativos ou se a métrica se mostrava indiferente ao tipo de cauda. Nossos resultados nesse sentido indicam pouco poder separatório em sua maioria. Naturalmente há algumas diferenças para alguns grupos como detalharemos a seguir, mas somente o grupo de moedas e de índices no estudo do Ibov, e de *commodities* no estudo do dólar parecem ter algum poder separador.

Para este grupo de estudos a fim de averiguar se havia assimetria nessa distribuição separamos os eventos de cauda em dois grupos - subidas fortes e quedas fortes-, gerando duas séries de figuras para cada ativo alvo de estudo. Consideramos quedas fortes aquelas em que o ativo teve retorno menor igual ao $P10$ até então e subidas fortes quando o retorno foi igual ou superior ao $P90$ até então. Contabilizamos então por faixa de turbulência e acoplagem,

no dia anterior à semana em questão, o número de eventos de quedas fortes gerando, no caso do dólar, a série de Figuras A.61, A.70, A.79, A.88, A.97 e A.106 e no caso do Ibov a A.7, A.16, A.25, A.34, A.43 e A.52. De maneira similar, contabilizamos os eventos de subida forte gerando a série de figuras A.62, A.71, A.80, A.89, A.98 e A.107 no caso do dólar e A.8, A.17, A.26, A.35, A.44 e A.53 no caso do Ibov.




Figura 4.3: Ibov - Índices - eventos de cauda

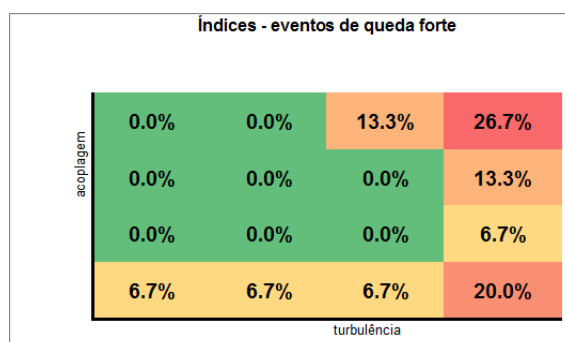


Figura 4.4: Ibov - Índices - eventos de queda forte

Observando os mapas de caudas e de quedas percebemos que não houve nenhuma grande assimetria. As Figuras 4.3 e 4.4 melhor exemplificam este fato. Na primeira delas, temos para o Ibov com o grupo de Índices os eventos de cauda como um todo. Se pensarmos no mapa como uma malha de 4 colunas por 4 linhas percebemos que as maiores concentrações estão nas células turbulência 4,acoplagem 4 e turbulência 4,acoplagem 2. O mapa como um todo indica importância para acoplagens altas (para qualquer turbulência) e turbulências altas (para qualquer acoplagem). No outro mapa, em que estão retratadas as quedas, as maiores concentrações estão em turbulência 2,acoplagem 4 e turbulência 4,acoplagem 2. Apesar da

célula de maior concentração ser diferente da do primeiro mapa, percebemos que há um rearranjo de concentração entre células vizinhas. Basta observar para tal que os níveis de acoplagem e turbulência baixos ficam pouco alterados, e as somas em tornos de grupos de células adjacentes são relativamente constantes.

De maneira similar, temos poucas alterações entre caudas e quedas fortes para CDSs soberanos, *Commodities*, Índices, Moedas e Todos como pode-se observar nas figuras do apêndice, tanto para o caso do dólar como do Ibov. Uma comparação mais interessante é a dos mapas de quedas fortes diretamente com os mapas de subidas fortes. Para o caso do dólar ainda assim, poucas diferenças são notáveis; apenas no caso do grupo de *Commodities* há uma assimetria um pouco mais apreciável. Observando as Figuras 4.5 e 4.6 a seguir pode-se perceber que o mapa de subida apresenta um aumento de concentração na região de baixa turbulência e alta acoplagem se comparado ao mapa de quedas.




Figura 4.5: Dólar - Commodities - eventos de queda forte




Figura 4.6: Dólar - Commodities - eventos de subida forte

Observando as figuras no apêndice para o caso do Ibov, os grupos de moedas e índices chamam atenção. No de índices, em relação às quedas fortes, percebemos certa assimetria nas

subidas fortes que tendem a regiões de acoplagem mais alta com turbulências menores. No de moedas, em relação às quedas fortes, percebemos uma migração para regiões de acoplagem e turbulência mais baixas. Assim, níveis de acoplagem altos para as moedas e baixos para os índices parecem potencialmente perigosos para o Ibov.

4.2 Acoplagem e Turbulência em Conjunto com EWMA

Nesta seção procuramos verificar se a métrica de acoplagem e turbulência (AT) é capaz de adicionar valor ao EWMA/GARCH, ou seja, melhorar as inferências feitas com uso do EWMA/GARCH. O EWMA é um método de previsão de volatilidade local amplamente utilizado na indústria financeira, o que demonstra sua boa relação no binômio custo de implementação/uso versus qualidade de resultados. Nos parece claro, através dos estudos que detalharemos em seguida, que a nova métrica é pior que o EWMA isoladamente mas melhora a qualidade de seus resultados se as duas métricas forem utilizadas em conjunto.

4.2.1 Comportamento do EWMA nos Mapas de AT

Um indicativo de que a métrica de acoplagem e turbulência é capaz de agregar valor às previsões do EWMA seria se os casos em que o EWMA acerta em suas previsões (e portanto também os casos em que ele erra) se concentrassem em determinadas regiões do mapa, i.e., se dada uma condição de acoplagem e turbulência pudéssemos dizer que a chance do EWMA estar correto (ou errado) é maior.

Regiões do mapa em que o EWMA é muito ou pouco conservador

Como dissemos anteriormente, o modelo EWMA estima a volatilidade no instante seguinte dados os retornos anteriores. Assim, a cada instante de tempo, a estimativa pode se mostrar conservadora caso o retorno seguinte resulte menor que a volatilidade estimada ou se

mostrar não conservadora, caso o retorno seguinte se mostre superior à volatilidade estimada. Deste modo, tentamos inicialmente verificar se, com os mapas de acoplagem e turbulência, conseguíamos separar as regiões onde o EWMA tendia a ser conservador das regiões onde ele tende a subestimar os desvios. Esse estudo mostrou que de fato há regiões de acoplagem e turbulência em que o EWMA tende a ser conservador e outras em que tende a subestimar o risco. Em geral, nas regiões de alta acoplagem/turbulência o modelo EWMA tende a ser conservador e em regiões de baixa acoplagem/turbulência ele tende a ser pouco conservador. A seguir detalhamos este estudo.

Conforme outros estudos anteriores, calculamos diariamente a série de acoplagem e turbulência, série essa diariamente condicional à informação conhecida até então. Também diariamente, com uso do modelo EWMA, estimamos o σ_{t+1} . Para este dia já tínhamos então o par $(\text{acoplagem}, \text{turbulência})_t$ e também σ_{t+1} . Verificamos então a razão entre o valor absoluto do retorno do dia seguinte ($|r_t|$) e σ_{t+1} . Assim, se essa razão fosse maior que 1 marcamos o dia t como um dia em que o EWMA foi pouco conservador. Se ao contrário, a razão fosse menor que 1 marcamos o dia t como conservador. A seguir, plotamos no mapa de acoplagem e turbulência do total de vezes que o EWMA tinha sido conservador, qual percentual ficou em determinada região de acoplagem / turbulência no dia d_t , fazendo o mesmo com as vezes em que ele não tinha sido conservador. Se o EWMA fosse indiferente à acoplagem e turbulência, esperávamos que estes percentuais ficassem em torno de 100%/16 em cada região. Todavia, dos estudos anteriores, já sabíamos que a métrica de AT era um bom indicativo de caudas, e o mesmo ocorre para o EWMA. Portanto, esperávamos que os erros do EWMA conservador ou não, se concentrassem na região de alta acoplagem/turbulência. Por outro lado, esperávamos que ambos os mapas (conservador e não-conservador) tivessem distribuições semelhantes. A série de figuras geradas para desvios superiores ao previsto com este estudo foi A.9,A.18, A.27,A.36, A.45 e A.54 para o Ibovespa e A.63,A.72, A.81,A.90, A.99 e A.108 para o dólar e para desvios inferiores ao previsto geramos a sequência de figuras A.10,A.19, A.28,A.37, A.46 e A.55 para o Ibovespa e A.64,A.73, A.82,A.91, A.100 e A.109 para o dólar.

A primeira observação clara nos mapas em que o EWMA é pouco conservador para o Ibov

é que o aumento de turbulência está diretamente relacionado com os estes eventos. O efeito da acoplagem é difuso, e parece depender de cada grupo de ativos em análise. Na figura abaixo temos o exemplo deste estudo usando índices de bolsa. Parece clara a concentração na região de alta turbulência e difusão quanto à acoplagem.




