

MAPEAMENTO DA PRODUTIVIDADE UTILIZANDO IMAGENS DE SATÉLITE, PRODUÇÃO DA LAVOURA E FUNÇÃO DENSIDADE DE PROBABILIDADE

RICARDO CANAL FILHO¹, MARCELO CHAN FU WEI¹, EUDOCIO RAFAEL OTAVIO DA SILVA², JOSÉ PAULO MOLIN³

¹ Engenheiro agrônomo, Doutorando, Depto. De Engenharia de Biossistemas, Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba – SP. Fone: (019)3447-8579, ricardocanal@usp.br

² Engenheiro agrícola e ambiental, Doutorando, Depto. De Engenharia de Biossistemas, Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba – SP. Fone: (019)3447-8579

³ Engenheiro agrícola, Professor Titular, Depto. De Engenharia de Biossistemas, Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba – SP. Fone: (019)3447-8579

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Porto Alegre, RS, 02 a 04 de julho de 2024

RESUMO: A obtenção de mapas de produtividade depende de métodos onerosos para coleta dos dados, calibrações constantes e tecnologias embarcadas em máquinas. Isso limita a adesão a esta tecnologia e o impacto positivo que essa camada de dados pode fornecer ao setor agropecuário. Este trabalho desenvolveu uma metodologia simples para mapear a produtividade de culturas agrícolas, com dados de fácil acesso ao setor produtivo: produção total por área e imagens de satélite. Utilizou-se dois anos consecutivos em duas áreas cultivadas com café e cana-de-açúcar, respectivamente. Gerou-se uma função de distribuição da produção total recuperada da lavoura a partir de imagens de satélite de momentos-chave da fenologia das culturas, por meio da função densidade de probabilidade e índices de vegetação. Os vetores de produtividade gerados foram comparados à produtividade observada e obtida por monitores comerciais, previamente validados. Os resultados reportaram correlação ($p < 0,01$) entre o predito e observado para todos os anos e culturas, com erros de predição comparáveis a outros métodos da literatura. A distribuição espacial dos valores também foi consistente entre os métodos, demonstrando potencial robusto para apoiar decisões de gestão. A metodologia apresentada pode ser uma alternativa viável a um amplo espectro de sistemas produtivos, manuais, semimecanizados ou mecanizados, uma vez que independe de maquinário, podendo impulsionar a adoção de práticas de agricultura de precisão.

PALAVRAS-CHAVE: geostatística, índices de vegetação, sensoriamento remoto

YIELD MAPPING USING SATELLITE IMAGERY, TOTAL FIELD PRODUCTION AND PROBABILITY DENSITY FUNCTION

ABSTRACT: The acquisition of yield maps relies on costly methods for data collection, constant calibrations, and technologies embedded in machinery. This limits the adoption of this technology and the positive impact that this layer of data can provide to the agricultural sector. This study developed a simple methodology for mapping the productivity of agricultural crops, using easily accessible data for the productive sector: total production per area and satellite images. Two consecutive years were used in two areas cultivated with coffee and sugarcane, respectively. A distribution function of total recovered crop production was generated from satellite images of key moments in crop phenology, through the probability density function of vegetation indices. The yield vectors generated were compared to the observed yield by previously validated commercial monitors. The results reported significant correlation ($p < 0.01$) between predicted and observed yield for all years and crops, with prediction errors comparable to other methods in the literature. The spatial distribution of values was also consistent among methods, demonstrating robust potential to support management decisions. The methodology presented can be a viable alternative to a wide range of productive systems, manual, semi-mechanized, or mechanized, as it does not depend on machinery, thus, it can boost the adoption of precision agriculture practices.

KEYWORDS: geostatistics, vegetation indices, remote sensing

INTRODUÇÃO: Os mapas de produtividade são o resultado da interação entre variáveis no espaço e tempo de uma cultura, podendo ser o ponto de partida para diversas investigações e decisões de gestão em busca de maior sustentabilidade produtiva (GEBBERS et al., 2010). Entretanto, a obtenção dessa camada é restrita e dependente da cultura, principalmente por questões relacionadas a métodos onerosos para obtenção dos dados

(i.e., coleta manual), necessidade de tecnologias embarcadas em máquinas e calibrações constantes para garantir a qualidade do dado gerado. Todos esses fatores limitam o impacto positivo que essa camada de dados pode fornecer ao setor agropecuário (CARRER et al., 2022; LONGCHAMPS et al., 2022).

