



UNIVERSIDADE EDUARDO MONDLANE

Faculdade de Ciências

Departamento de Matemática e Informática

Trabalho de Licenciatura em Estatística

**Análise da Relação Entre a Taxa de Juro Facilidade
Permanente de Cedência e a Taxa de Juro Activa em
Moçambique**

Autor: José Raimundo Ernesto Mondlane

Maputo, Outubro de 2015



UNIVERSIDADE EDUARDO MONDLANE

Faculdade de Ciências

Departamento de Matemática e Informática

Trabalho de Licenciatura em Estatística

**Análise da Relação Entre a Taxa de Juro Facilidade
Permanente de Cedência e a Taxa de Juro Activa em
Moçambique**

Autor: José Raimundo Ernesto Mondlane

Supervisor: Dr. Elísio Joaquim José Mabasso

Maputo, Outubro de 2015

Agradecimentos

Agradeço em primeiro lugar a Deus pela força e por iluminar sempre os meus caminhos, por me dar muita saúde, fé, coragem e acima de tudo muito amor, o qual se transformou em muitas alegrias perante os meus colegas durante o curso.

A todos os docentes do Departamento de Matemática e Informática pelo apoio, paciência, em especial ao professor Elísio Joaquim José Mabasso, por me ter orientado no trabalho, tendo demonstrado muita amizade, atenção e acima de tudo muita disponibilidade em ajudar.

Aos meus pais, Ernesto Mondlane e Latia Mandlate por terem sempre criado condições para prosseguir com a minha vida estudantil, onde quer que esteja meu pai, sei que tem olhado por mim pois sempre sinto o seu apoio, sua força e muito incentivo.

Aos meus familiares que por vezes pouco convivíamos por estar a estudar, mas sempre me entenderam e apoiaram.

Ao meu irmão Mateus Mondlane e meu amigo Sílvio Langa que se transformaram em meus segundo pai, pela atenção, apoio e incentivo.

À minha Esposa Isaura Macome por ter sempre acreditado em mim, tendo depositado muito apoio e por ser sempre a minha eterna companheira.

Aos meus inesquecíveis colegas do curso pelo apoio, paciência e pelas longas horas de estudo que tivemos, levarei- vos sempre no coração onde estiver.

A todos aquele que directa ou indirectamente contribui para a minha educação e formação.

DECLARAÇÃO DE HONRA

Declaro por minha honra, que o presente trabalho é resultado da minha própria investigação e das orientações do meu supervisor, e que não foi submetido para outro grau que não seja o indicado - **Licenciatura em Estatística**, da Universidade Eduardo Mondlane.

Autor

(José Raimundo Ernesto Mondlane)

RESUMO

O presente trabalho analisa a relação entre as Taxas de Juros Facilidade Permanente de Cedência e Activa em Moçambique no período de Março de 2005 até Outubro de 2012, para tal usou-se o Modelo Vectorial de Correção de Erros, por tratar-se de séries integradas de ordem 1, isto é, as séries foram diferenciadas uma vez para tornarem-se estacionárias. Verificou-se a existência de uma relação de equilíbrio de longo prazo entre as séries. O teste de Causalidade de Granger mostrou existência de uma relação de causalidade bidireccional entre as duas séries e mostrou também que a Taxa de Juro Activa é a variável mais exógena, isto é, não é explicada pela Taxa de Juro Facilidade Permanente de Cedência. A análise da Função Resposta-Impulso mostrou que as variações na Taxa de Juro Activa são significativamente influenciadas pelas variações na Taxa de Juros Facilidade Permanente de Cedência. A Função de Decomposição de Variância de Erro de Previsão mostrou uma influência positiva da Taxa Facilidade Permanente de Cedência na Taxa de Juros Activa.

Palavras-chave: Facilidade Permanente de Cedência, Taxa de Juro Activa, Modelo Vectorial de Correção de Erros, Resposta-Impulso, Decomposição de Variância.

Índice	Página
I INTRODUÇÃO	1
1.2 Objectivos	2
1.2.1 Gerais	2
1.2.2 Específicos	3
II REVISÃO DE LITERATURA.....	4
2.1 O Conceito de Série Temporal	4
2.2. Importância das Séries Temporais Económicas.....	5
2.3 Processos Estocásticos	6
2.3.1 Processos Estocásticos Estacionários	7
2.3.2 Processos Não Estacionários	9
2.3.3 Processos Estocásticos de Tendência Estacionária e Processos Estacionários em Diferenças	10
2.3.4 Processos Integrados	12
2.3.5 Fenómeno de Regressão Espúria	12
2.4 Estacionaridade	12
2.4.1 Análise Gráfica	12
2.4.2 Raiz Unitária	16
2.5 Modelos Auto-Regressivos	19
2.6 Modelos de Médias Móveis	22

2.7	Modelos Auto-Regressivos Vectoriais	25
2.7.1	Modelo Vectorial de Correção de Erro	29
2.7.2	Co-Integração	30
2.7.3	Causalidade de Granger	37
2.7.4	Número de Desfasagens	38
2.7.5	Análise da Decomposição de Variância	38
2.7.6	Função Resposta-Impulso	39
III	METODOLOGIA	40
3.1	Material	40
3.1.1	Dados Usados	40
3.1.2	Fonte de Dados	40
3.2	Métodos	41
3.2.1	Análise de Dados	41
3.2.2	Teste de Estacionaridade das Séries	41
3.2.3	Normalidade Multivariada	41
3.2.4	Modelo VAR	42
3.2.4.1	Teste de Co-Integração	42
3.2.4.2	Teste de Causalidade de Granger	43
3.2.4.3	Número de Desfasagem no Modelo	45
3.2.4.4	Análise de Decomposição da Variância	45

3.2.4.5 Função de Resposta-Impulso	45
IV ANÁLISE E DISCUSSÃO DE RESULTADOS	47
4.1 Análise Exploratória dos Dados	47
4.2 Teste de Estacionaridade	49
4.3 Modelo VAR	50
4.3.1 Teste Para Escolha de Número de Desfasagens do Modelo	50
4.3.2 Teste de Autocorrelação Serial Residual	51
4.3.3 Teste de Co-Integração	52
4.3.4 Teste de Causalidade de Granger/Exogenidade	53
4.3.5 Função Resposta-Impulso	54
4.3.6 Decomposição de Variância da Taxa de Juros Activa	55
V CONCLUSÕES	57
5.1 Recomendações	58
VI BIBLIOGRAFIA	59
ANEXO	61

Lista de Abreviaturas

BM- Banco de Moçambique

Tjact- Taxa de Juro activa

FPC-Taxa de Juro Facilidade Permanente de Cedência

LM- Multiplicador de Lagrange

PP- Phillips-Perron

KPSS- Kwiatkowski, Phillips, Shimidt e Shin

ADF- Dickey-Fuller Aumentado

VAR- Vector Auto-Regressivo

VEC- Vector de Correção de Erro

AR- Auto-Regressivo

MA- Médias Móveis

ARMA- Auto-Regressivo e de Médias Móveis

PE- Processo Estocástico

AIC- Critério de Informação de Akaike

SBC- Critério Bayesiano de Schwarz

DW- Durbin-Watson

LISTA DE FIGURAS

Figura 4.1a Representação gráfica da série taxa de juro facilidade permanente de cedência	47
Figura 4.1b Representação gráfica da série taxa de juro activa	48
Figura 4.3.5 Resposta-Impulso na taxa de juro activa	55

LISTA DE TABELAS

Tabela 4.1 Estatísticas Descritivas	48
Tabela 4.2 Estatística do teste de Raiz Unitária ADF para as séries	49
Tabela 4.3.1 Teste para escolha do número de defasagens do modelo	50
Tabela 4.3.2 Teste de autocorrelação serial residual baseado no procedimento LM ..	51
Tabela 4.3.3.1 Estatística do Traço	52
Tabela 4.3.3.2 Estatística do máximo Autovalor	52
Tabela 4.3.4.1 Teste de causalidade de Granger	53
Tabela 4.3.4.2 Teste de exogenidade de FPC e TJact	54
Tabela 4.3.6 Decomposição da variância da TJact	56

I INTRODUÇÃO

Segundo Mateus (2006), a taxa de juro é o preço pago pelo empréstimo de dinheiro e desempenha um papel chave na tomada de decisões económicas, já que interfere nos preços e nos custos de todos os sectores da economia.

Existem estreitas relações entre a taxa de juros e as variáveis económicas chaves como: a inflação, o desemprego, a taxa de câmbio, o fluxo de capital e o nível da dívida externa e interna. Um aumento na taxa de juros afecta negativamente o investimento e o consumo e, assim, interfere no crescimento da economia.

Em um país com dívida pública alta (Moçambique tem uma dívida publica em relação ao PIB de 41.7%, assim sendo não se encontra na lista de Países com alta dívida Pública, que chega a alcançar níveis de 226% e 202% para Japão e Zimbabwe respectivamente) o impacto da alta taxa de juros se ligará directamente ao aumento da dívida pública e afectará severamente a capacidade do governo para financiar seus projectos de investimento e cumprimento de seus programas económicos e sociais.

Em uma economia aberta, com mercados mundiais altamente integrados, qualquer mudança na taxa de juros poderia produzir movimentos nos fluxos de capital estrangeiro de importantes volumes que poderiam complicar a condução da política macroeconómica e gerar instabilidade económica.

Segundo o Relatório Anual do Banco de Moçambique (2011), a taxa de juro Facilidade Permanente de Cedência (FPC) é a taxa que o Banco de Moçambique (BM) aplica nas cedências de liquidez aos operadores do mercado que se encontrem com défices temporários de liquidez, por iniciativa destes; é usada pelo Banco de Moçambique para sinalizar a direcção da política monetária em função do desempenho dos indicadores fundamentais da economia. Como o Banco de Moçambique (Banco Central de Moçambique e controlador da política monetária e cambial do País) só concede o crédito a sectores ligados ao sistema financeiro então é possível supor que a variação na taxa de juro facilidade permanente de cedência tem

influência na variação da taxa de juro activa (TJact), que é a taxa que os Bancos Comerciais cobram pelo empréstimo de dinheiro e é designada como activa porque se inscreve nas contas do activo dos Bancos Comerciais.

Segundo o Boletim Estatístico do Banco de Moçambique (BM, 2014), entre Agosto de 2011 e Dezembro de 2014 o Banco de Moçambique reduziu continuamente a Taxa de Juro Facilidade Permanente de Cedência de 16.5% para 7.5%. Esta redução visa incitar a alocação do Financiamento Bancário ao Sector Privado. Todavia, a resposta dos Bancos Comerciais a redução das taxas de referência foi lenta e inferior ao esperado pelas Autoridades Monetárias e outros Agentes Económicos. As Taxas médias mensais Activas dos Bancos Comerciais praticamente só começaram a ser reduzidas a partir de Fevereiro de 2012 e a ritmos mais lentos que as taxas de referência. De cerca de 22,98% em Agosto de 2011, as taxas médias mensais activas passaram para aproximadamente 17,31% em Novembro de 2014.

Devido à influência da taxa de Juro sobre as outras variáveis importantes para a economia e bem-estar social, é necessário analisar o seu comportamento para melhor planeamento e controle de suas variações, principalmente o seu aumento.

1.2 Objectivos

1.1.2.1 Objectivo Geral

Analisar a relação entre a Taxa de Juro Facilidade Permanente de Cedência e a Taxa de Juro Activa em Moçambique no período de Abril de 2005 até Outubro de 2012.

1.2.2 Objectivos específicos:

Verificar a relação entre a Taxa de Juro FPC e a Tjact em Moçambique no período em análise.

Analisar os efeitos de choques exógenos sobre os valores presentes e passados das Taxas de Juros FPC e Tjact.

II REVISÃO DE LITERATURA

Neste capítulo faz-se a abordagem do enquadramento teórico sobre a econometria de séries temporais, que constitui o alicerce para o desenvolvimento do trabalho.

2.1 O Conceito de Série Temporal

Segundo Morettin (2004), uma série temporal é definida como um conjunto de observações de uma variável dispostas sequencialmente no tempo. Conforme o conjunto gerado, pode-se classificar a série em contínua ou discreta.

Diz-se que a série temporal é discreta quando o conjunto de observações no tempo for finito ou infinito enumerável. Caso contrário, isto é, se o conjunto gerado for infinito não enumerável, diz-se que a série é contínua. A grande maioria dos estudos económicos que se valem do tratamento de séries temporais utiliza séries discretas, onde as observações são geradas em um intervalo de tempo com amplitude constante.

De outra parte, uma série temporal pode ser classificada Como determinística ou estocástica. Diz-se determinística quando os valores futuros da série podem ser estabelecidos precisamente por alguma relação funcional matemática do tipo $Y = f(t)$. E diz-se estocástica quando seus valores futuros só puderem ser expostos em termos probabilísticos, uma vez que a série está descrita por meio de uma relação funcional que envolve não só o tempo, mas também uma variável aleatória do tipo $Y = f(t, a)$, onde "a" é o termo aleatório residual, cuja inclusão se torna necessária quando não se consegue explicar completamente algum movimento irregular da série unicamente através da relação matemática.

Segundo Gujarati (2006), os movimentos das séries temporais classificam-se em quatro tipos básicos de variações: a tendência, as variações sazonais, as variações cíclicas e as variações aleatórias.

A tendência, também chamada por alguns autores de tendência secular, é caracterizada como aquele movimento regular e contínuo de longo prazo, reflectindo um movimento ascendente ou descendente em longo período de tempo. De certa forma, pode ser vista como aquela componente que descreve as variações graduais que se mantêm em um longo período de observação da variável no tempo. Estatisticamente, pode-se caracterizá-la pelo facto de que a esperança de Y , $E(Y)$, varia no tempo.

As variações sazonais são aquelas variações periódicas que ocorrem com certa regularidade dentro de um curto período de tempo. Embora o próprio nome dê a entender que esses movimentos ocorrem por um período anual, de acordo com as estações climáticas, esses movimentos podem ser estendidos a qualquer intervalo de curto prazo, como diário, horário, semanal, mensal, trimestral etc.