Figura 4.7: Ibov - Índices - Desvios maiores que o previsto pelo EWMA

O comportamento dos mapas para o estudo do Ibov é similar nos casos em que o EWMA é muito conservador, como se pode ver nas figuras em anexo. Todavia, há uma redução de importância da turbulência quando o grupo é o de *commodities*, moedas e índices, se compararmos ao casos em que o EWMA não é conservador, como mostra a figura 4.8 à seguir. De fato, nestes casos a acoplagem parece ser mais importante que a turbulência, ao contrário do grupo dos CDSs Para os casos do dólar o comportamento é bastante similar como pode ser observado nas figuras do anexo.




Figura 4.8: Ibov - Índices - Desvios menores que o previsto pelo EWMA

Previsões pelo EWMA de Evento de Cauda segundo Mapa de AT

Em linha com o estudo anterior, buscamos agora, a cada dia, de posse da estimativa do desvio feita pelo EWMA para o dia seguinte, classificar as mesmas em estimativa de cauda

(caso o desvio estimado estivesse acima do $P90$ dos retornos ocorridos até então) ou não-cauda. O objetivo foi verificar o comportamento do mapa somente com as caudas. Fizemos para tanto quatro estudos em que separamos os dias em expectativa de cauda ou não e expectativa realizada ou não, de acordo com o percentil do retorno em relação aos retornos anteriores. Nestes, verificamos que o comportamento é bastante variado dependendo do estudo/grupo, mas, em geral, tanto acertos como erros se concentram em regiões de alta turbulência e acoplagem, indicando que essa é apenas a região de caudas. Como mostraremos a seguir, há alguns comportamentos diferentes tocante a região de concentração de erros e acertos, que podem ser auxiliares na tomada de decisão.

No primeiro estudo, contabilizamos de acordo com a região (no mapa de acoplagem e turbulência) em que se encontrava o dia $D0$, em que se fez a previsão para $D1$ com EWMA, quantas vezes ocorreu um evento de cauda em $D1$ sendo esta possibilidade não prevista em $D0$. Com isso, geramos a seguinte sequência de figuras: A.12, A.21, A.30, A.39, A.48 e A.57 para o Ibovespa e A.66, A.75, A.84, A.93, A.102 e A.111 para o dólar. Este é um dos eventos mais críticos estudados. Isto porque, se confiarmos no EWMA como previsor, é este tipo de erro que pode levar o gestor de investimentos a ficar muito exposto e acabar sofrendo com um evento de cauda. Parece claro, tanto no caso do dólar como no do Ibov, que para todos os grupos há aumento da concentração nas regiões de alta turbulência e acoplagem, com especial concentração no caso do estudo feito com o grupo de moedas e o de índices. Como a análise considera a situação de acoplagem e turbulência antes do evento de fato, i.e., junto com a previsão do EWMA, pode-se dizer que ela dá um bom indicativo de preocupação em relação a essas previsões que não esperam eventos de cauda, quando estivermos nessas regiões. Se considerarmos por exemplo os mapas de moedas, exibido na Figura 4.9 a seguir e as quatro regiões superiores à direita (maior que $P50$ para acoplagem e turbulência), percebemos que há uma concentração de erros deste tipo superior a 50%, ou seja, em mais da metade das vezes que o EWMA não previu eventos de cauda e eles ocorreram, estávamos nessa região no dia anterior. Assim, previsões nesta região inspiram cuidados.

As regiões em que os eventos se concentram são muito similares neste primeiro tipo de




Figura 4.9: Dólar - Moedas - EWMA não previu evento de cauda mas ocorreu

evento se compararmos o caso do dólar e do Ibov, como se pode observar nas figuras do anexo. Em todos os grupos a concentração de eventos se dá na região de alta acoplagem e turbulência, mas em alguns, em especial no de CDSs de bancos, algumas outras faixas de acoplagem ganham importância, sempre prevalecendo a alta turbulência.

No segundo tipo de evento, contabilizamos quantas vezes houve previsão de possibilidade de evento de cauda não tendo este ocorrido. As figuras geradas foram A.14, A.23, A.32, A.41, A.50 e A.59 para o Ibovespa e A.68, A.77, A.86, A.95, A.104 e A.113 para o dólar. Há algumas diferenças de concentração em relação aos mapas do primeiro evento. No caso do dólar, um dos fatos mais importantes a notar é que no grupo de moedas a concentração dos eventos se dá na região de baixa turbulência como mostra a Figura 4.10 a seguir. O grupo de *commodities* também tem uma mudança significativa, concentrando este tipo de evento na região de baixa acoplagem (menor que $P25$). Também no caso do Ibov o grupo de *commodities* apresentou boa diferenciação em relação ao caso anterior. Este resultado, associado ao anterior parece indicar bom potencial para adição de valor ao EWMA pelas séries de acoplagem e turbulência dos grupos de moedas e *commodities*.

No terceiro e quarto tipos de eventos, estudamos os acertos do EWMA. Inicialmente analisamos os mapas do comportamento apresentado nas vezes em que o EWMA previu a possibilidade de cauda e houve cauda. Os mapas referentes a estes eventos estão no apêndice nas figuras A.13, A.22, A.31, A.40, A.49 e A.58 para o Ibovespa e A.67, A.76, A.85, A.94, A.103 e A.112 para o dólar. Exceto pelo caso do mapa de *commodities*, é bastante claro que




Figura 4.10: Dólar - Moedas - EWMA previu evento de cauda mas ele não ocorreu

a concentração dos acertos do EWMA se dá na região de alta acoplagem e turbulência. Isto era esperado posto que quando a volatilidade prevista pelo EWMA aumenta já se iniciou a oscilação mais significativa dos retornos dos ativos descolando aquele estado de estados anteriores, aumentando a turbulência. A acoplagem também possivelmente aumentaria caso os retornos passassem a se deslocar todos em um mesmo sentido. Isto é de fato o que ocorre, exceto pelo grupo de *commodities*. Neste, ao contrário, os acertos do EWMA se dão na região de baixa acoplagem como vemos na Fig. 4.11 a seguir.




Figura 4.11: Dólar - Commodities - EWMA previu evento de cauda e ocorreu

É também interessante notar que os acertos de previsões do EWMA para o dólar, se distribuem no caso de *commodities* em regiões tanto de alta quanto de baixa turbulência, indicando que esta agrega pouco valor ao EWMA se olharmos as informações vindas de *commodities*. Por outro lado, a acoplagem agrega valor ao EWMA, no sentido que previsões corretas tendem a estar concentradas (na área de baixa acoplagem). No caso das previsões referentes ao Ibovespa seguem em linhas gerais a do dólar. Um ponto adicional a notar é que a acoplagem faz pouca diferença no caso dos índices de bolsa, importando mais a turbulência. O grupo de *commodities* ainda apresenta uma relevante concentração de acertos na região de baixa acoplagem e turbulência.

Por fim, no quarto tipo temos os acertos em que o EWMA não previu possibilidade de cauda e de fato não ocorreu evento de cauda. Os mapas gerados foram os seguintes: A.11, A.20, A.29, A.38, A.47 e A.56 para o Ibovespa e A.65, A.74, A.83, A.92, A.101 e A.110 para o dólar. Como pode-se observar, na série de figuras do dólar a turbulência aqui é pouco importante, i.e., não há concentração em região específica em função da turbulência. Por outro lado, notamos faixas de concentração de acoplagem. Isto indica que há um valor de acoplagem relativamente distinto dos demais por grupo, ou seja, cada grupo tem um padrão marcante esperado de acoplagem. Uma possibilidade a ser estudada em futuros trabalhos é a de que comportamentos de cauda ocorrem quando nos afastamos dessas faixas. Para o estudo do Ibov, comportamento similar é notado. Ainda, nota-se tanto para o Ibov e o dólar que quando todos os ativos estão juntos a concentração de acertos em previsões quando não há cauda é moderadamente crescente com a turbulência.

4.2.2 Análise da AT e EWMA com Filtros Condicionais

Após o estudo com mapas fizemos uma outra abordagem estatística que funcionou como um conjunto de filtros. Inicialmente classificamos, a cada dia, o retorno do dólar (ou do Ibov) de acordo com o percentil histórico do retorno até então em que se encaixava aquele dia. O fundamento é que os grandes retornos positivos e negativos são eventos de cauda da distribuição, i.e., ocorrem muito poucas vezes. Assim, dado um conjunto de retornos conhecidos até então, chamamos os grandes retornos positivos ou negativos de caudas desta distribuição. Deste modo, a cada dia sabíamos que lugar do histograma até então, o retorno de cada dia ocupou.

