

**UM MODELO DE RESPOSTA A CHOQUES NO CRESCIMENTO DAS EMISSÕES
DE GASES DE EFEITO ESTUFA
A SHOCK RESPONSE MODEL IN GROWING GREENHOUSE GAS EMISSIONS**

Attawan Guerino Locatel Suela

Doutorando em Economia Aplicada pela Universidade Federal de Viçosa (UFV) - MG

attawan_zull@hotmail.com

Gabriel Locatel Suela

Estudante do curso de Agronomia na Universidade Federal do Recôncavo da Bahia - BA

gabriellocateloff@gmail.com

Luana Marina Salgado Botelho

luanabotelho47@yahoo.com.br

Estudante do curso de Bacharelado em Cooperativismo na Universidade Federal de Viçosa (UFV) - MG

Ian Michael Trotter

Professor do Departamento de Economia Rural (DER), Viçosa - MG

ian.trotter@gmail.com

Área temática (submissão): *Meio ambiente, recursos naturais e sustentabilidade*

Classificação JEL do trabalho: *Q56 - Environment and Development; Environment and Trade; Sustainability; Environmental accounting*

RESUMO: O presente artigo identificou quais seriam os impactos na quantidade produtiva de cinco grandes seguimentos agropecuários, caso houvesse crescimento nas emissões de GEE no Brasil. Metodologicamente, foi estruturado e operacionalizado um Modelo de Auto Regressão Vetorial Estrutural com dados entre os anos de 1970 e 2018. Foram utilizadas as seguintes informações: o nível de emissões produzidas pelo setor de Agricultura, Floresta e Outros Usos da Terra (AFOLU), a quantidade produzida de cana-de-açúcar, milho e café, bem como o plantel de gado e suínos. De forma geral, os resultados obtidos revelam a importância de se controlar o nível de emissões geradas, pois houve redução na produção de todas os segmentos estudados. Assim, considerando as emissões oriundas do AFOLU, conclui-se que todos os setores escolhidos para o estudo sofrerão perdas na produção caso não haja controle nas emissões futuras, indicando a necessidade de políticas públicas pró-ambientais para os setores agropecuários.

Palavras-chave: SVAR, emissões, produção

ABSTRACT: The present article identified what would be the impacts on the productive quantity of five large agricultural segments, if there was an increase in GHG emissions in Brazil. Methodologically, a Structural Vector Auto Regression Model was structured and operated with data between the years 1970 and 2018. The following information was used: the level of emissions produced by the Agriculture, Forestry and Other Land Use (AFOLU) sector, the quantity of sugarcane, corn and coffee produced, as well as the cattle and swine breeding stock. In general, the results obtained reveal the importance of controlling the level of emissions generated, as there was a reduction in the production of all studied segments. Thus, considering emissions from AFOLU, it is concluded that all sectors chosen for the study will suffer losses in production if there is no control over future emissions, indicating the need for pro-environmental public policies for the agricultural sectors.

Key-word: SVAR, emissions, production.

1. INTRODUÇÃO

A produção agropecuária brasileira é considerada uma das mais importantes do mundo (Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA, 2018; *Food and Agriculture Organization of the United Nation* – FAO, 2019). Seu desempenho nas últimas décadas, tem sido excelente, com crescimento contínuo da produção, das exportações e do valor agregado. Entre as razões do crescimento destaca-se o progresso científico e tecnológico, com ênfase para a genética animal e o desenvolvimento de novos cultivares e variedades mais produtivas e resistentes a condições ambientais adversas (BROOKS, 2017; VILLORIA, 2019).

Por essa razão, é esperado que o Brasil contribua objetivamente para os desafios futuros que envolvem a produção de alimentos e segurança alimentar, combate às mudanças climáticas, crescimento populacional e urbanização (CEDDIA et al., 2013; STRASSBURG et al., 2014; SÁ et al., 2017; EMBRAPA, 2018; FAO, 2019). Segundo Macedo et al. (2012), Observatório do Clima (2014) e Velloria (2019) o país terá desempenho produtivo suficiente para atender a demanda interna e ainda conseguirá exportar excedentes para suprir a demanda externa.

Por outro lado, o país enfrenta um grande desafio: manter o bom desempenho da agropecuária aliado à sustentabilidade, sobretudo no que diz respeito à sua dimensão ambiental (MATSON E VITOUSEK, 2006; PERES et al. 2010; SOARES FILHO et al. 2014; BROOKS, 2017; COSTANZA et al., 2017; EMBRAPA, 2018). É provável que o atendimento à crescente demanda alimentar gere consequências negativas ao meio ambiente, como aumento do desmatamento, comprometimento de ecossistemas e maiores índices de poluição, com destaque para as emissões de gases de efeito estufa (GEE) (PFAFF E WALKER, 2010; EMBRAPA, 2018; FRANKLIN E PINDYCK, 2018; ROCHEDO et al., 2018).

Conforme os dados do relatório-síntese publicado pelo Sistema de Estimativas de Emissões de Gases de Efeito Estufa - SEEG (2019)¹, o país em 2018, foi o sétimo maior emissor de GEE no mundo, produzindo cerca 1,939 bilhões de toneladas brutas. O setor de Agricultura, Florestas e Outros Usos da Terra (Agriculture, Forest and Other Land Uses – AFOLU) foi responsável por aproximadamente 69% dessas emissões (SEEG, 2019), no qual, parcela expressiva dessas emissões, surgiram para enfrentar o desafio global da segurança alimentar (GODFRAY, et al., 2010; SMITH et al., 2013; SÁ et al., 2017).

