

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
CAMPUS MONTE CARMELO
INSTITUTO DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA
E INFORMAÇÕES GEOESPACIAIS - PPGAIG

LAURA CRISTINA MOURA XAVIER

**GEOTRAT POINTS: RECURSO LIVRE DE CÓDIGO ABERTO NO
SOFTWARE QGIS PARA MAPEAMENTO DO DESEMPENHO DE
EXPERIMENTOS AGRÍCOLAS**

Monte Carmelo-MG

2024

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
CAMPUS MONTE CARMELO
INSTITUTO DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA
E INFORMAÇÕES GEOESPACIAIS - PPGAIG

LAURA CRISTINA MOURA XAVIER

**GEOTRAT POINTS: RECURSO LIVRE DE CÓDIGO ABERTO NO
SOFTWARE QGIS PARA MAPEAMENTO DO DESEMPENHO DE
EXPERIMENTOS AGRÍCOLAS**

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais - PPGAIG da Universidade Federal de Uberlândia-UFU, campus Monte Carmelo, como requisito para a obtenção do título de Mestre, sob orientação do Prof. Dr. George Deroco Martins.

Monte Carmelo-MG

2024

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

X3 2024	<p>Xavier, Laura Cristina Moura, 1998- GEOTrat Points: recurso livre de código aberto no software QGIS para mapeamento do desempenho de experimentos agrícolas [recurso eletrônico] / Laura Cristina Moura Xavier. - 2024.</p> <p>Orientador: George Deroco Martins. Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Agricultura e Informações Geoespaciais. Modo de acesso: Internet. Disponível em: http://doi.org/10.14393/ufu.di.2024.143 Inclui bibliografia. Inclui ilustrações.</p> <p>1. Agronomia. I. Martins, George Deroco,1987-, (Orient.). II. Universidade Federal de Uberlândia. Pós-graduação em Agricultura e Informações Geoespaciais. III. Título.</p> <p style="text-align: right;">CDU: 631</p>
------------	--

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Agricultura e Informações
 Geoespaciais
 Rodovia LMG 746, Km 01, s/nº, Bloco 1AMC, Sala 1A202, Monte Carmelo-MG, CEP 38.500-000
 Telefone: (34) 3810-1033 - ppgaig@iciag.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agricultura e Informações Geoespaciais				
Defesa de:	Dissertação de Mestrado Acadêmico				
Data:	22/02/2024	Hora de início:	09:00	Hora de encerramento:	11:30
Matrícula do Discente:	32212AIG006				
Nome do Discente:	Laura Cristina Moura Xavier				
Título do Trabalho:	GEOTrat Points: recurso livre no software QGIS para mapeamento do desempenho de experimentos agrícolas				
Área de concentração:	Informações geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Aplicações e desenvolvimento de métodos em informações geoespaciais				

Reuniu-se na sala virtual conferenciaweb.rnp.br/sala/george-deroco-martins a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Dr. Murillo Guimarães Carneiro (UFU), Dr. Érico Fernando de Oliveira Martins (Universidade Estadual do Mato Grosso), Dr. George Deroco Martins (UFU) – orientador do candidato.

Iniciando os trabalhos o presidente da mesa, Dr. George Deroco Martins, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovada

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **George Deroco Martins, Professor(a) do Magistério Superior**, em 22/02/2024, às 13:52, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Murillo Guimarães Carneiro, Professor(a) do Magistério Superior**, em 22/02/2024, às 22:33, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Érico Fernando de Oliveira Martins, Usuário Externo**, em 23/02/2024, às 12:00, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5186133** e o código CRC **D12D2088**.

Dedico à minha amada e incentivadora mãe, Lindalva.

|

AGRADECIMENTOS

Agradeço à minha mãe, por sempre me incentivar em todas as batalhas da vida.

Agradeço aos colegas de turma do mestrado, Mariana, Fernando e Heitor, que se tornaram amigos especiais.

Agradeço aos amigos que persistem comigo na vida, Arthur, Cristiane, Mikaella e Joel.

Agradeço aos amigos que são uma família para mim, Milena e Gabriel.

Agradeço ao meu orientador Geoge Deroco Martins, que há anos tem cumprido perfeitamente seu papel em me nortear.

Agradeço a Lallemand Plant Care pelo financiamento do projeto de pesquisa.

Agradeço ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais - PPGAIG e a Universidade Federal de Uberlândia – UFU.

BIOGRAFIA

Laura Cristina Moura Xavier, filha de Lindalva Lopes de Moura e João Batista Xavier, nascida em 30 de maio de 1998, na cidade de Coromandel, Minas Gerais. Desde 2021, é Engenheira Agrimensora e Cartógrafa formada pela Universidade Federal de Uberlândia – UFU, campus Monte Carmelo. Durante a graduação, desenvolveu projetos de iniciação científica utilizando dados geoespaciais para mapeamento na agricultura. Desde o ano de 2021, atua como assistente técnica para empresa Topocart Topografia, Engenharia e Aerolevantamentos, sediada em Brasília-DF e, em 2022, ingressou no Programa de Pós-Graduação em Agricultura e Informações Geoespaciais – PPGAIG - UFU. No programa de mestrado, possuiu bolsa de pesquisa financiada pelo projeto da empresa Lallemand Plant Care.

SUMÁRIO

1	INTRODUÇÃO	1
2	DESENVOLVIMENTO DA SOLUÇÃO COMPUTACIONAL	3
2.1	Proposta, disponibilização e interface	3
2.2	Entradas	6
2.3	Algoritmos	8
2.4	Saídas	12
3	AVALIAÇÃO DE DESEMPENHO E DISCUSSÕES	13
3.1	Dados	14
3.2	Parâmetros	19
3.3	Resultados e Discussões	19
3.3	Limitações e desenvolvimentos futuros	23
4	CONCLUSÕES	25
	REFERÊNCIAS	26

RESUMO

A experimentação agrícola requer a seleção criteriosa do desenho experimental e do modelo de análise dos dados dos tratamentos. No entanto, mesmo com um rigoroso controle experimental, pode ocorrer que as discrepâncias entre os tratamentos sejam tão sutis que os modelos estatísticos tradicionais falhem em destacar diferenças estatisticamente significativas, mas que ocorrem na prática de campo. A incorporação de geotecnologias oferece a capacidade de mapear a variabilidade agrícola, mas, ainda assim, subsiste uma lacuna na disponibilidade de ferramentas destinadas a mapear e avaliar a eficácia de experimentos agrícolas. Com o propósito de superar essa limitação e promover a aplicação mais abrangente dos Sistemas de Informação Geográfica (SIGs) na agricultura, o escopo deste estudo se concentra no desenvolvimento de um recurso no software QGIS, destinado à avaliação de experimentos agrícolas empregando delineamento por blocos casualizados com até cinco tratamentos. O recurso desenvolvido incorpora técnicas de interpolação espacial por meio de krigagem geoestatística, geração de mapas e estatística. O estudo empregou amostra de produtividade de seis culturas distintas para identificar diferenças quantitativas e espaciais entre experimentos de dois tratamentos em termos de ganho de rendimento. Os resultados consistiram em duas superfícies que representam a área de estudo tratada com cada um dos tratamentos (T1 e T2), bem como uma superfície que reflete o ganho de rendimento do tratamento de referência em relação ao de controle, acompanhada de medidas de estatística descritiva relevantes sobre essa superfície de ganho. As representações cartográficas simuladas dos tratamentos, assim como os mapas ilustrando o ganho de rendimento, revelaram distinções tanto em termos numéricos quanto espaciais entre os tratamentos, com uma acurácia de até 95,40%. A ferramenta, denominada GEOTrat – Points, oferece flexibilidade para avaliar experimentos agrícolas de variados delineamentos, englobando diversas culturas e diferentes quantidades de amostras, proporcionando uma análise tanto numérica quanto espacial. Essa ferramenta apresenta-se como um recurso relevante para a experimentação agrícola, auxiliando na seleção de práticas de manejo apropriadas e na identificação de tratamentos mais eficazes.

Palavras-chave: experimentação agrícola; mapeamento; Sistemas de Informação Geográfica – SIGs; rendimento; tratamentos.

ABSTRACT

Agricultural experimentation requires careful selection of the experimental design and model for analyzing treatment data. However, even with rigorous experimental control, the discrepancies between treatments are so subtle that traditional statistical models fail to highlight statistically significant differences that occur in field practice. The incorporation of geotechnologies offers the ability to map agricultural variability, but a gap still exists in the availability of tools designed to map and evaluate the effectiveness of agricultural experiments. To overcome this limitation and promote the wider application of Geographic Information Systems (GIS) in agriculture, the scope of this study focuses on the development of a resource in QGIS software, aimed at evaluating agricultural experiments using a randomized block design with up to five treatments. The resource developed incorporates spatial interpolation techniques using geostatistical kriging, map generation, and statistics. The study used yield samples from six different crops to identify quantitative and spatial differences between two-treatment experiments in terms of yield gain. The results consisted of two surfaces representing the study area treated with each of the treatments (T1 and T2), as well as a surface reflecting the yield gain of the reference treatment in relation to the control treatment, accompanied by relevant descriptive statistics measures on this gain surface. The simulated cartographic representations of the treatments, as well as the maps illustrating the yield gain, revealed both numerical and spatial distinctions between the treatments, with an accuracy of up to 95.40%. The tool, called GEOTrat - Points, offers the flexibility to evaluate agricultural experiments of various designs, encompassing different crops and different quantities of samples, providing both numerical and spatial analysis. This tool is a relevant resource for agricultural experimentation, helping to select appropriate management practices and identify the most effective treatments.

Keywords: agricultural experimentation; Geographic Information Systems – GIS; mapping; treatments; yield.