As variações cíclicas são aquelas variações que referem-se as oscilações de longo prazo que caracterizam, em geral, os ciclos económicos. São as flutuações de longo prazo em torno da curva de tendência.

As variações aleatórias, também chamadas residuais, referem-se não só aqueles movimentos esporádicos ocasionados por eventos aleatórios imprevisíveis, tais como as calamidades naturais, mas também ao conjunto de todos aqueles movimentos da série que não foram possíveis de identificar em seus demais componentes, uma vez que não obedecem a nenhuma lei comportamental capaz de ser descrita de forma determinística, através de relações funcionais exclusivamente matemáticas.

2.2 Importância das Séries Temporais Económicas

Segundo Fischer (1982), a Econometria é o ramo da Ciência Económica que, através da análise estatística da realidade, busca estabelecer proposições económicas, de carácter quantitativo, que possibilitam não só compreender e analisar o comportamento das variáveis sob uma determinada base económica teórica, como também permitir a previsão de seus comportamentos futuros.

Os métodos econométricos utilizam-se de procedimentos estatístico - matemáticos, que com os quais proporcionam ao economista condições de abstrair o funcionamento da realidade económica, buscando sintetizá-la através da formulação de modelos teóricos.

Dentre os instrumentos estatísticos usados em Econometria para o estabelecimento das estimativas das relações funcionais propostas em seus modelos teóricos, podem-se destacar dois grandes grupos: aqueles que procuram estimar relações entre variáveis económicas, seja através de modelos de uma única equação, seja através de modelos mais complexos, como os de múltiplas equações simultâneas; e aqueles que se valem de equações de uma série temporal.

A análise das séries temporais permite que tanto os objectivos de previsão do futuro, baseados nos dados passados, como os de controlar o processo que gera a série, possam ser conhecidos independentemente do comportamento de outras variáveis.

2.3 Processos Estocásticos

Segundo Parzen (1972), o objecto da teoria dos processos estocásticos é o estudo daqueles mecanismos dinâmicos que proporcionam meios de análise de uma sequência de observações, vista conjunta e interdependente em uma sucessão de momentos de tempo, as quais são influenciadas por factores aleatórios. Assim, um processo estocástico deve ser entendido como um modelo que descreve a estrutura probabilística de uma sequência de observações. Formalmente, pode-se definir um processo estocástico como uma família de variáveis aleatórias $\{X(t), t \in T\}$ classificada mediante um parâmetro " t " que varia em um intervalo de tempo T . Portanto um processo estocástico caracteriza-se por ser uma função aleatória de " t ". Uma sequência de observações $X_t, t = 1, 2, 3, 4, \dots, t$, que corresponde à uma amostra de pontos no tempo, é chamada uma realização parcial do processo estocástico.

Ao observar o comportamento de uma série temporal, verifica-se que essa pode ser considerada como uma particular realização de uma sequência de observações produzida por um mecanismo probabilístico. Dessa maneira, uma série temporal pode ser vista como uma realização de um

processo estocástico. Ou seja, uma série temporal $X_1, X_2, X_3, \dots, X_t$, pode ser considerada como uma realização amostral de uma população infinita constituída por uma infinidade de outros possíveis resultados para o conjunto $\{X(t), t \in T\}$, realização que pode ter sido gerada pelo processo.

A análise das séries temporais pressupõe que o conjunto de observações tenha sido gerado por um processo estocástico e, como tal, possua uma estrutura probabilística que possa ser caracterizada e descrita. O estudo das séries temporais proporciona, então, a descrição da natureza aleatória do processo que gerou a amostra de observações em estudo. Sua análise supõe que cada ocorrência $X_1, X_2, X_3, \dots, X_t$, da série seja obtida aleatoriamente com base em uma estrutura probabilística. Consequentemente, a série temporal X_t é uma sequência de variáveis aleatórias conjuntamente distribuídas, pode se dizer que, existe alguma função de probabilidade $P(X_1, X_2, X_3, \dots, X_t)$ que assume valores para todas as possíveis combinações $X_1, X_2, X_3, \dots, X_t$. Assim, o objectivo básico da análise estatística de séries temporais é buscar, a partir da realização amostral do processo, descrever as características de sua aleatoriedade, com efeito de proporcionar os instrumentos para a inferência sobre as probabilidades associadas com o conjunto de valores futuros alternativos da série. Ao se conseguir especificar numericamente como é a função de probabilidade da série, torna-se viável inferir a probabilidade de um ou outro valor futuro ocorrer. Portanto, estudar modelos de séries temporais significa buscar obter meios capazes de inferir as características de seu processo gerador, bem como buscar modelos estocásticos que sejam capazes de descrever as situações particulares que ocorrem na realidade.

2.3.1 Processos Estocásticos Estacionários

Segundo Gujarati (2006), uma importante classe de processos estocásticos é a dos chamados processos estacionários. Antes de se conduzir qualquer análise baseada em dados de séries temporais, é importante analisar se a série é ou não estacionária, para a partir daí estabelecer a estrutura do modelo probabilístico que estimará a série. A razão simples de necessitar de dados estacionários, é

que qualquer modelo que é inferido a partir desses dados pode ser interpretado como estacionário ou estável, fornecendo assim uma base válida para a previsão.

Diz-se que um processo estocástico é estritamente estacionário, com todas as distribuições finitas dimensionais, que permanecem nas mesmas condições sob translação ao longo do tempo quando:

$$F(X_1, \dots, X_n; t_1, \dots, t_n) = F(X_1, \dots, X_n; t_1 + \tau, \dots, t_n + \tau) \quad (1)$$

Para todo $t_1, \dots, t_n, \tau \in \Gamma$ isto é, todas as distribuições unidimensionais não variam ao longo do tempo.

Portanto, a média $\mu_{(t)}$ e a variância $\sigma_{(t)}^2$ são constantes, algebricamente:

$$E\{X_{(t)}\} = \mu_{(t)} = \mu \text{ Para todo } t \in \tau$$

$$Var\{X_{(t)}\} = \sigma_{(t)}^2 = \sigma^2, \text{ Para todo } t \in \tau$$

Um caso particular com todas as distribuições bidimensionais, com dependência apenas do tempo, isto é, t_1 e t_2 ; com $t \in \tau$,

$$\gamma_{(t_1, t_2)} = \gamma_{(t_1+t, t_2+t)} \quad (2)$$

E fazendo $t = -t_2$ temos:

$$\gamma_{(t_1, t_2)} = \gamma_{(t_1-t_2, 0)} = \gamma_{(t_1, t_2)} = Cov\{X_{(t_1-t_2)}; X_{(0)}\} \quad (3)$$

De forma genérica temos (a função de auto-covariância):

$$\gamma_{(t)} = Cov\{X_{(t)}, X_{(t+\tau)}\} = Cov\{X_{(0)}, X_{(t)}\}, \text{ Para } t, \tau \in Z \quad (4)$$

Um processo estocástico $\{X_{(t)}, t \in \tau\}$, é dito fracamente estacionário (ou de segunda ordem), se e somente se:

$$E\{X_{(t)}\} = \mu_{(t)} = \mu \text{ Para todo } t \in \tau;$$

$E\{X_{(t)}^2\} < \infty$, Para todo $t \in \tau$

$\gamma_{(t_1, t_2)} = Cov\{X_{(t_1)}, X_{(t_2)}\}$ é uma função apenas de $|t_1 - t_2|$.

Observa-se que, a média e a sua variância são constantes ao longo do tempo, e que o valor da co-variância entre dois períodos de tempo depende apenas da distância, do intervalo ou da desfasagem entre dois períodos de tempo e, não do próprio tempo em que a co-variância é calculada.

Este tipo de Processos Estacionários, é conhecido na literatura de séries temporais como fracamente estacionária, ou estacionária em co-variância, ou estacionária de segunda ordem ou ainda processo estocástico em sentido amplo.

Um exemplo típico destes processos, são os chamados Processos Puramente Aleatórios, também conhecido como ruído branco (do inglês White Noise ou simplesmente WN). Diz-se que um processo estocástico é puramente aleatório se, a sua média é zero, a variância é constante, e este não exibe uma correlação serial (Gujarati, 2006).

O processo puramente aleatório é aplicado no modelo clássico de regressão linear normal pois, este pressupõe, que o termo do erro $\varepsilon_{(t)} \sim iidn(0, \sigma^2)$, isto é, $\varepsilon_{(t)}$ é identicamente, independente e normalmente distribuído com média igual a zero e a variância constante.

2.3.2 Processos Não Estacionários

Embora o interesse na análise de séries temporais é de que o processo estocástico seja estacionário, a maior parte destas não gozam desta propriedade (de estacionaridade), séries económicas, tais como preços de activos, preços de acções ou taxas de câmbio não são estacionárias. Um Processo não estacionário terá uma média, ou variância que varia ao longo do tempo, ou as duas.

2.3.3 Processos Estocásticos de Tendência Estacionária e Processos Estacionários em Diferenças

Uma série temporal diz-se que é de tendência determinística, quando esta é totalmente previsível ao longo do tempo e de tendência estocástica, quando não é previsível ao longo do tempo.

Seja $\varepsilon_{(t)}$ um termo de erro de ruído branco, com média igual a zero e variância igual a σ^2 .

Diz-se que a série X_t é um passeio aleatório sem deslocamento se:

$$X_t = X_{t-1} + \varepsilon_t \quad (5)$$

No modelo de passeio aleatório sem deslocamento, o valor de X no tempo t é igual ao seu valor no período $t-1$ mais um choque aleatório, portanto, o modelo é representado como um modelo auto-regressivo de ordem 1, ou simplesmente $AR(1)$, isto é, o valor de X é dado como uma relação em função do tempo com o seu valor desfasado em 1 período.

Substituindo os valores de t , tais que: $t = 1, 2, 3, \dots, t$

Onde $t = 0$ representa o início do processo com valor X_0 no período t , na expressão (5), temos:

$$X_t = X_0 + \sum \varepsilon_t \quad (6)$$

O valor esperado e a variância de X_t será dado por:

$$\text{Média: } E(X_t) = E(X_0 + \sum \varepsilon_t) = X_0 ;$$

$$\text{Variância: } Var(X_0) = t\sigma^2 .$$

A média de X_t , é igual ao seu valor inicial X_0 , que é constante, mas a medida que o tempo aumenta a sua variância também aumenta indefinidamente, violando assim a condição de estacionariedade. Uma característica importante neste modelo, é o facto dos choques aleatórios persistirem com o tempo, ou seja, é soma de X_0 mais o somatório dos choques aleatórios. É interessante notar que, quando se escreve a expressão (5) como:

$$X_t - X_{t-1} = \Delta X_t = \varepsilon_t \quad (7)$$

Onde: Δ é o operador de primeiras diferenças, facilmente nota-se que, embora, X_t seja não estacionário, em primeiras diferenças este torna-se estacionário. Daí que, um modelo de passeio aleatório é estacionário em primeiras diferenças.

Modificando a expressão (5) tal que:

$$X_t = \delta + X_{t-1} + \varepsilon_t \quad (8)$$

Neste caso, o PE é conhecido por passeio aleatório com deslocamento, onde, δ é conhecido como o parâmetro de deslocamento (do inglês *drift*), o termo deslocamento, vem pelo facto de escrever-se a expressão em primeiras diferenças como se segue:

$$X_t - X_{t-1} = \Delta X_t = \delta + \varepsilon_t \quad (9)$$

Portanto, X_t desloca-se em função do parâmetro de deslocamento de modo que:

$$E(X_t) = X_0 + t\delta;$$

$$Var(X_t) = t\sigma^2$$

Nota-se, que este também é não estacionário, dado que a média e a variância aumentam com o tempo, violando deste modo a condição de estacionariedade.

2.3.4 Processos Integrados

Diz-se que um processo estocástico é integrado de ordem d , denotado por $X_t \sim I(d)$, quando esta é diferenciada d vezes para que se torne estacionária. Com efeito, se um processo estocástico é estacionário desde o início (não há necessidade de diferenciá-la para que se torne estacionária), diz-se que é integrada de ordem zero, ou seja, $X_t \sim I(0)$.

No que diz respeito à ordem de integração das séries temporais económicas, no geral estas são $I(1)$, isto é, temos que diferenciá-las somente uma vez, para que se tornem estacionários.

2.3.5 Fenómeno de Regressão Espúria

Sejam X_t e Y_t , duas séries $I(1)$, a combinação linear destas gera um outro processo estocástico Z_t também $I(1)$, e portanto Z_t exibe uma tendência estocástica.

Geralmente é possível encontrar um R^2 elevado ($R^2 > 0.9$), e concluir que existe uma relação muito forte entre as variáveis, quando na verdade não existe. Este fenómeno é conhecido por **Regressão Espúria** (ou regressão sem sentido), o qual foi estudado e tratado pela primeira vez por Granger e Newbold (1974).

Um indicador, de presença de regressão espúria é o Durbin-Watson (DW), um valor extremamente baixo ($R^2 > DW$) de DW sugere uma forte auto-correlação de primeira ordem.

2.4 Estacionaridade

2.4.1 Análise Gráfica

Para a verificação da estacionaridade de uma série, um dos métodos preliminares, é a análise gráfica da série e o teste de correlograma. Estes desempenham um papel fundamental para identificar ou especular sobre a estacionaridade ou não de um processo estocástico.

Função de auto- covariância

Seja $\{X_t, t \in Z\}$ um Processo Estocástico real discreto, de médias zero e de auto- covariância:

$$\gamma_t = E\{X_t, X_{t+\tau}\} \quad (10)$$

Satisfazendo as seguintes propriedades:

$$\gamma_0 > 0$$

$$\gamma_{t-\tau} = \gamma_\tau$$

$$|\gamma_\tau| < \gamma_0$$

γ_τ é não negativa, definida no sentido que:

$$\sum_{j=1}^n \sum_{k=1}^n \alpha_j \alpha_k \gamma_{(j-k)} \geq 0, \quad (11)$$

Para quaisquer números reais $\alpha_1, \dots, \alpha_n$ e τ_1, \dots, τ_n de Z .

