

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

Luan Pierre Pott

**DETECÇÃO DE PLANTAS DANINHAS EM PRÉ-SEMEADURA COM
BASE EM DADOS ESPECTRAIS DE CAMPO**

Santa Maria, RS
2019

Luan Pierre Pott

**DETECÇÃO DE PLANTAS DANINHAS EM PRÉ-SEMEADURA COM BASE EM
DADOS ESPECTRAIS DE CAMPO**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, da Universidade Federal de Santa Maria, como requisito parcial para obtenção do título de **Mestre em Engenharia Agrícola**.

Orientador: Prof. Dr. Telmo Jorge Carneiro Amado
Co-orientador: PhD Ignacio Antonio Ciampitti

Santa Maria, RS
2019

Pott, Luan Pierre

DETECÇÃO DE PLANTAS DANINHAS EM PRÉ-SEMEADURA COM BASE
EM DADOS ESPECTRAIS DE CAMPO / Luan Pierre Pott.- 2019.
48 p.; 30 cm

Orientador: Telmo Jorge Carneiro Amado

Coorientador: Ignacio Antonio Ciampitti

Dissertação (mestrado) - Universidade Federal de Santa
Maria, Centro de Ciências Rurais, Programa de Pós
Graduação em Engenharia Agrícola, RS, 2019

1. agricultura de precisão 2. sensores 3. plantas
daninhas 4. curvas espectrais 5. índices de vegetação I.
Amado, Telmo Jorge Carneiro II. Ciampitti, Ignacio
Antonio III. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

© 2019

Todos os direitos autorais reservados à Luan Pierre Pott. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

Endereço: Avenida da Gruta, 139, Não-Me-Toque – RS, CEP: 97470-000.

Fone (55) 9 9206-0204; E-mail: luanpierrepot@hotmail.com

Luan Pierre Pott

**Detecção de plantas daninhas em pré-semeadura com base em dados
espectrais de campo**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, da Universidade Federal de Santa Maria, como requisito parcial para obtenção do título de **Mestre em Engenharia Agrícola**.

Aprovado em 03 de agosto de 2019:

Telmo Jorge Carneiro Amado, Dr. (UFSM)
(Presidente/Orientador)

Ignacio Antonio Ciampitti, PhD (Kansas State University) - Videoconferência

Mario Antonio Bianchi, Dr. (CCGL/UNICRUZ)

Santa Maria, RS
2019

AGRADECIMENTOS

Gostaria de agradecer à Deus por iluminar minha trajetória para conquista deste passo em minha vida.

À minha família, mãe Teresa Elena Pott, pai Eldemar Pott, irmã Luciana Pott Prediger pelo apoio incondicional, amor e carinho sempre prestados. Sem vocês nada seria possível.

Também agradeço aos meus avós *in memoriam* que estariam me motivando sempre para minhas conquistas, muito obrigado me orgulho muito de vocês.

À minha namorada Priscila Luisa Schuster por todo amor e carinho de sempre, compreendendo todos os momentos da minha vida.

À todos meus professores que me proporcionaram a educação, principalmente aos professores Telmo Jorge Carneiro Amado e Ignacio Antonio Ciampitti que foram meus conselheiros e grande educadores, não apenas cientificamente, mas também pessoal e profissional.

À todos meus amigos pelo apoio e convívio, irei levar para toda a vida.

Aos amigos do laboratório do Projeto Aquarius e KSU-Crops por toda ajuda, convívio diário, viagens, coleta de dados, parceria, amizade de sempre.

