

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”
Departamento de Engenharia de Biossistemas**

**Qualidade de mapas de produtividade de um monitor de colheita e
múltiplas colhedoras**

Matheus Fontana Westphalen

Trabalho de conclusão de curso para obtenção
de título de Engenheiro Agrônomo

**Piracicaba
2018**

Matheus Fontana Westphalen

**Qualidade de mapas de produtividade de um monitor de colheita e múltiplas
colhedoras**

Orientador:

Prof. Dr. **JOSÉ PAULO MOLIN**

Trabalho de conclusão de curso apresentado para
obtenção de título de Engenheiro Agrônomo

**Piracicaba
2018**

SUMÁRIO

RESUMO	7
ABSTRACT	9
1. INTRODUÇÃO	11
2. REVISÃO BIBLIOGRÁFICA	13
3. MATERIAL E MÉTODOS	21
4. RESULTADOS E DISCUSSÃO	27
5. CONCLUSÃO	61
REFERÊNCIAS BIBLIOGRÁFICAS	63

RESUMO

A aquisição dos dados de produtividade na operação de colheita é a etapa mais importante dentro do ciclo da Agricultura de Precisão (AP), que se inicia com o mapa de produtividade. Entretanto, em muitos casos alguns usuários das técnicas de AP não possuem todas as colhedoras instrumentadas com monitores de produtividade, necessários para a aquisição dos dados. A geração de mapas de produtividade com apenas uma colhedora instrumentada em meio a outras colhedoras não instrumentadas pode ser uma solução. Foi realizada a eliminação de faixas de colheita em três conjuntos de dados de produtividade com o intuito de simular essa situação e avaliar o efeito do raleamento dos dados na qualidade dos mapas gerados. Os dados brutos passaram por uma filtragem de ruídos e foram interpolados com o uso de dois métodos diferentes. A metodologia proposta apresentou bons resultados, mostrando que é possível obter mapas de produtividade confiáveis na operação de colheita com a utilização de apenas uma colhedora equipada com o monitor de produtividade em meio a outras colhedoras não equipadas, desde que operem em comboio, de maneira intercalada.

Palavras-chave: Agricultura de precisão; Mapas de colheita; Faixas de colheita; Soja; Milho

ABSTRACT

The acquisition of yield data in the harvesting operation is the most important step in the Precision Agriculture (AP) cycle, which starts with the yield map. However, in many cases some users of AP techniques do not have all of the harvesters instrumented with yield monitors needed to acquire the data. Generating productivity maps with only one harvester instrumented among other non-instrumented harvesters may be a solution. The elimination of harvest strips was done in three sets of yield data in order to simulate this situation and to evaluate the effect of thinning the data on the quality of the generated maps. The raw data underwent a noise filtering and were interpolated using two different methods. The proposed methodology produced good results, showing that it is possible to obtain reliable yield maps in the harvesting operation with the use of only one harvester equipped with the yield monitor in the midst of other non-equipped harvesters, since they operate in convoy and interleaved.

Keywords: Precision Agriculture; Yield Maps; Harvest Strips; Soybean; Corn

1. INTRODUÇÃO

A agricultura de precisão (AP) tem o objetivo de gerir de maneira inteligente a variabilidade espacial das lavouras, promovendo o suporte necessário para intervenções localizadas e tornando o sistema de produção mais eficiente. As técnicas destinadas a esse objetivo procuram agregar dados e informações de diversas fontes, processá-las e analisar os resultados espacializados a fim de possibilitar a compreensão do que ocorre a nível local, possibilitando gerir possíveis deficiências e potencializando possíveis oportunidades. Para isso, diversas tecnologias dedicadas vêm sendo desenvolvidas nas mais diversas áreas do conhecimento. Dentre muitas dessas tecnologias para a obtenção de dados, o mapa de produtividade é o mais importante. É o ponto de partida para o uso de técnicas de AP a serem realizadas nas lavouras. Seu uso auxilia na compreensão das relações de causa e efeito responsáveis pela variabilidade na lavoura, na delimitação de regiões frequentemente contrastantes, na recomendação da adubação a ser adotada ano após ano, além de outras aplicações.

Uma série de sensores e dispositivos são responsáveis pela obtenção dos dados utilizados na geração de um mapa de produtividade. São eles: O receptor GNSS (Sistema Global de Navegação por Satélites); o sensor de fluxo de grãos (no caso da colheita de cereais); o sensor de umidade; o monitor de colheita; o interruptor da plataforma e o sensor de velocidade. Atualmente, a velocidade é obtida não através de um sensor de roda, mas sim do receptor GNSS.

O sensor de fluxo de grãos é o que requer mais atenção. Existem dois princípios de funcionamento. Em um sensor de fluxo gravimétrico a massa de grãos se choca com uma placa de impacto localizada no topo do elevador de grãos limpos, que registra uma leitura tão maior quanto maior for o fluxo de grãos. Em um sensor de fluxo volumétrico, o volume de grãos nas taliscas do elevador de grãos limpos é mensurado pelo sensor. Para isso, um fecho de luz infravermelha é emitido, atravessando o corpo do elevador. Sempre que uma talisca, com ou sem grãos, corta o fecho, o tempo de corte é medido, gerando uma medida de volume. Com a densidade dos grãos informada pelo operador é possível calcular a massa de grãos que esta passando e, conseqüentemente, o fluxo.

Em ambos os casos uma adequada calibração é necessária, já que a medição é realizada indiretamente, e possui um grande peso na qualidade e confiabilidade dos dados gerados. No caso da obtenção de dados com diversas colhedoras operando em um mesmo talhão esse requerimento é ainda mais importante.

Erros de calibração são os mais graves. Porém, diversas outras fontes de erros geram problemas na obtenção dos mapas de produtividade, entre os quais se destacam os erros de largura incorreta da plataforma, de manobras de cabeceira e tempo de enchimento.

Entretanto, existe ainda a possibilidade de se obter um mapa de produtividade com o uso de apenas uma colhedora instrumentada para a geração dos dados em meio a outras colhedoras não instrumentadas, para aqueles usuários que por algum motivo não possuem todo o equipamento necessário.

Nesse contexto, o objetivo desse trabalho foi avaliar o efeito da remoção de faixas de dados de colheita em lavouras de milho e soja, com o uso de dois interpoladores diferentes na interpolação dos dados, no intuito de definir um nível máximo de ausência desses dados para a obtenção de mapas de produtividade confiáveis.

2. REVISÃO BIBLIOGRÁFICA

O conceito de AP enfatiza a importância de compreender a variabilidade existente dentro dos talhões e tratar da melhor maneira possível os diferentes locais. Segundo Batchelor (1997), o objetivo do uso de técnicas de AP possibilita o aumento da lucratividade através do correto manejo da variabilidade. Além disso, Searcy (1997) considera que as técnicas de AP ajudam na melhora da sustentabilidade econômica e ambiental da produção. Gentil e Ferreira (1997) citam ainda uma série de outros benefícios relacionados ao uso de técnicas de AP, como redução do risco na atividade agrícola, redução dos custos de produção, mais assertividade e rapidez nas tomadas de decisão, maior produtividade das lavouras, entre outros.

Para isso, muitos dados acerca da variabilidade nas lavouras são necessários. O mapeamento da produtividade se enquadra como a primeira e principal etapa a ser realizada no ciclo da AP, pois representa a resposta real da cultura ao manejo adotado. Para Balastreire (1998) é também a ferramenta de mais fácil emprego e utilização.