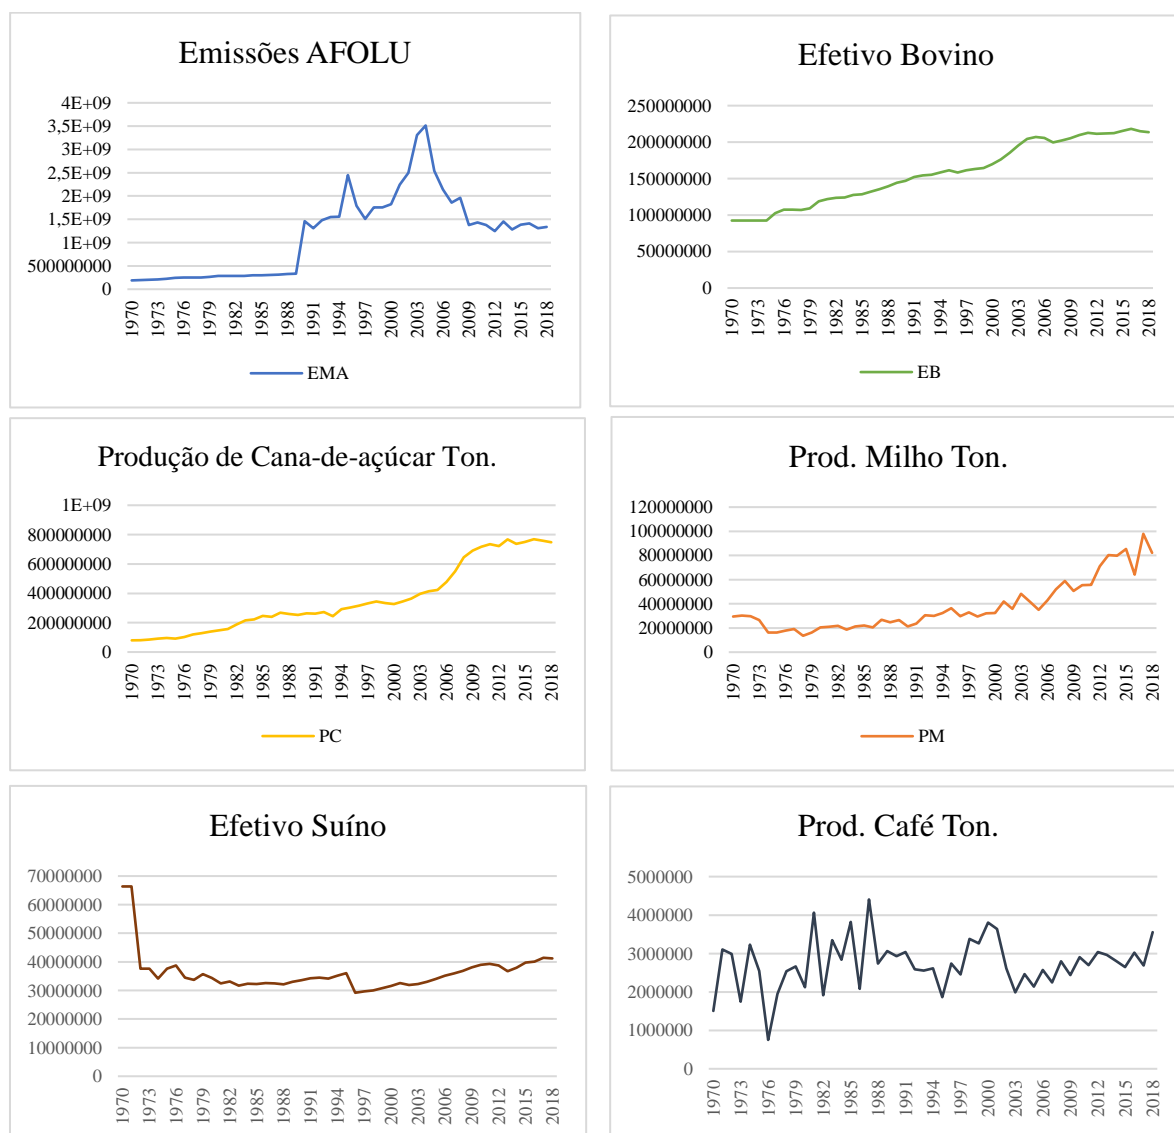
Nesse sentido, é possível afirmar que existe crescente pressão em todo o mundo, pela intensificação da produção (GARNETT e GODFRAY, 2012; CEDDIA et al., 2013; COHN et al., 2014; STRASSBURG et al., 2014; LIMA, 2017; SÁ et al., 2017). Dessa forma, isso estabelece compromissos eminentes ao crescimento da agropecuária, os quais consistem em evitar a degradação ambiental resultante das suas atividades campestres². Segundo Tilman et al. (2002), Soares Filho et al. (2014) e Rockström et al. (2017), para alcançar tais propósitos é necessário que os países invistam na intensificação sustentável da agricultura (ISA), que visa garantir a produção de mais alimentos e, ao mesmo tempo, tornar a *ecological footprint* (pegada ecológica) (BAZAN, 1997) do setor, cada vez menor.

SEEG (2019) e Suela (2019) apresentam em suas respectivas pesquisas, que a produção de grãos, cana-de-açúcar e proteína animal em todo Brasil se destacam como alguns dos maiores emissores brutos de GEE oriundos do AFOLU. Afim de representar tal impacto, optou-se por analisar conjuntamente cinco grandes modalidades produtivas: produção de milho, cana-de-açúcar, café, carne bovina e suína. O intuito principal é analisar o impacto que esses segmentos agropecuários sofreriam caso as emissões de GEE em todo o Brasil aumentassem consideravelmente.

¹Relatório-síntese: Análise das emissões brasileiras de gases de efeito estufa e suas implicações para as metas do Brasil (SEEG, 2019)

²Já que de todas as atividades econômicas, a agropecuária é, naturalmente, a mais dependente do clima e, consequentemente, a mais sensível a suas mudanças, fato que exige atenção para objetivos futuros (SILVA et al., 2018).

A Figura 1 descreve o comportamento das emissões de GEE e da produção de grãos de milho e café, cana-de-açúcar, gado e suínos no Brasil entre os períodos de 1970 e 2018. Observa-se crescimento elevado das emissões de GEE a partir dos anos 1990 com grande pico em 2004 devido a flexibilização do novo Código Florestal (OBSERVATÓRIO DO CLIMA, 2014). Nota-se também, o aumento na produção a taxas crescentes das culturas do milho, cana-de-açúcar e café bem como no efetivo bovino e de suínos em todo o Brasil. Alguns fatores que vêm contribuindo para a elevação da produção de grãos e proteína animal são: o aumento da produtividade agropecuária, aumentos nos preços das commodities, taxa de câmbio favorável em alguns períodos e a política brasileira de crédito agrícola (SÁ et al., 2017). Tais fatores tem contribuindo para expansão da oferta de grãos e proteína animal, principalmente a política brasileira de crédito que oferece apoio financeiro a taxas de juros bem inferior ao do restante da economia (EMBRAPA, 2018).



Fonte: Ipeadata (2020), IBGE (2020) e SEEG (2020)

Figura 1 - Evolução das emissões de GEE e crescimento da produção de Cana-de-açúcar, milho, gado, café e suínos.

Em trabalhos recentes que abordam o tema meio ambiente e emissões, destaca-se Cohn et al. (2014), que trata sobre o uso consciente de técnicas pró-ambientais na silvicultura

agrícola, produção de grãos, produção animal e nos diversos outros setores agropecuários, que utilizam a terra como insumo indispensável, tornam-se fundamentais para a mitigação das mudanças climática mundial. A necessidade imediata do uso responsável da terra incentivou o governo brasileiro a criar em 2010, o Plano de Agricultura de Baixo Carbono (Plano ABC) como parte dos compromissos voluntários de política climática estabelecidos na COP Copenhague em 2009 (EMBRAPA, 2018). Já trabalhos que atuam com a temática mudança climática e o uso do Modelo de Auto Regressão Vetorial pode-se destacar Janua et al., (2010) e Tesso et al., (2012), que tratam sobre o impacto das emissões de GEE na produção de alimentos no Paquistão e Etiópia, utilizando para isso um Modelo de Auto Regressão Vetorial (SVAR).