INTRODUÇÃO

A experimentação agrícola é fundamental para o desenvolvimento e melhoria da produção. Ela envolve a aplicação de métodos científicos para testar e avaliar diferentes técnicas, práticas e materiais utilizados na produção de alimentos e produtos agrícolas. Os experimentos realizados na agricultura podem ser conduzidos em diferentes dimensões, desde laboratório até grandes experimentos em campo. Além disso, eles podem incluir testes de diferentes culturas, fertilizantes, técnicas de irrigação, sistemas de cultivo e demais fatores que afetam a produção agrícola (FAO Não const, 2016).

Um dos aspectos mais importantes na condução de experimentos de pesquisa agrícola é a escolha adequada do desenho experimental e do modelo de análise desses dados. Isso assegura a randomização, replicação e controle dos tratamentos (Fisher, 1960), garantindo independência entre unidades experimentais e o aumento da precisão das estimativas (Casler, 2015). Porém, mesmo com este controle experimental, pode ocorrer que as diferenças entre os tratamentos sejam tão sutis que os modelos estatísticos clássicos são incapazes de evidenciar diferenças significativas na(s) variável(is) de estudo (Borges et al., 2019; Thai et al., 2020). Isso se deve ao fato de que esses modelos não levam em consideração a variação espacial de fatores ambientais e de solo, nem a dependência espacial dentro de uma determinada parcela.

A aplicação de tecnologias de posicionamento por satélite no âmbito da experimentação agrícola permite a coleta de informações georreferenciadas, fazendo com que os agricultores conduzam os experimentos de forma mais precisa. As geotecnologias englobam o uso de tecnologias como, por exemplo, sensoriamento remoto por satélite e aeronaves, Sistemas de Informação Geográfica - SIGs e os sistemas de posicionamento global (Karunathilake et al. (2023). A partir dessas informações geoespaciais, torna-se possível mapear a variabilidade espacial de elementos como o solo, a água, os nutrientes e a incidência de pragas e doenças. Além disso, possibilita o monitoramento do crescimento das culturas, contribuindo para a redução de custos, otimização do uso dos recursos e a minimização dos impactos ambientais (Massruhá et al., 2023).

Tecnologias como os SIGs têm um papel importante na agricultura moderna, permitindo que os agricultores coletem, gerenciem e analisem dados geoespaciais relacionados à produção agrícola. O QGIS, software livre com código-fonte aberto, pertencente à organização OSGEO (<https://www.osgeo.org/>), que é uma plataforma de SIG que possibilita o

desenvolvimento de ferramentas a fim de ampliar suas funcionalidades, além de permitir a busca e instalação de recursos e plugins desenvolvidos por terceiros (Jeppesen et al., 2018). No entanto, a falta de ferramentas abrangentes para mapear e avaliar a eficácia de experimentos agrícolas, especialmente aquelas que integram análises espaciais, geoprocessamento e visualização, ainda é uma limitação (Liu et al., 2021).

No cenário atual de softwares para agricultura de precisão, existem soluções com diversas aplicações como *FarmWorks by Trimble*, *AgLeader SMS*, *FarmLogs*, *Agrian* e *Climate FieldView*, que, mesmo não sendo específicos para este fim, podem ser utilizados para análise de experimentos agrícolas. Dentro do próprio ambiente QGIS, embora existam plugins dedicados à agricultura de precisão, como o Precision Agriculture Tools – PAT, GeoDataFarm, Smart Map entre outros (consultar QGIS Python Plugins Repository: plugins tagged with: agriculture https://plugins.qgis.org/plugins/tags/agriculture/?per_page=100), essas opções carecem de uma integração completa de técnicas avançadas para avaliação de experimentos agrícolas.

Para superar essa limitação e promover a aplicação mais ampla dos SIGs na agricultura, o objetivo deste trabalho foi desenvolver uma solução computacional apoiada no software QGIS, destinada à avaliação de experimentos agrícolas com delineamento do tipo blocos casualizados de até cinco tratamentos. Tal solução emprega técnicas de interpolação espacial para modelar variáveis agrícolas de interesse do usuário, análises estatísticas e a geração de mapas, permitindo uma comparação quantitativa e espacial dos tratamentos utilizados. Nesta pesquisa, utilizamos dados de produtividade para investigar se a integração dessas tecnologias e métodos pode oferecer uma solução eficaz para complementar a avaliação de experimentos agrícolas, facilitando a identificação de diferenças significativas entre tratamentos no ganho de rendimento.

DESENVOLVIMENTO DA SOLUÇÃO COMPUTACIONAL

2.1 Proposta, disponibilização e interface

A ferramenta desenvolvida neste estudo foi intitulada como “GEOTrat – Points” e sua versão encontra-se disponível no repositório GitHub, acessível online através do link <https://github.com/LauraMouraXavier/geotrat> (acesso realizado em fevereiro de 2024). No repositório estão disponíveis os arquivos GEOTrat_Points com as extensões .model e .py, compatíveis com a versão 3.22.8 do QGIS Desktop. Para utilização do recurso desenvolvido, é necessário importar um destes arquivos na caixa de ferramentas de processamento do software QGIS, além da instalação dos complementos SAGA e SAGA Next Gen.

A proposta da ferramenta GEOTrat – Points consiste em viabilizar a avaliação quantitativa e espacial da eficácia de um tratamento em relação a outros, por meio da utilização de mapas gerados através de interpolação geostatística. O experimento agrícola a ser conduzido em campo deve ser estruturado em um delineamento do tipo blocos casualizados, com o mínimo de dois e com o limite de até cinco tratamentos distintos, denominados de T1, T2, T3, T4 e T5. O usuário, por sua vez, deve realizar a coleta de amostras georreferenciadas da variável agrícola de interesse, com o intuito de efetuar uma análise comparativa. A Figura 1 ilustra exemplos de design de experimentos de campo adequados para aplicação do recurso desenvolvido neste estudo.

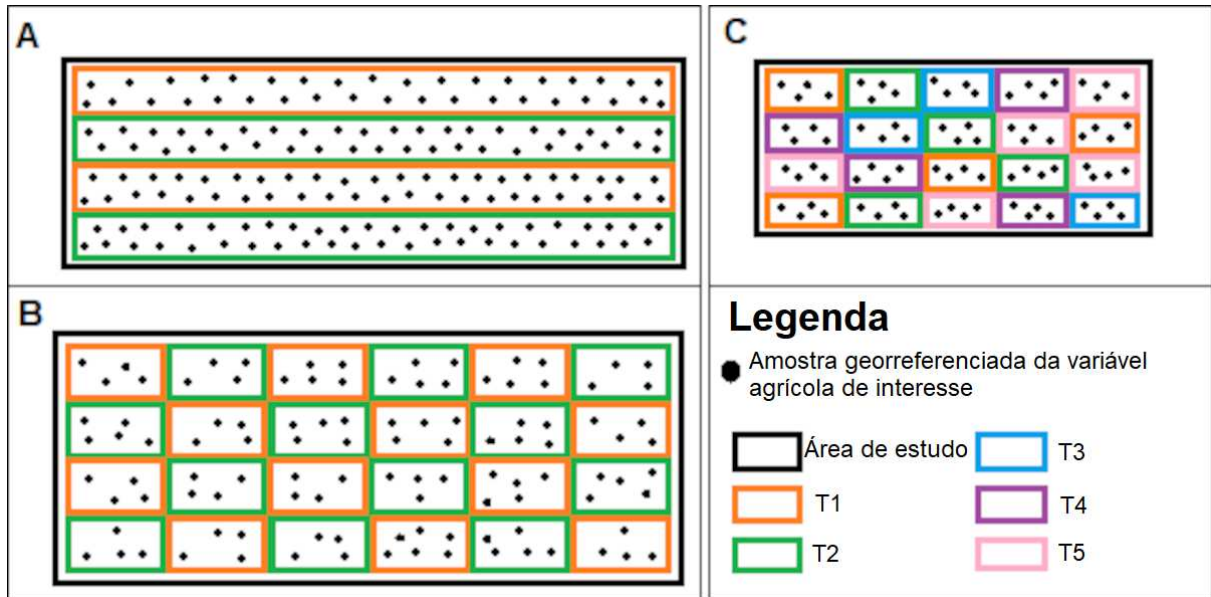


FIGURA 1 – Exemplos de design de experimentos de campo adequados para aplicação da ferramenta desenvolvida, (A) exemplo de design com blocos de parcelas contínuas de dois tratamentos, (B) exemplo de design de blocos intercalados de dois tratamentos, e (C) exemplo de design de blocos intercalados de cinco tratamentos.

Em complemento às características do experimento agrícola, além dos exemplos de designs apresentados na Figura 1, acrescenta-se que tanto a área de estudo quanto os blocos de tratamentos não estão restritos a dimensões específicas, podendo assumir qualquer configuração. Adicionalmente, o número de amostras é determinado pelo usuário e sugere-se seguir as normas definidas por manuais de experimentação agrícola. Informações mais detalhadas sobre os princípios do planejamento experimental, projeto e análise de dados em contextos agrícolas podem ser encontradas em Petersen (1994) e Quinn e Keough (2002). Recomenda-se também que as amostras abranjam integralmente a área de estudo, distribuídas de forma homogênea em quantidade equivalente entre os dois tratamentos.

A interface de execução de GEOTrat - Points segue o padrão das ferramentas desenvolvidas no QGIS e está apresentada na Figura 2.