Esta conquista é nossa! Obrigado

RESUMO

DETECÇÃO DE PLANTAS DANINHAS EM PRÉ-SEMEADURA COM BASE EM DADOS ESPECTRAIS DE CAMPO

AUTOR: Luan Pierre Pott

ORIENTADOR: Telmo Jorge Carneiro Amado

Visto o conceito de agricultura de precisão e as novas tecnologias para a agricultura, tem-se a busca do aprimoramento de ferramentas de uma etapa de extrema importância no manejo de culturas agrícolas, que é a identificação e controle de plantas daninhas. Para tanto, a variabilidade espacial da distribuição das plantas daninhas não está sendo consideradas na decisão de seus manejos na maioria dos casos. Neste sentido, objetivou-se com este trabalho: (i) a utilização de sensor hiperespectral para identificar bandas espectrais mais eficazes na distinção de plantas daninhas em relação à outros alvos (solo arenoso, solo argiloso e resíduos vegetais) em pré-semeadura; (ii) calcular índices de vegetação para avaliação da acurácia da distinção de plantas daninhas e outros alvos. Foram utilizados dois bancos de dados, o primeiro provindo de experimento de campo realizado na Universidade Federal de Santa Maria para calibração do modelo, e o segundo banco de dados foi construído com leituras em fazenda de produtores rurais, para validação do modelo. Foi utilizado o espectrorradiômetro HandHeld 2, ASD[®], com comprimentos de onda de 325-1075nm, para realizar leituras das curvas espectrais de espécies de plantas daninhas e outros alvos: solo argiloso, solo arenoso, e resíduos vegetais. Posteriormente foram agrupados os comprimentos de onda em bandas espectrais, bem como cálculo de índices de vegetação para análise dos dados. Os resultados demonstraram que os dados coletados no experimento de campo (calibração) e nas fazendas (validação) obtiveram curvas espectrais similares, onde as bandas espectrais do vermelho e do infravermelho próximo obtiveram maior acurácia comparado com as outras bandas. Os índices de vegetação utilizados aumentaram a acurácia da discriminação em relação à bandas espectrais isoladas. O trabalho fornece uma válida ferramenta para distinção de plantas daninhas de outros alvos com a utilização de sensor proximal em pré-semeadura de culturas agrícolas baseado em curvas espectrais.

Palavras-chave: Manejo Sítio-específico de Plantas daninhas. Curvas espectrais. Bandas espectrais. Índices de vegetação.

ABSTRACT

PRE-PLANTING WEED DETECTION BASED ON GROUND FIELD SPECTRAL DATA

AUTHOR: Luan Pierre Pott

ADVISOR: Telmo Jorge Carneiro Amado

According to the concept of precision agriculture and new technologies for agriculture, there were several studies to improve tools at an extremely important stage in crop management, which is the identification and control of weeds. Therefore, the spatial variability of weed distribution is not being considered in deciding their management in most cases. In this sense, the objective of this study was: (i) the use of a hyperspectral sensor to identify more efficient spectral bands in distinguishing weeds from other targets (sandy soil, clay soil and plant residues) in pre-planting; (ii) elaborate vegetation indices to evaluate the accuracy of weed distinction and other targets. Two databases were used, the first from a field experiment conducted at the Federal University of Santa Maria as training data, and the second database was built with readings on-farm as validation data. The HandHeld 2 spectrometer, ASD[®], with wavelengths of 325-1075nm, was used to perform spectral curves readings of weed species and other targets: clay soil, sandy soil, and residues. Subsequently, the wavelengths were grouped into spectral bands, as well as the calculation of vegetation indices for data analysis. The results showed that the data collected in the field experiment (training data) and in the farms (validation data) obtained similar spectral curves, where the red and near infrared spectral bands obtained higher accuracy compared to the other bands. The vegetation indices used increased the discrimination accuracy in relation to the isolated spectral bands. The work provides a valid tool for distinguishing weeds from other targets using proximal sensor pre-sowing of crops based on spectral curves.

Keywords: Site-specific Weed Management (SSWM); Spectral curves, Spectral bands; Vegetation indices.