A função de auto- correlação (FAC) do processo é definida por:

$$\rho_\tau = \frac{\gamma_\tau}{\gamma_0} \quad (12)$$

$\tau \in Z$, a FAC tem as propriedades de γ_τ excepto para $\gamma_0=1$, como a co-variância e a variância são mensuradas nas mesmas unidades de medida, γ_τ é um número sem unidades de medida situa-se entre -1 e 1, ou seja, $-1 \leq \rho_\tau \leq 1$, como qualquer coeficiente de correlação (Gujarati, 2006).

Se substituirmos ρ_τ em função de τ , o gráfico obtido é conhecido como função de auto- correlação populacional. Porque na prática tem-se apenas a realização (ou amostra) de um processo estocástico, pode-se calcular a função de auto- correlação amostral, para tal a co-variância amostral com desfasagem τ e a variância amostral definidas como se segue:

$$\hat{\gamma} = \frac{\sum (X_t - \bar{X})(X_{t-\tau} - \bar{X})}{n} \quad (13)$$

$$\hat{\gamma}_0 = \frac{\sum (X_t - \bar{X})^2}{n} \quad (14)$$

Onde, n é o tamanho da amostra, \bar{X} a média amostral, o gráfico assim obtido é conhecido como correlograma amostral.

O cálculo do auto- correlações e auto- correlações parciais é também usado para a identificação do comportamento da série. Enquanto a função de auto- correlação parcial, ajuda também na identificação do número de defasagens a ser incluídas no processo auto-regressivo, a função de auto- correlação é um indicativo de estacionariedade da série.

Quando a função de auto- correlação tende rapidamente para zero é um indicativo de que a série é estacionária, contrariamente, quando esta decresce muito lentamente, sugere existência de uma raiz unitária.

A FAC tem a propriedade de se atenuar a medida que o número de defasagens aumenta e apresenta comportamentos semelhantes em muitos casos, sendo por isso difícil distinguir entre processos de ordem diferente. Portanto, normalmente é usada a função de auto- correlação parcial, que leva em conta a história do processo até ao defasamento de ordem k correspondente (Meneses, 2007). Esta também permite capturar a extensão temporal e a robustez da memória do processo, ao medir a correlação dos valores actuais do processo, em relação aos seus valores passados (Gujarati, 2006).

Significância Estatística dos Coeficientes de Auto- correlação

Para testar a significância conjunta dos coeficientes de auto- correlação, são utilizados testes de Q de Box definido como:

$$Q = n \sum_{k=1}^m \hat{\rho}_k^2 \quad (15)$$

Onde n é o tamanho da amostra e m o tamanho do número de defasagens.

Um modelo de ruído branco fica caracterizado pela forma padrão das respectivas FAC e FACP ($\hat{\rho}_k = \varphi_{kk} = 0, k \neq 0$), pelo que o comportamento dos resíduos costuma avaliar-se em termos dos respectivos valores estimados destas funções (Gujarati, 2006).

Designando $\hat{\rho}_k u(t)$ e $\varphi_{kk} u(t)$, respectivamente as FAC e FACP estimadas a partir da sucessão dos resíduos, define-se um conjunto de testes estatísticos que permitem avaliar a qualidade de ajustamento.

O teste de Box-Pierce (1970) ou teste “Portmanteau”, testa a seguinte hipótese:

$$H_0: \hat{\rho}_1 u(t) = \hat{\rho}_2 u(t) = \dots = 0$$

Onde no geral se toma $m = N/4$. Na prática compara-se o Q calculado com o Q crítico na distribuição Qui - quadrado ao nível de significância escolhido.

Ljung e Box (1978) recomendaram um teste melhor na estimação de modelos ARIMA (p,d,q), baseado na estatística:

$$LB = n(n-2) \sum_{k=1}^m \frac{1}{n-k} \hat{\rho}^2(u) \quad (16)$$

$n = N - d$, que converge mais rapidamente, para uma distribuição do Qui - quadrado com $m - p - q$ graus de liberdade (por isso torna-se mais conveniente quando o tamanho da amostra não é muito grande).

2.4.2 Raiz Unitária

O processo de verificação de estacionaridade pelos métodos anteriormente descritos, embora sejam ferramentas úteis para o uso, e o último, um método inferencial foram desenvolvidos vários testes de raiz unitária (PP, KPSS, DF, ADF) entre outros, que são os mais recomendados pelos autores, o teste ADF (teste Aumentado de Dickey-Fuller) tornou-se muito popular e de uso prático por muitos investigadores (Gujarati, 2006).

Considere abaixo o modelo de passeio aleatório, também conhecido na literatura, como um exemplo de um processo de raiz unitária:

$$X_t = \rho X_{t-1} + \varepsilon_t, \quad (17)$$

No modelo de passeio aleatório com $-1 \leq \rho \leq 1$,

Se, $\rho = 1$, torna-se um modelo de passeio aleatório (sem deslocamento). O modelo de passeio aleatório é não estacionário, assim sendo, diz-se que exibe uma raiz unitária.

Se, $|\rho| < 1$, isto é, se o valor absoluto ρ é menor que um (1), pode se mostrar que o processo estocástico é estacionário.

Seja, o seguinte modelo auto-regressivo de ordem 1, denotado por AR (1), como segue.

$$X_t = \varphi X_{t-1} + \varepsilon_t, \text{ com } -1 \leq \varphi \leq 1 \quad (18)$$

Onde, ε_t representa o termo de erro ou de ruído branco. Sabe-se que, quando $\varphi = 1$, o modelo torna-se um modelo de passeio aleatório sem deslocamento, e portanto, é não estacionário.

Segue-se:

$$\Delta X_t = \varphi_t^* X_{t-1} + \varepsilon_t \quad (19)$$

No qual, $\varphi^* = \varphi - 1$ e Δ é o operador de primeiras diferenças. De onde se formula a hipótese seguinte:

$H_0: \varphi^* = 0$ (tem raiz unitária);

$H_1: \varphi^* < 0$ (não tem raiz unitária).

Quando $\varphi^* = 0$, então, $\varphi = 1$, isto é, temos uma raiz unitária, o que significa que a série temporal em estudo é não estacionária.

O teste Aumentado de Dickey-Fuller (ADF) é um dos mais preferidos pelos pesquisadores, conhecido como teste de τ (tau), o qual baseia-se na seguinte regressão:

$$\Delta X_t = \theta_0 + \mu_{1t} + \varphi_t^* X_{t-1} + \sum_{k=1}^p \gamma_{t=k} \Delta X_{t-k} + \varepsilon_t \quad (20)$$

Onde: μ_0 é uma constante e o termo μ_{1t} captura a tendência determinística existente nos dados. O número de *lags* (desfasamentos) do modelo escolhido de modo que o termo dos resíduos $\varepsilon_{(t)} \sim iidn(0, \sigma^2)$. Fazendo $\mu_{1t} = \gamma_\tau = 0$, a equação reduz-se ao modelo AR (1), descrito em (18).

O procedimento usual dos testes de ADF consiste na hipótese formulada anteriormente, este testa a existência de uma raiz unitária para a variável em nível (X_t), assim como em primeiras diferenças (ΔX), contra a hipótese alternativa de que esta seja estacionária.

Nos testes propostos por Dickey-Fuller para testar as hipóteses de estacionaridade da série, o primeiro, baseia-se na distribuição limite da estimativa MQO de φ^* , o qual utiliza os teste t tradicional descrito a seguir (Gujarati, 2006).

$$\tau = \frac{\phi MQ - 1}{\left(\frac{S^2}{\sum X^2(t-1)} \right)^{1/2}} \quad (21)$$

Em virtude do teorema a seguir: considera-se o modelo (20), com $X_0 = 0$, onde supõem-se que, $\varepsilon_{(t)} \sim iidn(0, \sigma^2)$. Então:

$$\tau \rightarrow \frac{([W_1]^2 - 1)}{2 \left(\int_0^1 [W_{(r)}]^2 \right)} \quad (22)$$

Onde: $W_{(r)}$ é o movimento Browniano Padrão e sob as mesmas suposições do teorema anterior obtem-se:

$$\tau \rightarrow \frac{([w_1]^2 - 1)}{2 \left(\int_0^1 [w_{(r)}]^2 \right)^{1/2}} \quad (23)$$

Portanto, os teoremas (22) e (23) são chamados testes de Dickey-Fuller, abreviadamente DF. As distribuições das estatísticas correspondentes são tabeladas e se utilizam os valores críticos de Mackinnon (1991, 1996).

Nota que rejeita-se H_0 , se o estimador τ for menor que o valor crítico definido. Embora, o estimador seja dado por:

$$\tau = \frac{\phi MQ}{\hat{ep}(\phi MQ)} \quad (24)$$

Com os denominadores corrigidos, a presença de θ_0 altera a distribuição assintótica da estimativa. Neste caso, a notação padrão a ser utilizada por τ e τ_μ , entende-se que o processo tem média $\mu = \theta_0 / (1 - \phi)$. Portanto, no lugar de utilizarmos as estatísticas (23) e (24), obtem-se:

$$\tau_\mu = \frac{\left[((W_1)^2 - 1) - W_1 \int_0^1 W_r dr \right]}{\sqrt{2 \left[\int_0^1 W_r^2 dr - \left(\int_0^1 W_r dr \right)^2 \right]}} \quad (25)$$

A distribuição de τ_μ afasta-se mais da distribuição normal do que no caso em que a média $\mu = 0$. O teste usando τ_μ é chamado teste de Dickey-Fuller aumentado (“*augmented Dickey-Fuller test*”) e abreviadamente ADF.

Na realidade as estatísticas τ e τ_μ são usadas para testar $H_0: \phi = 0 \mid \theta_0 = 0$. Pode-se testar separadamente $\theta_0 = 0$, mas a estatística t novamente não é apropriada (Morettin, 2004).

2.5. Modelos Auto-Regressivos (AR)

Num modelo Auto-Regressivo, os valores correntes de uma série X_t , dependem apenas de seus valores passados mais um termo de erros aleatórios. Em termos matemáticos, tal modelo denotado por $AR(p)$, tem a seguinte expressão geral:

$$X_t = \alpha_0 + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + \varepsilon_t \quad (26)$$

Onde p indica o número de defasagens de X_t . A forma mais simples da especificação de um processo Auto-Regressivo contém apenas uma defasagem, ou seja $p = 1$.

Os coeficientes α_i , são parâmetros reais e ε_t é termo dos resíduos com distribuição normal de média igual a zero e variância constante $DNII(0; \sigma^2)$.

Seja $E(X_t) = \mu$, então:

$$\mu = E(X_t) = \frac{\alpha_0}{1 - \alpha_1 - \dots - \alpha_p} \quad (27)$$

Condicionado o denominador de modo que este seja diferente de zero (portanto, estacionário), pode-se definir um operador B retroactivo, através do polinómio de $B^s X_t = X_{t-s}$, $s \geq 1$. Então, a equação (26) pode ser escrita, do seguinte modo:

$$\alpha(B) = 1 - \alpha_1 B - \alpha_2 B^2 - \dots - \alpha_p B^p \quad (28)$$

Onde, B é o operador Auto-Regressivo de ordem p , e

Aqui, $\alpha(B) = 1 - \alpha B$. Através de substituições sucessivas obtêm-se:

$$X_t = \sum_{j=0}^r \alpha^j \mu_{t-j} + \alpha^{r+1} X_{t-r-1} \quad (29)$$

Se X_t for estacionário, com variância finita σ_x^2 , segue-se:

$$E[X_t - \sum_{j=0}^r \alpha^j \mu_{t-j}]^2 = \alpha^{2r+2} E[X_{t-r-1}^2] = \alpha^{2r+2} \sigma_x^2 \quad (30)$$

Nota, que $|A| < 1$, $A^2 (r+1) \rightarrow 0$, quando $r \rightarrow \infty$, portanto sob esta suposição, resulta seguinte expressão:

$$X_t = \sum_{j=0}^{\infty} \alpha^j u_{t-j} \quad (31)$$

Onde, a convergência da sucessão é dada em média quadrática. A condição $|\alpha| < 1$ é suficiente para X_t ser estacionário. Multiplicando ambos os membros da equação (31) por $X_{t-\tau}$ e tomando a esperança matemática obtêm-se:

$$\gamma_{\tau} = \alpha \gamma_{\tau-1} = \dots = \alpha^{\tau} \gamma_0 \quad (32)$$

E portanto

$$\gamma_0 = \sigma^2 = \sum_{j=0}^{\infty} \alpha^{2j} = \frac{\sigma^2}{1 - \alpha^2} \quad (33)$$

De onde segue:

$$\gamma_{\tau} = \frac{\sigma^2}{1 - \alpha^2} \alpha^{\tau} \quad (34)$$

Como γ_{τ} simétrica pode-se escrever finalmente a FAC de um processo AR (p) do seguinte modo:

$$\rho_{\tau} = \frac{\gamma_{\tau}}{\gamma_0} \alpha^{|\tau|} \quad (35)$$

Com, $\tau \in \mathbb{Z}$.

Um processo $AR(1)$, X_t e X_{t-2} são correlacionados, mesmo que X_{t-2} não apareça directamente no modelo. O valor da correlação entre X_t e X_{t-2} (r_2) é igual à correlação entre X_t e X_{t-1} (r_1) multiplicada pela correlação entre X_{t-1} e X_{t-2} (r_{12}), de forma que $r_2 = r_1 r_{12}$. Assim, toda a correlação “indirecta” está presente na FAC de qualquer processo Auto-Regressivo (Enders, 2001).

O comportamento da função de auto- correlação de um processo Auto-Regressivo é uma mistura de decaimento exponencial e ou decaimento senoidal. Se as raízes da equação auto-regressiva forem reais, então as auto- correlações decairão exponencialmente. Caso as raízes sejam complexas, o decaimento será na forma senoidal (Granger e Newbold, 1986).