O presente trabalho contribui para o tema por incorporar a análise, tanto teórica quanto econométrica, analisando o poder degradante que as emissões de GEE causariam em cinco das grandes culturas produtivas brasileiras escolhidas. Nesse sentido, este artigo tem como objetivo verificar por meio de uma abordagem sistêmica estrutural, os impactos causados por choques nas emissões de GEE em alguns dos principais seguimentos agropecuários do Brasil, assim como a resposta da variância do erro de previsão na produção de GEE. Para isto, a base de dados utilizada conta com informações de produção das cinco culturas e das emissões de GEE geradas pelos setores do AFOLU para os anos de 1970 a 2018 adquiridas em IBGE (2020), Ipeadata (2020) e SEEG (2020).

2. METODOLOGIA

2.1. Modelo econométrico

O modelo VAR, proposto por Sims (1980), trata-se de um modelo de séries temporais ateórico em que as variáveis dependentes estão em função de suas próprias defasagens e de outras variáveis. Na sua forma primitiva, denominada VAR Estrutural (SVAR), pode-se estimar o modelo com base na teoria econômica a partir da incorporação de restrições na matriz de relações contemporâneas pelo procedimento de Bernanke, alternativo a decomposição triangular recursiva de Cholesky e as estimativas do VAR convencional. O SVAR pode ser representado como:

$$Ay_t = \alpha + \theta_1 y_{t-1} + \dots + \theta_p y_{t-p} + \varphi d_t + Be_t, \quad (1)$$

em que A é a matriz de relações contemporânea de ordem $k \times k$; y_t , um vetor de $k \times 1$ variáveis endógenas estacionárias; y_{t-p} , um vetor de $k \times 1$ variáveis defasadas estacionárias; $p_i = 1, 2, \dots, p$, a defasagem; α , um vetor de $k \times 1$ de intercepto; $\theta_i, i = 1, 2, \dots, p$, matrizes $k \times k$ dos coeficientes; B matriz diagonal $k \times k$; e_t , um vetor de $k \times 1$ de erros ortogonais, sendo $E(e_t) = 0$ e $E(e_t e_s') = \sum_{Diagonal}$; e d_t , um vetor de variáveis exógenas. A estimação do modelo pode ser realizada pelo método de Mínimo Quadrado Ordinário.

Multiplicando ambos os lados da equação anterior pela inversa da matriz de coeficientes de interações contemporâneas (A^{-1}), obtém-se o VAR padrão, também denominado reduzido ou convencional:

$$y_t = \psi + \mathcal{G}_1 y_{t-1} + \dots + \mathcal{G}_p y_{t-p} + \omega d_t + u_t, \quad (2)$$

em que $AA^{-1} = I$, $\psi = A^{-1}\alpha$, $\mathcal{G}_1 = A^{-1}\theta_1$, $\mathcal{G}_p = A^{-1}\theta_p$, $\omega = A^{-1}\varphi$ e $Au_t = Be_t$.

A versão reparametrizada de um modelo VAR (p), em que a ordem p pode ser fornecida por critérios de indicação, como o de *Akaike* (AIC) e de *Schwarz* (SC), é dada em termos de diferença na forma:

$$\Delta y_t = \Gamma_1 \Delta y_{t-1} + \dots + \Gamma_{p-1} \Delta y_{t-p+1} + \Pi y_{t-1} + \varphi d_t + u_t, \quad (3)$$

sendo $\Gamma_i = -\sum_{j=i+1}^p \theta_j$ e $\Pi = \sum_{i=1}^p \theta_i - I = -(I_k - \sum_{i=1}^p \theta_i)$,

em que y_t é um vetor de k variáveis; p , a defasagem; Δ , o operador de diferenças; $u_t \sim N(0, \Sigma)$; e d_t , um vetor de variáveis exógenas.

Este modelo pressupõe que as séries sejam estacionárias. Para obter a ordem de integração das variáveis, I(d), pode-se utilizar o teste de raiz unitária de Dickey-Fuller (DF), que testa a hipótese da existência de raiz unitária na série. No entanto, dado o problema de auto-correlação dos resíduos, o teste de raiz mais indicado é o de raiz unitária de Dickey-Fuller Aumentado (ADF), em que difere-se do teste DF por incorporar na equação de teste, defasagens para eliminação do problema de auto-correlação dos resíduos. A equação de teste de raiz unitária ADF, em sua forma completa, com os componentes intercepto e tendência, é representado por:

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \alpha_i \sum_{i=1}^m \Delta Y_{t-i} + \varepsilon_t, \quad (4)$$

em que Δ é o operador de diferença da variável em estudo, no caso Y_t ; β_1 e β_2 , os parâmetros intercepto e tendência, respectivamente; δ , o parâmetro da variável defasada; $\alpha_i \sum_{i=1}^m \Delta Y_{t-i}$, o termo de diferenças defasadas para evitar e retirar problemas de auto-correlações existentes nos resíduos, cujas defasagens podem ser indicadas pelos critérios estatísticos de *Akaike* (AIC) e *Schwarz* (SC); e ε_t , o erro aleatório.

O teste ADF é utilizado para analisar a significância estatística do parâmetro δ , estimado na equação (2), a seguinte forma:

$$\begin{aligned} H_0 : \delta_0 &= 0 \\ H_1 : \delta_1 &\neq 0 \end{aligned} \quad (5)$$

De acordo com Enders (1995), caso a hipótese nula testada for rejeitada, i.e., se a estatística τ (*tau*) calculada for tal que $|\tau| > |\tau_\tau|$, em valor absoluto maior que a estatística tabelada (τ_τ) na equação (2) - a um dado nível de significância estatística crítica (1%, 5% ou 10%), conclui-se que a série não possui raiz unitária, sendo estacionária.

Entretanto, caso a hipótese nula não for rejeitada, ou seja, $|\tau| < |\tau_\tau|$, deve-se analisar a significância estatística dos termos intercepto e tendência na equação de teste (2), uma vez que o teste de raiz unitária é sensível a presença desses termos. Para a equação de teste (2), com intercepto e sem tendência, a estatística tabelada passa a ser τ_μ e para a equação sem intercepto e sem tendência, τ . Dessa forma, caso a hipótese nula não seja rejeitada, não se deve aceitar de imediato a existência de raiz unitária na série, e a equação de teste deve ser estimada seguindo uma sequência lógica (ENDERS, 1995).

Confirmada a hipótese da existência de raiz unitária na série, esta deve ser diferenciada e testada novamente para a presença de raiz na série em diferenças, seguindo a sequência anteriormente apresentada, sendo realizadas d diferenciações até que o teste de raiz unitária seja rejeitado, e a ordem de integração da série indicada por $I(d)$.