LISTA DE FIGURAS

ARTIGO

Fig. 1 - Field trials were located in the South of Brazil, the Rio Grande do Sul, comprising a training (one field study, Santa Maria) and validation data sets (five on-farm fields). ..	24
Fig. 2 - Theoretical framework for the study.....	27
Fig. 3 - Spectral reflectance curves (mean, minimum and maximum) for weeds, residue, and soil type (clay, sandy) classes for the range of wavelength from 400 to 900 nm for the field trial.	29
Fig. 4 - Comparison of training (data from one field trial) and validation (data from five on-farm sites) spectral curves, portraying minimum and maximum spectral curves, for the weeds class (A), residues (B), and sandy soil (C).....	30
Fig. 5 - Linear discriminant analysis (LDA) for all the classes evaluated in this study for the field research (residue, sandy soil, and weeds).....	30
Fig. 6 - Conditional inference tree analysis using the bands: coastal blue, blue, green, yellow, red, red edge, and near-infrared	31
Fig. 7 - Mean decrease accuracy (MDA) of the spectral bands utilizing training and validation data in random forest analysis.....	32
Fig. 8 - Boxplot representing data distribution for different bands and indices for training data.	32
Fig. 9 - Condition inference tree of EVI (A), EVI2 (B), OSAVI (C), SAVI (D), NDVI (E), NIR – RED (F) and NIR/RED (G).	33

LISTA DE TABELAS

ARTIGO

Table 1 - The number of readings for each target evaluated in field trial and on-farm fields (5 total).	25
Table 2 - Separation of wavelengths in spectral bands. Centered refers to the medium wavelength of each spectral band.	27
Table 3 - Vegetation indices and their respective equations evaluated in this study.	28
Table 4 - Statistics of training threshold when analyzed the validation data.	33

LISTA DE SIGLAS

AP	Agricultura de Precisão
LEDs	Light Emitting Diodes
DGPS	Differential Global Positioning System
GNSS	Global Navigation Satellite System
SARP	Sistema de Aeronave Remotamente Pilotada
NIR	Near infrared
LDA	Linear Discriminant analysis
EVI	Enhanced Vegetation Index
EVI2	Enhanced Vegetation Index 2
OSAVI	Optimized Soil Adjusted Vegetation Index
SAVI	Soil Adjusted Vegetation Index
NDVI	Normalized Difference Vegetation Index

SUMÁRIO

1. APRESENTAÇÃO	12
1.1 REFERENCIAL TEÓRICO	12
1.2 JUSTIFICATIVA	16
1.3 HIPÓTESES	18
1.4 OBJETIVOS	18
1.5 MATERIAL E MÉTODOS	18
2. ARTIGO - PRE-PLANTING WEED DETECTION BASED ON GROUND FIELD SPECTRAL DATA	21
ABSTRACT	21
INTRODUCTION	22
MATERIALS AND METHODS	23
Training dataset	23
Validation dataset	24
Data collection	24
Data analyses	26
RESULTS	28
Spectral curves	28
Comparison between field trials and on-farm fields	29
Linear discriminant analysis (LDA)	30
Conditional inference tree analysis	30
Random forest analysis (training and validation data)	31
Vegetation indices	32
DISCUSSION	34
CONCLUSIONS	36
REFERENCES	37
3. CONCLUSÃO	45
REFERÊNCIAS	46

1. APRESENTAÇÃO

1.1 REFERENCIAL TEÓRICO

A agricultura de precisão (AP) revolucionou a produção agrícola no século XX e continuará a impactar o futuro da produção agrícola. Automatizou o gerenciamento de campos agrícolas usando a tecnologia da informação para integrar dados de várias fontes para modificar insumos com base na variabilidade específica do local (TORRES-SÁNCHEZ et al., 2013).

O gerenciamento de plantas daninhas de forma precisa é uma aplicação da AP que leva em conta a variabilidade de distribuição e densidade bem como seu manejo em sítio-específico (HUANG et al., 2016). Economicamente, plantas daninhas são plantas voluntárias que se desenvolvem onde não são desejadas e ocasionam perdas consideráveis nas culturas de grãos. Essas perdas são representadas pela redução de produtividade da cultura econômica e pelo aumento do custo de produção devido à utilização de métodos de controle. O método químico com a utilização de herbicidas é o mais comumente utilizado, devido sua rapidez de ação, alta eficiência e pela reduzida mão de obra demandada.