Em consequência da baixa adesão dos mapas de produtividade, todo o ciclo da agricultura de precisão (AP) pode ser comprometido. Decisões que dependem da quantidade produzida por área, tanto no tempo como no espaço, tornam-se ineficientes. São exemplos a adubação por exportação da cultura, decisão de reforma de lavouras em culturas perenes ou semiperenes, investigação de problemas pontuais como pragas e doenças, índices de lucratividade, etc.

Dessa forma, como alternativa à obtenção dos dados de produtividade por métodos manuais, semimecanizados ou mecanizados, tem-se os métodos a partir de sensoriamento orbital. Entretanto, a maioria dos estudos com sensoriamento orbital são dependentes da camada de produtividade para realizar a predição, o que novamente torna a sua adoção limitada (AMANKULOVA et al., 2024; NARVEKAR & RAO, 2024). Mas o dado de produção por área/talhão é mais disponível para a maioria dos produtores, bem como dados de sensoriamento orbital têm se popularizado pela facilidade de obtenção. Assim, torna-se oportuno investigar a possibilidade de mapear a produtividade de culturas agrícolas a partir de dados aos quais o setor produtivo possui mais acesso.

Levando em consideração o conhecimento acumulado na literatura quanto a fisiologia do crescimento e desenvolvimento dos cultivos, formulou-se a hipótese de que, utilizando apenas imagens de satélite, a totalização da produção de uma lavoura e funções estatísticas de densidade de probabilidade, é possível redistribuir a produção total de uma área, chegando ao mapa de produtividade daquela cultura. Dessa forma, o presente trabalho propõe um método simples de obtenção de mapas de produtividade para diferentes culturas agrícolas, que independe de sistemas de colheita.

MATERIAL E MÉTODOS: Para aferir o potencial da técnica em diferentes cenários, o estudo foi realizado: (i) em duas áreas com diferentes cultivos, café e cana-de-açúcar; (ii) dois anos consecutivos, para dar robustez às análises geradas. As informações referentes a cada área estão dispostas na Tabela 1.

TABELA 1. Caracterização das duas áreas utilizadas no presente estudo.

	Área 1	Área 2
Cultura	café arábica	cana-de-açúcar
Variedade	IAC Catuaí 144	SP83-2847
Espaçamento	4,0 m x 0,5 m	1,5 m entrelinhas
Safrá/produção	2020 (12 ^a safra) / 22,31 Mg	2018 (4 ^o corte) / 1974,71 Mg
	2021 (13 ^a safra) / 15,78 Mg	2019 (5 ^o corte) / 1901,80 Mg
Dimensão	11 ha	32 ha
Localização	Minas Gerais/Brasil	São Paulo/Brasil
Altitude média	1025 m	483 m
Clima (Köppen) ^a	Aw	Cwa

^a Clima segundo a classificação de Köppen, disponível em ALVARES et al. (2013).

Para gerar os mapas de produtividade pela abordagem proposta, foram necessárias imagens de satélite das áreas de café e cana-de-açúcar. Para a área do cafeeiro, foram utilizadas imagens da plataforma PlanetScope (PLANET TEAM, 2017), com resolução espacial de 3,0 m, do sensor Dove Classic – PS2, produto ortorretificado – Nível 3B. Na área de cana-de-açúcar, o provedor utilizado foi o Sentinel-2 L2A, com resolução espacial de 10,0 m, disponíveis na plataforma EOSDA Land Viewer (eos.com/products/landviewer/). As imagens utilizadas em ambas as áreas foram pré-processadas para a correção atmosférica, de sensor e radiométrica.

Nas duas áreas utilizadas neste estudo, trabalhos anteriores calibraram modelos de aprendizado de máquina para o mesmo talhão, no caso do café (MARTELLO et al., 2022) ou para talhões próximos, dentro da mesma fazenda, no caso da cana-de-açúcar (CANATA et al., 2021). A investigação do presente estudo para selecionar a melhor época de obtenção das imagens de satélite partiu destes resultados, reportados anteriormente. Buscou-se identificar possíveis relações entre imagens de maior componente da variância dos dados de produtividade, e estádios da fisiologia de crescimento e desenvolvimento da cultura. O objetivo foi de utilizar o conhecimento acumulado na literatura para compreender se parâmetros estatísticos poderiam ser relacionados a parâmetros agrônômicos.