Dessa maneira, define-se a função de auto- correlação parcial (FACP) como a sequência de correlações entre $(X_t \text{ e } X_{t-1})$, $(X_t \text{ e } X_{t-2})$, $(X_t \text{ e } X_{t-3})$ e assim por diante, desde que os efeitos de defasagens anteriores sobre X_t permaneçam constantes (Hill, Griffiths e Judge, 1999). A FACP é calculada como o valor do coeficiente a_{kk} na equação:

$$X_t = \alpha_{k1} X_{t-1} + \dots + \alpha_{kk} X_{t-k} + u_t \quad (36)$$

Onde, a_{kk} é obtido das equações aplicadas de Yule-walker

De forma resumida, um processo $AR_{(p)}$ é descrito Por:

Possuir uma função de auto- correlação, FAC, que é uma combinação de decaimentos exponenciais e senoidais e tamanho infinito;

Possuir uma função de auto- correlação, FACP, que é igual a zero para defasagens maiores a p .

2.6 Modelo de Médias Móveis

No processo de médias móveis, os valores da série X_t , resultam de uma soma ponderada, semelhante a uma média dos valores mais recentes dos erros (Hamilton, 1994). O modelo de médias móveis consiste em expressar os valores correntes da série X_t como uma função linear dos valores passados de erros aleatórios não correlacionados até um número finito de defasagens. Tal modelo com q defasagens – determinadas com base nos valores da função de Auto- Correlação simples ou pelos critérios de selecção de Akaike ou de Schwarz. Matematicamente, este modelo denotado por $MA_{(q)}$ pode ser expressado por:

$$X_t = \beta_0 + e_t + \beta_1 e_{t-1} + \beta_2 e_{t-2} + \dots + \beta_q e_{t-q} \quad (37)$$

Onde:

e_t : representa os erros aleatórios não correlacionados, não observáveis com média e variância constante.

$\beta_1 \dots \beta_q$, são constantes reais.

$$E(X_t) = \mu$$

$$Var(X_t) = \sigma^2 (1 + \beta_1^2 + \dots + \beta_q^2)$$

Tem interesse destacar que, quando $\mu = 0$, temos a FACP seguinte:

$$\gamma_\tau = E\{X_t X_{t-\tau}\} = \gamma_{u(\tau)} - \sum_{k=1}^q \theta_k \gamma_{\varepsilon(k-\tau)} \quad (38)$$

Definindo-se o operador de médias móveis de ordem q por $\beta(B) = 1 - \beta_1 B^1 + \dots + \beta_q B^q$ - o qual pode ser escrito como:

$$X_t = \beta(B) e_t \quad (39)$$

de onde, formalmente, segue

$$e_t = (1 - \beta B)^{-1} u_t = (1 - \theta B)^{-1} X_t = (1 + \theta B + \theta^2 B^2 + \dots + \theta^q B^q + \dots), \text{ ou seja, temos:}$$

$$X_t = -\theta X_{t-1} - \theta^2 X_{t-2} - \dots - u_t \quad (40)$$

Se $|\theta| < 1$, para que a série venha a convergir. Nesta equação, temos X_t escrito como um processo Auto-Regressivo de ordem infinita. Portanto, para $|\theta| < 1$ é uma condição de invencibilidade para o processo $MA(1)$, que pode ser generalizado. Se a condição de invencibilidade estiver satisfeita, ou seja, todas as raízes de $\theta(B) = 0$ devem estar fora do círculo unitário. Logo:

$$\Pi(B)X_t = u_t \quad (41)$$

Com o objectivo de converter uma série não estacionária em estacionária, são utilizadas, para efeito de estimação do modelo MA, as primeiras diferenças de X_t . Nesse caso, definindo-se primeiras diferenças como $x_t = X_t - X_{t-1}$ para simplificar a notação, tem-se para $q = 2$, a seguinte equação estimável:

$$x_t = \delta_0 + e_t + \delta_1 e_{t-1} + \delta_2 e_{t-2} \quad (42)$$

O modelo MA é, no entanto, não linear nos parâmetros. Portanto, estes não podem ser estimados mediante a aplicação simples do método dos mínimos quadrados ordinários. A estimação pode ser feita pelo método da máxima verosimilhança para processos que seguem distribuição normal ou por meio do método de busca gradativa desenvolvida por Box e Jenkins (Maddala, 2001).

Em geral, num processo $MA(q)$ a FAC apresenta um “corte” para zero para defasagens maiores que q , e a função de auto-correlação parcial possui tamanho infinito. De forma que pode ser resumido pelas seguintes características:

- ✓ Possuir uma FAC que é zero para defasagens maiores que q ;
- ✓ Possuir uma FACP que é uma combinação de decaimentos exponenciais e senoidais e tamanho infinito.

Para fins deste trabalho não serão desenvolvidos os modelos Auto-Regressivos Integrados e de Médias Móveis devido a sua popularidade e relevância.

Para fins deste trabalho não serão desenvolvidos os modelos Auto-Regressivos Integrados e de Médias Móveis devido a sua popularidade e relevância.

2.7 Modelos Auto-regressivos Vectoriais (VAR)

A modelagem VAR inicialmente estudada por Christopher Sims (1980), surge como forma crítica aos modelos de equações simultâneas, ou estruturais. Nestes modelos, algumas variáveis são tratadas como exógenas, sendo primeiramente, antes de estima-los estudar ou identificar a classe variável. No entanto, esta Identificação muitas vezes é subjectiva, visto que, se de facto existir uma simultaneidade entre as variáveis, segundo Sims, estas deviam ser tratadas sem nenhuma distinção a priori. É neste sentido que Sims propõe o modelo Vectorial Auto Regressivo ou simplesmente VAR.

Consideremos um modelo auto regressivo de ordem p, AR (p):

$$X_t = \alpha_0 + \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + \varepsilon_t \quad (43)$$

Pode-se agora considerar um vector de colunas, com n variáveis diferentes, de modo que,

$X_t = [X_{1t}, \dots, X_{nt}]'$ e modelar em termos dos seus valores passados. O resultado é uma Auto-Regressão Vectorial ou simplesmente VAR, representado pela expressão matemática abaixo:

$$X_t = \varphi_0 + \varphi_1 X_{t-1} + \dots + \varphi_p X_{t-p} + \varepsilon_t \quad (44)$$

Os φ_i são matrizes de coeficientes do tipo n x n, φ_0 é um vector de constantes de dimensão n x 1 e ε_t é um termo de ruído branco, com as seguintes propriedades: $E(\varepsilon_t) = 0$ para todo t e $E(\varepsilon_t, \varepsilon_s') = \Omega$ para s = t e $E(\varepsilon_t, \varepsilon_s') = 0$ para s \neq t.

Onde assume-se que a matriz de covariância Ω é definida positiva. Assim, os ε_t não estão correlacionados em série, mas podem estar contemporaneamente correlacionados.

Se, a matriz I_n é matriz identidade de ordem n , a equação (44) pode ser reescrito, na forma:

$$\varphi(B) X_t = \varphi_0 + \varepsilon_t \quad (45)$$

Onde $\varphi(B) = I_n - \varphi_1 B - \dots - \varphi_p B^p$ é um operador vectorial auto regressivo de ordem p , ou polinómio matricial $n \times n$ em B . Um caso particular quando $n = 2$, isto é, VAR (44) com duas variáveis. Reduz-se a um modelo de causalidade.

$$X_{1t} = \varphi_{10} + \varphi_{11} X_{1t-1} + \varphi_{12} X_{2t-2} + \varepsilon_{1t} \quad (46)$$

$$X_{2t} = \varphi_{20} + \varphi_{21} X_{1t-1} + \varphi_{22} X_{2t-2} + \varepsilon_{2t}$$

Observa-se, uma relação de dependência contemporânea implícita entre as variáveis do modelo, o qual denomina-se modelo vectorial na forma reduzida. Quando o parâmetro $\varphi_{12} = 0$, a variável X_{1t} não dependerá de X_{2t-2} , analogamente se $\varphi_{21} = 0$, X_{2t} não dependerá de X_{1t-1} , no caso em que um dos parâmetros é diferente de zero, existe uma dependência unilateral entre as variáveis, ou de retorno. Pode-se ainda encontrar mais um caso em que as variáveis são independentes entre si.

O processo X_t será estacionário se a média for constante e $E(X_{t+\tau}; X_t)$ não depender do tempo, ou do período em que é calculado. Nesta caso, se $E(X_t) = \mu$, então:

$$\mu = (I_n - \varphi)^{-1} \varphi_0 \quad (47)$$

Segue que o modelo pode ser escrito na forma:

$$X_t - \mu = \varphi(X_{t-1} - \mu) + \varepsilon_t \quad (48)$$

Ou ainda:

$$\tilde{X}_t = \varphi \tilde{X}_{t-1} + \varepsilon_t \quad (49)$$

X_t Será estacionário, se as soluções de: $[I_n - \varphi_1 B - \dots - \varphi_p B^p] = 0$, estiverem fora do círculo unitário.

$$E(X_t) = \mu = (I_n - \varphi_1 B - \dots - \varphi_p B^p)^{-1} \varphi_0.$$

Desta forma o modelo 49 pode ser especificado como:

$$\tilde{X}_t = \varphi_1 \tilde{X}_{t-1} + \dots + \varphi_p \tilde{X}_{t-p} + \varepsilon_t \quad (50)$$

Com $\tilde{X}_t = X_t - \mu$.

A construção destes modelos, segue o mesmo ciclo de identificação, diagnóstico, estimação e previsão do modelo ARIMA. A identificação, da ordem p de um modelo VAR(p) consiste em ajustar sequencialmente modelos Auto-regressivos vectoriais de ordens diferentes $(1, 2, \dots, k$, com $k \in N$) e testar os coeficientes (matrizes).

Outra forma de identificar a ordem p é com base nos critérios de informação de AIC e BIC.

Relativamente ao diagnóstico, utiliza-se a série dos resíduos para testar a H_0 de que os resíduos são um ruído branco, podendo ser usado a versão multivariado da estatística Box-Ljung-Pierce.

A série dos resíduos segue uma distribuição $\chi^2(n^2(m-p))$ graus de liberdade, onde espera-se que $m > p$ para que número de graus de liberdade seja positivo. Entre as grandes aplicações de modelos VAR, destacam-se a análise de impulsos – respostas e o teste de Causalidade de Granger.

Alguns dos defensores apontados pelo Gujarati (2006), acerca do uso do VAR, enfatizam algumas virtudes destes modelos:

É um método simples, pois não é preciso se preocupar em determinar quais das variáveis são endógenas e quais exógenas. Portanto, todas as variáveis são tratadas como endógenas. Não é necessário impor nenhuma restrição;

São mais flexíveis que os modelos univariados, em que os valores correntes de uma série temporal são relacionados apenas com seus valores passados e ou com os valores correntes e passados dos erros ou resíduos;

A estimação é simples, na medida em que se pode usar o método de MQO usual e pode ser aplicado a cada variável separadamente;

As previsões obtidas pelos modelos em muitos casos, são melhores do que os modelos mais complexos, tais como de equações simultâneas. Embora estes modelos sejam ateóricos, têm sido considerados mais apropriados para a análise de relações interligadas e dos impactos dinâmicos provocados pelos choques, ou distúrbios aleatórios.

Alguns críticos apontam os seguintes problemas:

Tal como o modelo ARIMA, este modelo é ateórico dado que usa menos informação a priori. Contudo, alguns econometristas, assinam que, no funcionamento real da economia, as variáveis nem sempre se inter-relacionam segundo preconiza a teoria económica;

Pela ênfase do VAR na previsão (principalmente a curto prazo), estes modelos são menos adequados a análises políticas;

Um dos grandes desafios destes modelos é determinar o número de lags a incluir no modelo, de modo particular quando o número de variáveis é relativamente grande;

O uso de modelos VAR pressupõe que as variáveis sejam estacionárias, no entanto, se o modelo tiver variáveis mistas, isto é, variáveis com ordens de integração diferentes torna-se difícil transformar os dados;

Visto que muitas vezes é difícil interpretar os coeficientes individuais, geralmente quem adopta esta técnica estima a denominada *função resposta a impulso*, ou simplesmente IRF (do inglês *impulse response function*), que rastreia o impacto dos choques para os vários períodos no futuro.

Em determino, disto uma vez que os coeficientes não são interpretados individuais, usa-se a estatística F para análise conjunta dos parâmetros de cada variável.

2.7.1 Modelo Vectorial de Correção de Erro (VEC)

O modelo de correcção de erros (VEC) faz a ligação entre aspectos relacionados com a dinâmica de curto prazo com os de longo prazo, isto é, permite combinar as vantagens de se modelar tanto nas diferenças quanto em nível. Segundo Harris (1995), o modelo vectorial de correcção de erros possui várias vantagens. Primeiro, assumindo que X e Y são co- integradas, o modelo de correcção de erros incorpora os efeitos de curto e de longo prazo. Uma segunda característica do modelo de correcção de erros é que todos os seus termos são estacionários, considerando que as variáveis X e Y são co- integradas e que os termos do modelo foram estimados. Por fim, uma terceira característica é que ele está de acordo com o conceito de Engle e Granger (1987) que consiste em testar a existência de uma combinação linear das variáveis não estacionárias ou integradas que seja estacionária. Assim, a formulação do modelo de correcção de erros está imune ao problema de regressão espúria.