O EWMA é um modelo bem aceito no mercado, sendo caso particular de um GARCH como comentado. Idealmente, quer-se um modelo que indique com antecedência se vai ocorrer uma queda brusca mais adiante. Até então, a partir dos mapas, tinha-se bons indicativos de que o modelo de acoplagem/turbulência era coerente com os eventos de cauda possivelmente

previsões também coerentes. Deste modo, passou-se então a tentar verificar, de uma forma quantitativa se o modelo de acoplagem e turbulência é capaz de ajudar o EWMA em suas previsões e também se, atuando em separado, ele apresentaria bons resultados. Dado que o EWMA faz previsões para o intervalo de σ_{t+1} dada a série $\{\sigma_t\}$ e dado r_t e, dado que o período mínimo de retorno escolhido é diário, nesse estudo buscou-se verificar se as séries de acoplagem e turbulência também podem fazer boas previsões diárias e se em conjunto com o EWMA melhoram as mesmas. O esquema tipo filtros é descrito a seguir.

Inicialmente, construiu-se toda a série temporal de previsões diárias de σ_t do EWMA, bem como da acoplagem e da turbulência, por grupo de ativos. Classificou-se, como descrito acima, os percentis diários dos retornos do ativo em questão, dólar ou Ibov. A partir daí, classificou-se cada dia como um dia em que houve previsão de evento de cauda para o dia seguinte ou não, conforme os estudos anteriores. Anotou-se então o percentil do retorno do ativo em questão no dia seguinte. Se fosse acima do $P90$ ou abaixo do $P10$ dos retornos até então a previsão teria acertado, errando em caso contrário. Assim, passamos a ter um histórico de dias em que houve previsão de evento de cauda pelo EWMA e percentil da distribuição até então, que caiu esse dia.

Procedimento similar foi adotado para acoplagem e turbulência. Lembrando que a acoplagem e a turbulência são séries temporais associadas aos grupos com os quais tentamos explicar o ocorrido com o ativo objeto de estudo, criamos então para cada ativo objeto, dólar e Ibov, seis grupos de estudo (cds bancos, cds soberanos, *commodities*, índices, moedas e todos juntos). Para cada grupo, contabilizamos também as previsões de cauda para o dia seguinte com a acoplagem e a turbulência. Estas previsões foram contabilizadas quando tanto a acoplagem quanto a turbulência referentes ao dia, com dados até o fim deste, estivessem acima do percentil $P90$ para acoplagem e turbulência individualmente medidas até então. O procedimento foi o mesmo em cada grupo de ativos. Nos casos de previsão de cauda, anotou-se o percentil da distribuição histórica dos retornos do ativo objeto referente ao retorno do dia seguinte, para o qual valia a previsão. Novamente, se abaixo do $P10$ ou acima do $P90$ a previsão seria certa. Com isso, para cada grupo, tivemos um histórico de previsões de

cauda com acoplagem e turbulência com o respectivo percentil que o ativo objeto de estudo apresentou de fato.

Por fim, fizemos um filtro (aqui no sentido de uma regra que só contabiliza dias em que há previsão de evento de cauda para o dia seguinte) usando EWMA e acoplagem/turbulência em conjunto. Assim, só consideramos as previsões de evento de cauda dos dias em que ambas as métricas previram evento de cauda para o dia seguinte.

Deste modo agora tínhamos quatro históricos, por par grupo/ativo objeto: um com o comportamento do ativo objeto segundo os percentis em que cada retorno se encaixou, um com os percentis ocorridos nos dias para os quais o EWMA previu evento de cauda, um com os percentis ocorridos nos dias para os quais a métrica de acoplagem/turbulência previu evento de cauda e, finalmente, um com os percentis ocorridos nos dias para os quais ambas as métricas (EWMA e acoplagem/turbulência) previram evento de cauda. A expectativa antes de fazer a verificação era a de que quanto melhor fosse o filtro, mais nas caudas iria se concentrar a distribuição destes eventos (percentil do retorno do ativo objeto nos dias em que houve previsão de evento de cauda).

A expectativa de distribuição dos eventos sem filtro é que se aproximaria de uma uniforme, podendo sofrer alguma deformação em função da condicionalidade dos eventos. A metodologia foi verificar, a cada dia, o percentil até então em que se encaixou o último retorno da série. Assim, os percentis não são sempre em relação ao mesmo todo, que faria que a expectativa fosse uniforme.

As figuras A.114, A.115, A.116, A.117, A.118, A.119, A.120, A.121, A.122, A.123, A.124, A.124 são o resultado deste estudo. Nestas fizemos o histograma relativo de cada um dos grupos. As faixas variam em percentis de 5% em 5%. Em cada uma destas estão contabilizados, por total de eventos que passou no filtro, quantos se enquadraram no respectivo percentil. A

faixa 0,05 por exemplo, contém os eventos que ficaram do percentil 0 exclusive ao percentil 5% inclusive. No percentil 0 estão apenas os eventos que ficaram no percentil 0% inclusive. Note que há mais de um evento pois a cada dia acrescentamos novos dados na distribuição.

Analisando as figuras para o dólar, percebe-se em todos os grupos que a distribuição azul, sem filtro, foi razoavelmente uniforme. O filtro ideal concentraria todos os eventos nas caudas (acima do $P95$ e abaixo do $P10$) no gráfico, não ficando nenhum evento nos percentis intermediários. Nota-se, apenas por inspeção visual das figuras, que em todos os grupos, neste sentido, o EWMA teve um resultado superior ao filtro de acoplagem/turbulência. Os grupos de CDSs soberanos, *commodities* e índices de bolsa foram os que conseguiram prever melhor os eventos de cauda, vistos os picos maiores nestes. Por fim, fica claro que o filtro com ambos os métodos em conjunto teve um resultado superior a todos os outros, pode-se dizer em todos os grupos de ativos.

Analisando as figuras para o Ibovespa, novamente o filtro com ambas as métricas atuando em conjunto apresenta a melhor performance. Simples inspeção visual indica uma melhor performance, ainda que leve, do filtro de acoplagem/turbulência ante o filtro EWMA. Aqui o poder de previsão de caudas do Ibov é notadamente superior com os grupos de CDSs de bancos e CDSs soberanos.

Quantificando a Performance dos Filtros

Afim de quantificar a performance de cada um destes filtros propusemos uma medida. Esta consiste em utilizar uma função qualquer que dá mais peso aos eventos nas caudas e menos aos eventos no centro da distribuição. Esta função pode ser linear, quadrática entre outras. Escolhemos a função $f(x) = \text{abs}(x - 1/2)$, ou seja, damos peso aos eventos igual à distância deles ao centro da distribuição. Assim criamos um índice de excentricidade da distribuição:

$$EC = \int_0^{1/2} y * f(x) * dx + \int_{1/2}^1 y * f(x) * dx \quad (4.1)$$

sendo y o número de eventos contabilizados no percentil x da distribuição e $f(x)$ é o valor da função peso no ponto. Aplicando esta medida aos resultados obtidos chegamos aos valores mostrados na Tabela B.

Percebemos, para os casos do Dólar, que o filtro de acoplagem e turbulência é, em todos os casos, pior que o EWMA no critério de separação de eventos de cauda. Já para o caso do Ibovespa, por vezes o filtro de acoplagem/turbulência separa melhor que o EWMA. Mas, em todos os casos, o uso do filtro EWMA em conjunto com o filtro de acoplagem/turbulência melhora a separação dos eventos de cauda, mostrando que, de fato, esta métrica tem valor a adicionar ao EWMA.

Capítulo 5

Conclusões e Sugestões

O objetivo deste trabalho foi estudar uma nova forma de mensurar o risco de catástrofes financeiras. Em especial, buscamos compará-la com uma forma clássica e bem aceita de mensurar risco do mercado financeiro, o modelo EWMA de volatilidade. Baseados no trabalho de Kritzman [1] ao qual introduzimos algumas modificações, avaliamos as séries temporais de turbulência financeira e grau de acoplagem para diferentes grupos de ativos, buscando prever, em certo sentido, eventos de cauda nas séries de retorno do dólar cotado em reais e do índice Ibovespa.

Para estes fins, na fase de tratamento de dados, introduzimos um modo de interpolar séries temporais que leva em consideração a correlação entre as mesmas. A análise foi feita por meio de mapas de intensidade e de um "filtro" por nós introduzido que busca avaliar, percentualmente, quantos eventos de uma dada série temporal se adequam a uma dada restrição. Introduzimos uma medida simples, não idêntica mas de objetivo similar ao conhecido AR (*Accuracy Ratio*) [20] para avaliar quão eficientes foram estes filtros.