A análise dos dados foi realizada na linguagem *Python*, no ambiente do programa *Jupyter Notebook* (KLUYVER et al., 2016) e os mapas de superfície foram gerados no sistema de informação geográfica *Quantum Geographic Information System - QGIS* (QGIS DEVELOPMENT TEAM, 2022). As imagens de satélite selecionadas foram utilizadas para calcular os valores do índice de vegetação por diferença normalizada (NDVI) (ROUSE et al., 1974) para cada pixel da imagem (Equação 1). Os valores do NDVI das imagens selecionadas foram, posteriormente, utilizados junto à massa total produzida em cada área, de café ou de cana-de-açúcar, em uma função de distribuição da produtividade.

$$NDVI = \frac{IVp - V}{IVp + V}, \quad (1)$$

em que: IVp é a reflectância no infravermelho próximo; e V é a reflectância no vermelho visível.

Sendo um dado facilmente disponível ao produtor, a produção total recuperada foi utilizada como valor de entrada da função, sendo a produção final que foi colhida, desconsiderando as perdas. Esse valor foi distribuído utilizando a função densidade de probabilidade (FDP) das imagens de satélite, com o valor de NDVI. A FDP descreve a probabilidade de uma variável aleatória contínua estar sob uma determinada faixa de valores, associando a cada ponto do espaço amostral uma probabilidade de ocorrência (JOHNSON & WICHERN, 2002). Para uma variável aleatória x , a probabilidade de que ela esteja em um intervalo $[a, b]$ é dada pela integral da função densidade de probabilidade nesse intervalo (Equação 2):

$$P(a \leq x \leq b) = \int_a^b f(x) dx \quad (2)$$

em que: P é a probabilidade, x é a variável aleatória, e a e b são os valores mínimo e máximo do intervalo.

Sabendo que a área sob a curva da FDP ao longo do seu domínio é necessariamente igual a 1, é possível distribuir a produção total da lavoura de forma a igualar a massa total produzida à probabilidade total da FDP, gerando um vetor que contém os valores de produção espacializados para cada ponto da lavoura. O vetor resultante foi concatenado com as coordenadas geográficas dos pontos de NDVI das imagens de satélite, para ser interpolado por krigagem ordinária após ajuste do variograma de dependência espacial. O mesmo foi feito com os pontos de produtividade obtidos dos trabalhos de CANATA et al. (2021) e MARTELLO et al. (2022). Os vetores de produtividade distribuída pela metodologia proposta neste trabalho, produtividade observada pelos monitores, bem como os mapas gerados para ambos pela interpolação, foram comparados por meio da correlação de Pearson ($p < 0,01$) (r), raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE), e resumo estatístico (distribuição quartílica, desvio padrão (θ), valores médios, mínimos e máximos).

RESULTADOS E DISCUSSÃO: Para o modelo preditivo do café, no estudo de MARTELLO et al. (2022), as imagens de satélite de maior representação da variância dos dados de produtividade foram as imagens de julho e agosto em ambas as colheitas, de 2020 e 2021. Sabe-se que o café possui um ciclo bienal, onde a fase vegetativa dura um ano, e a fase reprodutiva o ano subsequente (CAMARGO & CAMARGO, 2001). Dessa forma, construiu-se o gráfico de fenologia da lavoura de café do presente estudo (Figura 1).

Nota-se que os meses de julho e agosto coincidem exatamente com o período de dormência do cafeeiro na área de estudo. A fase de dormência ocorre após o período vegetativo. A produção do café depende da formação de gemas seriadas e da iniciação floral dessas gemas (evocação) um ano antes da produção. Após iniciadas, as gemas entrarão em dormência durante o período seco do ano, esperando a primeira chuva, que ocorre normalmente na primavera, para quebrar essa dormência e entrar na fase de florescimento/antese (CAMARGO & CAMARGO, 2001; RENA et al., 1986). Dessa maneira, a compreensão da fisiologia do cafeeiro indica que o potencial produtivo da colheita de 2020 estava definido durante os meses de julho e agosto de 2019, e o mesmo ocorreu na colheita seguinte, com o potencial produtivo de 2021 sendo demonstrado durante a fase de dormência de 2020, em julho e agosto. Outros autores, tentando construir modelos preditivos da produtividade a partir de imagens de satélite, também indicaram os meses de julho e agosto como maior componente da variância dos dados (SILVA et al., 2021).

Dessa maneira, os parâmetros agronômicos justificam o padrão estatístico observado na área de estudo. O maior fator da variância da produtividade pelos índices vegetativos de julho e agosto, um ano antes da colheita, indicam um princípio de causalidade. Assim, foram selecionadas as imagens de satélite desta fase fenológica (dormência) para gerar o mapa de produtividade a partir da abordagem proposta neste estudo.