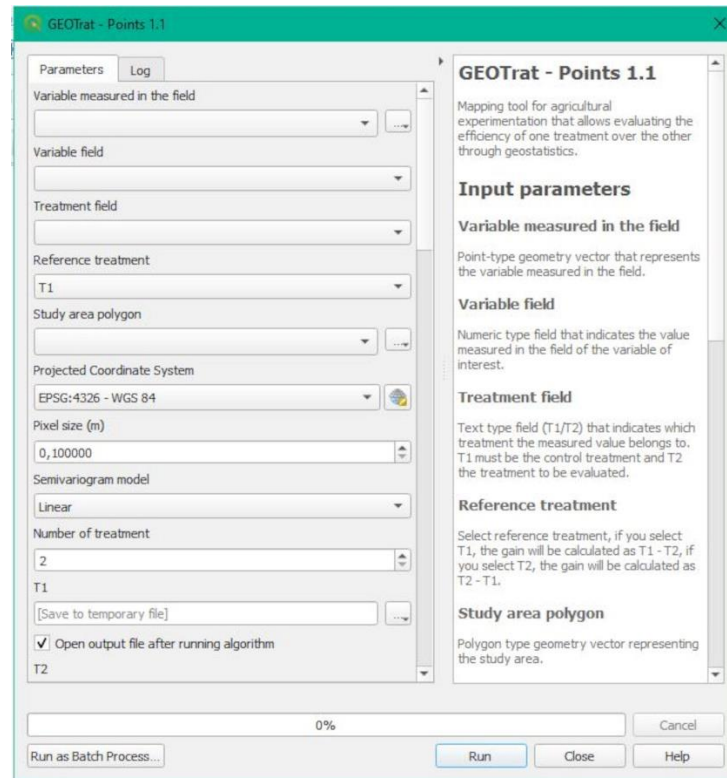


FIGURA 2 – Interface do recurso GEOTrat – Points

Os campos apresentados na interface da ferramenta destinam-se à inserção das entradas e à especificação dos caminhos para armazenamento dos resultados. As entradas consistem em informações fornecidas pelo usuário, abrangendo dados relacionados ao experimento conduzido em campo, bem como parâmetros necessários à realização da interpolação geoestatística. No canto direito da interface da ferramenta está localizada uma caixa de texto de auxílio com informações detalhadas sobre cada parâmetro de entrada e saída da ferramenta, além de oferecer detalhes acerca dos desenvolvedores e das versões disponíveis. A ferramenta também dispõe de botões destinados ao início da execução, ao fechamento da interface, ao acesso à função de ajuda e à execução de um conjunto de processos em lote.

O diagrama do fluxo lógico é apresentado na Figura 4. Ele é formado pelas interconexões e dependências entre as entradas, algoritmos utilizados e saídas. Os tópicos seguintes apresentam de forma detalhada as especificações das entradas, dos algoritmos e das saídas geradas pela ferramenta.

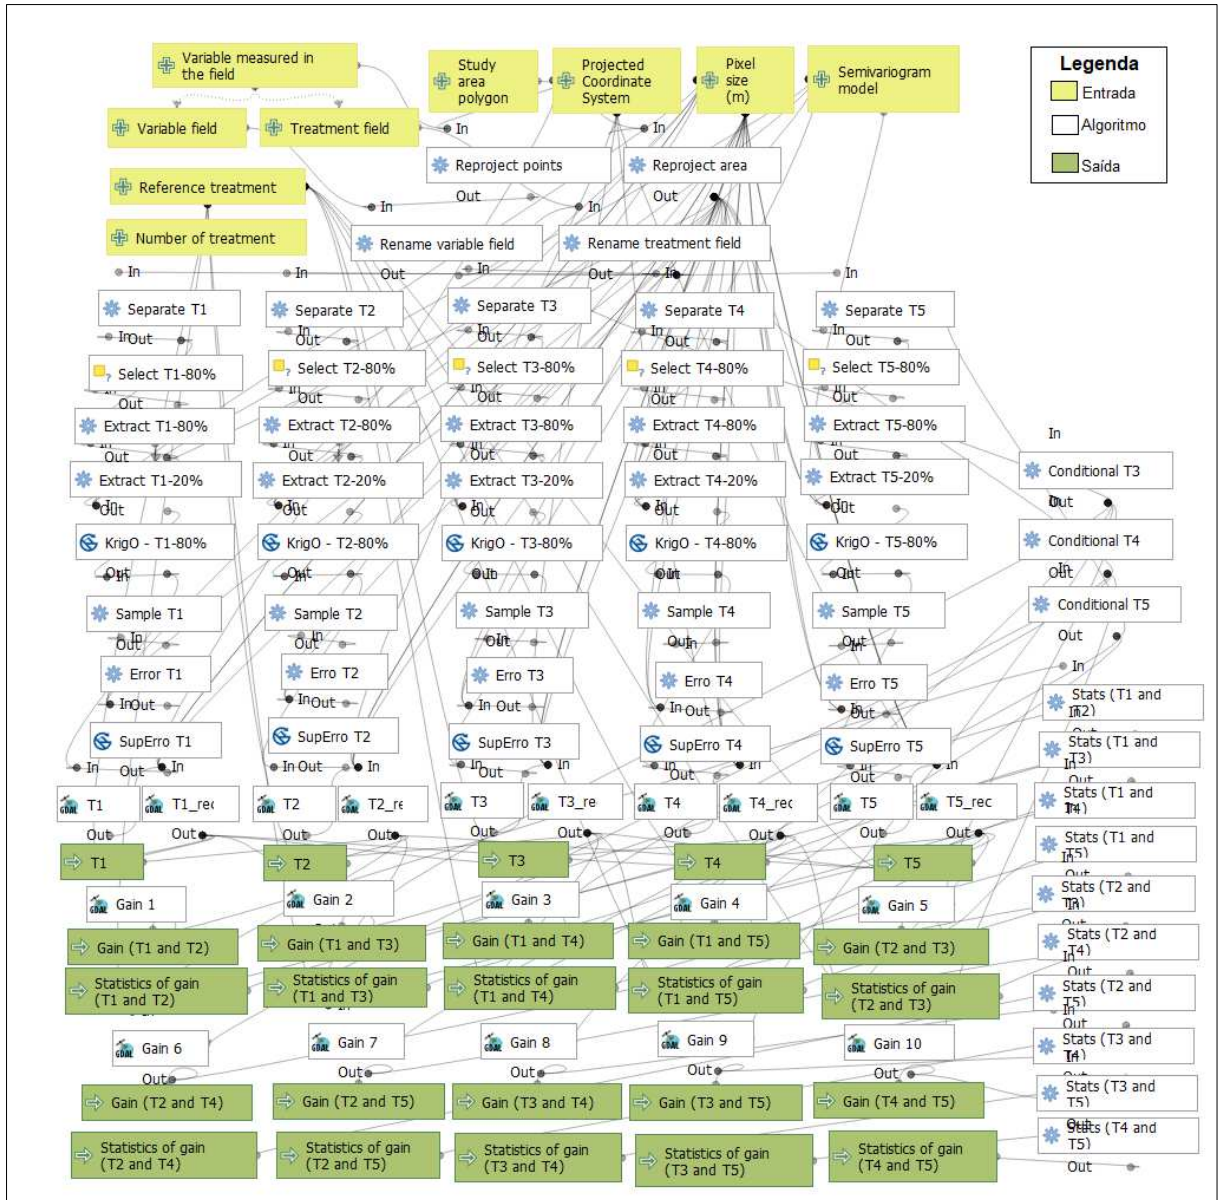


FIGURA 3 – Modelo de design da ferramenta GEOTrat – Points

2.2 Entradas

As entradas da ferramenta devem ser fornecidas pelo usuário e consistem em camadas vetoriais, campos de camadas vetoriais, sistema de referência de coordenadas, valores numéricos e listas enumeradas de opções. As especificações das entradas e seus formatos são apresentados na Tabela 1.

TABELA 1 – Especificações das entradas e seus formatos

Nome da entrada	Formato
<i>Variable measured in the field</i>	Camada vetorial – geometria do tipo ponto
<i>Variable field</i>	Campo do vetor – tipo numérico
<i>Treatment field</i>	Campo do vetor – tipo alfanumérico
<i>Reference treatment</i>	Lista enumerada (T1, T2, T3, T4, T5)
<i>Study area polygon</i>	Camada vetorial – geometria do tipo polígono
<i>Projected Coordinate System</i>	Sistema de Referência de Coordenadas
<i>Pixel size (m)</i>	Numérico
<i>Semivariogram model</i>	Lista enumerada (Linear, Exponencial, Gaussiano e Esférico)
<i>Number of treatments</i>	Numérico

Para utilização da ferramenta, a primeira informação a ser inserida pelo usuário é a *variable measured in the field*, a qual deve ser uma camada vetorial de geometria do tipo ponto no formato de arquivo shapefile. Essa camada vetorial deve conter os pontos georreferenciados das amostras obtidas no experimento de campo. A tabela de atributos do arquivo deve conter dois campos obrigatórios: um do tipo numérico, com os valores da variável agrícola medida em campo, a ser definido na entrada *Variable field*; e outro do tipo textual, identificando o tratamento aplicado (exemplo T1, T2, T3, T4, T5) a ser definido na entrada *Treatment field*.

Na entrada *Reference treatment*, que é uma lista enumerada com as opções T1 (padrão), T2, T3, T4 e T5, o usuário deve indicar qual o tratamento será considerado referência para a comparação com os demais tratamentos. Além disso, na entrada *Number of treatments* o usuário deve indicar qual a quantidade de tratamentos utilizados. Nesta opção, o valor mínimo é igual a dois (padrão) e o máximo é igual a cinco.

Além da camada vetorial de pontos, o usuário deve possuir uma camada vetorial de geometria do tipo polígono no formato de arquivo shapefile, que representará a delimitação da área de estudo do experimento de campo. Essa camada vetorial deve ser inserida na entrada *Study area polygon*.

