



DEPARTAMENTO DE ECONOMIA E DESENVOLVIMENTO AGRÁRIO
SECÇÃO DE ECONOMIA AGRÁRIA
LICENCIATURA EM AGROECONOMIA E EXTENSÃO AGRÁRIA

PROJECTO FINAL

Tema: Integração dos Mercados de Arroz entre as Regiões Norte, Centro e Sul de Moçambique

Autor:

Gilion de Cândido João Paulino

Supervisor: Prof. Doutor Meizal Popat

Co-Supervisora: Eng^a Gerivásia Mosse

Maputo, Agosto de 2024

DECLARAÇÃO DE HONRA

Declaro por minha honra que este trabalho de culminação de curso é da minha autoria, sob orientação dos meus supervisores, e nunca foi apresentado nesta ou em outra instituição para obtenção de qualquer outro grau académico. Este trabalho é apresentado em cumprimento parcial dos requisitos para a obtenção do grau de Licenciatura em Agroecologia e Extensão Agrária.

_____ Data:...../...../2024

Gilion de Cândido João Paulino

Por ser verdade, confirmo que o trabalho foi realizado pelo candidato sob minha supervisão.

Prof. Doutor Meizal Popat

Departamento de Economia e Desenvolvimento Agrário, Secção de Economia Agrária, Faculdade de Agronomia e Engenharia Florestal, Universidade Eduardo Mondlane

_____ Data:...../...../2024

Eng^a Gerivásia Mosse

Departamento de Economia e Desenvolvimento Agrário, Secção de Economia Agrária, Faculdade de Agronomia e Engenharia Florestal, Universidade Eduardo Mondlane

_____ Data:...../...../2024

Maputo, Agosto de 2024

Gilion de Cândido João Paulino

Integração dos Mercados de Arroz entre as Regiões Norte e Centro e Sul de Moçambique

O Projecto Final é submetido ao Departamento de Economia e Desenvolvimento Agrário, Secção de Economia Agrária da Faculdade de Agronomia e Engenharia Florestal - Universidade Eduardo Mondlane, em cumprimento dos requisitos exigidos para obtenção do grau académico de licenciado em Agroecologia e Extensão Agrária, sob a supervisão do Prof. Doutor Meizal Popat e da Eng^a Gerivásia Mosse.

DEDICATÓRIA

Dedico este trabalho aos meus amados pais, Sónia Jaime Mateus e Cândido João Paulino

Ao meu falecido Avó, João Paulino

E ao meu grande amigo Lionel Lucas

AGRADECIMENTOS

Agradeço em primeiro lugar ao Supremo Deus, pela vida, saúde, sabedoria, e por conceder-me forças durante a formação, pois muitos foram os motivos com a pretensão de fazer-me desistir.

Aos meus amados pais, pelo apoio incondicional, pelos ensinamentos e por nunca desistirem de mim desde a minha infância, durante os anos da formação, até então. E à minha família, que mesmo em meio à distância que nos separa, encorajaram e deram-me sábios conselhos para continuar.

Meus mais profundos agradecimentos aos meus grandes amigos Zecas Carlos Gomate, Atália Massingue, Emília Américo Nhiane, Marcos Muieva, Juvêncio Domingos, Nelson Domingos, José Cesar, Abdul Cádre, Joana Massingue, Sílvia João, e muitos outros, pelo companheirismo, conselhos, e apoio no suprimento das mais difíceis dificuldades. E aos meus irmãos da Igreja, especialmente à família Coana, aos irmãos Samuel Gazite, Fernando João, Lúcia João, que estiveram sempre presentes e dispostos a apoiar nas mais delicadas situações.

Agradeço igualmente aos meus colegas da faculdade em geral, e do curso em particular, que juntos trilhamos a difícil e longa carreira da licenciatura, contudo, juntos conseguimos atingir a meta desta grande corrida. Especial destaque vai aos colegas Zecas Carlos Gomate, Abdul Cádre, Maria Machalele, Hornélia Bambo, Ornília Mafuca, Cynthia Alafo, Watinissa Almirante, Helena João, Isac Chicolo, e vários outros constituintes dos ingressos de 2018 e 2017.

A conclusão deste trabalho somente foi possível através das intervenções directas ou indirectas de várias pessoas, com as quais tenho enorme dívida de gratidão. Assim, agradeço aos vários Docentes da FAEF, especialmente do Departamento de Economia e Desenvolvimento Agrário, particularmente às docentes Gerivásia Mosse, Felita Júlio, Gaby Manjate e Nícia Givá pelo encorajamento e pelos conhecimentos transmitidos ao longo dos 4 anos da formação. Aos meus supervisores, Prof. Doutor Meizal Popat e Eng^a Gerivásia Mosse, pelo contínuo acompanhamento e encorajamento durante a elaboração do trabalho.

ÍNDICE

DEDICATÓRIA	ii
AGRADECIMENTOS.....	iii
LISTA DE TABELAS	vi
LISTA DE FIGURAS	vii
LISTA DE ACRÓNIMOS	viii
RESUMO	ix
ABSTRACT.....	x
1. INTRODUÇÃO	1
1.1. Contextualização	1
1.1. Problema de estudo e Justificação.....	2
1.2. Objectivos.....	3
1.2.1. <i>Geral</i>	3
1.2.2. <i>Específicos</i>	3
2. REVISÃO BIBLIOGRÁFICA.....	4
2.1. Produção e consumo mundial de arroz	4
2.1.1. Exportação e Importação de arroz no mundo	5
2.2. Produção de arroz em Moçambique.....	6
2.3. Consumo/Utilização de arroz em Moçambique	9
2.4. Comercialização	10
2.5. Integração de Mercados e transmissão de preços.....	11
2.6. Estudos de Integração de mercados de arroz	18
3. METODOLOGIA	20
3.1. Especificação do modelo.....	20
3.2. Testes pré-estimativa.....	22
3.2.1. Número de defasagens.....	22
3.2.2. Teste de estacionariedade.....	22

3.2.3. Teste de cointegração	23
3.2.4. Testes de especificação	24
3.3. Testes pós-estimativa	25
3.3.1. Teste de casualidade.....	25
3.3.2. Função Impulso Resposta (FIR).....	26
3.3.3. Análise da Decomposição da Variância dos erros de previsão (ADV)	27
3.4. Mercados analisados	27
3.5. Fonte e tratamento dos dados	28
4. RESULTADOS E DISCUSSÃO	30
4.1. Estatísticas Descritivas e análise gráfica das séries de preços	30
4.2. Estacionariedade e ordem de integração das séries de preços	31
4.3. Teste de Cointegração de Johansen.....	33
4.4. Modelo de Vector de Correção de Erros (VEC)	36
4.5. Teste de Casualidade de Granger	41
4.6. Função Impulso Resposta (FIR).....	43
4.7. Análise da Decomposição da Variância dos Erros de Previsão (ADV).....	45
5. CONCLUSÃO	50
6. RECOMENDAÇÕES	51
7. REFERÊNCIAS BIBLIOGRÁFICAS	52
8. ANEXOS.....	57

LISTA DE TABELAS

Tabela 1. Principais produtores de arroz no mundo (2015-2020).....	5
Tabela 2. Principais exportadores e respectivos volumes exportados em toneladas (2017-2020)	6
Tabela 3. Variáveis do modelo.....	21
Tabela 4. Estatísticas descritivas dos preços reais de arroz (em MZN/kg).....	30
Tabela 5. Determinação de número de defasagens (lags)	32
Tabela 6. Resultados do teste de Dickey-Fuller Aumentado (ADF) em primeiras diferenças	33
Tabela 7. Resultados do teste de Phillips-Perron (PP) em primeiras diferenças	33
Tabela 8. Resultados do teste de Cointegração de Johansen (base geral).....	34
Tabela 9. Resultados do teste de cointegração de Johansen para mercados pareados	35
Tabela 10. Resultados do modelo VEC estimado	36
Tabela 11. Determinação de número de defasagens (lags)	41
Tabela 12. Resultados dos Testes de Causalidade de Granger para as séries diferenciadas.....	42
Tabela 13. Resultados do teste da ADV para o mercado de Cuamba.....	47
Tabela 14. Resultados do teste da ADV para o mercado de Nampula	47
Tabela 15. Resultados do teste da ADV para o mercado de Alto Molócuè.....	48
Tabela 16. Resultados do teste da ADV para o mercado de Beira	48
Tabela 17. Resultados do teste da ADV para o mercado de Chókwè.....	49
Tabela 18. Resultados do teste da ADV para o mercado de Maputo.....	49

LISTA DE FIGURAS

Figura 1. Evolução da produção mundial no período 2015-2020.....	4
Figura 2. Produção, área colhida e rendimento de arroz em Moçambique (2011-2020).....	7
Figura 3. Distribuição (%) da produção de arroz por Região (Fonte: IAI,2020).....	8
Figura 4. Distribuição da produção de arroz por província (Fonte: IAI 2020).....	8
Figura 5. Proporção do arroz nacional e importado (2010-2019) (Fonte: FAO, 2020).....	9
Figura 6. Evolução do Consumo per capita de arroz em Moçambique (2010-2019).....	10
Figura 7. Tendência dos preços mensais de arroz (em MZN/kg)	31

LISTA DE ACRÓNIMOS

ADF	Teste de Dickey-Fuller Aumentado
AIC	Akaike Information Criterion
ADV	Análise de Deposição de Variância
ARDL	Autoregressive Distributed Lag Models
CDD	Centro para Democracia e Desenvolvimento
CGE	Conta Geral do Estado
CIP	Centro de Integridade Pública
FAO	Food and Agriculture Organization
FIR	Função Impulso Resposta
FPE	Final Prediction Error
HQ	Hannan-Quinn Criterion
IAI	Inquerito Agrário Integrado
IIAM	Instituto de Investigação Agrária de Moçambique
IOF	Inquérito do Orçamento Familiar
IPC	Índice do Preço ao Consumidor
JICA	Agência de Cooperação Internacional Japonesa
LPU	Lei do Preço Único
MADER	Ministério da Agricultura e Desenvolvimento Rural
MASA	Ministério da Agricultura e Segurança Alimentar
MITADER	Ministério da Terra, Ambiente e Desenvolvimento Rural
PRA	Preço Real de arroz
SBC	Schwarz Bayesian Criterion
SIMA	Sistema de Informação de Mercados Agrícolas
VAR	Vector Auto-Regressivo
VEC	Vector de Correção de Erros

RESUMO

Este trabalho analisou a integração dos mercados de arroz nas regiões norte, centro e sul de Moçambique, especificamente entre os mercados de Cuamba, Nampula, Alto Molócuè, Beira, Chókwè e Maputo. O estudo utilizou séries mensais de preços médios nos mercados retalhistas, abrangendo o período de 2011 a 2020, coletadas pelo Sistema de Informação de Mercados Agrícolas (SIMA). A análise foi realizada por meio da estimativa de um modelo de Vetores Autorregressivos na forma restrita (VEC). Os resultados indicaram que, de modo geral, no curto prazo, os mercados domésticos de arroz não estavam perfeitamente integrados, uma vez que os coeficientes sugeriram uma transmissão não proporcional de preços, invalidando assim os pressupostos da Lei do Preço Único, embora houvesse integração entre os mercados da região central. Entre as regiões, destacou-se a integração entre os mercados do sul e os do centro e norte, com o mercado de Chókwè integrado ao da Beira e o de Maputo ao de Nampula. O teste de Johansen revelou a existência de três relações de longo prazo entre os preços do arroz nos seis mercados, indicando que, no longo prazo, os mercados de arroz em Moçambique estavam integrados entre si.

Palavras-chaves: Integração de mercados; transmissão de preços; arroz

ABSTRACT

This study analyzed the integration of rice markets in the northern, central, and southern regions of Mozambique, specifically among the markets of Cuamba, Nampula, Alto Molócuè, Beira, Chókwè, and Maputo. The study utilized monthly series of average retail market prices, covering the period from 2011 to 2020, collected by the Agricultural Markets Information System (SIMA). The analysis was conducted through the estimation of a Vector Error Correction Model (VECM). The results indicated that, overall, in the short term, domestic rice markets were not perfectly integrated, as the coefficients suggested a non-proportional transmission of prices, thereby invalidating the assumptions of the Law of One Price, although there was integration among the markets in the central region. Among the regions, the integration between the southern markets and those in the central and northern regions stood out, with Chókwè integrated with Beira and Maputo integrated with Nampula. The Johansen test revealed the existence of three long-term relationships among rice prices in the six markets, indicating that, in the long term, rice markets in Mozambique were integrated with each other.

Keywords: Market integration; price transmission; rice

1. INTRODUÇÃO

1.1. Contextualização

O arroz (*Oryza sativa*) é um cereal conhecido há mais de 3,000 anos AC, e é comumente aceite como de origem Asiática, concretamente da Índia (Muendane, 1999). Segundo os dados da FAO (2020), a China é o maior produtor no mundo, contribuindo com aproximadamente um terço da produção mundial. Na África, a importância do arroz vem crescendo rapidamente, sendo que actualmente é cultivado por mais de 75% dos países, e é responsável por cerca de 5% da produção mundial (Martins, 2015; FAO, 2020).

Em Moçambique, o arroz é o terceiro cereal mais consumido depois do milho e trigo, com um consumo *per capita* estimado em 40 kg em 2019 (FAO, 2020). Dados do Inquérito do Orçamento Familiar (IOF, 2019/2020) apontam que as famílias moçambicanas gastam 5.9% do seu orçamento alimentar com arroz, dos quais 3.2% nas zonas urbanas e 2.7% nas zonas rurais. Segundo o MASA (2016), em Moçambique o arroz destaca-se pelo rápido aumento da preferência pelos consumidores em relação a outros cereais, sendo que a taxa de crescimento anual do consumo é estimada em 8.6%, comparativamente ao milho (5.5%), trigo (7.4%) e mapira (4.7%). A demanda actual de arroz limpo é estimada em 576,181 toneladas, o que corresponde a um défice de pouco mais de 226,000 toneladas, custando ao país cerca de 130 milhões de dólares por ano em importações, sobretudo dos países asiáticos como a Tailândia, Vietname e Paquistão (IIAM, 2020; MITADER, 2016)

O potencial agrícola para a produção do arroz em Moçambique é estimado em cerca de 900,000 há (IIAM, 2020). O arroz é a quarta cultura mais produzida dentre as principais culturas alimentares produzidas no país, com uma produção de cerca de 137,243 toneladas em 2020, depois de mandioca (6,025,663 toneladas), milho (1,632,321 toneladas) e Batata-doce (145,387 toneladas) (IAI, 2020). Grande parte da produção de arroz no país é cultivada pelos pequenos produtores (cerca de 97.8%), e é maioritariamente voltada para a subsistência, seguindo-se os médios e grandes produtores, com 2% e 1%, respectivamente (IAI, 2020). Os rendimentos médios de arroz giram em torno de 1.2 ton/ha em sequeiro e 3.5 ton/ha em sistemas irrigados (IIAM, 2020).

Entre 2016 e 2020 o país registou uma tendência crescente na produção do arroz, sendo que a taxa de crescimento anual da produção foi estimada em aproximadamente 2.6% (FAO, 2020). No entanto, essa tendência é maioritariamente impulsionada pela expansão da área cultivada enquanto o nível de produtividade continua estagnado, com rendimento médio de cerca de 1.2 ton/ha (MADER 2020). Segundo o MASA (2016), como forma de melhorar a produtividade, o Governo tem implementado programas nacionais de produção de arroz, como é o caso do Programa Nacional da Cultura de Arroz

(2015-2019), que até 2019 previa um incremento dos rendimentos de 1.2 ton/ha para 2.6 ton/ha em sistema de sequeiro e de 3.5 ton/ha para 5 ton/ha em sistemas irrigados (IIAM, 2020).

1.1.Problema de estudo e Justificação

A integração de mercados é um importante pressuposto para um bom funcionamento de mercados, estando relacionada à influência (direta ou indireta) que um mercado exerce sobre o outro, de forma que a oferta e demanda em um afetam o preço e o volume transacionado no outro (FACKLER; GOODWIN, 2001, citados por Paulo, 2011). De acordo com Baulch (1997), citado por Popat et al (2021), uma eficiente transmissão de preços garante a redução da volatilidade dos preços das commodities e gera ganhos no comércio.

Pelo que, nas últimas duas décadas os temas integração de mercados e transmissão de preços têm atraído grande interesse por parte de analistas em vários países, e Moçambique não constitui uma exceção. De acordo com Van Campenhout (2012), há duas razões que tornam Moçambique num caso de estudo interessante: primeiro, a extensão do território nacional e a elevada densidade populacional, que tornam a provisão e manutenção de infraestruturas um problema; segundo, a guerra civil dos 16 anos que teve como consequência a recente retoma da reabilitação das estradas e dos investimentos.

Assim, diversos estudos sobre a integração de mercados e a transmissão de preços têm sido realizados em Moçambique. Exemplos notáveis incluem os trabalhos de Paulo (2011), Tostão e Brorsen (2005), Van Campenhout (2012), e Popat et al. (2021), entre outros. Grande parte desses estudos concentram sua análise no mercado de milho, justificando-se pelo facto de ser a principal cultura do país, sendo cultivada por mais de 80% dos produtores nacionais. De modo geral, esses estudos indicam que os mercados de milho em Moçambique estão longe de ser completamente integrados, e que há uma variação significativa no nível de integração entre diferentes pares de mercados em todo o país (Van Campenhout, 2012).

Entretanto, o presente estudo foca sua análise no mercado do arroz, uma cultura que se tem destacado pelo rápido aumento no seu consumo em relação aos outros cereais. No geral, estudos nesse âmbito para o arroz apontam para a existência de uma relação de cointegração entre mercados mundiais e os domésticos. Em sua análise, Minot (2010) demonstrou que a elasticidade da transmissão de preços de longo prazo entre os mercados domésticos (Chókwè, Gorongosa, Nampula e Tete) e os mercados mundiais era estatisticamente significativa, sendo que uma variação de 1% nos preços mundiais resulta em um aumento de mais 30% nos preços locais. O único mercado de arroz cujo preço não está cointegrado com o preço mundial foi Maputo.

Em seu estudo sobre a integração dos mercados nacionais (Chókwè e Maputo), produtores e consumidores, com os mercados internacionais (Tailândia), o MITADER (2016) demonstrou que os mercados de Chókwè e Tailândia não estão cointegrados a longo prazo, mas existe uma relativa integração e transmissão de preços a curto prazo entre os mercados da Tailândia e Maputo, sendo que uma variação de 1% nos preços praticados na Tailândia causa uma variação de cerca de 17% nos preços praticados em Maputo. O mesmo estudo demonstrou que apesar da proximidade entre os mercados retalhistas de Chókwè (mercado produtor) e Maputo (mercado consumidor), não existe nenhuma integração entre ambos, e os preços praticados em Chókwè não exercem influência nos preços praticados em Maputo.

Conforme demonstrado nas análises supracitadas, em geral, os estudos de integração e transmissão de preços circunscrevem suas análises no estudo da relação entre os mercados nacionais e os internacionais, e pouco se aprofundam no estudo da relação de integração entre os mercados nacionais de arroz. Assim, não obstante as importações representarem mais de 50% do consumo interno do arroz em Moçambique, existe uma significativa oferta e demanda interna que justifica um estudo aprofundado dos mercados domésticos. Pelo que, o presente estudo é uma análise da integração dos mercados domésticos do arroz em Moçambique, e contribui com literatura sobre a cadeia de valor do arroz de duas maneiras principais. Primeiro, trata-se de um estudo actualizado sobre integração do mercado interno do arroz em Moçambique. Segundo, analisa de forma mais aprofundada a relação entre os mercados produtores e consumidores do arroz, considerando simultaneamente mercados nas três regiões de Moçambique.

1.2. Objectivos

1.2.1. Geral

- ❖ Analisar a integração dos mercados de arroz entre as regiões norte, centro e sul de Moçambique

1.2.2. Específicos

- ❖ Determinar o grau de integração entre os mercados de Cuamba, Nampula, Alto Molócuè, Beira, Chókwè e Maputo;
- ❖ Descrever o sentido de casualidade de transmissão de preços entre os mercados de Cuamba, Nampula, Alto Molócuè, Beira, Chókwè e Maputo;

2. REVISÃO BIBLIOGRÁFICA

2.1. Produção e consumo mundial de arroz

O arroz é o segundo cereal mais cultivado e o principal alimento para mais da metade da população mundial (Coêlho, 2021). Em termos nutritivos, o arroz é um dos alimentos com melhor balanço nutricional, cuja composição compreende 20% da energia e 15% da proteína necessárias ao Homem (Freitas & Filho, 2006), e a sua produção massiva é um dos instrumentos para combate a fome em vários países em via de desenvolvimento (Lopes & Rocha, 2005).

O arroz é actualmente cultivado numa área mundial estimada em 163 milhões de hectares, e o seu consumo *per capita* estima-se numa média de 54kg/ano. A maior parte da produção mundial é consumida nos próprios países produtores, somente cerca de 5% do total produzido no mundo destina-se à exportação (Coêlho, 2021).

Os dados da FAO (2020) apontam que aproximadamente 90% do arroz cultivado em todo mundo é proveniente da Ásia, pelo fato de ser item básico na dieta da população, seguida da África com 4.6%, América do Sul com 3.3%, América do norte com 1.2%, e Europa e a Oceânia perfazem juntos 1% da produção mundial.

Entre 2015 e 2020 a produção mundial registou padrões diferentes de variação, tendo 2019 como o período crítico em que a produção mostrou um decréscimo de 2.9% relativamente ao ano anterior. Segundo Júnior (2019), a redução da produção em 2019 pode estar associada as incertezas quanto ao fenómeno El Niño na China e Índia, reduzindo a produção em 1% e 0.5%, respectivamente (INFOARROZ, 2019). Segundo mesma fonte, em 2019 a África registou um declínio da produção de 3% em relação à 2018, devido a insuficiência de chuvas.

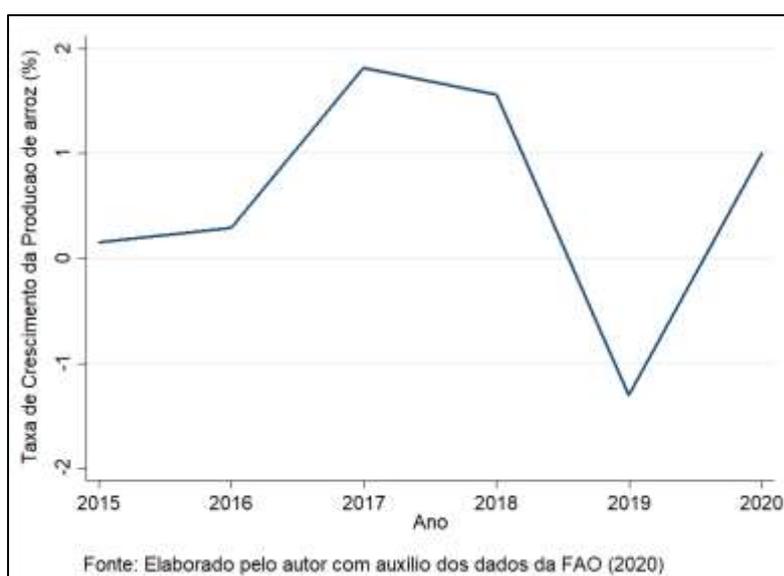


Figura 1. Evolução da produção mundial no período 2015-2020

Com base na Tabela 1 pode-se constatar que os países asiáticos lideram o ranking dos principais produtores de arroz no mundo, destacando-se a China e a Índia com os respectivos 29% e 23%, e os outros países asiáticos respondem por mais de 36% desta produção (FAO, 2020). De acordo com a mesma fonte, Brasil, Estados Unidos da América, Nigéria e outros países contribuem juntos com aproximadamente 18% da produção mundial.

Tabela 1. Principais produtores de arroz no mundo (2015-2020)

País	Produção média anual (toneladas)	Contribuição na produção mundial (%)	Taxa crescimento anual (%)	Área média cultivada ¹ (ha)
China	213,321,698.8	28.6	0.4	30,640,061.8
Índia	169,901,121.7	22.8	2.1	43,881,753.3
Indonésia	56,461,294.83	7.5	-1.1	10,933,682.7
Bangladesh	53,385,760.83	7.2	1.0	11,407,553.3
Vietname	43,544,481.5	5.8	-0.8	7,586,127.7
Tailândia	30,609,196.83	4.1	-0.7	10,339,026.7
Filipinas	18,704,867.83	2.5	0.4	4,699,145
Japão	10,579,208.33	1.4	-0.1	1,519,666.7
Paquistão	9,114,250.17	1.2	-2.0	2,923,857.8
Brasil	11,442,703	1.5	-0.9	1,891,410
Estados Unidos	9,307,988.3	1.2	2.3	1,107,501.7
Nigéria	5,186,636.17	0.7	5.5	5,027,942.2
Nepal	3,405,127.5	0.5	2.1	1,460,154.5
Outros	111,441,771.7	14.9	1.2	29,552,106.8
Mundial	746,406,107.5	100	0.6	162,969,990.2

Fonte: Elaborado pelo autor com auxílio dos dados da FAO (2020)

2.1.1. Exportação e Importação de arroz no mundo

Apesar de maior produtor no mundo, a nível do comércio internacional a China vem perdendo o seu papel de importante exportador. Por exemplo, em 2000 supriu 12.7% da necessidade mundial de arroz, e em 2005 forneceu apenas 3.9% (Paula, 2008). Segundo os dados apresentados por Coêlho

¹ Calculada através da fórmula **Taxa de crescimento da área (%) = (Valor atual da produção – Valor da área no ano anterior) / Valor da área do ano anterior x 100%**, posteriormente dividida pelo número de anos, tornando-a média.

(2021), actualmente a Índia lidera o ranking dos principais exportadores, tendo de 2017 a 2020 contribuído com mais de 25% do total exportado no mundo, e segue-se a Tailândia que no mesmo período foi responsável por mais de 15%.

Tabela 2. Principais exportadores e respectivos volumes exportados em toneladas (2017-2020)

País	2017	2018	2019	2020	Contribuição na exportação mundial (%)
Índia	12,041	10,420	12,300	12,500	26.48
Tailândia	11,056	7,562	5,500	7,000	17.44
Vietname	6,590	6,581	6,400	6,300	14.50
Paquistão	4,011	4,493	4,000	4,100	9.30
Estados Unidos	2,763	2,971	2,990	3,080	6.61
China	1,364	2,770	2,600	2,700	5.29
Burma	2,750	2,700	2,300	2,200	5.58
Camboja	1,300	1,350	1,350	1,400	3.03
Brasil	1,152	878	1,100	900	2.26
Outros	3,596	3,323	3,488	800	6.28
Mundo	47,396	43,894	42,868	44,299	100.00

Fonte: Coêlho (2021)

2.2. Produção de arroz em Moçambique

Em Moçambique o arroz é um cultivado há cerca de 500 anos, e o potencial agrícola actual para a produção é estimado em cerca de 900,000 ha (FAO, 2014; IIAM, 2020). Segundo IIAM (2020), deste potencial, apenas 310,000 ha são explorados actualmente, os quais são cultivados maioritariamente por pequenos e médios produtores (aproximadamente 90%), cuja produção é maioritariamente virada ao autoconsumo. Com uma produção de 551,181 toneladas em casca por ano e 350,000 toneladas limpo, o arroz é o segundo cereal mais produzido depois do milho, sendo que os seus rendimentos médios rondam em torno de 1.2 ton/ha em sequeiro e 3.5ton/ha em sistema irrigado (IIAM, 2020; FAO, 2014).

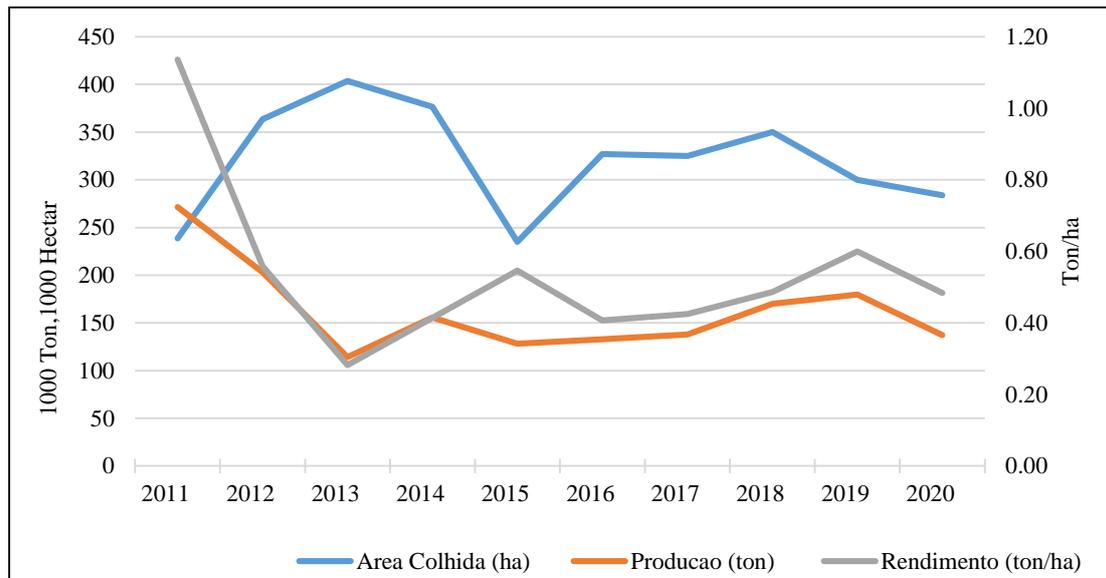


Figura 2. Produção, área colhida e rendimento de arroz em Moçambique (2011-2020).

(Fonte: FAO, 2020)

Moçambique possui condições agrícolas adequadas para produção de arroz, sendo caracterizado por uma grande variabilidade em termos de padrões de chuvas e outros factores climáticos FAO (2020). Como resultado da variabilidade das condições agro-ecológicas, a produção apresenta uma distribuição desproporcional a nível das regiões do país. Dados do IAI (2020) indicam que a região centro lidera o ranking da produção com 48%. Segundo Martins (2015), na década 2000-2010 a importância da produção foi maioritariamente atribuída às regiões centro e norte, as quais contribuíam com 62% e 31%, respectivamente, e a região sul com apenas 7%. No entanto, dados do IAI (2020) apontam que actualmente a região centro continua liderando com 48%, seguindo-se o sul com 32% e norte com aproximadamente 20%. A melhoria da importância da região sul na produção de arroz pode justificada pelo aumento da produção na província de Gaza, impulsionado pelos financiamentos feitos Governo para a manutenção das infraestruturas dos regadios de Limpopo e Chókwè, e pela implementação de projectos de produção de arroz, como é o caso do projecto Wambao em 2012 (Rosário, 2020; Abbas, 2018). O IAI (2020) demonstra que apesar do maior peso da produção ser observado no centro, a província de Gaza lidera o ranking provincial com uma produção de 55,836 toneladas, seguida da Zambézia com 42,861, Sofala com 40,719 e Nampula com 22,331 toneladas.

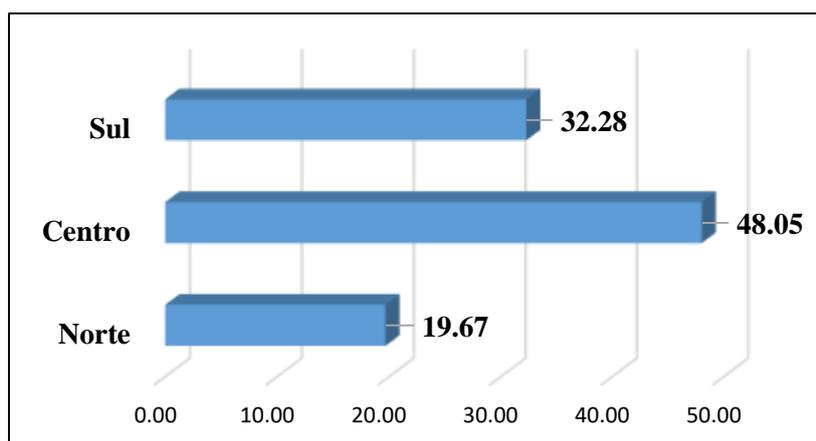


Figura 3. Distribuição (%) da produção de arroz por Região (Fonte: IAI,2020)

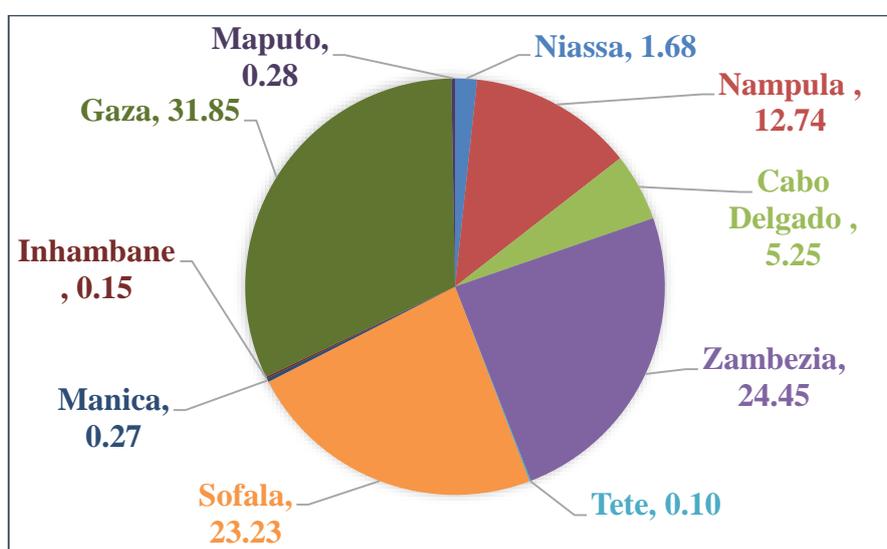


Figura 4. Distribuição da produção de arroz por província (Fonte: IAI 2020)

Apesar da posição do arroz entre as principais culturas alimentares em Moçambique e da tendência crescente da produção, o nível de produtividade continua baixo. Segundo o IAI (2020), a baixa produtividade do arroz em Moçambique está associada aos seguintes factores:

- Baixo uso de tecnologias: Semente certificada (8.7%), Fertilizantes (2.8%), Pesticidas (6.3%), Irrigação (4.3%),
- Baixo acesso ao crédito agrário (0.6%);
- Baixo acesso a infra-estruturas e serviços de apoio a comercialização que aumenta os custos de transacção (vias de acesso, armazéns, energia eléctrica, serviços financeiros);
- Fraca capacidade de gestão de água nos campos de arroz devido ao fraco nivelamento das terras/solos;
- As adversidades climáticas: inundações, cheias, seca e estiagem.