Os mapas de intensidade mostraram que, em geral, há relação entre os níveis de acoplagem e turbulência e a ocorrência de eventos de cauda. Em especial, na maior parte das vezes em que ocorreram eventos de cauda tanto no dólar quanto no Ibovespa, os níveis de acoplagem e turbulência estavam elevados. Há algumas particularidades dentro de cada grupo estudado bem como de cada ativo objeto de estudo, mas essa é uma conclusão geral. Usando estes

mapas para verificar o comportamento comparativo ao EWMA, percebemos novamente, de modo geral exceto pelo grupo de *commodities*, que os eventos de cauda tendem a se concentrar em faixas de alta turbulência e acoplagem, e, assim, são as regiões em que o EWMA tende a concentrar suas previsões mais subestimadas bem como as superestimadas. A partir dos mapas, todavia, não pudemos inferir se o EWMA era comparativamente melhor ou pior que a nova métrica (acoplagem/turbulência). Apenas verificamos, quando o EWMA não foi preciso, que níveis de acoplagem e turbulência tínhamos. Ressaltamos que, inferir que a partir dos mapas, a nova métrica é “boa”, seria leviano pois a maior concentração de “erros” do EWMA em uma região de acoplagem/turbulência alta não implica que quando estivermos em regiões de acoplagem/turbulência alta teremos eventos de cauda nem que o EWMA vá “errar”.

Finalmente, com o intuito de avaliar de uma forma mais palpável e quantitativa (importante do ponto de vista de finanças) quem tem melhor capacidade preditiva e, se a nova métrica tem valor no sentido de acrescentar informação, propusemos a análise com filtros. Inicialmente, fizemos uma contabilização percentual de quantos eventos ocorreram em cada percentil condicional histórico. A filtragem baseou-se em impor certas restrições à contabilização de eventos. Em seguida, investigou-se quantos eventos ocorreram em cada percentil com ou sem restrições e, através de uma medida proposta, avaliamos quantos eventos de caudas adicionais foram contabilizados em relação ao total de eventos. Nossa conclusão foi a de que o EWMA é individualmente melhor que a métrica de acoplagem/turbulência, porém o EWMA associado à métrica de acoplagem/turbulência é melhor que o EWMA individualmente.

Referências Bibliográficas

- [1] KRITZMAN, M.;LI, Y. **Skulls, Financial Turbulence,and Risk Management**, Financial Analysts Journal, Volume 66, Número 5, 2010
- [2] STOCK, J. H.; WATSON, M. W. **Macroeconomic Forecasting Using Diffusion Indexes**, Journal of Business and Economic Statistics,Vol. 20, No. 2, Abril 2002
- [3] BAI, J.;NG,S. **Determining the Number of Factors in Approximate Factor Models**, Econometrica, Volume 70, Número 1, Janeiro 2002
- [4] MAHALANOBIS, P.C. **On the Generalized Distance in Statistics**, Proceedings of the National Institute of Sciences of India, Volume 2, Número 1, Abril 1936
- [5] ROUAH, F.D.; VAINBERG, M. **Option pricing models and volatility using Excel-VBA**, Wiley finance series, 2007
- [6] MUSIAL,J.P.;VERSTRAETE,M.M.; GOBRON, N.**Comparing the effectiveness of recent algorithms to fill and smooth incomplete and noisy time series**,Atmospheric Chemistry and Physics Discussions,2011
- [7] LITTERMAN,R.;SCHEINKMAN, J. **Common Factors Affecting Bond Returns**, The Journal of Fixed Income ,1991
- [8] KING, G.; HONAKER, J.; JOSEPH, A. et al **Analyzing Incomplete Political Science Data: An Alternative Algorithm for Multiple Imputation**,American Political Science Review Vol. 95, No. 1, Março 2001
- [9] HONAKER, J.;KING, G. **What to Do about Missing Values in Time-Series Cross-Section Data**, American Journal of Political Science, Vol. 54, No. 2, April 2010, Pp. 561-581

- [10] FARES,C. **Estimation et Prévion de la Volatilité de L'Indice SP 500**, Université du Québec à Montréal, Maio 2008
- [11] RYAN, K.;GILES,D., **Testing for Unit Roots in Economic Time-Series with Missing Observations**, Department of Economics, Univertsity of Victoria, review Março 1998
- [12] FILHO,A. et al **Manual de Economia**,Saraiva, São Paulo, 1996
- [13] KRITZMAN,M.;LI,Y.;PAGE, S. et al **Principal Components as a Measure of Systemic Risk**,MIT Sloan School Working Paper 4785-10, Junho 2010
- [14] ALEXANDER, C.; **Modelos de Mercados: Um guia para Análise de Informações Financeiras**,São Paulo, Bolsa de Mercadorias e Futuros, 2005
- [15] ANG, A.; BEKAERT G. ; **International Asset Allocation with Regime Shifts**, Review of Financial Studies, vol. 15, no. 4,2002
- [16] GONZÁLEZ-HERMOSILLO, B.;HESSE, H.; **Global Market Conditions and Systemic Risk**, IMF Working Paper, WP/09/230
- [17] DAS, S.; UPPAL, R.; **Systemic Risk and International Portfolio Choice**, THE JOURNAL OF FINANCE, VOL. LIX, NO. 6, Dezembro/2004
- [18] LOS, A.; **Financial Market Risk**, Routledge, 2003
- [19] WU,L. et al; **Learning Bregman Distance Functions and Its Application for Semi-Supervised Clustering**, IEE Transactions on Data on Knowledge and Data Engineering, Março / 2012
- [20] KRAFT,H.; KROISANDT,G.; MÜLLER,M.; **Assessing the Discriminatory Power of Credit Scores**,German Finance Association, Agosto / 2002
- [21] REZENDA,V. **O Método de Galerkin**,Departamento de Matemática da Universidade Estadual de Maringá, 2005
- [22] STRANG,G. **Álgebra Linear e suas Aplicações**,Cengage Learning, 2010
- [23] MEUCCI,A. **Risk and Asset Allocation**,Springer, 2007

- [24] RUBIN, E.: **Quantitative commentary on Thucydides**, The American Statistician, Dezembro, 1971

Apêndice A

Figuras




Figura A.1: Comportamento das séries de acoplagem e turbulência para o grupo de CDSs Soberanos




Figura A.2: Comportamento das séries de acoplagem e turbulência para o grupo de Commodities




Figura A.3: Comportamento das séries de acoplagem e turbulência para o grupo de Moedas




Figura A.4: Comportamento das séries de acoplagem e turbulência para o grupo de Índices




Figura A.5: Comportamento das séries de acoplagem e turbulência para o grupo Todos




