

Regionalização da produção de soja no Paraná e no Mato grosso a partir do algoritmo Skater

Cleverton Tiago Carneiro de Santana¹

¹ Instituto Nacional de Pesquisas Espaciais – INPE

Caixa Postal 515 – 12227-010 – São José dos Campos – SP, Brasil

cleverton.santana@inpe.br

Resumo: O Brasil é o maior produtor e exportador de soja do mundo. Nos últimos anos, a produção de soja aumentou consideravelmente para atender à crescente demanda do mercado interno e externo, ocupando uma área de 38,93 milhões de hectares do território nacional. Com isso, do ponto de vista do monitoramento agroclimático, é necessário buscar mecanismos para estimar a produtividade dessas culturas com base em metodologias objetivas de coletas *in situ*. Porém, em função da dimensão continental, é necessário que as coletas abranjam regiões homogêneas de produção e, a produtividade é melhor indicador para definir tais regiões. O estudo de caso contemplou os municípios produtores do Paraná e do Mato Grosso, sendo utilizado os dados da Pesquisa Agrícola Municipal do Instituto Brasileiro de Geografia e Estatística (PAM-IBGE) por retratarem a realidade agrícola do país. Assim, o objetivo do presente estudo foi realizar a regionalização espacial da produção de soja nos dois maiores estados produtores de soja do país empregando-se o algoritmo *Spatial 'K'luster Analysis by Tree Edge Removal* (SKATER). As culturas agrícolas dependem de recursos naturais (solo, clima) concentrados no espaço geográfico, o que reforça a ideia de que a produção ocorre na forma de agrupamentos (clusters), espalhados pelo espaço econômico. Porém, esse agrupamento pode mudar em razão do manejo (sementes, adubação, mecanização...), e por isso é necessário técnicas de agrupamento para melhor caracterização dessas áreas. A aplicação do algoritmo Skater nas áreas de produção de soja, com base na produtividade, permitiu regionalizar as áreas de estudo em regiões contíguas e a partir dessa técnica foi possível avaliar a distribuição de região homogêneas nos dois estados (Paraná e Mato Grosso) e estimar a melhor quantidade de regiões contíguas. Como recomendações para trabalhos futuros, outras variáveis explicativas devem ser consideradas, visando uma melhoria na representação gerada pelo modelo.

Palavras-chave: Análise exploratória espacial, Dados geográficos, Produtividade, SKATER.

1 Introdução

Em diversas análises espaciais (dados com aplicações geográficas) da agropecuária, como análises de dados de área média do produtor rural, produtividade, percentual de atividade econômica (agricultura, pecuária, produção florestal, etc), os dados são organizados como um grande conjunto de objetos espaciais representados por áreas, como os indicadores municipais do Censo Agropecuário e da Pesquisa Agrícola Municipal do Instituto Brasileiro de Geografia e Estatística (IBGE).

As duas pesquisas são importantes ferramentas utilizada para formulação e avaliação de políticas agrícolas e a Companhia Nacional de Abastecimento (Conab), órgão do Ministério da Agricultura, Pecuária e Abastecimento, utiliza dados dessas pesquisas para regionalizar as áreas produtoras de café, com o intuito de realizar amostragem para a Estimativa da Safra Brasileira de Café.

Em muitas circunstâncias, como nas estimativas de produção realizada pela Conab, é desejável agrupar um grande número de municípios (objetos espaciais) em um número menor de subconjuntos de município (objetos), que são internamente homogêneos em relação ao nível tecnológico) e ocupam regiões contíguas no espaço. Este procedimento é denominado regionalização, o que resulta em novas áreas a partir dos agrupamentos de municípios com uma extensão geográfica mais abrangente, denominadas regiões. O agrupamento constitui uma das tarefas mais importantes na análise de dados (HENRIQUES et al., 2012)

A estimativa de produtividade agrícola é um desafio, sobretudo em países com dimensões continentais, onde há grande variabilidade de solo, clima, culturas e tecnologia aplicada. Os procedimentos convencionais de estimativa de produtividade envolvem conhecimento do pacote tecnológico utilizado pelo produtor, dos tipos de solo, de modelagem estatística com modelos preditivos, do acompanhamento sistemático das condições agrometeorológicas e de técnicas de amostragens *in situ* (CONAB, 2020).

As amostragens *in situ* são extremamente relevantes, pois são mensurações objetivas da produtividade, mas demandam rigor estatístico na amostragem e podem apresentar baixa precisão se houver falha metodológica, além de demandarem alto curso com recursos humanos e financeiros. Assim, agrupar um conjunto de unidades de área homogêneas, como os municípios, para compor uma região maior pode ser

extremamente útil para procedimentos de amostragem (MARTIN, 1998), otimizando a coleta e reduzindo os custos.

A mensuração da produtividade de soja pela Conab é realizada via amostragem probabilística e a coleta de dados é realizada a esmo, sendo que 1 amostra é coletada a cada 15 km nas regiões produtoras. Com isso, as variações regionais não são levadas em consideração e, com isso, regiões com um pacote tecnológico diferente podem não estar sendo devidamente contempladas nas amostragens realizadas. Portanto, com o intuito de realizar estimativas ainda mais precisas, é fundamental mensurar com precisão as regiões de coletas de dados através da formação de grupos compostos internamente de áreas similares.

Uma técnica para gerar áreas homogêneas com base na produtividade é a regionalização. A regionalização é um procedimento de classificação aplicado a objetos espaciais com representação de área, que os agrupa em regiões contíguas homogêneas. Assim, o algoritmo SKATER é um método eficiente para regionalização. A primeira etapa cria um gráfico de conectividade que captura a relação de vizinhança entre os objetos. O resultado é a divisão dos objetos espaciais em regiões conectadas que possuam homogeneidade interna máxima. Esse método combina desempenho e qualidade, sendo uma boa alternativa a outros métodos de regionalização encontrados na literatura (ASSUNÇÃO, et al., 2006).

Nesse sentido, esse estudo objetivou explorar formas de regionalizar a produção de soja no Paraná e no Mato Grosso, a partir dos dados de produtividade, usando o algoritmo Skater (*Spatial 'K'luster Analysis by Tree Edge Removal*). O propósito é compreender as características da região sob a perspectiva agrícola e verificar se há conglomerados espaciais semelhantes da perspectiva da produção dessas *commodities*.

2 Metodologia

2.1 Área de estudo

Em 2020 a Conab, em conjunto com empresas parceiras, iniciou o levantamento objetivo de produtividade de soja. O intuito era coleta amostras nas principais regiões produtoras de soja para colaborar na melhorar das estatísticas agrícolas de produção, conforme ilustrado na Figura 1. Essa nova metodologia demanda estudos exploratórios sobre a distribuição espacial da produtividade de soja. Uma primeira

estratégia foi coletar amostras aleatoriamente, considerando a divisão político-administrativa por Unidade da Federação como uma região homogênea. No entanto, essa estratégia de regionalização omitiria as semelhanças entre os municípios fronteiriços e não levaria em conta a dependência espacial dos processos agrícolas.

Figura 1 - Área de coleta de amostras do CropTour da Conab.



Fonte: Conab.