Para o modelo preditivo da produtividade da cana-de-açúcar, no estudo de CANATA et al. (2021), o maior

2018		2019					2020					2021																			
		1º ano fenológico					2º ano fenológico					3º ano fenológico																			
3ª fase	Antese	4ª fase	Granação	5ª fase	Maturação	6ª fase	Senescência	1ª fase	Formação de gemas seriadas	2ª fase	Evocação floral	3ª fase	Antese	4ª fase	Granação	5ª fase	Maturação	6ª fase	Senescência												
Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago								
Período reprodutivo		Morte de ramos					Período vegetativo					Dormência					Período reprodutivo					Morte de ramos									
Período vegetativo		Dormência					Período reprodutivo					Morte de ramos					Período vegetativo					Dormência									
1ª fase		Formação de gemas seriadas					Evocação floral					Antese					Granação					Maturação					2ª fase				
Formação de gemas seriadas		Evocação floral					Antese					Granação					Maturação					Formação de gemas seriadas					Evocação floral				

FIGURA 1. Fases fenológicas do cafeeiro identificadas para a área utilizada no presente estudo, durante as safras de 2020 e 2021. Adaptado de Camargo e Camargo (2001).

componente da variância da produtividade foi dado pelo sensoriamento orbital nas fases de perfilhamento da cultura, principalmente ao final, próximo à fase de crescimento dos colmos. Sabe-se que o perfilhamento culmina na formação da touceira. Essa fase é quem define a população de colmos que será colhida (GASCHO & SHIH, 1983). No auge do perfilhamento, logo antes da fase de crescimento dos brotos, o NDVI de uma lavoura de cana-de-açúcar cresce rapidamente, até atingir um pico e estabilizar, posteriormente decrescendo (ZHENG et al., 2021). BONNET (2013) comenta que, como a produtividade ótima depende da densidade de colmos na área, o perfilhamento é a fase crítica do processo de aumento do potencial produtivo. SINGELS et al. (2005) demonstraram que, apesar de duas cultivares obterem diferentes números de perfilhos, o pico do perfilhamento foi atingido após o mesmo tempo térmico acumulado, indicando que há um momento na lavoura de cana-de-açúcar onde o potencial produtivo foi atingido. A partir daí o crescimento e maturação dos colmos depende da população que foi gerada até essa fase de fechamento do dossel.

Denota-se, portanto, que o forte componente da variância das imagens de satélite do perfilhamento para explicar os dados de produtividade pode ter fundamento em relações agronômicas da cultura. Baseado nisso, optou-se pelo teste da distribuição da produção com as imagens desse estágio fenológico. Investigadas as relações agronômicas entre os dados, da mesma forma que para a área de café, foram selecionadas as imagens de satélite do auge do perfilhamento para gerar o mapa de produtividade a partir da abordagem proposta neste estudo.

O resumo estatístico dos dados demonstra que a estratégia de distribuição da produtividade pela FDP obteve resultados próximos aos observados pelos monitores de produtividade (Tabela 2). A média da produtividade foi exatamente a mesma entre os dados observados e preditos para todos os quatro cenários testados (dois anos de colheita do café, e dois anos de colheita de cana). Já o θ apresentou a tendência de ser menor entre os dados preditos do que para os dados observados. Isso pode ser explicado, parcialmente, pela tendência na distribuição da produtividade pela FDP ter perdido os valores extremos (máximos) de produtividade na área de cana-de-açúcar. Na área de café, ocorreu o contrário, a predição pela FDP aumentou a faixa de produtividade em ambos os anos, reduzindo os valores mínimos e aumentando os máximos observados. Entretanto, a análise dos quartis demonstra que o comportamento estatístico dos dados representa de forma fidedigna o observado pelos monitores. Por exemplo, para a colheita de 2020, na área de café, os valores observados e preditos dos quartis 0,25, 0,50 e 0,75 foram 1,63/1,71, 2,04/2,08 e 2,54/2,42 Mg ha⁻¹, respectivamente. Os demais anos, de café e cana-de-açúcar, mostram comportamento semelhante.

Para uso na agricultura, a proximidade entre os valores quartílicos da produtividade observada e predita possui importância sumária, pois indica que a distribuição dos valores na área seguiu um padrão definido, em concordância com os valores observados pelos monitores. Isso permite a tomada de decisão correta para gestão da lavoura a partir das informações que o mapa pode gerar.