No caso de duas variáveis o termo de correcção de erros pode-se escrever como:

$$\begin{cases} \Delta Y_t = \alpha_1(X_{t-1} - \beta Y_{t-1}) + \varepsilon_{1t} \\ \Delta X_t = \alpha_2(X_{t-1} - \beta Y_{t-1}) + \varepsilon_{2t} \end{cases} \quad (51)$$

Constata-se na equação (51), que se o desvio ocorrido for positivo $X_{t-1} - \beta Y_{t-1} > 0$, então o valor de Y_t deve aumentar e o valor de X_t deve diminuir para que se atinja a igualdade de longo prazo ($X_t = \beta Y_t$). O modelo VEC é um modelo VAR com incorporação do termo de correcção de erros.

$$\begin{cases} \Delta Y_t = \alpha_{10} + \alpha_1(X_{t-1} - \beta Y_{t-1}) + \sum_i \alpha_{11}(i) \Delta Y_{t-i} + \sum_i \alpha_{12}(i) \Delta X_{t-1} + \varepsilon_{1t} \\ \Delta X_t = \alpha_{20} + \alpha_2(X_{t-1} - \beta Y_{t-1}) + \sum_i \alpha_{21}(i) \Delta Y_{t-i} + \sum_i \alpha_{22}(i) \Delta X_{t-1} + \varepsilon_{2t} \end{cases} \quad (52)$$

2.7.2 Co-Integração

Granger e Newbold (1974), quando procuravam estudar o fenómeno de Regressão Espúria, verificaram através de simulações, que dada duas séries completamente não estacionárias, mas integradas de ordem um I (1), as regressões de uma sobre a outra tenderá a produzir uma relação aparentemente significativa, ou seja, o comportamento de duas séries completamente não correlacionadas, mas integradas de ordem um I (1), quando regredido uma sobre a outra tenderá a produzir uma relação aparentemente significativa. Estes resultados trouxeram a necessidade de desenvolver técnicas para analisar a relação de tais séries não estacionárias. Para determinar estas análises foram desenvolvidos modelos para descrever movimentações dinâmicas de duas ou mais séries temporárias. No geral as séries económicas tais como séries de preço de activos apresentam uma tendência estocástica comum a longo prazo, ou seja, elas são co-integradas (Coelho, 2002), isto é:

Sejam X_t e Y_t , processos I (d), então a combinação linear em Z_t é dada por:

$$Z_t = Y_t - \alpha X_t, \quad (53)$$

No geral, (a série Z_t) é também integrado de ordem I (d). Mas é possível que Z_t seja integrada de ordem menor, tal que, esta seja I (d - b), $b > 0$. Se X_t e Y_t são integradas de mesma ordem, tal que $d = b = 1$, então Z_t será estacionária em nível, isto é, I (0). Este facto pode ser estendido para um modelo multivariado.

Seja X_t um vector no qual as componentes são Co-integradas de ordem (d, b) e escrevemos, $X_t \sim CI(d, b)$ se:

Todas as componentes de X_t são $I(d)$;

Existe um vector $\beta = (\beta_1, \dots, \beta_n)$, não nulo, tal que:

$$X_t = \beta_1 X_{1t} + \dots + \beta_n X_{nt} \sim I(d-b), d \geq b > 0 \quad (54)$$

O vector β , de ordem $n \times 1$, é chamado vector co-integrado (ou vector de Co-integração).

Considerando os seguintes modelos:

$$X_{1t} + \beta X_{2t} = u_t, \quad (55)$$

$$u_t = \varphi_1 u_{t-1} + \varepsilon_{1t}, \quad (56)$$

$$X_{1t} + \alpha X_{2t} = v_t, \quad (57)$$

$$v_t = \varphi_2 v_{t-1} + \varepsilon_{2t}, \quad (58)$$

Onde, supõe-se que os termos ε_{it} são distribuídos normalmente, com média igual a zero e com $E(\varepsilon_{it} \varepsilon_{jt}) = 0$, $j = 1, 2$. Suponhamos que $\varphi_i \neq 0$, $i = 1, 2$.

Então, se: $\varphi_i < 1$ (para $i = 1, 2$) ou $\varphi_1 = \varphi_2$, nestes casos, X_{1t} e X_{2t} serão $I(0)$ e $I(1)$ respectivamente, mas em ambos os casos, os parâmetros não são identificados. No caso em que, $\varphi_1 = 1$, $\varphi_2 < 1$, ou $\varphi_1 < 1$, $\varphi_2 = 1$, X_{1t} e X_{2t} serão $I(1)$ e portanto, $(1, \alpha)'$ e $(1, \beta)'$ são os vectores co-integrados e as equações (55) e (56) podem ser identificadas.

No geral o vector de Co-integração β é normalizado fixando o seu coeficiente igual a 1, tal que $\beta = (1, -\beta_2, \dots, -\beta_n)'$ de modo que:

$$\beta' X_t = X_{1t} - \beta_2 X_{2t} \dots - \beta_n X_{nt} \quad (59)$$

Lema 1

Processos co-integrados têm uma tendência estocástica comum entre elas e caminharão, juntos no longo prazo porque a combinação linear entre elas é reversível à média (estacionária).

Lema 2

Segundo Coelho (2002), se duas séries são co-integradas, então, existe uma relação de equilíbrio de longo prazo entre elas. Muitas variáveis económicas apresentam relação de equilíbrio.

Testes de Co-integração

Os testes de Co-integração assumem uma grande importância na área das ciências econométricas, que reside no facto de permitirem verificar se existe equilíbrio, ou relacionamento de longo prazo entre as variáveis económicas.

Existem no entanto três principais tipos de testes de Co-integração:

Teste denominado de Engle-Granger - Desenvolvido por Engle e Granger (EG) em 1987;

Teste de Phillips-Ouliaris - Apresentado por Phillips e Ouliaris em 1990;

Teste de Johansen - Desenvolvido por Johansen e Juselius (1990).

Diferenças

O teste de Johansen é um teste multivariado, tem uma abordagem mais complexa pela sua exigência teórica, tem uma vantagem em relação aos outros dois por permitir identificar o número de vectores de co-integrantes entre as variáveis dentro de um sistema multivariado;

Os testes de Engle-Granger e Phillips-Ouliaris, são testes que permitem, somente, verificar se as variáveis são co-integradas ou não (Gujarati, 2006).

Considere X_t , um vector de $n \times 1$ componentes e todas integradas de ordem 1, $I(1)$, quando:

Há, no máximo, um vector de Co-integração, este caso foi tratado por EG. Mas, o teste proposto por EG, testa a Co-integração de apenas duas variáveis.

Há r , $0 \leq r < n$, vectores de Co-integração, caso considerado por Johansen (1988).

Assim, para estimar a relação de equilíbrio de longo prazo entre y_t e x_t é necessário apenas estimar o seguinte modelo.

$$Y_t = \alpha + \beta X_t + u_t \quad (60)$$

Uma estimativa consistente dessa relação pode ser obtida utilizando o método de mínimos quadrados. Resumidamente, estima-se uma regressão com as variáveis em nível e aplica-se o teste de raiz unitária sobre os resíduos dessa regressão, sendo consideradas séries co-integradas, aquelas cuja série dos resíduos seja estacionária. Para verificar a estacionaridade dos resíduos foram utilizados os testes.

$$\hat{u}_t = \alpha \hat{u}_{t-1} + e_t \quad (61)$$

Deve-se testar a hipótese de que $\alpha = 0$, utilizando os valores tabelados por Engle & Granger. Se esta hipótese não for rejeitada, pode-se concluir que os resíduos são não estacionários. Caso os resíduos sejam estacionários, tem-se a indicação de que as variáveis analisadas possuem relacionamento de longo prazo e de que existe um modelo de correcção de erro (MCE). Este modelo faz a ligação entre

aspectos relacionados com a dinâmica de curto prazo com os de longo prazo, isto é, permite combinar as vantagens de se modelar tanto nas diferenças quanto em nível.

Para Harris (1995), os valores correntes da variável dependente Y são determinados não somente pelos valores correntes da variável explicativa X , mas também pelos seus valores passados, devido aos custos de ajustamento. A variável X desfasada pode ser indicada por X_{t-i} ($i = 0, \dots, q$). Por outro lado, valores desfasados de Y [Y_{t-i} ($i = 0, \dots, p$)] podem ser incluídos também no modelo, tornando-o um modelo dinâmico de curto-prazo. Um modelo dinâmico simples pode ser dado considerando $p = q = 1$, dessa forma tem-se:

$$Y_t = a_0 + Y_0 X_t + Y_1 X_{t-1} + a Y_{t-1} + u_t \quad (62)$$

Sendo que os resíduos são ruídos brancos [$u_t \sim IN(0, \sigma)$]. Esta formulação de um modelo dinâmico pode ser facilmente generalizada, tornando-se mais realista, pela incorporação de mais *lags* de p e q . Contudo, existem vários problemas que podem ocorrer com este modelo dinâmico, tais como multicolinearidade, erro de especificação e regressão espúria. Uma solução para este último problema é trabalhar com um modelo dinâmico nas primeiras diferenças. Contudo, este procedimento remove informações de longo prazo do modelo, o que impede a utilização do modelo para previsão. Um recurso mais apropriado é fornecido pela formulação do modelo de correcção de erro (MCE) de um modelo dinâmico. Reajustando e reparametrizando (62), obtém-se:

$$\Delta Y_t = a_0 + Y_0 \Delta X_t - (1 - \alpha_1) u_{t-1} + \varepsilon_t \quad (63)$$

Ou

$$\Delta Y_t = a_0 + a_1 \Delta X_t + a_2 u_{t-1} + \varepsilon_t \quad (64)$$

Assim, as equações (62) e (63) são equivalentes, contudo o MCE possui várias vantagens. Primeiro, assumindo que X e Y são co-integradas, o MCE incorpora os efeitos de curto prazo e de longo prazo. O equilíbrio de longo prazo, apresentado na equação (60), está incorporado no modelo. Dessa forma, se existe equilíbrio para qualquer período de tempo, então:

$$u_{t-1} = Y_{t-1} - \alpha - \beta X_{t-1} = 0 \quad (65)$$

Para períodos de desequilíbrio, este termo é diferente de zero e mensura a distância que o sistema está de seu equilíbrio no período t . Assim, a estimativa de $(1 - \alpha_1)$ fornece informações sobre o processo de ajustamento de variável y ou sobre sua resposta ao desequilíbrio. Uma segunda característica do MCE é que todos os seus termos são estacionários, considerando que as variáveis y e x são co-integradas e que os termos α e β foram estimados. Por fim, uma terceira característica do MCE é que o mesmo está de acordo com o conceito de Co-integração de Engle & Granger (1982).

Para fins deste trabalho aplicou-se o modelo de co-integração proposto por Johansen (1988), idêntico ao ADF, descrito abaixo:

Considerando um modelo AR (p):

$$X_t = A_1 X_{t-1} + A_2 X_{t-2} + \dots + A_p X_{t-p} + \varepsilon_t \quad (66)$$

Substituindo X_t em ambos os membros tem-se:

$$\Delta X_t = (A_1 - I) X_{t-1} + A_2 X_{t-2} + \dots + A_p X_{t-p} + \varepsilon_t \quad (67)$$

Que origina:

$$\Delta X_t = \sum_{i=1}^{p-1} \Delta \beta_i + \Pi_p X_{t-1} + \varepsilon_t \quad (68)$$

Onde:

$$\beta = -(I - \sum_{i=1}^p A_i) \quad \text{e} \quad \Pi = -(I - \sum_{j=1}^i A_j) \quad (69)$$

O número de equações de co- integração dependerá do posto da matriz Π . Com efeito, o posto da matriz será igual ao número de vectores de co- integração. Ou seja, o posto da matriz Π é igual ao número de raízes características (autovalores) que diferem de zero.

Segundo Harris (1995) para realizar o teste de co- integração de Johansen pode-se utilizar dois testes específicos, o primeiro é o teste de traço $\lambda_{tr}(r)$ onde:

$$\lambda_{tr}(r) = -T \sum_{i=r+1}^n \ln(1 - \lambda_i) \quad (70)$$

Com as seguintes hipóteses:

H_0 : Existem r^* vectores de co-integração

H_1 : Existem $r > r^*$ vectores de co-integração

Regra de decisão: Rejeitar H_0 se $|\lambda_{tr}| > |\lambda_{crit}|$, para qualquer nível de significância

O segundo teste é o teste de máximo autovalor que baseia-se na estatística:

$$\lambda_{tr}(r) = -T \sum_{i=r+1}^n \ln(1 - \lambda_{r+1}) \quad (71)$$

Hipoteses do teste:

H_0 : Existem r^* vectores de co-integração

H_1 : Existem $r + 1 > r^*$ vectores de co-integração

Regra de decisão: Rejeitar se $|\lambda_{max}| > |\lambda_{crit}|$, para qualquer nível de significância

2.7.3 Causalidade de Granger

O conceito de causalidade à Granger, foi inicialmente estudado por Granger em 1969 e posteriormente popularizado por Sims em 1972. É um conceito actual e persistem ainda discussões em torno da sua definição, pela controvérsia filosófica do sentido da palavra. Alguns econometristas, tais como Edward Leamer preferem o termo precedência á causalidade. Francis Diebold prefere o termo causalidade preditiva, considerando que uma variável X_t causa a variável Y_t , se a informação passada da variável X_t permite melhorar as predições da variável Y_t , isto é, se Y_t for melhor previsto com base nos valores passados de X_t e Y_t juntos do que apenas com os valores passados de Y_t (Gujarati, 2006).

Segundo Gujarati (2006), define-se causalidade em termos de previsibilidade, considerando que a variável X_t causa um efeito na variável Y_t com respeito a um dado universo de informação. De modo que Y_t pode ser previsto mais eficientemente usando valores passados de X_t , em relação a toda sua informação passada disponível. A elucidação de relações de causalidade entre variáveis económicas continua a ser um dos principais problemas em pesquisas empíricas, daí que o domínio deste tema conserva a sua relevância nas mais diversas áreas.

Com base nessa definição segue-se que:

$X_t \rightarrow Y_t$: X_t causa Y_t no sentido de Granger se:

$$\sigma^2(Y_t | \bar{A}_t) < \sigma^2(Y_t | \bar{A}_t - \bar{X}_t) \quad (72)$$

Ou seja, Y_t pode ser melhor prevista usando toda informação disponível, incluindo a informação passada de Y_t e X_t . Dizemos então que X_t é exógena ou antecedente a Y_t .