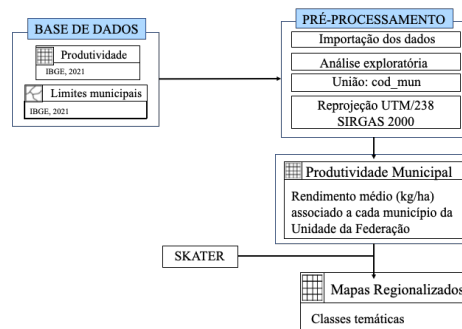
Assim, o presente estudo foi realizado para os dois principais estados produtores de soja no Brasil. O Mato Grosso possui quatro biomas (Amazônia, Cerrado e Pantanal), enquanto o Paraná predomina a Mata Atlântica. A área em estudo possui 540 municípios, sendo 399 no Paraná e 141 no Mato Grosso.

2.2 Fonte e classificação de dados

As principais etapas deste trabalho estão expostas na Figura 2. Para a montagem dos mapas regionalizados foi utilizado a Projeção UTM e o Sistema de Coordenadas Geográficas Datum SIRGAS 2000 (Sistema de Referência Geocêntrico para as Américas). As bases de dados utilizadas foram o Censo Agropecuário e da Pesquisa Agrícola Municipal. Em relação ao Censo Agropecuário, ano de referência 2017, a variável utilizada foi a produtividade de soja, enquanto em relação à Pesquisa Agrícola Municipal, foi utilizado a série histórica (2000-2019). Utilizou-se a linguagem

de programação Python para manipulação dos dados, execução do algoritmo SKATER e produção os mapas de regionalização resultantes.

Figura 2 - Principais etapas do trabalho.



2.3 Variável selecionada

Para a regionalização espacial da área de produção de soja foi utilizado a produtividade, que foi padronizada para o processamento do algoritmo de regionalização. A produtividade agrícola é um fator agrônômico influenciado por três grandes variáveis, o nível tecnológico do produtor, a condição edafoclimática (solo e clima) e o manejo da cultura.

A condição edafoclimática possui duas variáveis, solo e clima. O solo tem variabilidade espacial, porém com pouca variação temporal. Ou seja, apesar de sofrer influência de degradação ao longo do tempo, em geral é um processo lento e não tem impacto direto no curto prazo (entre duas safras, por exemplo). Em relação ao clima, a variabilidade é espaço-temporal e pode ter consequência sob a produtividade em curto intervalo temporal e também em regiões muito próximas. Em relação ao manejo da cultura, ela é uma variável influenciada pelo espaço (localização) e também pelo tempo (ano-safra). A intensidade do ataque de pragas, por exemplo, pode provocar alteração na estratégia de manejo do produtor.

Já o nível tecnológico do produtor é influenciado, principalmente, por dois fatores. O primeiro tem relação com a possibilidade de investimento do produtor (variação temporal) em cada safra, que por sua vez é influenciada pela gestão do produtor e pelo preço pago ao produto. Se há expectativa de maior retorno em relação ao custo de produção, o produtor aumenta o investimento. Caso a expectativa é que essa margem diminua, o produtor reduz o investimento. O segundo fator é a localização do

cultivo. Solos mais férteis, por exemplo, recebem variedades com potencial de produtividade maior, em detrimento à solos menos férteis. Assim, a produtividade é um indicador altamente influenciado pela sua localização espaço-temporal.

2.4 O algoritmo SKATER

Classificar objetos é um processo em comum em diversas atividades. Na agricultura, a categorização por nível tecnológico, tamanho de área, aptidão agrícola, regiões agroclimáticas e susceptibilidade a doenças são exemplo de classificações comum quando é impraticável o tratamento individualizado dos dados como entidade única, sobretudo em grandes áreas (ANDERBERG, 1973). A separação em categorias é necessária e empregada em uma série de análises agronômicas. Descrições de cultivos agrícolas, por exemplo, consideram aspectos como tamanho de área, produtividade, tipo de semente, cultivar, nível de adubação, época de plantio, etc. Cada um destes itens pode ser o atributo de uma área, município, microrregião, mesorregião, unidade da federação ou grande região. Os atributos são determinantes em qualquer processo de classificação, ou como no contexto deste trabalho, ao uso de técnicas para regionalização.

A regionalização espacial é a partição de objetos com representação espacial e variável (is) associada (as) em áreas, onde os objetos membros de uma classe formam uma região contígua (SILVA et al., 2015) e atendam a três critérios:

- a) devem ser contíguos;
- b) apresentem similaridades com relação à (s) variável (is) associada (as); e
- c) objetos de regiões diferentes devem ser diferentes entre si com relação às variáveis associadas.


Assim, a regionalização é uma técnica de aprendizado de máquina não supervisionada em análise espacial para descobrir clusters espacialmente contíguos, também conhecidos como regiões, em que os clusters são baseados conjuntamente na similaridade nos valores das variáveis e na proximidade no espaço (ASSUNÇÃO et al., 2002).

A representação de objetos espaciais baseada em grafos foi integrada em diversas metodologias amplamente utilizadas em várias áreas e permite colocar a regionalização como um problema de particionamento de grafos (ASSUNÇÃO, et. al. 2006). Um desses métodos baseados em grafos é o algoritmo SKATER que reduz a

representação gráfica completa de objetos espaciais a uma representação em árvore que pode ser facilmente podada para criar regiões. O SKATER usa a árvore geradora mínima como alternativa para avaliar objetos espaciais e definir regiões.

O algoritmo SKATER considera o conjunto de objetos geográficos contíguos (Figura 3a) como um grafo (Figura 3b), em que os objetos são representados por nós e as arestas são as relações de vizinhança. A partir daí é possível transformar o grafo em uma Árvore Geradora Mínima (AGM) (Figura 3c), que será particionada iterativamente (Figura 3d) gerando a regionalização desejada (Figura 3e).

Figura 3 - Representação esquemática do método de regionalização via Skater.



Fonte: Camargo, 2021.

Geo-objetos (a), geração do grafo (b), construção da árvore geradora mínima (c), realização da poda (d) e definição dos conglomerados espaciais (e).

Uma AGM é uma árvore geradora com custo mínimo, onde o custo é medido como a soma das dissimilaridades em todas as arestas da árvore (ASSUNÇÃO, et. al. 2006). A AGM é construída base no algoritmo de Prim (JUNGNICKEL, 1999). AGM de um grafo é um subgrafo que contém todos os nós da AGM e o número de arestas é igual ao número de nós menos um. O custo de um grafo é igual a soma dos custos das arestas. Nesse trabalho, o custo de uma aresta será a distância euclidiana entre os atributos dos objetos geográficos ligados a ela.

Para o processo de poda, e conseqüente formação das regiões, o algoritmo SKATER elimina as arestas de menores custos. O “custo” para remover a aresta da AGM é dada por:

$$I = SQD_T - SQD_I$$

Onde SQD_T corresponde à soma dos quadrados dos desvios total da árvore e SQD_A à soma dos quadrados dos desvios dos dois grupos a e b gerados a partir da eliminação da aresta:

$$SQD_T = \sum_{j=1}^m \sum_{i=1}^n (x_{ij} - x_j)^2$$

$$SQD_I = SQD_{Ta} + SQD_{Tb}$$

A partição da AGM os seguintes passos foram seguidos: 1) calculou-se o custo de eliminação de cada aresta; 2) eliminou-se sucessivamente as arestas da AGM que tivessem o menor custo; e 3) repetiu-se o processo até atingir o número de regiões definido para cada Unidade da Federação.