TABELA 2. Resumo estatístico dos vetores de produtividade observada e predita para as áreas de café e de cana-de-açúcar, em ambas as safras utilizadas no presente estudo.

	Café				Cana-de-açúcar			
	2020		2021		2018		2019	
	Obs	Pred	Obs	Pred	Obs	Pred	Obs	Pred
	<i>Mg ha⁻¹</i>							
média	2,05	2,05	1,45	1,45	60,13	60,13	57,91	57,91
θ	0,50	0,44	0,43	0,35	7,79	5,59	7,84	5,04
mín	1,06	0,54	0,65	0,42	43,23	44,30	40,16	40,74
1° qrt	1,63	1,71	1,06	1,17	54,65	56,48	52,67	54,37
2° qrt	2,04	2,08	1,47	1,51	58,84	59,95	56,47	58,13
3° qrt	2,54	2,42	1,81	1,72	63,63	63,17	61,30	61,39
máx	2,87	3,11	2,23	2,33	84,34	75,86	92,66	71,76

Obs: observado; Pred: predito; média: média aritmética; θ : desvio padrão; mín: valor mínimo observado; 1° qrt: quartil de 25% dos dados; 2° qrt: quartil de 50%; 3° qrt: quartil de 75%; máximo: valor máximo observado.

A Tabela 3 mostra os parâmetros de correlação, RMSE e MAE entre o vetor de produtividade do monitor e do vetor de produtividade predito a partir deste estudo. A estratégia proposta neste estudo foi capaz de mapear a produtividade com r significativo a 99% para ambas as culturas, café e cana-de-açúcar, nos dois anos avaliados para cada área. O mapeamento da produtividade do café apresentou os maiores valores de r, de 0,89 e 0,80, e a cana de açúcar apresentou r de 0,72 e 0,64.

Na análise do erro de predição, a área de café apresentou RMSE e MAE de 0,22/0,18 e 0,26/0,21 Mg ha⁻¹ para as colheitas de 2020 e 2021, respectivamente. Em comparação, MARTELLO et al. (2022) utilizaram modelos *random forest* (RF) com imagens NDVI de julho e agosto, obtendo RMSE e MAE de 0,21/0,16 e 0,25/0,19 Mg ha⁻¹ para as colheitas de 2020 e 2021. Por outro lado, SILVA et al. (2021), ao prever a produtividade de café com imagens orbitais e dados de campo, alcançaram RMSE de 0,60 a 0,64 Mg ha⁻¹.

Na área de cana-de-açúcar, a abordagem deste estudo resultou em RMSE e MAE de 5,43/4,36 Mg ha⁻¹ na colheita de 2018 e 6,00/4,64 Mg ha⁻¹ na colheita de 2019. CANATA et al. (2021), ao prever a produtividade conjunta dos dois anos com modelos RF e dados de NDVI em talhões adjacentes ao utilizado neste estudo, encontraram RMSE e MAE de 5,39/4,18 Mg ha⁻¹.

A vantagem do método proposto neste trabalho, entretanto, é a simplicidade de dados de entrada para realizar a predição. Enquanto um modelo RF necessita calibração com um monitor de produtividade, para posterior predição, a estratégia de distribuição pela FDP utiliza somente os dados coletados por satélite, de fácil acesso, e a produção total da lavoura em que se deseja gerar o mapa de produtividade.

TABELA 3. Parâmetros estatístico entre a produtividade observada com os monitores de produtividade e a produtividade predita considerando imagens de satélite, produção total recuperada da lavoura e distribuição pela função densidade de probabilidade.

	Café		Cana-de-açúcar	
	2020	2021	2018	2019
r	0,89**	0,80**	0,72**	0,64**
RMSE	0,22	0,26	5,43	6,00
MAE	0,18	0,21	4,36	4,64

r: Correlação de Pearson, **correlação significativa a 99%; RMSE: raiz do erro quadrático médio, Mg ha⁻¹; e MAE: erro médio absoluto, Mg ha⁻¹

Nos mapas da lavoura de café, observa-se o mesmo comportamento espacial entre o observado pelos monitores e o predito pela estratégia adotada neste estudo. É possível identificar um contraste entre os dois anos, demarcando zonas distintas. Entretanto, não são zonas de alta e baixa produtividade, mas possivelmente zonas de diferente comportamento fisiológico das plantas. A produção do café é governada pelo fenômeno da bienalidade, onde, apesar de crescimento vegetativo e reprodutivo ocorrerem concomitantemente, em um ano o maior dreno é o vegetativo, e no outro o reprodutivo (CAMARGO & CAMARGO, 2001). Dessa maneira, todos os tratamentos culturais têm de ser orientados por esse fenômeno, uma vez que as diferentes fases fenológicas geram demandas nutrifisiológicas distintas.