A comparação entre os tratamentos realizada pela ferramenta utiliza a técnica de interpolação espacial por meio da geoestatística, especificamente pelo método da Krigagem (mais detalhes no tópico 2.3). Este método é empregado na geração de superfícies, através da estimativa de superfícies matriciais. Portanto, o usuário deve fornecer informações adicionais, tais como a resolução espacial em metros das superfícies geradas, que deve ser especificada na entrada *Pixel size (m)*. Recomenda-se que o tamanho do pixel escolhido seja compatível com a distância média de coleta das amostras em campo. Ademais, na entrada *Semivariogram model*, o usuário deve inserir o modelo matemático do semivariograma a ser utilizado na interpolação

por krigagem. A lista enumerada disponibiliza as opções: Linear (padrão), Gaussiano, Exponencial e Esférico. Depois de definidas as entradas, o usuário poderá executar a ferramenta.

2.3 Algoritmos

Os algoritmos utilizados para o desenvolvimento da ferramenta pertencem ao pacote de geoprocessamento do QGIS e aos provedores de algoritmos SAGA e GDAL. A Tabela 2 apresenta a sequência de procedimentos executados pela ferramenta, detalhando a ordem de execução, a descrição atribuída a cada processo no desenvolvimento da ferramenta, o algoritmo empregado e seu respectivo provedor.

TABELA 2 - Procedimentos executados pela ferramenta, ordem de execução, descrição, algoritmo e provedor

Ordem de execução	Processo	Descrição na ferramenta	Algoritmo	Provedor
1	Reprojetar pontos das amostras Reprojetar área	Reproject points Reproject area	Reproject layer	QGIS
2	Renomear o campo da variável agrícola de interesse da camada de pontos Renomear o campo que especifica os tratamentos da camada de pontos	Rename variable field Rename treatment field	Rename field	QGIS
3	Separar os pontos pertencentes aos diferentes tratamentos	Separate T1 Separate T2 Separate T3 Separate T4 Separate T5	Extract by attribute	QGIS
4	Selecionar 80% dos pontos pertencentes a cada tratamento	Select T1-80% Select T2-80% Select T3-80% Select T4-80% Select T5-80%	Random selection	QGIS
5	Extrair para camada vetorial os pontos selecionados	Extract T1-80% Extract T2-80% Extract T3-80% Extract T4-80% Extract T5-80%	Extract selected features	QGIS
6	Extrair para camada vetorial os 20% restante dos pontos	Extract T1-20% Extract T2-20% Extract T3-20% Extract T4-20% Extract T5-20%	Extract by location	QGIS

continua...

				TABELA 5 - continua...
7	Estimar a variável de interesse para a área de estudo a partir de 80% dos pontos - Interpolação por krigagem ordinária	KrigO - T1-80% KrigO - T2-80% KrigO - T3-80% KrigO - T4-80% KrigO - T5-80%	Ordinary kriging	SAGA
8	Coletar amostras da superfície estimada com pontos utilizando os 20% dos pontos	Sample T1 Sample T2 Sample T3 Sample T4 Sample T5	Sample raster values	QGIS
9	Calcular o erro de estimativa da superfície gerada	Error T1 Error T2 Error T3 Error T4 Error T5	Fied calculator	QGIS
10	Gerar uma superfície do erro calculado - Interpolação por Krigagem ordinária	SupError T1 SupError T2 SupError T3 SupError T4 SupError T5	Ordinary kriging	SAGA
11	Somar as superfícies de estimativa e de erro calculado, gerando uma superfície final estimada	T1 T2 T3 T4 T5	Raster calculator	GDAL
12	Recortar a superfície final na área de estudo	T1_rec T2_rec T3_rec T4_rec T5_rec	Clip raster by mask layer	GDAL
13	Subtração entre as superfícies finais (Tratamento Referência - Demais Tratamentos)	Gain (T1 and T2) Gain (T1 and T3) Gain (T1 and T4) Gain (T1 and T5) Gain (T2 and T3) Gain (T2 and T4) Gain (T2 and T5) Gain (T3 and T4) Gain (T3 and T5) Gain (T4 and T5)	Raster calculator	GDAL
14	Calcular estatística básica das superfícies gerada pela subtração	Stats (T1 and T2) Stats (T1 and T3) Stats (T1 and T4) Stats (T1 and T5) Stats (T2 and T3) Stats (T2 and T4) Stats (T2 and T5) Stats (T3 and T4) Stats (T3 and T5) Stats (T4 and T5)	Raster layer statistics	QGIS

O procedimento apresentado na Tabela 2 descreve os 14 passos executados pela ferramenta GEOTrat – Points quando o usuário inicia a execução. O primeiro passo consiste na reprojeção das camadas de pontos para um sistema de coordenadas projetadas, uma vez que, em etapas subsequentes, será realizada a krigagem ordinária. Essa técnica requer que os dados estejam em um sistema métrico de coordenadas para que os semivariogramas, calculados considerando a distância entre as amostras, sejam calculados. Sendo assim, a reprojeção dos dados de entrada garante a adequação para os processos realizados.

Em seguida, no passo 2, os campos relevantes na camada de pontos, que representam a variável agrícola de interesse e a especificação do tratamento, são padronizados com um nome específico. Isso facilita a identificação e a manipulação dos dados durante o processo de análise. No passo 3, os pontos são separados com base no atributo de tratamento, resultando em camadas distintas de pontos para cada tratamento.

Nos passos 4, 5 e 6 realiza-se uma seleção aleatória das amostras de cada tratamento. Essa divisão é necessária para geração do modelo de interpolação de superfície pelo método da krigagem e, posteriormente, para estimativa do erro deste modelo. Este método de divisão de amostras para modelagem é conhecido como *holdout*, uma técnica muito comum usada em aprendizado de máquina e estatística para avaliar a eficácia de um modelo matemático. Ele foi escolhido devido à facilidade de implementação. Nesse método, o conjunto de dados é dividido em dois subconjuntos mutuamente excludentes um conjunto de treinamento, utilizado para gerar o modelo de estimativa (geralmente, 80% dos dados), e um conjunto de teste, utilizado para avaliar o desempenho do modelo (geralmente, 20% dos dados). Mais informações sobre a técnica *holdout* podem ser encontradas em Fisher (1936), e mais recentemente nos trabalhos de Muller e Guido (2016) e Géron (2022).

No passo 7, a interpolação por krigagem ordinária é realizada utilizando 80% dos pontos com as amostras de cada tratamento, estimando a variável de interesse para a área de estudo. Isso resulta na criação de superfícies estimadas da variável de interesse com base apenas nos pontos de cada tratamento (T1, T2, T3, T4, T5). A krigagem é uma técnica amplamente utilizada na geoestatística e na análise espacial e serve para estimar valores desconhecidos em locais não amostrados com base em observações pontuais conhecidas (Journel e Huijbregts, 1978). Esta técnica é empregada em aplicações agrícolas para mapear a variabilidade espacial de atributos do solo, produtividade de culturas e outros parâmetros agrícolas (Kiboi et al., 2018; Wang, Semeonova e Shahbazi, 2019; Sharma et al., 2021).

A krigagem ordinária destaca-se como uma das técnicas mais utilizadas na geoestatística, devido a sua capacidade de considerar a dependência espacial dos dados. Essa abordagem pressupõe que a correlação entre os valores em diferentes locais pode ser modelada por meio de um semivariograma, o qual descreve como a variabilidade dos dados varia com a distância entre os pontos amostrados. A partir disso, estima valores não amostrados, ponderando as observações mais próximas e a estrutura de correlação espacial (Isaaks e Srivastava, 1989).

Na ferramenta GEOTrat – Points, os parâmetros utilizados para a execução do algoritmo de krigagem ordinária, disponibilizada pelo provedor SAGA, são os pontos das amostras dos tratamentos, e os parâmetros definidos na entrada, sendo eles a variável de interesse, contorno da área de estudo, tamanho do pixel de interpolação e modelo de semivariograma. A fim de facilitar as comparações entre os experimentos, nos demais parâmetros foram mantidos os valores padrão do algoritmo (lag igual a 100, skip igual a 1, search range global, maximum search distance igual a 1000, minimum de 16 vizinhos e maximum de 20 vizinhos).

Nos passos 8 e 9 são coletadas amostras das superfícies estimadas, utilizando os 20% dos pontos, separados no passo 6. Após essa amostragem, procede-se o cálculo do erro de estimativa através da subtração do valor da variável de interesse estimado do valor mensurado correspondente. Esse erro calculado, no passo 10, é utilizado para gerar uma superfície que representa o erro calculado para as superfícies. Esse passo é realizado utilizando a técnica de krigagem ordinária. Em seguida, no passo 11, a superfície de estimativa da variável agrícola de cada tratamento e a sua respectiva superfície de erro são somadas, produzindo superfícies finais estimadas para os tratamentos. No passo 12, essas superfícies finais são recortadas, limitando, assim, a análise ao espaço da área de estudo.

Por fim, no passo 13 ocorre a subtração entre as superfícies finais dos tratamentos, permitindo a comparação entre o tratamento definido como referência e os demais tratamentos. Em complemento, no passo 14 são calculadas estatísticas básicas das superfícies resultantes das subtrações, fornecendo informações importantes sobre as diferenças entre os tratamentos, como soma, média, desvio padrão, máximo e mínimo.

2.4 Saídas

As saídas geradas pelo recurso desenvolvido neste estudo consistem em superfícies estimadas no formato matricial para a área de estudo da variável agrícola de interesse contemplando os tratamentos. A superfície T1 representa uma estimativa da variável agrícola para a área de estudo caso fosse tratada exclusivamente com o tratamento T1; o mesmo ocorre para a saída T2, T3, T4 e T5.

Além disso, a ferramenta gera uma saída denominada Gain, que é uma superfície no formato matricial representando o ganho associado ao tratamento definido como referência em relação aos outros tratamentos. Um arquivo de saída com a extensão HTML, intitulado *Statistics of Gain*, é gerado para apresentar as estatísticas básicas dessas superfícies. Ressalta-se que os resultados gerados são apresentados na mesma unidade de medida da variável agrícola de interesse, e o tempo de execução é variável, dependendo das configurações do equipamento utilizado e da quantidade de pontos a serem analisados.