Estudo que analisou um total de 63 artigos sobre a lucratividade de sistemas que adotaram algum tipo de ferramenta de agricultura de precisão indicou que a aplicação sítio-específico de herbicidas mostrou-se vantajosa em 73% dos casos, 16% apresentaram resultados mistos e em 11% deles foi desvantajosa (SHIRATSUCHI et al., 2003).

Em relação ao histórico das tecnologias utilizadas nas pulverizações agrícolas terrestres, marcador de espuma foi a primeira tecnologia a ser adaptada e utilizada em pulverizadores. Consiste na marcação de linhas nos limites da barra de pulverização com o objetivo de orientar o operador, evitando áreas sem aplicação e/ou áreas com sobreposição do agroquímico (BALASTREIRE; BAIO, 2001). Na sequência, tecnologias que permitam ajustar doses de aplicação, velocidade, visualização do volume do tanque, e controle de seções de barra facilitaram o controle e eficiência das pulverizações (POTT et al., 2016).

Barra de luzes, tecnologia que substituiria os marcadores de espuma é um equipamento utilizado para a orientação de um veículo em faixas adjacentes, com o propósito de diminuir a sobreposição entre passadas consecutivas e otimizar a eficiência da operação agrícola. Possui um conjunto de LEDs (*Light Emitting Diodes*) verdes que se mantêm ligados quando o veículo está mantendo o alinhamento programado e um conjunto de LEDs vermelhos que se mantem ligados quando o veículo está se afastando do alinhamento programado (BALASTREIRE; BAIO, 2001).

A tecnologia DGPS (*Differential Global Positioning System*) possibilitou a implantação das barras de luzes, o desenvolvimento do piloto automático para a guia de máquinas agrícolas, e o georreferenciamento de infestações de plantas daninhas (SHIRATSUCHI et al., 2003).

As plantas daninhas são frequentemente encontradas infestando lavouras, terrenos baldios, calçadas, estradas, seja por sua característica agressiva, seja por estar adaptada a povoar ambientes perturbados. É reconhecível que muitas espécies de plantas daninhas se localizam de forma agrupada, em “reboleiras”, devido principalmente a características de crescimento e forma de dispersão de propágulos (GERHARDS et al., 1996; LAMB; BROWN, 2000).

Mesmo com a distribuição desuniforme das plantas daninhas em áreas agrícolas, técnicas aprimoradas de sistema de informação geográfica tornam possível caracterizar esta variabilidade espacial, obtendo como produto mapas temáticos de espécies de plantas daninhas, sua densidade, diversidade, entre outros (SHIRATSUCHI et al., 2003; POTT et al., 2018; POTT et al., 2019).

Um dos métodos convencionais para levantamento das plantas daninhas é método de delimitação do perímetro das infestações, o qual consiste no caminhamento pelo campo e demarcação de pontos e polígonos com “reboleiras” de plantas daninhas, registrando a presença de espécies, densidade e diversidade da flora, utilizando a tecnologia GNSS (*Global Navigation Satellite System*) (SHIRATSUCHI et al., 2003).

O método de amostragem em grade é amplamente utilizado para levantamento da variabilidade espacial de acidez e fertilidade de solos para correção e adubação a taxa variada, mas pode ser também utilizada para levantamento de plantas daninhas. O método consiste na divisão da área em pequenas unidades (grades), podendo variar em tamanho e forma geométrica. A mais comumente utilizada é a grade quadriculada, em que há um ponto central georreferenciado, o qual será utilizado como ponto de informação para interpolação em software especializado, gerando mapas temáticos (SHIRATSUCHI et al., 2003; SCHAFFRATH et al., 2017; POTT et al., 2019).