Essa peculiaridade pôde ser notada apenas a partir dos mapas de produtividade, uma vez que o monitoramento da produção total da lavoura levaria o gestor à conclusão habitual de que toda a lavoura possuía o mesmo comportamento fisiológico. Isso reforça a grande valia da estratégia apresentada neste estudo. O mapa de produtividade do monitor embarcado em colhedora só poderia ser obtido por essa tecnologia, em sistemas mecanizados e por produtores que adotem essa estratégia. O mapa distribuído pela FDP utiliza apenas a informação usual da totalização da produção no talhão e imagens de satélite de livre acesso, e permite mesmo aos produtores de sistemas manuais ou semimecanizados a terem a espacialização da produção da sua lavoura, tomando as decisões mais assertivas a partir disso.

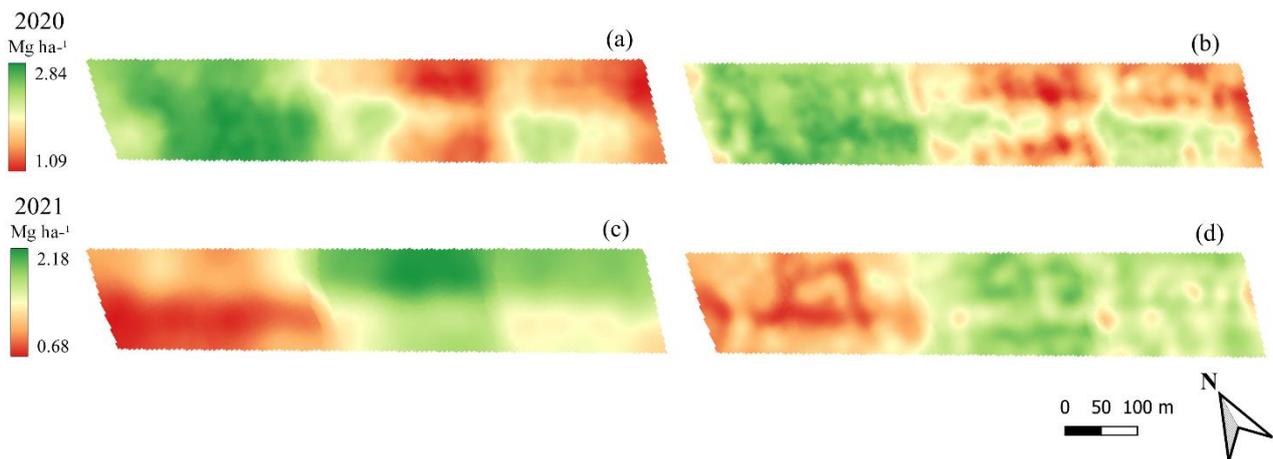


FIGURA 2. Caracterização espacial da produtividade do café, obtidas por krigagem ordinária, para as colheitas de 2020 e 2021. (a) e (c) dados do monitor de produtividade embarcado na colhedora; (b) e (d) produtividade predita com imagens de satélite, produção total do talhão e distribuição pela função densidade de probabilidade dos vetores.

Os mapas da lavoura de cana-de-açúcar também demarcaram o mesmo comportamento espacial entre o observado pelos monitores e predito pela estratégia deste estudo. Diferente da lavoura de café, aqui podem ser observadas zonas bem definidas que se repetem entre os dois anos, de maior e menor produtividade na área. Apesar da distribuição pela FDP ter suavizado os pontos de maior produtividade da área, nota-se que isso ocorreu em poucos pontos da lavoura, e a distribuição quartílica acompanhou de forma robusta os valores do monitor, gerando mapas semelhantes para ambas as estratégias. Ambos os mapas permitiriam ao gestor da área direcionar atividades que dependem da massa de cana produzida, como adubação de reposição, investigação de falhas e ataques de pragas e doenças, reforma do canavial, entre outras. Mais uma vez, é reforçada a utilidade da estratégia proposta neste estudo. Os mapas foram gerados apenas com a produção total da área e o monitoramento orbital. Uma estratégia que não necessita embarcar novas tecnologias nas máquinas, nem adequar a frente de trabalho das máquinas em campo, reduzindo o operacional necessário para chegar no mapeamento da produtividade.