Ao final, cada grupo corresponderá a uma sub-região homogênea e contígua e todo o mapa estará dividido em c sub-regiões. A qualidade Q da partição pode ser medida pela soma dos quadrados dos desvios de cada grupo. O cálculo de Q para a partição dos dados em c grupos e da soma dos quadros dos desvios SQD para um grupo qualquer k é realizado a partir das equações abaixo (ASSUNÇÃO et al., 2006).

$$Q(c) = \sum_{i=1}^c SQD_i$$

$$SQD_k = \sum_{j=1}^m \sum_{i=1}^{nk} (x_{ij} - x_j)^2$$

Onde m é o número de atributos em análise, nk é o número de elementos do grupo k , x_{ij} é o valor do j -ésimo atributo do objeto espacial i , x_j é a média do j -ésimo atributo para todos os objetos do grupo k .

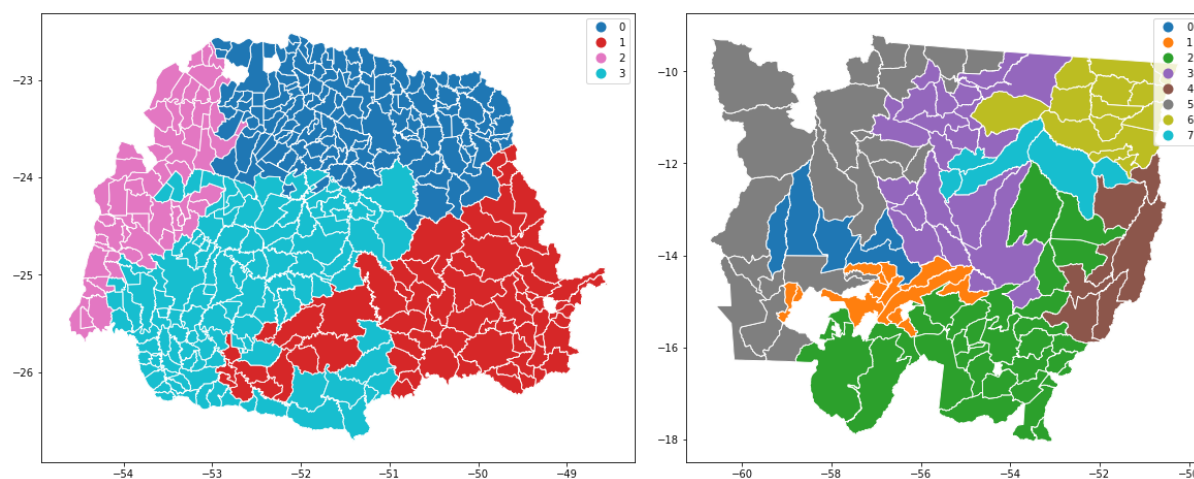
2.5 Processamento dos dados

A linguagem de programação Python para os resultados alcançados. Para a manipulação dos dados foram utilizadas as bibliotecas **geopandas** e **pandas**. Para a realização dos cálculos estatísticos foram utilizadas as bibliotecas **esda**, **libpysal**, **numpy**, **shapely** e o pacote **contextily**. Para a plotagem dos gráficos e mapas para visualização dos resultados foi utilizada a biblioteca **matplotlib**. Para a regionalização via algoritmo Skater foram utilizadas as bibliotecas **spopt**, **mapclassify**, **libpysal**, **sklearn**, **numpy** e o pacote **ipywidgets**.

3 Resultados e discussão

Inicialmente, a regionalização do Paraná e do Mato Grosso foram realizadas com base nos dados do Censo Agro 2017 (Figura 4). Porém, isso trouxe alguns resultados não esperados, considerando as condições agrônômicas desses estados. Algumas regiões com características bem distintas foram agregadas no mesmo cluster. Isso ocorreu, provavelmente por ocasião da variabilidade da produtividade municipal que foi de 913 kg/ha à 4.369 kg/ha para o Paraná e 1.800 kg/ha à 4.256 kg/ha para o Mato Grosso (Figura 5) e também pela informação restrita à apenas um ano-safra (2016/17).

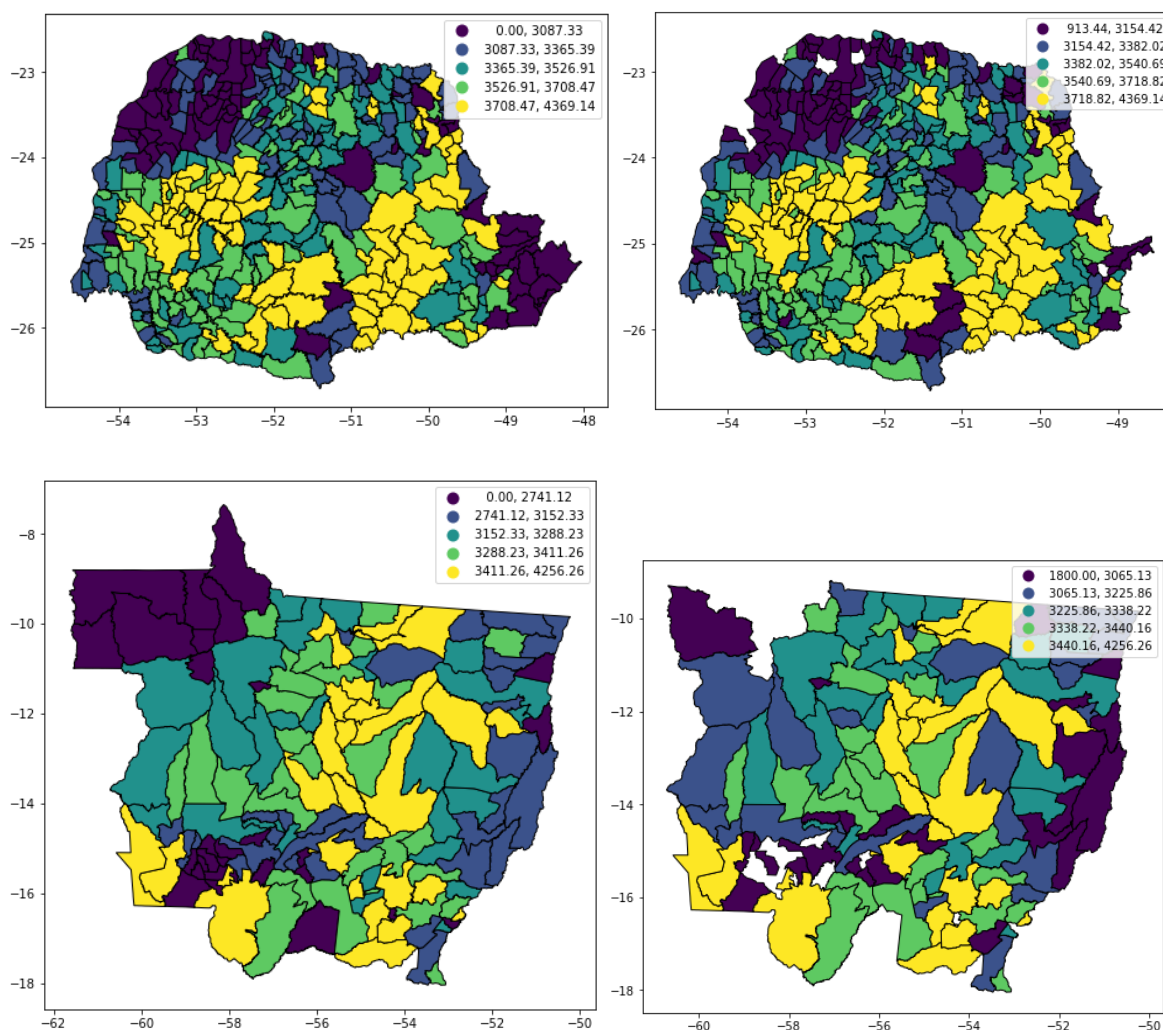
Figura 4 - Regionalização espacial dos municípios do Paraná e Mato Grosso.