AVALIAÇÃO DE DESEMPENHO E DISCUSSÕES

Neste tópico é apresentada a avaliação de desempenho da ferramenta GEOTrat - Points. Os dados utilizados para o estudo de caso foram cedidos pela empresa Lallemand Plant Care Ltda. Eles pertencem a experimentos que seguiram um delineamento em blocos, composto por dois tratamentos distintos com produtos de origem biológica. É importante destacar que as informações relativas às especificações dos produtos utilizados são confidenciais e, portanto, não estão inclusas no escopo desta pesquisa.

As superfícies simuladas para a área experimental, sob os tratamentos T1 e T2, foram avaliadas por meio do cálculo do Root Mean Square Error – RMSE, utilizando as amostras retiradas do banco de dados antes do início do estudo de caso utilizando a ferramenta supracitada. O RMSE é uma métrica amplamente empregada para avaliar a precisão de modelos de previsão e estimativa. Quanto menor o valor do RMSE, menor é a discrepância relativa entre as estimativas e os valores mensurados em campo. Portanto, a Equação 1 apresenta a fórmula utilizada para o cálculo do RMSE em porcentagem:

$$RMSE (\%) = \frac{\sqrt{\frac{\sum(y_i - \hat{y}_i)^2}{n}}}{\frac{\sum y_i}{n}} * 100 \quad (1)$$

onde y_i representa o valor medido em campo de produtividade; \hat{y}_i expressa o valor estimado de produtividade e; n o número de amostras de avaliação.

Outra medida de avaliação das superfícies calculadas neste estudo foi o Coeficiente de Correlação de Pearson (r), que pode assumir valores no intervalo entre -1 e +1. Este coeficiente foi utilizado para medir a intensidade e direção da relação linear entre os valores de produtividade medidos em campo e aqueles estimados para as superfícies T1 e T2. A Equação 2 apresenta a fórmula utilizada para o cálculo de r :

$$r = \frac{\sum(y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{(\sum(y_i - \bar{y})^2)(\sum(\hat{y}_i - \bar{\hat{y}})^2)}} \quad (2)$$

onde y_i representa o valor medido em campo de produtividade; \bar{y} expressa a média da produtividade medida em campo; \hat{y}_i indica o valor estimado de produtividade e; $\bar{\hat{y}}$ representa a média da produtividade estimada.

3.1 Dados

As amostras foram coletadas em seis áreas experimentais, sendo cinco delas localizadas na França e uma no Brasil. Nestas áreas foram cultivadas diferentes culturas em grãos, incluindo cevada, girassol, milho, soja trigo e triticale. A Figura 4 apresenta a localização geográfica dessas seis áreas, assim como a configuração adotada para o design dos tratamentos.

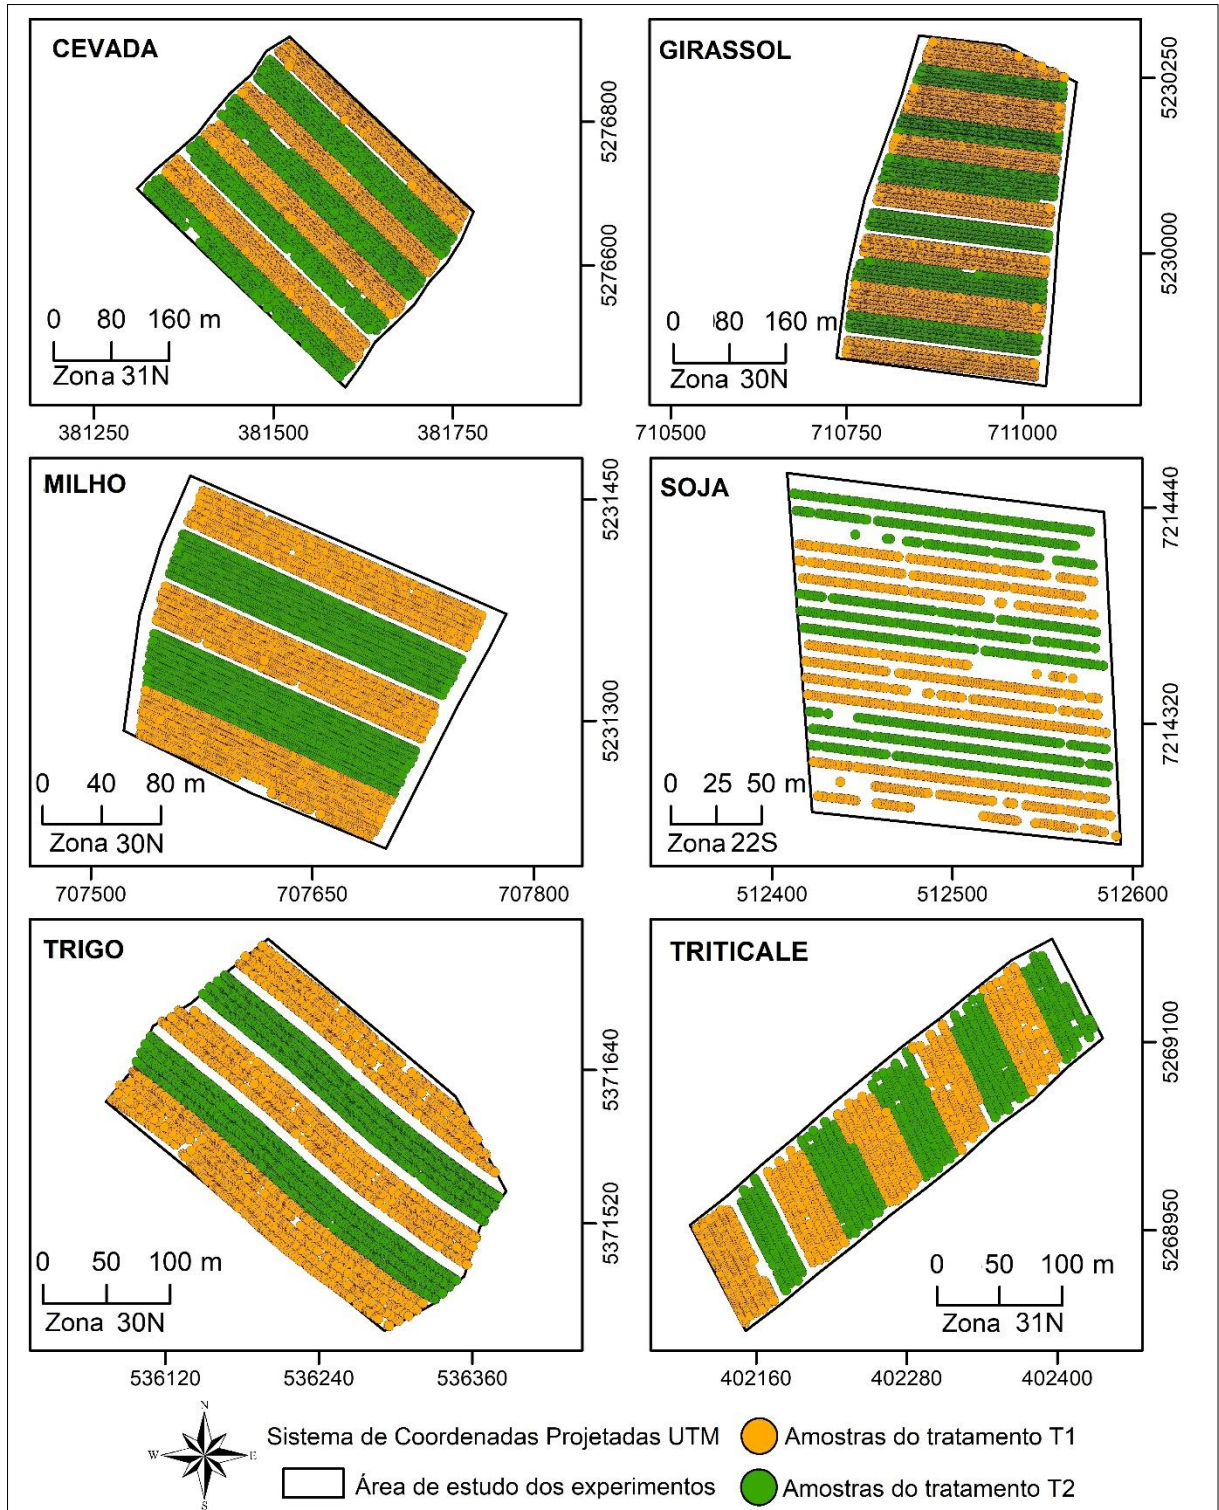


FIGURA 4 – Mapa de localização das áreas experimentais para estudo de caso utilizando GEOTrat – Points

O mapa da Figura 4 apresenta espacialmente a distribuição das amostras dos tratamentos T1 e T2. Nestes experimentos, o intuito foi avaliar o impacto do tratamento T2 no aumento da

produtividade das culturas em estudo. Nesse sentido, a coleta das amostras foi realizada com máquina agrícola do tipo colheitadeira, de forma a abranger homoganeamente toda a área experimental. Complementa-se que as amostras já são coletadas de forma georreferenciada, não importando a direção da colheita ou a disposição dos tratamentos. A presença de áreas vazias em algumas faixas dos tratamentos é decorrente de falhas na linha de plantio ou de erros no equipamento de medição de produtividade da máquina.

Para cada uma das áreas foram disponibilizados dois arquivos vetoriais no formato shapefile. Um arquivo vetorial de geometria do tipo ponto, com um campo numérico contendo o valor da produtividade em kg/ha. O outro campo é do tipo textual binário e especifica o tratamento utilizado, identificado como T1 ou T2. O outro arquivo vetorial de geometria do tipo polígono representa a delimitação da área experimental. A Tabela 3 apresenta informações relevantes sobre cada área, que incluem a cultura, tamanho da área e as estatísticas básicas relacionadas às amostras de produtividade total e para cada tratamento.