2.3. Consumo/Utilização de arroz em Moçambique

Em termos de consumo, Moçambique tem mostrado uma tendência crescente nos últimos anos, facto que pode estar associado ao aumento da população que tem vindo a se registar. Por exemplo, de 2011 a 2013 a taxa média anual de crescimento da população foi estimada em 2.7% - nesse período registou-se uma taxa de crescimento média anual de consumo de arroz de 8.5%; de 2016 a 2020 a população cresceu em uma taxa média anual estimada em 2.9%, tendo se registado uma taxa média anual de consumo de arroz de 11.7% (FAO, 2020).

O aumento da diferença entre a oferta e a procura de arroz tende a sobrecarregar as importações deste cereal (FAO, 2014). Segundo o MITADER (2016), as necessidades actuais do consumo de arroz são maioritariamente satisfeitas pelas importações, uma vez que a produção nacional não é suficiente para sustentar os mercados locais. Actualmente a demanda do arroz limpo é de 576,181 toneladas, o que corresponde a um défice de 226,000 toneladas, custando ao país cerca de 130 milhões de dólares por ano em importações, sobretudo dos países Asiáticos como a Tailândia, Vietname e Paquistão (IIAM 2020; MITADER, 2016).

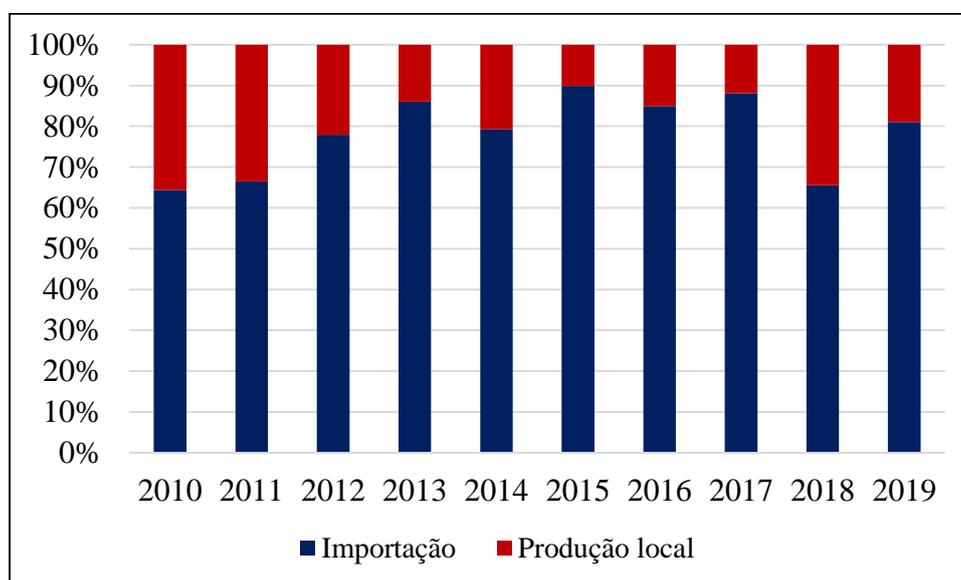


Figura 5. Proporção do arroz nacional e importado (2010-2019) (Fonte: FAO, 2020)

O arroz contribui em cerca de 10.55% do total da dieta alimentar moçambicana em termos de calorias *per capita*, e é a terceira maior fonte de calorias da dieta depois da mandioca (719 calorias/por/dia) e milho (534 calorias/pessoa/dia), (Zamdanela, 2001, citado por FAO, 2014, p.7). A Figura 6 demonstra

tendência crescente do consumo *per capita* no país, facto que pode estar associado a crescente preferência do cereal nos últimos anos MASA (2016).

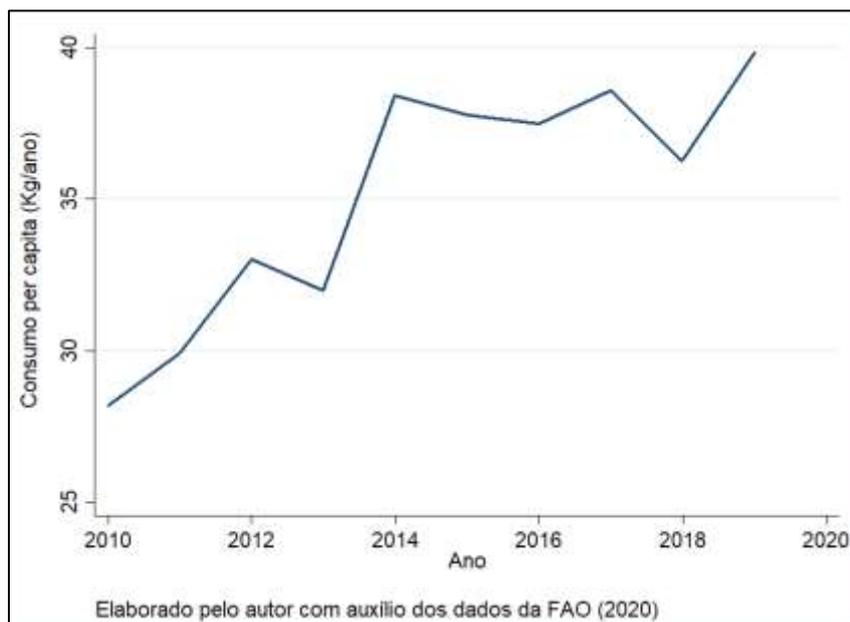


Figura 6. Evolução do Consumo per capita de arroz em Moçambique (2010-2019)

2.4. Comercialização

A produção nacional de arroz comercializada é proveniente, por um lado, da colheita obtida no sector empresarial, e por outro lado, do excedente do sector familiar (Muendane, 1999). No entanto, a produção familiar (que representa 90%) é realizada de forma dispersa e em pequenas quantidades, facto que não justifica o seu transporte para mercados maiores, regionais – isto é, o excedente familiar é plenamente vendido e consumido localmente (FAO, 2014). Assim, grande parte da produção comercializada nos grandes mercados, como é o caso da província e cidade de Maputo, é proveniente da importação. Nos últimos anos, os níveis de importação do arroz vêm aumentando, sendo que de 2015 a 2019 a taxa de crescimento anual estimou-se em 31% (FAO, 2020).

Apesar da venda pelos pequenos produtores ser efectuada localmente, tendem geralmente a receber preços baixos em relação aos grossistas e retalhistas (FAO, 2020). Segundo Zunguene (2014), a independência entre os mercados resulta na fraca transmissão da informação de preços entre os diferentes agentes da cadeia de comercialização, resultando, geralmente, na recepção de preços baixos pelos produtores quando comparados com os preços ao nível de retalhista, aumentando assim, somente os lucros dos grossistas e retalhistas.

Segundo Mosca & Abbas (2017, p.3 e 4), vários factores contribuem para a formação e variação de preços de produtos alimentares em Moçambique, incluindo o arroz, a saber:

- ❖ A procura e sua relação quantitativa com a oferta e as variações sazonais como consequência das épocas de colheita;
- ❖ As importações, principalmente para o sul do país e em especial para a cidade de Maputo.
- ❖ Os elevados custos de transporte entre o norte e centro (zonas produtoras) com o sul (zona deficitária);
- ❖ As dificuldades da circulação de bens agrícolas das zonas produtoras em consequência do estado das estradas de nível secundário e terciário;
- ❖ Dispersão e pequena escala dos produtores, o que dificulta a actuação das empresas de comercialização e a capacidade negocial dos produtores, bem como a capacidade de fornecimento de volumes elevados e de forma continuada (por exemplo no abastecimento a indústria);
- ❖ Desconhecimento das estimativas sobre as quantidades comercializadas através do comércio informal e pelos próprios produtores, sobretudo ao longo das principais estradas que conectam o meio rural aos centros urbanos;
- ❖ A baixa capacidade de armazenagem por parte dos produtores e a nível local, o que não possibilita a gestão das vendas em função dos momentos em que os preços são mais favoráveis ao produtor.

2.5. Integração de Mercados e transmissão de preços

Define-se por integração de mercados, como a medida do grau em que choques de procura e oferta que surgem em uma região são transmitidos para outra região (Fackler & Goodwin 2001, citado por Ayalew, 2018). O principal enfoque na análise da integração de mercados é o preço, pelo que Rocha (2009) define a integração de mercados como o estudo da forma como os choques de preços de um mercado são transmitidas aos preços de outros, isto é, se os preços do mercado são definidos de forma interdependente entre os mercados em análise. Vários estudos aplicam os termos integração de mercados e transmissão de preços como sinónimos. Porém, segundo Popat et al (2021, p.4), apesar de inter-relacionados, esses conceitos são diferentes. Segundo o autor, *“a transmissão de preços é considerada como uma forma de integração de mercado e, em muitos casos, os dois termos são usados de forma intercambiável”*.

A integração de mercados é medida pelo índice de preço (R_{AB}) associado a um mercado (Ayalew, 2018). Matematicamente, representa-se pela equação:

$$R_{AB} = \frac{\left| \frac{\partial P_B}{\partial \varepsilon_A} \right|}{\left| \frac{\partial P_A}{\partial \varepsilon_A} \right|} = \frac{\partial P_B}{\partial P_A} \quad (1)$$

Onde P_A e P_B são os preços de referência nas regiões A e B, respectivamente; ε_A representa o choque hipotético na região A; e ∂ representa a derivada de primeira ordem do respectivo preço em relação ao choque de mercado.

Existem três tipos de integração de mercados. Margarido, Shikida & Calvo (2018), destacam os primeiros dois tipos, nomeadamente: a integração vertical e a integração espacial. O primeiro caso descreve como os choques de preços são transmitidos ao longo da mesma cadeia de valor dentro de um mesmo mercado, e de acordo com Ayalew (2018), neste caso, a integração de mercado é geralmente medida entre os preços da matéria-prima e do produto final. O segundo caso descreve como os choques de preços são transmitidos ao longo da mesma cadeia de valor, porém, em diferentes mercados. Ayalew (2018) aponta a existência de um terceiro tipo da integração de mercados, o qual consiste em analisar a transmissão dos choques de preços envolvendo duas *commodities* diferentes. Diferentes factores podem impulsionar a ocorrência do processo de transmissão dos choques de preços entre mercados. Segundo Graef (2017) existem pelo menos seis factores, nomeadamente: os custos de transacção e transporte; poder de mercado; rendimentos crescentes de escala de produção; diferenciação e homogeneidade do produto; taxa de câmbio; e políticas alfandegárias e internas. O conceito de integração de mercados pressupõe *a priori*, uma situação em que os mercados em análise partilham alguma relação comercial (Ayalew, 2018; Graef, 2017). No entanto, segundo Fackler & Goodwin (2001), citado por Graef (2017), a transmissão de preços pode ocorrer mesmo que dois mercados (A e B, por exemplo) não estejam directamente ligados por meio do comércio, mas ambos estejam directamente conectados no comércio por um terceiro mercado comum (C).

A análise da integração de mercados é baseada em dois conceitos chave, a Lei do Preço Único (LPU) e a Arbitragem Espacial (Listorti & Esposti, 2012; Graef, 2017; Ayalew, 2018). A LPU estabelece que, numa condição em que o produto é homogéneo entre mercados espacialmente separados e ligados por comércio e arbitragem, considerando a inexistência de custos de transporte ou outras barreiras comerciais, o preço será comum e único (quando expresso na mesma moeda) (Ghoshray, 2011; Listorti & Esposti, 2012). No entanto, apesar do papel da LPU de fundamentar os métodos da análise de integração de mercados, Listorti & Esposti (2012, p.84) demonstram que os seus pressupostos são restritivos e improváveis de se concretizar na prática, expondo a sua validade universal em questionamento.

Ainda Listorti & Esposti (2012), apontam que a problemática anterior da LPU está associada aos seguintes factores: i) na prática os processos económicos são maioritariamente dinâmicos e passíveis de desvios temporários do equilíbrio, ao passo que a LPU é um conceito que exhibe processos estáticos; ii) a assunção do equilíbrio dos preços não é realista, pois muitos factores podem impedir a convergência dos preços; e iii) a LPU pode ser limitada por factores como políticas de regulamentação doméstica e de fronteira, poder do mercado, heterogeneidade e perecibilidade do produto, fluxo imperfeito de informações e expectativas.

Segundo Ayalew (2018, 15), “a efectividade de cada um desses factores depende da natureza do tipo de integração de mercado e algumas outras situações socioeconómicas e políticas. Por exemplo, os países em desenvolvimento são frequentemente caracterizados por infra-estruturas precárias, comércio ineficiente mecanismos e ambientes políticos instáveis que dificultam a integração do mercado”.

Assim, em alternativa à Lei do Preço Único, aplica-se o conceito da arbitragem espacial (Popat et al., 2021). A arbitragem espacial é uma condição em que os comerciantes buscam obter lucro transportando produtos de mercados com preços baixos para os mercados com preços altos, baseando-se na situação em que a diferença de preço entre os mercados excede os custos marginais de transporte e maneo (Chaves, 2011). Consequentemente, a arbitragem espacial ocasiona o aumento do preço nos mercados com preços baixos e a redução nos mercados de preços altos, até que a diferença de preços seja reduzida ao custo marginal de transporte (Graef, 2017).

A Lei do Preço Único e a Arbitragem Espacial (também chamada de LPU fraco) são descritas pelas seguintes equações, respectivamente (Ayalew, 2018; Popat et al., 2021):

$$P_i + r_{ij} = P_j \quad (2)$$

$$P_j - P_i \leq r_{ij} \quad (2.1)$$

Onde: P_i e P_j são os preços da mercadoria nos mercados i e j , respectivamente; r_{ij} representa o custo para a transferência da mercadoria do mercado i para o j .

Os métodos para a análise da integração de mercados podem ser agrupados nos seguintes tipos: análise de correlação, modelos regressão estática e dinâmica e o modelo de limite de paridade (Ayalew, 2018; Popat et al., 2021; Abdulai, 2000). Desses métodos, os modelos de regressão dinâmica são os mais utilizados porque permitem representar as relações de preços desfasados e consideram a endogeneidade dos mesmos ao modelo. Segundo Popat et al (2021), os modelos de regressão dinâmica são em sua maioria fundamentados em modelos Auto-regressivos de Desfasagens Distribuídas (ARDL).

Os modelos ARDL tem como objectivo verificar a existência de elasticidades de curto e longo prazo, independentemente da sua ordem de integração (Lopes, 2014). Segundo Souza & Veríssimo (2021) e Queiroz & Vieira (2019), comparativamente aos outros modelos de cointegração, os modelos ARDL apresentam algumas vantagens, a saber: i) são eficientes para capturar relações de longo prazo em amostras menores de dados; ii) possuem capacidade de seleccionar as melhores desfasagens para cada uma das variáveis incluídas nos modelos; e iii) podem ser aplicados tanto para conjunto de variáveis estacionárias I (0), não estacionários I (1), assim como as mutuamente cointegradas.

Um caso dos modelos ARDL é o modelo vector auto-regressivo (VAR). Proposto por Sims (1980), o modelo VAR consiste em capturar relações dinâmicas entre variáveis endógenas conjuntas sem que haja imposição, *a priori*, de restrições como a selecção de variáveis exógenas do modelo (Margarido, 2000). Segundo Block, Coronel & Veloso (2012, p.6), no modelo VAR cada variável é explicada por seus próprios valores desfasados e pelos valores desfasados de outras variáveis do sistema, e este permite a estimativa de elasticidades de impulso para p períodos à frente, possibilitando a avaliação do comportamento das variáveis em resposta a choques em quaisquer dos componentes do sistema. De acordo com Margarido (2000), o modelo VAR pode ser reescrito na sua forma restrita em modelo de vector de correcção de erro (VEC), ou seja, o modelo VEC é a forma especial do VAR. Segundo mesmo autor, a modelação do VAR na forma de um VEC permite a incorporação de informações tanto de curto prazo assim como de longo prazo. O modelo VEC é apropriado para o caso em que as séries não são estacionárias I (1) ou são cointegradas (Queiroz & Vieira, 2019).

A estimativa dos modelos VAR e VEC é concretizada mediante a realização de testes, cuja finalidade é validar os resultados do modelo especificado. Segundo Popat et al (2021) e Hill, Griffiths, & Lim (2012), os testes para a validação do modelo podem ser realizados em duas fases, nomeadamente, a fase pré-estimativa ao modelo e a fase pós-estimativa ao modelo.

1) Testes pré-estimativa

Os testes da fase pré-estimativa são os procedimentos que antecedem a estimativa do modelo, e resultam em informações necessários para a posterior especificação do modelo. Incluem os testes para determinação do número de desfasagens, e os testes de estacionariedade da série em estudo (Gonçalves, 2011; Popat et al (2021)). As séries temporais económicas, em sua grande maioria, se caracterizam por serem não estacionárias, levando a um problema de regressão espúria, ou seja, ao fazer uma regressão de uma variável de série temporal sobre outra variável de série temporal, pode-se obter um coeficiente de determinação (R^2) bem alto, mesmo não havendo uma relação significativa

entre as variáveis (Gujarati & Porter, 2011). Assim, para evitar o problema da regressão espúria, os mesmos autores, propõem que o teste de cointegração seja considerado nesta fase.

A. Número de defasagens

Tanto o modelo VAR assim como VEC examinam as relações lineares entre cada variável e os valores defasados dela própria e de todas as demais variáveis. Assim, torna-se necessário determinar o número de defasagens das variáveis envolvidas no modelo. De acordo com EISFELD et al., (2007, p.6), é desejável incluir o maior número possível de defasagens, de modo a evitar a imposição de restrições falsas sobre a dinâmica do modelo.

A determinação do número de defasagens do modelo VAR pode ser feita através de critérios de informação, tais como: Akaike Information Criterion (AIC), Final Prediction Error (FPE), Schwarz Bayesian Criterion (SBC) e Hannan-Quinn Criterion (HQ) (Gonçalves, 2011, p.6). Vários estudos recorrem aos critérios de SBC e HQ devido a sua maior consistência, e capacidade de escolher correctamente a ordem em grandes amostras (Lütkepohl, 2005)

B. Testes de estacionariedade

De acordo com Einfeld et al., (2007), a condição fundamental para a aplicação do modelo VAR é que a série temporal estudada seja estacionária, ou seja, não apresente tendência ou sazonalidade. Uma série temporal é dita estacionária se sua média e variância forem constantes ao longo do tempo e o valor da covariância entre os dois períodos de tempo depender apenas da distância, do intervalo ou defasagem entre os dois períodos e não o tempo real ao qual a covariância é computada (Gujarati & Porter, 2011).

Inicialmente a estacionariedade de uma série temporal pode ser feita de forma intuitiva através do teste da análise gráfica da mesma. Segundo Gujarati & Porter (2011), através do comportamento da média (nos gráficos) ao longo do tempo pode-se perceber indícios de uma provável natureza estacionária das séries temporais. Entretanto, segundo os mesmos autores, para que se certifique a estacionariedade, a análise gráfica deve ser combinada com testes formais.

Existem vários testes para a verificação da estacionariedade de uma série temporal, mas nos últimos anos tem se atribuído especial atenção ao teste de raiz unitária. O teste de raiz unitária consiste em determinar a ordem de integração das variáveis envolvidas no modelo, ou seja, o número de vezes em que uma determinada série precisa ser diferenciada para tornar estacionária (Margarido & Anfalos 1999, p. 21). Contudo, o teste de raiz unitária pode ser efectivado através dos testes de Dickey Fuller (DF); Augmented Dickey Fuller (ADF) e Phillips-Perron (PP).

O teste de Dickey Fuller (DF) consiste em testar a hipótese da presença ou não de uma raiz unitária, mediante a qual detecta-se se uma série temporal é ou não estacionária (Gujarati & Porter 2011). Este teste apresenta-se nas suas três formas, a saber: i) Quando a variável endógena é um passeio aleatório²; Quando a variável endógena é um passeio aleatório com deslocamento; e Quando a variável endógena é um passeio aleatório com deslocamento em torno de uma tendência determinística. O teste de DF é aplicado numa situação em que o termo erro é não correlacionado, entretanto, nos casos em o termo erro é correlacionado aplica-se o teste de Dickey-Fuller aumentado (DFA) (Gujarati & Porter, 2011). Segundo os mesmos autores, enquanto, por um lado, os testes de DF e ADF são aplicados para tratar de possíveis correlações seriais nos termos de erro ao adicionar os termos de diferença desfasados da variável dependente, por outro lado, aplica-se o teste de Phillips-Perron (PP) para tratar da correlação serial nos termos de erro sem adicionar os termos de diferença desfasados através dos métodos estatísticos não paramétricos.

A. Teste de cointegração

A cointegração tem como finalidade determinar o número de vectores de cointegração que serão necessários no sistema, fornecendo informações sobre a existência do relacionamento de longo prazo (Eisfeld et al., 2007). Esta condição é testada através do procedimento de Johansen (1988), a qual propõe um procedimento que utiliza a máxima verossimilhança para estimar os vectores de cointegração, além de verificar a presença de diversos vectores e não apenas um único vector” (Johansen e Juselius, 1990, citados por Graef, 2017, p.56). A partir do teste de Johansen é possível testar a significância dos parâmetros que constituem os vectores de cointegração, o que é relevante para identificar a existência ou não da transmissão de preços entre mercados (Coelho, 2002). O teste de cointegração de Johansen é estimado através da estatística de traço e de máximo autovalor, determinados com base no teste de significância nas raízes características ou autovalores da matriz cointegrante.

2) Testes pós-estimativa

Como o próprio nome sugere, estes testes são realizados logo após a especificação do modelo. No entanto, a validação dos resultados destes testes só é garantida sob a condição da realização do teste das propriedades dos resíduos, nomeadamente, a independência, normalidade, homoscedasticidade e a autocorrelação (Popat et al, 2021). Posto isso, procede-se com os propriamente ditos testes pós-

² Segundo Gujarati & Porter (2011) o termo passeio aleatório é muitas vezes comparado com um caminhar de bêbado. Deixando um bar, o bêbado move-se numa distância aleatória ut no tempo t, e, continuando a caminhar indefinidamente, eventualmente se desviará cada vez mais do bar. O mesmo é dito sobre os preços das acções. O preço da acção de hoje é igual ao de ontem mais um choque aleatório.

estimativa, os quais incluem o teste de Cointegração, teste de causalidade, Função Impulso-Resposta e Decomposição da Variância dos Erros de Previsão.

A. Teste de causalidade de Granger

O teste de cointegração é a condição para a realização do teste de casualidade. De acordo com Gujarati & Porter (2011), antes do teste de casualidade, primeiro deve-se descobrir as variáveis são cointegradas. Graef (2017, p.55), *“o conceito que envolve o teste explica que o futuro não é a causa do passado nem do presente, ou seja, se o evento A ocorre posteriormente a B, logo B não pode causar A. No entanto, se A ocorre antes que B, não necessariamente o evento A causou B. Assim, o teste tem a intenção de mostrar se uma determinada variável pode melhorar a previsão de outra variável”*. O teste de casualidade é feito através do procedimento proposto por Granger (1969). Segundo Brooks (2008), o teste de casualidade permite verificar se as defasagens de uma variável entram como repressores na equação de outra variável e se são estatisticamente significativas, logo, reduz a arbitrariedade da escolha da ordenação causal das variáveis, já que utiliza métodos estatísticos. A cointegração entre duas séries temporais de preços implica causalidade de Granger em pelo menos uma direção, sendo o contrário não necessariamente verdadeiro (Rapsomanikis, Hallam e Conforti, 2003, citados por Graef, 2017).

B. Função impulso resposta e decomposição da variância

Pelo teste de casualidade torna-se possível estimar qual variável determina o efeito de outras variáveis no modelo VAR, no entanto, não permite estimar que tipo de comportamento resulta da casualidade exercida. Para o efeito, recorre-se à análise da função impulso resposta (FIR) e da decomposição de variância. Segundo Brooks (2008), os testes da função impulso resposta e da decomposição de variância permitem estimar o sinal da relação entre as variáveis e/ou o tempo que dura o efeito de cada choque nas variáveis, isto é, se mudanças em uma variável tem impactos negativos ou positivos nas demais, e o tempo que o efeito leva para ser incorporado.

Mayorga et al., (2007) classificam as séries do modelo VAR em variáveis incluídas e variáveis residuais. Segundo os autores, com a função impulso resposta delinea-se o comportamento das séries incluídas no modelo VAR em resposta a choques ou mudanças provocadas por variáveis residuais. Por outro lado, a análise da decomposição de variância mostra a proporção (%) do erro da variância prevista atribuída aos choques de uma determinada variável em relação aos choques nas outras variáveis do modelo VAR (Gonçalves, 2011, p.12).

2.6. Estudos de Integração de mercados de arroz

Estudos referentes à integração de mercados e transmissão de preços têm ganhado grande atenção nos últimos tempos, especialmente para *commodities* agrícolas. Em Moçambique, por exemplo, vários estudos dessa natureza foram realizados, com maior enfoque para o mercado do milho, dado que é a principal cultura mais produzida e consumida do país. Segundo Graef (2017), os resultados destes estudos têm fundamentado políticas no sentido de intervenção governamental, bem como de acções no sector privado, uma vez que através da integração de mercados pode-se visualizar a eficiência dos mercados através da interdependência dos agentes económicos no que diz respeito ao repasse de informações consistentes sobre preços e movimentação do produto ao longo da cadeia de valor.

Ghafoor & Aslam (2012) analisaram a integração espacial do mercado entre os principais mercados de arroz no Paquistão e a transmissão de preços de dois mercados internacionais de arroz, a saber: EUA e Tailândia. Neste estudo, os autores serviram-se da abordagem de cointegração de Johansen e do mecanismo de correcção de erros foram para analisar os dados para o período de Janeiro de 2000 a Dezembro de 2009. A análise dos dados revelou que os cinco principais mercados de arroz do Paquistão (viz. Lahore, Faisalabad, Sargodha e Multan) foram integrados entre si. O vector de ajuste medido através do Mecanismo de Correcção de Erros mostrou que são necessários quase 4-5 meses para ajustar qualquer choque de curto prazo nos mercados de arroz do Paquistão. No caso de transmissão de preços dos mercados internacionais para os mercados domésticos de arroz do Paquistão, verificou-se que não houve cointegração, facto que pode ser justificado pelo fato de o próprio Paquistão ser um grande exportador de arroz e depender menos dos mercados internacionais para formação de preços em seus mercados domésticos de arroz.

Em seu estudo sobre a integração de mercado e transmissão de preços na Índia, Acharya et al (2012) analisou uma amostra de cinco grandes mercados grossistas, cinco mercados retalhistas e oito mercados grossistas primários de arroz. O estudo concluiu que os preços analisados na primeira diferença foram integrados quando a tendência linear foi excluída do teste de raiz unitária e havia, em geral, uma relação de equilíbrio de longo prazo nos mercados domésticos de arroz. Verificou-se a integração mesmo entre os mercados grossistas de arroz geograficamente dispersos. Os preços do arroz em diferentes mercados grossistas convergiam no longo prazo. A velocidade de ajuste, no entanto, variava entre diferentes pares de mercado. E no curto prazo, os mercados grossistas de arroz estavam bem integrados e as mudanças de preços eram transmitidas contemporaneamente, embora não totalmente. Os mercados retalhistas de arroz apresentam quase o mesmo padrão de integração que os mercados grossistas.

Em Moçambique, o MITADER (2016) realizou um estudo de integração de mercados, cujo objectivo consistia em analisar a integração dos mercados nacionais, produtores e consumidores de arroz e milho, com os mercados internacionais, nomeadamente África do Sul (milho) e Tailândia (arroz). O estudo demonstrou que para o caso do arroz os mercados retalhistas de Maputo, retalhista de Chókwè e o mercado da Tailândia não estão cointegrados a longo prazo. No entanto, referiu que existe uma integração e transmissão de preços a curto prazo entre os mercados da Tailândia e o mercado retalhista de Maputo. Demonstrou também que apesar da proximidade entre os mercados retalhistas de Chókwè (mercado produtor) e Maputo (mercado consumidor), não existiu nenhuma integração entre ambos, e os preços praticados em Chókwè não exerciam influência nos preços praticados em Maputo.

Em sua análise, Minot (2010) demonstrou que a elasticidade da transmissão de preços de longo prazo entre os mercados domésticos (Chókwè, Gorongosa, Nampula e Tete) e os mercados mundiais era estatisticamente significativa, sendo que uma variação de 1% nos preços mundiais resulta em um aumento de mais 30% nos preços locais. O único mercado de arroz cujo preço não está cointegrado com o preço mundial foi Maputo.

3. METODOLOGIA

Esta secção apresenta a descrição dos dados utilizados e os principais métodos aplicados para a sua análise, com vista a responder aos objectivos do estudo. Primeiro, foi apresentado o modelo econométrico; segundo, os principais testes utilizados para validação do modelo especificado; e finalmente, foram apresentadas as principais fontes dos dados e os diferentes mecanismos de análise.

3.1. Especificação do modelo

Inicialmente, foi estimado um modelo vector auto-regressivo de ordem p na forma de vectores de correcção de erros (VEC) para as variáveis do estudo, especificado pela equação seguinte:

$$\Delta x_t = \Gamma_0 + \Gamma x_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta x_{t-i} + \sum_{j=1}^J \pi_j \Delta Y_{j,t} + \varepsilon_t \quad (3)$$

Onde: $\Gamma = -(I - A_1 - A_2 - \dots - A_i)$, ($i = 1, \dots, k - 1$) e $\Gamma_i = -(I - A_1 - A_2 - \dots - A_j)$

- ❖ $x_t = (n \times 1)$ é o vector das variáveis endógenas (mercados) no período t ;
- ❖ $\Delta x_{t-i} = (n \times 1)$ é o vector x_{t-i} nas primeiras diferenças;
- ❖ p é a ordem da defasagem;
- ❖ $\Gamma_0 = (n \times 1)$ vector do intercepto;
- ❖ Γ é a matriz rank³, que permite determinar a presença de cointegração;
- ❖ $A = (n \times n)$ matrizes dos parâmetros desconhecidos para os regressores endógenos;
- ❖ $I = (n \times n)$ representa a matriz de identidade;
- ❖ $\pi = (J \times J)$ vector dos parâmetros desconhecidos para os regressores exógenos (*dummies*);
- ❖ $\Delta Y_{t-j} = (J \times J)$ matrizes das variáveis exógenas, *dummies* sazonais, *dummies* de intervenção, ou qualquer outro tipo de regressor que são considerados fixos e não-estocásticos;
- ❖ $\varepsilon_t = (n \times 1)$ vetor do termo de erro de ruído branco (assumido como independente e identicamente distribuído com média zero e matriz de variância $\sum \varepsilon$).

³ $\Gamma = \alpha\beta$, onde α representa a velocidade de ajustamento dos parâmetros da matriz no curto prazo; e β é a matriz de coeficientes de cointegração de longo prazo. Na equação é também embutido um termo $\beta'_{x_{t-i}}$, que representa $n - 1$ relações de cointegração no modelo multivariado assegurando, desta forma, que x_t converge para uma solução de equilíbrio no longo prazo.

Tabela 3. Variáveis do modelo

Variável	Descrição
x_1	Log do preço (real) do arroz (retalhista) para mercado de Cuamba (Região norte)
x_2	Log do preço (real) do arroz (retalhista) para mercado de Nampula (Região norte)
x_3	Log do preço (real) do arroz (retalhista) para mercado de Alto Molócuè (Região centro)
x_4	Log do preço (real) do arroz (retalhista) para mercado de Beira (Região centro)
x_5	Log do preço (real) do arroz (retalhista) para mercado de Chókwè (Região sul)
x_6	Log do preço (real) do arroz (retalhista) para mercado de Maputo (Região sul)
Y_1	Dummy para a dívida pública do governo ($Y_1 = 1$ desde Abril de 2015 e $Y_1 = 0$ caso contrário)
Y_2	Dummy para COVID-19 ($Y_2 = 1$ desde Março de 2020 e $Y_2 = 0$ caso contrário)
S_{1-11}	Dummies sazonais (Janeiro a Novembro). S é subconjunto de Y

A especificação do modelo VAR na forma de vectores de correcção de erros (VEC) deveu-se às seguintes razões: primeiro, nesta forma permite analisar tanto regressores estacionários I (0), não estacionários I (1) ou mutuamente cointegrados, pois de acordo com Listorti & Esposti (2012), as séries de *commodities* agrícolas são frequentemente não estacionárias; segundo, o estudo pretende capturar as relações de curto e longo prazo, e segundo Souza & Veríssimo (2021) o modelo VEC é apropriado para esse fim; e terceiro, é um modelo com uma exigência relativamente baixa de dados (Popat et al., 2021).