Transformando o modelo VAR em um VMA (Vetor Média Móvel) e promovendo a ortogonalização dos resíduos e diagonalizando-se a matriz de variância-covariância dos erros para verificar o efeito do choque em apenas uma variável sobre o sistema, pode-se obter a Função Impulso Resposta e a Decomposição da Variância do Erro de Previsão. Na sua forma compacta, o VMA é apresentado como:

$$y_t = \mu + \sum_{i=0}^{\infty} \phi_i \varepsilon_{t-i} \quad (6)$$

em que se denominam os coeficientes de ϕ_i como Função Impulso Resposta, observados a partir dos choques ε_{it} para as variáveis definidas y_t , mensurando o impacto nas variáveis gerado pelos respectivos choques nos erros.

Utilizando a equação anterior para realização da previsão, o erro de previsão é expresso em função de seus próprios resíduos:

$$y_{t+n} - E_t y_{t+n} = \sum_{i=0}^{n-1} \phi_i \varepsilon_{t+n-i} \quad (7)$$

em que $y_{t+n} - E_t y_{t+n}$ é o erro de previsão n -período à frente; sendo y_t um vetor formado pelas variáveis endógenas x_t e z_t , focalizando-se somente a série $\{x_t\}$, o erro de previsão n -período à frente é representado como:

$$x_{t+n} - E_t x_{t+n} = \sum_{i=0}^{n-1} \phi_i \varepsilon_{x_{t+n-i}} + \sum_{i=0}^{n-1} \phi_i \varepsilon_{z_{t+n-i}} \quad (8)$$

Denominando a variância do erro de previsão de x_{t+n} por $\sigma_y(n)^2$:

$$\sigma_y(n)^2 = E_t [(x_{t+n} - E_t x_{t+n})^2] \quad (9)$$

em que $\sigma_y(n)^2$ é função de x_t e z_t , e a variância do erro pode ser decomposta em termos da série $\{x_t\}$ e $\{z_t\}$, obtendo-se a Decomposição da Variância do Erro de Previsão, em que $\sigma_y(n)^2$ aumenta com a elevação do horizonte de previsão n , dado que $\phi_{jk}(i)^2 > 0$ (ENDERS, 1995).

2.2. Fonte de dados

Neste estudo, foram utilizados seis séries com observações anuais de 1970 a 2018, totalizando um horizonte de 49 anos. As fontes de dados foram IBGE (2020), Ipeadata (2020) e SEEG (2020).

EMA é a quantidade bruta emitida de GEE pelos setores que compõe o AFOLU, em toneladas;

EB é o número de cabeças de gado;

PCDA é a quantidade produzida de cana-de-açúcar em toneladas;

PM é a quantidade produzida de milho em toneladas;

ESUI é o número de suínos;

PCF é a quantidade produzida de café em toneladas.

As séries produtivas foram escolhidas conforme Assad et al. (2013), Embrapa (2018) e Suela (2019), que argumentam sobre a importância em focar nesses seguimentos produtivos, quando se procura propor ações pró-ambientais, pois as pesquisas em questão apontam os níveis em grande escala de GEE emitidos por essas culturas, o que as tornam prováveis alvos no combate à poluição oriundo do maior rural.

3. RESULTADOS E DISCUSSÃO

3.1 Estatística Descritiva das Variáveis Empregadas no Estudo

A Tabela 1 apresenta as estatísticas descritivas das variáveis utilizadas no estudo, referentes ao período de 1970 a 2018.

Tabela 1 - Estatísticas descritivas para as variáveis envolvidas no estudo, 1970 - 2018.

Estatística	EMA	EB	PCDA	PM	ESUI	PCF
Unidade	Toneladas	Nº de cabeças	Toneladas	Toneladas	Nº de cabeças	Toneladas
Média	1172059795	157945433,1	357320921	37754526,04	36163374,06	2732394,8
Máximo	3513393799	218190768	768594154	97910658	66374000	4405416
Mínimo	189454503	92495364	79752936	13569401	29202182	751969
Nº Observações	49	49	49	49	49	49

Fonte: Resultado da pesquisa

3.2. Análise de estacionariedade

Conforme enfatizado, o primeiro passo para a análise econométrica é verificar se as variáveis envolvidas no estudo são estacionárias. Para isso, foi utilizado o teste de Dickey-Fuller Aumentado. Os resultados do teste ADF com as séries são apresentados na Tabela 2.³

Como pode ser observado na Tabela 2, aos níveis de 1%, 5% e 10%, não se pode rejeitar a hipótese nula de raiz unitária, sugerindo, portanto, que as seis séries são estacionárias em nível e que as séries são integradas de ordem 0 (I(0)).

Tabela 2 - Resultado do teste de raiz unitária ADF para as séries EMA, EB, PC, PM, ESUI e PCF no período 1970-2018.

Variáveis	ADF	
	Em nível	Resultado
EMA	-5.381	I(0)
EB	-4.334	I(0)
PCDA	-7.490	I(0)
PM	-6.680	I(0)
ESUI	-5.420	I(0)
PCF	-7.170	I(0)
Nível de significância	Valores críticos	
1%	-3.600	
5%	-2.938	
10%	-2.604	

Nota: Foi utilizado o critério de Schwarz para a definição do número de defasagens.

Fonte: Resultado da pesquisa.

³ Foram feitos outros testes de raiz unitária para confirmar o teste ADF, tais como Phillips-Perron (PP), Kwiatkowski-Phillips-Schmidt-Shin (KPSS) e Dickey-Fuller GLS (DF-GLS); todos proporcionaram o mesmo resultado, ou seja, foi constatada raiz unitária.

O próximo passo é determinar o número de defasagens do VAR. O número máximo de defasagens⁴ (para que não se perdessem muitos graus de liberdade, dado o tamanho reduzido da amostra) foi de 4, a Tabela 3 mostra em destaque quais as defasagens escolhidas por cada um dos critérios (a 5% de significância). Como pode ser notado das 4 estatísticas testadas, 3 consideram que o modelo com 2 defasagens seria o mais indicado para análise, portanto para estimação adota-se 2 defasagens.

Tabela 3 - Critérios de seleção de defasagem para estimação do modelo VAR

Lag	LR	FPE	AIC	SC	HQ
0	NA	6.1e-06	-0,65815	-0,497562	-0,598287
1	371,3	3.2e-09*	-8,19809	-7,39513	-7,89875
2	19	4.4e-09	-7,91734*	-6,47201*	-7,37854*

Nota: LR: Razão de verossimilhança. Critério FPE. AIC: Critério de Akaike. SC: Critério de Schwarz. HQ: Hannan-Quinn

Fonte: Resultados da pesquisa.

A Tabela 4 apresenta o resultado do modelo VAR estrutural conforme especificação descrita em (2)⁵, lembrando que a ordem das variáveis do modelo estimado são *EMA*, *EB*, *PCDA*, *PM*, *ESUI* e *PCF*. Observa-se que dos 16 coeficientes estimados quase todos foram significativos a 1%, exceto C(10), que foi significativo a 10%.