Os monitores de produtividade começaram a surgir no mercado na década de 1990. Dois princípios de funcionamento para o sensor de fluxo de grãos contemplam a grande maioria dos equipamentos utilizados hoje. São eles o princípio de funcionamento gravimétrico e volumétrico. Segundo Molin et al. (2000), existem erros de difícil controle em sensores de fluxo de grãos volumétricos, mas de modo geral esse erro é baixo e está dentro do limite especificado pelos fabricantes. Os autores mencionam ainda que calibrações frequentes são necessárias para uma boa acurácia.

Os dados obtidos por um monitor se configuram em um mapa de pontos. A produção de cada ponto é dividida pela área formada entre a largura da plataforma e a distância percorrida durante o intervalo de tempo da geração do ponto. Assim, é gerada uma produtividade, que é então extrapolada para kg ha^{-1} . A produção de cada ponto é estimada por um sensor de fluxo de grãos. Por ser uma mensuração indireta, uma calibração é necessária.

Para Molin (2000), a qualidade do mapa de produtividade depende de uma frequente calibração do equipamento. Isso exige tempo e pode representar uma grande fonte de erros caso as colhedoras não estejam igualmente bem calibradas,

causando perda de confiabilidade e aumento do tempo de processamento dos dados.

Os dados brutos oriundos diretamente dos monitores de produtividades possuem muitos erros intrínsecos. Por isso é importante que seja realizada uma filtragem adequada para retirada dos ruídos, que são pontos de muita alta ou baixa produtividade, e que não condizem com a sua vizinhança. Muitos autores reportam as mais diversas fontes de erros. Moore (1997) constatou que erros em mapas de produtividade eram provenientes de calibração incorreta do sensor volumétrico do fluxo de grãos, largura incorreta da plataforma, e tempo de enchimento da colhedora. Já Blackmore e Marshal (1996), citaram erros devidos ao sistema de retilha da colhedora e perdas de colheita.

Muitos pesquisadores buscam métodos para remover dados errôneos sem prejudicar a qualidade e confiabilidade do mapa de produtividade final. Gimenez e Molin (2004) trabalharam com um algoritmo programado em uma planilha Excel para a remoção de dados errôneos em mapas de produtividade, eliminando de 21 a 41% dos pontos dos conjuntos de dados e concluindo que o algoritmo foi capaz de reduzir a variância e o desvio padrão do conjunto de dados. Concluíram ainda que o algoritmo é simples de ser construído, apesar de a aplicação ser trabalhosa.

Maldaner et al. (2016) propuseram uma metodologia para a correção de problemas oriundos da calibração divergente entre duas ou mais colhedoras utilizadas na geração de um mapa de produtividade. Os autores obtiveram sucesso em corrigir os problemas em seus conjuntos de dados.

Spekken et al. (2013) desenvolveram um software (*Map Filter*) para filtragem de dados que compara o valor do ponto analisado com os valores de seus vizinhos dentro de um raio de análise previamente escolhido. O ponto pode ser classificado como consistente, impróprio ou inconsistente, a depender do resultado da análise do coeficiente de variação entre o dado analisado e os demais pontos dentro do raio de análise. Os autores consideraram que o método foi eficiente em eliminar pontos inconsistentes do conjunto de dados.

Bigolin (2016) trabalhou com dados de produtividade avaliando a eficácia do software *Map Filter*, onde concluiu que os cortes estatísticos contribuíram eficientemente na limpeza de dados errôneos. Entretanto, segundo o autor, o software não se mostrou muito eficiente na limpeza dos dados errôneos em mapas

de produtividade na cultura da soja, constatando que muitos dados reais de produtividade podem ser eliminados no caso de filtragens mais rigorosas.

Maldaner et al. (2018), com base em trabalhos de Spekken et al. (2013), geraram a versão *Map Filter 2.0*, capaz de eliminar dados errôneos em mapas de produtividade, realizando três etapas de filtragem em sequência: filtragem global, filtragem local anisotrópica e filtragem local isotrópica. A filtragem global gera um limite máximo e mínimo, onde os pontos fora dos limites são eliminados. A filtragem local anisotrópica analisa o valor dos pontos com base na variação com seus vizinhos na mesma linha, enquanto a filtragem local isotrópica analisa todos os pontos dentro de um raio pré-escolhido. Segundo os autores, o software se mostrou capaz de remover eficientemente dados inconsistentes, ao mesmo tempo em que preserva os dados consistentes.

Em sequência às etapas de filtragem, os dados de produtividade precisam ser interpolados. Esse processo é necessário sempre que se queira estimar o valor de um atributo qualquer em um local em que a informação não existe. Para isso, devem existir pontos amostrais próximos à região de interesse. Existem diversas metodologias para a interpolação de variáveis espacializadas na literatura. Segundo Molin (2008), o inverso da distância elevado a uma potência (IDP), Krigagem e vizinho mais próximo são os métodos de interpolação mais utilizados. Os métodos se diferenciam pela forma com que os pesos são atribuídos às amostras.

Para Molin et al. (2015) a interpolação pelo IDP é muito utilizada devido à sua praticidade e resultados satisfatórios, especialmente no caso de conjuntos de dados com elevada densidade de pontos por área.

De acordo com Mazzini e Schettini (2009), na interpolação pelo IDP a influência do ponto amostrado sobre o ponto estimado é inversamente proporcional à distância entre eles. A influência será tanto maior com a diminuição da distância entre os pontos quanto maior for o valor da potência escolhida. A interpolação pelo IDP de dados com densidades amostrais muito baixas pode levar a estimativas errôneas.

Segundo Michelin et al. (2017) o método do IDP é mais fácil de ser utilizado em comparação com a Krigagem, que por sua vez requer um ajuste rigoroso do semivariograma teórico. Os autores trabalharam com a interpolação de dados de produtividade de milho e constataram que o IDP obteve resultados tão bons quanto a Krigagem.

Segundo Weber e Englund (1992) na interpolação pelo método do inverso da distância ao quadrado (IQD) o pesos atribuído ao ponto pode ser calculado pela seguinte fórmula:

$$IQD = \frac{\left(\frac{r_s - r_i}{r_i}\right)^2}{\sum_{i=1}^n \left(\frac{r_s - r_i}{r_i}\right)^2}$$

em que,

r_s – raio de busca

r_i – distância entre a amostra e o ponto estimado

Molin (2008) esclarece que a Krigagem é um dos mais complexos métodos de interpolação, bem como bastante demorado. Esse método requer a geração de um modelo denominado semivariograma, que expressa o quanto um atributo varia espacialmente com a distância. Para a construção desse modelo, são calculadas as semivariâncias como uma combinação de todos os pontos amostrais. O gráfico da semivariância pela distância configura o semivariograma.

De acordo com Molin et al. (2015) a semivariância pode ser calculada pela seguinte fórmula:

$$SV = \frac{(p_1 - p_2)^2}{2}$$

em que,

p_1 – valor no ponto um

p_2 – valor no ponto dois

SV – semivariância calculada entre p_1 e p_2

Um gráfico, denominado semivariograma de nuvem, é formado pela semivariância para cada par de pontos, em função da distância entre eles. O semivariograma experimental é então obtido realizando-se a média ponderada dos valores de semivariância para cada intervalo de distância específica, a partir do qual um modelo teórico pode ser ajustado (MOLIN et al. 2015).