O modelo VEC é amplamente aplicado em estudos sobre integração de mercados, tanto no contexto nacional, assim como internacional. Por exemplo, a nível nacional, pode-se destacar estudos como os de Zunguene (2018), Popat et al (2021), Macamo (2018), e outros. A nível internacional, pode-se destacar os estudos de Ayalew (2018), Graef (2017), Barbosa, Margarido & Junior (2002), Souza & Veríssimo (2021), Queiroz & Vieira (2019), e muitos outros.

De forma geral, a estimação do modelo VEC seguiu as seguintes etapas:

- 1º. Estimativa dos pré-testes da série, a saber: testes para determinação do número de defasagens, teste de estacionariedade da série e o teste de cointegração;
- 2º. Modelo estimado;

- 3°. Estimativa dos testes de especificação com vista a determinar as propriedades dos resíduos (Autocorrelação e normalidade dos resíduos, e estabilidade do modelo);
- 4°. Estimativa dos testes pós-estimativa, que incluem o teste de casualidade, Função Impulso Resposta (FIR) e Decomposição da Variância.

3.2. Testes pré-estimativa

3.2.1. Número de defasagens

A estimativa do modelo VEC requer a determinação da ordem de defasagens adequada. Assim, para este estudo utilizaram-se principalmente os critérios de Schwarz Bayesian Criterion (SBC) e Hannan-Quinn Criterion (HQ), devido a sua maior consistência em relação aos outros, como descrito por Lütkepohl (2005). Estes critérios de informação são descritos pelas equações 5 e 6.

Para o Critério de Schwarz Bayesian (SC):

$$SBC_p = \ln\sigma^2 + n \frac{\ln T}{T} \quad (4)$$

Onde σ^2 é a variância, T é o número de parâmetros a serem estimados e n é o número de observações da amostra.

Para o critério de Hannan-Quinn (HQ):

$$HQ = \ln(\sigma^2) + \frac{n^2 \ln[\ln(T)]}{T} \quad (5)$$

3.2.2. Teste de estacionariedade

Como base para a estimativa do modelo VEC, realizou-se o teste de estacionariedade, cuja finalidade foi verificar se a série temporal em análise é estacionária ou não, ou seja, não apresenta tendência ou sazonalidade. Para tal, efectuou-se primeiramente uma análise intuitiva dos gráficos de tempo da série. Segundo Eisfeld et al (2007), a análise do gráfico de tempo pode indicar a presença de tendência ou alteração na variância, o que revelaria se a série é ou não estacionária.

No entanto, para efectivar-se o teste de estacionariedade das séries, a análise intuitiva anterior foi combinada com alguns testes estatísticos, os testes de raiz unitária, concretamente, procedimentos Dickey-Fuller Aumentado (DFA) e o Phillips-Perron (PP). O teste foi feito inicialmente para variáveis de níveis, e posteriormente para variáveis em primeira diferença. A equação 4 define os

testes de raiz unitária para os preços de arroz, onde α e T representam o termo constante e tendência, respectivamente. O teste foi efectuado com três modelos para cada procedimento, i) modelo com tendência e constante; ii) modelo apenas com intercepto; e iii) modelo sem intercepto e sem tendência.

$$\Delta X_t = \alpha + \gamma T + \delta X_{t-1} + \sum_{i=1}^k \beta_i \Delta X_{t-1} + U_t \quad (6)$$

A equação 4 pode ser dissociada para os três modelos como descrito nas equações 4.1, 4.2 e 4.3.

➤ Modelo sem intercepto e sem tendência: $\Delta X_t = \delta X_{t-1} + u_t$ (6.1)

➤ Modelo com intercepto e sem tendência: $\Delta X_t = \beta_1 + \delta X_{t-1} + u_t$ (6.2)

➤ Modelo com intercepto e com tendência: $\Delta X_t = \beta_1 + \beta_2 \delta X_{t-1} + u_t$ (6.3)

Compara-se o valor da estatística τ com valores tabelados para servir de suporte à tomada de decisão. Nesse estudo adoptou-se o nível de significância de 5%.

Hipóteses testadas:

- ❖ **H0:** $\delta = 0$ (possui raiz unitária ou a série temporal é não estacionária, ou ela possui uma tendência estocástica).
- ❖ **Ha:** $\delta < 0$ (não possui raiz unitária ou a série temporal é estacionária, possivelmente em torno de uma tendência determinística).

3.2.3. Teste de cointegração

Uma vez provada a estacionariedade das séries em estudo, procedeu-se com o teste de cointegração de Johansen, que consistiu em determinar o número de vectores de cointegração entre as variáveis do modelo VEC. O teste de Johansen é baseado em dois testes de razão de verossimilhança, testes de traço e de máximo autovalor, descritas pelas equações 7 e 8.

1) Estatística de traço:

$$\lambda_{\text{traço}} = -2 \ln Q = -T \sum_{i=r+1}^P \ln(1 - \lambda_i) \quad (7)$$

2) Estatística de máximo autovalor:

$$\lambda_{\text{max}} = -2 \ln(Q: r | r + 1) = -T \ln(1 - \lambda_{r+1}) \quad (8)$$

Onde T representa o número de observações, $r = 0, 1, \dots, n - 1$; λ_i e λ_{r+1} indicam as raízes características obtidas da matriz e representam os vectores de correcção de erros;

$$Q = \frac{\text{função de verossimilhança restrita maximizada}}{\text{função de verossimilhança sem restrição maximizada}}$$

Hipóteses testadas:

❖ Para estatística do traço:

$$\mathbf{H}_0: r \leq r_0; \mathbf{H}_a: r > r_0$$

❖ Para estatística do máximo autovalor:

$$\mathbf{H}_0: r = r_0; \mathbf{H}_a: r = r_0 + 1$$

3.2.4. Testes de especificação

Como parte da especificação do modelo, nesta secção foi feita a análise das propriedades dos resíduos, cujo objectivo, por um lado, consistiu em validar os resultados do modelo especificado, e por outro lado, a obtenção de resultados consistentes e testes pós-estimativa validos”. Para esse efeito, foi realizado o teste autocorrelação dos resíduos através do procedimento de Multiplicador de Lagrange (LM), teste de normalidade dos resíduos através do procedimento de Jarque-Bera (JB), e o teste de estabilidade do modelo – interpretado graficamente.

O teste de LM é descrito pela seguinte expressão analítica:

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_p u_{t-p} + \varepsilon_t \quad (9)$$

Onde u_{t-p} são os valores desfasados dos resíduos anteriores; ε_t são os novos resíduos

Hipóteses testadas

O teste LM tem como hipótese nula, a ausência de autocorrelação nos resíduos. Se rejeitada a hipótese nula, estima-se um VEC de ordem maior, até que autocorrelação seja eliminada.

$$\mathbf{H}_0: \rho_1 = \rho_2 = \dots = \rho_p = 0$$

$$\mathbf{H}_a: \rho_1 \neq \rho_2 \neq \dots \neq \rho_p \neq 0$$

O teste de JB é descrito pela seguinte expressão analítica:

$$JB = \frac{T}{6} \left[S^2 + \frac{(K - 3)^2}{4} \right] \sim X^2_{(\alpha,2)} \quad (10)$$

Onde JB é o valor do Jarque-Bera; T é o número de observações; S denota o valor de skewness; e K – 3 é o excesso de kurtosis.

Hipóteses testadas

H₀: Os resíduos seguem uma distribuição normal; **H_a:** Os resíduos não seguem uma distribuição normal.

3.3. Testes pós-estimativa

Tendo sido validados os resultados do modelo (equação 10), procedeu-se com os testes pós-estimativa com vista a se avaliar a adequação ou estabilidade do modelo VEC estimado. Esses testes, incluem o teste de causalidade de Granger, função impulso resposta e decomposição de variância.

3.3.1. Teste de causalidade

Desenvolvido a partir dos conceitos de Granger (1969) e Sims (1972), o teste de causalidade permite verificar se as defasagens de uma variável entram como repressoras na equação de outra variável e se são estatisticamente significativas (Brooks, 2008). O teste de causalidade foi feito através do procedimento de Granger, tendo sido estimado através das seguintes equações:

$$X_{it} = \gamma_0 + \sum_{k=1}^n \alpha_{ik} X_{it-k} + \sum_{j=1}^n \beta_{jk} X_{jt-k} + u_{1t} \quad (11)$$

$$X_{jt} = \varphi_0 + \sum_{i=1}^m \lambda_{ik} X_{jt-k} + \sum_{j=1}^m \delta_{jk} X_{it-k} + u_{2t} \quad (12)$$

Onde:

- ❖ X_{it} – é o preço do arroz no mercado i no período t;
- ❖ X_{jt} – é o preço do arroz no mercado j no período t;
- ❖ γ_0 e φ_0 – indicam os interceptos;
- ❖ α_{ik} , β_{jk} , λ_{ik} e δ_{jk} – são os parâmetros estimados da variável preço desfasado para os mercados i e j;
- ❖ u_{1t} e u_{2t} – são termos erro.

O teste tem como objectivo verificar:

- (i) X_1 causa Granger X_2 : defasagens em X_1 devem ser significativas nas equações de X_2 . Tem-se a **causalidade unidireccional** de X_1 para X_2 ;
- (ii) X_2 causa Granger X_1 : defasagens em X_2 devem ser significativas nas equações de X_1 . Tem-se uma **causalidade unidireccional** de X_2 para X_1 ;
- (iii) X_1 causa Granger X_2 e vice-versa: ambos os conjuntos são significativos, caracterizando uma **causalidade bidireccional**;
- (iv) X_1 e X_2 ocorrem simultaneamente: nenhuma defasagem é estatisticamente significativa, as variáveis são, portanto, **independentes**;
- (v) X_1 causa Granger X_2 , mas o contrário não é válido: X_1 é exógena a X_2 .

❖ Para a equação 11

$$\mathbf{H}_0: \beta_{jk} = 0$$

$$\mathbf{H}_a: \beta_{jk} \neq 0$$

❖ Para a equação 12

$$\mathbf{H}_0: \delta_{jk} = 0$$

$$\mathbf{H}_a: \delta_{jk} \neq 0$$

3.3.2. Função Impulso Resposta (FIR)

A FIR demonstra a capacidade de resposta das variáveis dependentes aos choques (Gonçalves, 2011). Para a concretização do procedimento, considerou-se um choque unitário ao erro para cada variável de cada equação, sendo verificados os choques sobre o modelo VEC ao longo do tempo. Assim, o total de respostas ao impulso é igual a g^2 , em que g é o número de variáveis. Segundo Gonçalves (2011), considerando um sistema estável, o choque vai desaparecendo gradualmente.

Considerando a estacionariedade das séries a FIR foi estimado com base na equação:

$$X_{it} = \mu + \sum_{i=0}^{\infty} \phi_i \varepsilon_{t-i} \quad (13)$$

Onde:

- ❖ X_{it} – são os preços do arroz no periodo t no mercado i ;
- ❖ μ – é a média de longo prazo;
- ❖ ϕ - representa os coeficientes da FIR usados para medir os efeitos dos choques sobre a trajectória temporal das séries X_{it} e X_{jt} do modelo.

3.3.3. Análise da Decomposição da Variância dos erros de previsão (ADV)

Concernente à decomposição da variância, esta “determina o quanto da variância do erro de previsão s passos à frente de uma variável específica é explicado pelas inovações em cada uma das variáveis explicativas para $(s = 1, 2, \dots)$ ” (Gonçalves, 2011, p.12). A mesma autora ressalta que maior parte do erro de previsão da série no VAR é explicada pelos choques da série analisada. A ADV foi estimada com base na seguinte equação:

$$y_{t+n} - E_y y_{t+n} = \sum_{i=0}^{\infty} \phi_i \varepsilon_{t-i} \quad (14)$$

Onde:

- ❖ $y_{t+n} - E_y y_{t+n}$ – é o erro de previsão de n -períodos a frente, sendo y_t um vector formado pelas variáveis endógenas Y_{it} e Y_{jt} .

3.4. Mercados analisados

O estudo foi elaborado envolvendo os mercados de Cuamba e Nampula (região norte), Alto Molócuè e Beira (região centro) e Chókwè e Maputo (região sul). A princípio os mercados foram seleccionados considerando a disponibilidade de preços para o período em análise (2011-2020), sendo posteriormente considerados outros critérios de escolha, como é o caso da importância na cadeia de comercialização de arroz, produção ou consumo.

A escolha do mercado de Maputo deveu-se ao facto deste constituir o principal centro consumidor de arroz em Moçambique, e altamente vulnerável a variação de preços (MITADER, 2016). Por outro lado, o mercado de Maputo é o maior centro urbano do país, conferindo-lhe maior poder de compra do cereal, e é principal importador de arroz, sobretudo dos mercados asiáticos, possibilitado pelo conhecido porto de Maputo. A escolha dos mercados de Beira e Nampula deveu-se ao facto de serem os principais centros urbanos do país, depois de Maputo, respectivamente, conferindo-lhes poder de compra e consumo de arroz. Assim como Maputo, Beira e Nampula possuem ligação com os respectivos portos de Nacala e Beira, possibilitando-lhes, igualmente, a recepção do arroz importado.

A selecção do mercado de Chókwè deveu-se ao facto de ser o principal centro produtor de arroz a nível da região sul, considerando a possibilidade do transporte da sua produção para o mercado de Maputo, criando um potencial de competitividade com o arroz importado. Relativamente aos mercados de Cuamba e Alto Molócuè, a sua escolha deveu-se ao facto de possuírem o *status* de alguns dos

principais produtores de arroz a nível das regiões norte e centro, respectivamente (MADER, 2020), e devido a sua proximidade com os respectivos mercados consumidores de Nampula e Beira, considerando a possibilidade do transporte da sua produção para estes mercados.

3.5. Fonte e tratamento dos dados

O estudo utilizou séries mensais de preços médios a nível dos mercados retalhistas, abrangendo o período 2011 a 2020. Os dados de preços foram colectados do Sistema de Informação de Mercados Agrícolas (SIMA), que é a entidade oficial do Ministério da Agricultura e Desenvolvimento Rural (MADER), responsável pela colecta, divulgação e monitoria dos preços de produtos agrícolas em Moçambique. Com vista a padronizar as séries utilizadas, os preços foram convertidos do carácter nominal (não ajustados pela inflação) ao real (ajustados pela inflação). A conversão foi feita pelo Índice de Preços ao Consumidor (IPC) de Moçambique (que considera 2010 como o ano base), obtido do Instituto Nacional de Estatística (INE), através da seguinte fórmula:

$$Pr = \frac{PN}{IPC} * 100$$

Onde Pr denota o preço real de arroz, e PN o preço nominal de arroz. Posteriormente, os preços reais foram transformados em logaritmo, para melhor visualização da tendência evolutiva dos preços e interpretação das elasticidades dos preços. Segundo Adami & Miranda (2011), a utilização da transformação logarítmica permite, por um lado, estabilização da variância das séries ao longo do tempo e, por outro lado, verificação da evolução das séries no tempo.

Outro aspecto analisado nos preços foi a sazonalidade. Inúmeras séries temporais mensais ou trimestrais exibem padrões sazonais, e muitas vezes é desejável remover a componente sazonal (ajuste sazonal ou dessazonalização⁴), de modo que se possa concentrar nos demais componentes, como a tendência, que é um aumento ou diminuição razoavelmente constante durante um período de tempo prolongado (Gujarati & Porter, 2011).

Segundo Souza et al (2016), a sazonalidade⁵ é um dos factores que influencia a instabilidade dos preços de produtos agro-pecuários ao longo do tempo, dificultando o ajuste entre a produção e as alterações do mercado, obrigando os agentes do mercado (principalmente o produtor) a ter maior cuidado com as oscilações de preços. O ajuste sazonal foi feito através do método de variáveis

⁴ É o processo que consiste na remoção da sazonalidade de uma série temporal, e a série temporal assim obtida é chamada série temporal dessazonalizada, ou ajustada sazonalmente (Gujarati & Porter, 2011).

⁵ Souza et al (2016) descreve a sazonalidade como as flutuações regulares nos valores da variável com duração inferior a um ano. O processo de remoção da sazonalidade de uma série chama-se dessazonalização ou ajuste sazonal.

dummies, que consistiu em uma regressão entre as séries de preços e variáveis dummies sazonais (fictícias) criadas. As dummies assumem o valor 1 para o mês relevante e 0 para os outros meses. Foram considerados os meses de Janeiro a Novembro, e Dezembro foi excluído por que considerou-se como o mês de referência.

As análises foram precedidas de estatísticas descritivas dos preços, com objectivo de se obter informações referentes aos preços médios, preços máximos e mínimos, o desvio padrão bem como os coeficientes de variação. Complementarmente, foram gerados gráficos de series de tempo, com vista a mostrar tendências e ciclos/sazonalidade das séries temporais. Os dados foram organizados e processados no pacote Excel do Microsoft Office 2013, e posteriormente importados ao *software* STATA – versões 14 e 16 para a realização dos testes estatísticos e esboço de alguns gráficos.

4. RESULTADOS E DISCUSSÃO

4.1. Estatísticas Descritivas e análise gráfica das séries de preços

A Tabela 4 apresenta os resultados das estatísticas descritivas dos preços de arroz para os mercados de Cuamba, Nampula, Alto Molócuè, Beira, Chókwè e Maputo durante a década 2011-2020. Com base nesses resultados, constatou-se que o mercado de Cuamba foi o que registou o preço médio mais alto (33.69 MZN/kg), bem como o menor e maior preço, 17.58 MZN/kg e 54.61 MZN/kg, respectivamente. Esses resultados condizem com os verificados por Mosca & Abbas (2013), os quais indicaram que, de forma geral, os preços mais altos são praticados na província de Niassa.

Em termos de variabilidade, o mercado de Maputo foi o que registou os maiores valores de desvio padrão e coeficiente de variação, 9.23 e 31.34%, respectivamente. Esses resultados sugerem maior volatilidade dos preços do mercado de Maputo em relação aos outros mercados. Resultado semelhante foi observado no estudo do MITADER (2016), o qual verificou elevada variabilidade dos preços de arroz no mercado de Maputo, e associa esse comportamento principalmente à dependência do mercado as variações dos preços praticados nos mercados asiáticos.

Tabela 4. Estatísticas descritivas dos preços reais de arroz (em MZN/kg)

Estatísticas	Mercados					
	Cuamba	Nampula	Alto Molócuè	Beira	Chókwè	Maputo
Média	33.69	29.82	31.57	28.84	32.33	29.48
Mínimo	17.58	19.07	21.14	19.25	20.16	19.79
Máximo	54.61	51.69	49.25	45.45	43.74	49.58
Desvio Padrão	7.24	8.19	7.44	6.82	7.03	9.23
CV (%)	21.50	27.48	23.56	23.66	21.74	31.34
No de Observações	120	120	120	120	120	120

A Figura 7 apresenta a evolução dos preços de arroz nos mercados analisados durante a década 2011-2020. De forma geral pode-se notar que as séries de preços não apresentam o mesmo padrão das flutuações ao longo do período em análise, denotando intuitivamente uma fraca cointegração entre os mercados. No entanto, apesar da diferença no padrão da evolução, de Janeiro de 2011 a Dezembro de

2015 os preços médios foram ligeiramente baixos, variando entre 17 MZN/kg e 21 MZN/kg. Entre 2016 e 2017 todos mercados registaram uma subida acentuada dos preços, relativamente aos verificados nos períodos anteriores, tendo alcançado até Dezembro de 2017 o pico de 54 MZN/kg (em Cuamba), aproximadamente três vezes maior que o preço máximo praticado entre 2011 e 2015. Esse incremento dos preços pode ser explicado pelo aumento da inflação de vários produtos (principalmente alimentares) iniciado em 2015, por ocasião da inserção da dívida pública do Governo na Conta Geral do Estado (CGE). Segundo o CDD (2019), com a inclusão da dívida pública do Governo na CGE de 2015, a inflação anual acelerou de 3,65% em 2015 para 19,9% em 2017, gerando assim, em apenas 2 anos, um aumento do custo de vida na ordem de 453 pontos percentuais. Ainda nesse período a inflação dos produtos alimentares básicos, incluindo o arroz, aumentou em 32% (Cortez et al, 2021). De acordo com os mesmos autores, em 2016 registou-se um aumento no nível de preços que resultou em 2.6 milhões de pessoas abaixo do limiar da pobreza.

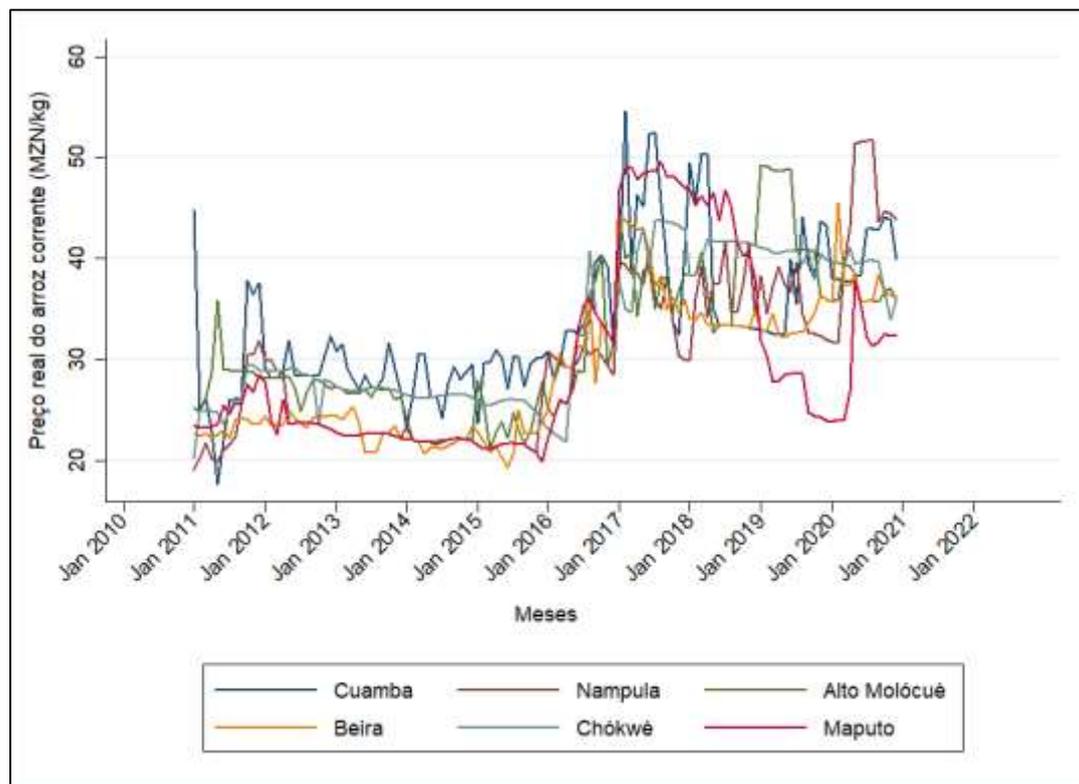


Figura 7. Tendência dos preços mensais de arroz (em MZN/kg)

4.2. Estacionariedade e ordem de integração das séries de preços

Inicialmente determinou-se o número adequado de defasagens por se incluir no teste de estacionariedade, no modelo VEC e no teste de cointegração de Johansen através dos critérios da razão de verossimilhança (LR), Erro de Previsão Final (FPE), Akaike (AIC), Schwarz (SC) e Hannan-Quinn (HQ). A Tabela 5 mostra os resultados fornecidos por todos critérios de informação incluídos

no pacote estatístico (STATA 14) para determinação do número de defasagens, sendo que quatro (4) dos quais (FPE, AIC, SC e HQ) indicaram significativo para uma (1) defasagem, e apenas um critério (LR) revelou significativo para três (3) defasagens. Segundo Zunguene (2014), pode-se usar o número de defasagens sugeridas pela maioria dos critérios, desde que a maioria dos quais apontem para o mesmo número de lags. Assim, tendo em conta os critérios escolhidos para este estudo, SC e HQ, e o resultado da maioria dos critérios, tanto para o teste de cointegração de Johansen assim como para o modelo VEC foi aplicada uma (1) defasagem.

Tabela 5. Determinação de número de defasagens (lags)

Desfasagens (lags)	LL	LR	FPE	AIC	HQ	SC
0	395.525		4.9e-11	-6.71594	-6.65813	-6.57352
1	887.683	984.32	1.9e-14*	-14.5807*	-14.176*	-13.5837*
2	921.093	66.822	2.0e-14	-14.5361	-13.7845	-12.6845
3	948.245	54.304	2.3e-14	-14.3835	-13.285	-11.6774
4	976.361	56.231*	2.7e-14	-14.2476	-12.8022	-10.6869

Observação: (*) denota a ordem de defasagem seleccionada pelo critério.

Na Figura 7 pode-se observar que as séries dos preços em análise não apresentaram uma tendência linear bem definida ao longo do tempo, isto é, a média não foi constante, revelando uma intuitiva não estacionariedade das mesmas. Entretanto, analisou-se a hipótese de forma mais criteriosa através dos testes de raiz unitária de Dickey-Fuller Aumentado (ADF) e Phillips-Perron (PP). Inicialmente os testes foram efectuados para séries em níveis, revelando-se a não estacionariedade para os mercados de Nampula, Alto Molócuè, Beira, Chókwè e Maputo. A série de Cuamba foi uma excepção, tendo se revelado estacionária para ambos testes. Posteriormente, diferenciaram-se todas as séries, tendo-se revelado estacionárias em primeira diferença, ao nível de significância de 5%, pois os módulos dos valores calculados são superiores aos módulos dos valores críticos (vide as Tabelas 6 e 7). Estes resultados sugerem que as séries são integradas de primeira ordem, I(1).

Tabela 6. Resultados do teste de Dickey-Fuller Aumentado (ADF) em primeiras diferenças

Série diferenciada	t_{τ}	$\tau_{\tau-}(\alpha = 0.05)$	t_{μ}	$\tau_{\mu-}(\alpha = 0.05)$	t_0	$\tau_{0-}(\alpha = 0.05)$
Diff_PRACuamba	-13.38	-3.45	-13.47	-1.66	-13.52	-1.95
Diff_PRANampula	-11.05	-3.45	-11.09	-1.66	-11.07	-1.95
Diff_PRAAlto Molócuè	-12.21	-3.45	-12.26	-1.66	-12.30	-1.95
Diff_PRABeira	-14.70	-3.45	-14.77	-1.66	-14.75	-1.95
Diff_PRACHókwè	-13.27	-3.45	-13.32	-1.66	-13.33	-1.95
Diff_PRAMaputo	-9.52	-3.45	-9.56	-1.66	-9.58	-1.95
Probabilidade	0.0000	0.0000	0.0000

Observações: τ_{τ} – Modelo com tendência e constante; τ_{μ} – Modelo apenas com intercepto; τ_0 – Modelo sem intercepto e sem tendência. t_{τ} , t_{μ} e t_0 – Valores calculados para os três modelos, respectivamente. Os valores críticos e a probabilidade foram obtidos em Mackinnon (1991).

Tabela 7. Resultados do teste de Phillips-Perron (PP) em primeiras diferenças

Série diferenciada	t_{τ}	$\tau_{\tau-}(\alpha = 0.05)$	t_{μ}	$\tau_{\mu-}(\alpha = 0.05)$	t_0	$\tau_{0-}(\alpha = 0.05)$
Diff_PRACuamba	-14.67	-3.45	-14.79	-2.89	-14.81	-1.95
Diff_PRANampula	-11.06	-3.45	-11.11	-2.89	-11.07	-1.95
Diff_PRAAlto Molócuè	-12.90	-3.45	-12.97	-2.89	-12.99	-1.95
Diff_PRABeira	-14.90	-3.45	-14.96	-2.89	-14.89	-1.95
Diff_PRACHókwè	-13.28	-3.45	-13.33	-2.89	-13.32	-1.95
Diff_PRAMaputo	-9.47	-3.45	-9.51	-2.89	-9.54	-1.95
Probabilidade	0.0000	0.0000	0.0000

Observações: τ_{τ} – Modelo com tendência e constante; τ_{μ} – Modelo apenas com intercepto; τ_0 – Modelo sem intercepto e sem intercepto. t_{τ} , t_{μ} e t_0 – Valores calculados para os três modelos, respectivamente. Os valores críticos e a probabilidade foram obtidos em Mackinnon (1991).

4.3. Teste de Cointegração de Johansen

O teste de estacionariedade revelou uma possível cointegração das séries, no entanto para confirmar-se esse resultado analisou-se a cointegração pelo procedimento de Johansen. Inicialmente a análise do teste de Johansen foi realizada em uma base geral envolvendo todos os mercados em estudo. De

acordo com o teste de traço, na primeira estatística o valor calculado (145.73) é maior que o valor crítico (94.15), assim a 5% de significância, rejeita-se a hipótese nula, mostrando a presença de um vetor de cointegração. O mesmo sucede para a segunda e terceira estatística, em que os valores calculados (82.53 e 52.86) são maiores que os valores críticos (68.52 e 47.21), respectivamente, mostrando a 5% de significância a presença de mais dois vectores de cointegração. Portanto, numa base geral o teste de traço revelou a presença de três vectores de cointegração, mostrando assim que existem três relações de longo prazo entre os mercados estudados, ou seja, os mercados de arroz em Moçambique estão integrados entre si.

Tabela 8. Resultados do teste de Cointegração de Johansen (base geral)

Teste de Traço					Teste de Máximo autovalor				
H0	H1	Autovalor	T-trace	$\tau_{\alpha=0.05}$	H0	H1	Autovalor	T-max	$\tau_{\alpha=0.05}$
$r = 0$	$r > 0$		145.73	94.15	$r = 0$	$r = 1$		63.20	39.37
$r \leq 1$	$r > 1$	0.41	82.53	68.52	$r = 1$	$r = 2$	0.41	29.67	33.46
$r \leq 2$	$r > 2$	0.22	52.86	47.21	$r = 2$	$r = 3$	0.22	24.85	27.07
$r \leq 3$	$r > 3$	0.19	28.01	29.68	$r = 3$	$r = 4$	0.189	20.63	20.97

Observação: (*) significativo a 5%

Em seguida procedeu-se com a análise do teste de Johansen entre pares de mercados. Com base nos resultados da Tabela 9 constatou-se que há um vector de cointegração nos mercados de arroz de Cuamba e Nampula, pois o valor calculado, 42.36, é superior que o valor crítico, 15.41, a um nível de significância de 5%. Portanto, existe uma relação de longo prazo entre os mercados de Cuamba e Nampula, isto é, estes mercados estão cointegrados a longo prazo.

Exceptuando o par Beira – Maputo, em todos os outros mercados verificou-se resultado semelhante ao par Cuamba – Nampula, ou seja, existe um vector de cointegração entre os pares de mercados, apontando para a existência de uma relação linear de longo prazo. Esta condição de equilíbrio a longo prazo entre os mercados nacionais de arroz é uma evidência de integração entre os mercados, demonstrando uma possível validação dos pressupostos teóricos da LPU. Esta condição de integração pode-se justificar pelo facto das regiões norte, centro e sul serem abastecidos por um mercado comum,

mercado Asiático, possibilitando que os mercados de Cuamba, Nampula, Alto Molócuè, Beira, Chókwè e Maputo atendam de maneira praticamente comum a demanda interna de arroz.

Tabela 9. Resultados do teste de cointegração de Johansen para mercados pareados

Mercados pareados	Teste de Traço				Teste de Máximo autovalor			
	H0	Ha	T-trace	$\tau_{\alpha=0.05}$	H0	H1	T-max	$\tau_{\alpha=0.05}$
Cuamba – Nampula	$r = 0$	$r > 0$	42.36	15.41	$r = 0$	$r = 1$	40.24	14.07
	$r \leq 1$	$r > 1$	2.12	3.76	$r = 1$	$r = 2$	2.12	3.76
Cuamba – Alto Molócuè	$r = 0$	$r > 0$	34.74	15.41	$r = 0$	$r = 1$	31.07	14.07
	$r \leq 1$	$r > 1$	3.67	3.76	$r = 1$	$r = 2$	3.67	3.76
Cuamba – Beira	$r = 0$	$r > 0$	49.33	15.41	$r = 0$	$r = 1$	47.22	14.07
	$r \leq 1$	$r > 1$	2.11	3.76	$r = 1$	$r = 2$	2.11	3.76
Cuamba – Chókwè	$r = 0$	$r > 0$	46.34	15.41	$r = 0$	$r = 1$	43.44	14.07
	$r \leq 1$	$r > 1$	2.89	3.76	$r = 1$	$r = 2$	2.89	3.76
Cuamba – Maputo	$r = 0$	$r > 0$	28.38	15.41	$r = 0$	$r = 1$	26.59	14.07
	$r \leq 1$	$r > 1$	1.79	3.76	$r = 1$	$r = 2$	1.79	3.76
Nampula – Alto Molócuè	$r = 0$	$r > 0$	16.96	15.41	$r = 0$	$r = 1$	14.69	14.07
	$r \leq 1$	$r > 1$	2.27	3.76	$r = 1$	$r = 2$	2.27	3.76
Nampula – Beira	$r = 0$	$r > 0$	23.09	15.41	$r = 0$	$r = 1$	21.71	14.07
	$r \leq 1$	$r > 1$	1.38	3.76	$r = 1$	$r = 2$	1.38	3.76
Nampula – Chókwè	$r = 0$	$r > 0$	18.63	15.41	$r = 0$	$r = 1$	16.15	14.07
	$r \leq 1$	$r > 1$	2.47	3.76	$r = 1$	$r = 2$	2.47	3.76
Nampula – Maputo	$r = 0$	$r > 0$	7.01	15.41	$r = 0$	$r = 1$	5.07	14.07
	$r \leq 1$	$r > 1$	1.94	3.76	$r = 1$	$r = 2$	1.94	3.76
Alto Molócuè – Beira	$r = 0$	$r > 0$	18.26	15.41	$r = 0$	$r = 1$	16.22	14.07
	$r \leq 1$	$r > 1$	2.04	3.76	$r = 1$	$r = 2$	2.04	3.76
Alto Molócuè – Chókwè	$r = 0$	$r > 0$	26.54	15.41	$r = 0$	$r = 1$	23.11	14.07
	$r \leq 1$	$r > 1$	3.42	3.76	$r = 1$	$r = 2$	3.42	3.76
Alto Molócuè – Maputo	$r = 0$	$r > 0$	11.27	15.41	$r = 0$	$r = 1$	9.49	14.07

	$r \leq 1$	$r > 1$	1.78	3.76	$r = 1$	$r = 2$	1.78	3.76
Beira – Chókwè	$r = 0$	$r > 0$	23.19	15.41	$r = 0$	$r = 1$	20.92	14.07
	$r \leq 1$	$r > 1$	2.27	3.76	$r = 1$	$r = 2$	2.27	3.76
Beira – Maputo	$r = 0$	$r > 0$	9.79	15.41	$r = 0$	$r = 1$	7.89	14.07
	$r \leq 1$	$r > 1$	1.91	3.76	$r = 1$	$r = 2$	1.91	3.76
Chókwè – Maputo	$r = 0$	$r > 0$	16.69	15.41	$r = 0$	$r = 1$	14.75	14.07
	$r \leq 1$	$r > 1$	1.94	3.76	$r = 1$	$r = 2$	1.94	3.76
Observação: (*) significativo a 5%								

Segundo Souza & Veríssimo (2021), a cointegração de séries indica que as mesmas exibem uma relação de longo prazo, e podem ser combinadas de forma linear, ou seja, mesmo que existam choques no curto prazo afectando o movimento das séries individuais, esses podem convergir com o tempo, isto é, no longo prazo. Os mesmos autores referem que, para esse caso deve-se estimar os modelos VAR e VEC. Margarido (2012) citando Johansen (1995), atesta que em contextos como este, em que o número de vectores de cointegração é inferior ao número de variáveis envolvidas no modelo, o mais indicado é aplicar o modelo VEC com vista a captar tanto relações de curto, assim como de longo prazo.