TABELA 3 – Cultura, tamanho da área e estatísticas básicas das amostras de produtividade

Cultura	Área (ha)	Tratamento	Número de amostras	Média (kg/ha)	Soma (kg/ha)	Mínimo (kg/ha)	Máximo (kg/ha)	Desvio padrão (kg/ha)	Coefficiente de variação (%)
Cevada	11.48	Total	4800	5600.00	26869700.00	1000.00	10100.00	1530.00	27.32
		T1	2400	5680.00	13635900.00	1200.00	10100.00	1570.00	27.64
		T2	2400	5510.00	13233800.00	1000.00	9900.00	1480.00	26.86
Girassol	12.62	Total	9800	3591.52	35196923.10	2132.10	4829.00	494.26	13.76
		T1	4900	3468.91	16997649.60	2132.10	4827.20	503.90	14.53
		T2	4900	3714.14	18199273.50	2138.80	4829.00	452.32	12.18
Milho	3.92	Total	4400	10362.17	45593563.00	5364.20	15072.20	1362.58	13.15
		T1	2200	10436.65	22960630.90	5364.20	15072.20	1458.12	13.97
		T2	2200	10287.69	22632932.10	5670.70	15000.20	1255.40	12.20
Soja	3.2	Total	1600	4470.00	7156520.00	3840.00	5090.00	250.00	5.59
		T1	800	4450.00	3557810.00	3840.00	5070.00	250.00	5.62
		T2	800	4500.00	3598710.00	3880.00	5090.00	240.00	5.33
Trigo	5.01	Total	3400	8060.00	27420830.00	4780.00	10900.00	980.00	12.16
		T1	1700	7760.00	13191740.00	4950.00	10610.00	920.00	11.86
		T2	1700	8370.00	14229080.00	4780.00	10900.00	950.00	11.35
Triticale	3.54	Total	1940	6163.93	11958025.90	2520.80	9607.00	1181.11	19.16
		T1	970	6063.13	5881237.70	2520.80	9607.00	1215.33	20.04
		T2	970	6264.73	6076788.20	2682.20	9326.70	1136.97	18.15

A Tabela 3 fornece uma análise da produtividade das diferentes culturas agrícolas e em relação aos tratamentos. Observa-se que para o estudo de caso foi incluída uma variedade de culturas de grãos, com tamanhos de áreas distintos, variando de 3.20 até 12.62 ha. Além disso, a quantidade de amostras difere consideravelmente, com intervalos que vão de 1600 pontos para a cultura de soja a 9800 pontos para a cultura de girassol, sendo o número de amostras proporcional ao tamanho da área. Deve-se considerar, também, as linhas de plantio utilizadas na condução do experimento.

O número de amostras por hectare recomendado para a utilização da krigagem aplicada à agricultura varia de acordo com a variabilidade espacial, tamanho da área, precisão desejada e recursos disponíveis (Oliver e Webster, 2015). Nos experimentos desta pesquisa, a relação de quantidade de amostras por área é significativamente alta, sendo a cultura de cevada a que possui menor quantidade de amostras por área, aproximadamente 418.12 amostras/ha. A cultura de milho é a que possui a maior quantidade de amostras por área, aproximadamente 1122.45 amostras/ha. O equipamento utilizado para coleta da produtividade para as áreas experimentais confere uma alta densidade de amostras.

A produtividade média das áreas experimentais varia em um intervalo de 3591.52 kg/ha para a cultura de girassol, até 10362.17 kg/ha para a área de milho. Por sua vez ao analisar a soma de produtividade, nota-se que o milho foi a cultura que apresentou maior produção, com 45593563.00 kg/ha, enquanto a soja registra a menor produção, com 7156520.00 kg/ha. Em relação ao percentual de variação dos valores de produtividade, as culturas de cevada e triticale possuem maior variabilidade, com coeficientes de variação de 27.32% e 19.16%, respectivamente. As culturas de girassol, milho e trigo apresentam variabilidades similares, com valores de 13.76%, 13.15% e 12.16%, respectivamente, enquanto a cultura da soja possui a menor variabilidade, com 5.59%.

A Tabela 3 inclui as médias de produtividade para cada tratamento em cada experimento, apresentando diferenças significativas entre as médias de produtividade. As discrepâncias entre as médias de produtividade dos tratamentos variam no intervalo de 50 kg/ha para a cultura de soja, até o valor de 610.10 kg/ha para a cultura de trigo. É importante observar que, em todos os experimentos, os tratamentos de referência foram os do tratamento T2; contudo, notam-se médias de produtividade superiores no tratamento T1 para as culturas de cevada, milho e soja.

A variabilidade na produtividade das culturas de grãos é um fenômeno que pode ser relacionada a diversos fatores. As flutuações nas precipitações, temperaturas e nos padrões

climáticos afetam o crescimento e desenvolvimento dessas culturas. Além disso, as características físicas e químicas do solo, como textura, fertilidade e acidez interferem diretamente na absorção de nutrientes pelas plantas. Outro fator de relevância é a escolha do manejo agrícola, como, por exemplo, o uso de variedades de sementes, fertilizantes, irrigação e controle de pragas e doenças. A interação entre esses fatores pode gerar as variações na produtividade das culturas (Ngoune e Shelton, 2020).

3.2 Parâmetros

O estudo de caso de GEOTrat – Points foi precedido por uma etapa de particionamento das amostras, visando à avaliação externa das estimativas de produtividade geradas pelos modelos. Para isso, uma parcela de 20% das amostras totais foi selecionada aleatoriamente para cada tratamento. Esse processo foi executado por meio do software QGIS, fazendo uso da funcionalidade de seleção randômica.

Os parâmetros de entrada para execução foram definidos como os 80% remanescentes das amostras após o particionamento inicial, seleção do campo contendo a produtividade, seleção do campo especificando o tratamento, definição do tratamento de referência estabelecido como T2. Ademais, foram incluídos os limites das áreas experimentais, o sistema de coordenadas projetado referente à localização de cada área, um tamanho de pixel padrão de 1.50 metros e a seleção do modelo de semivariograma com equação linear como padrão.

3.3 Resultados e Discussões

A Figura 5 apresenta a superfície de ganho de produtividade em kg/ha, e, em sequência, as estimativas de produtividade para a área de estudo sob condições de tratamento T1 e sob o tratamento T2. As duas últimas estão apresentadas no mesmo intervalo de classificação para as legendas.