$X_t \leftarrow Y_t$: Y_t causa X_t no sentido de Granger se:

$$\sigma^2(Y_t | A_t, \bar{\bar{X}}) < \sigma^2(Y_t | \bar{A}_t) \quad (73)$$

O valor presente de X_t é melhor previsto se o valor presente de Y_t for incluído.

$X_t \leftrightarrow Y_t$: neste caso há feedback, quando X_t causa Y_t , e Y_t causa X_t .

Onde, A_t (com $t \in Z$) é um conjunto de informação relevante até o instante t , contendo X_t e Y_t ,

define-se $\bar{A}_t = \{A_s : s < t\}$, $\bar{A}_t = \{A_s : s < t\}$. Esta definição estende-se também para vectores aleatórios.

Para $X_t = [X_{1t}, \dots, X_{rt}]$ e $Y_t = [Y_{1t}, \dots, Y_{st}]$.

2.7.4 Número de Desfasagens

Num modelo VAR, todas as variáveis são endógenas e dependem das próprias desfasagens e das desfasagens de todas as demais variáveis do sistema, a escolha da ordem de desfasagens do VAR é arbitrária. Por um lado, é desejável incluir o maior número possível de desfasagens, de modo a evitar a imposição de restrições falsas sobre a dinâmica do modelo. Por outro lado, quanto maior a ordem de desfasagens, maior o número de parâmetros a serem estimados consequentemente, menos graus de liberdade para a estimação.

Segundo Margarido (2004), para a tomada de decisão em relação ao número de desfasagens que devem ser aplicadas, utilizam-se os critérios AIC (Akaike Information Criterion) ou então o SBC (Schwarz Bayesian Criterion).

2.7.5 Análise da Decomposição de Variância

Segundo Bueno (2008), a decomposição da variância é uma forma de mostrar que a percentagem da variância do erro de previsão é decorrente de cada variável endógena, ao longo do horizonte de previsão, ou seja, é a identificação da responsabilidade de cada uma das variáveis na explicação da variância de todas as variáveis do sistema, após um choque, servindo como “classificação” da importância relativa de cada variável na determinação dela mesma e das demais.

2.7.6 Função Resposta – Impulso

O modelo VAR, de um modo geral, não permite identificar todos os parâmetros da forma estrutural, a menos que sejam impostas restrições adicionais. A solução pode ser um sistema recursivo, impondo alguns coeficientes iguais a zero, definidos por argumentos económicos.

Segundo Vartanian (2010), a função de resposta - impulso é uma técnica, que permite avaliar os efeitos de um choque em uma série temporal sobre a outra. Em outras palavras, os resultados apresentados na função de Resposta - Impulso permitem avaliar adequadamente resultados de choques em qualquer uma das variáveis do sistema. Em resumo, representa o horizonte temporal dos efeitos dos choques das demais variáveis no VAR sob uma determinada variável (Enders, 2010).

III METODOLOGIA

Neste capítulo serão apresentados os materiais e métodos necessários para alcançar-se os objectivos do estudo.

3.1 Material

3.1.1 Dados Usados

Para a realização deste trabalho e tendo em conta os objectivos descritos, utilizou-se os seguintes dados:

Uma série temporal da Taxa de juros activa de Moçambique com maturidade de 30 dias, referente ao período de Abril de 2005 a Outubro de 2012 e;

Uma série temporal da taxa Facilidade Permanente de Cedência mensal para o mesmo período. A taxa de juros facilidade permanente de cedência é diária mas para fins deste trabalho usou-se a taxa média mensal através do cálculo da média aritmética das taxas diárias pela fórmula:

$$FPC = \frac{\sum_{i=1}^n FPCD}{n} ; \text{onde: } FPC \text{ representa a taxa facilidade permanente de cedência mensal;}$$

$FPCD$: representa a taxa facilidade permanente de cedência diária e;

n : representa o número de dias do mês.

3.1.2 Fonte de Dados

Para alcançar os objectivos da investigação usou-se uma base de dados secundária obtida no Banco de Moçambique através do seu sítio na internet (www.bancomoc.mz), contendo 91 observações mensais das séries Taxa de Juros Facilidade Permanente de Cedência (FPC) e Taxa de Juros Activa ($TJact$) com maturidade de 30 dias, observados no período de Abril de 2005 até Outubro de 2012.

3.2 Métodos

3.2.1 Análise de dados

Os dados foram processados no *software* estatístico Eviews versão 5 e a um nível de significância de 5%.

3.2.2 Teste de estacionaridade das séries

Para verificação da estacionaridade das séries primeiro fez-se a análise gráfica que mostrou indícios de não estacionaridade em nível, pois os gráficos apresentam oscilações não constantes com o decorrer do tempo e depois procedeu-se com o teste de ADF, descrito no capítulo II, com as seguintes hipóteses e regra de decisão:

Hipóteses:

H_0 : A série tem uma raiz unitária (é não estacionária)

H_a : A série não tem raiz unitária (é estacionária)

Regra de decisão:

RH_0 Se $\text{Prob} < \forall \alpha$

RH_0 Se $|\tau_{cal}| > |\tau_{crit}|, \forall \alpha$

3.2.3 Normalidade Multivariada

Para a verificação da normalidade baseiou-se na estatística de Jeque-Berra, com a hipótese nula de não presença de normalidade, com distribuição Qui-Quadrado. Essa análise mostrou que as duas variáveis seguem a distribuição normal pois possuem valor da probabilidade associada a estatística superior a α .

Hipoteses do teste:

H_0 : A distribuição das variáveis não é normal

H_1 : A distribuição das variáveis é normal

Regra de decisão: Rejeitar H_0 se $\text{Prob} > \alpha$

3.2.4 Modelo VAR

Depois de ter-se verificado que as séries em análise são estacionárias em primeiras diferenças, seguiu-se com a análise da relação de equilíbrio de longo prazo para não incorrer ao risco de regressão espúria, onde verificou-se com base na estatística de maior autovalor e de traço que as séries são co-integradas. Por tratarem-se de séries estacionárias em primeiras diferenças e co-integradas, usou-se o modelo VEC (Vector de Correção de Erro), através das funções de resposta-impulso e de decomposição da variância, ambos descritos no capítulo II.

3.2.4.1 Teste de Co- Integração

O teste de estacionaridade mostrou existência de uma estacionaridade em primeiras diferenças das séries, havendo em seguida necessidade de verificar se as séries possuem uma relação de equilíbrio de longo prazo para não incorrer a regressões espúrias. E neste trabalhou a verificação da co-integração das séries baseou-se no teste de Johansen, descrito no capítulo II, com as seguintes hipóteses e regra de decisão:

Hipoteses do teste:

H_0 : Existem r^* vectores de co-integração

H_1 : Existem $r > r^*$ vectores de co-integração

Regra de decisão: Rejeitar H_0 se $|\lambda_{tr}| > |\lambda_{crit}|$, para qualquer nível de significância

Ou

H_0 : Existem r^* vectores de co-integração

H_1 : Existem $r + 1 > r^*$ vectores de co-integração

Regra de decisão: Rejeitar se $|\lambda_{max}| > |\lambda_{crit}|$, para qualquer nível de significância

3.2.4.2 Teste de Causalidade de Granger

Para testar a relação de causalidade considera-se um modelo com duas equações onde as variáveis são X_t e Y_t com n e m defasagens, respectivamente.

$$X_t = \sum_{i=1}^n \alpha_i X_{t-i} + \sum_{j=1}^n \beta_j Y_{t-j} + \varepsilon_{1t} \quad (3.2.6.1)$$

$$Y_t = \sum_{i=1}^m \lambda_i X_{t-i} + \sum_{j=1}^m \delta_j Y_{t-j} + \varepsilon_{2t} \quad (3.2.6.2)$$

Onde pressupõe-se que as perturbações aleatórias ε_{1t} e ε_{2t} não estão correlacionadas entre si. O teste de Causalidade à Granger permite distinguir quatro casos:

Causalidade Unidireccional de Y_t para X_t : se o conjunto dos coeficientes ou parâmetros estimados das variáveis defasadas Y_t em (3.2.6.1) são estatisticamente diferentes de zero (ou $\sum_{j=1}^n \beta_j \neq 0$) e o conjunto dos coeficientes estimados de X_t defasado (3.2.6.2) não é estatisticamente diferente de zero (isto é, $\sum_{i=1}^m \lambda_i = 0$).

Causalidade unidireccional de X_t para Y_t : quando o conjunto de coeficientes Y_t defasados em (3.2.6.1) não é estatisticamente diferente de zero (isto é, $\sum_{i=j}^m \lambda_i = 0$ e o conjunto dos coeficientes dos X_t defasados em (3.2.6.2) é estatisticamente diferente de zero ($\sum_{j=1}^n \beta_j \neq 0$).

Retorno (Feedback) ou causalidade bilateral: quando o conjunto dos coeficientes de Y_t e X_t são estatisticamente diferentes de zero nas duas regressões.

Independência: quando o conjunto dos coeficientes de Y_t e X_t não são estatisticamente diferentes de zero nas duas regressões. Onde é testada a hipótese nula de $\sum \beta_i = 0$, isto é, os termos desfasados de Y_t não são significativos.

Para verificação da causalidade, aplica-se o teste F com m e $n-k$ graus de liberdade com base na seguinte estatística:

$$F = \frac{(SQR_T - SQR_{gr})/m}{SQR_{gr}/n-k} \quad (3.2.6.3)$$

Decisão: Se o valor do teste $F_{calculado}$ for maior que o valor crítico de $F_{critico}$ ao nível de significância seleccionado, rejeita-se a hipótese nula. Portanto, pode-se dizer que Y_t causa (no sentido de Granger) o X_t . Em seguida repetem-se as hipóteses para os restantes casos acima citados.

Diagnóstico: Quando os resíduos das regressões consideradas no modelo de causalidade de Granger apresentam-se auto-correlacionados entre si, pode retirar algum significado aos testes de significância individuais (testes t) e ao próprio teste global F (Manso, 2005). Para se verificar como os resíduos encontram-se correlacionados entre si, foi introduzido um modelo de regressão baseado no MQO:

$$Y_t = \alpha + \sum_{i=1}^p \beta_i \Delta X_{t-1} + \varepsilon_t \quad (3.2.6.4)$$

Um valor extremamente baixo de DW sugere forte auto-correlação de primeira ordem, ($R^2 > DW$) o que sugere que a regressão estimada seja espúria.

3.2.4.3 Número de Desfasagem no Modelo

A escolha do número de desfasagem do modelo baseiou-se nos critérios de Akaike e Schwarz, onde com base nestes critérios optou-se pelo modelo com duas desfasagens por este possuir menor valor desses critérios.

3.2.4.4 Análise de Decomposição da Variância

Analisou-se a decomposição da variância para mostrar a percentagem da variância do erro de previsão decorrente de cada variável endógena, ou seja, para a identificação da responsabilidade (peso) de cada uma das variáveis na explicação da variância de todas as variáveis do sistema, após um choque, servindo como classificação da importância relativa de cada variável na determinação dela mesma e das demais.

3.2.4.5 Função de Resposta-Impulso

A análise da função de resposta-impulso permitiu avaliar os efeitos de um choque em uma série temporal sobre a outra, ou seja, permitiu avaliar adequadamente resultados de choques em qualquer uma das variáveis do sistema.

Passos para Estimação de um Modelo VAR

1. Variáveis endógenas: Escolher as variáveis endógenas que comporão o vector
2. Gráficos: Analisar os gráficos das séries para verificar a existência de tendências estocásticas e determinísticas
3. Teste de Raízes Unitárias: Realizar testes ADF para determinar a ordem de integração
4. Se as séries forem $I(0)$, deve-se estimar um modelo VAR sem diferenciar as séries
5. Teste de Co- integração: Se uma ou mais séries forem $I(1)$, fazer o teste de co- integração de Johansen para determinar a existência e número de relações de co- integração.

6. Estimação do VAR ou VEC: Deve-se estimar um VAR se não houver equações de co-integração, e um VEC se houver uma ou mais equações de co- integração.

IV RESULTADOS E DISCUSSÕES

4.1 Análise Exploratória de Dados

Uma condição básica para aplicação do Modelo Auto Regressivo Vectorial (VAR) é que as séries temporais em estudo sejam estacionárias, ou seja, não apresentem tendência ou sazonalidade. A representação gráfica dos dados é um passo fundamental na identificação do comportamento de uma série temporal. As figuras 4.1a e 4.1b apresentam a análise dos gráficos das séries FPC e TJact no período de Abril de 2005 a Outubro de 2012. Neste período as duas séries apresentam oscilações ora crescentes ou decrescentes. Estas oscilações não são constantes ao longo do tempo, o que leva a suspeitar que a média e a variância não são constantes ao longo do tempo.




Figura 4.1a: Representação gráfica da série taxa de juro facilidade permanente de cedência
[Fonte: Output do Eviews]




Figura 4.1b: Representação gráfica da série taxa de juro activa [Fonte: Output do Eviews]

Com base na tabela 4.1, o coeficiente de assimetria tem para as duas taxas de juros valores compreendidos entre -2 e 2, o que mostra que a distribuição dos dados é simétrica. Olhando para o índice de Curtose que mostra o achatamento das séries, nota-se que há indícios de que a distribuição das observações da Taxa Facilidade permanente de cedência e activa seja normal pois, este possui o valor da probabilidade associada a estatística de Jarque-Bera superior a 0.05.

Tabela 4.1: Estatísticas descritivas [Fonte: Elaboração própria]

<i>Variável</i>	<i>Jarque-Bera</i>		<i>Coefficientes</i>	
	<i>Valor</i>	<i>Prob</i>	<i>Assimetria</i>	<i>Curtose</i>
<i>FPC</i>	5,1548	0,0760	0,2905	1,9891
<i>Tjact</i>	3,9848	0,1364	-0,1935	2,0507

4.2 Teste de Estacionaridade

Para analisar a estacionaridade das séries, recorreu-se primeiramente a análise gráfica (Figura 4.1a e 4.1b), que verificou-se que existem indícios de não estacionaridade das séries em nível.