Fonte: O autor.

Entretanto, como ambos os estados produzem soja em quase todos os municípios, visualmente é possível verificar que não há presença de “ilhas” que poderiam provocar erros na regionalização, mesmo após a eliminação dos municípios não produtores de soja. O resultado pode ser verificado na Figura 5.

Figura 5 - Distribuição espacial da produtividade nos municípios do Paraná e do Mato Grosso.



Fonte: IBGE (2017).

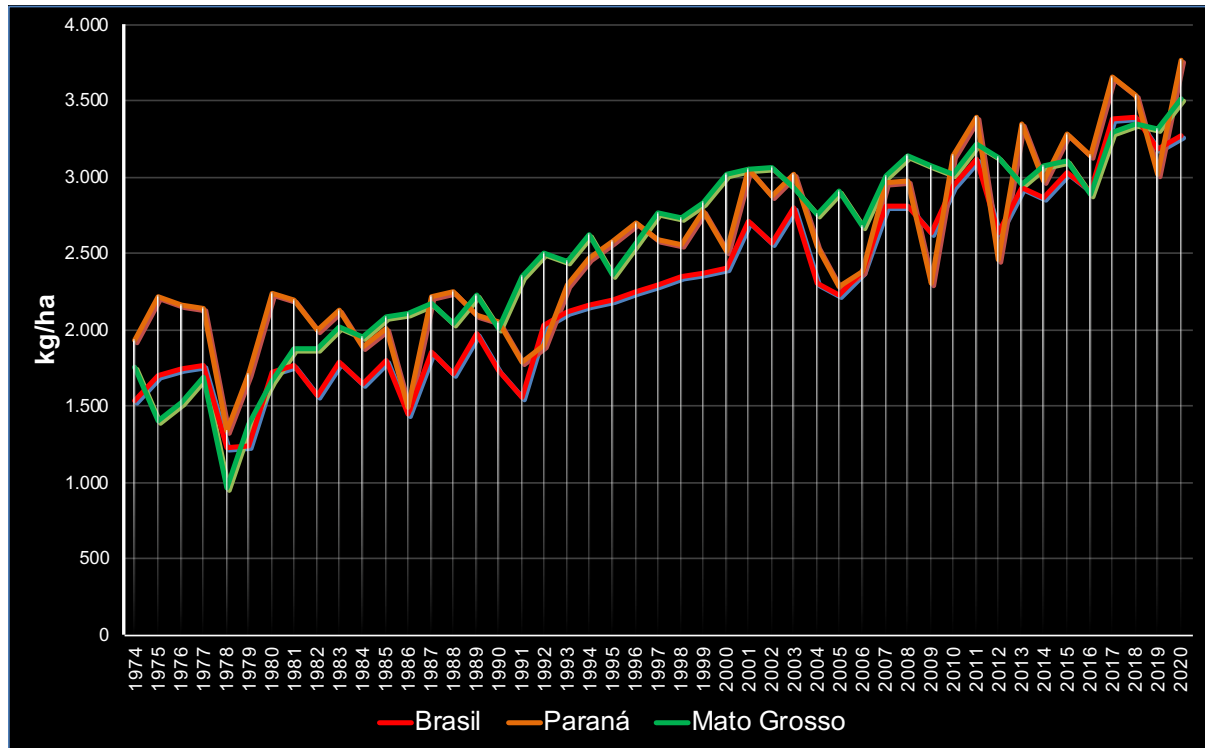
Nota: (a) mapa do Paraná e do Mato Grosso com todos os municípios e (b) mapa do Paraná e do Mato Grosso apenas com os municípios produtores de soja.

É possível verificar, analiticamente, a partir da espacialização da produtividade que há regiões contíguas com níveis de produtividade semelhantes, o que nos leva a concluir que a produtividade pode ser um bom indicador para regionalização desses estados em áreas homogêneas (Figura 5).

Para eliminar o problema encontrado, com resultados de regionalização não coerentes com o esperado, tendo em vista a produção de soja desses estados, optou-se por utilizar os dados do Pesquisa Agrícola Municipal do Instituto Brasileiro de Geografia e Estatística (IBGE, 2020). A pesquisa possui dados de 1974 a 2020 e, por

isso, permitiu analisar o padrão espacial da produtividade nos últimos 45 anos (Figura 6).

Figura 6 - Evolução da produtividade de soja do Paraná, Mato Grosso e Brasil.