4.4. Modelo de Vector de Correção de Erros (VEC)

Tabela 10. Resultados do modelo VEC estimado

Mercados pareados	Equilíbrio do curto prazo		Equilíbrio do longo prazo		Dummies	
	Coefficiente	P-value	Coefficiente	P-value	dumDPG	dumCOV
D_Cuamba (t-1)	0.183 (0.138)	0.185	1		0.014 (0.021)	-0.048 (0.039)
D_Nampula (t-1)			-0.695 (0.148)**	0.000		
D_Cuamba (t-1)	0.246 (0.127)	0.054	1		0.063 (0.026)**	0.032 (0.038)
D_Alto Molócuè (t-1)			-0.229 (0.161)	0.152		
D_Cuamba (t-1)	0.039 (0.157)	0.806	1		0.021 (0.021)	0.002 (0.036)
D_Beira (t-1)			-0.649 (0.138)**	0.000		

D_Cuamba (t-1)	0.201 (0.171)	0.238	1		0.043 (0.023)	0.031 (0.038)
D_Chókwè (t-1)				-0.554 (0.133)**	0.000	
D_Cuamba (t-1)	0.221 (0.155)	0.155	1		0.059 (0.024)**	0.052 (0.039)
D_Maputo (t-1)				-0.318 (0.107)**	0.003	
D_Nampula (t-1)	-0.092 (0.063)	0.148	1		0.004 (0.015)	0.042 (.0.028)
D_Cuamba (t-1)				-1.439 (0.248)**	0.000	
D_Nampula (t-1)	0.053 (0.089)	0.556	1		0.041 (0.016)**	0.104 (0.031)**
D_Alto Molócuè (t-1)				-0.676 (0.132)**	0.000	
D_Nampula (t-1)	-0.036 (0.109)	0.741	1		0.017 (0.014)	0.083 (0.028)**
D_Beira (t-1)				-0.444 (0.151)**	0.000	
D_Nampula (t-1)	0.026 (0.119)	0.828	1		0.033 (0.016)**	0.092 (0.031)**
D_Chókwè (t-1)				-0.748 (0.136)**	0.000	
D_Nampula (t-1)	-0.148 (0.116)	0.200	1		0.053 (0.018)**	0.119 (0.033)**
D_Maputo (t-1)				-0.328 (0.129)**	0.011	
D_Alto Molócuè (t-1)	-0.039 (0.067)	0.561	1		0.029 (0.020)	0.002 (0.029)
D_Cuamba (t-1)				-4.348 (0.898)**	0.000	
D_Alto Molócuè (t-1)	-0.192 (0.108)	0.075	1		0.006 (0.019)	-0.017 (0.035)
D_Nampula (t-1)				-1.480 (0.215)**	0.000	
D_Alto Molócuè (t-1)	-0.281 (0.121)*	0.020	1		0.011 (0.016)	-0.025 (0.028)
D_Beira (t-1)				-0.885 (0.227)**	0.000	
D_Alto Molócuè (t-1)	0.011 (0.134)	0.935	1		0.016 (0.016)	-0.009 (0.028)
D_Chókwè (t-1)				-0.946 (0.175)**	0.000	
D_Alto Molócuè (t-1)	0.066 (0.100)	0.509	1		0.011 (0.015)	0.031 (0.025)
D_Maputo (t-1)				-0.308 (0.192)	0.109	
D_Beira (t-1)	-0.032 (0.053)	0.552	1		0.019 (0.013)	-0.033 (0.022)
D_Cuamba (t-1)				-1.541 (0.218)**	0.000	
D_Beira (t-1)	0.030 (0.083)	0.712	1			

D_Nampula (t-1)			-1.171 (0.157)**	0.000	0.014 (.0.013)	-0.047 (0.025)
D_Beira (t-1)	0.027 (0.080)	0.741	1		0.018 (0.013)	-0.032 (0.023)
D_Alto Molócuè (t-1)			-1.129 (0.206)**	0.000		
D_Beira (t-1)	-0.057 (0.107)	0.594	1		0.016 (0.013)	-0.036 (0.023)
D_Chókwè (t-1)			-0.956 (0.118)**	0.000		
D_Beira (t-1)	0.177 (0.096)	0.066	1		0.046 (0.016)**	-0.038 (0.022)**
D_Maputo (t-1)			2.102 (0.899)*	0.019		
D_Chókwè (t-1)	-0.070 (0.047)	0.139	1		-0.0009 (0.012)	-0.029 (0.020)
D_Cuamba (t-1)			-1.804 (0.267)**	0.000		
D_Chókwè (t-1)	0.009 (0.074)	0.904	1		-0.007 (0.012)**	-0.059 (0.023)**
D_Nampula (t-1)			-1.337 (0.173)**	0.000		
D_Chókwè (t-1)	-0.094 (0.073)	0.195	1		0.007 (0.011)	-0.022 (0.020)
D_Alto Molócuè (t-1)			-1.337 (0.173)**	0.000		
D_Chókwè (t-1)	-0.299 (0.084)*	0.000	1		-0.008 (0.011)	-0.044 (0.018)**
D_Beira (t-1)			-1.046 (0.135)**	0.000		
D_Chókwè (t-1)	-0.112 (0.086)	0.192	1		0.025 (0.012)	0.0009 (0.021)
D_Maputo (t-1)			-0.450 (0.144)**	0.002		
D_Maputo (t-1)	-0.050 (0.101)	0.389	1		0.006 (0.016)	0.028 (0.026)
D_Cuamba (t-1)			-3.143 (0.548)**	0.000		
D_Maputo (t-1)	0.230 (0.094)*	0.015	1		0.019 (0.017)	0.052 (0.030)
D_Nampula (t-1)			-3.051 (0.549)**	0.000		
D_Maputo (t-1)	0.116 (0.083)	0.161	1		0.011 (0.015)	0.031 (0.025)
D_Alto Molócuè (t-1)			-3.249 (0.802)**	0.000		
D_Maputo (t-1)	-0.046 (0.108)	0.671	1		0.025 (0.018)	0.025 (0.024)
D_Beira (t-1)			0.476 (0.676)*	0.000		
D_Maputo (t-1)	0.209 (0.112)	0.063	1			

D_Chókwè (t-1)	-2.222 (0.475)**	0.000	0.013 (0.015)	0.046 (0.026)
----------------	------------------	-------	------------------	------------------

Observação: Todas as variáveis são diferenciadas e desfasadas de um período (t-1). * significativo a 5% mas com sinal do coeficiente não analisável. ** significativo a 5% e com sinal do coeficiente analisável A componente entre parenteses é o Erro Padrão.

Segundo Ghafoor & Aslam (2012), a integração de mercados por meio da cointegração pode resultar em desequilíbrios no curto prazo, ou seja, o ajuste de preços entre os mercados pode não ocorrer instantaneamente, levando algum período para que tais ajustes de preços espaciais se verifiquem. Assim, os mesmos autores propõem a estimativa de um modelo VEC, pois considera o ajuste do desequilíbrio de curto e longo prazo nos mercados, e permite estimar o tempo necessário para remover os desequilíbrios em cada período.

Dado que os resultados do teste de Cointegração de Johansen indicaram a existência de relação de longo prazo entre os mercados, o estudo adequou-se para a estimativa do modelo VEC. Assim, recorreu-se à análise dos coeficientes das variáveis (mercados) do Modelo VEC, ou seja, pela equação de cointegração normalizada (Margarido, 2012). Segundo Margarido et al (2000), uma vez feita a análise dos coeficientes das variáveis incluídas no VECM bivariado, os coeficientes estimados das variáveis de saída (endógenas) assumem valor igual a um (no longo prazo), e a análise das estimativas dos coeficientes deve ser conduzida com o sinal invertido. A Tabela 10 apresenta os resultados do modelo VEC estimado para o equilíbrio do curto e longo prazo. Foram realizados testes de especificação de modo a validar-se os resultados do modelo estimado (vide o anexo 4), pelo que, o teste de Multiplicador de Lagrange (LM) indicou que os resíduos dos modelos bivariados não são serialmente correlacionados. Pelo teste de Jarque-Bera (JB), constatou-se que a 5% de significância, os resíduos de todos os modelos bivariados seguem uma distribuição normal. Finalmente verificou-se a estabilidade dos modelos bivariados, tendo se constatado pela análise gráfica que todas as raízes inversas estão contidas dentro do círculo, assim o modelo VEC estimado em primeiras diferenças não possui raízes unitárias, ou seja, o modelo é estável.

Em relação ao equilíbrio do curto prazo indicou-se a integração entre os mercados de Alto Molócuè e Beira, Chókwè e Beira, e entre Maputo e Nampula. Com bases nesses resultados, constatou-se que em decorrência de um choque inesperado sobre o preço de arroz, 28% dos desequilíbrios são corrigidos a cada mês entre os mercados de Alto Molócuè e Beira, 30% entre os mercados de Chókwè e Beira, e 23% entre os mercados de Maputo e Nampula. Contudo, para que os desequilíbrios no preço sejam eliminados totalmente, são necessários 4 meses para os pares Alto Molócuè - Beira e Chókwè e Beira, e 3 meses necessários para o par Maputo e Nampula.

Em relação ao equilíbrio de longo prazo, analisou-se a estimativa da elasticidade dos preços para cada par de mercados. Os resultados indicaram relação significativa para praticamente todos os pares de mercados, exceptuando os pares Cuamba-Alto Molócuè e Alto Molócuè-Maputo. Assim, um aumento em média de 1% nos preços de arroz em Cuamba, resulta em um aumento em média de 0.70%, 0.65%, 0.55% e 0.32% nos preços de Nampula, Beira, Chókwè e Maputo, respectivamente. Se os preços de arroz no mercado de Nampula aumentarem em média 1%, os preços nos mercados de Cuamba, Alto Molócuè, Beira, Chókwè e Maputo aumentarão em média em 1.44%, 0.68%, 0.44%, 0.75% e 0.33%, respectivamente. Com base nesses resultados pode-se contatar que os preços de arroz nos mercados Cuamba e Nampula são transmitidos menos do que proporcionalmente para os preços dos seus respectivos pares, ou seja, menor que a unidade. Segundo Graef (2017), nesse caso, os resultados não validam a Lei do Preço Único, bem como os mercados não podem ser considerados perfeitamente integrados. O par Nampula-Cuamba é uma excepção pois um aumento em média de 1% nos preços praticados em Nampula, resulta em um aumento em média de 1.44% nos preços praticados em Cuamba, isto é, uma transmissão de preços mais do que proporcional.

Por outro lado, um aumento em média de 1% nos preços de arroz em Alto Molócuè, causará em média um aumento nos preços de Cuamba, Nampula, Beira e Chókwè de 4.35%, 1.48%, 0.89% e 0.95%, respectivamente. Se os preços de arroz na Beira aumentarem em média 1%, os preços nos mercados de Cuamba, Nampula, Alto Molócuè e Chókwè aumentarão em 1.54%, 1.17%, 1.13%, e 0.95%, respectivamente. Um aumento em média de 1% nos preços de arroz em Chókwè, causará em média um aumento nos preços de Cuamba, Nampula, Alto Molócuè, Beira e Maputo de 1.54%, 1.17%, 1.34%, 1.05% e 0.45%, respectivamente. Se os preços de arroz em Maputo aumentarem em média 1%, os preços nos mercados de Cuamba, Nampula, Alto Molócuè e Chókwè aumentarão em 3.14%, 3.05%, 3.25%, e 2.22%, respectivamente. Nesses casos pode-se observar que os preços de arroz nos mercados de Alto Molócuè, Beira, Chókwè e Maputo são transmitidos mais do que proporcionalmente para os preços dos seus respectivos pares. Portanto, a Lei do Preço Único não é validada, e os mercados não podem ser considerados perfeitamente integrados. Neste caso, os pares Alto Molócuè-Beira, Alto Molócuè- Chókwè, Beira- Chókwè e Chókwè-Maputo constituem uma excepção pois os preços são transmitidos menos do que proporcionalmente.

O estudo do MITADER (2016) obteve resultados diferentes, tendo indicado a não integração entre os mercados retalhistas de Chókwè e Maputo tanto no curto, bem como no longo prazo. Essa ligeira discrepância dos resultados entre estes estudos pode-se atribuir a diferença no horizonte temporal considerado para a sua realização.

4.5. Teste de Casualidade de Granger

O teste de casualidade complementa os resultados do teste de cointegração, pois este segundo por si só não apresenta informações suficientes sobre a existência de uma relação de causa e efeito entre as variáveis, no entanto assegura pelo menos uma causalidade unidirecional entre os mercados (Ayalew, 2018). Assim, recorreu-se ao teste de casualidade de Granger, que consiste em determinar a direção da formação de preços entre dois mercados e a arbitragem espacial relacionada (Ghafoor & Aslam, 2012).

A estimativa do teste de casualidade de Granger foi antecedida pela determinação do número de defasagens para as séries diferenciadas, através dos critérios de informação da razão de verossimilhança (LR), Erro de Previsão Final (FPE), Akaik (AIC), Schwarz (SC) e Hannan-Quinn (HQ). Conforme os resultados da Tabela 11, os critérios de Erro de Previsão Final (FPE), Akaik (AIC), Schwarz (SC) e Hannan-Quinn (HQ) indicaram a necessidade de incluir uma defasagem, e o critério da razão de verossimilhança (LR) indicou a necessidade de três defasagens. Assim, tendo em conta o resultado da maioria dos critérios incluindo os principais critérios para o estudo (SC e HQ), a estimativa do teste de casualidade levou em conta uma defasagem.

Tabela 11. Determinação de número de defasagens (lags)

Desfasagens (lags)	LL	LR	FPE	AIC	HQ	SC
0	731.118		4.8e-16	-12.576	-12.4985	-12.385
1	1108.69	755.15	2.0e-18*	-18.0294*	-17.3319*	-16.3109*
2	1139.64	61.888	3.7e-18	-17.4545	-16.1369	-14.2083
3	1192.87	106.46*	4.6e-18	-17.4545	-15.3296	-12.4934
4	1233.77	81.81	7.5e-18	-16.8656	-14.3079	-10.5642

Observação: (*) denota a ordem de defasagem seleccionada pelo critério.

Determinado o número de defasagens, seguiu-se a estimativa do teste de casualidade de Granger, cujos resultados são apresentados na Tabela 12. Os resultados mostraram a existência de uma causalidade unidirecional entre os mercados de Cuamba e Alto Molócuè, Alto Molócuè e Nampula, e, Maputo e Nampula. Isso implica que o granger Cuamba, Alto Molócuè e Maputo causam a formação dos preços de arroz nos respectivos mercados de Alto Molócuè e Nampula, e não se verifica mecanismo reverso.

Tabela 12. Resultados dos Testes de Causalidade de Granger para as séries diferenciadas

Hipótese nula	Chi_sq	Probabilidade
Diff_PRANampula não causa Diff_PRACuamba	2.819	0.093
Diff_PRAAlto Molócuè não causa Diff_PRACuamba	5.729*	0.017
Diff_PRABeira não causa Diff_PRACuamba	0.635	0.426
Diff_PRACHókwè não causa Diff_PRACuamba	0.009	0.926
Diff_PRAMaputo não causa Diff_PRACuamba	0.406	0.524
Diff_PRACuamba não causa Diff_PRANampula	0.688	0.407
Diff_PRAAlto Molócuè não causa Diff_PRANampula	2.538	0.111
Diff_PRABeira não causa Diff_PRANampula	1.102	0.294
Diff_PRACHókwè não causa Diff_PRANampula	0.011	0.918
Diff_PRAMaputo não causa Diff_PRANampula	1.074	0.300
Diff_PRACuamba não causa Diff_PRAAlto Molócuè	0.312	0.576
Diff_PRANampula não causa Diff_PRAAlto Molócuè	4.299*	0.038
Diff_PRABeira não causa Diff_PRAAlto Molócuè	2.289	0.130
Diff_PRACHókwè não causa Diff_PRAAlto Molócuè	2.053	0.152
Diff_PRAMaputo não causa Diff_PRAAlto Molócuè	0.116	0.733
Diff_PRACuamba não causa Diff_PRABeira	0.779	0.377
Diff_PRANampula não causa Diff_PRABeira	0.258	0.611
Diff_PRAAlto Molócuè não causa Diff_PRABeira	0.172	0.678
Diff_PRACHókwè não causa Diff_PRABeira	1.269	0.260
Diff_PRAMaputo não causa Diff_PRABeira	0.542	0.461
Diff_PRACuamba não causa Diff_PRACHókwè	0.280	0.597
Diff_PRANampula não causa Diff_PRACHókwè	0.866	0.352
Diff_PRAAlto Molócuè não causa Diff_PRACHókwè	1.779	0.182
Diff_PRABeira não causa Diff_PRACHókwè	3.105	0.078
Diff_PRAMaputo não causa Diff_PRACHókwè	0.095	0.757
Diff_PRACuamba não causa Diff_PRAMaputo	1.008	0.315
Diff_PRANampula não causa Diff_PRAMaputo	4.261*	0.039

Diff_PRAAlto Molócuè não causa Diff_PRAMaputo	0.413	0.521
Diff_PRABeira não causa Diff_PRAMaputo	1.337	0.248
Diff_PRAChókwè não causa Diff_PRAMaputo	2.098	0.147

Observação: * Significativo a 5%, isto é, existe casualidade

Assim, com base nesses resultados, pode-se concluir que os mercados nacionais de arroz não são interdependentes, concordando desta forma com os resultados obtidos da estimativa do VEC. Como destacado pela FAO (2014), devido à factores como a precariedade das vias rodoviárias, o comércio de arroz entre os mercados nacionais torna-se difícil, e conseqüentemente a interdependência entre os mesmos fica comprometida.

4.6. Função Impulso Resposta (FIR)

As condições de estacionariedade e casualidade entre os mercados fornecem indícios de uma possível relação de causa-efeito entre as variáveis envolvidas no modelo. No entanto, não permitem perceber a capacidade de resposta das variáveis dependentes aos choques ocorridos nas variáveis exógenas, sendo para o efeito recorrido à análise da Função Impulso Resposta (FIR) através do princípio de ortogonalização de Cholesky. Segundo Ayalew (2018), a FIR permite capturar a resposta dos preços praticados num mercado, como resultado dos choques não antecipados ocorridos nele e em outros mercados. Para este trabalho considera-se que um choque não antecipado sobre qualquer uma das variáveis perdure no máximo doze meses. Os resultados da FIR estão apresentados graficamente no Anexo 3. O eixo horizontal denota as unidades de tempo em meses em que é estimado o modelo VEC; e o eixo vertical representa o logaritmo do preço em MZN/kg.

Com base nesses gráficos, pode-se constatar que após um choque inesperado sobre os seus preços, todos os mercados registam um decaimento contínuo do preço durante os 12 meses, exceptuando os mercados produtores de Cuamba, Alto Molócuè e Chókwè, os quais a partir 10 meses tendem a tomar um comportamento ligeiramente estacionário, facto que pode estar associado ao efeito regulador do preço da produção local de arroz.

A nível da região norte, um choque inesperado sobre os preços de arroz no mercado de Cuamba resulta num decrescimento contínuo dos preços de arroz praticados no mercado de Nampula durante os 12 meses. No caso contrário, os preços no mercado de Cuamba respondem positivamente, crescendo até ao quinto mês, aonde a partir do qual o preço começa a decrescer lentamente. O aumento do preço pode estar associado aos elevados custos de transporte do arroz de Nampula para

Cuamba, os quais por sua vez podem estar associados à precariedade das vias rodoviárias. E o decréscimo pode estar provavelmente associado ao efeito regulador dos preços da produção local de arroz.

Em relação à região centro, um choque inesperado sobre os preços de arroz no mercado de Alto Molócuè resulta num crescimento dos preços no mercado da Beira nos primeiros 6 meses, e a partir do sétimo mês os preços decrescem rapidamente até atingir níveis mais baixos até ao último mês. O decréscimo pode justificar-se pela proximidade do mercado da Beira com produtores como Dondo e Búzi, que fornecem informalmente excedentes de arroz, sendo Beira o maior centro urbano e consumidor a nível provincial e regional. No cenário inverso, os preços do mercado de Alto Molócuè regista um crescimento a taxas decrescentes até ao oitavo mês, onde a partir do qual o preço estabiliza-se permanentemente.

Para o caso da região sul, uma unidade de choque inesperado sobre os preços de arroz no mercado de Chókwè resultam num decréscimo dos preços praticados no mercado de Maputo até ao oitavo mês, e a partir do qual os preços iniciam um lento crescimento até ao final dos 12 meses. Um choque sobre os preços praticados no mercado de Maputo resulta num aumento dos preços do mercado de Chókwè nos primeiros 5 meses, e a partir do sexto mês os preços decrescem rapidamente, sugerindo provavelmente um efeito regulador dos preços da produção local de arroz.

As funções de impulso e resposta para relações entre mercados de diferentes regiões apresentam igualmente comportamentos variados para cada par, no entanto pode-se considerar o papel dos mercados asiáticos como elo de ligação entre os mercados das três regiões, uma vez que estes abastecem as três regiões através dos portos de Nacala, Beira e Maputo, tendo em conta que não há interdependência entre os mercados arroz analisados. Assim, um choque inesperado sobre os preços praticados no mercado de Nampula resulta num rápido crescimento dos preços praticados em Maputo nos primeiros 5 meses, e a partir do sexto mês os preços decrescem rapidamente até ao último mês. Essa rápida volatilidade dos preços em Maputo pode estar associada ao constante fluxo do arroz neste mercado, devido aos elevados níveis de importação do arroz neste ponto do país (Arlindo et al, 2004).

Para o caso da relação impulso resposta entre os mercados das regiões norte e centro pode-se destacar as funções Nampula- Alto Molócuè, devido a proximidade entre estes dois mercados. Para o primeiro caso, um choque inesperado sobre os preços praticados no mercado de Nampula resulta num decréscimo contínuo dos preços praticados em Alto Molócuè nos primeiros 3 meses, e a partir do qual os preços aumentam rapidamente até ao último mês. Assim como em outros mercados produtores, em Alto Molócuè o efeito regulador dos preços da produção local de arroz é um

importante factor para definir o comportamento dos preços neste mercado. No caso inverso, os preços praticados no mercado respondem de forma crescente nos primeiros 7 meses, a partir do sétimo mês os preços estabilizam-se permanentemente. Os impulsos do mercado de Alto Molócuè podem derivar das quantidades do arroz nacional transportadas informalmente para o comércio nos mercados retalhistas de Nampula.

4.7. Análise da Decomposição da Variância dos Erros de Previsão (ADV)

A Tabela 15 apresenta os resultados da decomposição da variância dos erros de previsão para séries de preços dos mercados em análise. Segundo Enders (2004), citado por Graef (2017), através da ADV mede-se a proporção das respostas geradas em uma variável em consequência de choques exógenos ocorridos em si mesma e nas demais variáveis envolvidas no modelo ao longo do tempo. Neste estudo a decomposição da variância dos erros de previsão foi estimada considerando 12 meses como o período de duração de um choque sobre os preços de arroz.

A coluna de período na Tabela 13 representa o número considerado de meses no qual dura um choque sobre os preços de arroz. A segunda coluna captura a proporção da variância dos erros de previsão em função dos choques que afectam os preços do mercado de Cuamba, isto é, mede-se o efeito que um choque sobre os preços de arroz em Cuamba tem sobre o mesmo mercado. Da terceira à sétima coluna indica-se a proporção da variância dos erros de previsão dos preços no mercado de Cuamba que é atribuída aos preços do resto dos mercados em análise. A lógica de interpretação é a mesma para o resto das Tabelas da ADV.

Com base nos resultados da ADV apresentados nas Tabelas 13, 14, 15, 16, 17 e 18, pode-se constatar que após um choque inesperado sobre os preços de cada um dos mercados, grande parte da proporção da variância dos erros de previsão é atribuída a elas mesmas, isto é, maior parte das variações de preços observadas nos mercados de arroz em Moçambique em decorrência de um choque inesperado, são explicadas pelos preços do mesmo mercado, sendo que outros mercados exercem pouco ou nenhum efeito sobre tais variações. Assim, decorridos 12 meses, após um choque não antecipado sobre os preços em todos mercados, Cuamba explica 55.67% das variações nos seus preços, Nampula 58.94%, Alto Molócuè 62.7%, Beira 62.39%, Chókwè 31.95%, e Maputo 35.42%. Esse cenário da auto-explicação da variância dos erros de previsão pode estar associado a falta de interdependência entre os mercados de arroz em Moçambique (como demonstrado na estimativa do modelo VEC e teste de casualidade de Granger) em decorrência da fraca relação comercial de arroz entre os mercados, que por sua vez está relacionada aos elevados custos de transporte devido a precariedade das vias de acesso e à baixa produção nacional que não justifica o seu transporte.

Outro aspecto por se realçar é a existência em alguns mercados, de meses nos quais não se perfaz o total de 100% de explicação da variância dos erros de previsão em decorrência de um choque inesperado. Por exemplo, os preços no mercado de Maputo atingem a proporção máxima da explicação da variância dos erros de previsão no primeiro mês (com um total de 67.68%), e o mínimo no último mês (com 40.88%). Esse facto pode sugerir a existência de variáveis não incluídas no modelo que exercem algum poder explicativo sobre o comportamento dos preços em Maputo, por exemplo, preços de arroz em outros mercados do país. Aliado a ideia anterior, pode-se destacar o comportamento decrescente da auto-explicação da variância dos erros de previsão ao longo do tempo, facto que se verifica em todos os mercados. Esse cenário pode-se justificar pela crescente ao longo do tempo da proporção de explicação da variância dos erros de previsão atribuída aos outros mercados em decorrência de um choque inesperado.

Apesar de expressiva proporção da variância dos erros de previsão ser explicada pelos preços dos próprios mercados, parte desse percentual é explicado pelos preços de outros mercados. Para o caso do mercado de Cuamba, decorridos 12 meses após um choque sobre os seus preços, destaca-se o mercado de Nampula com 3.26%, seguindo Alto Molócuè com 1.25%, Beira com 1.39%, Chókwè com 0.84% e Maputo com 0.44%, explicando juntos apenas 7.18% da variância dos erros de previsão dos preços de arroz no mercado de Cuamba. Como se pode constatar, os mercados de Nampula e Alto Molócuè têm maior destaque, estando provavelmente associado à proximidade entre estes mercados, que propicia alguma facilidade na sua relação comercial. (vide a Tabela 13).

A Tabela 14 apresentados os resultados referentes ao mercado de Nampula, para o qual, decorridos 12 meses após um choque inesperado sobre seus preços, 14.47% da variância dos erros de previsão é atribuída aos preços de arroz em Maputo, seguindo Chókwè com 12.12%, Beira com 11.63%, Cuamba com 6.41% e Alto Molócuè com 6.10%. Apesar da longa distância entre o mercado de Nampula e os mercados do Sul, grande parte da decomposição da variância dos erros de previsão lhes é atribuída. Esse cenário pode ser explicado, por um lado, pelo facto de Nampula ser o terceiro maior centro urbano do país, conferindo-lhe poder de um dos maiores consumidores de arroz em Moçambique, a semelhança dos mercados do sul; e por outro lado, a já referida relação desses mercados através dos mercados asiáticos.

Com base nos resultados da Tabela 15, para o caso do mercado de Alto Molócuè, pode-se ressaltar a proximidade como principal factor para os principais mercados que influenciam a sua decomposição da variância dos erros de previsão, destacando-se Nampula e Cuamba, com 12.90% e 10.49%, respectivamente. E seguem-se os mercados da Beira, Chókwè e Maputo, com 4.42%, 4.33% e 0.49%, respectivamente. Assim como Nampula, a decomposição da variância dos erros de previsão dos

preços de arroz do mercado da Beira é maioritariamente explicada pelos mercados de Maputo e Chókwè, com 21.26% e 16%, respectivamente, seguindo Cuamba com 7.35%, Nampula com 6.16% e Alto Molócuè com 3.43%. Além razões já ressaltadas no caso de Nampula, para o mercado da Beira, outro motivo é a ligação alimentar deste mercado com o de Maputo através dos portos da Beira e Maputo, respectivamente. (vide a Tabela 16).

Tabela 13. Resultados do teste da ADV para o mercado de Cuamba

Período	Log_Cuamba	Log_Nampula	Log_A. Molócuè	Log_Beira	Log_Chókwè	Log_Maputo
1	100.00	0.00	0.00	0.00	0.00	0.00
2	91.91	4.08	0.51	1.77	1.08	0.67
3	90.63	4.89	0.97	2.00	0.89	0.63
4	85.43	4.95	1.25	2.02	0.82	0.60
5	79.88	4.73	1.39	1.95	0.79	0.57
6	74.89	4.43	1.44	1.86	0.79	0.55
7	70.50	4.16	1.44	1.76	0.8	0.52
8	66.68	3.91	1.41	1.66	0.81	0.50
9	63.35	3.71	1.37	1.58	0.82	0.48
10	60.44	3.53	1.33	1.51	0.83	0.46
11	57.90	3.38	1.29	1.44	0.84	0.45
12	55.67	3.26	1.25	1.39	0.84	0.44

Tabela 14. Resultados do teste da ADV para o mercado de Nampula

Período	Log_Nampula	Log_Cuamba	Log_A. Molócuè	Log_Beira	Log_Chókwè	Log_Maputo
1	95.36	0.00	1.39	1.68	0.60	12.77
2	92.38	0.66	0.82	3.92	1.93	12.73
3	87.42	1.99	0.55	2.03	3.85	12.82
4	81.80	3.65	0.46	4.13	1.53	12.97
5	76.31	0.56	0.51	5.93	3.55	13.15
6	71.30	1.87	0.66	7.40	5.43	13.34
7	66.88	3.01	0.92	8.58	7.08	13.53
8	63.04	3.97	1.26	9.51	8.49	13.72
9	59.73	4.76	1.68	10.25	9.67	13.92
10	56.88	5.42	2.13	10.82	10.64	14.11
11	54.41	5.96	2.61	11.27	11.45	14.29
12	52.27	6.41	3.10	11.63	12.12	14.47

Tabela 15. Resultados do teste da ADV para o mercado de Alto Molócuè

Período	Log_A. Molócuè	Log_Cuamba	Log_Nampula	In_Beira	Log_Chókwè	Log_Maputo
1	91.65	3.480	0.00	10.76	0.00	0.12
2	87.45	5.240	0.87	11.00	0.17	0.07
3	83.51	6.700	1.20	10.53	0.58	0.05
4	80.04	7.810	2.84	9.76	1.19	0.05
5	76.91	8.600	4.49	8.89	0.14	0.05
6	74.01	9.160	6.06	8.01	0.68	0.06
7	71.30	9.550	7.52	7.20	1.27	0.08
8	68.73	9.830	8.85	6.47	1.90	0.12
9	66.32	10.040	10.05	5.83	2.54	0.18
10	64.05	10.210	11.12	5.27	3.17	0.26
11	61.93	10.360	12.06	4.81	3.77	0.36
12	59.96	10.490	12.90	4.42	4.33	0.49

Em relação ao mercado de Chókwè, decorridos 12 meses após um choque inesperado sobre seus preços, 4.23% da decomposição da variância dos erros de previsão é explicada pelos preços de Maputo, seguindo Beira com 3.28%, Alto Molócuè com 0.15%, Nampula com 0.21% e Cuamba com 0.36%. No caso do mercado de Maputo, Chókwè é o principal a influenciar a decomposição da variância dos erros de previsão, com 2.17%, seguido de Nampula, Beira, Alto Molócuè e Cuamba, com 2.01%, 0.96%, 0.23% e 0.07%, respectivamente. Portanto, a proximidade entre os mercados da região pode ser considerada como um factor importante no comportamento da decomposição da variância dos erros de previsão entre ambos mercados. Estudos de Macamo (2018), Zunguene (2014) e Paulo (2011), sobre a integração dos mercados de milho e amendoim, destacam igualmente a importância da proximidade entre os mercados Moçambicanos como uma razão que contribui no nível de transmissão dos preços entre os mesmos, uma vez que facilita as trocas comerciais.