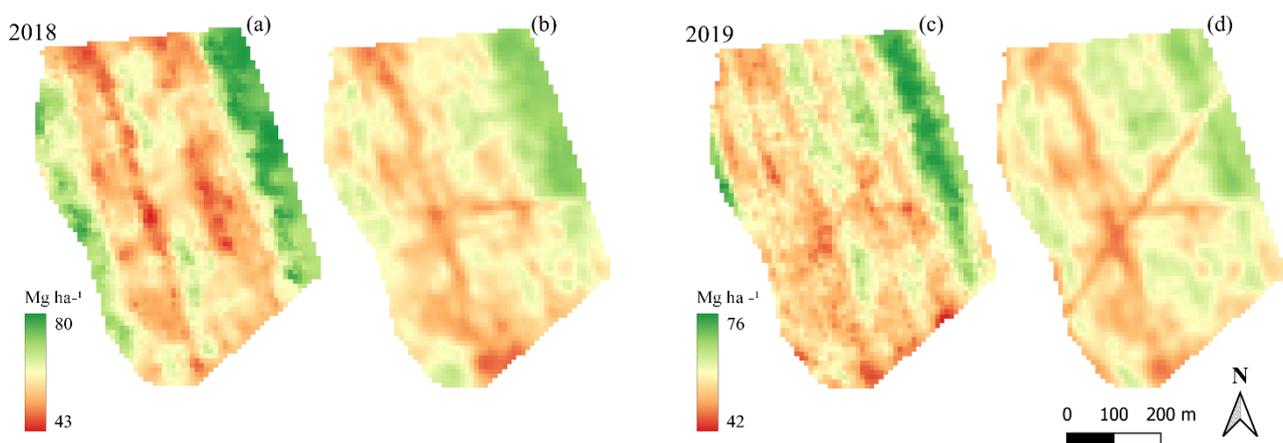


FIGURA 3. Caracterização espacial da produtividade da cana-de-açúcar, obtidas por krigagem ordinária, para as colheitas de 2018 e 2019. (a) e (c) dados do monitor de produtividade da colhedora; (b) e (d) produtividade predita com imagens de satélite, produção total do talhão e distribuição pela função densidade de probabilidade dos vetores.

Futuros trabalhos podem testar essa estratégia para outras culturas, ou utilizando diferentes sensores imageadores e regiões do espectro eletromagnético que tenham interações relevantes com as culturas agrícolas. Espera-se que essa estratégia auxilie sistemas produtivos onde o uso de monitores de produtividade embarcado em máquinas agrícolas, seja dificultoso, ou impossibilitado. Uma estratégia simples e eficaz para mapear a

produção das culturas agrícolas em uma lavoura, capaz de popularizar o uso de mapas de produtividade, pode ser um grande precursor das práticas de AP.

CONCLUSÃO: Neste trabalho, funções estatísticas de densidade de probabilidade foram utilizadas para gerar mapas de produtividade para duas culturas agrícolas, café e cana-de-açúcar. A estratégia desenvolvida utiliza dados de simples obtenção como entrada da função: a totalização da produção combinada a imagens de satélite de momentos relevantes da fisiologia da cultura. Essa estratégia demonstrou capacidade de mapear a produtividade para ambas as culturas, café e cana-de-açúcar. A estabilidade temporal do método também demonstrou robustez, uma vez que ela funcionou em dois anos consecutivos para as duas áreas/culturas. Os resultados indicam esta como uma alternativa viável a um amplo espectro de sistemas produtivos. Uma vez que independe de maquinário, pode ser útil a sistemas manuais, semimecanizados, ou mesmo em sistemas mecanizados em que monitores de produtividade apresentem desvantagens para sua adoção.

AGRADECIMENTOS: À Fundação de Amparo à Pesquisa do Estado de São Paulo (Fapesp) pelo financiamento ao primeiro autor, processo nº 2023/04638-1*.

*As opiniões, hipóteses e conclusões ou recomendações expressas neste material são de responsabilidade do(s) autor(es) e não necessariamente refletem a visão da FAPESP.