Figura A.6: ibov CDSs Bancos - eventos de cauda




Figura A.7: ibov CDSs Bancos - eventos de queda forte




Figura A.8: ibov CDSs Bancos - eventos de subida forte




Figura A.9: ibov CDSs Bancos - ewma - desvio maior que o previsto




Figura A.10: ibov CDSs Bancos - ewma - desvio menor que o previsto




Figura A.11: ibov CDSs Bancos - ewma não previu cauda e acertou




Figura A.12: ibov CDSs Bancos - ewma nao previu cauda e erro




Figura A.13: ibov CDSs Bancos - ewma previu cauda e acertou




Figura A.14: ibov CDSs Bancos - ewma previu cauda e erro




Figura A.15: ibov CDSs Soberanos - eventos de cauda




Figura A.16: ibov CDSs Soberanos - eventos de queda forte




Figura A.17: ibov CDSs Soberanos - eventos de subida forte




Figura A.18: ibov CDSs Soberanos - ewma - desvio maior que o previsto




Figura A.19: ibov CDSs Soberanos - ewma - desvio menor que o previsto




Figura A.20: ibov CDSs Soberanos - ewma não previu cauda e acertou

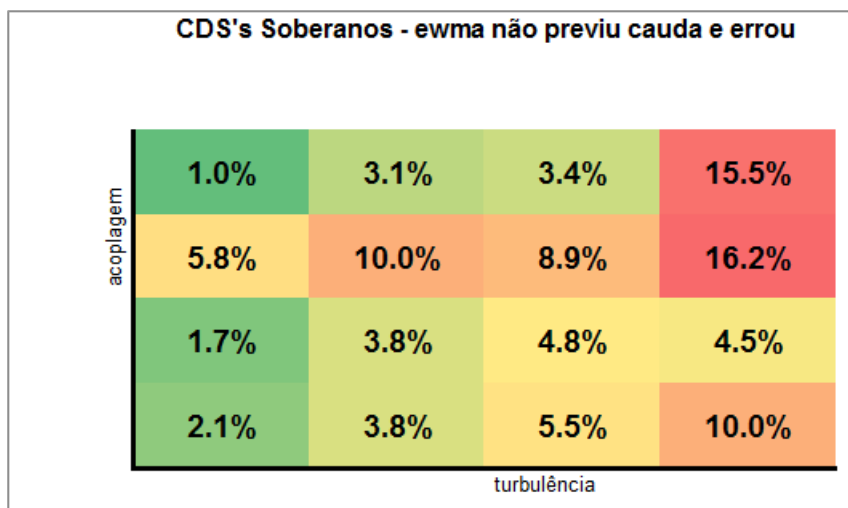


Figura A.21: ibov CDSs Soberanos - ewma não previu cauda e errou




Figura A.22: ibov CDSs Soberanos - ewma previu cauda e acertou




Figura A.23: ibov CDSs Soberanos - ewma previu cauda e errou




Figura A.24: ibov Commodities - eventos de cauda




Figura A.25: ibov Commodities - eventos de queda forte




Figura A.26: ibov Commodities - eventos de subida forte




Figura A.27: ibov Commodities - ewma - desvio maior que o previsto




Figura A.28: ibov Commodities - ewma - desvio menor que o previsto




Figura A.29: ibov Commodities - ewma não previu cauda e acertou




Figura A.30: ibov Commodities - ewma não previu cauda e errou




Figura A.31: ibov Commodities - ewma previu cauda e acertou




Figura A.32: ibov Commodities - ewma previu cauda e errou




Figura A.33: ibov Índices - eventos de cauda




Figura A.34: ibov Índices - eventos de queda forte




Figura A.35: ibov Índices - eventos de subida forte




Figura A.36: ibov Índices - ewma - desvio maior que o previsto




Figura A.37: ibov Índices - ewma - desvio menor que o previsto




Figura A.38: ibov Índices - ewma não previu cauda e acertou




Figura A.39: ibov Índices - ewma não previu cauda e errou




Figura A.40: ibov Índices - ewma previu cauda e acertou




Figura A.41: ibov Índices - ewma previu cauda e erro




Figura A.42: ibov Moedas - eventos de cauda




Figura A.43: ibov Moedas - eventos de queda forte




Figura A.44: ibov Moedas - eventos de subida forte




Figura A.45: ibov Moedas - ewma - desvio maior que o previsto




Figura A.46: ibov Moedas - ewma - desvio menor que o previsto




Figura A.47: ibov Moedas - ewma nao previu cauda e acertou




Figura A.48: ibov Moedas - ewma nao previu cauda e errou




Figura A.49: ibov Moedas - ewma previu cauda e acertou




Figura A.50: ibov Moedas - ewma previu cauda e erro




Figura A.51: ibov Todos - eventos de cauda




Figura A.52: ibov Todos - eventos de queda forte

Todos - eventos de subida forte

acoplagem	0.0%	0.0%	0.0%	52.9%
	0.0%	0.0%	5.9%	5.9%
	5.9%	5.9%	0.0%	0.0%
	5.9%	5.9%	11.8%	0.0%
	turbulência			

Figura A.53: ibov Todos - eventos de subida forte

Todos - ewma - desvio maior que o previsto

acoplagem	5.0%	5.3%	8.7%	20.2%
	0.6%	2.4%	3.1%	3.6%
	1.7%	2.1%	3.6%	3.6%
	4.0%	9.6%	10.7%	15.8%
	turbulência			

Figura A.54: ibov Todos - ewma - desvio maior que o previsto

Todos - ewma - desvio menor que o previsto

acoplagem	8.4%	6.8%	8.5%	17.8%
	1.5%	2.0%	2.5%	3.0%
	2.4%	3.0%	2.9%	3.7%
	6.2%	7.9%	10.9%	12.4%
	turbulência			

Figura A.55: ibov Todos - ewma - desvio menor que o previsto

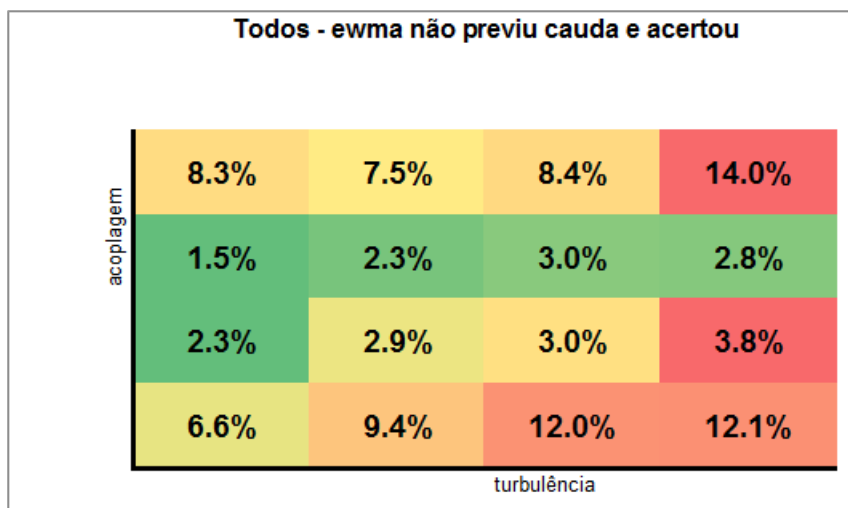


Figura A.56: ibov Todos - ewma nao previu cauda e acertou




Figura A.57: ibov Todos - ewma nao previu cauda e errou




Figura A.58: ibov Todos - ewma previu cauda e acertou




Figura A.59: ibov Todos - ewma previu cauda e erro




Figura A.60: brl CDSs Bancos - eventos de cauda




Figura A.61: brl CDSs Bancos - eventos de queda forte




Figura A.62: brl CDSs Bancos - eventos de subida forte




Figura A.63: brl CDSs Bancos - ewma - desvio maior que o previsto




Figura A.64: brl CDSs Bancos - ewma - desvio menor que o previsto




Figura A.65: brl CDSs Bancos - ewma não previu cauda e acertou




Figura A.66: brl CDSs Bancos - ewma não previu cauda e errou




Figura A.67: brl CDSs Bancos - ewma previu cauda e acertou




Figura A.68: brl CDSs Bancos - ewma previu cauda e erro




Figura A.69: brl CDSs Soberanos - eventos de cauda




Figura A.70: brl CDSs Soberanos - eventos de queda forte




Figura A.71: brl CDSs Soberanos - eventos de subida forte




Figura A.72: brl CDSs Soberanos - ewma - desvio maior que o previsto




Figura A.73: brl CDSs Soberanos - ewma - desvio menor que o previsto




Figura A.74: brl CDSs Soberanos - ewma não previu cauda e acertou




Figura A.75: brl CDSs Soberanos - ewma não previu cauda e errou




Figura A.76: brl CDSs Soberanos - ewma previu cauda e acertou




Figura A.77: brl CDSs Soberanos - ewma previu cauda e erro




Figura A.78: brl Commodities - eventos de cauda




Figura A.79: brl Commodities - eventos de queda forte




Figura A.80: brl Commodities - eventos de subida forte




Figura A.81: brl Commodities - ewma - desvio maior que o previsto




Figura A.82: brl Commodities - ewma - desvio menor que o previsto




Figura A.83: brl Commodities - ewma nao previu cauda e acertou




Figura A.84: brl Commodities - ewma nao previu cauda e errou




Figura A.85: brl Commodities - ewma previu cauda e acertou




Figura A.86: brl Commodities - ewma previu cauda e erro




Figura A.87: brl Índices - eventos de cauda




Figura A.88: brl Índices - eventos de queda forte




Figura A.89: brl Índices - eventos de subida forte




Figura A.90: brl Índices - ewma - desvio maior que o previsto




Figura A.91: brl Índices - ewma - desvio menor que o previsto




Figura A.92: brl Indices - ewma nao previu cauda e acertou




Figura A.93: brl Indices - ewma nao previu cauda e errou




Figura A.94: brl Indices - ewma previu cauda e acertou




Figura A.95: brl Índices - ewma previu cauda e erro




Figura A.96: brl Moedas - eventos de cauda




Figura A.97: brl Moedas - eventos de queda forte




Figura A.98: brl Moedas - eventos de subida forte




Figura A.99: brl Moedas - ewma - desvio maior que o previsto




Figura A.100: brl Moedas - ewma - desvio menor que o previsto




Figura A.101: brl Moedas - ewma não previu cauda e acertou




Figura A.102: brl Moedas - ewma não previu cauda e errou




Figura A.103: brl Moedas - ewma previu cauda e acertou

Moedas - ewma previu cauda e erro

acoplagem	19.0%	12.7%	14.9%	8.6%
	6.3%	8.6%	10.0%	8.6%
	0.9%	0.9%	1.8%	4.5%
	0.5%	0.5%	0.5%	1.8%
	turbulência			