Tabela 16. Resultados do teste da ADV para o mercado de Beira

Período	Log_Beira	Log_Cuamba	Log_Nampula	Log_A. Molócuè	Log_Chókwè	Log_Maputo
1	86.67	0.00	0.00	0.00	3.59	12.57
2	81.13	0.04	1.78	1.48	3.97	16.33
3	75.44	1.73	0.45	3.49	4.70	18.49
4	70.12	3.30	1.69	5.60	5.92	19.70
5	65.37	4.50	2.85	7.70	7.47	20.36
6	61.22	5.37	3.80	9.77	9.12	20.72
7	57.62	5.98	4.54	0.23	10.71	20.92
8	54.52	6.42	5.09	0.79	12.14	21.04
9	51.85	6.75	5.49	1.42	13.38	21.11
10	49.54	7.00	5.79	2.09	14.42	21.17
11	47.54	7.19	6.00	2.77	15.29	21.21
12	45.79	7.35	6.16	3.43	16.00	21.26

Tabela 17. Resultados do teste da ADV para o mercado de Chókwè

Período	Log_Chókwè	Log_Cuamba	Log_Nampula	Log_A. Molócuè	Log_Beira	Log_Maputo
1	90.15	0.00	0.00	0.00	0.00	0.42
2	84.66	0.07	0.07	0.08	0.87	0.22
3	77.67	0.10	0.17	0.18	1.92	0.39
4	70.13	0.10	0.24	0.26	2.78	0.79
5	62.76	0.09	0.28	0.32	3.36	1.31
6	56.01	0.09	0.29	0.36	3.69	1.86
7	50.10	0.10	0.29	0.38	3.81	2.40
8	45.08	0.11	0.27	0.39	3.8	2.89
9	40.86	0.13	0.25	0.39	3.7	3.32
10	37.34	0.14	0.24	0.38	3.57	3.69
11	34.40	0.14	0.22	0.37	3.42	3.99
12	31.95	0.15	0.21	0.36	3.28	4.23

Tabela 18. Resultados do teste da ADV para o mercado de Maputo

Período	Log_Maputo	Log_Cuamba	Log_Nampula	Log_A. Molócuè	Log_Beira	Log_Chókwè
1	67.68	0.00	0.00	0.00	0.00	0.00
2	63.06	0.00	0.08	0.00	0.01	0.19
3	58.73	0.01	0.24	0.00	0.05	0.56
4	54.81	0.01	0.44	0.00	0.12	0.99
5	51.30	0.01	0.67	0.01	0.22	1.41
6	48.16	0.01	0.91	0.02	0.34	1.75
7	45.37	0.01	1.13	0.04	0.48	2.00
8	42.90	0.01	1.34	0.07	0.61	2.15
9	40.69	0.02	1.54	0.10	0.73	2.23
10	38.73	0.03	1.71	0.14	0.83	2.25
11	36.99	0.05	1.87	0.19	0.91	2.22
12	35.43	0.07	2.01	0.23	0.96	2.17

5. CONCLUSÃO

Os resultados da estimativa do Modelo de Vetor de Correção de Erros (VECM) indicaram que os mercados de arroz em Moçambique não estão totalmente integrados no curto prazo, uma vez que os coeficientes sugeriram uma transmissão não proporcional de preços, invalidando assim os pressupostos da Lei do Preço Único. Entretanto, os mercados da região central foram integrados entre si. Entre as regiões, destacou-se a integração entre os mercados do sul e os mercados do centro e norte, sendo que o mercado de Chókwè é integrado com o mercado da Beira, e o mercado de Maputo é integrado com Nampula.

Através do teste de Johansen o estudo revelou a existência de três relações de longo prazo entre os preços do arroz nos seis mercados, indicando que os mercados de arroz em Moçambique estão integrados entre si no longo prazo. Por outro lado, indicaram que, no curto prazo, os mercados domésticos de arroz não estavam perfeitamente integrados.

Finalmente, o teste de causalidade de Granger mostrou a existência de uma causalidade unidirecional entre os mercados de Cuamba e Alto Molócuè, Alto Molócuè e Nampula, e, Maputo e Nampula, ou seja, o granger Cuamba, Alto Molócuè e Maputo causa a formação dos preços de arroz nos respectivos mercados de Alto Molócuè e Nampula, e não se verifica mecanismo reverso. Este cenário atribuiu-se principalmente à factores como a precariedade das vias rodoviárias, que dificultam o comércio de arroz entre os mercados nacionais.

6. RECOMENDAÇÕES

6.1. Aos fazedores de políticas agrárias:

- ❖ Promoção de programas que contribuam para o aumento da produção e produtividade de arroz em Moçambique com vista a contribuir para a redução dos níveis de importação no país;
- ❖ Investir em infraestruturas de transporte, como estradas e ferrovias, para facilitar o fluxo de arroz entre as diferentes regiões;
- ❖ Estimular a cooperação entre os mercados regionais através de políticas que incentivem o comércio inter-regional. Isso pode incluir a remoção de barreiras comerciais internas e a harmonização de regulamentações;
- ❖ Criar incentivos para aumentar a produção de arroz em regiões menos integradas. Isso pode ser feito através de subsídios, apoio técnico e financeiro aos agricultores, e programas de capacitação;
- ❖ Incentivar o desenvolvimento de mercados locais e regionais, proporcionando infraestrutura adequada como armazéns e centros de distribuição que facilitem a comercialização eficiente;
- ❖ Promover a adoção de tecnologias agrícolas modernas que possam aumentar a produtividade e a eficiência da cadeia de valor do arroz. Isso pode incluir técnicas de cultivo, melhoramento genético e boas práticas de pós-colheita;
- ❖ Estabelecer um sistema contínuo de monitoramento e avaliação para acompanhar a integração dos mercados e ajustar as políticas conforme necessário. Isso garantirá que as intervenções sejam eficazes e alinhadas com as necessidades do mercado;
- ❖ Fortalecer e expandir o Sistema de Informação de Mercados Agrícolas (SIMA) para garantir a disponibilidade e acessibilidade de informações de preços em tempo real. Informações transparentes e atualizadas podem ajudar os produtores e comerciantes a tomar decisões.

6.2. Aos investigadores:

- ❖ Realização de mais estudos detalhados sobre a cadeia de valor de arroz, com vista a disponibilidade de informações referentes aos mercados do cereal;
- ❖ Realização de mais estudos sobre integração de mercados de arroz em Moçambique, considerando papel dos portos nacionais na comercialização dos produtos alimentares.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ABBAS, M. **Chókwè: efeitos locais de políticas instáveis, erráticas e contraditórias**. Observador do Meio Rural (OMR) - No 62. Maio, 2018.
- ABDULAI, A. **Spatial Price transmission and asymmetry in the Ghanaian maize market**. The Journal of Development Economics, 63 (2), 327. DOI: 10.1016/s0304-3878(00) 00115-2; 2000.
- ADAMI, A.C de O; MIRANDA, S.H.G. **Transmissão de Preços e Cointegração no Mercado Brasileiro de Arroz**. RESR, Piracicaba, SP, vol. 49, nº 01, p. 55-80, Jan/Mar 2011 – Impressa em Maio 2011.
- ARLINDO, P. et al. **Mudanças nos Padrões de Consumo na Zona Sul: Que Opções Alimentares Para as Camadas mais Pobres?** Flash No. 38p. Maputo: SIMA-DEST, MADER-Direção de Economia, 2004.
- AYALEW, A. A. **Market Integration and Price Transmission: Analysis on Ethiopian Sesame Seed Export**. v. 1, n. 1186, p. 1–50, 2018.
- BANCO MUNDIAL. **Actualidade Económica de Moçambique - Enfrentando Escolhas Difíceis**. 1. ed. 2016.
- BLOCK, A.S; CORONEL, D.A; VELOSO, A.O. **Análise da transmissão de preços no sector sucroalcooleiro brasileiro**. PPGA - UFSM. São Paulo, 2012.
- BUNTE, F. (2006). **Pricing and performance in agri-food supply chains**. Quantifying the agri-food supply chain, 39-47.
- BROOKS, C. **Introductory Econometrics for Finance**. 2ªEd. Editora Cambridge, 2008. Cap.6-7, p.265-379.
- CAMPENHOUT, B. VAN. **Integração de Mercados em Moçambique. 2015: Uma Extensão Não-Paramétrica ao Modelo de Limiar**. IFPRI. NW - Washington, DC 20006-1002 USA, 2015.
- CDD. **Que preço os moçambicanos estão a pagar pela dívida pública insustentável?** DesR/www.cddmoz.org. Maputo, 2019.
- COÊLHO, J. D. **Arroz: Produção e Mercado**. ETENE No 156 - Banco do Nordeste / <https://www.bnb.gov.br/etene>. p. 1-7, 2021.
- COELHO, A. B. **A cultura do algodão e a questão da integração entre preços internos e externos**. 2002. 136f. Dissertação (Mestrado em Economia) – Universidade de São Paulo: São Paulo. 2002.

- CORTEZ, E. et al. **Custos e consequências das dívidas ocultas para Moçambique**. CIP, Moçambique / Chr. Michelson Institute, Noruega. Maputo, Moçambique / Bergen, Noruega, 2021.
- Donário, A.A; DOS SANTOS, R.B. **A procura e a oferta**. Centro de Análise Económica de Regulação Social (CARS) - Universidade Autónoma de Lisboa. Lisboa, 2015.
- EHLERS, R. S. **Análise de Séries Temporais**. 4. ed. São Paulo: Departamento de Estatística, UFPR, 2005.
- EISFELD, C. DE L. et al. **Análise do poder de previsão do modelo de vectores auto regressivos (VAR) para a quantidade de madeira serrada exportada pelo estado do Paraná**. p. 1–11, 2007.
- FAO. **Análise de incentivos e desincentivos de preço para o arroz em Moçambique**. MAFAP, v. 1, n. Serie de notas tecnicas, by Loganemio, Dolito Lucas, ROME, p. 1-37, 2014.
- FAO (2020). **Bases de dados de produção, rendimento, área cultivada, e comércio externo, para a cultura de arroz em Moçambique e no mundo**. Disponível em <http://faostat.fao.org>
- FILHO, O.C. da S; FRASCAROLI, B.F; MAIA, S.F. **Transmissão de preços no mercado internacional da soja: uma abordagem pelos modelos ARMAX e VAR**. UFPB. JEL: G15, G28, Q10. Brasília, 2010.
- FREITAS, C. A. DE; FILHO, Á. L. M. **Elementos Históricos e Evolução Recente do Desempenho da Rizicultura no Mercado Mundial, e nos Países do Mercosul**. São Paulo, p. 1-19, 2006.
- GHAFOOR, A. and ASLAM, M. 2012, **Market Integration and Price Transmission in Rice markets of Pakistan**, SANEI Working Paper Series No. 12-08, South Asia Network of Economic Research Institutes, Dhaka.
- GHOSHROY, A. **Underlying Trends and International Price Transmission of Agricultural Commodities**. n. 257, p. 1–39, 2011.
- GONÇALVES, C. DE O. **Perspectivas da Siderurgia Brasileira para os Próximos 10 Anos: Uma Análise por Vectores Auto-regressivos**. p. 1-44, 2011.
- GONZÁLEZ-RIVERA, G.; HELFAND, S. M. **The extent, pattern and degree of market integration: a multivariate approach for the Brazilian rice market**. American Journal of Agricultural Economics, v. 83, n. 3, p. 576-592, 2001.
- GRAEF, C. E. **Transmissão de Preços no Mercado Internacional e Brasileiro de Açúcar**. UNIOESTE - *Campus De Toledo*. Toledo, p. 1-72, 2017.

GUJARATI, D. N; PORTER, D. C. **Basic Econometrics**. 5th. ed. New York: AMGH Editora Ltda, 2011.

HILL, C. R; GRIFFITHS, W. E; LIM, G. C. (2012). **Principles of Econometrics** (4 ed.): John Wiley & Sons Inc.

IIAM. **Variedades de Arroz (Orizia sativa L.) Com Alto Potencial de Rendimento**. MADER - IIAM / www.iiam.gov.mz. Maputo, 2020.

JICA. **Pesquisa preparatória no projecto de desenvolvimento do porto de Nacala na República de Moçambique**. OCIDI, Oriental Consultor Co. Ltd. ECOH CORPORATION, Ides Inc, 2011.

KHARIN, S. (2018) "**Análise de transmissão de preços: o caso dos produtos lácteos na Rússia**", **AGRIS on-line Papers in Economics and Informatics**, Vol. 10, No. 1, pp. 15-23. ISSN 1804-1930. DOI 10.7160/aol.2018.100102.

LISTORTI, G., & ESPOSTI, R. (2012). **Horizontal Price Transmission in Agricultural Markets: Fundamental Concepts and Open Empirical Issues**. **Bio-based and Applied Economics**, 1(1), 81-108. DOI:10.13128/bae-10769

LOPES, A. DE M.; ROCHA, A. C. P. N. **Alguns Aspectos Econômicos e Sociais da Produção Mundial de Arroz Em 2005**. p. 9–18, 2005.

LÜTKEPOHL, H. (2005). **New introduction to multiple time series analysis**. Berlin: Springer.

MABOTA, A.P. et al. **A Realidade a Cerca da Subida de Preços: A Dinâmica dos Preços de Alimentos em Moçambique e as Implicações Políticas**. Flash No. 50p / www.minag.org.mz. Maputo: SIMA-DEST, MINAG-Direcção de Economia - Dpto. Estatística, 2008.

MACAMO, R Da C. **Análise da integração de preços de milho-branco entre os mercados de Moçambique e Malawi**. p. 1-65. Faculdade de Agronomia e Engenharia Florestal. Maputo, 2018.

MADER. **Inquérito Agrário Integrado 2020 - Marco Estatístico**. MADER - Direcção de Planificação e Políticas. Maputo, 2020.

MAGAIA, R.; DIQUE, S. **Impacto da Covid-19 no Sector Empresarial Moçambicano e Propostas de Medidas para a Sua Mitigação**. Maputo: CTA, 2020.

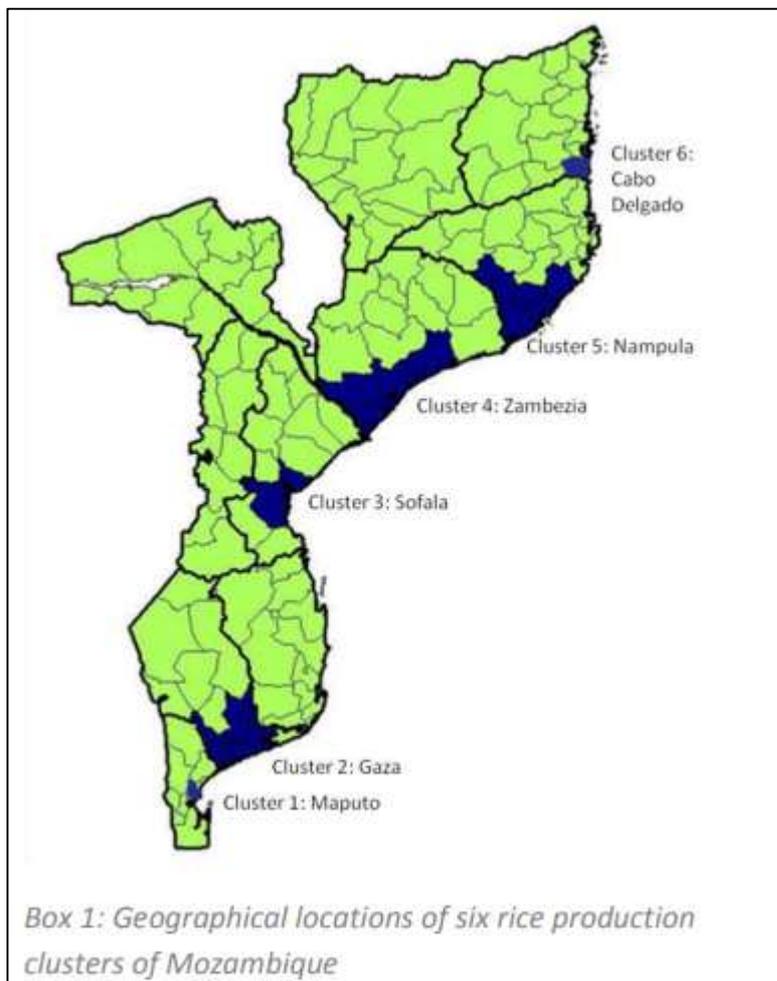
MARGARIDO, M. A; ANEFALOS, L. C. **Testes de raiz unitária e o software SAS**. **Agricultura em São Paulo**, São Paulo, v. 46, n. 2, p. 19-45, 1999.

- MARGARIDO, M. A; SHIKIDA, P. F. A. **Análise da transmissão de preços e das volatilidades entre o mercado internacional do petróleo e o de açúcar importado pelos Estados Unidos.** *Revista de Economia & Relações Internacionais*, v.10, n.20, p.70-90, Jan., 2012
- MARGARIDO, M.A. **Transmissão de preços agrícolas internacionais sobre preços agrícolas domésticos: o caso do Brasil/** Mário António Margarido. --- Piracarba, 2000. p173.
- MARGARIDO, M. A; SHIKIDA, P. F. A; CALVO, J. C. A; CARRILLO, J. I. C. R. **Análise da elasticidade da transmissão dos preços internacionais do açúcar para os preços no Brasil.** In: CONGRESSO BRASILEIRO DE ECONOMIA E SOCIOLOGIA RURAL (SOBER), 54, 2016, Maceió. Anais... Maceió/AL, 2016.
- MARTINS, C. K. S. **Avaliação de Azolla filiculoides no controlo de infestantes e como biofertilizante na produção de arroz irrigado.** Faculdade de Agronomia e Engenharia Florestal, v. 1, p. 1–83, 2015.
- MASA. **Programa Nacional para o Desenvolvimento do Arroz (NRDP-2016 - 2027).** Maputo, 2016.
- MAYORGA, R. DE O. et al. **Análise de transmissão de preços do mercado atacadista de melão do Brasil.** 1. ed. Rio de Janeiro: RER, 2007.
- MINOT, Nicholas. **Transmission of World Food Price Changes to African Markets and its Effect on Household Welfare.** IFPRI Discussion Paper 01059. Markets, Trade and Institutions Division. January 2011
- MINOT, Nicholas. **Transmission of World Food Price Changes to Markets in Sub-Saharan Africa.** AgEcon Search/ <http://ageconsearch.umn.edu> Maputo, 2010.
- MINOT, Nicholas. **Food price volatility in sub-Saharan Africa: Has it really increased?** Food Policy 45 (2014) 45–56. Markets, Trade, and Institutions Division, International Food Policy Research Institute, 2033 K Street NW, Washington, DC 20006, USA, 2013.
- MITADER. **Transmissão dos preços do milho e arroz entre a Ásia e Moçambique.** DNDR POLICY BRIEF - MITADER / www.ruralmoc.gov.mz. Maputo, 2016. p. 1–6, 2016.
- MITADER. **Será competitivo produzir Milho e Arroz em Moçambique?** DNDR POLICY BRIEF - MITADER / www.ruralmoc.gov.mz. Maputo, 2016.
- MOSCA, J.; ABBAS, M. **Preços e Mercados de Produtos Agrícolas Alimentares.** Observador Rural, n. 19, p. 1–48, 2017.

- MOSCA, João. **Agricultura e Desenvolvimento em África**. Lisboa, Instituto Piaget: 2008.
- MUENDANE, C. T. **Análise da Cadeia de Produção, Transformação e Comercialização de Arroz, com base em Custos e Preços, na Região Sul de Moçambique**. Maputo, 1999.
- NDAVA, A. O. **Análise dos contratos de integração entre produtores de arroz e a agroindústria Wanbao no perímetro irrigado do rio Limpopo em Moçambique**. Universidade Federal de Goiás (UFG) - Escola de Agronomia. Goiânia-GO – Brasil, Junho 2019.
- PAULA, S. R. L. DE. **Orizicultura: Principais Características Actuais**. v1, p. 1–6, 2008.
- PAULO, A. M. **Transmissão de Preços de Milho Branco entre Moçambique, Malawi e Zâmbia**. p. 1–17, 2011.
- POPAT, M. et al. **Infrastructure Investments, Regional Trade Agreements and Agricultural Market Integration in Mozambique**. DOI: <https://doi.org/10.21203/rs.3.rs-417100/v1>, 2021.
- QUEIROZ, I.S. de A; VIEIRA, F.V. **Taxa de câmbio e ajuste externo: uma investigação com modelos ARDL para as economias emergentes do BRICS**. Rev. Econ.Comtemp, v.23, n.3, p 1-29 2019, e192335. DOI: 10.1590/198055272335.
- RAPSOMANIKIS, G.; HALLAM, D.; CONFORTI, P. **Market integration and price transmission in selected food and cash crop markets of developing countries: review and applications**. Commodity Market Review, Rome, 2003. Disponível em: 25-05-2016
- ROSÁRIO, N. M. **Desenvolvimento e agricultura na região do regadio do baixo Limpopo, gaza/moçambique: história, situação atual e perspectivas**. Universidade Federal do Rio Grande do Sul - Faculdade de Ciências Econômicas. Porto Alegre, 2020.
- SOUSA, R.M; VERÍSSIMO, M.P. **Determinantes das exportações brasileiras de petróleo: uma aplicação ARDL e NARDL**. BRAZILIAN KEYNESIAN REVIEW, 7(2), p.211-242, 2nd Semester/2021.
- TERRA, P. R. S. **Estrutura de capital e factores macroeconómicos na América Latina**. 1. ed. Porto Alegre: Universidade Federal do Rio Grande do Sul Escola de Administração — PPGA, 2007.
- World Bank (2018). **Moçambique: Avaliação da Pobreza – Crescimento forte mas não partilhado**. Washington D.C.: World Bank.
- ZUNGUENE, Z.L. **Análise de Integração de Mercados de Amendoim Pequeno entre Mercados de Maputo, Maxixe, Manica e Nampula**. Faculdade de Agronomia e Engenharia Florestal. Maputo,2014.

8. ANEXOS

Anexo 1. *Clusters* (zonas) de produção de arroz em Moçambique



Fonte: MASA, 2016.

Cluster 1: Maputo (Matutuine, Magude e Marracuene)

Cluster 2: Gaza (Chókwè, Xai-Xai e Bilene)

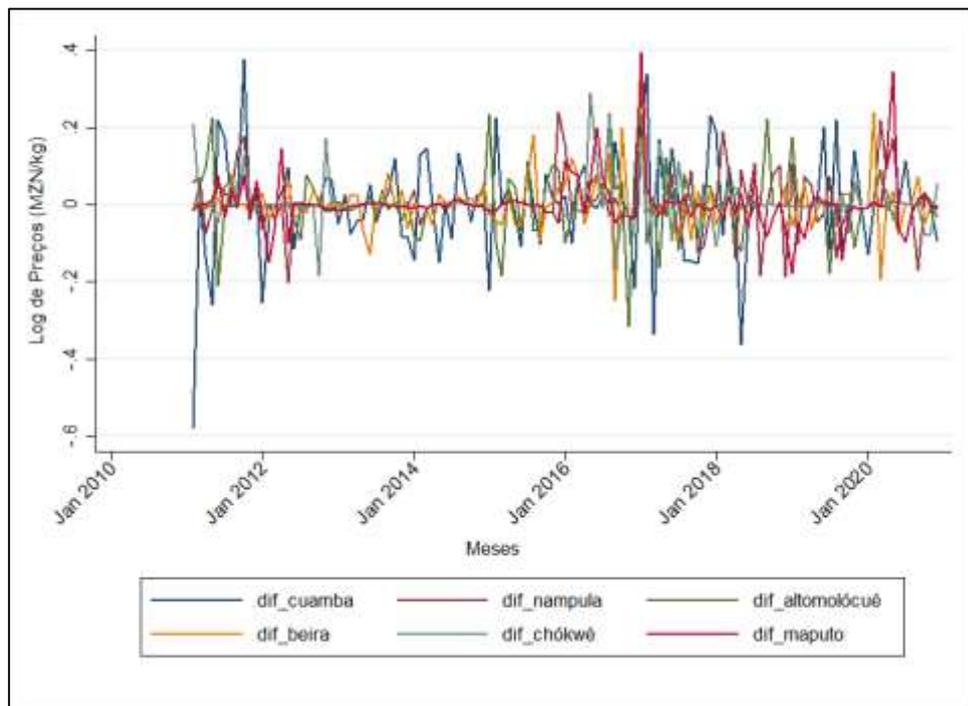
Cluster 3: Sofala (Búzi, Dondo, Beira e Caia)

Cluster 4: Zambézia (Nicoadala, Mopeia, Murrumbala, M. Costa, Namacurra e Chinde-Luabo),

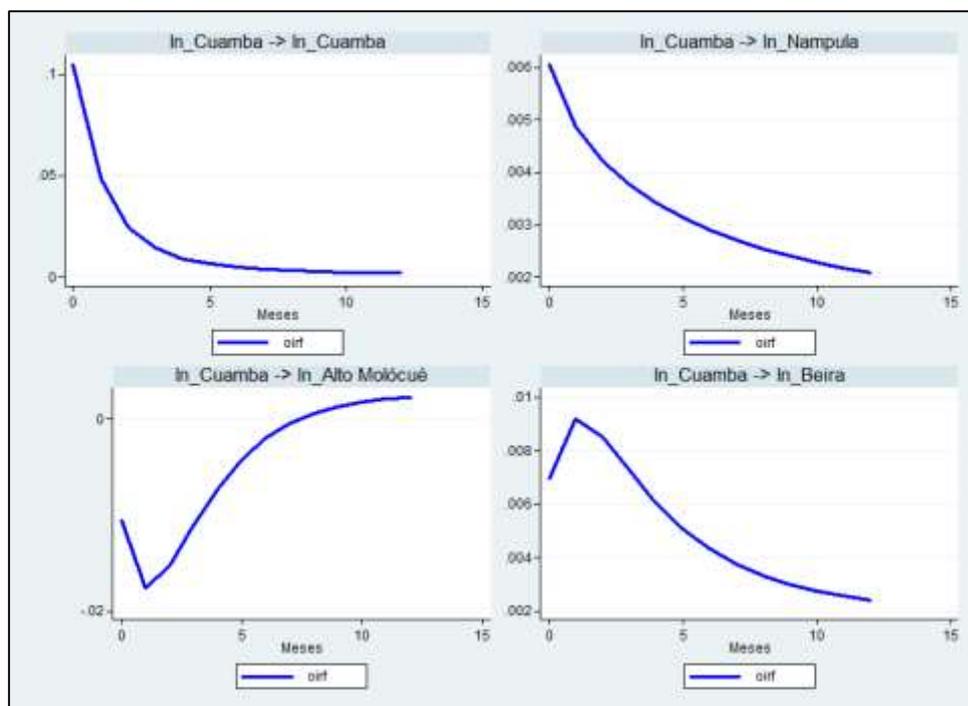
Cluster 5: Nampula (Angoche e Moma)

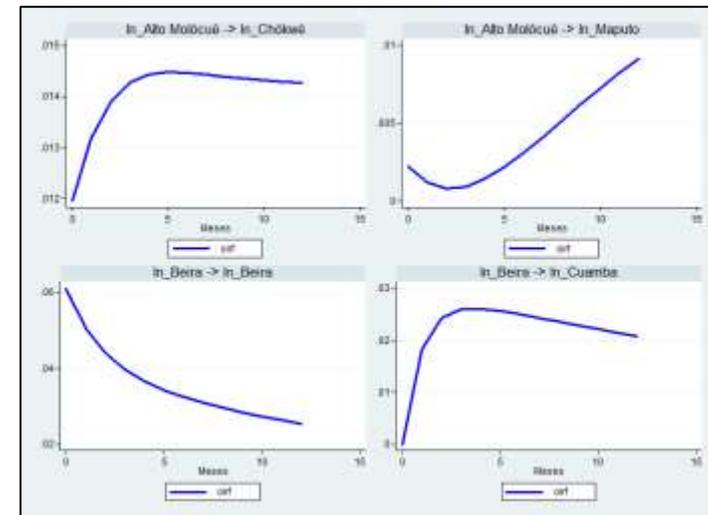
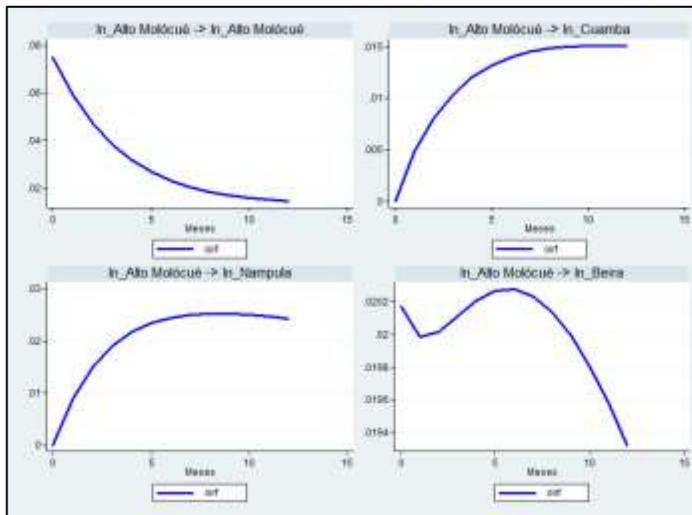
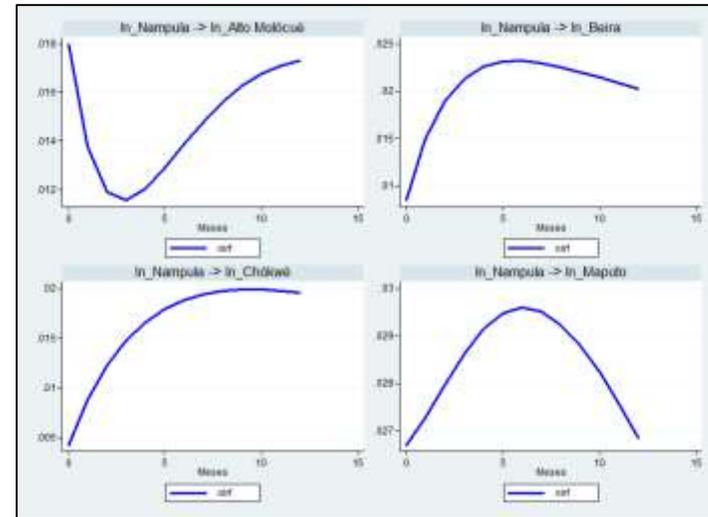
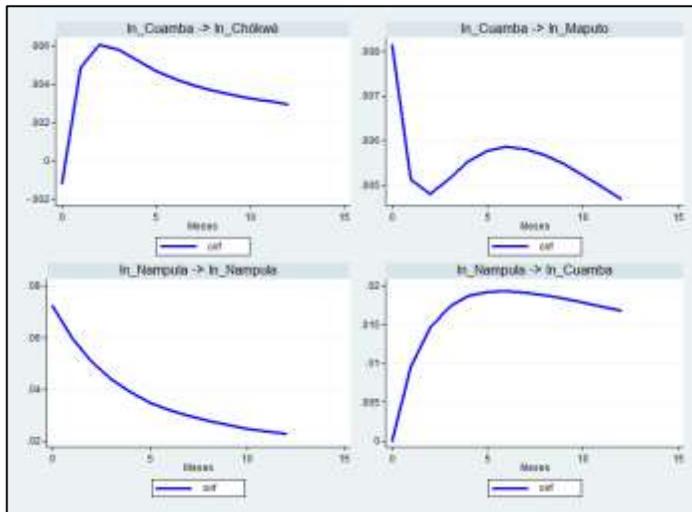
Cluster 6: Cabo Delgado (Balama e Muidumbe).