Ao observar os resultados da Tabela 4, pode-se entender as informações da seguinte maneira. A elevação de 10% na variável EMA (Emissões de GEE oriundos do AFOLU) implica na redução de 0,097% no EB (Efetivo Bovino), redução de 0,011% na PDCA (Produção de Cana-de-Açúcar), redução na produção de Milho (PM) em 0,38%, redução de 0,007% no ESUI (Efetivo Suíno) e redução de 0,0011% na produção de Café (PCF), contemporaneamente. Esse conjunto de resultados apresenta a importância em se controlar as emissões de GEE produzidos pelos setores que compõe o AFOLU. O conjunto de resultados obtidos, demonstram a importância em reduzir as emissões de GEE produzidas, pois ao não controlar o nível de emissões geradas, os setores agropecuários, podem ser afetados negativamente com a perda da capacidade produtiva (COSTANZA et al., 2017). A principal consequência do acúmulo nas emissões é o aumento da temperatura atmosféricas, que traz consigo diversas consequências como o desequilíbrio natural das águas e excesso de irradiação solar (VILLORIA, 2019). Tais consequências podem provocar a redução da produção de culturas, como as utilizadas no estudo (ASSAD et al., 2013; IPCC, 2014).

A tabela 4 apresenta que, o aumento no efetivo bovino (EB) em 10%, causa contemporaneamente, o aumento de 1,9% no ESUI e o aumento de 8,51% na PM. A partir das informações fornecidas por Sá et al. (2017) e EMBRAPA (2018), o aumento no EB causaria contemporaneamente a ampliação nas lavouras de milho, soja e sorgo, por serem as principais fontes de energia essenciais para o desenvolvimento e crescimento dessa espécie animal. Dessa forma, com o aumento no EB, surgiria a necessidade de ampliação das fontes de energia animal, o que levaria a ampliação da oferta deste animal para suprir a demanda exigida pelo segmento. Os resultados indicam também, que o aumento na oferta de milho, levaria contemporaneamente, a aquisição de novas matrizes suínas. Com a maior oferta de alimentos, o custo de produção de novos suínos seria afetado positivamente o que explicaria o crescimento nesse setor.

Analisou-se também, o que ocorreria caso houvesse elevação de 10% na PDCA, contemporaneamente. A PM seria afetada negativamente com a queda na produção em 3,9%. Ao verificar o aumento de 10% na PM, notou-se que haveria crescimento na produção de ESUI

⁴ O modelo foi estimado utilizando o software EViews 10 e as saídas se encontram no Apêndice.

⁵ $Au_t = Be_t$

em 0,56% e aumento de 3,1% em número de cabeças de gado, o aumento nas matrizes suínas e de gado segue a lógica da oferta e demanda, com o crescimento na oferta de milho no mercado, as cadeias de produção de suínos e gado seriam afetada positivamente, pois esse grão influencia diretamente na produção desses animais por ser uma das principais fontes energéticas para o crescimento e desenvolvimento dessas espécies. Dessa forma, com o valor do serial reduzido o incentivo para ampliação do número de matrizes é maior, causando assim o crescimento desses segmentos (EMBRAPA, 2018).

Tabela 4 - Resultados do modelo VAR estrutural, com a ordem das variáveis dada da seguinte forma: EMA, PC, EB e PM.

MATRIZ A					
1	0	0	0	0	0
C(1)	1	0	C(9)	0	0
C(2)	0	1	0	0	0
C(3)	C(6)	C(8)	1	0	0
C(4)	C(7)	0	C(10)	1	0
C(5)	0	0	0	0	1
MATRIZ B					
C(11)	0	0	0	0	0
0	C(12)	0	0	0	0
0	0	C(13)	0	0	0
0	0	0	C(14)	0	0
0	0	0	0	C(15)	0
0	0	0	0	0	C(16)

	COEFICIENTES	DESVIO-PADRÃO	ESTATÍSTICA z	PROBABILIDADE
C(1)	0.009694	0.113332	-0.425299	0.0006
C(2)	0.001095	0.123965	-0.997135	0.0002
C(3)	0.037840	0.069240	0.982768	0.0052
C(4)	0.000683	0.157583	-1.038.429	0.0000
C(5)	0.000107	0.088092	-2.325.015	0.0003
C(6)	-0.851284	0.079797	0.543655	0.0046
C(7)	-0.188827	0.044587	0.382768	0.0100
C(8)	0.385120	0.896452	0.584738	0.0092
C(9)	-0.310577	0.051744	-0.844712	0.0021
C(10)	-0.055388	0.885556	-1.782.758	0.0705
C(11)	3.40E+08	31839.47	9.797.958	0.0000
C(12)	19740412	67182.76	9.797.958	0.0000
C(13)	20401496	58235.13	9.797.958	0.0000
C(14)	21133884	52168.29	9.797.958	0.0000
C(15)	1933376.	31836.47	9.797.958	0.0000
C(16)	658425.0	29556.43	9.797.958	0.0000

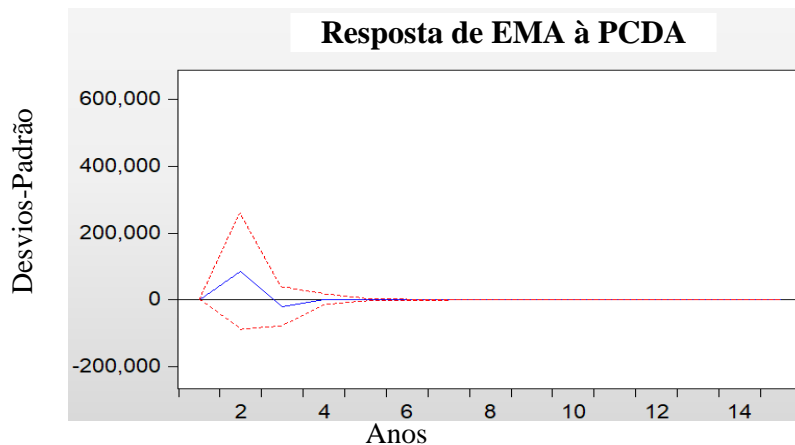
Fonte: resultado da pesquisa.