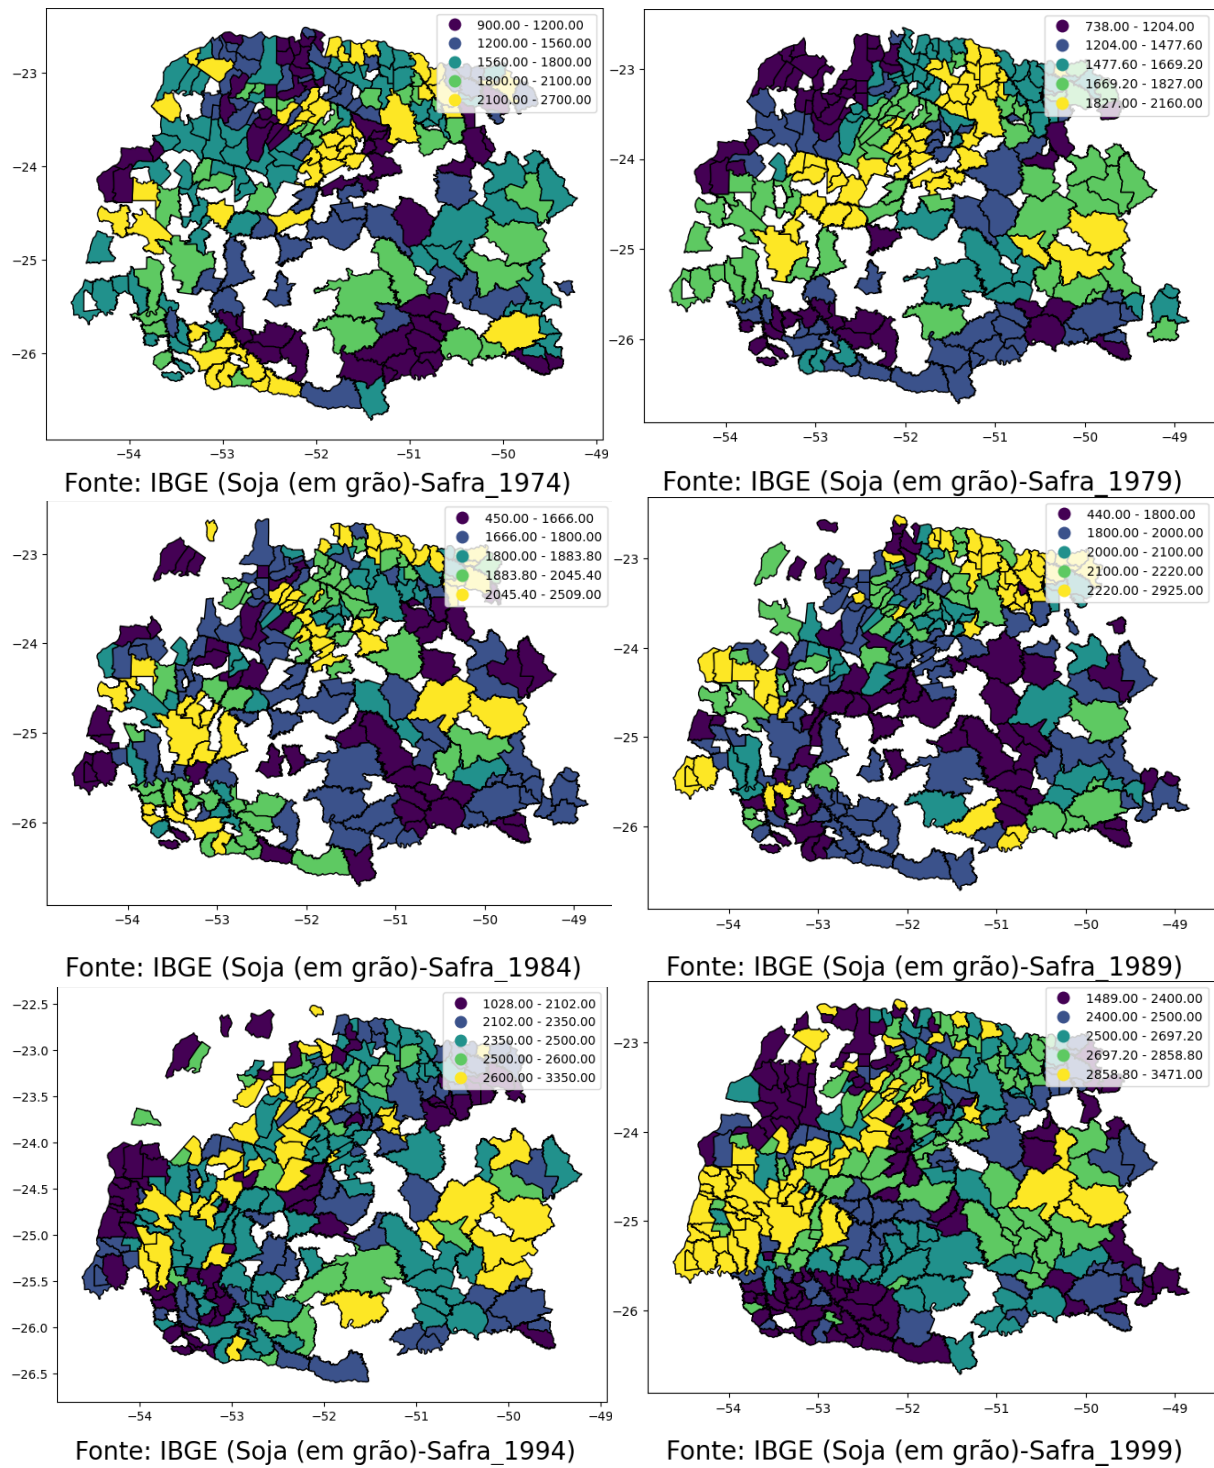


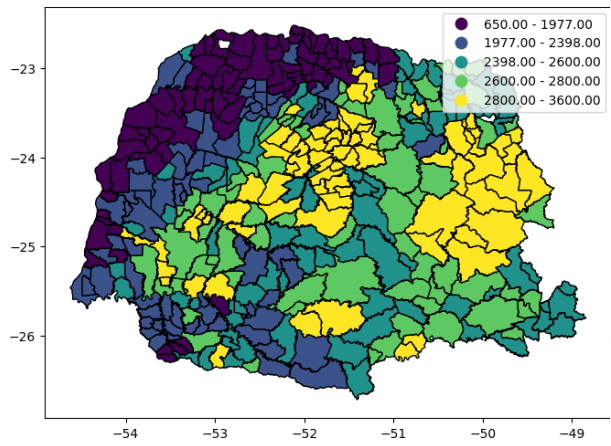
Fonte: IBGE (2020).

As culturas agrícolas dependem de recursos naturais (solo, clima) concentrados no espaço geográfico, o que reforça a ideia de que a produção ocorre na forma de agrupamentos (clusters), distribuídos pelo espaço econômico. Porém, esses agrupamentos podem mudar em razão do manejo (sementes, adubação, mecanização...) e isso é bem característico na produção de soja nesse estado.

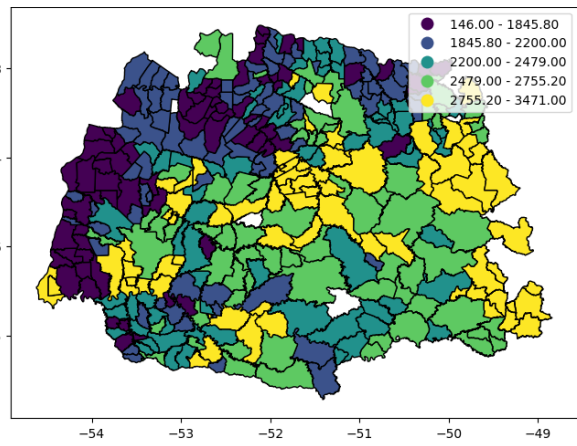
É possível identificar que algumas regiões se especializaram na produção da oleaginosa e isso resultou em elevados índices de produtividade, como podemos observar na distribuição espacial da produtividade de soja no Paraná e no Mato Grosso. Até meados de 2000, as maiores produtividades médias municipais eram distribuídas por todo o estado, com variação anual em razão das condições climáticas. Porém, algumas regiões se destacaram nos últimos anos com elevados níveis de produtividade. Com isso, optou-se por restringir a regionalização dos estados com os dados dos últimos 20 anos (2000-2019).

Figura 7 – Produtividade municipal de soja no Paraná (anos selecionados).