Segundo Yamamoto e Landim (2015) a Krigagem calcula o valor do ponto estimado de maneira não tendenciosa, buscando a mínima variância associada ao valor estimado, usando uma análise variográfica para isso. A análise variográfica, etapa que precede a interpolação em si, mostra também se o conjunto de dados possui dependência espacial (DE), necessária à interpolação por Krigagem.

De acordo com Cambardella et al. (1994) a dependência espacial pode ser definida segundo o grau de dependência espacial (GDE), onde: $GDE \leq 25\%$ - dependência espacial forte; $25\% < GDE < 75\%$ - dependência espacial moderada; $GDE \geq 75\%$ - dependência espacial fraca.

Betzek et al. (2014) compararam diferentes métodos de interpolação na produtividade de soja em duas áreas amostrais e concluíram que não houve diferença significativa entre os mapas gerados com o uso do IQD ou da Krigagem como interpoladores.

Shiratsuchi et al. (2004) avaliaram o efeito da eliminação de faixas de colheita em um mapa de produtividade de milho, e concluíram que seria possível representar adequadamente a variabilidade da área em relação ao mapa original, com os dados completos, eliminando-se até cinco faixas com dados de colheita. Isso revela que, em uma situação real, uma colhedora instrumentada para a geração do mapa de produtividade poderia operar em meio a outras cinco não instrumentadas em um mesmo talhão, e ainda representar bem a variabilidade da área.

Bazzi et al. (2008), avaliaram o efeito da eliminação de faixas de colheita em um mapa de produtividade na cultura do milho utilizando dois métodos de interpolação para a geração dos mapas e concluíram que até três faixas podem ser eliminadas para um nível arbitrário de 10% do coeficiente de desvio relativo (CDR) com o uso do método do inverso da distância ao quadrado para a interpolação. Já na interpolação com o uso do método da Krigagem, concluíram que apenas uma faixa pode ser eliminada. Já para um nível arbitrário de 5% do CDR, nenhuma faixa pode ser eliminada, para quaisquer métodos de interpolação.

O coeficiente de desvio relativo, proposto por Coelho (2006), expressa a diferença média, em módulo, dos valores interpolados em cada mapa, considerando um deles como mapa-padrão.

$$CDR = \sum_{i=1}^n \left| \frac{P_{ij} - P_{ipad}}{P_{ipad}} \right| \frac{100}{n}$$

em que,

n - número de pontos;

Pipad – produtividade no ponto i para o mapa padrão, e

Pij – produtividade no ponto i para o mapa j.

Cohen (1960) propôs outra técnica de comparação entre mapas denominada índice Kappa. O índice Kappa indica o quanto as observações divergem do que seria esperado. Segundo Congalton (1991), uma matriz de erro permite o cálculo do índice, através da fórmula:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} + x_{+i})}$$

em que,

K – índice Kappa de concordância;

N – número de observações;

r – número de linhas da matriz de erro;

x_{ij} – observações da linha i e coluna j;

x_{i+} - total marginal da linha i, e

x_{+i} – total marginal da coluna i.

Landis e Koch (1977) sugerem indicadores para interpretação do índice Kappa (Tabela 1).

Tabela 1. Índice Kappa e concordância	
Índice Kappa	Concordância
< 0,00	Insignificante
0,00 - 0,20	Fraca
0,21 - 0,40	Razoável
0,41 - 0,60	Moderada
0,61 - 0,80	Forte
0,81 - 1,00	Quase perfeita

A utilização de apenas uma colhedora equipada com o monitor de produtividade em meio a outras não instrumentadas poderia ser de grande utilidade

para muitos usuários. Porém, poucos são os estudos completos e mais aprofundados nessa linha, sendo um item que ainda demanda aprofundamento.

3. MATERIAL E MÉTODOS

Foram obtidos três conjuntos de dados de produtividade em uma propriedade rural localizada da região Oeste da Bahia, sob as coordenadas centrais 11°48'00"S e 46°01'00"O. O primeiro e o segundo conjunto de mapas foram obtidos de duas lavouras de soja, com 90 e 115 ha, denominadas como áreas 1 e 2, respectivamente. O terceiro conjunto é proveniente de uma lavoura de milho, de 305 ha (área 3). Todas as áreas (Figura 1) são de sequeiro e possuem relevo plano, com menos de 2% de declividade. O espaçamento de semeadura adotado em todas as áreas foi de 0,6m.



Figura 1. Representação esquemática das áreas.

As áreas 1 (soja) e 3 (milho) possuem mais de 20 anos de cultivo, produtivas e com solo em boas condições de fertilidade, manejadas sob o sistema de produção plantio direto. A área 2, cultivada com soja, possui apenas quatro anos de cultivo, menor fertilidade e também é manejada sob o sistema de produção plantio direto.

As áreas 1 e 2, cultivadas com soja, foram colhidas do dia 26 ao dia 28 de março de 2018 e do dia 28 ao dia 31 de março de 2018, respectivamente. A área 3, de milho, foi colhida do dia 03 de maio ao dia 07 de julho de 2018, onde houveram

diversas pausas por longos períodos em função de problemas de estocagem. Em todos os casos as condições de colheita eram ideais.

Na colheita foram utilizadas duas colhedoras automotrizes, modelo JD STS 9770 (John Deere, Horizontina, RS), equipadas de fábrica com a instrumentação necessária para o monitoramento da produtividade. O sensor de produtividade de ambas as colhedoras é do tipo gravimétrico. Na colheita da soja as colhedoras estavam equipadas com plataformas modelo Hidraflex 630F (John Deere, Horizontina, RS), com 9,14m de largura útil. Na colheita do milho foi utilizada apenas uma das colhedoras utilizadas na colheita das áreas de soja, equipada com uma plataforma despigadora de milho modelo Bocuda 4120 (Vence Tudo, Ibirubá, RS) com capacidade para nove fileiras e largura útil de 5,4m. Os monitores de produtividade estavam equipados com receptores GNSS com correção diferencial via satélite, com erro médio de aproximadamente 0,15 m, segundo o fabricante. As colhedoras possuíam correção automática da largura de corte, de modo que eram descontadas eventuais sobreposições, o que é frequente em passadas de arremate. Para isso, o monitor de colheita instalado nas colhedoras divide a plataforma em seis seções iguais de 1,5m, no caso da plataforma de soja, e em seis seções iguais de 0,9m, no caso da plataforma despigadora de milho. Isso mitiga eventuais erros de largura incorreta da plataforma, mas essa resolução de apenas um sexto da largura da plataforma ainda pode levar a ocorrência de erros. O corte de apenas quatorze linhas de soja, por exemplo (a plataforma possui capacidade para quinze), não levaria à correções automáticas da largura de corte, uma vez a resolução da correção automática não é atingida. Esse problema também ocorreu em algumas passadas realizadas na área 3, de milho. Mesmo com a correção automática da largura de corte, erros de largura incorreta da plataforma ocorreram devido a erros do operador, onde, nos casos de arremates, a colhedora não poderia realizar a passada com parte da plataforma em uma área colhida por outra colhedora, sob pena de a correção automática não ser realizada.

Houve ainda um problema de calibração das colhedoras nas áreas 1 e 2, cultivadas com soja. Apesar de realizado o procedimento de calibração, as colhedoras apresentaram divergências quanto às suas calibrações. Assim, uma delas superestimava consideravelmente a produtividade real da área. Esse problema foi corrigido com base na metodologia proposta por Maldaner et al. (2016), e foi o primeiro passo a ser realizado. Ainda que, mesmo com a correção, esse

problema tenha prejudicado a qualidade dos dados em alguma medida, o fato de todos os tratamentos serem oriundos de um mapa comum, que é a testemunha, fez com que esses dados fossem passíveis de ser utilizados.