SVAR Matricialmente

$$\begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0,0097 & 1 & 0 & -0,311 & 0 & 0 \\ 0,0011 & 0 & 1 & 0 & 0 & 0 \\ 0,038 & -0,85 & 0,39 & 1 & 0 & 0 \\ 0,0007 & -0,19 & 0 & -0,056 & 1 & 0 \\ 0,00011 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \times \begin{pmatrix} EMA \\ EB \\ PCDA \\ PM \\ ESUI \\ PCF \end{pmatrix} =$$

$$= \begin{cases} EMA \\ 0,0097EMA + EB - 0,311PM \\ 0,0011EMA + PCDA \\ 0,038EMA - 0,85EB + 0,39PCDA + PM \\ 0,0007EMA - 0,19EB - 0,056PM + ESUI \\ 0,00011EMA + PCF \end{cases} \rightarrow \begin{cases} EMA = \text{TERMOS DEFASADOS (TD)} \\ EB = -0,0097EMA + 0,311PM + TD \\ PCDA = -0,0011EMA + TD \\ PM = -0,038EMA + 0,85EB - 0,39PCDA + TD \\ ESUI = -0,0007EMA + 0,19EB + 0,056PM + TD \\ PCF = -0,00011EMA + TD \end{cases}$$


Após realizado a análise dos resultados do SVAR é importante verificar os resultados oriundos da função impulso-resposta oriundas da própria estimação do SVAR que podem ser vistos nas figuras abaixo. A Figura 2 apresenta a função impulso-resposta relativo ao impacto que a Produção de Cana-de-açúcar causa nas emissões de GEE caso haja um choque em sua produção.



Fonte: Dados da pesquisa.

Figura 2: Resposta da variação nas emissões de GEE a partir de um choque na produção de Cana-de-açúcar.


A Figura 2 demonstra que no primeiro ano, um choque de dois desvios-padrão na produção de Cana-de-açúcar faz com que as emissões de GEE cresça nos dois primeiros anos, decline no terceiro, se estabilizando apenas no quinto ano.



Fonte: Dados da Pesquisa

Figura 3: Resposta da variação nas emissões de GEE a partir de um choque na produção de Milho.


A Figura 3 apresenta que no primeiro ano, um choque de 2 desvios-padrão na produção de Milho faz com que as emissões de GEE comece com queda, aumentando as emissões no terceiro e se estabilizando somente no quinto ano.



Fonte: Dados da Pesquisa

Figura 4: Resposta da variação nas emissões de GEE a partir de um choque no Efetivo Bovino.


Nota-se na Figura 4 que ao aplicar um choque de 2 desvios-padrão à aquisição de novas cabeças de gado o comportamento nas emissões é bem interessante, observa-se que apenas no primeiro ano as emissões não são positivas, do segundo ano em diante as emissões de GEE crescem, oscilam nos anos subsequentes, porém, sempre positivo, o que significa que o aumento no plantel bovino tem grandes consequências em relação as emissões, a estabilização ocorre somente no décimo segundo ano.



Fonte: Dados da Pesquisa

Figura 5: Resposta da variação nas emissões de GEE a partir de um choque no Efetivo Suíno.

A Figura 5 apresenta a resposta das emissões de GEE em relação a um choque de dois desvios-padrão no aumento do efetivo suíno. O primeiro ano mostra que caso haja crescimento no plantel suíno, as emissões de GEE aumentam, logo após, a redução nas emissões conseguindo se estabilizar no quarto ano.



Fonte: Dados da Pesquisa

Figura 6: Resposta da variação nas emissões de GEE a partir de um choque na produção de Café.

Por fim, nota-se na Figura 6 que ao aplicar um choque de 2 desvios-padrão à na produção de Café, o comportamento nas emissões se apresenta oscilatório até sua estabilização. O choque na Produção de café no primeiro ano causa queda nas emissões até o segundo ano, ao chegar no ano três, ocorre aumento nas emissões, no qual, a estabilização só é obtida no quarto ano.

A decomposição da variância é outro método que busca analisar a influência de uma variável sobre outra (as). Nesse sentido, utilizou-se esse método originário do próprio SVAR para explicitar a participação de cada variável na variância dos resíduos da outra. O resultado da decomposição da variância é apresentado na Tabela 5.

Conforme exposto na Tabela 5, a principal variável para explicar a variância da variação nas emissões de GEE é ela própria, entretanto com o passar do tempo todas as variáveis do modelo vão ganhando importância para explicar a variância do erro de previsão da variação nas emissões de GEE. Por exemplo, no 15º período 7.31% da variância do erro de previsão é devido

ao efetivo bovino (EB), e 5.90% devido a produção de Cana-de-açúcar, a produção de milho é responsável por explicar 3,31%, e a produção de Café é responsável por 4,09%, a cultura com menor participação na explicação da variância na variação das emissões e a produção de matrizes suínas com 1,44%, como já mencionado anteriormente, a variação das emissões é a responsável por explicar a maior parte das emissões, para o caso dessa pesquisa, a parcela que a compete ficou entorno de 77.9% da variância.

Tabela 5 - Decomposição da variância do erro de previsão da variação nas emissões de GEE

Ano	EMA	EB	PCDA	PM	ESUI	PCF
1	100.0000	0.000000	0.000000	0.000000	0.000000	0.000000
2	90.67127	5.057336	0.258794	2.158710	1.395414	0.458477
3	83.04580	7.240865	3.996938	3.124754	1.427777	1.163862
4	78.99296	7.277104	5.731473	3.011824	1.378603	3.608035
5	78.13054	7.200719	5.883366	3.299805	1.425527	4.060047
6	77.99508	7.312291	5.887327	3.297531	1.431169	4.076606
7	77.97409	7.311766	5.889621	3.316198	1.433409	4.074913
8	77.93147	7.313056	5.899047	3.318989	1.439311	4.098123
9	77.92929	7.313760	5.899295	3.319667	1.439925	4.098064
10	77.92439	7.318420	5.899499	3.319801	1.439832	4.098062
11	77.92404	7.318398	5.899525	3.319809	1.440061	4.098167
12	77.92175	7.318278	5.900275	3.319792	1.440144	4.099763
13	77.92172	7.318263	5.900280	3.319783	1.440154	4.099802
14	77.92159	7.318391	5.900271	3.319792	1.440156	4.099797
15	77.92155	7.318388	5.900275	3.319792	1.440156	4.099837

Fonte: Dados da Pesquisa

4. CONCLUSÃO

Este estudo teve como objetivo verificar contemporaneamente, quais seriam os impactos nas principais culturas produtivas brasileiras, caso houvesse aumento nas emissões de GEE, além de analisar os prováveis impactos nas culturas produtivas, de maneira contemporânea, caso houvesse crescimento em cada uma das variáveis do modelo, assim como a resposta da variância do erro de previsão nas emissões GEE. Para isso foi estimado pelo método VAR Estrutural.

Nota-se que que todas as variáveis escolhidas, apresentaram redução na quantidade produzida caso houvesse choques nas quantidades emitidas de GEE. De maneira geral, as culturas produtivas respondem de forma positiva a aumentos na quantidade produtivas das demais variáveis. É possível concluir a partir da função impulso-resposta que um choque de dois desvios-padrão no aumento do EB é o que gera maior volatilidade e maior tempo para se dissipar no horizonte de 15 anos. Por fim é possível concluir ainda que o aumento no EB e na PDCA são os principais responsáveis para explicar a variância do erro da variação da produção.

AGRADECIMENTO

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Os autores também

agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq pela concessão de Bolsa de Produtividade em Pesquisa (Processos 30XXXX/2018-8 e 42XXXX/2016-0) e Bolsa de Pós-Doutorado Júnior (Processo 43XXXX/2016-3).