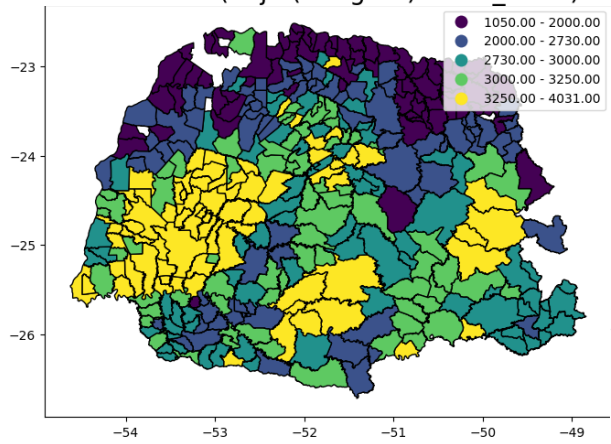




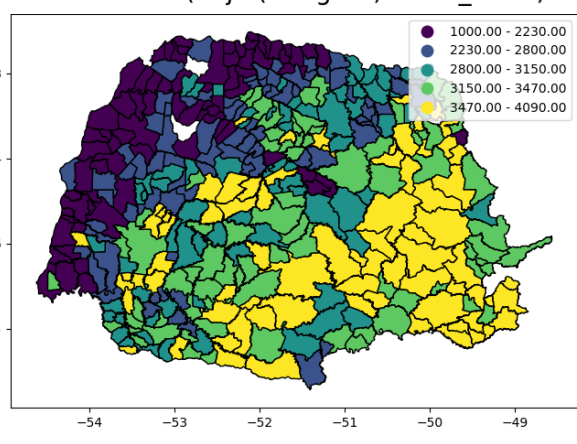
Fonte: IBGE (Soja (em grão)-Safras_2004)



Fonte: IBGE (Soja (em grão)-Safras_2009)




Fonte: IBGE (Soja (em grão)-Safras_2014)




Fonte: IBGE (Soja (em grão)-Safras_2019)

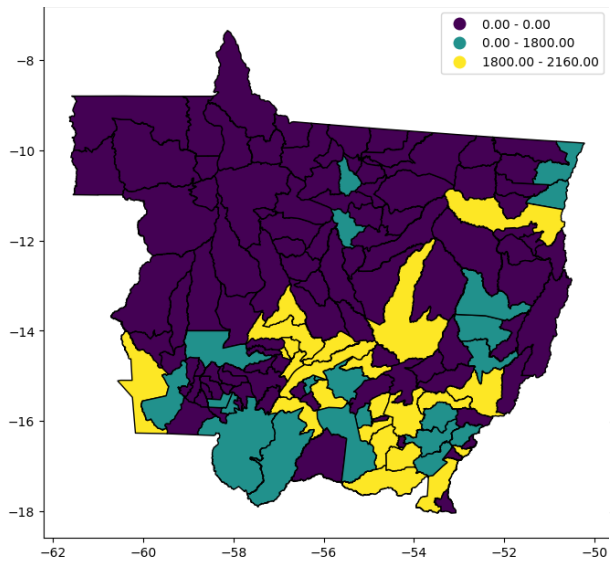
Figura 8 - Produtividade municipal de soja no Mato Grosso (anos selecionados).



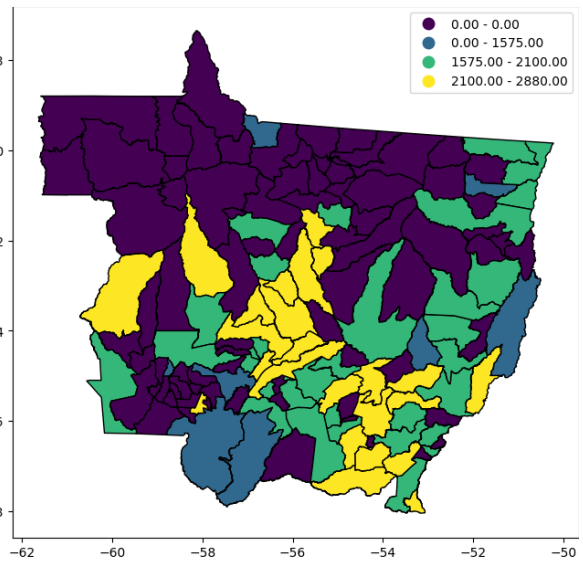
Fonte: IBGE (Soja (em grão)-Safras_1974)



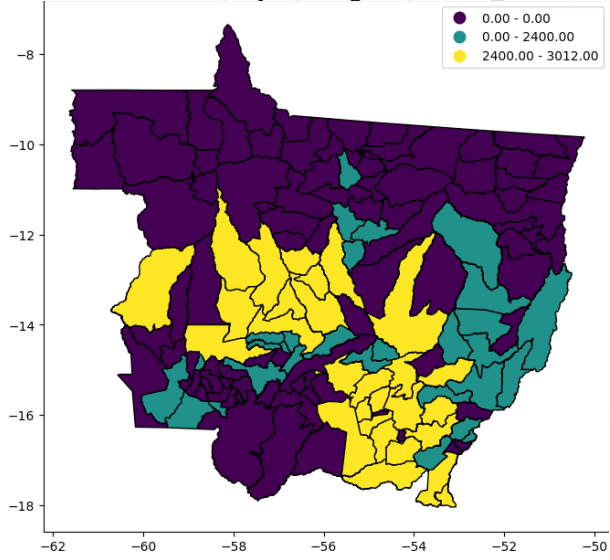
Fonte: IBGE (Soja (em grão)-Safras_1979)




Fonte: IBGE (Soja (em grão)-Safrá 1984)



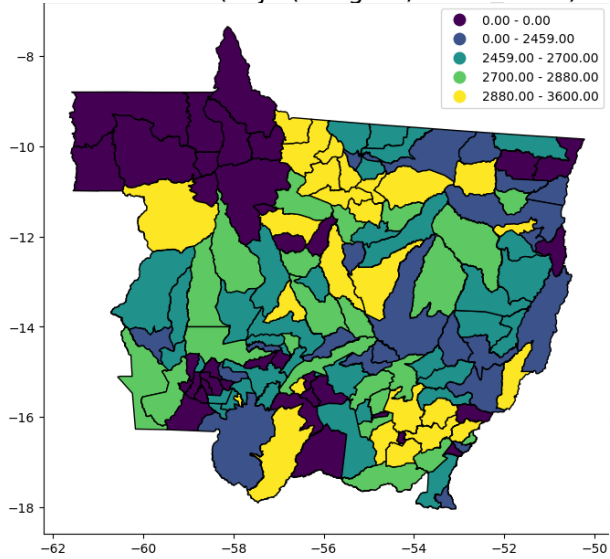
Fonte: IBGE (Soja (em grão)-Safrá 1989)



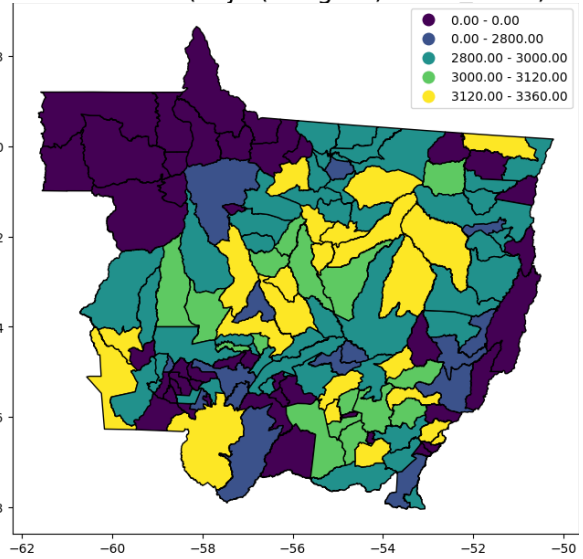
Fonte: IBGE (Soja (em grão)-Safrá 1994)