Os dados coletados nas colhedoras foram gravados em um *pendrive* e exportados para um computador, por meio do software APEX, próprio da marca John Deere, em formato csv, prontos para serem processados no Sistema de Informação Geográfica (SIG) QGIS versão 2.14.17.

No processamento dos dados, o segundo passo foi realizar a eliminação das faixas de colheita. Isso foi feito anteriormente a quaisquer etapas de filtragens, uma vez que o objetivo era realizar a simulação de uma colheita com apenas uma colhedora equipada para o monitoramento da produtividade em meio a outras colhedoras.

Trabalhou-se com o cenário de dados completos de cada talhão (testemunha) e com a simulação de coleta de dados com uma colhedora equipada com o monitor de colheita e uma, duas, três, quatro e cinco colhedoras não equipadas com o monitor de colheita (tratamentos um, dois, três, quatro e cinco, respectivamente), sempre operando em comboio. A Figura 2 exemplifica o procedimento para a definição dos tratamentos.




Figura 2. Testemunha (A); duas colhedoras, uma com e uma sem o monitor de colheita (B); três colhedoras, uma com e duas sem o monitor de colheita (C).

Os dados gerados após a eliminação das faixas de colheita foram então submetidos à etapa de filtragem para a identificação e remoção de erros seguindo a metodologia descrita por Menegatti (2002). Basicamente, os principais passos adotados foram a remoção de pontos com produtividade nula e com erros grosseiros de posicionamento, seguidos por um corte estatístico inferior e superior, realizado pelo software *MapFilter* 2.0, proposto por Maldaner et al. (2018). Também com o uso do software, foi realizada uma filtragem de pontos errôneos através da análise do coeficiente de variação. Uma série de análises preliminares foram realizadas para determinar qual seriam os parâmetros adotados pelo software para a realização da filtragem. Foi escolhida a combinação que resultou no menor coeficiente de variação do conjunto de dados, concomitantemente com a menor quantidade de dados descartados possível e menor alteração nos valores máximos, mínimos e da média

entre os tratamentos. Para a filtragem global, escolheu-se a variação máxima do limite de 40%, 30% e 25% para as áreas 1, 2 e 3, respectivamente. Em cada área, o mesmo valor foi utilizado para todos os tratamentos. Na filtragem local, o raio de análise escolhido foi de uma 1,5 vezes a distância entre passadas, o que implica em diferentes raios de análise para cada tratamento. A variação máxima do limite para a filtragem local foi de 10% para todas as áreas e todos os tratamentos.

Após as filtragens, os dados dos mapas foram interpolados com a utilização de dois métodos de interpolação diferentes. Foi utilizado o método da Krigagem simples e o método do inverso da distância elevado ao quadrado (IQD). Na Krigagem simples, um único semivariograma teórico, obtido através do semivariograma empírico, é utilizado para a interpolação em toda a área. Foram feitas tentativas de usar a Krigagem ordinária, onde um semivariograma local é calculado para cada ponto estimado. Entretanto não foram obtidos bons resultados preliminares, apenas a geração de mapas totalmente desconexos. O tamanho do pixel utilizado na interpolação foi de 5m x 5m.

Em função da Krigagem ter sido escolhida como um dos métodos de interpolação para a geração dos mapas, foi feita uma análise da dependência espacial em todos os conjuntos de dados, para constatar a existência de dependência espacial, necessária para a interpolação.

Para a análise de concordância entre a testemunha e os demais tratamentos foi realizada uma análise da estatística descritiva, do coeficiente de desvio relativo e do índice Kappa de concordância. Foi realizada também uma análise de regressão, onde o Coeficiente de Correlação de Pearson e a raiz do erro quadrático médio (RMSE) puderam ser observados.

4. RESULTADOS E DISCUSSÃO

As figuras 2 e 3 apresentam os mapas de dados brutos referentes às áreas 1 e 2, respectivamente, ambas cultivadas com soja, antes do processamento para a eliminação do problema causado pela calibração diferente das colhedoras.




Figura 2. Mapa de produtividade dos dados brutos referentes à área 1, antes da correção de calibração




Figura 3. Mapa de produtividade dos dados brutos referentes à área 2, antes da correção de calibração

É possível notar, pelas Figuras 2 e 3, a clara distinção entre as duas colhedoras, em função da diferença de calibração. A área colhida por cada uma está claramente demarcada, onde uma das colhedoras superestima a produtividade.

As Figuras 4, 5 e 6 apresentam os mapas de dados brutos referentes às áreas 1, 2 e 3, respectivamente, onde já foi feito, para as áreas 1 e 2, cultivadas com soja, a correção do problema de calibração segundo a metodologia proposta por Maldaner et al. (2016).




Figura 4. Mapa de produtividade dos dados brutos referentes à área 1




Figura 5. Mapa de produtividade dos dados brutos referentes à área 2




Figura 6. Mapa de produtividade dos dados brutos referentes à área 3

Observando os mapas de dados brutos é possível constatar uma grande quantidade de ruídos provenientes de manobras de cabeceira e largura incorreta da plataforma, em algumas passadas, o que é mais frequente na área 3. Existem também valores discrepantes de produtividade, extremamente altos, não condizentes com o potencial produtivo das culturas, motivos pelos quais a etapa de filtragem é importante.

Em sequência a aquisição dos dados brutos, foi realizada a etapa de filtragens. Os mapas filtrados oriundos da testemunha, sem a exclusão de faixas de colheita, podem ser visualizados nas figuras 7, 8 e 9, para as áreas 1, 2 e 3, respectivamente.




Figura 7. Mapa de produtividade dos dados brutos referentes à área 1, após a filtragem




Figura 8. Mapa de produtividade dos dados brutos referentes à área 2, após a filtragem




Figura 9. Mapa de produtividade dos dados brutos referentes à área 3, após a filtragem

As figuras 7, 8 e 9 permitem observar a grande quantidade de dados errôneos que foram eliminados dos conjuntos de dados brutos, muitos dos quais eram provenientes de manobras de cabeceira e erros de largura incorreta da plataforma.

As Tabelas 2, 3 e 4 apresentam a estatística descritiva dos dados brutos e filtrados referentes às áreas 1, 2 e 3, respectivamente:

A partir da análise da estatística descritiva dos conjuntos de dados brutos e filtrados, é possível perceber que uma parcela substancial de pontos foi eliminada em todas as áreas. Foram removidos de 37 a 43 % dos dados provenientes da área 1, de 38 a 43 % da área 2 e de 47 a 49 % da área 3. Isso mostra que, percentualmente, a quantidade de dados removidos foi parecida em todos os tratamentos. Bigolin (2016), trabalhando com filtragem de dados de produtividade, eliminou de 20 a 25% dos dados de produtividade de soja e milho provenientes do seu conjunto de dados. Essa grande quantidade de dados errôneos está associada às diversas fontes de erros em mapas de produtividade. Assim, a quantidade necessária de dados removidos para a obtenção de um bom conjunto para a interpolação pode ser um reflexo da qualidade de obtenção dos dados no momento da colheita. Dessa maneira, todos os fatores que influenciam na qualidade da coleta devem ser atentamente observados, uma vez que filtrações mais rigorosas representam um risco maior de perda de dados consistentes.