5. REFERÊNCIAS

ASSAD, E. et. al. Impactos das Mudanças Climáticas na Produção Agrícola Brasileira. Banco Mundial. 2013.

BAZAN, G. Our Ecological Footprint: reducing human impact on the earth. *Electronic Green Journal*. 1(7). doi:10.5070/g31710273. 1997.

BROOKS J. Brazilian Agriculture: Balancing Growth with the Need for Equality and Sustainability. *EuroChoices*, 16(1), 32–36. doi:10.1111/1746-692x.12148. 2017.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – Embrapa. Visão 2030: o futuro da agricultura brasileira. Brasília, DF. p. 212. 2018.

CEDDIA M. G.; SEDLACEK S.; BARDSLEY N. O.; GOMEZ-Y-PALOMA S. Sustainable agricultural intensification or Jevons paradox? The role of public governance in tropical South America. *Global Environmental Change*. 23. 1052–1063. <https://doi.org/10.1016/j.gloenvcha.2013.07.005>. 2013.

COHN A. S.; MOSNIER A.; HAVLIK P.; VALIN H.; HERRERO M.; SCHMID E.; O’HARE M.; OBERSTEINER M. Cattle ranching intensification in Brazil can reduce global greenhouse gas emissions by sparing land from deforestation. *PNAS*. 111. 7236-7241. www.pnas.org/cgi/doi/10.1073/pnas.1307163111. 2014.

COSTANZA R.; GROOT R.; BRAAT L.; KUBISZEWSKI I.; FIORAMONTI L.; SUTTON P.; FARBER S.; GRASSO M. Twenty years of ecosystem services: How far have we come and how far do we still need to go? *Ecosystem Services*. 28. 1-16. <https://doi.org/10.1016/j.ecoser.2017.09.008>. 2017.

ENDERS, W. *Applied econometric time series*. New York: John Wiley, 1995. 433p.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATION – FAO, OECD-FAO Agricultural Outlook 2019-2028, OECD Publishing, Paris/Food and Agriculture Organization of the United Nations, Rome. https://doi.org/10.1787/agr_outlook-2019-en. 2019.

FRANKLIN S. L.; PINDYCK R. S. Tropical Forests, Tipping Points, and the Social Cost of Deforestation. *Ecological Economics*. 153. 161-171. <https://doi.org/10.1016/j.ecolecon.2018.06.003>. 2018.

GARNETT T.; GODFRAY C. Sustainable intensification in agriculture. Navigating a course through competing food system priorities, Food Climate Research Network and the Oxford Martin Programme on the Future of Food, University of Oxford, UK. 2012.

GODFRAY H. C. J.; BEDDINGTON J. R.; CRUTE I. R.; HADDAD L.; LAWRENCE D.; MUIR J. F.; PRETTY J. ROBINSON S.; THOMAS S. M.; TOULIMIN C. Food Security: The Challenge of Feeding 9 Billion People. *Science*. 327. 812-818. DOI: 10.1126/science.1185383. 2010.

IBGE - Para 1931-1987: Estatísticas históricas do Brasil: séries econômicas, demográficas e sociais de 1550 a 1988. 2. ed. rev. e atual. do v. 3 de Séries estatísticas retrospectivas. Rio de Janeiro: IBGE, 1990. Apud: Estatísticas do século XX, Centro de documentação e disseminação de informações. Rio de Janeiro: IBGE, 2003. Acessada em 20 de setembro de 2020.

IPCC .Climate Change 2014: Impacts, Adaptation, and Vulnerability. 2014.

JANJUA, P., SAMAD, G., KHAN, N., & NASIR, M. (2010). Impact of Climate Change on Wheat Production: A Case Study of Pakistan [with Comments]. *The Pakistan Development Review*, 49(4), 799-822. Retrieved September 25, 2020, from <http://www.jstor.org/stable/41428691>.

IPEADATA - Séries temporais produção de milho e cana-de-açúcar. Acesso em 20 de setembro de 2020. 2020.

LIMA C. Z. Impacts of Low Carbon Agriculture in Brazil: a CGE application. 2017. 113f. Tese (Doutorado em Economia Aplicada) – Universidade Federal de Viçosa, Minas Gerais. 2017.

MACEDO M. N.; DEFRIES R. S.; MORTON D. C.; STICKLER C. M.; GALFORD G. L.; SHIMABUKURO Y. E. Decoupling of deforestation and soy production in the southern Amazon during the late 2000s. *PNAS*. 109(4). 1341-1346. www.pnas.org/cgi/doi/10.1073/pnas.1111374109. 2012.

MATSON P. A.; VITOUSEK P. M. Agricultural Intensification: Will Land Spared from Farming be Land Spared for Nature? *Conservation Biology*. 20(3). 709-710. DOI: 10.1111/j.1523-1739.2006.00442.x. 2006.

OBSERVATÓRIO DO CLIMA. Análise da evolução das emissões de GEE no Brasil (1990-2012). São Paulo: Observatório do Clima, 2014.

PERES C. A.; GARDNER T. A.; BARLOW J.; ZUANON J.; MECHALSKI F.; LEES A. C.; VIEIRA I. C. G.; MOREIRA F. M. S.; FEELEY K. J. Biodiversity conservation in human-modified Amazonian forest landscapes. *Biological Conservation*. 143. 2314-2327. DOI:10.1016/j.biocon.2010.01.021. 2010.

PFUFF A.; WALKER R. Regional interdependence and forest “transitions”: Substitute deforestation limits the relevance of local reversals. *Land Use Policy*. 27. 119-129. DOI:10.1016/j.landusepol.2009.07.010. 2010.

ROCHEDO P. R. R.; SOARES-FILHO B.; SCHAEFFER R.; VIOLA E.; SZKLO A.; LUCENA A. F. P.; KOBERLE A.; DAVIS J. L.; RAJÃO R.; RATHMANN R. The threat of political bargaining to climate mitigation in Brazil. *Nature Climate Change*. 8. 695-698. <https://doi.org/10.1038/s41558-018-0213-y>. 2018.

ROCKSTRÖM, J.; WILLIAMS, J.; DAILY, G. et al. Sustainable intensification of agriculture for human prosperity and global sustainability. *Ambio*. 46(1). 4-17. <https://doi.org/10.1007/s13280-016-0793-6>. 2017.

SÁ J. C. M.; LAL R.; CERRI C. C.; LORENZ M. H.; CARVALHO P. C. F. Low-carbon agriculture in South America to mitigate global climate change and advance food security. *Environmental international*. 98. 102–112. <http://dx.doi.org/10.1016/j.envint.2016.10.020>. 2017.

SILVA R. O.; BARIONI L. G.; PELLEGRINO G. Q.; MORAN D. The role of agricultural intensification in Brazil's Nationally Determined Contribution on emissions mitigation. *Agricultural Systems*. 161. 102-112. <https://doi.org/10.1016/j.agsy.2018.01.003>. 2018.