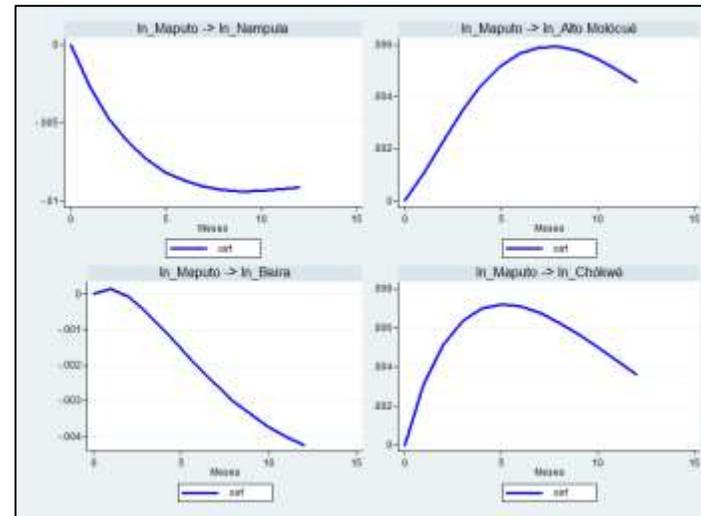
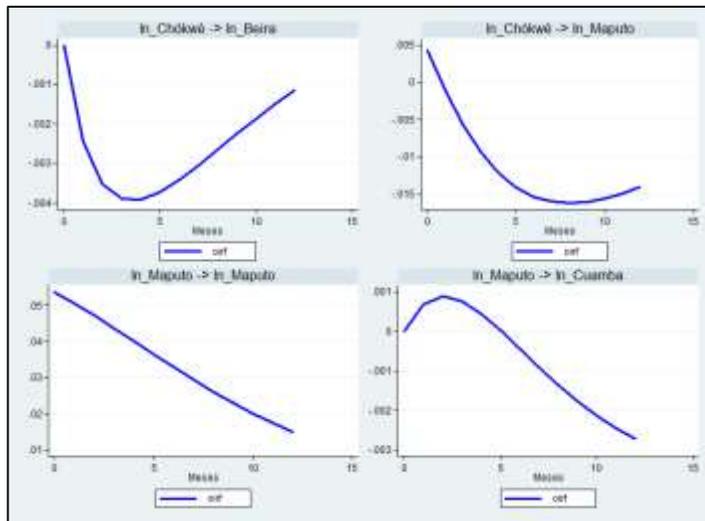
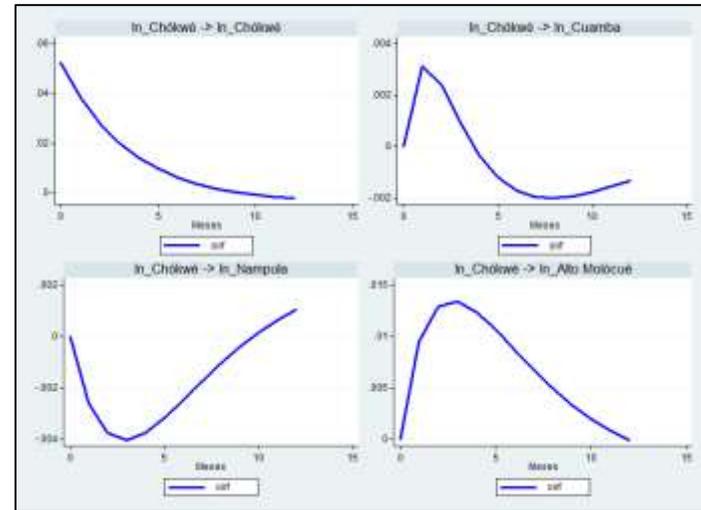
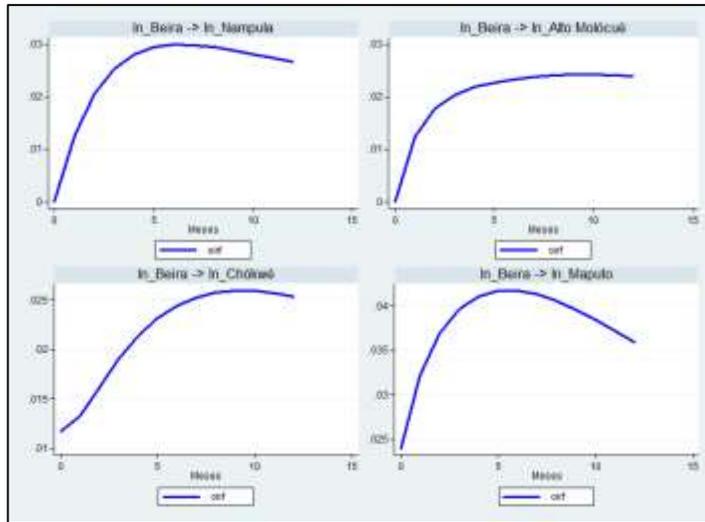
Anexo 2: Gráfico da estacionariedade de preços em primeira diferença



Anexo 3: Gráficos da Função Impulso Resposta (FIR)







Mercado da Beira

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-2.766	-4.034	-3.447	-3.147

MacKinnon approximate p-value for Z(t) = 0.2096

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	0.524	-2.597	-1.950	-1.611

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-3.183	-19.863	-13.738	-11.025
Z(t)	-1.234	-3.504	-2.889	-2.579

MacKinnon approximate p-value for Z(t) = 0.6589

Mercado de Chókwe

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-2.579	-4.034	-3.447	-3.147

MacKinnon approximate p-value for Z(t) = 0.2895

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	0.720	-2.597	-1.950	-1.611

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Z(t) has t-distribution			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-1.548	-2.359	-1.658	-1.289

p-value for Z(t) = 0.0622

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-11.822	-27.527	-20.776	-17.563
Z(t)	-2.509	-4.034	-3.447	-3.147

MacKinnon approximate p-value for Z(t) = 0.3237

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	0.127	-13.338	-7.913	-5.613
Z(t)	0.766	-2.597	-1.950	-1.611

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Z(t) has t-distribution			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-2.221	-2.359	-1.658	-1.289

p-value for Z(t) = 0.0141

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-11.822	-27.527	-20.776	-17.563
Z(t)	-2.509	-4.034	-3.447	-3.147

MacKinnon approximate p-value for Z(t) = 0.3237

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-3.183	-19.863	-13.738	-11.025
Z(t)	-1.234	-3.504	-2.889	-2.579

MacKinnon approximate p-value for Z(t) = 0.6589

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	0.127	-13.338	-7.913	-5.613
Z(t)	0.766	-2.597	-1.950	-1.611

Mercado de Maputo

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-1.524	-4.034	-3.447	-3.147

MacKinnon approximate p-value for Z(t) = 0.8208

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Z(t) has t-distribution			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-1.357	-2.359	-1.658	-1.289

p-value for Z(t) = 0.0886

Dickey-Fuller test for unit root Number of obs = 119

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	0.308	-2.597	-1.950	-1.611

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-11.822	-27.527	-20.776	-17.563
Z(t)	-2.509	-4.034	-3.447	-3.147

MacKinnon approximate p-value for Z(t) = 0.3237

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-3.183	-19.863	-13.738	-11.025
Z(t)	-1.234	-3.504	-2.889	-2.579

MacKinnon approximate p-value for Z(t) = 0.6589

Phillips-Perron test for unit root Number of obs = 119
Newey-West lags = 4

Test Statistic	Interpolated Dickey-Fuller			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	0.127	-13.338	-7.913	-5.613
Z(t)	0.766	-2.597	-1.950	-1.611

Anexo 2: Número de defasagens (lags) incluídas no teste de estacionariedade, teste de cointegração de Johansen e no modelo VEC

varsoc Incuamba Innampula Inaltomolôcuè Inbeira Inchókwè Inmaputo

Selection-order criteria

Sample: May 2011 - December 2020 Number of obs = 116

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	395.525				4.9e-11	-6.71594	-6.65813	-6.57352
1	887.683	984.32	36	0.000	1.9e-14*	-14.5807*	-14.176*	-13.5837*
2	921.093	66.822	36	0.001	2.0e-14	-14.5361	-13.7845	-12.6845
3	948.245	54.304	36	0.026	2.3e-14	-14.3835	-13.285	-11.6774
4	976.361	56.231*	36	0.017	2.7e-14	-14.2476	-12.8022	-10.6869

Anexo 3: Resultados do teste (geral) de Cointegração de Johansen

```

Johansen tests for cointegration
Trend: constant                               Number of obs = 119
Sample: February 2011 - December 2020        Lags = 1

```

maximum	rank	parms	LL	eigenvalue	trace	5% critical value
	0	6	834.40587	.	145.7308	94.15
	1	17	866.00666	0.41205	82.5292	68.52
	2	26	880.8402	0.22066	52.8622	47.21
	3	33	893.26626	0.18848	28.0100*	29.68
	4	38	903.58031	0.15915	7.3819	15.41
	5	41	906.54145	0.04855	1.4596	3.76
	6	42	907.27127	0.01219		

maximum	rank	parms	LL	eigenvalue	max statistic	5% critical value
	0	6	834.40587	.	63.2016	39.37
	1	17	866.00666	0.41205	29.6671	33.46
	2	26	880.8402	0.22066	24.8521	27.07
	3	33	893.26626	0.18848	20.6281	20.97
	4	38	903.58031	0.15915	5.9223	14.07
	5	41	906.54145	0.04855	1.4596	3.76
	6	42	907.27127	0.01219		

Anexo 3.1: Resultados do teste (em pares) de Cointegração de Johansen

Cuamba-Nampula

```

vecrank Incuamba Innampula, trend(constant) lags(1) max

```

```

Johansen tests for cointegration
Trend: constant                               Number of obs = 119
Sample: February 2011 - December 2020        Lags = 1

```

maximum	rank	parms	LL	eigenvalue	trace	5% critical value
	0	2	210.73336	.	42.3627	15.41
	1	5	230.85474	0.28693	2.1200*	3.76
	2	6	231.91472	0.01766		

maximum	rank	parms	LL	eigenvalue	max statistic	5% critical value
	0	2	210.73336	.	40.2428	14.07
	1	5	230.85474	0.28693	2.1200	3.76
	2	6	231.91472	0.01766		

Cuamba-Alto Molócuè

```

vecrank Incuamba Inaltomolócuè, trend(constant) lags(1) max

```

```

Johansen tests for cointegration
Trend: constant                               Number of obs = 119
Sample: February 2011 - December 2020        Lags = 1

```

maximum	rank	parms	LL	eigenvalue	trace	5% critical value
	0	2	200.68795	.	34.7414	15.41
	1	5	216.2232	0.22979	3.6709*	3.76
	2	6	218.05867	0.03038		

Cuamba-Beira

```

vecrank Incuamba Inbeira, trend(constant) lags(1) max

```

```

Johansen tests for cointegration
Trend: constant                               Number of obs = 119
Sample: February 2011 - December 2020        Lags = 1

```

maximum	rank	parms	LL	eigenvalue	trace	5% critical value
	0	2	227.71462	.	49.3315	15.41
	1	5	251.32671	0.32756	2.1073*	3.76
	2	6	252.38037	0.01755		

maximum	rank	parms	LL	eigenvalue	max statistic	5% critical value
	0	2	200.68795	.	31.0705	14.07
	1	5	216.2232	0.22979	3.6709	3.76
	2	6	218.05867	0.03038		

maximum	rank	parms	LL	eigenvalue	max statistic	5% critical value
	0	2	227.71462	.	47.2242	14.07
	1	5	251.32671	0.32756	2.1073	3.76
	2	6	252.38037	0.01755		

Cuamba-Chókwè

```

. vecrank lncuamba lncókwè, trend(constant) lags(1) max

Johansen tests for cointegration
Trend: constant      Number of obs = 119
Sample: February 2011 - December 2020      Lags = 1

```

rank	parms	LL	eigenvalue	trace statistic	5% critical value
0	2	239.24997	.	46.3366	15.41
1	5	260.97149	0.30585	2.8936*	3.76
2	6	262.41828	0.02402		

rank	parms	LL	eigenvalue	max statistic	5% critical value
0	2	239.24997	.	43.4430	14.07
1	5	260.97149	0.30585	2.8936	3.76
2	6	262.41828	0.02402		

Cuamba-Maputo

```

. vecrank lncuamba lncmaputo, trend(constant) lags(1) max

Johansen tests for cointegration
Trend: constant      Number of obs = 119
Sample: February 2011 - December 2020      Lags = 1

```

rank	parms	LL	eigenvalue	trace statistic	5% critical value
0	2	227.37822	.	28.3786	15.41
1	5	240.67395	0.20025	1.7872*	3.76
2	6	241.56753	0.01491		

Nampula-Alto Molócue

```

. vecrank lncuamba lncaltomolócué, trend(constant) lags(1) max

Johansen tests for cointegration
Trend: constant      Number of obs = 119
Sample: February 2011 - December 2020      Lags = 1

```

rank	parms	LL	eigenvalue	trace statistic	5% critical value
0	2	261.50275	.	16.9574	15.41
1	5	268.84714	0.11612	2.2687*	3.76
2	6	269.98148	0.01888		

rank	parms	LL	eigenvalue	max statistic	5% critical value
0	2	227.37822	.	26.5915	14.07
1	5	240.67395	0.20025	1.7872	3.76
2	6	241.56753	0.01491		

rank	parms	LL	eigenvalue	max statistic	5% critical value
0	2	261.50275	.	14.6888	14.07
1	5	268.84714	0.11612	2.2687	3.76
2	6	269.98148	0.01888		

Nampula-Beira

```

. vecrank lncuamba lncbeira, trend(constant) lags(1) max

Johansen tests for cointegration
Trend: constant      Number of obs = 119
Sample: February 2011 - December 2020      Lags = 1

```

rank	parms	LL	eigenvalue	trace statistic	5% critical value
0	2	296.80842	.	23.0907	15.41
1	5	297.66568	0.16679	1.3761*	3.76
2	6	298.35375	0.01150		

rank	parms	LL	eigenvalue	max statistic	5% critical value
0	2	286.80842	.	21.7145	14.07
1	5	297.66568	0.16679	1.3761	3.76
2	6	298.35375	0.01150		

Nampula-Chókwè

. vecrank lnampula lnchókwè, trend(constant) lags(1) max

Johansen tests for cointegration						Number of obs =	119
Trend: constant						Lags =	1
Sample: February 2011 - December 2020							
maximum	rank	parms	LL	eigenvalue	trace	5%	critical
	0	2	298.2292	.	18.6275	15.41	
	1	5	306.30644	0.12694	2.4730*	3.76	
	2	6	307.54293	0.02057			

maximum	rank	parms	LL	eigenvalue	trace	5%	critical
	0	2	298.2292	.	16.1545	14.07	
	1	5	306.30644	0.12694	2.4730	3.76	
	2	6	307.54293	0.02057			

Nampula-Maputo

. vecrank lnampula lnmaputo, trend(constant) lags(1) max

Johansen tests for cointegration						Number of obs =	119
Trend: constant						Lags =	1
Sample: February 2011 - December 2020							
maximum	rank	parms	LL	eigenvalue	trace	5%	critical
	0	2	296.4366	.	7.0137*	15.41	
	1	5	298.9729	0.04173	1.9411	3.76	
	2	6	299.94344	0.01618			

maximum	rank	parms	LL	eigenvalue	max	5%	critical
	0	2	296.4366	.	5.0726	14.07	
	1	5	298.9729	0.04173	1.9411	3.76	
	2	6	299.94344	0.01618			

Alto Molócuè-Beira

. vecrank lnaltomolócuè lnbeira, trend(constant) lags(1) max

Johansen tests for cointegration						Number of obs =	119
Trend: constant						Lags =	1
Sample: February 2011 - December 2020							
maximum	rank	parms	LL	eigenvalue	trace	5%	critical
	0	2	279.93951	.	18.2611	15.41	
	1	5	288.04887	0.12741	2.0424*	3.76	
	2	6	289.07007	0.01702			

maximum	rank	parms	LL	eigenvalue	max	5%	critical
	0	2	279.93951	.	16.2187	14.07	
	1	5	288.04887	0.12741	2.0424	3.76	
	2	6	289.07007	0.01702			

Alto Molócuè-Chókwè

. vecrank lnaltomolócuè lnchókwè, trend(constant) lags(1) max

Johansen tests for cointegration						Number of obs =	119
Trend: constant						Lags =	1
Sample: February 2011 - December 2020							
maximum	rank	parms	LL	eigenvalue	trace	5%	critical
	0	2	289.3324	.	26.5358	15.41	
	1	5	300.88976	0.17654	3.4211*	3.76	
	2	6	302.60031	0.02834			

Alto Molócuè-Maputo

. vecrank lnaltomolócuè lnmaputo, trend(constant) lags(1) max

Johansen tests for cointegration						Number of obs =	119
Trend: constant						Lags =	1
Sample: February 2011 - December 2020							
maximum	rank	parms	LL	eigenvalue	trace	5%	critical
	0	2	276.1765	.	11.2724*	15.41	
	1	5	280.92027	0.07663	1.7849	3.76	
	2	6	281.81272	0.01489			

maximum	rank	parms	LL	eigenvalue	max	5%	critical
	0	2	276.1765	.	9.4875	14.07	
	1	5	280.92027	0.07663	1.7849	3.76	
	2	6	281.81272	0.01489			

Anexo 4: Resultados do VEC (mercados pareados) e respectivos testes de especificação

Cuamba-Nampula

```
. vec Incuamba Innampula, sindicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)
> lags(2)
```

Vector error-correction model

```
Sample: March 2011 - December 2020      Number of obs   =      118
                                           AIC              =    -3.612091
Log likelihood =    248.1133              HQIC            =    -3.27841
Det (Sigma_m1) =    .0000511             SBIC           =    -2.790277
```

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_Incuamba	17	.108608	0.2631	36.06394	0.0045
D_Innampula	17	.07897	0.1330	15.49147	0.5601

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_Incuamba					
_cel					
L1.	-.3548409	.0853263	-4.16	0.000	-.5220774 -.1876044
Incuamba					
LD.	.0141323	.0872577	0.16	0.871	-.1568896 .1851542
Innampula					
LD.	.183179	.1382381	1.33	0.185	-.0877627 .4541207
m1	-.0405555	.0500705	-0.81	0.418	-.138692 .0575809
m2	.0180354	.0512712	0.35	0.725	-.0824543 .1185252
m3	-.0115913	.0486628	-0.24	0.812	-.1069687 .0837862
m4	-.0072418	.0490585	-0.15	0.883	-.1033947 .088911
m5	-.0816611	.048682	-1.68	0.093	-.177076 .0137538
m6	.0014515	.049423	0.03	0.977	-.0954158 .0983188
m7	-.0115736	.049275	-0.23	0.814	-.1081509 .0850037
m8	-.0059405	.0490715	-0.12	0.904	-.1021188 .0902378
m9	-.0130339	.048883	-0.27	0.790	-.1088429 .0827751
m10	.0266784	.0486913	0.55	0.584	-.0687549 .1221116
m11	.0019632	.0487222	0.04	0.968	-.0935305 .097457
dumDPG	.013557	.0212909	0.64	0.524	-.0281724 .0552863
dumCOV	-.0480973	.0389369	-1.24	0.217	-.1244121 .0282176
_cons	-.0018509	.0365035	-0.05	0.960	-.0733965 .0696948

Johansen normalization restriction imposed

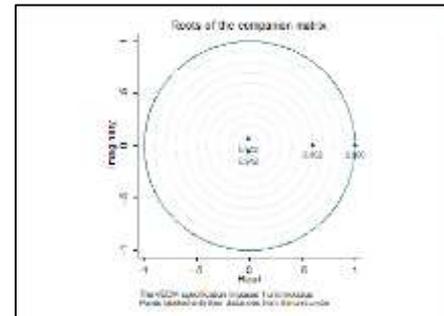
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
Incuamba	1
Innampula	-.6950826	.1477328	-4.70	0.000	-.9846336 -.4055316
_cons	-1.186558

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	2.1830	4	0.70214
2	4.9692	4	0.29047

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_Incuamba	1.869	2	0.39278
D_Innampula	35.661	2	0.00000
ALL	37.530	4	0.00000



Johansen normalization restriction imposed

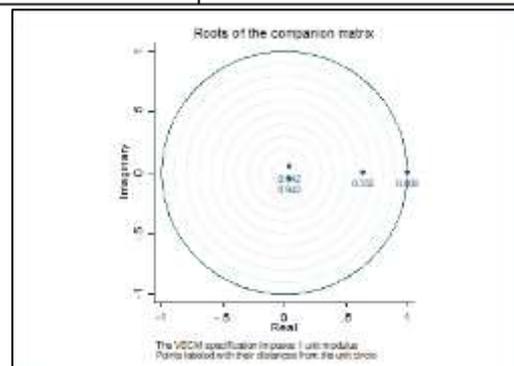
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
Incuamba	1
Inaltomolôcué	-.2299733	.1606563	-1.43	0.152	-.5448539 .0849073
_cons	-2.633993

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	10.8923	4	0.02780
2	13.1703	4	0.01047

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_Innaputo	1125.672	2	0.00000
D_Inchókwé	158.693	2	0.00000
ALL	1284.365	4	0.00000



Cuamba-Alto Molôcué

```
. vec Incuamba Inaltomolôcué, sindicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)
```

Vector error-correction model

```
Sample: March 2011 - December 2020      Number of obs   =      118
                                           AIC              =    -3.46976
Log likelihood =    239.7158              HQIC            =    -3.136079
Det (Sigma_m1) =    .000059              SBIC           =    -2.647946
```

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_Incuamba	17	.106724	0.2885	40.94403	0.0010
D_Inaltomolôcué	17	.084082	0.1649	19.94958	0.2768

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_Incuamba					
_cel					
L1.	-.3267655	.0778405	-4.20	0.000	-.4793301 -.174201
Incuamba					
LD.	.0291919	.0850342	0.34	0.731	-.1374722 .1958559
Inaltomolôcué					
LD.	.2457064	.1274445	1.93	0.054	-.0040803 .495493
m1	-.0517625	.0496148	-1.04	0.297	-.1490058 .0454808
m2	.0186745	.0506791	0.37	0.713	-.0806546 .1180037
m3	-.0094206	.0477985	-0.20	0.844	-.1031039 .0842627
m4	-.0051605	.0480355	-0.11	0.914	-.0993084 .0889875
m5	-.0847295	.0478426	-1.77	0.077	-.1784993 .0090403
m6	-.0100847	.0489601	-0.21	0.837	-.1060448 .0858753
m7	-.0032095	.0482051	-0.07	0.947	-.0976897 .0912708
m8	.0099089	.0479018	0.21	0.836	-.083977 .1037948
m9	-.0348949	.0484971	-0.72	0.472	-.1299475 .0601578
m10	.013688	.048274	0.28	0.777	-.0809274 .1083033
m11	-.0046223	.0480438	-0.10	0.923	-.0987864 .0895419
dumDPG	.0627759	.0255206	2.46	0.014	.0127565 .1127953
dumCOV	.0321525	.0376001	0.86	0.392	-.0415424 .1058474
_cons	-.0002696	.0361465	-0.01	0.994	-.0711154 .0705763

Cuamba-Beira

. vec Incuamba Inbeira, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*) la
> gs (2)

Vector error-correction model

Sample: March 2011 - December 2020 Number of obs = 118
AIC = -4.046907
Log likelihood = 273.7675 HQIC = -3.713227
Det (Sigma_m1) = .0000331 SBIC = -3.225094

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_Incuamba	17	.104343	0.3199	47.49833	0.0001
D_Inbeira	17	.064766	0.2219	28.80916	0.0363

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_Incuamba					
_cel					
LL	-.4896097	.0913138	-5.36	0.000	-.6685815
Incuamba					
LD	.083858	.0858018	0.98	0.328	-.0843105
Inbeira					
LD	.0386489	.1572784	0.25	0.806	-.2696111
m1	-.042165	.0480977	-0.88	0.381	-.1364349
m2	.0281235	.0485858	0.58	0.563	-.0671029
m3	-.024587	.0469392	-0.52	0.600	-.116586
m4	-.0034357	.0468923	-0.07	0.942	-.0953429
m5	-.0818228	.0468493	-1.75	0.081	-.1736457
m6	-.0018981	.0474486	-0.04	0.968	-.0948956
m7	-.0025464	.0473118	-0.05	0.957	-.0952759
m8	.012255	.046782	0.26	0.793	-.0794361
m9	-.0252461	.0471406	-0.54	0.592	-.11764
m10	.0309388	.0468559	0.66	0.509	-.060897
m11	.0029237	.0468825	0.06	0.950	-.0889642
dumDPG	.0211776	.020696	1.02	0.306	-.0193859
dumCOV	.0020986	.0359866	0.06	0.953	-.0684338
_cons	.0000113	.0350415	0.00	1.000	-.0686688

Johansen normalization restriction imposed

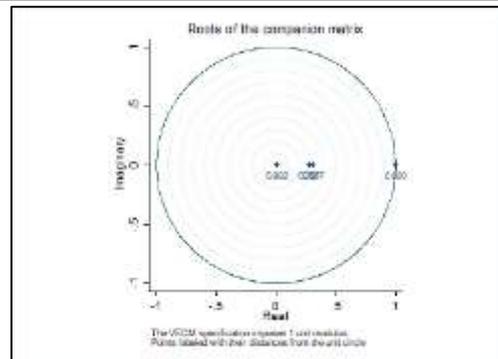
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
cel					
Incuamba	1
Inbeira	-.6490493	.1375029	-4.72	0.000	-.9185502
_cons	-1.327237	.	.	.	-.3795485

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	2.5627	4	0.63345
2	1.6872	4	0.79304

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_Incuamba	7.997	2	0.01835
D_Inbeira	193.548	2	0.00000
ALL	201.545	4	0.00000



Cuamba-Chókwè

. vec Incuamba Inchókwè, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)
> aqs (2)

Vector error-correction model

Sample: March 2011 - December 2020 Number of obs = 118
AIC = -4.239279
Log likelihood = 285.1175 HQIC = -3.905599
Det (Sigma_m1) = .0000273 SBIC = -3.417466

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_Incuamba	17	.108412	0.2658	36.55925	0.0039
D_Inchókwè	17	.05771	0.1747	21.3854	0.2095

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_Incuamba					
_cel					
LL	-.406798	.0881966	-4.61	0.000	-.5796601
Incuamba					
LD	.0785138	.089141	0.88	0.378	-.0961994
Inchókwè					
LD	.2010659	.170564	1.18	0.238	-.1332335
m1	-.0318984	.0501594	-0.64	0.525	-.1302089
m2	.050385	.0501802	1.00	0.315	-.0479663
m3	-.0001332	.0485476	-0.00	0.998	-.0952846
m4	-.0174183	.0485256	0.36	0.720	-.0776901
m5	-.0777705	.0485708	-1.60	0.109	-.1729675
m6	-.0003895	.0493912	-0.01	0.994	-.0971945
m7	-.0053015	.0490908	-0.11	0.914	-.1015177
m8	.0001862	.0488164	0.00	0.997	-.0954923
m9	-.0319478	.0488428	-0.65	0.513	-.1276778
m10	.0277316	.0488618	0.57	0.570	-.0680357
m11	.014157	.0489276	0.29	0.772	-.0817394
dumDPG	.04327	.0229365	1.89	0.059	-.0016846
dumCOV	.0311998	.0379806	0.82	0.411	-.0432409
_cons	-.0022071	.0364392	-0.06	0.952	-.0736265

Johansen normalization restriction imposed

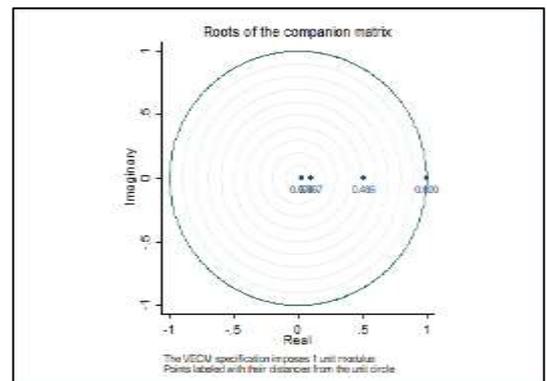
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
cel					
Incuamba	1
Inchókwè	-.5544341	.1329106	-4.17	0.000	-.814934
_cons	-1.527704	.	.	.	-.2939341

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	0.8771	4	0.92783
2	1.1507	4	0.88615

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_Incuamba	8.913	2	0.01160
D_Inchókwè	252.018	2	0.00000
ALL	260.931	4	0.00000



Cuamba-Maputo

```
. vec incuamba innaputo, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)
> aqs(2)
```

Vector error-correction model

```
Sample: March 2011 - December 2020      Number of obs = 118
                                           AIC = -3.86693
Log likelihood = 263.1488                HQIC = -3.533249
Det(Sigma_ml) = .0000396                SBIC = -3.045116
```

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_incuamba	17	.107048	0.2841	40.08667	0.0013
D_innaputo	17	.069812	0.1146	13.07564	0.7311

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_incuamba					
_cel					
L1.	-.4020736	.0871049	-4.62	0.000	-.5727961 - .2313511
incuamba					
LD.	.0435612	.0894456	0.49	0.626	-.131749 .2188715
innaputo					
LD.	.2212315	.155454	1.42	0.155	-.0834526 .5259157
m1	-.0347971	.0493193	-0.71	0.480	-.1314612 .0618669
m2	.0351857	.0499954	0.70	0.482	-.0628035 .1331749
m3	-.008161	.0479352	-0.17	0.865	-.1021123 .0857903
m4	.0054027	.0479571	0.11	0.910	-.0885914 .0993968
m5	-.0875626	.0481478	-1.82	0.069	-.1819306 .0068054
m6	-.0132863	.0494176	-0.27	0.788	-.1101431 .0835704
m7	-.0178478	.0486889	-0.37	0.714	-.1132765 .077581
m8	-.0043104	.048277	-0.09	0.929	-.0989317 .0903108
m9	-.0290494	.0481173	-0.60	0.546	-.1233575 .0652587
m10	.0290969	.0481223	0.60	0.545	-.0652211 .1234149
m11	.0021412	.0480001	0.04	0.964	-.0919373 .0962197
dumDPG	.058316	.0241948	2.41	0.016	.010895 .105737
dumCOV	.0519276	.0393818	1.32	0.187	-.0252594 .1291145
_cons	.0006337	.0360171	0.02	0.986	-.0699585 .0712259

Johansen normalization restriction imposed

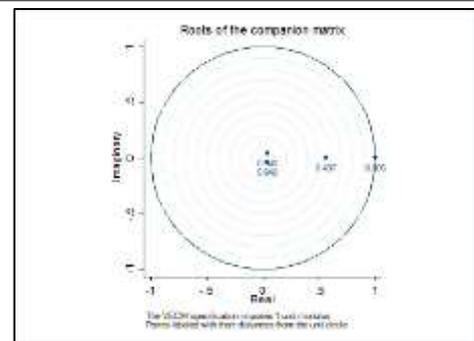
	beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
cel						
incuamba		1				
innaputo		-.3181562	.1073692	-2.96	0.003	-.528596 - .1077165
_cons		-2.364923				

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	1.3684	4	0.84966
2	2.7364	4	0.60287

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_incuamba	7.168	2	0.02777
D_innaputo	707.815	2	0.00000
ALL	714.982	4	0.00000



Nampula-Cuamba

```
. vec innampula incuamba, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)
> lags(2)
```

Vector error-correction model

```
Sample: March 2011 - December 2020      Number of obs = 118
                                           AIC = -3.612091
Log likelihood = 248.1133                HQIC = -3.27841
Det(Sigma_ml) = .0000511                SBIC = -2.790277
```

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_innampula	17	.07897	0.1330	15.49147	0.5601
D_incuamba	17	.108608	0.2631	36.06394	0.0045

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_innampula					
_cel					
L1.	-.0668392	.043124	-1.55	0.121	-.1513608 .0176824
innampula					
LD.	.0130332	.1005143	0.13	0.897	-.1839712 .2100375
incuamba					
LD.	-.091832	.0634459	-1.45	0.148	-.2161837 .0325197
m1	.0617534	.0364068	1.70	0.090	-.0096026 .1331093
m2	.0025923	.0372798	0.07	0.945	-.0704748 .0756594
m3	.0368788	.0353832	1.04	0.297	-.0324711 .1062286
m4	-.0055481	.0356709	-0.16	0.876	-.0754618 .0643656
m5	.0033495	.0353971	0.09	0.925	-.0660276 .0727266
m6	.0176907	.035936	0.49	0.623	-.0527425 .0881239
m7	.0252777	.0358284	0.71	0.480	-.0449446 .0955
m8	-.0274587	.0356804	-0.77	0.442	-.0973909 .0424735
m9	.0050925	.0355433	0.14	0.886	-.0645711 .0747562
m10	.0120721	.0354039	0.34	0.733	-.0573183 .0814625
m11	-.0053943	.0354264	-0.15	0.879	-.0748287 .0640402
dumDPG	.0042693	.0154808	0.28	0.783	-.0260725 .0346111
dumCOV	.0422972	.0283114	1.49	0.135	-.0131921 .0977864
_cons	-.00683	.0265421	-0.26	0.797	-.0588515 .0451916

Johansen normalization restriction imposed

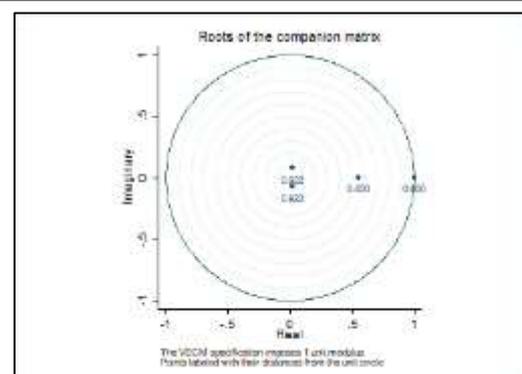
	beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
cel						
innampula		1				
incuamba		-1.438678	.2476919	-5.81	0.000	-1.924145 - .9532108
_cons		1.707075				

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	2.1830	4	0.70214
2	4.9692	4	0.29047

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_innampula	53.513	2	0.00000
D_incuamba	0.817	2	0.66460
ALL	54.330	4	0.00000



Nampula-Alto Molócué

. vec innampula inaltomolócué, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -4.301934
 HQIC = -3.968254
 Det(Sigma_ml) = .0000257
 SBIC = -3.480121

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_innampula	17	.072693	0.2653	36.47683	0.0040
D_inaltomolócué	17	.083921	0.1681	20.41272	0.2537

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
D_innampula						
_cel						
L1.	-.2591529	.060665	-4.27	0.000	-.3780541	-.1402517
innampula						
LD.	.0192075	.0931432	0.21	0.837	-.1633499	.2017648
inaltomolócué						
LD.	.0527394	.0894971	0.59	0.556	-.1226717	.2281505
m1	.056154	.0337892	1.66	0.097	-.0100715	.1223796
m2	-.0047509	.0348456	-0.14	0.892	-.0730471	.0635452
m3	.0327564	.0325776	1.01	0.315	-.0310946	.0966074
m4	-.0105813	.0328715	-0.32	0.748	-.0750083	.0538457
m5	-.0003303	.0325626	-0.01	0.993	-.0641246	.0635185
m6	.0071938	.0329602	0.22	0.827	-.057407	.0717946
m7	.0184331	.0325913	0.57	0.572	-.0454447	.082311
m8	-.0221375	.0327073	-0.68	0.499	-.0862427	.0419676
m9	-.0040527	.0332506	-0.12	0.903	-.0692227	.0611172
m10	.0012878	.0328516	0.04	0.969	-.0631001	.0656758
m11	-.0151543	.0326884	-0.46	0.643	-.0792224	.0489137
dumDPG	.0405735	.0161728	2.51	0.012	.0088754	.0722717
dumCOV	.104475	.030506	3.42	0.001	.0446843	.1642657
_cons	.0003204	.0245991	0.01	0.990	-.0478929	.0485337