Também possível perceber que a filtragem proporcionou uma melhora na qualidade do conjunto de dados, reduzindo grandemente os valores de desvio padrão em todos eles. O desvio padrão indica o quanto os valores das observações diferem, em média, da média do conjunto de dados, dando uma ideia da magnitude da variabilidade da área, ainda que não possa indicar nada espacializadamente. É possível inferir que a magnitude da variabilidade na área 1 é próxima a da área 2, sendo os valores de desvio padrão da área 1 um pouco maiores. A área 3, por sua vez, apresentou valores de desvio padrão bem mais elevados. Entre os tratamentos, os valores de desvio padrão se apresentaram semelhantes, com destaque para a área 3.

O coeficiente de variação também apresentou valores menores após a filtragem. Esse coeficiente engloba o peso do desvio padrão sobre a média dos dados. Assim, uma vez que todos os tratamentos apresentaram médias muito próximas, é possível interpreta-lo de maneira semelhante ao desvio padrão. Para corroborar com a confirmação da hipótese, é desejável que os valores de desvio padrão entre os tratamentos e a testemunha sejam tão próximos quanto possível.

Os valores de curtose foram drasticamente reduzidos em todos os conjuntos, para todos os tratamentos, o que indica a eliminação de dados errôneos com valores discrepantes de alta produtividade. Como também foi observado por Bigolin (2016), pontos com produtividades exageradamente baixas ou nulas foram eliminados,

muitos dos quais provenientes de manobras de cabeceira. Os valores de média, máximos e mínimos se mostraram adequados ao padrão de produtividade esperado para as culturas em todas as áreas e tratamentos após a filtragem.

As Tabelas 5, 6 e 7 apresentam a estatística descritiva dos mapas de produtividade resultantes da interpolação dos dados pelo método do inverso da distância ao quadrado, para as áreas 1, 2 e 3, respectivamente.

Tabela 5. Estatística descritiva dos dados resultantes da interpolação (IQD) dos dados filtrados para a área 1

Área 1						
Estatística Descritiva	Testemunha	Tratamento				
		1	2	3	4	5
N	35574	35574	35574	35574	35574	35574
Média (Kg ha ⁻¹)	5322	5348	5370	5376	5292	5347
Variância	39987,06	37753,91	35369,37	30380,59	22786,28	25159,74
Desvio Padrão (Kg ha ⁻¹)	199,97	194,30	188,07	174,30	150,95	158,62
CV(%)	3,76	3,63	3,50	3,24	2,85	2,97
Valor Mínimo (Kg ha ⁻¹)	3574	3791	3569	3958	3940	4190
Mediana	5335	5358	5381	5394	5301	5375
Valor Máximo (Kg ha ⁻¹)	7070	7183	7354	7174	6630	6627
Assimetria	0,13	0,13	0,62	0,63	-0,38	-0,89
Curtose	6,57	9,11	9,35	10,26	7,31	5,02

Tabela 6. Estatística descritiva dos dados resultantes da interpolação (IQD) dos dados filtrados para a área 2

Área 2						
Estatística Descritiva	Testemunha	Tratamento				
		1	2	3	4	5
N	44566	44566	44566	44566	44566	44566
Média (Kg ha ⁻¹)	4462	4470	4484	4475	4454	4490
Variância	24261,63	20378,65	18452,06	15020,56	20126,87	17253,73
Desvio Padrão (Kg ha ⁻¹)	155,76	142,75	135,84	122,56	141,87	131,35
CV(%)	3,49	3,19	3,03	2,74	3,19	2,93
Valor Mínimo (Kg ha ⁻¹)	3426,65	3424,07	3677,00	3334,36	3710,06	3513,96
Mediana	4465,26	4479,09	4486,81	4490,58	4466,27	4494,51
Valor Máximo (Kg ha ⁻¹)	5443,16	5259,49	5373,04	5212,87	5216,59	5218,86
Assimetria	-0,21	-0,31	-0,07	-0,31	-0,25	-0,42
Curtose	1,40	1,88	1,32	1,67	0,80	1,91

Tabela 7. Estatística descritiva dos dados resultantes da interpolação (IQD) dos dados filtrados para a área 3

Estatística Descritiva	Área 3					
	Testemunha	Tratamento				
		1	2	3	4	5
N	121244	121244	121244	121244	121244	121244
Média (Kg ha ⁻¹)	10428	10376	10412	10410	10306	10487
Variância	302094,24	318587,17	282932,89	287122,95	283763,60	267801,00
Desvio Padrão (Kg ha ⁻¹)	549,63	564,44	531,91	535,84	532,69	517,49
CV(%)	5,27	5,44	5,11	5,15	5,17	4,93
Valor Mínimo (Kg ha ⁻¹)	7976,13	7736,60	7847,53	8038,72	8097,79	8066,38
Mediana	10456,89	10432,78	10418,26	10405,70	10262,06	10489,14
Valor Máximo (Kg ha ⁻¹)	12851,89	12635,53	12597,19	12669,15	12566,85	12770,29
Assimetria	-0,23	-0,19	-0,11	0,04	0,21	-0,17
Curtose	0,15	-0,09	0,07	0,38	-0,12	0,31


A análise da estatística descritiva dos conjuntos de dados relativos aos mapas gerados com o uso da interpolação pelo método do inverso da distância ao quadrado revelou que o interpolador aproximou ainda mais os valores da média entre os tratamentos, tomando como referência os dados filtrados.

A interpolação causou uma diminuição dos valores do desvio padrão e do coeficiente de variação em todos os conjuntos de dados, que por sua vez diminuíram progressivamente a partir do tratamento um em direção ao tratamento 5, que representa a situação com a maior quantidade de dados eliminados. Isso indica que houve maior suavização, diminuindo a resolução na representação da variabilidade. A diminuição dos valores de desvio padrão em relação ao desvio padrão dos dados filtrados observados nas Tabelas 2, 3 e 4, parece indicar que ainda haviam pontos discrepantes em relação aos seus vizinhos que escaparam à filtragem, e que tiveram seus valores suavizados pelo interpolador.

A diminuição do desvio padrão e do coeficiente de variação não significa necessariamente uma melhora na qualidade do mapa, uma vez que esses valores são intrinsicamente condicionados pela variabilidade existente na área e existirão em alguma medida.

Houveram ainda oscilações maiores nos valores mínimos e máximos de produtividade entre os tratamentos na área 1, bem como valores mais altos de curtose, o que não foi observado nas outras áreas.

A Figura 6 apresenta os gráficos dos semivariogramas empíricos e teóricos utilizados em todos conjuntos de dados.






Figura 6. Semivariogramas empíricos e teóricos relativos aos dados filtrados, para todas as áreas e tratamentos.

Alguns semivariogramas não apresentaram um patamar bem definido, onde os valores de semivariância continuaram a aumentar em grandes distâncias, ainda que sensivelmente. Apesar de elevados, os valores de RMSE obtidos podem ser justificados pelos altos valores de semivariância observados.

Os parâmetros dos semivariogramas são apresentados na Tabela 8. Observa-se um grau de dependência moderado para todos os conjuntos, o que possibilita a utilização do método da Krigagem para realizar a interpolação.