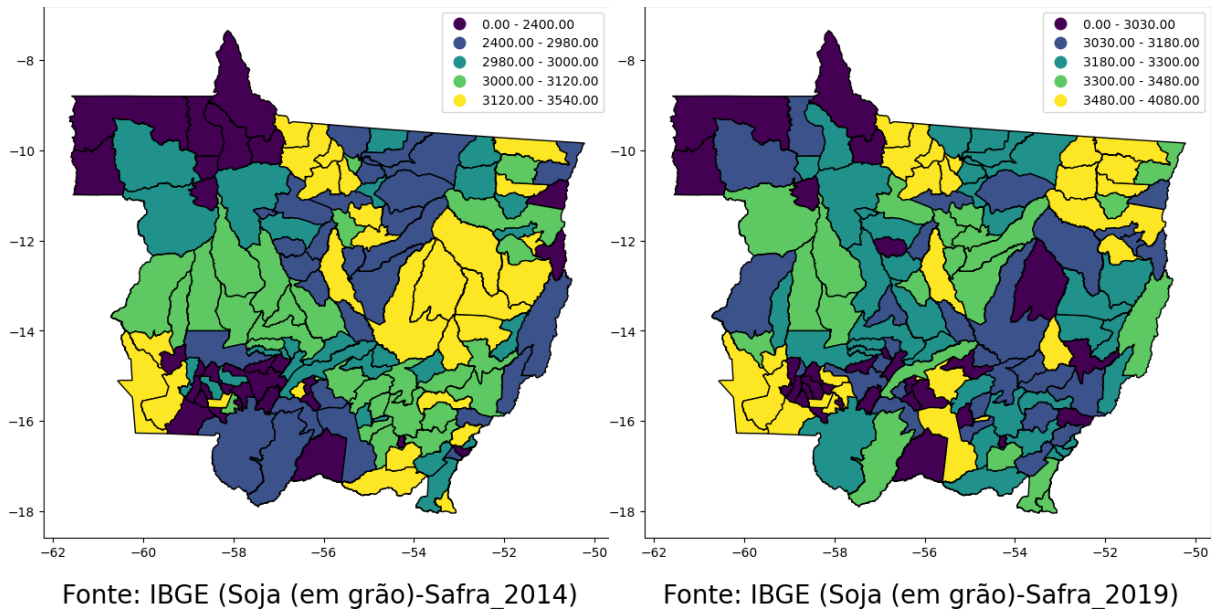
Fonte: IBGE (Soja (em grão)-Safrá 1999)



Fonte: IBGE (Soja (em grão)-Safrá_2004)

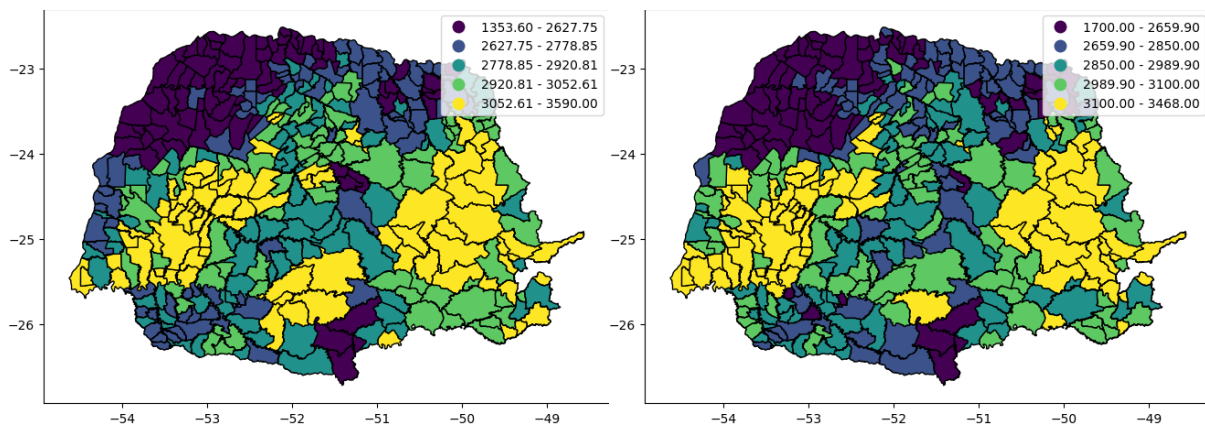


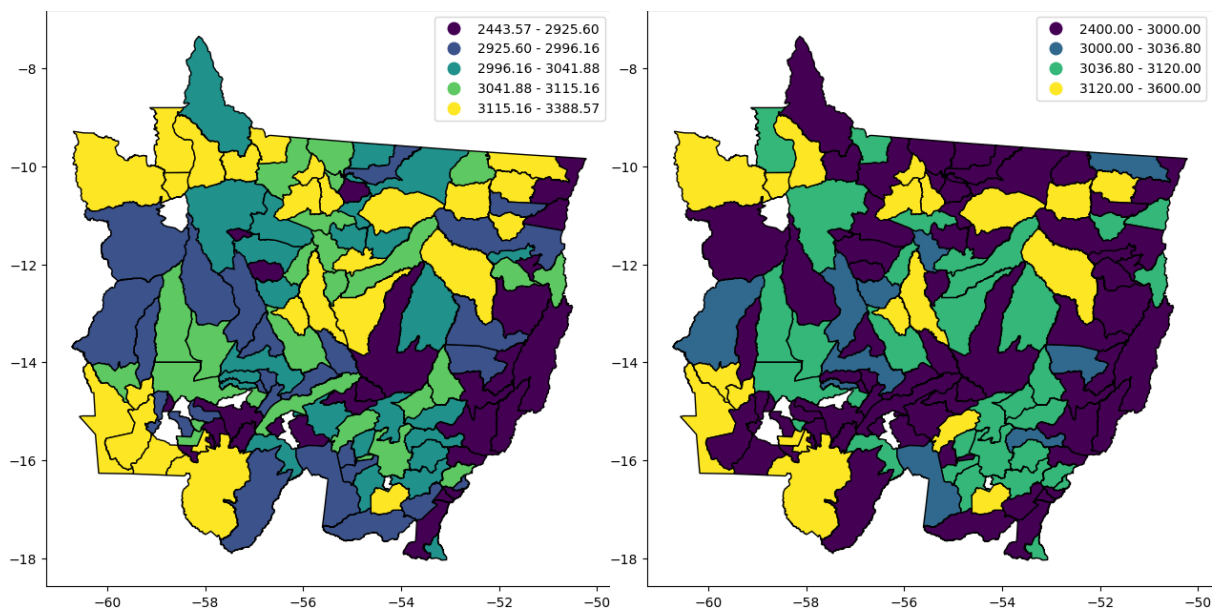
Fonte: IBGE (Soja (em grão)-Safrá_2009)



Além disso, optou-se por utilizar a mediana da produtividade do período escolhido, em detrimento ao uso da média, pelo fato da média sofrer grande influência da presença de *outliers*. Apesar de, como já visto, a produtividade das culturas agrícolas sofrer influência de vários fatores ao longo do tempo, as condições climáticas podem produzir fortes desvio nos padrões de produtividades e acarretar na maior presença de *outliers*.