Johansen normalization restriction imposed

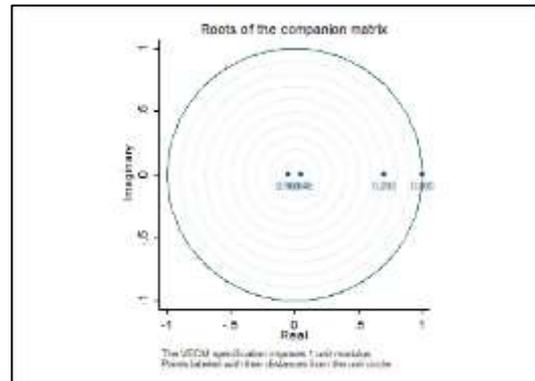
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cel	1	
innampula	-.6755883	.1324708	-5.10	0.000	-.9352262	-.4159504
inaltomolócué	-.9246458

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	6.3480	4	0.17462
2	10.1348	4	0.03822

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_innampula	63.060	2	0.00000
D_inaltomolócué	52.859	2	0.00000
ALL	115.919	4	0.00000



Nampula-Beira

. vec innampula inbeira, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)
 > ags(2)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -4.795387
 HQIC = -4.461707
 Det(Sigma_ml) = .0000157
 SBIC = -3.973574

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_innampula	17	.073288	0.2533	34.25353	0.0078
D_inbeira	17	.064347	0.2320	30.50279	0.0229

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
D_innampula						
_cel						
L1.	-.2814988	.0644872	-4.37	0.000	-.4078914	-.1551062
innampula						
LD.	.0688524	.0940084	0.73	0.464	-.1154007	.2531055
inbeira						
LD.	-.03637	.1099174	-0.33	0.741	-.2518042	.1790641
m1	.0585202	.0338091	1.73	0.083	-.0077445	.1247849
m2	.002384	.0345166	0.07	0.945	-.0652674	.0700354
m3	.027071	.0329749	0.82	0.412	-.0375586	.0917006
m4	-.0107223	.0330535	-0.32	0.746	-.0755059	.0540613
m5	.0019923	.032816	0.06	0.952	-.0623259	.0663105
m6	.0174403	.0327908	0.53	0.595	-.0468285	.081709
m7	.0256809	.0329882	0.78	0.436	-.0389749	.0903367
m8	-.0180314	.0330632	-0.55	0.586	-.0828342	.0467713
m9	.0033329	.0332625	0.10	0.920	-.0618603	.0685262
m10	.0130541	.0328502	0.40	0.691	-.0513311	.0774392
m11	-.0076998	.0329306	-0.23	0.815	-.0722426	.056843
dumDPG	.0165953	.0144294	1.15	0.250	-.0116858	.0448764
dumCOV	.0826118	.0279777	2.95	0.003	.0277766	.137447
_cons	-.0002755	.0246809	-0.01	0.991	-.0486492	.0480981

Johansen normalization restriction imposed

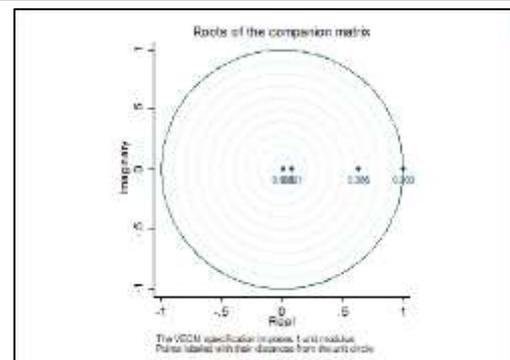
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cel	1	
innampula	-.8537677	.1514687	-5.64	0.000	-1.150641	-.5568945
inbeira	-.4442708

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	3.1277	4	0.53669
2	1.6075	4	0.80745

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_innampula	49.782	2	0.00000
D_inbeira	178.166	2	0.00000
ALL	227.948	4	0.00000



Nampula-Chókwè

```
. vec innampula inchókwè, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)
> laqs(2)
```

Vector error-correction model

```
Sample: March 2011 - December 2020      Number of obs = 118
                                           AIC = -5.012928
Log likelihood = 330.7627                 HQIC = -4.679247
Det (Sigma_ml) = .0000126                SBIC = -4.191114
```

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_innampula	17	.075213	0.2135	27.41867	0.0522
D_inchókwè	17	.056711	0.2030	25.73105	0.0795

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_innampula_cel					
L1.	-.2357441	.0640461	-3.68	0.000	-.3612723 - .110216
innampula_LD.	.0700209	.0983049	0.71	0.476	-.1226532 .2626951
inchókwè_LD.	.0260108	.1199127	0.22	0.828	-.2090138 .2610354
m1	.0620468	.0348496	1.78	0.075	-.0062572 .1303509
m2	.0099987	.0354111	0.28	0.778	-.0594059 .0794032
m3	.0428738	.0337259	1.27	0.204	-.0232278 .1089754
m4	.0012181	.034002	0.04	0.971	-.0654246 .0678609
m5	.0059346	.0337451	0.18	0.860	-.0602047 .0720738
m6	.0149715	.0337555	0.44	0.657	-.0511882 .0811311
m7	.0185399	.0337449	0.55	0.583	-.0475989 .0846786
m8	-.0310877	.03373	-0.92	0.357	-.0971972 .0350218
m9	-.0046191	.0338136	-0.14	0.891	-.0708925 .0616543
m10	-.0060991	.0338159	0.18	0.857	-.0601789 .0723772
m11	-.0061299	.0339705	-0.18	0.857	-.0727108 .0604511
dumDFC	.0332735	.0162283	2.05	0.040	.0014667 .0650803
dumCOV	.0924081	.0308311	3.00	0.003	.0319804 .1528359
_cons	-.0051096	.0253249	-0.20	0.840	-.0547455 .0445264

Johansen normalization restriction imposed

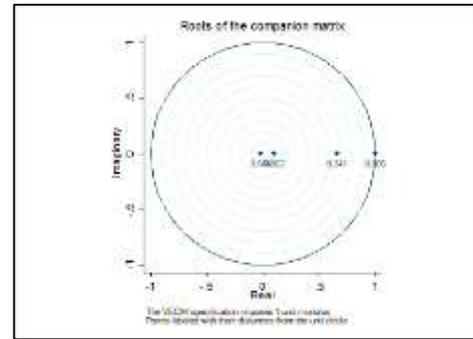
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
cel					
innampula	1
inchókwè	-.7478157	.136425	-5.48	0.000	-1.015204 -.4804275
_cons	-.6662459

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	1.2242	4	0.87409
2	0.4270	4	0.98020

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_innampula	71.197	2	0.00000
D_inchókwè	219.749	2	0.00000
ALL	290.946	4	0.00000



Nampula-Maputo

```
. vec innampula inmaputo, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)
> laqs(2)
```

Vector error-correction model

```
Sample: March 2011 - December 2020      Number of obs = 118
                                           AIC = -4.827261
Log likelihood = 319.8084                 HQIC = -4.493581
Det (Sigma_ml) = .0000152                SBIC = -4.005448
```

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_innampula	17	.073913	0.2405	31.97518	0.0152
D_inmaputo	17	.06783	0.1642	19.84101	0.2824

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_innampula_cel					
L1.	-.2323222	.0557271	-4.17	0.000	-.3415454 - .1230991
innampula_LD.	.0866461	.1027126	0.84	0.399	-.1146668 .2879591
inmaputo_LD.	-.1484413	.1157959	-1.28	0.200	-.375397 .0785145
m1	.0628532	.0340794	1.84	0.065	-.0039413 .1296476
m2	.013704	.0348079	0.39	0.694	-.0545183 .0819262
m3	.0361275	.033114	1.09	0.275	-.0287747 .1010297
m4	-.0067648	.0333383	-0.20	0.839	-.0721066 .058577
m5	.0057158	.0332647	0.17	0.864	-.0594817 .0709133
m6	.0204354	.0335263	0.61	0.542	-.045275 .0861458
m7	.0179835	.0331949	0.54	0.588	-.0470774 .0830444
m8	-.0310209	.0331433	-0.94	0.349	-.0959806 .0339388
m9	.001131	.0332638	0.03	0.973	-.0640649 .0663268
m10	.0048424	.0331705	0.15	0.884	-.0601706 .0698554
m11	-.0080065	.0331057	-0.24	0.809	-.0728924 .0568793
dumDFC	.0534554	.0180942	2.95	0.003	.0179914 .0889194
dumCOV	.1185128	.0329247	3.60	0.000	.0539815 .1830441
_cons	.0038042	.02504	0.15	0.879	-.0452733 .0528818

Johansen normalization restriction imposed

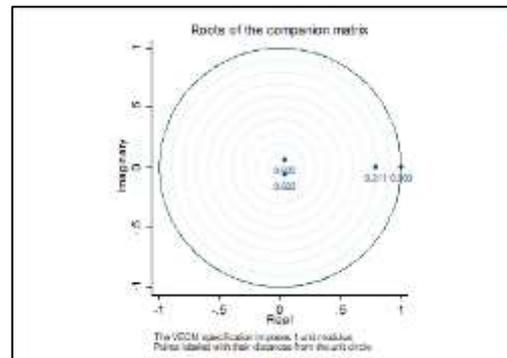
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
cel					
innampula	1
inmaputo	-.3277355	.1293603	-2.53	0.011	-.5812771 -.0741939
_cons	-2.057812

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	2.3449	4	0.67261
2	2.8865	4	0.57700

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_innampula	68.162	2	0.00000
D_inmaputo	235.890	2	0.00000
ALL	304.052	4	0.00000



Alto Molócuè-Cuamba

. vec inaltomolócué incuamba, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -3.46976
 Log likelihood = 239.7158
 HQIC = -3.136079
 Det(Sigma_ml) = .000059
 SBIC = -2.647946

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_inaltomolócué	17	.084082	0.1649	19.94958	0.2768
D_incuamba	17	.106724	0.2885	40.94403	0.0010

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_inaltomolócué_cel					
LI.	.018296	.0141033	1.30	0.195	-.009346 .045938
inaltomolócué					
LD.	-.1484529	.1004059	-1.48	0.139	-.3452447 .048339
incuamba					
LD.	-.0389966	.0669934	-0.58	0.561	-.1703012 .0923079
m1	.0549543	.0390885	1.41	0.160	-.0216579 .1315664
m2	-.0428074	.039927	-1.07	0.284	-.1210628 .0354481
m3	-.0085976	.0376576	-0.23	0.819	-.082405 .0652099
m4	-.0262175	.0378443	-0.69	0.488	-.100391 .047956
m5	.0180097	.0376923	0.48	0.633	-.0558659 .0918853
m6	-.0422411	.0385727	-1.10	0.273	-.1178422 .0333601
m7	-.0493032	.0379779	-1.30	0.194	-.1237385 .0251321
m8	.0184222	.037739	0.49	0.625	-.0555448 .0923893
m9	.0173617	.038208	0.45	0.650	-.0575246 .0922479
m10	-.0050964	.0380322	-0.13	0.893	-.0796382 .0694453
m11	-.0409861	.0378508	-1.08	0.279	-.1151723 .0332002
dumDFG	.0290742	.0201061	1.45	0.148	-.010333 .0684815
dumCOV	.0016814	.0296229	0.06	0.955	-.0563784 .0597411
_cons	.0011073	.0284777	0.04	0.969	-.0547079 .0569225

Johansen normalization restriction imposed

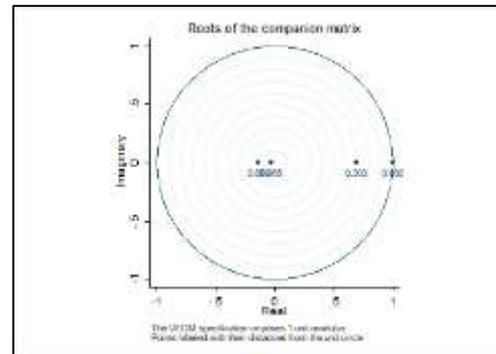
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
inaltomolócué	1
incuamba	-4.348331	.8983565	-4.84	0.000	-6.109077 -2.587584
_cons	11.45347

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	10.8923	4	0.02780
2	13.1703	4	0.01047

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_inaltomolócué	72.435	2	0.00000
D_incuamba	7.863	2	0.01962
ALL	80.298	4	0.00000



Alto Molócuè-Nampula

. vec inaltomolócué innampula, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -4.301934
 Log likelihood = 288.8141
 HQIC = -3.968254
 Det(Sigma_ml) = .0000257
 SBIC = -3.480121

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_inaltomolócué	17	.083921	0.1681	20.41272	0.2537
D_innampula	17	.072693	0.2653	36.47683	0.0040

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_inaltomolócué_cel					
LI.	-.0384952	.047315	-0.81	0.416	-.1312309 .0542406
inaltomolócué					
LD.	-.0620642	.1033208	-0.60	0.548	-.2645693 .1404409
innampula					
LD.	-.1916084	.1075301	-1.78	0.075	-.4023635 .0191467
m1	.0538717	.0390082	1.38	0.167	-.022583 .1303265
m2	-.0312438	.0402279	-0.78	0.437	-.1100889 .0476014
m3	-.003308	.0376096	-0.09	0.930	-.0770214 .0704054
m4	-.0168279	.0379488	-0.44	0.657	-.0912063 .0575505
m5	.0181034	.0375922	0.48	0.630	-.0555761 .0917828
m6	-.0332335	.0380512	-0.87	0.382	-.1078126 .0413455
m7	-.0418102	.0376254	-1.11	0.266	-.1155545 .0319342
m8	.0230332	.0377593	0.61	0.542	-.0509737 .09704
m9	.0087426	.0383865	0.23	0.820	-.0664935 .0839786
m10	-.0023212	.0379258	-0.06	0.951	-.0766545 .0720121
m11	-.040189	.0377374	-1.06	0.287	-.1141529 .033775
dumDFG	.0061291	.0186709	0.33	0.743	-.0304652 .0427233
dumCOV	-.0173106	.035218	-0.49	0.623	-.0863366 .0517154
_cons	.0014573	.0283986	0.05	0.959	-.054203 .0571176

Johansen normalization restriction imposed

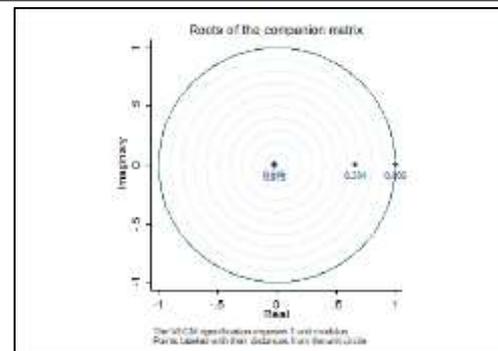
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
inaltomolócué	1
innampula	-1.480191	.2148923	-6.89	0.000	-1.901373 -1.05901
_cons	1.368653

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	6.3480	4	0.17462
2	10.1348	4	0.03822

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_inaltomolócué	81.807	2	0.00000
D_innampula	19.997	2	0.00005
ALL	101.804	4	0.00000



Alto Molócuè-Beira

. vec inaltomolócué inbeira, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: **March 2011 - December 2020** Number of obs = 118
 AIC = -4.602908
 Log likelihood = 306.5716 HQIC = -4.269228
 Det(Sigma_ml) = .000019 SBIC = -3.781095

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_inaltomolócué	17	.079823	0.2474	33.2005	0.0106
D_inbeira	17	.064887	0.2190	28.32301	0.0413

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_inaltomolócué					
_cel					
L1.	-.2185948	.0623326	-3.51	0.000	-.3407643 - .0964252
inaltomolócué					
LD.	.0149774	.0987944	0.15	0.880	-.178656 .2086108
inbeira					
LD.	-.2807754	.120815	-2.32	0.020	-.5175685 -.0439824
m1	.0509353	.0371046	1.37	0.170	-.0217883 .123659
m2	-.0337075	.0378759	-0.89	0.373	-.107943 .040528
m3	-.0017682	.0358645	-0.05	0.961	-.0720614 .068525
m4	-.0292142	.0359287	-0.81	0.416	-.0996331 .0412047
m5	.013567	.0358157	0.38	0.705	-.0566305 .0837645
m6	-.0322415	.0362003	-0.89	0.373	-.1031928 .0387097
m7	-.0454092	.0358219	-1.27	0.205	-.1156188 .0248004
m8	.0211972	.0357044	0.59	0.553	-.0487821 .0911764
m9	.0215303	.03645	0.59	0.555	-.0499105 .0929711
m10	-.0047002	.0362244	-0.13	0.897	-.0756987 .0662984
m11	-.0335504	.0359795	-0.93	0.351	-.1040689 .0369682
dumDFG	.0107732	.0155311	0.69	0.488	-.0196672 .0412135
dumCOV	-.0245461	.0279653	-0.88	0.380	-.079357 .0302648
_cons	.000064	.0270079	0.00	0.998	-.0528705 .0529985

Johansen normalization restriction imposed

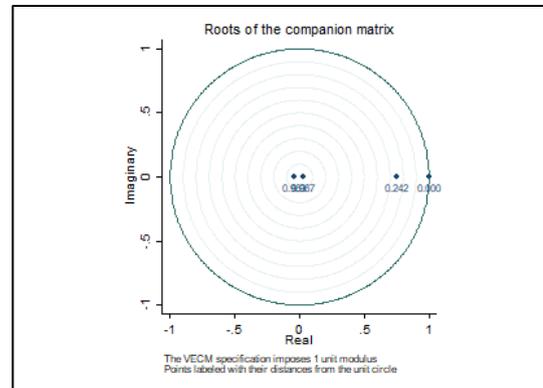
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
inaltomolócué	1				
inbeira	-.8852923	.2273872	-3.89	0.000	-1.330963 -.4396215
_cons	-.5029034				

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	5.2750	4	0.26023
2	5.9621	4	0.20200

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_inaltomolócué	52.346	2	0.00000
D_inbeira	148.337	2	0.00000
ALL	200.683	4	0.00000



Alto Molócuè-Chókwè

. vec inaltomolócué inchókwè, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: **March 2011 - December 2020** Number of obs = 118
 AIC = -4.815725
 Log likelihood = 319.1278 HQIC = -4.482044
 Det(Sigma_ml) = .0000153 SBIC = -3.993912

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_inaltomolócué	17	.081194	0.2213	28.70704	0.0373
D_inchókwè	17	.057984	0.1669	20.22841	0.2627

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_inaltomolócué					
_cel					
L1.	-.2197564	.070722	-3.11	0.002	-.3583689 -.0811438
inaltomolócué					
LD.	-.0226527	.1017217	-0.22	0.824	-.2220236 .1767182
inchókwè					
LD.	.0108742	.1343021	0.08	0.935	-.252353 .2741014
m1	.0527875	.0380227	1.39	0.165	-.0217357 .1273106
m2	-.0299891	.0386621	-0.78	0.438	-.1057654 .0457872
m3	.0067853	.0365923	0.19	0.853	-.0649344 .0785049
m4	-.0123496	.0366586	-0.34	0.736	-.0841991 .0594999
m5	.0240327	.0364394	0.66	0.510	-.0473871 .0954525
m6	-.0317408	.0368669	-0.86	0.389	-.1039986 .0405169
m7	-.0443343	.0363417	-1.22	0.222	-.1155628 .0268942
m8	.0128368	.0364102	0.35	0.724	-.0585258 .0841994
m9	.0046107	.0370766	0.12	0.901	-.0680581 .0772795
m10	-.0049268	.036976	-0.13	0.894	-.0773986 .0675449
m11	-.0366986	.0368563	-1.00	0.319	-.1089357 .0355385
dumDFG	.0161948	.0157703	1.03	0.304	-.0147145 .0471041
dumCOV	-.0096682	.0282932	-0.34	0.733	-.0651219 .0457855
_cons	-.0033361	.0275663	-0.12	0.904	-.057365 .0506928

Johansen normalization restriction imposed

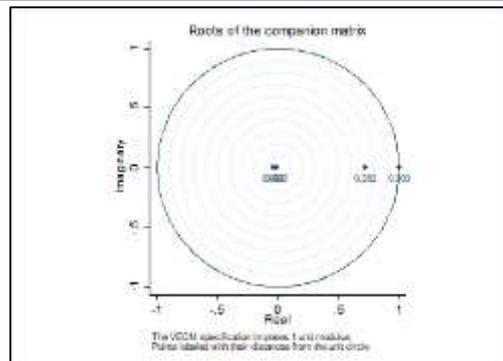
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
inaltomolócué	1				
inchókwè	-.9458534	.1750627	-5.40	0.000	-1.28897 -.6027369
_cons	-.1715688				

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	8.4821	4	0.07543
2	10.7380	4	0.02967

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_inaltomolócué	87.420	2	0.00000
D_inchókwè	185.777	2	0.00000
ALL	273.197	4	0.00000



Alto Molócuè-Maputo

. vec inaltomolocéuá inmaputo, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: **March 2011 - December 2020** Number of obs = 118
 AIC = -4.416203
 Log likelihood = 295.556 HQIC = -4.082523
 Det(Sigma_ml) = .0000229 SBIC = -3.59439

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_inaltomolocéuá	17	.080896	0.2270	29.66373	0.0289
D_inmaputo	17	.069337	0.1266	14.64513	0.6210

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_inaltomolocéuá					
_cel					
L1.	-.1657901	.0498395	-3.33	0.001	-.2634738 -.0681064
inaltomolocéuá					
LD.	-.0385957	.0965132	-0.40	0.689	-.2277582 .1505667
inmaputo					
LD.	-.1419405	.1171714	-1.21	0.226	-.3715922 .0877112
m1	.0535659	.0375947	1.42	0.154	-.0201184 .1272502
m2	-.0276649	.0386467	-0.72	0.474	-.1034109 .0480812
m3	-.0022591	.0362361	-0.06	0.950	-.0732805 .0687624
m4	-.0221242	.0363665	-0.61	0.543	-.0934012 .0491528
m5	.0223607	.0363893	0.61	0.539	-.048961 .0936823
m6	-.0268327	.0370666	-0.72	0.469	-.0994807 .0458153
m7	-.0436432	.0363123	-1.20	0.229	-.114814 .0275275
m8	.0161735	.0362594	0.45	0.656	-.0548937 .0872407
m9	.0125232	.0367898	0.34	0.734	-.0595836 .08463
m10	-.005285	.0366529	-0.14	0.885	-.0771234 .0665535
m11	-.0389186	.0363809	-1.07	0.285	-.1102239 .0323867
dumDPG	.0400837	.0176452	2.27	0.023	.0054998 .0746677
dumCOV	.0151981	.0287451	0.53	0.597	-.0411412 .0715374
_cons	.00372	.027406	0.14	0.892	-.0499948 .0574347

Johansen normalization restriction imposed

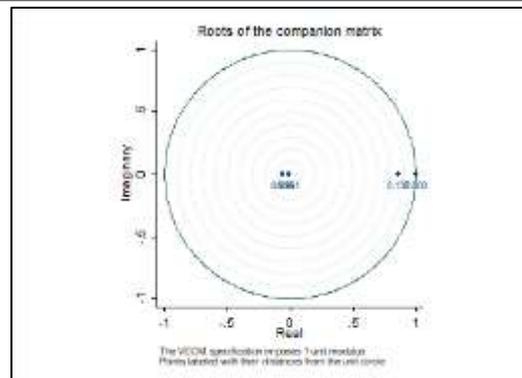
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
inaltomolocéuá	1
inmaputo	-.3077055	.1919449	-1.60	0.109	-.6839105 .0684995
_cons	-2.281432

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	3.5133	4	0.47585
2	10.9249	4	0.02742

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_inaltomolocéuá	71.559	2	0.00000
D_inmaputo	647.363	2	0.00000
ALL	718.922	4	0.00000



Beira-Cuamba

. vec inbeira incuamba, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*) :

Vector error-correction model

Sample: **March 2011 - December 2020** Number of obs = 118
 AIC = -4.046907
 Log likelihood = 273.7675 HQIC = -3.713227
 Det(Sigma_ml) = .0000331 SBIC = -3.225094

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_inbeira	17	.064766	0.2219	28.80916	0.0363
D_incuamba	17	.104343	0.3199	47.49833	0.0001

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_inbeira					
_cel					
L1.	.0088945	.0367873	0.24	0.809	-.0632073 .0809963
inbeira					
LD.	-.3331441	.0976231	-3.41	0.001	-.5244819 -.1418063
incuamba					
LD.	-.0316698	.0532574	-0.59	0.552	-.1360524 .0727129
m1	.0251673	.0298544	0.84	0.399	-.0333462 .0836808
m2	.026149	.0301573	0.87	0.386	-.0329583 .0852563
m3	-.0058481	.0291353	-0.20	0.841	-.0629522 .0512559
m4	-.0277903	.0291062	-0.95	0.340	-.0848373 .0292568
m5	-.0120223	.0290795	-0.41	0.679	-.069017 .0449725
m6	-.0346709	.0294515	-1.18	0.239	-.0923947 .0230529
m7	-.0220275	.0293666	-0.75	0.453	-.0795849 .0355299
m8	.0323901	.0290377	1.12	0.265	-.0245227 .089303
m9	-.0134912	.0292603	-0.46	0.645	-.0708404 .0438579
m10	-.0089964	.0290836	0.31	0.757	-.0480064 .0659992
m11	2.48e-06	.0291001	0.00	1.000	-.0570326 .0570376
dumDPG	.0187364	.0128461	1.46	0.145	-.0064415 .0439142
dumCOV	-.0325021	.022337	-1.46	0.146	-.0762818 .0112776
_cons	-.0004048	.0217504	-0.02	0.985	-.0430347 .0422252

Johansen normalization restriction imposed

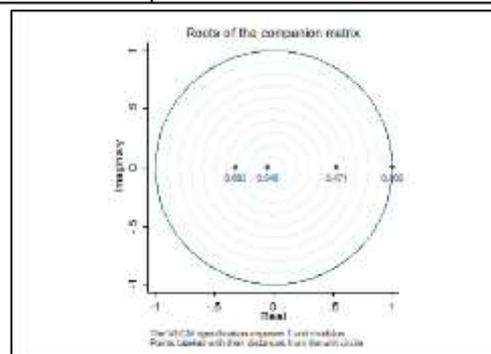
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
inbeira	1
incuamba	-1.540715	.2177876	-7.07	0.000	-1.967571 -1.113859
_cons	2.044894

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	2.5627	4	0.63345
2	1.6872	4	0.79304

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_inbeira	222.974	2	0.00000
D_incuamba	8.175	2	0.01678
ALL	231.148	4	0.00000



Beira-Nampula

. vec lnbeira lnnampula, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -4.795387
 HQIC = -4.461707
 SBIC = -3.973574

Log likelihood = 317.9278
 Det(Sigma_ml) = .0000157

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D lnbeira	17	.064347	0.2320	30.50279	0.0229
D lnnampula	17	.073288	0.2533	34.25353	0.0078

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D lnbeira					
_cel					
L1.	-.058974	.0483404	-1.22	0.222	-.1537195 .0357714
lnbeira					
LD.	-.3002932	.096508	-3.11	0.002	-.4894454 -.111141
lnnampula					
LD.	.0304172	.0825398	0.37	0.712	-.1313579 .1921923
m1	.0250922	.0296846	0.85	0.398	-.0330885 .0832729
m2	.0237708	.0303058	0.78	0.433	-.0356274 .083169
m3	-.0037768	.0289521	-0.13	0.896	-.0605219 .0529683
m4	-.0282465	.0290211	-0.97	0.330	-.0851269 .0286338
m5	-.0123517	.0288126	-0.43	0.668	-.0688234 .0441199
m6	-.0319171	.0287905	-1.11	0.268	-.0883454 .0245111
m7	-.0255908	.0289638	-0.88	0.377	-.0823589 .0311773
m8	.0270086	.0290297	0.93	0.352	-.0298885 .0839057
m9	-.0140805	.0292046	-0.48	0.630	-.0713205 .0431594
m10	.009075	.0288426	0.31	0.753	-.0474555 .0656055
m11	-.0028721	.0289132	-0.10	0.921	-.059541 .0537968
dumDPC	.0149221	.0126691	1.18	0.239	-.0099088 .0397553
dumCOV	-.0470121	.0245645	-1.91	0.056	-.0951577 .0011334
_cons	-.0011228	.0216699	-0.05	0.959	-.0435951 .0413495

Johansen normalization restriction imposed

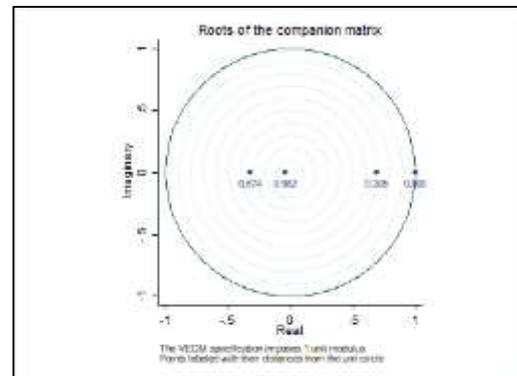
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
lnbeira	1
lnnampula	-1.171279	.1556132	-7.53	0.000	-1.476275 -.8662825
_cons	.520365

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	3.1277	4	0.53669
2	1.6075	4	0.80745

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D lnbeira	290.345	2	0.00000
D lnnampula	21.742	2	0.00002
ALL	312.088	4	0.00000



Beira-Chókwè

. vec lnbeira lnochókwè, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -5.503292
 HQIC = -5.169612
 SBIC = -4.681479

Log likelihood = 359.6942
 Det(Sigma_ml) = 7.72e-06

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D lnbeira	17	.064828	0.2204	28.5616	0.0388
D lnochókwè	17	.051843	0.3340	50.64964	0.0000

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D lnbeira					
_cel					
L1.	.0230933	.0630941	0.37	0.714	-.1005688 .1467554
lnbeira					
LD.	-.3289806	.104435	-3.15	0.002	-.5336694 -.1242918
lnchókwè					
LD.	-.0568709	.1067627	-0.53	0.594	-.2661218 .1523801
m1	.023311	.0300544	0.78	0.438	-.0355946 .0822166
m2	.0265723	.0301585	0.88	0.378	-.0325373 .0856819
m3	-.0068365	.0293906	-0.23	0.816	-.0644411 .0507681
m4	-.0286125	.0293	-0.98	0.329	-.0860394 .0288144
m5	-.0117102	.0291823	-0.40	0.688	-.0689065 .0454886
m6	-.0293423	.0290938	-1.01	0.313	-.0863652 .0276806
m7	-.0220824	.0290866	-0.76	0.448	-.0790912 .0349264
m8	.0338008	.0291466	1.16	0.246	-.0233255 .0909271
m9	-.0120313	.0294981	-0.41	0.683	-.0698465 .0457839
m10	.0095312	.0291815	0.33	0.744	-.0476634 .0667258
m11	-.0033078	.0294327	-0.11	0.911	-.0609949 .0543793
dumDPC	.0162028	.0132503	1.22	0.221	-.0097673 .042173
dumCOV	-.0360777	.0230489	-1.57	0.118	-.0812527 .0090973
_cons	.0012274	.0219531	0.06	0.955	-.0418 .0442547

Johansen normalization restriction imposed

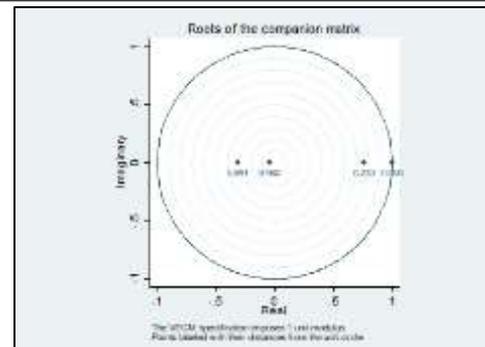
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
lnbeira	1
lnchókwè	-.9561841	.1183224	-8.08	0.000	-1.188092 -.7242766
_cons	-.0226545

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	4.5311	4	0.33887
2	1.9031	4	0.75358

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D lnbeira	225.454	2	0.00000
D lnochókwè	61.011	2	0.00000
ALL	286.465	4	0.00000



Beira-Maputo

. vec Inbeira Inmaputo, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*) :

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -5.140969
 Log likelihood = 338.3172
 HQIC = -4.807288
 Det(Sigma_m1) = .0000111
 SBIC = -4.319156

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_Inbeira	17	.061949	0.2881	40.88319	0.0010
D_Inmaputo	17	.069041	0.1341	15.63748	0.5497