Figura A.104: brl Moedas - ewma previu cauda e erro

Todos - eventos de cauda

acoplagem	1.1%	6.5%	3.3%	45.7%
	2.2%	3.3%	2.2%	4.3%
	1.1%	8.7%	3.3%	3.3%
	1.1%	2.2%	2.2%	9.8%
	turbulência			

Figura A.105: brl Todos - eventos de cauda

Todos - eventos de queda forte

acoplagem	0.0%	5.6%	2.8%	41.7%
	5.6%	0.0%	5.6%	2.8%
	0.0%	11.1%	2.8%	5.6%
	2.8%	0.0%	2.8%	11.1%
	turbulência			

Figura A.106: brl Todos - eventos de queda forte

Todos - eventos de subida forte

acoplagem	1.8%	7.1%	3.6%	48.2%
	0.0%	5.4%	0.0%	5.4%
	1.8%	7.1%	3.6%	1.8%
	0.0%	3.6%	1.8%	8.9%
	turbulência			

Figura A.107: brl Todos - eventos de subida forte

Todos - ewma - desvio maior que o previsto

acoplagem	6.1%	5.9%	8.4%	21.0%
	0.8%	1.8%	3.0%	3.8%
	1.6%	2.3%	3.4%	4.3%
	4.3%	6.9%	10.3%	16.1%
	turbulência			

Figura A.108: brl Todos - ewma - desvio maior que o previsto

Todos - ewma - desvio menor que o previsto

acoplagem	7.9%	6.5%	8.6%	17.5%
	1.4%	2.3%	2.6%	2.9%
	2.4%	2.9%	2.9%	3.4%
	6.1%	9.1%	11.0%	12.3%
	turbulência			