REFERÊNCIAS

- ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; de Moraes Gonçalves, J.L.; Sparovek, G. Köppen's Climate Classification Map for Brazil. *Meteorologische zeitschrift*, v.22, p.711–728, 2013.
- AMANKULOVA, K.; FARMONOV, N.; OMONOV, K.; ABDURAKHIMOVA, M.; & MUCSI, L. Integrating the Sentinel-1, Sentinel-2 and topographic data into soybean yield modelling using machine learning. *Advances in Space Research*, v.73, p.4052-4066, 2024.
- BONNETT, G. D. Developmental stages (phenology). *Sugarcane: physiology, biochemistry, and functional biology*, p.35-53, 2013.
- CAMARGO, Â.P.D., & CAMARGO, M.B.P.D. Definition and outline for the phenological phases of arabic coffee under Brazilian tropical conditions. *Bragantia*, v.60, p.65-68, 2001.
- CANATA, T. F., WEI, M. C. F., MALDANER, L. F., & MOLIN, J. P. Sugarcane yield mapping using high-resolution imagery data and machine learning technique. *Remote Sensing*, v.13(2), p.232, 2021.
- CARRER, M.J., FILHO, H.M. de S., VINHOLIS, M. de M.B., MOZAMBANI, C.I. Precision agriculture adoption and technical efficiency: An analysis of sugarcane farms in Brazil. *Technological Forecasting and Social Change* 177, 2022.
- GASCHO, G. J.; SHIH, S. F. Sugarcane. In: Teare, I. D.; Peet, M. M. (Ed.). *Crop-water relations*. New York: Wiley-Interscience. p. 445-479, 1983.
- GEBBERS, R., ADAMCHUK, V.I. Precision agriculture and food security. *Science*, v.327, n.5967, p.828-831, 2010.
- JOHNSON, R. A., & WICHERN, D. W. Applied multivariate statistical analysis – 6th edition. New Jersey: Pearson Education, 2007.
- KLUYVER, T., RAGAN-KELLEY, B., PÉREZ, F., GRANGER, B. E., BUSSONNIER, M., FREDERIC, J., & WILLING, C. (2016). Jupyter Notebooks-a publishing format for reproducible computational workflows. *Elpub*, v. 2016, p. 87-90, 2016.
- LONGCHAMPS, L., TISSEYRE, B., TAYLOR, J., SAGOO, L., MOMIN, A., FOUNTAS, S., MANFRINI, L., AMPATZIDIS, Y., SCHUELLER, J.K., KHOSLA, R. Yield sensing technologies for perennial and annual horticultural crops: a review. *Precision Agriculture*, v.23, p.2407–2448, 2022.
- MARTELLO, M., MOLIN, J. P., WEI, M. C. F., CANAL FILHO, R., & NICOLETTI, J. V. M. Coffee-yield estimation using high-resolution time-series satellite images and machine learning. *AgriEngineering*, v.4(4), p.888-902, 2022.
- NARVEKAR, C.; RAO, M. Agricultural Productivity Improvement—Role Of AI And Yield Prediction Using Machine Learning. In: *Precision Agriculture for Sustainability*. Apple Academic Press, p. 83-97, 2024.

PLANET TEAM. Planet Application Program Interface. In Space for Life on Earth; Planet Team: San Francisco, CA, USA. Available online: <https://api.planet.com>. 2017.

QGIS DEVELOPMENT TEAM. Quantum Geographic Information System. Open-Source Geospatial Foundation Project. Available online: <http://qgis.osgeo.org>. 2022

RENA, A.B.; MAESTRI, M. Fisiologia Do Cafeeiro. Cultura Do Cafeeiro: Fatores Que Afetam a Produtividade. Piracicaba, SP: **Associação Brasileira para Pesquisa da Potassa e do Fosfato**, 1986.

ROUSE, J. W., HAAS, R. H., SCHELL, J. A., & DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. **NASA Special Publications**, v.351(1), p.309, 1974.

SILVA, P. A. A., ALVES, M. C., da SILVA, F. M., & FIGUEIREDO, V. C. Coffee yield estimation by Landsat-8 imagery considering shading effects of planting row's orientation in center pivot. **Remote Sensing Applications: Society and Environment**, v.24, p.100613, 2021.

SINGELS, A., SMIT, M. A., REDSHAW, K. A., & DONALDSON, R. A. The effect of crop start date, crop class and cultivar on sugarcane canopy development and radiation interception. **Field crops research**, v.92(2-3), p.249-260, 2005.

ZHENG, Y., LUCIANO, A. C. S., DONG, J., & YUAN, W., 2021. High-resolution map of sugarcane cultivation in Brazil using a phenology-based method. **Earth System Science Data Discussions**, p.1-25, 2021.