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
D_Inbeira						
_cel						
L1.	-.0271741	.0096762	-2.81	0.005	-.0461391	-.0082091
Inbeira						
LD.	-.4056166	.096951	-4.18	0.000	-.5956371	-.2155961
Inmaputo						
LD.	.1767665	.096275	1.84	0.066	-.011929	.3654619
m1	.0250296	.0285589	0.88	0.381	-.0309447	.081004
m2	.0250018	.0288321	0.87	0.386	-.0315081	.0815116
m3	-.0012867	.0278663	-0.05	0.963	-.0558972	.0533239
m4	-.0301625	.027732	-1.09	0.277	-.0845162	.0241911
m5	-.0201473	.02799	-0.72	0.472	-.0750066	.034712
m6	-.0388285	.02812	-1.38	0.167	-.0939427	.0162856
m7	-.0276454	.0279882	-0.99	0.323	-.0825012	.0272104
m8	.0305104	.0277508	1.10	0.272	-.0238801	.0849009
m9	-.010712	.0279887	-0.38	0.702	-.0655689	.0441449
m10	.0118664	.0277722	0.43	0.669	-.0425662	.0662989
m11	-.0005493	.0277988	-0.02	0.984	-.055034	.0539355
dumDFG	.0463637	.015759	2.94	0.003	.0154765	.0772509
dumCOV	-.0378803	.0215786	-1.76	0.079	-.0801736	.004413
_cons	.0083221	.0209818	0.40	0.692	-.0328016	.0494457

Johansen normalization restriction imposed

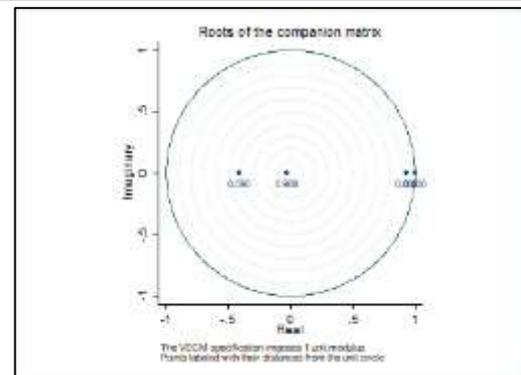
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cel						
Inbeira	1	
Inmaputo	2.10185	.8994245	2.34	0.019	.3390107	3.86469
_cons	-9.495345

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	2.4742	4	0.64926
2	0.6700	4	0.95497

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_Inbeira	280.342	2	0.00000
D_Inmaputo	330.198	2	0.00000
ALL	610.540	4	0.00000



Chókwè-Cuamba

. vec Inchókwè Incuamba, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -4.239279
 Log likelihood = 285.1175
 HQIC = -3.905599
 Det(Sigma_m1) = .0000273
 SBIC = -3.417466

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_Inchókwè	17	.05771	0.1747	21.3854	0.2095
D_Incuamba	17	.108412	0.2658	36.55925	0.0039

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
D_Inchókwè						
_cel						
L1.	-.0481431	.0260298	-1.85	0.064	-.0991606	.0028745
Inchókwè						
LD.	-.2058651	.090794	-2.27	0.023	-.3838181	-.0279121
Incuamba						
LD.	-.0701438	.0474512	-1.48	0.139	-.1631465	.0228589
m1	-.0008951	.0267007	-0.03	0.973	-.0532274	.0514372
m2	-.0102174	.0267117	-0.38	0.702	-.0625714	.0421367
m3	.0081297	.0258427	0.31	0.753	-.042521	.0587804
m4	.0302944	.025831	1.17	0.241	-.0203333	.0809222
m5	.0456613	.025855	1.77	0.077	-.0050137	.0963362
m6	.016566	.0262918	0.63	0.529	-.0349649	.0680969
m7	.0288463	.0261318	1.10	0.270	-.0223712	.0800638
m8	.0412831	.0259858	1.59	0.112	-.0096482	.0922143
m9	.0025155	.0259998	0.10	0.923	-.0484432	.0534742
m10	-.0188768	.0260099	-0.73	0.468	-.0698553	.0321017
m11	.0127871	.026045	0.49	0.623	-.0382601	.0638343
dumDFG	-.0009672	.0122095	-0.08	0.937	-.0248973	.0229629
dumCOV	-.0298867	.0202177	-1.48	0.139	-.0695127	.0097393
_cons	-.0103397	.0193972	-0.53	0.594	-.0483575	.027678

Johansen normalization restriction imposed

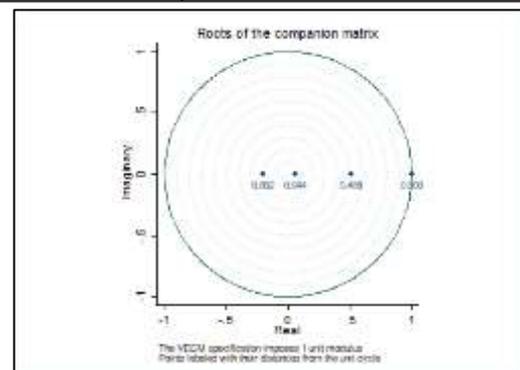
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cel						
Inchókwè	1	
Incuamba	-1.803641	.2672373	-6.75	0.000	-2.327416	-1.279866
_cons	2.755429

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	0.8771	4	0.92783
2	1.1507	4	0.88615

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_Inchókwè	279.025	2	0.00000
D_Incuamba	7.699	2	0.02129
ALL	286.724	4	0.00000



Chókwè-Nampula

. vec InChókwé Innampula, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -5.012928
 HQIC = -4.679247
 Det(Sigma_m1) = .0000126
 SBIC = -4.191114

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_InChókwé	17	.056711	0.2030	25.73105	0.0795
D_Innampula	17	.075213	0.2135	27.41867	0.0522

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_InChókwé					
_cel					
L1.	-.0943576	.0361131	-2.61	0.009	-.1651379 -.0235773
InChókwé					
LD.	-.1920115	.0904153	-2.12	0.034	-.3692223 -.0148006
Innampula					
LD.	.0089104	.0741229	0.12	0.904	-.1363678 .1541886
m1	-.00093	.026277	-0.04	0.972	-.0524319 .0505719
m2	-.0188587	.0267003	-0.71	0.480	-.0711904 .033473
m3	.0054608	.0254297	0.21	0.830	-.0443805 .0553021
m4	.0227077	.0256379	0.89	0.376	-.0275416 .072957
m5	.0399627	.0254442	1.57	0.116	-.009907 .0898323
m6	.0120248	.025452	0.47	0.637	-.0378602 .0619098
m7	.0180296	.025444	0.71	0.479	-.0318396 .0678989
m8	.0317343	.0254327	1.25	0.212	-.0181129 .0815815
m9	.0004535	.0254958	0.02	0.986	-.0495173 .0504243
m10	-.0202595	.0254975	-0.79	0.427	-.0702337 .0297148
m11	.0088062	.0256141	0.34	0.731	-.0413965 .0590089
dumDPG	-.0066909	.0122363	-0.55	0.585	-.0306736 .0172917
dumCOV	-.0590528	.0232469	-2.54	0.011	-.104616 -.0134897
_cons	-.0095465	.0190952	-0.50	0.617	-.0469725 .0278795

Johansen normalization restriction imposed

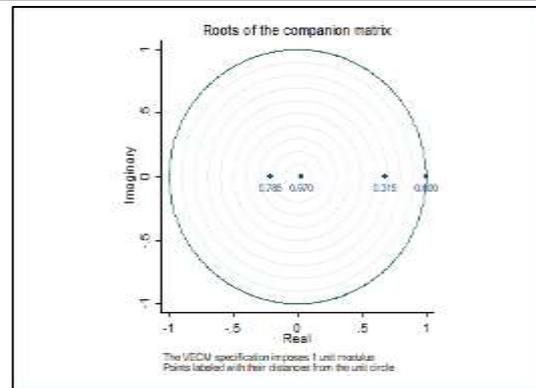
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
InChókwé	1
Innampula	-1.337228	.1732461	-7.72	0.000	-1.676784 -.9976718
_cons	.8909226

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	1.2242	4	0.87409
2	0.4270	4	0.98020

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_InChókwé	235.071	2	0.00000
D_Innampula	52.293	2	0.00000
ALL	287.364	4	0.00000



Chókwè-Alto Molócué

. vec InChókwé Inaltomolócué, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -4.815725
 HQIC = -4.482044
 Det(Sigma_m1) = .0000153
 SBIC = -3.993912

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_InChókwé	17	.057984	0.1669	20.22841	0.2627
D_Inaltomolócué	17	.081194	0.2213	28.70704	0.0373

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_InChókwé					
_cel					
L1.	-.0726804	.0477712	-1.52	0.128	-.1663102 .0209494
InChókwé					
LD.	-.1545599	.0959114	-1.61	0.107	-.3425429 .0334223
Inaltomolócué					
LD.	-.0941667	.0726443	-1.30	0.195	-.2365469 .0482135
m1	.0040938	.0271538	0.15	0.880	-.0491267 .0573143
m2	-.0070762	.0276104	-0.26	0.798	-.0611916 .0470393
m3	.0047808	.0261323	0.18	0.855	-.0464376 .0559991
m4	.0291851	.0261796	1.11	0.265	-.022126 .0804962
m5	.0427747	.0260231	1.64	0.100	-.0082296 .0937789
m6	.0156468	.0263284	0.59	0.552	-.0359558 .0672495
m7	.0215667	.0259533	0.83	0.406	-.0293009 .0724344
m8	.0382349	.0260022	1.47	0.141	-.0127285 .0891983
m9	.0047043	.0264782	0.18	0.859	-.0471919 .0566006
m10	-.0166544	.0264063	-0.63	0.528	-.0684099 .0351011
m11	.01265	.0263208	0.48	0.631	-.0389379 .0642379
dumDPG	.0066002	.0112623	0.59	0.558	-.0154736 .0286739
dumCOV	-.0221544	.0202055	-1.10	0.273	-.0617565 .0174477
_cons	-.0095409	.0196864	-0.48	0.628	-.0481255 .0290437

Johansen normalization restriction imposed

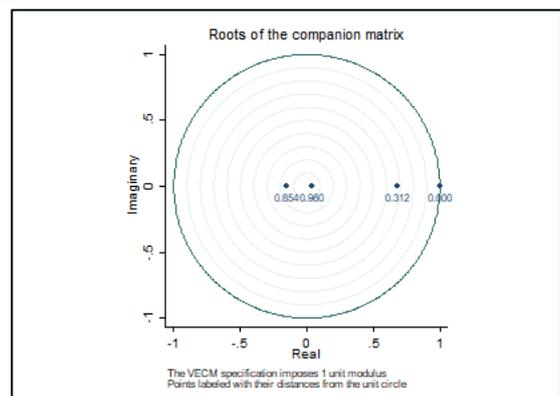
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
InChókwé	1
Inaltomolócué	-1.057246	.1622138	-6.52	0.000	-1.37518 -.739313
_cons	.1813905

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	8.4821	4	0.07543
2	10.7380	4	0.02967

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_InChókwé	300.000	2	0.00000
D_Inaltomolócué	39.467	2	0.00000
ALL	339.467	4	0.00000



Chókhwè-Beira

. vec InChókhwé Inbeira, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 Log likelihood = 359.6942
 Det(Sigma_ml) = 7.72e-06
 AIC = -5.503292
 HQIC = -5.169612
 SBIC = -4.681479

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_InChókhwé	17	.051843	0.3340	50.64964	0.0000
D_Inbeira	17	.064828	0.2204	28.5616	0.0388

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_InChókhwé					
_ce1					
L1.	-.2456125	.0482461	-5.09	0.000	-.340173 - .151052
InChókhwé					
LD.	-.1160418	.085379	-1.36	0.174	-.2833816 .0512979
Inbeira					
LD.	-.2992992	.0835175	-3.58	0.000	-.4629906 -.1356079
m1	.0013496	.0240348	0.06	0.955	-.0457577 .0484569
m2	-.0114425	.024118	-0.47	0.635	-.058713 .035828
m3	-.0027274	.0235039	-0.12	0.908	-.0487943 .0433395
m4	.012789	.0234314	0.55	0.585	-.0331358 .0587138
m5	.0318431	.0233373	1.36	0.172	-.0138972 .0775834
m6	.0133108	.0232666	0.57	0.567	-.0322909 .0589125
m7	.0225879	.0232608	0.97	0.332	-.0230026 .0681783
m8	.046152	.0233088	1.98	0.048	-.0004676 .0918364
m9	.0169629	.0235899	0.72	0.472	-.0292724 .0631982
m10	-.0158722	.0233367	-0.68	0.496	-.0616112 .0298668
m11	.0185791	.0235376	0.79	0.430	-.0275538 .064712
dumDPG	-.0080206	.0105964	-0.76	0.449	-.0287891 .012748
dumCOV	-.0444736	.0184324	-2.41	0.016	-.0806004 -.0083468
_cons	-.0001103	.0175561	-0.01	0.995	-.0345197 .034299

Johansen normalization restriction imposed

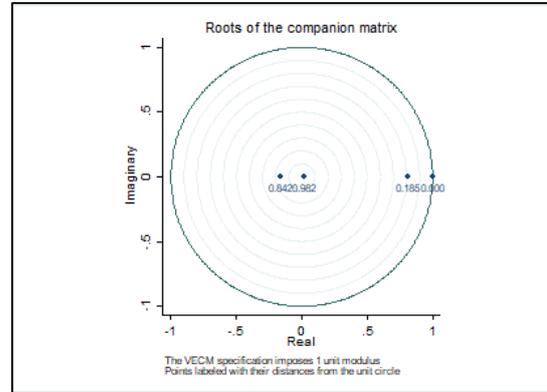
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_ce1					
InChókhwé	1
Inbeira	-1.045824	.1345468	-7.77	0.000	-1.30953 -.7821169
_cons	.0236926

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	4.5311	4	0.33887
2	1.9031	4	0.75358

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_InChókhwé	76.913	2	0.00000
D_Inbeira	139.439	2	0.00000
ALL	216.351	4	0.00000



Chókhwè-Maputo

. vec InChókhwé Inmaputo, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 Log likelihood = 342.5707
 Det(Sigma_ml) = .0000103
 AIC = -5.213062
 HQIC = -4.879382
 SBIC = -4.391249

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_InChókhwé	17	.056031	0.2220	28.82702	0.0362
D_Inmaputo	17	.068616	0.1447	17.08654	0.4485

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_InChókhwé					
_ce1					
L1.	-.1524703	.04746	-3.21	0.001	-.2454903 -.0594503
InChókhwé					
LD.	-.1442226	.0915824	-1.57	0.115	-.3237208 .0352757
Inmaputo					
LD.	-.1118133	.0857887	-1.30	0.192	-.279956 .0563294
m1	.0023693	.0259485	0.09	0.927	-.0484888 .0532274
m2	-.0056016	.0261385	-0.21	0.830	-.056832 .0456289
m3	.0038846	.0251405	0.15	0.877	-.0453899 .0531592
m4	.0245507	.0251376	0.98	0.329	-.024718 .0738194
m5	.0421328	.0252048	1.67	0.095	-.0072678 .0915333
m6	.0151567	.0254191	0.60	0.551	-.0346638 .0649772
m7	.0210096	.0251817	0.83	0.404	-.0283456 .0703648
m8	.0351468	.025083	1.40	0.161	-.014015 .0843086
m9	-.0001556	.0251305	-0.01	0.995	-.0494105 .0490993
m10	-.0210187	.0251736	-0.83	0.404	-.0703581 .0283208
m11	.0117961	.0253	0.47	0.641	-.037791 .0613832
dumDPG	.0248289	.0120923	2.05	0.040	.0011284 .0485294
dumCOV	.0009488	.0211997	0.04	0.964	-.040602 .0424995
_cons	.0056136	.0194614	0.29	0.773	-.03253 .0437573

Johansen normalization restriction imposed

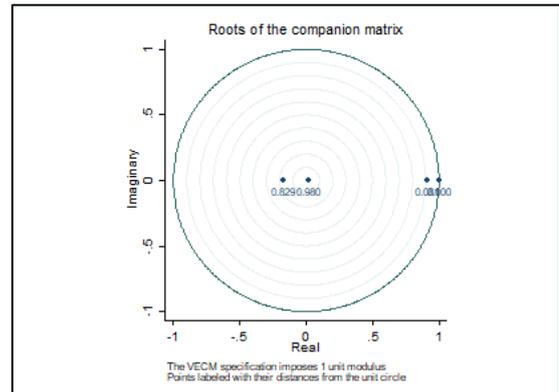
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_ce1					
InChókhwé	1
Inmaputo	-.4500853	.1444136	-3.12	0.002	-.7331307 -.1670398
_cons	-1.773542

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	0.5434	4	0.96914
2	1.3812	4	0.84746

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_InChókhwé	190.752	2	0.00000
D_Inmaputo	780.216	2	0.00000
ALL	970.968	4	0.00000



Maputo-Cuamba

. vec Inmaputo Incuamba, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -3.86693
 Log likelihood = 263.1488
 HQIC = -3.533249
 Det (Sigma_m1) = .0000396
 SBIC = -3.045116

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_Inmaputo	17	.069812	0.1146	13.07564	0.7311
D_Incuamba	17	.107048	0.2841	40.08667	0.0013

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_Inmaputo					
_cel					
L1.	.0050462	.0180732	0.28	0.780	-.0303766 .0404689
Inmaputo					
LD.	.1155554	.1013801	1.14	0.254	-.083146 .3142567
Incuamba					
LD.	-.0502438	.0583324	-0.86	0.389	-.1645733 .0640857
m1	.0443308	.0321638	1.38	0.168	-.0187092 .1073707
m2	-.0063676	.0326048	-0.20	0.845	-.0702718 .0575366
m3	.0065035	.0312612	0.21	0.835	-.0547674 .0677743
m4	.0309085	.0312754	0.99	0.323	-.0303903 .0922072
m5	.0489271	.0313999	1.56	0.119	-.0126155 .1104697
m6	.0165671	.0322279	0.51	0.607	-.0465985 .0797327
m7	-.011932	.0317528	-0.38	0.707	-.0503023 .0741663
m8	.0140893	.0314841	0.45	0.655	-.0476184 .0757971
m9	-.0188233	.0313799	-0.60	0.549	-.0803268 .0426802
m10	.0138625	.0313832	0.44	0.659	-.0476474 .0753725
m11	.0012689	.0313035	0.04	0.968	-.0600848 .0626227
dumDPG	.0062838	.0157788	0.40	0.690	-.024642 .0372097
dumCOV	.0278444	.0256831	1.08	0.278	-.0224935 .0781823
_cons	-.0160646	.0234887	-0.68	0.494	-.0621016 .0299725

Johansen normalization restriction imposed

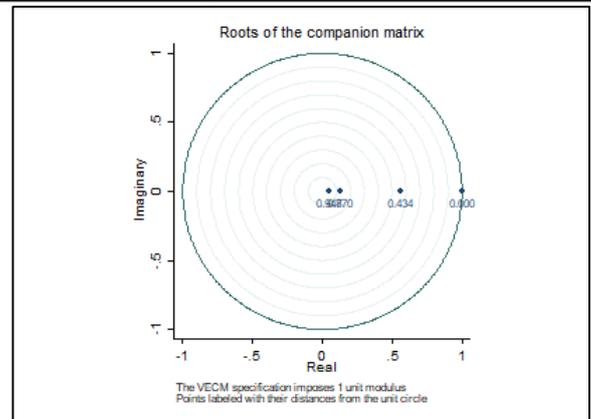
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
Inmaputo	1
Incuamba	-3.14311	.5476949	-5.74	0.000	-4.216572 -2.069648
_cons	7.433213

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	1.3684	4	0.84966
2	2.7364	4	0.60287

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_Inmaputo	836.688	2	0.00000
D_Incuamba	7.604	2	0.02232
ALL	844.292	4	0.00000



Maputo-Nampula

. vec Inmaputo Innampula, indicators (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -4.827261
 Log likelihood = 319.8084
 HQIC = -4.493581
 Det (Sigma_m1) = .0000152
 SBIC = -4.005448

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_Inmaputo	17	.06783	0.1642	19.84101	0.2824
D_Innampula	17	.073913	0.2405	31.97518	0.0152

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_Inmaputo					
_cel					
L1.	.0271102	.0167605	1.62	0.106	-.005748 .059952
Inmaputo					
LD.	-.0159899	.106265	-0.15	0.880	-.2242654 .1922856
Innampula					
LD.	.2303799	.0942585	2.44	0.015	.0456366 .4151233
m1	.0417587	.0312744	1.34	0.182	-.0195381 .1030554
m2	-.0091436	.0319429	-0.29	0.775	-.0717506 .0534634
m3	.0045865	.0303884	0.15	0.880	-.0549737 .0641467
m4	.0243754	.0305943	0.80	0.426	-.0355883 .084339
m5	.053572	.0305267	1.75	0.079	-.0062593 .1134033
m6	.0267202	.0307669	0.87	0.385	-.0335818 .0870221
m7	.010178	.0304627	0.33	0.738	-.0495278 .0698839
m8	.0123722	.0304154	0.41	0.684	-.0472408 .0719852
m9	-.0121961	.0305259	-0.40	0.690	-.0720258 .0476336
m10	-.0103814	.0304403	-0.34	0.733	-.0492805 .0700433
m11	-.0026273	.0303808	-0.09	0.931	-.0621726 .056918
dumDPG	.019205	.0166049	1.16	0.247	-.01334 .05175
dumCOV	.0526407	.0302148	1.74	0.081	-.0065791 .1118606
_cons	-.0106876	.022979	-0.47	0.642	-.0557257 .0343505

Johansen normalization restriction imposed

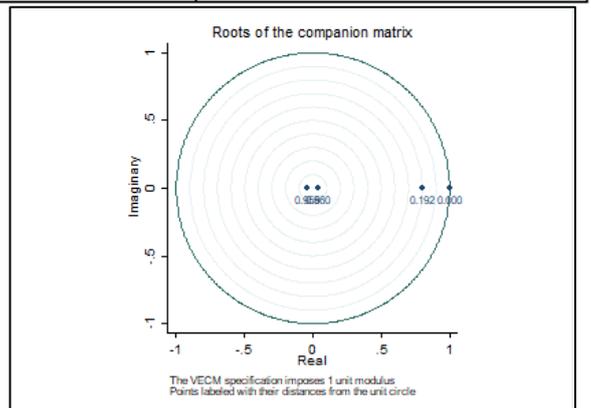
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_cel					
Inmaputo	1
Innampula	-3.051241	.5489612	-5.56	0.000	-4.127185 -1.975297
_cons	6.278879

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	2.3449	4	0.67261
2	2.8865	4	0.57700

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_Inmaputo	1186.134	2	0.00000
D_Innampula	29.464	2	0.00000
ALL	1215.597	4	0.00000



Maputo-Alto Molócuê

. vec inmaputo inalantomolócuê, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -4.416203
 Log likelihood = 295.556
 HQIC = -4.082523
 Det(Sigma_ml) = .0000229
 SBIC = -3.59439

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_inmaputo	17	.069337	0.1266	14.64513	0.6210
D_inalantomolócuê	17	.080896	0.2270	29.66373	0.0289

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_inmaputo					
_csl					
L1.	.0149715	.0131446	1.14	0.255	-.0107914 .0407344
Inmaputo					
LD.	.0663801	.1004288	0.66	0.509	-.1304567 .263217
inalantomolócuê					
LD.	.1159531	.0827225	1.40	0.161	-.04618 .2780861
m1	.0392649	.0322228	1.22	0.223	-.0238907 .1024204
m2	-.0084674	.0331244	-0.26	0.798	-.0733901 .0564553
m3	.0086408	.0310583	0.28	0.781	-.0522324 .069514
m4	.0287835	.0311701	0.92	0.356	-.0323087 .0898758
m5	.0481164	.0311896	1.54	0.123	-.0130141 .1092469
m6	.0183616	.0317696	0.58	0.563	-.0439057 .0806289
m7	.0116717	.0311236	0.38	0.708	-.0493295 .0726729
m8	.0129123	.0310783	0.42	0.678	-.0480001 .0738247
m9	-.0265155	.031533	-0.84	0.400	-.088319 .035288
m10	.0091936	.0314156	0.29	0.770	-.0523799 .0707671
m11	-.0026813	.0311825	-0.09	0.931	-.0637977 .0584352
dumDFC	.0109256	.0151239	0.72	0.470	-.0187167 .0405678
dumCOV	.031324	.0246377	1.27	0.204	-.0169649 .079613
_cons	-.0126756	.0234899	-0.54	0.589	-.058715 .0333639

Johansen normalization restriction imposed

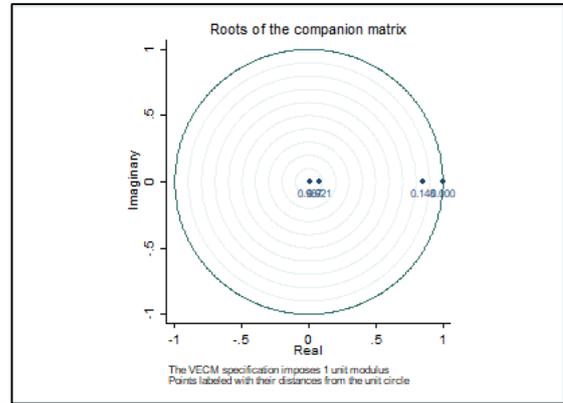
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_csl					
Inmaputo	1
inalantomolócuê	-3.249861	.8016997	-4.05	0.000	-4.821163 -1.678558
_cons	7.414336

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	3.5133	4	0.47585
2	10.9249	4	0.02742

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_inmaputo	979.162	2	0.00000
D_inalantomolócuê	41.300	2	0.00000
ALL	1020.462	4	0.00000



Maputo-Beira

. vec inmaputo inbeira, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -5.140969
 Log likelihood = 338.3172
 HQIC = -4.807288
 Det(Sigma_ml) = .0000111
 SBIC = -4.319156

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_inmaputo	17	.069041	0.1341	15.63748	0.5497
D_inbeira	17	.061949	0.2881	40.88319	0.0010

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_inmaputo					
_csl					
L1.	-.0422505	.0226664	-1.86	0.062	-.0866757 .0021748
Inmaputo					
LD.	.1394574	.1072973	1.30	0.194	-.0708414 .3497561
inbeira					
LD.	-.0459022	.1080507	-0.42	0.671	-.2576777 .1658733
m1	.043994	.0318285	1.38	0.167	-.0183888 .1063768
m2	-.0016306	.032133	-0.05	0.960	-.0646101 .0613489
m3	.0095654	.031053	0.31	0.758	-.0512973 .0704282
m4	.0301918	.0309069	0.98	0.329	-.0303847 .0907683
m5	.046305	.0311945	1.48	0.138	-.014835 .1074451
m6	.0218777	.0313394	0.70	0.485	-.0395463 .0833018
m7	.0108613	.0311925	0.35	0.728	-.0502748 .0719974
m8	.0146424	.0309279	0.47	0.636	-.0459751 .0752599
m9	-.015527	.0311931	-0.50	0.619	-.0766643 .0456104
m10	.0150706	.0309518	0.49	0.626	-.0455938 .075735
m11	.0011441	.0309815	0.04	0.971	-.0595785 .0618667
dumDFC	.0248093	.0175633	1.41	0.158	-.0096141 .0592326
dumCOV	.0247191	.0240491	1.03	0.304	-.0224163 .0718545
_cons	-.0112501	.023384	-0.48	0.630	-.0570819 .0345817

Johansen normalization restriction imposed

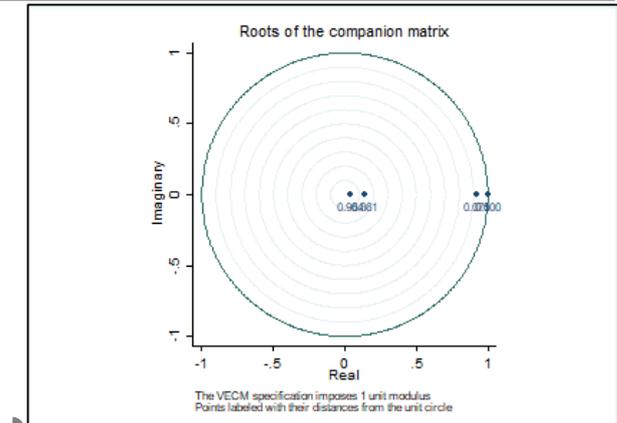
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
_csl					
Inmaputo	1
inbeira	.4757713	.6757319	0.70	0.481	-.848639 1.800181
_cons	-4.517612

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	2.4742	4	0.64926
2	0.6700	4	0.95497

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_inmaputo	1028.574	2	0.00000
D_inbeira	61.098	2	0.00000
ALL	1089.672	4	0.00000



Maputo-Chókwè

. vec lnmaputo lnchókwè, indicadores (m1 m2 m3 m4 m5 m6 m7 m8 m9 m10 m11 dum*)

Vector error-correction model

Sample: March 2011 - December 2020
 Number of obs = 118
 AIC = -5.213062
 Log likelihood = -342.5707
 HQIC = -4.879382
 Det (Sigma_ml) = .0000103
 SBIC = -4.391249

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_lnmaputo	17	.069616	0.1447	17.08654	0.4485
D_lnchókwè	17	.056031	0.2220	28.82702	0.0362

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
D_lnmaputo					
_cel					
L1.	.0400862	.0261589	1.53	0.125	-.0111843 .0913568
lnmaputo					
LD.	.0148641	.1050575	0.14	0.887	-.1910448 .220773
lnchókwè					
LD.	.2086476	.1121525	1.86	0.063	-.0111673 .4284625
m1	.050789	.0317767	1.60	0.110	-.0114923 .1130702
m2	.0033861	.0320094	0.11	0.916	-.0593511 .0661233
m3	.0041621	.0307873	0.14	0.892	-.0561799 .064504
m4	.0306415	.0307836	1.00	0.320	-.0296933 .0909764
m5	.0464092	.030866	1.50	0.133	-.0140872 .1069055
m6	.0212772	.0311284	0.68	0.494	-.0397334 .0822878
m7	.0143696	.0308377	0.47	0.641	-.0460711 .0748104
m8	.0139224	.0307168	0.45	0.650	-.0462815 .0741264
m9	-.0196025	.030775	-0.64	0.524	-.0799204 .0407155
m10	.0197382	.0308278	0.64	0.522	-.0406833 .0801596
m11	.0070165	.0309826	0.23	0.821	-.0537082 .0677412
dumDPG	.0129598	.0148083	0.88	0.381	-.016064 .0419836
dumCOV	.046041	.0259614	1.77	0.076	-.0048423 .0969244
_cons	-.0096101	.0238326	-0.40	0.687	-.0563212 .0371009

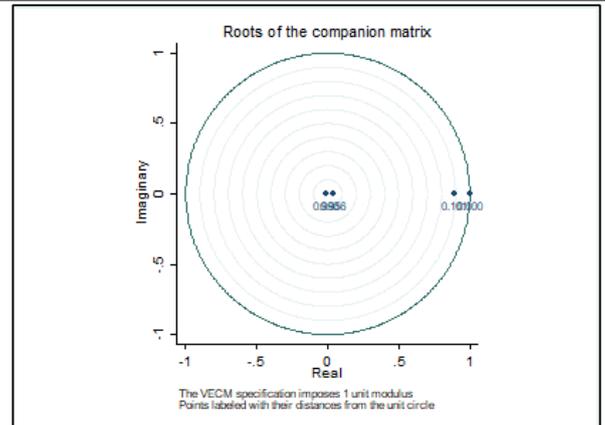
Johansen normalization restriction imposed					
beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
cel					
lnmaputo	1
lnchókwè	-2.221801	.4745373	-4.68	0.000	-3.151877 -1.291725
_cons	3.940457

Lagrange-multiplier test

lag	chi2	df	Prob > chi2
1	0.5434	4	0.96914
2	1.3812	4	0.84746

Jarque-Bera test

Equation	chi2	df	Prob > chi2
D_lnmaputo	1125.672	2	0.00000
D_lnchókwè	158.693	2	0.00000
ALL	1284.365	4	0.00000



Anexo 5: Resultados do Teste de Casualidade de Granger

Granger causality Wald tests

Equation	Excluded	chi2	df	Prob > chi2
dif_cuamba	dif_nampula	2.8193	1	0.093
dif_cuamba	dif_altomolócuè	5.719	1	0.017
dif_cuamba	dif_beira	.63483	1	0.426
dif_cuamba	dif_chókwè	.00872	1	0.926
dif_cuamba	dif_maputo	.40595	1	0.524
dif_cuamba	ALL	16.503	5	0.006
dif_nampula	dif_cuamba	.68824	1	0.407
dif_nampula	dif_altomolócuè	2.5376	1	0.111
dif_nampula	dif_beira	1.1018	1	0.294
dif_nampula	dif_chókwè	.01057	1	0.918
dif_nampula	dif_maputo	1.0738	1	0.300
dif_nampula	ALL	6.0153	5	0.305
dif_altomolócuè	dif_cuamba	.31213	1	0.576
dif_altomolócuè	dif_nampula	4.2991	1	0.038
dif_altomolócuè	dif_beira	2.2889	1	0.130
dif_altomolócuè	dif_chókwè	2.0533	1	0.152
dif_altomolócuè	dif_maputo	.11638	1	0.733
dif_altomolócuè	ALL	8.7856	5	0.118

dif_beira	dif_cuamba	.77916	1	0.377
dif_beira	dif_nampula	.25831	1	0.611
dif_beira	dif_altomolócuè	.1721	1	0.678
dif_beira	dif_chókwè	1.2694	1	0.260
dif_beira	dif_maputo	.54284	1	0.461
dif_beira	ALL	2.979	5	0.703
dif_chókwè	dif_cuamba	.2801	1	0.597
dif_chókwè	dif_nampula	.86645	1	0.352
dif_chókwè	dif_altomolócuè	1.7789	1	0.182
dif_chókwè	dif_beira	3.1048	1	0.078
dif_chókwè	dif_maputo	.09549	1	0.757
dif_chókwè	ALL	7.2158	5	0.205
dif_maputo	dif_cuamba	1.0081	1	0.315
dif_maputo	dif_nampula	4.2614	1	0.039
dif_maputo	dif_altomolócuè	.41254	1	0.521
dif_maputo	dif_beira	1.3369	1	0.248
dif_maputo	dif_chókwè	2.0981	1	0.147
dif_maputo	ALL	10.093	5	0.073