Tabela 8. Parâmetros dos semivariogramas teóricos para todas as áreas e tratamentos

Área	Tratamento	Modelo	Efeito pepita	Contribuição	Patamar	Alcance	GDE (%)	DE
1	Testemunha	E	57467	83668	141135	16,74	40,32	M
	T1	E	49410	102081	151491	17,51	32,62	M
	T2	ED	49832	143660	193492	16,04	25,75	M
	T3	ED	52102	101974	154076	24,92	33,82	M
	T4	E	54816	68616	123432	69,08	44,41	M
	T5	G	74157	48770	122927	65,49	60,33	M
2	Testemunha	ED	70508	46740	117248	44,71	61,71	M
	T1	ED	53125	36628	89753	29,94	59,19	M
	T2	E	53259	38883	92142	59,57	57,80	M
	T3	E	50504	28811	79315	88,43	63,68	M
	T4	E	46773	48541	95314	87,11	49,07	M
	T5	E	46304	42771	89075	83,09	51,98	M
3	Testemunha	ED	295095	525488	820583	8,16	35,96	M
	T1	ED	266409	547617	814026	14,59	32,73	M
	T2	ED	230881	339700	570581	9,73	40,46	M
	T3	E	321388	429012	750400	105,80	42,83	M
	T4	ED	250606	416459	667065	29,57	37,57	M
	T5	E	267997	437589	705586	122,10	37,98	M

E: Exponencial, ED: Exponencial duplo, G: Gaussiano, DE: Dependência espacial, GDE: Grau de dependência espacial, M: Moderada

As Tabelas 9, 10 e 11 apresentam a estatística descritiva dos mapas de produtividade resultantes da interpolação dos dados pelo método da Krigagem para as áreas 1, 2 e 3, respectivamente.

Tabela 9. Estatística descritiva dos dados resultantes da interpolação (Krigagem) dos dados filtrados para a área 1

Estatística Descritiva	Área 1					
	Tratamento					
	Testemunha	1	2	3	4	5
N	35615	35615	35615	35615	35615	35615
Média (Kg ha ⁻¹)	5316	5339	5364	5371	5286	5348
Variância	79112.29	82368.34	68727.66	57915.85	44164.38	41967.65
Desvio Padrão (Kg ha ⁻¹)	281.27	287.00	262.16	240.66	210.15	204.86
CV(%)	5.29	5.38	4.89	4.48	3.98	3.83
Valor Mínimo (Kg ha ⁻¹)	3976	3877	4165	4131	4120	4327
Mediana	5328	5347	5375	5399	5290	5370
Valor Máximo (Kg ha ⁻¹)	7011	7061	7106	7022	6393	6314
Assimetria	0.34	0.13	0.33	0.35	-0.20	-0.78
Curtose	4.78	4.50	4.28	4.98	2.87	2.05

Tabela 10. Estatística descritiva dos dados resultantes da interpolação (Krigagem) dos dados filtrados para a área 2

Área 2						
Estatística Descritiva	Testemunha	Tratamento				
		1	2	3	4	5
N	44561	44561	44561	44561	44561	44561
Média (Kg ha ⁻¹)	4459	4470	4481	4471	4440	4485
Variância	28649.56	29489.36	31007.40	22412.48	35183.56	31278.95
Desvio Padrão (Kg ha ⁻¹)	169.26	171.72	176.09	149.71	187.57	176.86
CV(%)	3.80	3.84	3.93	3.35	4.22	3.94
Valor Mínimo (Kg ha ⁻¹)	3764	3752	3877	3964	3811	3762
Mediana	4464	4477	4484	4484	4455	4486
Valor Máximo (Kg ha ⁻¹)	4975	5000	4975	4926	4964	4976
Assimetria	-0.31	-0.32	-0.17	-0.34	-0.29	-0.36
Curtose	0.02	0.18	-0.33	-0.15	-0.28	0.20

Tabela 11. Estatística descritiva dos dados resultantes da interpolação (krigagem) dos dados filtrados para a área 3

Área 3						
Estatística Descritiva	Testemunha	Tratamento				
		1	2	3	4	5
N	121247	121247	121247	121247	121247	121247
Média (Kg ha ⁻¹)	10393	10347	10369	10374	10268	10447
Variância	456278.67	500889.12	468196.25	491039.86	477653.16	479751.73
Desvio Padrão (Kg ha ⁻¹)	675.48	707.74	684.25	700.74	691.12	692.64
CV(%)	6.50	6.84	6.60	6.75	6.73	6.63
Valor Mínimo (Kg ha ⁻¹)	8208	8143	8166	8359	8218	8445
Mediana	10443	10417	10395	10359	10233	10454
Valor Máximo (Kg ha ⁻¹)	12214	12335	12212	12314	12127	12224
Assimetria	-0.30	-0.20	-0.18	0.09	0.17	-0.19
Curtose	-0.25	-0.44	-0.31	0.00	-0.46	-0.25

A análise da estatística descritiva dos conjuntos de dados relativos aos mapas gerados com o uso da interpolação pelo método Krigagem revelou maiores coeficientes de variação em todas as áreas e tratamentos, em relação ao inverso da distância ao quadrado como interpolador, ainda que a diferença não tenha sido tão expressiva.

De modo geral, os resultados apresentados pela estatística descritiva com o uso desse interpolador se assemelharam muito aos resultados apresentados pela estatística descritiva com o uso do inverso da distância ao quadrado como interpolador.

É possível destacar ainda que os valores de curtose para a área 1 permaneceram elevados em relação às outras áreas. Todos os conjuntos de dados apresentaram distribuição normal e simétrica.

Nas Figuras 10, 11 e 12 estão representados os mapas de produtividade para as áreas 1, 2 e 3, respectivamente, para todos os tratamentos, interpolados pelo método do inverso da distância ao quadrado.




Figura 10. Mapas de produtividade referentes à área 1, com o uso da interpolação pelo IQD. Figuras A, B, C, D, E e F: testemunha, tratamento um, dois, três, quatro e cinco, respectivamente.




Figura 11. Mapas de produtividade referentes à área 2, com o uso da interpolação pelo IQD. Figuras A, B, C, D, E e F: testemunha, tratamento um dois, três, quatro e cinco, respectivamente.




Figura 12. Mapas de produtividade referentes à área 3, com o uso da interpolação pelo IQD. Figuras A, B, C, D, E e F: testemunha, tratamento um, dois, três, quatro e cinco, respectivamente.

A magnitude da variabilidade das áreas não se mostrou muito alta, principalmente nas áreas 1 e 2, cultivadas com soja, onde a maior parte das variações de produtividade se encontram relativamente próximas à média, como mostra o desvio padrão na estatística descritiva. A amplitude dos dados também se mostrou alta, se comparada com o desvio padrão. Isso pode dificultar a visualização, a depender da classificação de cores a ser realizada. Por isso, foi utilizado na classificação um maior número de classes no intervalo de produtividade que se encontra entre os quartis um e três. Os dados restantes, com valores abaixo do quartil um, foram divididos em duas classes, a partir do quartil um até o valor mínimo. Da mesma maneira, os dados com valores maiores que o valor do quartil três também foram divididos em duas classes, partindo do quartil três até o valor máximo. Em cada área, a classificação foi igual para os dois métodos de interpolação e para todos os tratamentos, para permitir a sua comparação. Esse procedimento possibilitou uma boa análise visual da variabilidade, sem ocorrência de tendenciosidades.

Visualmente, analisando da Figura 10, é possível observar que a variabilidade da produtividade expressa pela testemunha se manteve nos tratamentos de um a três, apesar da progressiva degradação da qualidade do mapa. Os tratamentos quatro e cinco mostraram uma dissonância maior em relação à testemunha, apresentando resultados piores e perda de qualidade. Na Figura 11, que representa a área 2 (soja) podemos observar que, de modo geral, a variabilidade expressa pela testemunha manteve-se em todos os tratamentos, com resultados mais satisfatórios em do que na área 1, representada pela Figura 10. A área 3, cultivada com milho, representada pela Figura 12 também seguiu um padrão semelhante.