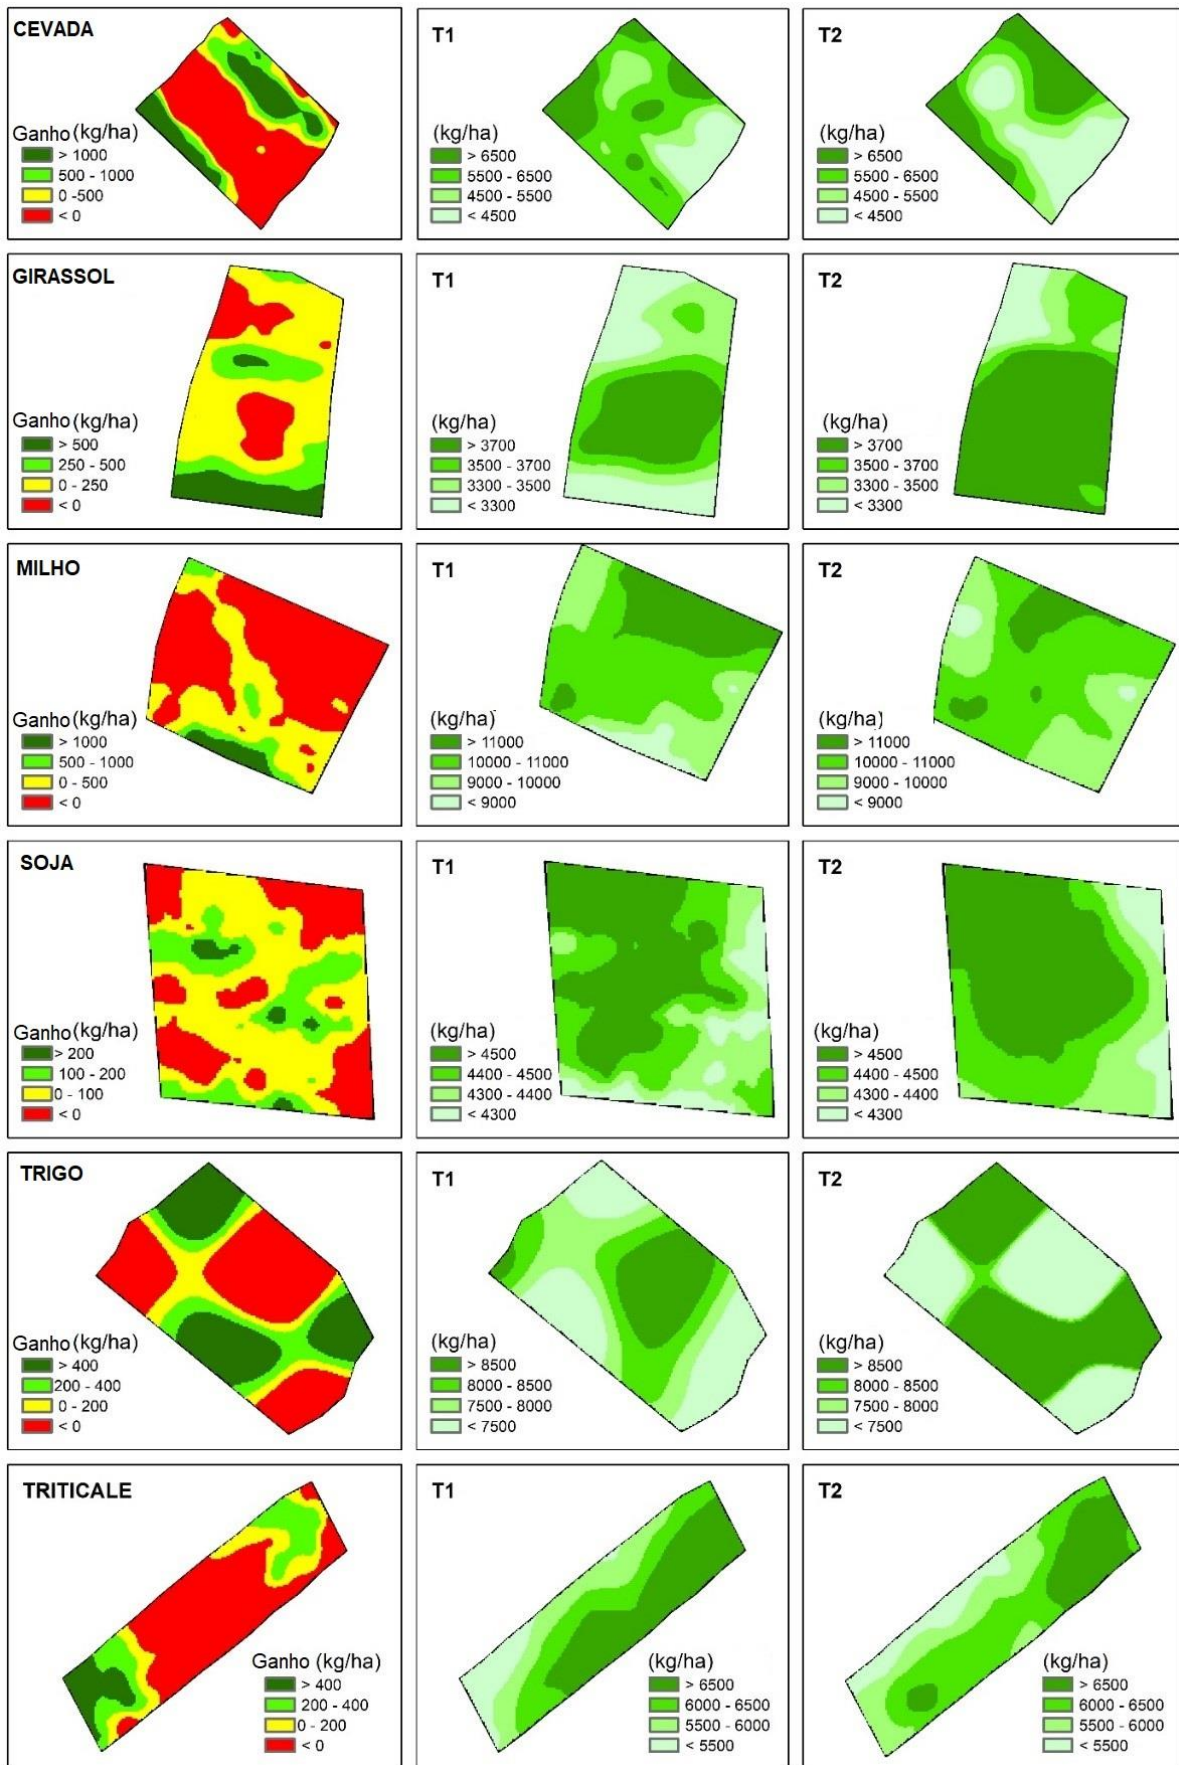


FIGURA 5 – Superfícies estimadas

O primeiro mapa de cada cultura apresenta a superfície de ganho final de produtividade. Conforme ilustrado, a partir da estimativa realizada, haveria perda de produtividade nos locais representados em cor vermelha se o tratamento de referência (T2) fosse utilizado em toda a área, e nos locais de cor amarelo, verde claro e verde escuro haveria ganho. Os mapas em sequência, com o título T1 e T2, apresentam a produtividade estimada para a área sob os tratamentos.

Em todas as culturas há diferença significativa entre a distribuição da produtividade dos tratamentos T1 e T2. Essa condição é causada pela variabilidade resultantes das diferentes técnicas de manejo empregadas, as quais foram aplicadas em parcelas alteradas. Nota-se que as culturas de girassol, trigo e soja apresentam áreas expressivas com altos valores de produtividade no tratamento de referência T2. Já a cultura de Triticale resultou em mais áreas com altos valores de produtividade no tratamento T1 devido a sua maior amplitude dos valores de produtividade.

Visualmente, os mapas de ganho das culturas de cevada e de milho apresentaram perda de produtividade, o que corrobora as estatísticas básicas das amostras apresentadas na Tabela 3, visto que a média de produtividade dessas culturas era menor no tratamento de referência. Isso também justifica o ocorrido para as culturas de girassol e soja, em que há ganho de produtividade em quase toda a área experimental. Para a cultura de trigo, nota-se que há uma homogeneidade entre ganho e perda. Identificar locais onde o tratamento de referência realizado resultou em ganho de produtividade em relação ao outro tratamento permite que os agricultores aloquem recursos de maneira mais eficaz, de forma econômica e sustentável (Martins et al., 2023).

A Tabela 4 apresenta os resultados das estatísticas básicas da superfície de ganho de produtividade, proporcionando ao usuário uma maior compreensão da estimativa realizada.

TABELA 4 – Estatísticas básicas da superfície de ganho de produtividade

Cultura	kg/ha				
	Mínimo	Máximo	Soma	Média	Desvio padrão
Cevada	-2818.89	3071.81	-3961719.13	-138.01	1185.83
Girassol	-318.47	918.32	6669211.02	211.34	248.49
Milho	-1534.31	2251.93	-1382874.80	-141.14	576.46
Soja	-185.59	248.82	301334.48	37.63	82.74
Trigo	-12134.21	9171.82	6356454.12	507.38	5122.48
Triticale	-913.61	809.09	-594242.22	-67.06	374.54

A Tabela 4 apresenta o máximo, mínimo, soma, média e desvio padrão da superfície de ganho de produtividade. A partir dessas métricas, é possível realizar uma análise geral sobre perda ou ganho de produtividade e concluir se o tratamento realizado foi eficiente. Os resultados indicam que a cultura de trigo obteve maior amplitude nos valores de produtividade, variando de uma perda de -12134.24 kg/ha a um ganho de 9171.82 kg/ha. Em termos de soma de produtividade, observa-se que a cevada apresentou maior perda, com saldo negativo de 3961719.13 kg/ha, enquanto a cultura de girassol apresentou ganho de produtividade de 6669211.02 kg/ha.

Nesta pesquisa, cada cultura apresentou uma quantidade diferente de amostras para a avaliação. A Tabela 5 apresenta o RMSE (%) e o coeficiente de correlação de Pearson para cada superfície de tratamento.

TABELA 5 – RMSE e r das estimativas para T1 e T2

Cultura	Número de amostras	RMSE (%)		r	
		T1	T2	T1	T2
Cevada	480	14.13	23.27	0.86	0.68
Girassol	980	9.93	8.12	0.75	0.76
Milho	440	9.78	9.98	0.72	0.62
Soja	160	4.92	4.60	0.68	0.58
Trigo	340	13.84	69.71	0.21	-0.16
Triticale	194	17.13	16.45	0.52	0.52

A Tabela 5 apresenta o RMSE em porcentagem das estimativas geradas para as superfícies T1 e T2. Os resultados obtidos revelam uma variabilidade significativa na acurácia das estimativas para diferentes culturas e tratamentos. Nota-se que a cultura de trigo, especialmente no tratamento T2, apresentou um valor elevado de RMSE, consideravelmente discrepante em relação às outras culturas, atingindo 69.71%, acompanhado de uma correlação negativa de -0.16. Essa discrepância pode ser atribuída à complexidade de modelagem da produtividade do trigo, conforme as conclusões de Oikonomidis et al. (2022), que apresentam as dificuldades na previsão desse tipo de cultura.

Em contrapartida com a cultura do trigo, as estimativas para outras culturas, como soja, milho, triticale e girassol revelaram percentuais de erros menores, com acurácia superior a 82.87% pertencente à cultura de triticale e até 95.40% na cultura da soja. Esse resultado é similar ao trabalho de Kwaghtyo e Eke (2023), que destacaram a eficácia do modelo de aprendizado de máquina Random Forest (RF) na previsão do rendimento das culturas, atingindo

uma precisão de 95%. Neste trabalho, ao utilizar um modelo de estimativa para a produtividade de menor complexidade de implementação, a krigagem ordinária, é demonstrado que diferentes abordagens metodológicas podem apresentar resultados similares na acurácia da predição dessa variável.

A discrepância nos valores das métricas de avaliação de desempenho dos modelos pode ser atribuída a diferenças nos conjuntos de dados, nas características climáticas, bem como nas abordagens metodológicas utilizadas. Ahmed (2023), na previsão do rendimento do milho na Arábia Saudita, utilizando dados climáticos e modelos baseados em Redes Neurais Artificiais – RNA e Máquina de Vetor de Suporte – MVS, apresentou valores de métricas de avaliação, como RMSE e r , que variaram consideravelmente. As correlações apresentadas no estudo variaram entre 0.82 para até 0.86 dependendo do algoritmo, e, neste trabalho, para a cultura do milho, de 0.72 para T1 e 0.62 para T2.

Os erros de estimativa podem estar relacionados à variabilidade da produtividade, ao modelo de semivariograma adotado, ao tamanho das amostras, tendências espaciais, entre outros fatores (Oliver e Webster, 2015). É válido destacar que a acurácia dos modelos gerados neste trabalho está diretamente relacionada com a qualidade da amostragem realizada em campo e com o conhecimento sobre as tendências da variável de interesse.