Em relação ao tamanho de grade a ser gerada para malha de coleta de informação, é dependente da área agrícola, disponibilidade de mão-de-obra, tempo destinado a esse serviço, entre outros. Na medida que diminui a grade amostral, aumentando o número de pontos por área, mais confiável e precisa é a informação. Porém, é notório o maior trabalho e a onerosidade deste serviço (CHIBA; FILHO; VIEIRA, 2010).

Vários tamanhos de grades foram analisados com o intuito de recomendação de um tamanho de grade que seja viável e com bom nível de precisão. A grade de 6 x 6m² foi

considerado o tamanho máximo de uma grade, já que grades maiores podem gerar mapas com baixa resolução, inviabilizando a técnica (LUTMAN; PERRY, 1999).

As áreas mínimas de coletas de dados para a realização do mapeamento das plantas daninhas já foram testadas, chegando-se a quadrados amostrais de 0,06m² a 0,38m² como os mínimos possíveis (DESSAINT et al., 1991; CARDINA et al., 1996; GEHARDS et al., 1996).

Outro método convencional de levantamento das plantas daninhas é através de avaliações na largura da barra de pulverização. Os pulverizadores existentes no mercado possuem uma largura de barra com bicos de pulverização que pode variar desde pulverizadores costais de 1m até pulverizadores mecanizados terrestres e pulverização aérea de 30 m ou mais (SHIRATSUCHI et al., 2003).

Na maioria dos pulverizadores nestas larguras de trabalho o volume pulverizado é considerado o mesmo, não havendo variações de taxa de aplicação por bico ao longo da barra de pulverização. Como ao longo da barra da maioria dos pulverizadores do mercado a taxa de aplicação é considerada constante, não há tanta relevância em analisar a variabilidade de plantas daninhas ao longo da largura da barra. Porém, é de grande utilidade o levantamento da variabilidade ao longo do deslocamento longitudinal do pulverizador, haja vista a possibilidade de pulverização a taxas variadas ser realizada em faixas, onde estas faixas serão dependentes da largura de trabalho do pulverizador (POTT et al., 2016).

Com o banco de dados da comunidade de espécies daninhas da área obtidos pelo levantamento convencional, são gerados os mapas temáticos, sendo possível visualizá-los ou em forma de grade, com o tamanho de grade pré-estabelecido, ou como mapas temáticos interpolados, nos quais são utilizadas as ferramentas da geoestatística (SHIRATSUCHI et al., 2003; CHIBA; FILHO; VIEIRA, 2010; SCHAFFRATH et al., 2017; POTT et al., 2019).

Os mapas de prescrição de herbicidas tanto em pré ou pós-emergência devem levar em consideração aspectos quantitativos e qualitativos da infestação (ANTUNIASSI et al., 2010). Fatores importantes são: o histórico da distribuição das plantas daninhas, atributos do solo como pH, matéria orgânica do solo, e cobertura vegetal. Ainda, o processo de tomada de decisão na criação de um mapa de pulverização deve levar em conta os erros do sistema de posicionamento, a acurabilidade do mapeamento dos alvos, a movimentação das manchas de plantas ao longo do tempo e as características de desempenho do equipamento de pulverização como o tempo de resposta, velocidade, tamanho da barra, entre outros (ANTUNIASSI et al., 2010).

Os métodos convencionais de levantamento da comunidade infestante para posterior prescrição de pulverização de herbicidas, como os descritos anteriormente, são métodos muito

trabalhosos e demandam muito tempo para o levantamento (SHIRATSUCHI et al., 2003; POTT et al., 2016). Alternativas aos sistemas convencionais de levantamento de plantas daninhas vem sendo amplamente estudadas, principalmente utilizando sistemas com sensores para detecção de plantas daninhas em campos de cultivos agrícolas (WESTWOOD et al., 2017; POTT et al., 2018).