De maneira geral, é possível notar concordância entre os tratamentos e a testemunha, para as três áreas, apesar de ter havido discordâncias em algumas regiões específicas nas em todas as áreas, principalmente nos tratamentos quatro e cinco, onde mais faixas de colheita foram eliminadas.

Nas Figuras 13, 14 e 15 estão representados os mapas de produtividade para as áreas 1, 2 e 3, respectivamente, para todos os tratamentos, interpolados pelo método da Krigagem.




Figura 13. Mapas de produtividade referentes à área 1, com o uso da interpolação pelo método da Krigagem. Figuras A, B, C, D, E e F: testemunha, tratamento um, dois, três, quatro e cinco, respectivamente.




Figura 14. Mapas de produtividade referentes à área 2, com o uso da interpolação pelo método da Krigagem. Figuras A, B, C, D, E e F: testemunha, tratamento um, dois, três, quatro e cinco, respectivamente.




Figura 15. Mapas de produtividade referentes à área 3, com o uso da interpolação pelo método da Krigagem. Figuras A, B, C, D, E e F: testemunha, tratamento um, dois, três, quatro e cinco, respectivamente.

A variabilidade expressa nas três áreas com o uso deste interpolador se mostrou muito fiel à variabilidade expressa com o uso do outro método, mostrando as mesmas discordâncias entre os tratamentos e as testemunhas. A diferença marcante é a suavização do mapa, mitigando o efeito de dados discrepantes ainda restantes e diminuindo o peso, por vezes excessivo, de dados muito próximos do ponto estimado, o que é muito facilmente observado nas Figuras 10, 11 e 12. Assim, não foram observadas diferenças expressivas entre os métodos de interpolação.

Os resultados são semelhantes aos de Shiratsuchi et al. (2004), que trabalharam com exclusão de faixas de colheita, onde até dez faixas foram eliminadas do mapa original. Os autores puderam observar que, visualmente, houve boa concordância entre o conjunto de dados original e os tratamentos, onde os dados foram eliminados, mostrando que as grandes tendências da distribuição da variabilidade foram mantidas.

A Tabela 12 apresenta os resultados referentes à análise do índice Kappa, onde foi realizada a comparação entre a testemunha e todos os tratamentos.

Tabela 12. Índice Kappa na comparação entre a testemunha e os tratamentos, para todas as áreas e métodos de interpolação

	Índice Kappa									
	IQD					Krigagem				
	T1	T2	T3	T4	T5	T1	T2	T3	T4	T5
Área 1	0,754	0,668	0,523	0,516	0,441	0,774	0,717	0,567	0,464	0,393
Área 2	0,780	0,661	0,615	0,595	0,544	0,846	0,728	0,694	0,620	0,619
Área 3	0,585	0,533	0,515	0,423	0,433	0,531	0,449	0,398	0,358	0,333

Pode ser observada a progressiva diminuição do índice à medida que mais faixas de colheita são eliminadas, o que indica cada vez menos concordância entre a testemunha e os tratamentos. Apenas a área 2 apresentou um comportamento diferente, onde a queda do índice foi menos intensa do que nas demais áreas, especialmente para os mapas oriundos da interpolação pelo método da Krigagem.

Segundo Landis e Koch (1977), a concordância entre os tratamentos e as testemunhas variou, para as três áreas, de moderada a forte, em geral, o que parece ser condizente com a análise visual apresentada acima. Isso revela que apesar da progressiva degradação da qualidade, podemos, segundo esse índice, obter dados satisfatórios, uma vez que pôde ser obtida uma concordância moderada para a maioria dos conjuntos de dados.

A Tabela 13 apresenta os resultados referentes à análise do coeficiente de desvio relativo (CDR).

Tabela 13. Coeficiente de desvio relativo na comparação entre a testemunha e os tratamentos, para as três áreas e os dois métodos de interpolação

	CDR (%)									
	IQD					Krigagem				
	T1	T2	T3	T4	T5	T1	T2	T3	T4	T5
Área 1	1,700	2,049	2,385	2,223	2,479	2,656	2,908	3,343	3,449	3,756
Área 2	1,488	1,976	1,990	2,228	2,371	1,689	2,242	2,197	2,748	2,753
Área 3	1,893	2,033	2,444	2,606	2,598	2,559	2,808	3,466	3,560	3,651


O coeficiente de desvio relativo representa o quanto varia a média dos desvios dos tratamentos, para cada ponto, em relação à média do conjunto de dados da testemunha. Podemos observar na Tabela 13 que os valores aumentam à medida que mais faixas de colheita são eliminadas, uma vez que, quanto maior o índice, menor a concordância. Esse efeito é muito parecido com o que foi observado na análise do índice Kappa, onde os valores diminuíram progressivamente, indicando menor concordância. Entretanto, apesar desse aumento progressivo, os

valores se mostraram sempre próximos e baixos. Isso sugere que a eliminação de faixas de colheita não causou grandes diferenças entre os tratamentos e a testemunha. O fato de os valores serem próximos sugere ainda que os tratamentos não diferem muito entre si. O índice Kappa, entretanto, não corrobora com essa observação, uma vez que a variação do índice entre os tratamentos foi bem mais significativa.






Bazzi et al. (2008) também trabalharam com exclusão de faixas de colheita em mapas de produtividade, onde analisaram o índice Kappa e o coeficiente de desvio relativo. Os autores também constataram a diminuição progressiva do índice Kappa e o aumento progressivo do coeficiente de desvio relativo à medida que mais faixas de colheita eram eliminadas. Entretanto, observaram que os valores do coeficiente de desvio relativo foram sempre maiores, concomitantemente com valores menores do índice Kappa.

As Figuras 16, 17, 18 apresentam os gráficos resultantes da análise de correlação realizada entre a testemunha e os tratamentos em todas as áreas, para os dois métodos de interpolação.

Área 1
IQD



Área 1
Krigagem












Figura 16. Análise de regressão entre a testemunha e os tratamentos para a área 1 e os dois métodos de interpolação.

Área 2
IQD



Área 2
Krigagem












Figura 17. Análise de regressão entre a testemunha e os tratamentos para a área 2 e os dois métodos de interpolação.

**Área 3
IQD**



**Área 3
Krigagem**






Figura 18. Análise de regressão entre a testemunha e os tratamentos para a área 3 e os dois métodos de interpolação.

As Figuras 16, 17 e 18 mostram que o coeficiente de correlação de Pearson diminui à medida que mais faixas de colheita são eliminadas do conjunto de dados, concomitantemente com o aumento do RMSE, sugerindo degradação da qualidade do mapa. Isso também pôde ser observado na análise do índice Kappa e do CDR. Shiratsuchi et al. (2004) também analisaram o coeficiente de correlação de Pearson em seus trabalhos, onde constataram um comportamento semelhante.

De modo geral, o coeficiente de correlação se mostrou sempre maior quando o método da Krigagem foi utilizado para a interpolação nas áreas 1 e 2, cultivadas com soja. Estranhamente, na área 3 (milho) foi observado o oposto. Isso sugere, para as áreas 1 e 2, que a Krigagem promoveu a geração dos mapas de maneira mais suavizada, e esperava-se que isso também ocorresse na área 3. A menor

largura da faixa de colheita utilizada na área 3, de 5,4 m, contra 9 m nas áreas 1 e 2, talvez tenha contribuído para um menor efeito de suavização da interpolação pela Krigagem em relação ao IQD, uma vez que os dados mais densos, em função da menor largura da plataforma, permitiram ao IQD interpolar os dados tão suavizadamente quanto a Krigagem.