A utilização do conhecimento espacial sobre as culturas está se tornando uma tendência amplamente explorada na Agricultura 5.0, contribuindo significativamente para a experimentação agrícola baseada em dados. As informações geradas pela ferramenta GEOTrat – Points desempenham um papel crucial ao auxiliar os agricultores na tomada de decisões relacionadas à eficiência dos tratamentos utilizados em campo. Ela fornece uma interpretação valiosa de forma qualitativa e quantitativa do manejo avaliado. Os estudos recentes enfatizam que recursos semelhantes desempenham um papel fundamental no processamento de dados, monitoramento, planejamento, documentação e gerenciamento das operações agrícolas, tornando essas ferramentas essenciais para a modernização da agricultura (Saiz-Rubio e Rovira-Más, 2020; Asfaw et al., 2018; Koksall e Tekinerdogan, 2019).

3.4 Limitações e desenvolvimentos futuros

GEOTrat – Points é um recurso para o QGIS que permite a avaliação da eficiência de tratamentos agrícolas de experimentos de campo. Uma das limitações da ferramenta é o usuário não conseguir visualizar o semivariograma do modelo de krigagem ordinária. Outra limitação

é que apenas o método de krigagem ordinária está disponível. Mesmo que embora esse método permita a geração de mapas de alta qualidade, ele não necessariamente funciona bem em qualquer aplicação concebível ou para qualquer variável. O ideal seria contar com algoritmos de aprendizado de máquina mais robustos como Suport Vector Machine – SVM, Redes Neurais Artificiais – RNA e Florestas Aleatórias – FA.

Os desenvolvimentos futuros compreendem a otimização automática do modelo de semivariograma para ajuste dos modelos de krigagem ordinária e inclusão de técnicas de validação cruzada para avaliação do modelo. Por fim, uma extensão do recurso GEOTrat possibilitará a utilização de bandas de imagens ou índices de vegetação obtidas sob diversas naturezas para avaliação de tratamentos de campo.

CONCLUSÕES

A fim de possibilitar uma análise quantitativa e espacial dos manejos agrícolas, foi desenvolvida a ferramenta GEOTrat - Points integrada ao software QGIS. Este recurso realiza a modelagem de variáveis coletadas em campo, executa análises estatísticas e gera visualizações de superfícies. A abordagem empregada baseia-se no método de krigagem ordinária, permitindo a simulação das variáveis de interesse em toda a área experimental, com base em tratamentos individuais. Posteriormente, ocorre a comparação entre o tratamento de referência e os demais tratamentos. Os resultados são exportados em formato raster, enquanto as estatísticas são apresentadas em um arquivo HTML.

Para avaliar o desempenho de GEOTrat - Points, realizou-se um estudo de caso que envolveu a comparação de áreas experimentais onde dois tratamentos distintos foram aplicados em culturas como cevada, girassol, milho, trigo, soja e triticale. O estudo considerou diferentes tamanhos de amostras da produtividade agrícola nas áreas em análise. De maneira geral, os processamentos sob os diferentes tratamentos demonstraram altos níveis de acurácia de mapeamento, proporcionando uma interpretação qualitativa e quantitativa das variações de produtividade.

A ferramenta GEOTrat - Points oferece a flexibilidade necessária para avaliar experimentos agrícolas de variados portes, abrangendo diferentes culturas e quantidades de amostras. A precisão das estimativas geradas está diretamente relacionada à qualidade, quantidade e natureza das variáveis coletadas no campo. A capacidade de interpretação de dados fornecida por essa ferramenta contribui significativamente para a experimentação agrícola, auxiliando na seleção de práticas de manejo adequadas e na compreensão de tratamentos mais eficazes.

REFERÊNCIAS

- AHMED, Shakeel. A Software Framework for Predicting the Maize Yield Using Modified Multi-Layer Perceptron. **Sustainability**, v. 15, n. 4, p. 3017, 2023. DOI: <https://doi.org/10.3390/su15043017>.
- ASFAW, Dagmawi et al. TAMSAT-ALERT v1: A new framework for agricultural decision support. **Geoscientific Model Development**, v. 11, n. 6, p. 2353-2371, 2018. DOI: <https://doi.org/10.5194/gmd-11-2353-2018>.
- BORGES, Alejandra et al. Can spatial modeling substitute for experimental design in agricultural experiments? **Crop Science**, v. 59, n. 1, p. 44-53, 2019. DOI: <https://doi.org/10.2135/cropsci2018.03.0177>.
- CASLER, Michael D. Fundamentals of experimental design: Guidelines for designing successful experiments. **Agronomy Journal**, v. 107, n. 2, p. 692-705, 2015. DOI: <https://doi.org/10.2134/agronj2013.0114>.
- FAO. **Plant breeding and experimentation**: A guide to good practice. Rome: Food and Agriculture Organization of the United Nations, 2016. Disponível em: <https://www.fao.org/3/i6030e/i6030e.pdf> Acesso em: 29 fev. 2024.
- FISHER, Ronald A. The use of multiple measurements in taxonomic problems. **Annals of eugenics**, v. 7, n. 2, p. 179-188, 1936. DOI: <https://doi.org/10.1111/j.1469-1809.1936.tb02137.x>.
- FISHER, Ronald A. **The design of experiments**. 1. ed. London, Edinburgh: Oliver and Boyd, 1960. 257 p.
- GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. O'Reilly Media, Inc., 2022.
- ISAAKS, Edward H.; SRIVASTAVA, R. M. **An introduction to geostatistics**. New York: Oxford University Press, 1989.
- JEPPESEN, Jacob Høxbroe et al. Open geospatial infrastructure for data management and analytics in interdisciplinary research. **Computers and Electronics in Agriculture**, v. 145, p. 130-141, 2018. DOI: <https://doi.org/10.1016/j.compag.2017.12.026>.
- JOURNAL, A., G; HUIJBREGTS, C., J. **Mining geostatistics**. 17. ed. London: Academic Press, Mathematical Geology. 610p.
- KARUNATHILAKE, E. M. B. M. et al. The path to smart farming: Innovations and opportunities in precision agriculture. **Agriculture**, v. 13, n. 8, p. 1593, 2023. DOI: <https://doi.org/10.3390/agriculture13081593>
- KWAGHTYO, Dekera Kenneth; EKE, Christopher Ifeanyi. Smart farming prediction models for precision agriculture: a comprehensive survey. **Artificial Intelligence Review**, v. 56, n. 6, p. 5729-5772, 2023. DOI: <https://doi.org/10.1007/s10462-022-10266-6>.

KIBOI, Milka N. et al. Microbial biomass and acid phosphomonoesterase activity in soils of the Central Highlands of Kenya. *Geoderma Regional*, v. 15, p. e00193, 2018. DOI: <https://doi.org/10.1016/j.geodrs.2018.e00193>.

KÖKSAL, Ö.; TEKINERDOGAN, Bedir. Architecture design approach for IoT-based farm management information systems. *Precision Agriculture*, v. 20, p. 926-958, 2019. DOI: <https://doi.org/10.1007/s11119-018-09624-8>.

LIU, Wei et al. A systematic literature review on applications of information and communication technologies and blockchain technologies for precision agriculture development. *Journal of Cleaner Production*, v. 298, p. 126763, 2021. DOI: <https://doi.org/10.1016/j.jclepro.2021.126763>.

MASSRUHÁ, S. M. F. S. et al. (ed.). **Digital agriculture: research, development and innovation in production chains**. Brasília, DF: Embrapa, 2023. cap. 4, p. 71-89.

MÜLLER, Andreas C.; GUIDO, Sarah. **Introduction to machine learning with Python: a guide for data scientists**. "O'Reilly Media, Inc.", 2016.

NGOUNE, Liliane Tandzi; MUTENGWA, Charles Shelton. **Factors affecting yield of crops**. *Agronomy-climate change & food security*, p. 9, 2020.

OIKONOMIDIS, Alexandros; CATAL, Cagatay; KASSAHUN, Ayalew. Hybrid deep learning-based models for crop yield prediction. *Applied artificial intelligence*, v. 36, n. 1, p. 2031822, 2022. DOI: <https://doi.org/10.1080/08839514.2022.2031823>.

OLIVER, Margaret A. et al. **Basic steps in geostatistics: the variogram and kriging**. Cham, Switzerland: Springer International Publishing, 2015.

PETERSEN, Roger G. **Agricultural field experiments: design and analysis**. Crc Press, 1994.

QUINN, Gerald Peter; KEOUGH, Michael J. **Experimental design and data analysis for biologists**. Cambridge university press, 2002.

SAIZ-RUBIO, Verónica; ROVIRA-MÁS, Francisco. From smart farming towards agriculture 5.0: A review on crop data management. *Agronomy*, v. 10, n. 2, p. 207, 2020. DOI: <https://doi.org/10.3390/agronomy10020207>.

SHARMA, R. P. et al. Spatial variability assessment of soil fertility in black soils of central India using geostatistical modeling. *Archives of Agronomy and Soil Science*, v. 67, n. 7, p. 876-888, 2021. DOI: <https://doi.org/10.1080/03650340.2020.1766678>.

THAI, Thi Huyen et al. Statistical analysis versus the m5p machine learning algorithm to analyze the yield of winter wheat in a long-term fertilizer experiment. *Agronomy*, v. 10, n. 11, p. 1779, 2020. DOI: <https://doi.org/10.3390/agronomy10111779>.

WANG, Jie; SIMEONOVA, Sandra; SHAHBAZI, Mozhdeh. Orientation-and scale-invariant multi-vehicle detection and tracking from unmanned aerial videos. *Remote Sensing*, v. 11, n. 18, p. 2155, 2019. DOI: <https://doi.org/10.3390/rs11182155>.