Os sensores são os sistemas responsáveis pela conversão da energia proveniente dos objetos em um registro, que permita associar a energia captada com as características físicas, químicas, biológicas ou geométricas dos alvos (NOVO, 1989; JENSEN, 2009). A partir disto, é possível inferir sobre questões agrônômicas como: estado nutricional das culturas, características do solo, estresse hídrico, sanidade, presença de plantas daninhas, entre outras (MOREIRA, 2001).

A discriminação de alvos por sensores ópticos que captam sinais eletromagnéticos, pode-se identificar e entender o objeto com unicidade de comportamento (JENSEN, 2009). De todos os comprimentos de onda do espectro eletromagnético, as regiões do visível e do infravermelho próximo são as mais utilizadas para aplicações no meio agrícola (400-3.000 nanômetros) (MOREIRA, 2001; JENSEN, 2009; MOLIN et al., 2015).

Devido ao comportamento espectral específico de cada alvo, é possível através da reflectância nos comprimentos de onda inferir sobre alvos agrícolas. Os sensores ópticos que mensuram a interação da energia com alvos são denominados radiômetros e variam em função das bandas espectrais e dos comprimentos de onda com os quais trabalham (NOVO, 1989; JENSEN, 2009).

Há radiômetros que operam em poucas bandas espectrais, que são caracterizadas por diferentes intervalos de faixas do espectro eletromagnético. Dessa forma, recebem o nome de sensores multiespectrais, já que mensuram mais do que uma banda do espectro eletromagnético. Já sensores hiperespectrais operam em inúmeros comprimentos de onda. Sendo a diferença entre eles a resolução espectral que o sensor opera (JENSEN, 2009).

Sensores ópticos possuem capacidade para detecção sem contato, processo de medição simples, rápida resposta, alta confiabilidade e baixo consumo de energia, sendo desta forma um método de aplicação simples e fácil procedimento que pode ser usado em sistemas de aplicação em tempo real (MOREIRA, 2001).

No que diz respeito à detecção e localização de plantas daninhas em culturas, foram desenvolvidas várias abordagens que podem ser primeiramente distinguidas com base na plataforma (satélite, aéreo, sistema de aeronave remotamente pilotada (SARP) ou proximal), e tipo (imageador e não-imageador) utilizado para aquisição de seus produtos. Na última década,

SARPs tornaram-se uma plataforma muito popular para transportar sistemas de aquisição e, assim, monitorar os campos agrícolas (ZHANG; KOVACS, 2012).

Comparado ao satélite ou tripulado aéreo, as principais vantagens dos SARPs são seus resultados rápidos, alta resolução espacial e temporal e, portanto, sua capacidade operacional. Nos últimos anos, vários trabalhos abordaram o uso de SARPs para detecção e mapeamento de plantas daninhas (LOUARGANT et al., 2018).

Em comparação com veículos terrestres, o sensoriamento remoto usando SARPs é uma abordagem mais eficaz para fornecer um mapa de plantas daninhas em grandes áreas. No entanto, o sensoriamento remoto para detectar e mapear necessidades requer: (1) diferenças suficientes na reflectância espectral ou textura entre plantas daninhas e solo ou culturas e (2) uma resolução espacial e espectral apropriada para a aquisição sistema (LAMB; BROWN, 2001).

Vários autores demonstraram que plantas e culturas cultivadas podem ser discriminadas usando sua assinatura espectral (HUANG et al., 2016; HERRMANN et al., 2013; SHAPIRA et al., 2013; GIRMA et al., 2005; VRINDTS et al., 2002; FEYAERTS; VAN GOOL, 2001). No entanto, quando os dados são capturados em campo por pequenos SARPs, a capacidade de distinção espectral encontra dificuldades como: utilização de limitadas bandas espectrais pela limitação de carga, a informação espectral coletada poderá ter influência de condições de insolação, cobertura de nuvens, sombra e poeira e a reflectância espectral possui interferência em plantas com estresse fisiológico (CARTER; KNAPP, 2001).