O processo de modelação das séries temporais financeiras implica que, em primeiro lugar, se proceda a análise das propriedades de estacionaridade das séries em estudo. Para o efeito, utilizar-se-á o teste de raiz unitária de Dickey e Fuller descritos no Capítulo III. Os resultados encontram-se na Tabela 4.2 e com base nos resultados, verifica-se que as séries em análise não são estacionárias em nível pois as probabilidades são maiores que o nível de significância assumido (0.05). O mesmo pode-se concluir comparando o módulo dos valores calculados e críticos do teste t, onde para as duas séries o módulo do valor de t calculado é menor que o módulo do valor do t crítico (tabelado). Após diferenciar as séries uma vez, verifica-se que elas tornam-se estacionárias. Em suma as séries em análise são estacionárias em primeiras diferenças, *prob* = 0.00 menor que o nível de significância de 0.05 e módulo de valores do t calculado superior que o módulo do valor do t crítico.

Tabela 4.2: Estatística do teste de raiz unitária ADF para as séries [Fonte: Elaboração Própria]

Variável	Teste de ADF			
	Em Nível			
	<i>t Calculado</i>	<i>Prob</i>	<i>Valor Crítico</i>	
			1%	5%
FPC	-1,6525	0,7638	-4,0645	-3,4611
Tjact	-1,8698	0,6618	-4,0645	-3,4611
Em 1ª Diferença				
FPC	-7,0113	0,0000	-4,0645	-3,4611
Tjact	-13,3896	0,0000	-4,0645	-3,4611

4.3 Modelo VAR

Como o teste de ADF mostrou que as séries não são I (0) então, ao invés de usar o modelo Auto-regressivo Vectorial (VAR), deve-se utilizar o modelo Vectorial de Correção de Erro (VEC).

4.3.1 Teste Para a Escolha de Número de Desfasagens do Modelo

Antes de estimar-se o vector de correcção de erro é necessário adoptar algum critério para seleccionar o número de desfasagens que será considerado no modelo, para isso foi estimado um modelo VAR, e foi utilizado o teste para escolha do número de desfasagens, o teste baseou-se nos critérios de Akaike (AIC) e Schwartz e, com base nos resultados da Tabela 4.3.1 o melhor modelo será o de 2 desfasagens pois este possui os menores valores destes critérios.

Tabela 4.3.1: Teste para escolha do número de desfasagens do modelo [Fonte: Elaboração Própria]

Desfasagens	AIC	SC
0	860.258	866.087
1	542.277	559.762
2	518.8912*	548.0339*
3	525.615	566.415
4	532.402	584.859
5	540.093	604.207
6	545.502	621.273
7	551.755	639.183
8	556.532	655.617

4.3.2 Teste de Autocorrelação Serial Residual

A tabela 4.4.2 apresenta os resultados do teste de autocorrelação serial residual baseada no procedimento LM, onde verifica-se que o modelo estimado não apresenta autocorrelação serial residual pois todas as probabilidades são superiores a probabilidade fixada (0.05). Então, a nível de significância de 5% rejeita-se a hipótese de presença de autocorrelação serial residual.

Tabela 4.3.2: Teste de autocorrelação serial residual baseado no procedimento LM [Fonte: Elaboração Própria]

Desfasagens	LM-Stat	Prob
1	2.262739	0.6876
2	3.726197	0.4443
3	1.887792	0.7564
4	2.780827	0.5951
5	0.753178	0.9446
6	0.798027	0.9387
7	2.424334	0.6582
8	2.464975	0.6509
9	2.409152	0.6610
10	7.076266	0.1319
11	0.453510	0.9779
12	2.816900	0.5889

4.3.3 Teste de Co- Integração

Depois de ter-se verificado que as séries são integradas de mesma ordem, isto é $I(1)$, tem interesse realizar-se o teste de co- integração de Johansen (teste escolhido para fins deste trabalho) para verificar a relação de longo prazo entre as séries.

Os resultados do teste de co- integração apresentados nas tabelas 4.3.3.1 e 4.3.3.2 indicam a existência de um único vector co- integrante no modelo, de acordo com as estatísticas de traço e de autovalor máximo. Para $r=0$ a estatística do traço (16.87488) é superior ao valor crítico correspondente (15.49471), logo a nível de significância de 5% deve-se rejeitar a hipótese nula de não existência de um vector de co- integração, o mesmo pode-se concluir comparando a estatística de maior autovalor (15.14616) com o valor crítico correspondente (14.26460). Para $r=1$, a estatística do traço assim como a estatística do maior autovalor são menores que os valores críticos correspondentes, logo a nível de significância de 5% não rejeita-se a hipótese nula, o que significa que existe um vector de co- integração.

Tabela 4.3.3.1: Estatística do Traço [Fonte: Elaboração Própria]

Nº de Vectors de Co-Integração	Autovalor	Estatística do traço	Valor crítico a 5%
Nunhum	0,1190	16,8749	15,4947
No maximo 1	0,0415	3,7287	3,8415

Tabela 4.3.3.2: Estatística do máximo Autovalor [Fonte: Elaboração Própria]

Nº de Vectors de Co-Integração	Autovalor	Estatística do Maior Autovalor	Valor crítico a 5%
Nunhum	0,1190	15,1462	14,2646
No maximo 1	0,0415	3,7287	3,8415

4.3.4 Teste de Causalidade de Granger/Teste de Exogenidade de Wald

A tabela 4.3.4.1 apresenta o resultado do teste de causalidade de Granger para indicar o sentido de causalidade e, a tabela 4.3.4.2 indica para além da relação de causalidade, qual das duas séries é mais exógena. O modelo apresentado incorpora 2 desfasamentos das 2 séries de modo a remover qualquer tipo de auto- correlação remanescente nos resíduos.

Com base na tabela 4.3.4.1, a $Pr o = 0.00960 < 0.05$, então a nível de significância de 5% a série FPC causa à Granger a série TJact, o mesmo verifica-se para o caso contrário, isto é, como $Pr o = 0.00661 < 0.05$, a série TJact causa à Granger a série FPC. Em suma, existe uma relação de Causalidade Bidireccional entre as séries FPC e TJact.

A tabela 4.3.4.1 apresenta o teste de exogenidade, baseando-se na estatística Qui-Quadrado que ordena as variáveis das mais exógenas (menores valores da estatística) para as mais endógenas, e com base nos resultados da tabela abaixo a variável mais exógena é Taxa de juros activa, pois apresenta menor valor da estatística Qui- Quadrado.

Tabela 4.3.4.1: Teste de causalidade de Granger [Fonte: Elaboração Própria]

Hipótese Nula	Obs	Estatística	Prob
FPC não causa a Granger a TJact	89	4,9123	0,0096
Tjact não causa a Granger a FPC		5,3310	0,0066

Tabela 4.3.4.2: Teste de exogenidade de FPC e TJact [**Fonte:** Elaboração Própria]

	Variável Dependente			
	FPC		Tjact	
	χ^2	Prob	χ^2	Prob
FPC			0,1813	0,9133
Tjact	10,4491	0,0054		
Total	10,4491	0,0054	0,1813	0,9133

4.3.5 Função Resposta-Impulso

A Figura 4.3.5 apresenta os resultados das funções Resposta-Impulso. A linha contínua representa a função Resposta-Impulso, enquanto as linhas pontilhadas representam o intervalo de ± 2 desvios padrão. Os desvios-padrão foram gerados por meio de simulação de Monte Carlo com 1000 repetições. A intuição dessa ferramenta é que qualquer resposta que leve o intervalo de confiança de ± 2 desvios-padrão a se afastar do valor zero representa uma resposta significativa da variável a alterações na outra variável independente contemplada.

Os choques nas variáveis, taxas de juros activa e taxas de juros FPC, não só afectam directamente a elas mesmas, como também são transmitidos duma para a outra. As respostas da taxa de juros activa a impulsos na taxa de juros facilidade permanente de cedência, mostram o comportamento dos choques em cada uma das inovações nos valores correntes e futuros da taxa de juro activa.

A taxa de juro activa responde significativamente a variações em si própria durante aproximadamente dez períodos, e aos choques na taxa de juros facilidade permanente de cedência durante aproximadamente 8 períodos, excluindo-se apenas o intervalo do primeiro ao segundo período em que esses choques não são significativos.

Resumindo, as variações na taxa de juros activa são significativamente influenciadas pelas variações na taxa de juros facilidade permanente de cedência.

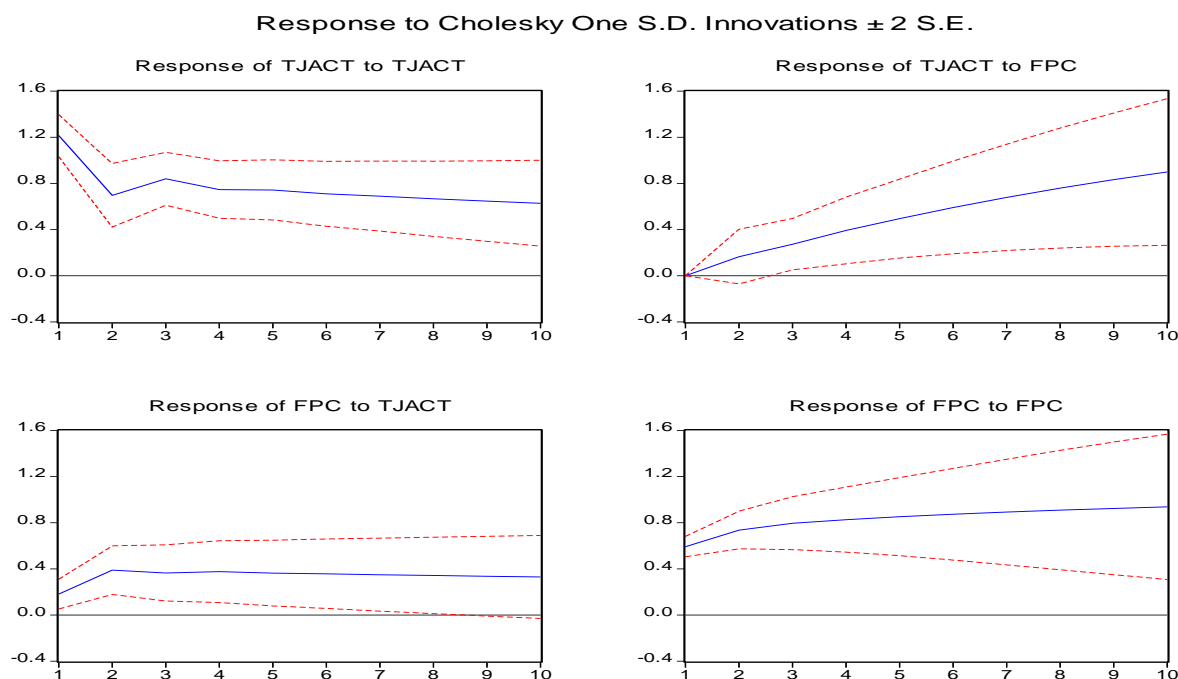


Figura 4.3.5: Resposta-Impulso na taxa de juro [Fonte: Output do Eviews]

4.3.6 Decomposição da Variância da taxa de juros Activa

A análise de decomposição da variância dos erros de previsão permite quantificar o peso de cada variável independente na determinação da variância do erro de previsão da variável dependente ao longo do tempo. Neste trabalho utilizou-se a decomposição de variância de erro de previsão de um período de 12 meses, onde com base na tabela 4.3.6 verificou-se que grande parte da variação da taxa de juro activa se da, inicialmente, em função dos choques em si mesma. No primeiro período 100% da variação da taxa de juros activa resultou dos choques nela própria, o que significa que não teve nenhuma influência da taxa de juros facilidade permanente de cedência. Nota-se também que com o decorrer do tempo, reduzem-se os choques da taxa de juros activa em si própria, o que aumenta a incidência das variações resultantes do choque desta, com a taxa de juros facilidade permanente de

cedência, resumindo, a variação dos choques da taxa de juros activa em si própria apresenta uma tendência decrescente com o decorrer do tempo, o que aumenta as variações do choque desta, com a taxa de juros facilidade permanente de cedência. O resultado obtido na análise da decomposição da variância não difere do que se encontrou analisando a função de Resposta-Impulso, ambos mostram existência de uma influência positiva significativa da taxa de juros facilidade permanente de cedência sobre a taxa de juros activa.

Tabela 4.3.6: Decomposição da Variância da TJact [Fonte: Elaboração Própria]

Período	S.E.	Tjact	FPC
1	1.197474	100.0000	0.000000
2	1.342041	98.54246	1.457542
3	1.482341	96.97014	3.029864
4	1.589193	93.36771	6.632294
5	1.690399	88.47875	11.52125
6	1.792043	82.42665	17.57335
7	1.898403	75.66723	24.33277
8	2.012110	68.61916	31.38084
9	2.134200	61.65712	38.34288
10	2.264759	55.06408	44.93592
11	2.403261	49.01813	50.98187
12	2.548843	43.60628	56.39372

V CONCLUSÕES

Neste trabalho fez-se a análise da relação entre a taxa de juros activa e a taxa de juros facilidade permanente de cedência em Moçambique. As relações foram analisadas por meio da estimativa de um modelo VAR, com as funções de resposta-impulso e de decomposição da variância do erro de previsão. Adicionalmente, foi realizada a análise de co-integração que detecta a relação de equilíbrio de longo prazo entre as séries e os testes de causalidade e exogenidade.

A análise das séries mostrou que elas são I (1) e que possuem um vector de co-integração, consequentemente verificou-se que existia uma relação de equilíbrio de longo prazo. A co-integração, no entanto, não é a única evidência de relação entre as variáveis, constatou-se evidências de relações importantes a curto prazo verificadas com aplicação do teste de exogenidade/causalidade que mostrou que a variável mais exógena é a taxa de juros activa e também constatou-se que o comportamento de cada uma das variáveis causa efeito na outra.