Figura A.109: brl Todos - ewma - desvio menor que o previsto

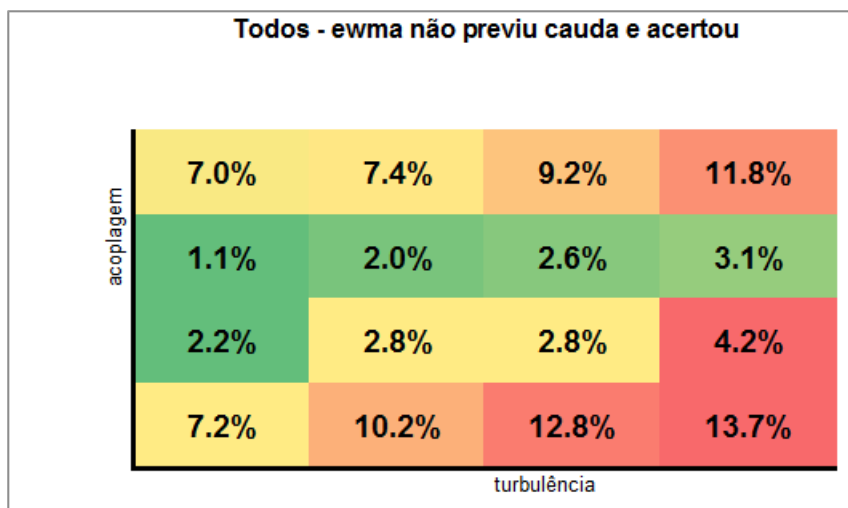


Figura A.110: brl Todos - ewma não previu cauda e acertou

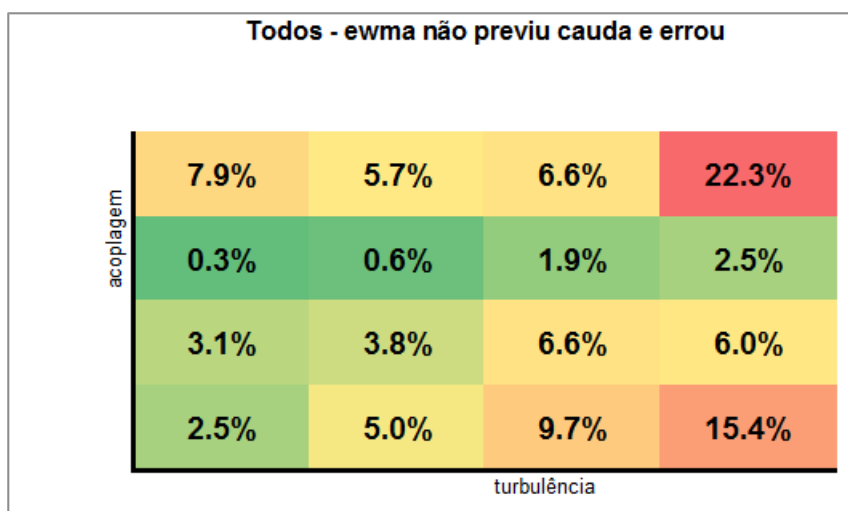


Figura A.111: brl Todos - ewma não previu cauda e errou




Figura A.112: brl Todos - ewma previu cauda e acertou




Figura A.113: brl Todos - ewma previu cauda e errou




Figura A.114: brl Distribuição Filtros CDS Bancos




Figura A.115: brl Distribuição Filtros CDS Soberanos

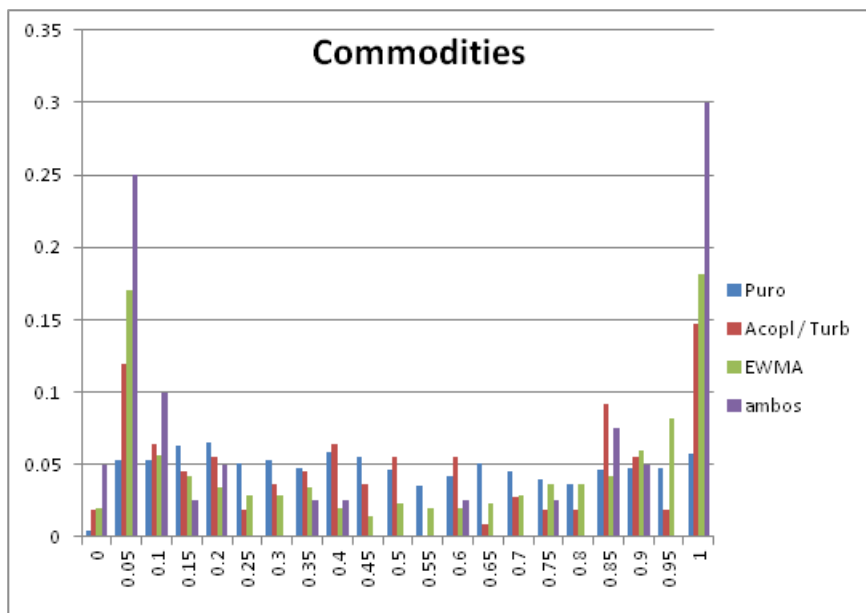


Figura A.116: brl Distribuição Filtros Commodities




Figura A.117: brl Distribuição Filtros Indices




Figura A.118: brl Distribuição Filtros Indices




Figura A.119: brl Distribuição Filtros Todos

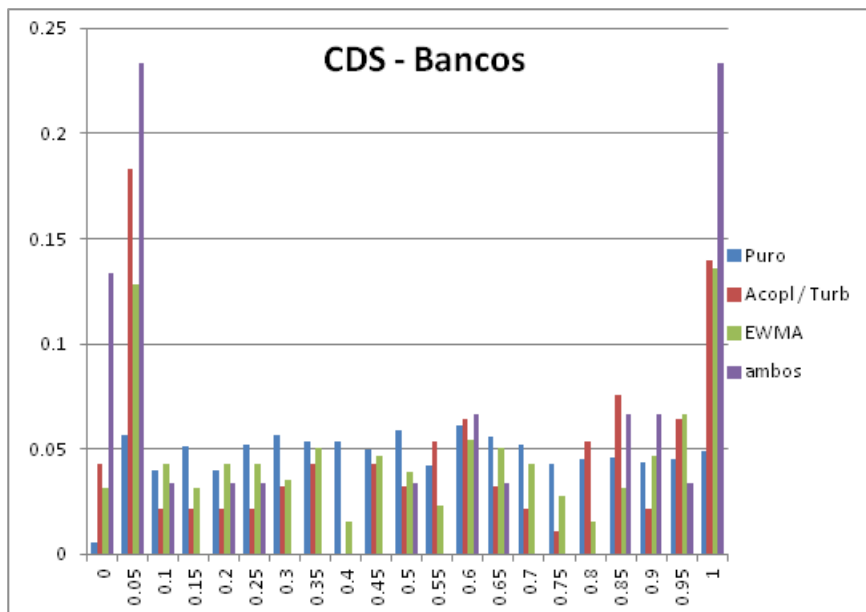


Figura A.120: ibov Distribuição Filtros CDS Bancos




Figura A.121: ibov Distribuição Filtros CDS Soberanos

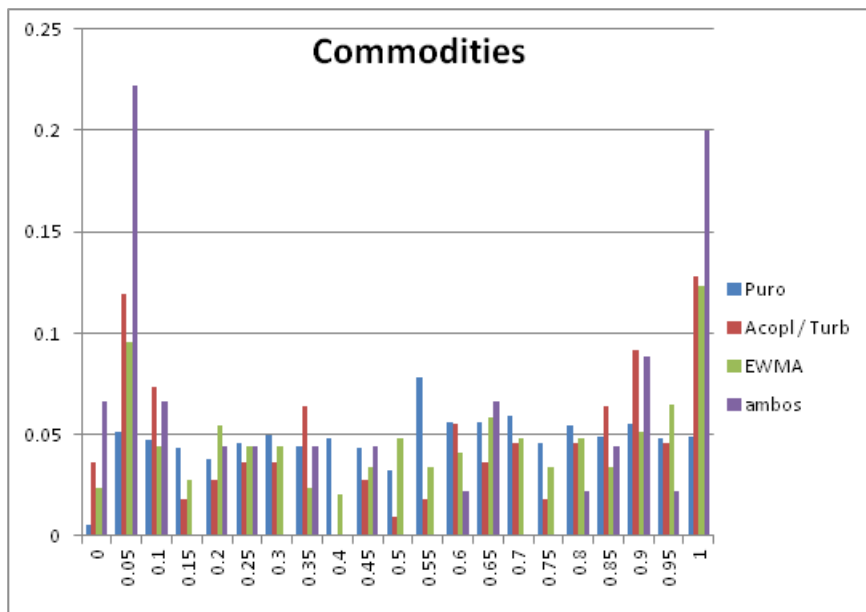


Figura A.122: ibov Distribuição Filtros Commmodities




Figura A.123: ibov Distribuição Filtros Indices




Figura A.124: ibov Distribuição Filtros Indices




Figura A.125: ibov Distribuição Filtros Todos

Apêndice B

Tabelas

Tabela B.1: Ativos Utilizados e Lacunas nas Séries Temporais

Descrição	Grupo / Tipo	Data Inicial	Maior Lacuna	Número de Vezes Maior Lacuna
Mbl Bank (5 Anos)	CDS Bancos	18/08/2003	6	1
Mizuho Bank (5 Anos)	CDS Bancos	11/02/2003	3	2
Intesa Sanpaolo Bank (5 Anos)	CDS Bancos	11/02/2003	4	1
Wells Fargo (5 Anos)	CDS Bancos	28/02/2003	7	2
Cincinnati Bank (5 Anos)	CDS Bancos	11/02/2003	2	3
Hsbc (5 Anos)	CDS Bancos	11/02/2003	2	1
Barclays (5 Anos)	CDS Bancos	11/02/2003	1	5
Le Credit Lyonnais (5 Anos)	CDS Bancos	17/07/2003	2	2
Lloyds (5 Anos)	CDS Bancos	07/11/2003	1	3
Credit Suisse (5 Anos)	CDS Bancos	07/11/2003	1	2
American Express (5 Anos)	CDS Bancos	07/11/2003	7	2
Morgan Stanley (5 Anos)	CDS Bancos	30/04/2008	7	1
Standard Chartered Bank (5 Anos)	CDS Bancos	07/11/2003	2	1
Royal Bank Of Scotland (5 Anos)	CDS Bancos	07/11/2003	1	2
Ing (5 Anos)	CDS Bancos	07/11/2003	1	3
Ubs (5 Anos)	CDS Bancos	07/11/2003	1	3
Unicredit Spa (5 Anos)	CDS Bancos	07/11/2003	1	3
Commerz Bank (5 Anos)	CDS Bancos	07/11/2003	1	4
Sumitomo Mitsui (5 Anos)	CDS Bancos	07/11/2003	3	2
Nomura (5 Anos)	CDS Bancos	07/11/2003	3	2
Bank Of America (5 Anos)	CDS Bancos	07/11/2003	3	1
Jp Morgan (5 Anos)	CDS Bancos	07/11/2003	1	8
Goldman Sachs (5 Anos)	CDS Bancos	07/11/2003	7	1
Bbva (5 Anos)	CDS Bancos	07/11/2003	1	2
Bnp Paribas (5 Anos)	CDS Bancos	07/11/2003	1	3
Santander (5 Anos)	CDS Bancos	07/11/2003	1	3
Societe Generale (5 Anos)	CDS Bancos	07/11/2003	1	3
Deutsche Bank (5 Anos)	CDS Bancos	07/11/2003	0	1

Descrição	Grupo / Tipo	Data Inicial	Maior Lacuna	Número de Vezes Maior Lacuna
Milho	Commodities / Futuro CME	10/01/2000	2	2
Soja	Commodities / Futuro CME	10/01/2000	2	2
Café Arabica	Commodities / Futuro CME	22/09/2000	2	16
Gado	Commodities / Futuro CME	10/01/2000	2	1
Açúcar	Commodities / Futuro CME	10/01/2000	4	1
Cobre	Commodities / Spot	10/01/2000	2	8
Níquel	Commodities / Spot	18/10/2000	4	1
Platina	Commodities / Spot	10/01/2000	2	8
Ouro	Commodities / Spot	10/01/2000	2	8
Prata	Commodities / Spot	10/01/2000	2	8
Porco	Commodities / Futuro CME	10/01/2000	2	1
Petróleo Crú	Commodities / Futuro CME	10/01/2000	2	8
Diesel	Commodities / Futuro CME	10/01/2000	2	11
Petróleo Brent Crú	Commodities / Futuro CME	10/01/2000	2	11
Shanghai	Índice de Bolsa	24/02/2002	7	5
Dow Jones Indus. Avg	Índice de Bolsa	04/01/2000	4	1
Nasdaq Composite Index	Índice de Bolsa	04/01/2000	4	1
México Ipc Index	Índice de Bolsa	04/01/2000	2	7
Brazil Bovespa Index	Índice de Bolsa	04/01/2000	2	15
Ftse 100 Index	Índice de Bolsa	04/01/2000	2	13
Cac 40 Index	Índice de Bolsa	04/01/2000	2	10
Dax Index	Índice de Bolsa	04/01/2000	3	2
Ibex 35 Index	Índice de Bolsa	04/01/2000	3	2
Ftse Mib Index	Índice de Bolsa	04/01/2000	3	2
Nikkei 225	Índice de Bolsa	04/01/2000	4	1
Hang Seng Index	Índice de Bolsa	04/01/2000	3	5
S&P/Asx 200 Index	Índice de Bolsa	04/01/2000	3	1
Sensex	Índice de Bolsa	04/01/2000	2	7
Europa	Moedas Spot	03/01/2000	0	0
Japão	Moedas Spot	03/01/2000	0	0
Inglaterra	Moedas Spot	03/01/2000	0	0
Canada	Moedas Spot	03/01/2000	0	0
Austrália	Moedas Spot	03/01/2000	0	0
Nova Zelândia	Moedas Spot	03/01/2000	0	0
Dinamarca	Moedas Spot	03/01/2000	0	0
Suécia	Moedas Spot	03/01/2000	0	0
Noruega	Moedas Spot	03/01/2000	0	0
África Do Sul	Moedas Spot	03/01/2000	0	0
Brasil	Moedas Spot	03/01/2000	2	1
Suíça	Moedas Spot	03/01/2000	0	0
México	Moedas Spot	03/01/2000	0	0
Nova Zelândia (5 anos)	CDS Soberanos	14/05/2009	1	3
Noruega (5 Anos)	CDS Soberanos	18/02/2009	2	1
Irlanda (5 Anos)	CDS Soberanos	29/01/2009	2	1
Austrália (5 Anos)	CDS Soberanos	22/09/2008	6	1
Finlândia (5 Anos)	CDS Soberanos	26/01/2009	1	2
Holanda (5 Anos)	CDS Soberanos	05/09/2008	3	1
Dinamarca (5 Anos)	CDS Soberanos	27/01/2009	1	2
Reino Unido (5 Anos)	CDS Soberanos	26/01/2009	1	5
Suécia (5 Anos)	CDS Soberanos	22/07/2008	1	5
Vietnam (5 Anos)	CDS Soberanos	28/08/2008	6	1
Indonésia (5 Anos)	CDS Soberanos	03/01/2006	3	1
Argentina (5 Anos)	CDS Soberanos	22/06/2005	1	2
Espanha (5 Anos)	CDS Soberanos	11/06/2004	8	1
Panamá (5 Anos)	CDS Soberanos	03/11/2003	2	2
Peru (5 Anos)	CDS Soberanos	20/10/2003	2	2
Portugal (5 Anos)	CDS Soberanos	01/04/2003	6	2
Bélgica (5 Anos)	CDS Soberanos	24/06/2008	2	1
Alemanha (5 Anos)	CDS Soberanos	24/07/2008	2	1
Itália (5 Anos)	CDS Soberanos	18/03/2003	6	3
Grécia (5 Anos)	CDS Soberanos	18/03/2003	6	1
Chile (5 Anos)	CDS Soberanos	27/01/2003	4	1
Venezuela (5 Anos)	CDS Soberanos	27/01/2003	4	1
China (5 Anos)	CDS Soberanos	24/01/2003	4	2
Colômbia (5 Anos)	CDS Soberanos	24/01/2003	4	1
Jgb (5 Anos)	CDS Soberanos	07/01/2003	6	3
Korea (5 Anos)	CDS Soberanos	04/03/2002	4	1
Malásia (5 Anos)	CDS Soberanos	22/10/2001	9	2
Brasil (5 Anos)	CDS Soberanos	11/10/2001	9	1
México (5 Anos)	CDS Soberanos	11/10/2001	9	1
Polónia (5 Anos)	CDS Soberanos	20/10/2000	2	9
Turquia (5 Anos)	CDS Soberanos	11/10/2000	5	1
Rússia (5 Anos)	CDS Soberanos	11/10/2000	5	1