Diversos estudos demonstraram que a escolha de pelo menos quatro bandas espectrais forneceu melhores resultados do que o uso de câmeras RGB padrão, especialmente quando se utilizou informações de infravermelho próximo (NIR) (TORRES-SÁNCHEZ et al., 2013; PEÑA et al., 2015).

Em particular, a utilização de informação NIR melhora a separação entre a vegetação e o solo no pré-processamento de imagens (LOTTE et al., 2017). Em estudos recentes, foi utilizado câmera multiespectral de seis bandas (banda centrados em 530, 550, 570, 670, 700 e 800 nm) (PÉREZ-ORTIZ et al., 2016; PEÑA et al., 2013). Também em estudos com câmera multiespectral foram utilizadas seis bandas (banda centrados em 450, 530, 670, 700, 740 e 780 nm) (LÓPEZ-GRANADOS et al., 2016).

1.2 JUSTIFICATIVA

Planta daninha é toda e qualquer planta superior que interfira nos interesses do homem e no meio ambiente seja em meio social ou agrícola, este último ocasionando interferência na produtividade de culturas (PITELLI R. A., 2015).

A ocorrência de plantas daninhas em lavouras anuais ocasiona tanto interferências diretas como indiretas. Para a cultura da soja (*Glycine max* (L.) Merrill), a interferência de plantas daninhas resulta em perdas de produtividade de grãos de 20 a 70%, conforme o nível de infestação (GAZZIERO et al., 2012).

Logo, o controle de plantas daninhas é de suma importância em atividades agrícolas. Entre os métodos de controle, se destaca o método químico, com o emprego dos herbicidas, o qual é o mais utilizado devido sua rapidez de ação e elevada eficiência. Porém, agroquímicos de modo geral possuem alto custo, onerando a produção agrícola, além do impacto ambiental causado pelo uso intensivo destes produtos na fauna e flora do ambiente.

A pulverização, seja ela em época de pré-semeadura (dessecação), pré-emergência ou pós-emergência, é rotineiramente realizada em área total, não levando em consideração a variabilidade espacial da comunidade infestante, de sua densidade de infestação, ou ainda a variabilidade de atributos de solo que interferem no efeito dos produtos.

Pulverizações de forma dirigida, com o intuito de controlar plantas daninhas, proporcionam, além de uma maior economia de produto, uma harmonização das questões ambientais. Nuspl et al. (1996), e Heisel et al. (1996) obtiveram economia na quantidade de herbicida de 30% a 80% e 66% a 75%, respectivamente, devido à pulverização dirigida, comparada à pulverização em área total.

Uma alternativa para controle de plantas daninhas de forma dirigida é a utilização de sensores ópticos para detecção e controle em tempo real (WESTWOOD et al., 2017; POTT, et al., 2018). Sensores são os sistemas responsáveis pela conversão da energia proveniente dos objetos em um registro na forma de imagem ou gráfico, que permita associar a energia captada com as características físicas, químicas, biológicas ou geométricas dos alvos.

O sensoriamento tem sido avaliado para distinção de espécies, ou grupo de espécies de plantas daninhas partindo da premissa que cada espécie possui certas características que podem ser utilizadas para diferenciá-la de outra, geralmente forma, tamanho e reflectância da folha (EVERITT et al., 1992; BROWN et al., 1994; VILELA et al., 2006).

Características espectrais de ramos e folhas de várias culturas e plantas daninhas foram estudadas usando espectrômetro e sensores ópticos que, através da reflectância e características de comprimento de onda formam índices baseados na coloração e contribuem para o modelo de classificação para detecção de plantas daninhas (WANG et al., 2007).

Deste modo, informações geradas a partir de experimentos que selecione comprimentos de onda para confecção de sensores específicos capazes de diferir plantas daninhas de outros alvos juntamente com a automação agrícola vinculada com sistemas de pulverizações capacita o controle dirigido de plantas daninhas em pré-semeadura.