Nas áreas 1 e 2 (soja), o coeficiente angular das retas obtidas com a regressão linear permaneceram distantes do valor um, em todos os tratamentos, independentemente do interpolador utilizado, o que não seria desejável. Isso sugere que podem ter ocorrido diferenças sistemáticas nos valores absolutos estimados em cada ponto, ainda que a variabilidade possa ter sido corretamente representada. Isso não condiz com o que pôde ser observado na estatística descritiva, onde, em geral, os valores da média, mediana, e os valores máximos e mínimos de produtividade foram parecidos entre os tratamentos e as testemunhas das duas áreas. Já para a área 3 (milho), o coeficiente angular se manteve mais próximo do valor um.

Pode-se notar também que, em geral, o valor do RMSE foi maior nos mapas em que a interpolação pelo método da Krigagem foi utilizada, aumentando progressivamente à medida que mais faixas são excluídas.

5. CONCLUSÃO

A filtragem dos dados se mostrou indispensável para a geração de mapas de produtividade confiáveis, uma vez que puderam ser constatados muitos dados errôneos, comuns em dados provenientes de monitores de produtividade.

A interpolação por Krigagem e inverso da distância não gerou diferenças expressivas nos mapas em quaisquer áreas ou tratamentos.

Na área 1, a exclusão de até quatro faixas de colheita não impactou significativamente na qualidade final do mapa obtido, permitindo o adequado entendimento da variabilidade expresso pela testemunha. Nas áreas 2 e 3 a remoção de até cinco faixas de colheita não impossibilitou o entendimento da variabilidade da área.

Os resultados mostraram ser possível realizar a colheita com apenas uma colhedora instrumentada para o monitoramento da produtividade da lavoura em meio a até quatro outras colhedoras não instrumentadas, desde que operando em comboio e intercaladamente, mantendo a confiabilidade e o padrão real de variabilidade expressa pela área.

REFERÊNCIAS BIBLIOGRÁFICAS

- BALASTREIRE, L. A. Estudo de caso, uma pesquisa brasileira em agricultura de precisão. **SILVA, FM.; BORGES, PH de M. Mecanização e agricultura de precisão. Lavras: UFLA/SBEA**, p. 203-32, 1998.
- BATCHELOR, Bill. **Precision agriculture: introduction to precision agriculture**. Iowa State University, University Extension, 1997.
- BAZZI, Cláudio L. et al. Influência da distância entre passadas de colhedora equipada com monitor de colheita na precisão dos mapas de produtividade na cultura do milho. **Engenharia Agrícola**, v. 28, n. 2, p. 355-363, 2008.
- BETZEK, N. M.; SOUZA, E. G.; BAZZI, C. L.; MATTÉ, M. A.; SCHENATTO, K. Influência do método de interpolação na produtividade de soja em duas áreas amostrais. In: **CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO**. São Pedro – SP, 2014.
- BIGOLIN, G. L. Análise do desempenho do aplicativo *Map Filter* na limpeza de dados errôneos gerados por monitores de produtividade. **Piracicaba, SP**, 2016.
- BLACKMORE, B. S.; MARSHALL, C. J. Yield mapping; errors and algorithms. **Precision agriculture**, n. precisionagricu3, p. 403-415, 1996.
- CAMBARDELLA, C. A. et al. Field-scale variability of soil properties in central Iowa soils. **Soil science society of America journal**, v. 58, n. 5, p. 1501-1511, 1994.
- COELHO, Edy Célia et al. Influência da densidade amostral e do tipo de interpolador na elaboração de mapas temáticos. 2006. 116 f. Dissertação (Mestrado em Engenharia de Sistemas Agroindustriais) – Universidade Estadual do Oeste do Paraná, Cascavel, 2006.
- COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v. 20, n. 1, p. 37-46, 1960.
- CONGALTON, Russell G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment**, v. 37, n. 1, p. 35-46, 1991.
- GENTIL, L. V.; FERREIRA, S. M. Agricultura de precisão: Prepare-se para o futuro, mas com os pés no chão. **Revista A Granja, Porto Alegre**, n. 610, p. p12-17, 1999.
- GIMENEZ, Leandro M.; MOLIN, José Paulo. Algoritmo para redução de erros em mapas de produtividade para agricultura de precisão. **Revista Brasileira de Agrocomputação**, v. 2, n. 1, p. 5-10, 2004.

LANDIS, J. Richard; KOCH, Gary G. The measurement of observer agreement for categorical data. **Biometrics**, p. 159-174, 1977.

MALDANER, Leonardo F. et al. Processing yield data from two or more combines. **13th international conference on precision agriculture**. 2016.

MALDANER, Leonardo F. et al. Identifying and filtering out outliers in spatial datasets. 2018.

MAZZINI, P. L. F.; SCHETTINI, Carlos Augusto França. Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quase-sinóticos. **Brazilian Journal of Aquatic Science and Technology**, v. 13, n. 1, p. 53-64, 2009.

MENEGATTI, Leonardo Afonso Angeli et al. Metodologia para identificação, caracterização e remoção de erros em mapas de produtividade. **Piracicaba, SP**, 2002.

MICHELON, Gabriela Karoline et al. Função para determinação de melhores parâmetros para o interpolador inverso da distância. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 8, n. 15, p. 1, 2017.

MOLIN, José P. Geração e interpretação de mapas de produtividade para agricultura de precisão. **BORÉM, A.; GIÚDICE, MP; QUEIROZ, DM; MANTOVANI, EC**, p. 237-58, 2000.

MOLIN, J. P. et al. Acurácia de um monitor de produtividade com sensor de fluxo volumétrico. In: **CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA**. 2000.

MOLIN, José Paulo. **Agricultura de precisão: o gerenciamento da variabilidade**. 2008.

MOLIN, José Paulo; DO AMARAL, Lucas Rios; COLAÇO, André. **Agricultura de precisão**. Oficina de Textos, 2015.

MOORE, M. **Investigation in to the accuracy of yield maps and their subsequent use in crop management**. 1997. Tese de Doutorado. Ph. D Thesis. Cranfield University. Silsoe college.

SEARCY, Stephen W. **Precision farming: A new approach to crop management**. Texas Agricultural Extension Service, Texas A & M University System, 1997.

SHIRATSUCHI, L. S.; MACHADO, ALT; FACCIONI, G. C. Geração de mapas de produtividade de milho: efeito do espaçamento entre faixas de colheita. In: **CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO**. Piracicaba: ESALQ/USP, 2004.

SPEKKEN, M. A. R. K.; ANSELM, A. A.; MOLIN, J. P. A simple method for filtering spatial data. In: **Precision agriculture'13**. Wageningen Academic Publishers, Wageningen, 2013. p. 259-266.

TUKEY, John W. **Exploratory data analysis**. 1977.

VIEIRA, S. R. J. L. et al. Geostatistical theory and application to variability of some agronomical properties. **Hilgardia**, v. 51, n. 3, p. 1-75, 1983.

WEBER, Dennis; ENGLUND, Evan. Evaluation and comparison of spatial interpolators. **Mathematical Geology**, v. 24, n. 4, p. 381-391, 1992.

YAMAMOTO, Jorge Kazuo; LANDIM, Paulo M. Barbosa. **Geoestatística: conceitos e aplicações**. Oficina de textos, 2015.