Figura 9 - Média e mediana da produtividade nos municípios do Paraná e do Mato Grosso (2000-2019).

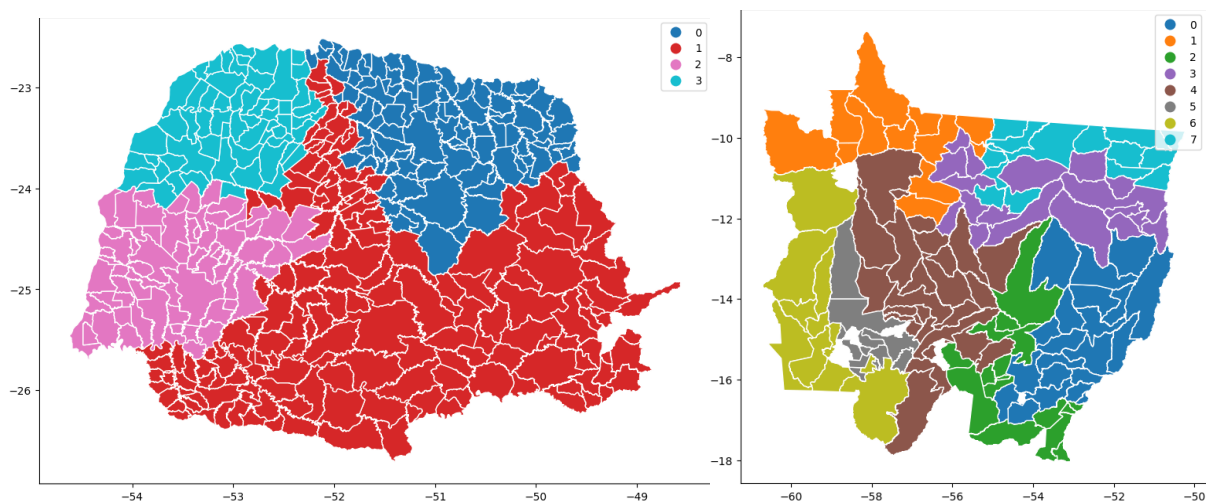




Fonte: Autor, com base nos dados do IBGE (2020).

O mapa do Paraná e o Mato Grosso foram transformados em uma representação baseado em grafos para que fosse possível a geração de uma AGM. Após a poda das arestas de menor custo, foram feitas várias simulações de forma que o melhor resultado encontrado foi a regionalização do Paraná em 4 regiões e o Mato Grosso em 8 regiões.

Figura 10 - Regionalização espacial dos municípios do Paraná e Mato Grosso.



Fonte: Autor.

A análise do agrupamento espacial gerado pelo algoritmo SKATER (Figura 10) mostra que alguns agrupamentos são influenciadas pela zona fronteiriça. A região 0 e 3 do Paraná fazem fronteira com os estados de São Paulo e Mato Grosso do Sul,

respectivamente, e possuem semelhanças com a produção desses estados, tanto em relação ao tipo de solo, quando em relação às condições climáticas. Na região limítrofe com o Paraguai (região 2), os aglomerados espaciais formaram um grupo muito característico, onde se concentra uma das regiões agrícolas com os solos mais férteis do Brasil. Já a região 1 tem a característica que não ter produção de soja tão expressiva e possui um clima diferente do restante do estado, sobretudo com maior frequências de temperaturas mais baixas, com presença de geadas.

No Mato Grosso, as regiões 1 e 7 possuem pouca produção de soja e presença de áreas recém convertidas de pastagens para produção de grãos. A região 4 condiz com a Chapada do Parecis, uma região extensa de planície agricultável. A região 6 expressa grande parte do Vale do Guaporé, uma região com altitudes menores em relação ao restante do estado e com produção de soja mais recente. Já a região 0 corresponde a parte do Vale do Araguaia, com sistema de produção e condições edafoclimáticas semelhantes à Goiás.

Assim, a regionalização pelo método SKATER possibilitou analisar a variabilidade existente (MENGUE et al., 2020) na produtividade nas diferentes regiões da área de estudo, agrupando em clusters espaciais, e assim, permitindo o entendimento da dinâmica dos processos de produção de soja.

4 Conclusões

A aplicação do algoritmo Skater nas áreas de produção de soja, com base na produtividade, permitiu regionalizar as áreas de estudo em regiões contíguas.

A partir da técnica de regionalização foi possível avaliar a distribuição de região homogêneas nos dois estados (Paraná e Mato Grosso) e estimar a melhor quantidade de regiões contíguas.

A utilização dos dados de apenas um ano agrícola (Censo 2017) induz a regionalizações diferentes do esperado.

Como recomendações para trabalhos futuros, outras variáveis explicativas devem ser consideradas, visando uma melhoria na representação gerada pelo modelo.

Referências

ANDERBERG, M. R. **Clustering analysis for application**. London: Academic Press, 1973. 359p.

ASSUNÇÃO, R. M.; LAGE, J. P.; REIS, E. A. Análise de conglomerados espaciais via Árvore Geradora Mínima. **Revista Brasileira de Estatística**, Rio de Janeiro, v. 63, n. 220, p. 7-24, 2002.

ASSUNÇÃO, R. M.; NEVES, M. C.; CÂMARA, G.; FREITAS, C. C. Efficient regionalisation techniques for socio-economic geographical units using minimum spanning trees. **International Journal of Geographical Information Science**, v. 20, n.7, p. 797-811, 2006.

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **Boletim de acompanhamento da safra brasileira de grãos**, v. 8, n. 1, outubro de 2020. Disponível em: < <https://www.conab.gov.br/info-agro/safras/graos>>. Acesso em: 29 set. 2021.

HENRIQUES, R.; BAÇÃO, F.; LOBO, V. Exploratory geospatial data analysis using the GeoSOM suite. Computers, **Environment and Urban Systems**, v. 36, n. 2, p. 218-232, 2012.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Censo Agro 2017**. Sistema IBGE de Recuperação Automática (SIDRA), 2017. Disponível em: <https://sidra.ibge.gov.br/pesquisa/censo-agropecuario/censo-agropecuario-2017>. Acesso em 20 Set. 2021.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Pesquisa Agrícola Municipal**. Sistema IBGE de Recuperação Automática (SIDRA), 2020. Disponível em: <https://sidra.ibge.gov.br/pesquisa/pam>. Acesso em 16 Out. 2021.

JUNGNICKEL, D. **Graphs, Networks and Algorithms**. Berlin: Springer, 1999.

MARTIN, D., 1998, Optimizing census geography: the separation of collection and output geographies. **International Journal of Geographical Information Science**, 12, pp. 673–685.

MENGUE, V. P.; FREITAS, M. W. D.; SILVA, T. S.; FONTANA, D. C.; SCOTTÁ, F. C. LAND-USE and land-cover change processes in Pampa biome and relation with environmental and socioeconomic data, **Applied Geography**, v. 125, 2020.

SILVA, M. A. S.; DOMPIERI, M. H. G.; SANTOS, A. V.; ALMEIDA, M. R. M.; MEDEIROS, S. S. **Regionalização da área de atuação da Embrapa Tabuleiros Costeiros a partir do algoritmo SKATER**. Aracaju: Embrapa Tabuleiros Costeiros, 2015.