SIMS, C. A. Macroeconomics and reality. *Econometrica*, v. 48, p. 1-48, 1980.

SISTEMA DE ESTIMATIVAS DE EMISSÕES E REMOÇÕES DE GASES DE EFEITO ESTUFA – SEEG. Análise das Emissões brasileiras de Gases de Efeito Estufa e suas Implicações para as Metas do Brasil. 2019. Disponível: http://www.observatoriodoclima.eco.br/wp-content/uploads/2019/11/OC_SEEG_Relatorio_2019pdf.pdf>. Acesso em 31 de Maio de 2020.

- SOARES-FILHO B.; RAJÃO R.; MACEDO M.; CARNEIRO A.; COSTA W.; COE M.; RODRIGUES H.; ALENCAR A. Cracking Brazil's Forest Code. *Science*. 344. 363-364. DOI: 10.1126/science.1246663. 2014.
- SMITH P.; HABERL H.; POPP A.; ERB K. H.; LAUK C.; HARPPER R.; TUBIELLO F. N. et al. How much land-based greenhouse gas mitigation can be achieved without compromising food security and environmental goals? *Global Change Biology*. 19. 2285-2302. DOI: 10.1111/gcb.12160. 2013.
- STRASSBURG B. B. N.; LATAWIEC A. E.; BARIONI L. G.; NOBRE C. A.; SILVA V. P.; VALENTIM J. F.; VIANNA M.; ASSAD E. D. When enough should be enough: Improving the use of current agricultural lands could meet production demands and spare natural habitats in Brazil. *Global Environmental Change*. 28. 84-97. <http://dx.doi.org/10.1016/j.gloenvcha.2014.06.001>. 2014.
- SUELA A. G. L. Efeitos ambientais da implementação do Plano ABC no MATOPIBA: uma abordagem por Insumo-Produto. 2019. 70f. Dissertação. (Mestrado em Economia Aplicada) - Universidade Federal de Viçosa, Minas Gerais. 2019.
- TESSO, G., EMANA, B., & KETEMA, M. (2012). A time series analysis of climate variability and its impacts on food production in North Shewa zone in Ethiopia. *African Crop Science Journal*, 20, 261-274.
- TILMAN D.; CASSMAN K. G.; MATSON P. A.; NAYLOR R.; POLASKY S. Agricultural sustainability and intensive production practices. *Nature*. 418. 671-677. 10.1038/nature01014. 2002.
- VILLORIA B. N. Technology Spillovers and Land Use Change: Empirical Evidence from Global Agriculture. *American Journal Agricultural Economics*. 101(3): 870-893. doi: 10.1093/ajae/aay088. 2019.

APÊNDICE

A.1 - Dickey-Fuller Aumentado

Null Hypothesis: EMA has a unit root		
Exogenous: Constant		
Lag Length: 0 (Automatic - based on SIC, maxlag=0)		
		t-Statistic Prob.*
Augmented Dickey-Fuller test statistic		-5.381535 0.0000
Test critical values:	1% level	-3.574446
	5% level	-2.923780
	10% level	-2.599925
*MacKinnon (1996) one-sided p-values.		

Null Hypothesis: EB has a unit root		
Exogenous: Constant		
Lag Length: 0 (Automatic - based on SIC, maxlag=0)		
		t-Statistic Prob.*
Augmented Dickey-Fuller test statistic		-4.334230 0.0000
Test critical values:	1% level	-3.574446
	5% level	-2.923780
	10% level	-2.599925
*MacKinnon (1996) one-sided p-values.		

Null Hypothesis: PC has a unit root		
Exogenous: Constant		
Lag Length: 0 (Automatic - based on SIC, maxlag=0)		
		t-Statistic Prob.*
Augmented Dickey-Fuller test statistic		-7.490023 0.0000
Test critical values:	1% level	-3.574446
	5% level	-2.923780
	10% level	-2.599925
*MacKinnon (1996) one-sided p-values.		

Null Hypothesis: PM has a unit root		
Exogenous: Constant		
Lag Length: 0 (Automatic - based on SIC, maxlag=0)		
		t-Statistic
		Prob.*
Augmented Dickey-Fuller test statistic		-6.681350
Test critical values:	1% level	-3.574446
	5% level	-2.923780
	10% level	-2.599925

Null Hypothesis: PCF has a unit root		
Exogenous: Constant		
Lag Length: 0 (Automatic - based on SIC, maxlag=0)		
		t-Statistic
		Prob.*
Augmented Dickey-Fuller test statistic		-7.170764
Test critical values:	1% level	-3.574446
	5% level	-2.923780
	10% level	-2.599925
*MacKinnon (1996) one-sided p-values.		

A.2 - SVAR

Structural VAR Estimates					
Date: 10/21/20 Time: 09:50					
Sample (adjusted): 1972 2018					
Included observations: 47 after adjustments					
Estimation method: Maximum likelihood via Newton-Raphson (analytic derivatives)					
Convergence achieved after 85 iterations					
Structural VAR is over-identified					
Model: $Ae = Bu$ where $E[uu'] = I$					
A =					
1	0	0	0	0	0
C(1)	1	0	C(9)	0	0
C(2)	0	1	0	0	0
C(3)	C(6)	C(8)	1	0	0
C(4)	C(7)	0	C(10)	1	0
C(5)	0	0	0	0	1
B =					
C(11)	0	0	0	0	0
0	C(12)	0	0	0	0
0	0	C(13)	0	0	0
0	0	0	C(14)	0	0
0	0	0	0	C(15)	0
0	0	0	0	0	C(16)
	Coefficient	Std. Error	z-Statistic	Prob.	
C(1)	0.009694	0.113332	-0.425299	0.0006	
C(2)	0.001095	0.123965	-0.997135	0.0002	
C(3)	0.037840	0.069240	0.982768	0.0052	
C(4)	0.000683	0.157583	-1.038.429	0.0000	
C(5)	0.000107	0.088092	-2.325.015	0.0003	
C(6)	-0.851284	0.079797	0.543655	0.0046	
C(7)	-0.188827	0.044587	0.382768	0.0100	
C(8)	0.385120	0.896452	0.584738	0.0092	
C(9)	-0.310577	0.051744	-0.844712	0.0021	
C(10)	-0.055388	0.885556	-1.782.758	0.0705	
C(11)	3.40E+08	31839.47	9.797.958	0.0000	
C(12)	19740412	67182.76	9.797.958	0.0000	
C(13)	20401496	58235.13	9.797.958	0.0000	
C(14)	21133884	52168.29	9.797.958	0.0000	
C(15)	1933376.	31836.47	9.797.958	0.0000	
C(16)	658425.0	29556.43	9.797.958	0.0000	
Log likelihood	-4856.697				
LR test for over-identification:					
Chi-square(6)	25.30898		Probability	0.0003	