Tabela B.2: Principais Picos nas Séries de Turbulência

GRUPO	PICO 1	PICO 2	PICO 3
CDSs Bancos	30/07/2008	06/08/2007	17/09/2008
CDSs Soberanos	10/10/2008	23/03/2007	07/11/2002
Commodities	29/07/2010	26/02/2008	23/02/2009
Índices	28/10/2008	10/05/2010	22/01/2008
Moedas	09/10/2008	24/02/2004	06/09/2011
Todos	30/07/2007	16/08/2007	17/09/2008

Tabela B.3: Valores da Medida de Excentricidade Proposta

		Sem Filtro	Acopl/Turb	EWMA	EWMA + Acopl/Turb	Ganho Acopl/Turb	Ganho EWMA	Ganho EWMA+Acopl/Turb
BRL	CDS Bancos	0.01348	0.01762	0.01759	0.01837	0.00414	0.00411	0.00489
BRL	CDS Soberanos	0.01187	0.01818	0.01843	0.01885	0.00631	0.00656	0.00698
BRL	Commodities	0.01298	0.01542	0.01754	0.02056	0.00244	0.00456	0.00758
BRL	Índices de Bolsa	0.01275	0.01485	0.01746	0.01942	0.0021	0.00471	0.00667
BRL	Moedas	0.01279	0.01595	0.0175	0.01887	0.00315	0.0047	0.00608
BRL	Todos	0.01278	0.01646	0.01754	0.0186	0.00367	0.00476	0.00582
IBOV	CDS Bancos	0.01222	0.01569	0.01519	0.0195	0.00347	0.00297	0.00728
IBOV	CDS Soberanos	0.01197	0.01564	0.01541	0.01694	0.00368	0.00344	0.00497
IBOV	Commodities	0.01231	0.01614	0.01469	0.01858	0.00382	0.00238	0.00627
IBOV	Índices de Bolsa	0.01193	0.01311	0.01483	0.01544	0.00118	0.0029	0.00351
IBOV	Moedas	0.01196	0.01412	0.01486	0.01557	0.00216	0.0029	0.00361
IBOV	Todos	0.01193	0.01487	0.01469	0.0169	0.00294	0.00276	0.00497

Apêndice C

Códigos Fonte

```
function principal

[retornos,texto]=xlsread('C:\retornos_cds_soberanos.xls'); %arquivo de input
[m,n]=size(retornos);
dias=texto(2:end,1);
cabecalhos=texto(1,:);
base=199;
inicio=zeros(n,1);
iniciar_cov=zeros(n,1);
for j=1:n
    inicio(j)=primeiro_nao_nulo(retornos(:,j));
end
iniciar_cov=inicio+base;
col_iniciar=[(1:1:n)',iniciar_cov(:,1)]; %coluna 1 começa em tal, 2 em tal etc

ga=zeros(m-base,1);
tf=zeros(m-base,1);
retornos_av=zeros(1,3);
for k=base+1:m
    clearvars matriz
    c=1;
    for col=1:n
```

```
if c==1 && col_iniciar(col,2)<=k
    matriz=retornos(k-base:k,col); %janela fixa
    c=2;
elseif c==2 && col_iniciar(col,2)<=k
    matriz=cat(2,matriz,retornos(k-base:k,col)); %janela fixa
end
end
matriz(isnan(matriz))=0;
[ga(k-base),rets]=grau_acoplagem(matriz,3,0.99);
retornos_av=cat(1,retornos_av,rets');
tf(k-base)=turbulencia_financeira(matriz,0.99);
end

x=texto(base+1:m)';
y=datenum(x,'dd/mm/yyyy');
retornos_av(1,:)=[];

[a,b]=size(retornos_av);

fid=fopen('C:\teste_saida.csv','wt'); %arquivo de saída

for i=1:a
    A(i,1)=x(i);
    for j=1:b
        A(i,1+j)={retornos_av(i,j)};
    end
end

[rows,cols]=size(A)
```

```
for i=1:rows
fprintf(fid,'%s',A{i,1:end-1});
fprintf(fid,'%s\n',A{i,end});
end

fclose(fid);

subplot(2,1,1),plot(y,ga),xlabel('datas');
datetick('x','dd/mm/yyyy');
title('Grau de acoplagem');

subplot(2,1,2),plot(y,tf),xlabel('datas');
datetick('x','dd/mm/yyyy');
title('Turbulencia Financeira');

end

function [resp,retornos_avects]=grau_acoplagem(matriz,n,lambda)
c=matriz;
d=excesso_retorno(c);
e=matriz_covariancia(d,lambda);
variancas=diag(e);
temp=sqrt(variancas)*sqrt(variancas)';
matriz_correl=temp*e;
[Vects,Vals] = eig(e);
[autovalores,indices]=sort(diag(Vals),'descend');
```

```
autovetores=Vects(:,indices(1));
for i=2:n
autovetores=cat(2,autovetores,Vects(:,indices(i)));
end
retornos_avects=(autovetores')*(matriz(end,:))';
numerador=sum(autovalores(1:n)); %somo os n maiores
variancia_ativos=diag(Vals);
denominador=sum(variancia_ativos);
resp=numerador/denominador;
end
```

```
function turb=turbulencia_financeira(b,lambda)
c=b; %estou supondo que a matriz passada é a dos retornos
d=excesso_retorno(c);
e=matriz_covariancia(d,lambda);
turb=d(end,:)*e^(-1)*d(end,:)'
end
```

```
function resp=matriz_retornos(matriz_precos)
[m,n]=size(matriz_precos); %pego o tamanho
r1=zeros(m,n); %pre-aloco
r2=zeros(m,n); %pre-aloco
r3=zeros(m-1,n); %pre-aloco matriz resposta
r1=log(matriz_precos);
r2=log(matriz_precos);
r1(1,:)=[]; %tiro a primeira linha de Ln(A)
```

```
r2(m,:)=[]; %tiro a ultima linha de Ln(A)
```

```
resp=r1-r2; %calculo os retornos
```

```
end
```

```
function resp=excesso_retorno(matriz_retornos)
```

```
[m,n]=size(matriz_retornos); %pego o tamanho
```

```
vetor_medias=mean(matriz_retornos); %vetor linha com as medias por coluna da matriz_retornos
```

```
r2=zeros(m,n); %pre-aloco
```

```
resp=zeros(m,n); %pre-aloco
```

```
r2= repmat(vetor_medias,m,1); %faco uma matriz com a media por coluna em cada elemento da matriz
```

```
resp=matriz_retornos-r2; %calculo os retornos
```

```
end
```

```
function resp=matriz_covariancia(matriz_exc_retornos,lambda)
```

```
[m,n]=size(matriz_exc_retornos); %pego o tamanho
```

```
resp=zeros(m,n); %pre-aloco
```

```
potencias=[m:-1:1]'; %vetor com as potencias às quais vou elevar lambda
```

```
la=lambda.*ones(m,1); %vetor de lambdas
```

```
lamb_pot=la.^potencias; %vetor com as potencias decrescentes de lambda
```

```
lambdas=zeros(m,n); %pre aloco
```

```
lambdas=repmat(lamb_pot,1,n);
```

```
resp=((1-lambdas).*matriz_exc_retornos)'*(lambdas.*matriz_exc_retornos);
```

```
end
```

```
function num=primeiro_ao_nulo(vetor)
```

```
[m,n]=size(vetor);
```

```
k=1;
```

```
while isempty(vetor(k,1)) || isnan(vetor(k,1))
```

```
k=k+1;
```

```
end
```

```
num=k;
```

```
end
```