A função de resposta-impulso e de decomposição da variância do erro de previsão colaboraram com o que se constatou anteriormente, mostrando também que as variações na taxa de juros activa são significativamente influenciadas pelas variações na taxa de juros facilidade permanente de cedência.

Na prática, os resultados mostram que qualquer alteração na taxa de juro facilidade permanente de cedência implicaria numa alteração na taxa de juro activa. Se a taxa de juro facilidade permanente de cedência for aumentada, a taxa de juro activa aumentaria também e consequentemente reduziriam os empréstimos bancários e investimentos, afectando directamente o bem-estar da população uma vez que esta depende na sua maioria de empréstimos bancários para criação de habitação e negócios devido a baixos salários.

5.1 Recomendações

Os resultados mostram que existe uma forte influência da taxa de juros facilidade permanente de cedência na taxa de juros activa então, o Banco de Moçambique deve controlar as oscilações da taxa facilidade permanente de cedência pois esta influência nas oscilações da taxa de juros activa, e por sua vez os bancos comerciais devem seguir os ajustes da taxa facilidade permanente de cedência.

VI BIBLIOGRAFIA

- Banco de Moçambique (2011). *Relatório Anual: CDI- Banco de Moçambique*. Maputo
- Banco de Moçambique (2012). *Boletim Estatístico*. Maputo
- Banco de Moçambique (2014). *Boletim Estatístico*. Maputo
- Bueno, R.L.S. (2008). *Econometria de Séries Temporais*. São Paulo: Cengage Learning.
- Coelho, A.B. (2002). *A cultura do algodão e a questão da integração entre preços internos e externos*. Brasília.
- Enders, W. (2010), *Applied Econometric Time Series*. New York: John Wiley and Sons. Press.
- Engle, R., e Granger, C. W. (1982). Cointegration and error correction representation, estimation and testing. *Econometrica*, Chicago.
- Fischer, S. (1982). *Séries univariantes de tempo - metodologia de Box & Jenkins*. Porto Alegre: Fundação de Economia Estatística.
- Gujarati, D. (2006). *Econometria Básica*. 4 edição. Rio de Janeiro: Editora Campos.
- Griffiths, William E., Hill, R. Carter e Judge, George G. (1999). *Learning and Practicing Econometrics*. New York
- Hamilton, J. (1994). *Time Series Analysis*. Princeton University Press, Princeton.
- Harris, R. I. D. (1995), *Using cointegration analysis in econometric modeling*. London.
- Johansen, S., e Juselius, K. (1990). *Maximum Likelihood estimation and inference on cointegration*. Oxford Bulletin of economics and Statistics.
- Johansen, S. (1988). *Statistical Analysis of cointegration vectors*. *Journal of Economics Dynamics and Control*, London.
- Ljung, G.M.; Box, G.E.P. (1978). *On a measure of lack of fit in time series models*. Biometrika.
- Mackinnon, James G. (1991). *Critical values for cointegration tests*. New York: Oxford University.
- Maddala, G. S. (2001). *Introduction to econometrics*. New York. John Wiley and Sons.
- Margarido A. Mario. (2004). *teste de co-integração de Johansen*.
- Morentin, P. A. (2004). *Econometria Financeira*. São Paulo.
- Mateus, M. A. (2006). *Cálculo Financeiro*. 5ª Edição. Edições Sílabo. Lisboa
- Sims, C. A. (1980). *Macroeconomics and Reality*. Econometria.

Vartanian, P. R. (2010). *Choques Monetários e Cambiais sob Regimes de Câmbio Flutuante nos Países Membros do Mercosul: Há Indícios de Convergência Macroeconómica?* Economia, Brasília.

Anexo

Anexo A: Base de Dados

Tabela 1: Base de dados

FPC	13	13	13	13	13	13	13	13.17
TJact	18.93	18.55	18.11	19.04	19.35	19.58	19.65	21.28
13.62	13.37	13.9	14.7	19	19	19	19	17.47
20.33	19.39	19.61	22.55	23.49	23.75	23.99	23.56	23.70
17	17	17.17	17.5	17.5	17.5	17.5	17.5	17.5
23.47	23.88	23.56	23.65	22.82	22.73	23.24	23.83	23.42
16.03	15.5	15.5	15.5	15.5	15.5	15.5	15.1	13
23.09	22.91	22.30	22.68	21.92	21.88	21.26	20.21	20.45
13	13	13	13	13	12	11.5	11.5	11.5
19.72	19.78	19.92	20.21	19.85	19.51	20.37	19.70	19.16
11.5	11.5	11.5	11.5	11.5	11.5	11.5	11.5	11.5
19.54	18.40	17.32	17.80	18.96	18.93	18.05	17.30	16.76
11.5	11.5	11.5	11.5	11.5	11.5	11.5	11.9	12.5
15.94	15.97	19.65	15.07	17.27	16.78	17.33	17.45	18.56
13.63	14.5	14.5	15.07	15.5	15.5	15.5	16.18	16.5
18.51	18.82	17.55	22.97	19.84	19.93	20.68	23.70	24.12


16.5	16.5	16.5	16.5	16.15	16	16	16	15.39
24.22	25.53	23.43	25.62	24.26	22.98	22.76	22.97	22.45

15	15	14.07	13.63	13.5	12.57	11.5	11.5	10.8
22.63	23.77	25.06	24.84	23.32	21.48	21.74	21.72	23.82

10.5	9.9
20.88	20.83

Anexo B: Estatísticas Descritivas das Séries

Figura B.1: Estatísticas descritivas da série taxa de juros activa.



Anexo C: Correlograma das Taxas FPC e TJact

Figura C1: Correlograma da taxa de juros FPC em nível

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
. *****	. *****	1	0.910	0.910	77.831	0.000
. *****	. * .	2	0.816	-0.066	141.20	0.000
. *****	. .	3	0.726	-0.034	191.88	0.000
. *****	. .	4	0.650	0.031	232.98	0.000
. *****	. .	5	0.589	0.036	267.06	0.000
. *****	. .	6	0.534	0.001	295.48	0.000
. *****	. .	7	0.478	-0.043	318.50	0.000
. ****	. * .	8	0.412	-0.085	335.78	0.000
. ****	. * .	9	0.335	-0.096	347.35	0.000
. **	. * .	10	0.252	-0.089	353.97	0.000
. * .	. * .	11	0.167	-0.084	356.91	0.000
. * .	. * .	12	0.084	-0.071	357.67	0.000
. .	. .	13	0.012	-0.032	357.68	0.000
. .	. .	14	-0.054	-0.049	358.01	0.000
. * .	. .	15	-0.098	0.062	359.08	0.000
. * .	. .	16	-0.124	0.061	360.83	0.000
. * .	. .	17	-0.148	-0.012	363.35	0.000
. * .	. .	18	-0.177	-0.037	366.98	0.000
** .	. .	19	-0.211	-0.044	372.22	0.000
** .	. .	20	-0.243	-0.021	379.27	0.000
** .	. .	21	-0.272	-0.039	388.24	0.000
** .	. .	22	-0.297	-0.051	399.04	0.000
** .	. .	23	-0.303	0.029	410.43	0.000

Figura C2: Correlograma da série FPC em 1^{as} diferenças

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
. **	. **	1	0.282	0.282	7.4175	0.006
. * .	. .	2	0.139	0.065	9.2461	0.010
. * .	. .	3	0.073	0.020	9.7574	0.021
. .	. * .	4	-0.051	-0.092	10.010	0.040
. .	. .	5	-0.032	-0.003	10.107	0.072
. .	. * .	6	0.038	0.066	10.248	0.115
. * .	. * .	7	0.132	0.130	11.989	0.101
. * .	. .	8	0.133	0.061	13.777	0.088
. .	. * .	9	0.025	-0.068	13.839	0.128
. .	. .	10	0.054	0.038	14.146	0.166
. .	. .	11	0.023	0.019	14.203	0.222
. .	. .	12	-0.002	0.008	14.203	0.288
. .	. .	13	-0.001	-0.018	14.203	0.360
. * .	. * .	14	-0.147	-0.187	16.573	0.280
. * .	. .	15	-0.084	-0.025	17.360	0.298
. .	. .	16	-0.027	0.039	17.438	0.358
. .	. * .	17	0.043	0.087	17.651	0.411
. * .	. .	18	0.069	0.012	18.197	0.443
. .	. * .	19	-0.018	-0.099	18.235	0.507
. .	. .	20	-0.029	-0.029	18.338	0.565
. * .	. .	21	-0.084	-0.012	19.182	0.573
** .	** .	22	-0.285	-0.213	29.044	0.144
. * .	. * .	23	-0.061	0.078	29.500	0.164

Figura C3: Correlograma da Série TJact em nível.

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
. *****	. *****	1	0.859	0.859	69.330	0.000
. *****	. **	2	0.813	0.288	132.16	0.000
. *****	. .	3	0.743	-0.004	185.28	0.000
. *****	. .	4	0.697	0.039	232.58	0.000
. *****	. * .	5	0.618	-0.113	270.21	0.000
. *****	. .	6	0.563	-0.022	301.71	0.000
. *****	. .	7	0.493	-0.054	326.19	0.000
. ***	. ** .	8	0.394	-0.205	341.98	0.000
. **	. ** .	9	0.277	-0.227	349.92	0.000
. **	. .	10	0.201	-0.010	354.15	0.000
. * .	. * .	11	0.095	-0.132	355.11	0.000
. .	. .	12	0.032	0.046	355.22	0.000
. .	. * .	13	-0.024	0.096	355.29	0.000
. * .	. * .	14	-0.058	0.095	355.65	0.000
. * .	. .	15	-0.105	0.063	356.88	0.000
. * .	. * .	16	-0.124	0.110	358.62	0.000
. * .	. **	17	-0.104	0.232	359.86	0.000
. * .	. * .	18	-0.139	-0.127	362.11	0.000
. * .	. .	19	-0.125	0.032	363.94	0.000
. * .	. * .	20	-0.116	-0.063	365.55	0.000
. * .	. ** .	21	-0.119	-0.210	367.25	0.000
. * .	. ** .	22	-0.145	-0.276	369.82	0.000
. * .	. ** .	23	-0.156	-0.276	372.87	0.000

Figura C4: Correlograma da série TJact em 1^as diferenças

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
*** .	*** .	1	-0.351	-0.351	11.439	0.001
. *.	. *.	2	0.069	-0.061	11.889	0.003
. *.	. *.	3	-0.089	-0.097	12.635	0.005
. *.	. *.	4	0.120	0.068	14.013	0.007
. *.	. .	5	-0.063	0.003	14.396	0.013
. .	. .	6	0.021	-0.002	14.439	0.025
. *.	. *.	7	0.072	0.102	14.960	0.037
. .	. .	8	-0.002	0.055	14.961	0.060
. *.	. *.	9	-0.134	-0.129	16.786	0.052
. *.	. *.	10	0.164	0.096	19.581	0.033
. .	. .	11	-0.046	0.031	19.804	0.048
. .	. *.	12	-0.041	-0.070	19.986	0.067
. .	. .	13	-0.005	-0.007	19.988	0.096
. .	. .	14	0.048	0.010	20.238	0.123
. .	. .	15	-0.040	-0.027	20.419	0.156
. *.	. *.	16	-0.086	-0.094	21.244	0.169
. *.	. .	17	0.127	0.058	23.073	0.147
. .	. .	18	-0.015	0.034	23.099	0.187
. *.	. .	19	-0.065	-0.031	23.595	0.212
. .	. .	20	-0.023	-0.057	23.655	0.258
. *.	. .	21	0.072	0.022	24.277	0.280
. *.	. .	22	-0.093	-0.057	25.323	0.282
. .	. .	23	-0.000	-0.038	25.323	0.334

Tabela 2: Teste de escolha do número de Lags com vários critérios de selecção

Lag	LogL	LR	FPE	AIC	SC	HQ
0	-286.6900	NA	16.69539	8.490882	8.556162	8.516748
1	-156.4706	248.9489	0.407753	4.778546	4.974385	4.856143
2	-144.7975	21.62956*	0.325512*	4.552867*	4.879265*	4.682196*
3	-143.5784	2.187097	0.353585	4.634660	5.091617	4.815720
4	-142.2004	2.391209	0.382567	4.711778	5.299294	4.944570
5	-141.4866	1.196686	0.422490	4.808430	5.526506	5.092954
6	-140.2294	2.033792	0.459724	4.889099	5.737735	5.225355
7	-137.8663	3.683673	0.484922	4.937243	5.916438	5.325230
8	-135.8721	2.991229	0.517956	4.996239	6.105992	5.435957
9	-132.5532	4.783126	0.533149	5.016271	6.256584	5.507721
10	-126.6865	8.109854	0.510327	4.961368	6.332240	5.504549
11	-125.3799	1.729345	0.560057	5.040585	6.542017	5.635498
12	-124.5428	1.058689	0.625045	5.133611	6.765602	5.780256
13	-121.6518	3.486138	0.658923	5.166231	6.928781	5.864607
14	-118.6756	3.413965	0.695588	5.196340	7.089450	5.946448
15	-114.5832	4.453476	0.713726	5.193623	7.217292	5.995463
16	-112.1669	2.487304	0.773228	5.240204	7.394432	6.093775
17	-110.8914	1.238044	0.871273	5.320335	7.605122	6.225637
18	-107.8073	2.811966	0.937063	5.347273	7.762620	6.304308
19	-105.5553	1.920811	1.040686	5.398685	7.944591	6.407451
20	-104.3885	0.926619	1.203840	5.482013	8.158478	6.542511
21	-101.5718	2.071080	1.340389	5.516817	8.323842	6.629046
22	-94.98814	4.453639	1.352293	5.440828	8.378411	6.604788
23	-90.12117	3.006072	1.455993	5.415328	8.483471	6.631021