1.3 HIPÓTESES

Caso haja diferença espectral de alvos de plantas daninhas de outros alvos no momento de pulverização de pré-semeadura, então é possível construir modelo para diferenciação de plantas daninhas de outros alvos.

Se bandas espectrais possuem eficiência de distinção de plantas daninhas de outros alvos, então possibilita a utilização de sensores multiespectrais.

Se índices de vegetação incrementam a eficiência de distinção de plantas daninhas de outros alvos, então sua utilização no modelo pode ser priorizada.

1.4 OBJETIVOS

Fornecer conhecimento técnico/científico sobre utilização de sensor óptico para diferenciação de plantas daninhas de outros alvos em pré-semeadura.

Conhecer características espectrais dos alvos encontrados na atividade de pulverização em pré-semeadura.

Confeccionar bandas espectrais pra diferenciação de plantas daninhas de outros alvos encontrados em pulverização de pré-semeadura.

Calcular índices de vegetação para agregar em eficácia para a distinção.

1.5 MATERIAL E MÉTODOS

Para realizar o trabalho foram utilizados dois banco de dados, o primeiro em experimento de campo (dados de treinamento), realizado na cidade de Santa Maria na Universidade Federal de Santa Maria, área chamada Área Nova, durante safra de 2016/2017 e o segundo banco de dados (dados de validação) foi adquirido com dados de agricultores nas cidades de: Não-Me-Toque, Lagoa dos Três Canto, Tapera, Cruz Alta e Itaara do estado do Rio Grande do Sul.

Para o primeiro banco de dados, o estudo compreendeu oito espécies (sete plantas daninhas e uma cultura comercial): *Amaranthus hybridus* L., *Bidens pilosa* L., *Urochloa plantaginea* (Link) R. D. Webster., *Euphorbia heterophylla* L., *Glycine max* (L.) Merr. (soja), *Ipomoea grandifolia* (Dammer) O'Donell, *Panicum maximum* Jacq. e *Sida rhombifolia* L.

O delineamento experimental foi inteiramente casualizado, com quatro repetições. As dimensões da parcela foram de 3 x 2 m. Todas as espécies foram semeadas em 10 de novembro em um arranjo de quatro linhas com 0,5 m entre linhas.

Para realizar as leituras de resíduos da cultura (cobertura morta), o milho (*Zea mays* L.), a soja e a aveia preta (*Avena sativa* L.) foram cultivadas durante a safra 2016/17 e, após a colheita, as medições foram realizadas.

Foram coletadas amostras de solo com 0,10 m de profundidade para identificar a textura do solo, para solo argiloso e arenoso.

Para o segundo banco de dados (dados de validação) foram realizadas leituras com sensor em plantas daninhas nas cidades citadas acima. As avaliações foram realizadas nesses campos de fevereiro de 2016 a março de 2018. As leituras do radiômetro das ervas daninhas foram coletadas em dois anos, nas culturas de verão e inverno, para compor o conjunto de dados para validação. Além disso, foram coletadas leituras de radiômetro a partir de amostras de solo arenoso, resíduos e solo argiloso.

As avaliações foram realizadas através da coleta de reflectância medida utilizando o espectrorradiômetro FieldSpec® HandHeld 2TM ASD Inc. (sensor passivo com avaliações coletadas na posição do zênite, a 0,3 m do alvo) variando de 325 a 1075 nm, com precisão de ± 1 nm e resolução <3 nm a 700 nm. O sensor possui um campo de visão de ângulo cônico total de 25 graus, capaz de coletar dados espectrais de 277,71 cm² para cada medida. As leituras foram realizadas em pontos somente em dias ensolarados, na ausência de nuvens ao meio-dia (12h).

As plantas daninhas tanto do experimento de campo, como na coleta de informações nos agricultores apresentavam-se em diferentes estádios fenológicos de desenvolvimento, aumentando a variação dos dados.

Para os dados do experimento de campo, foram coletadas 393 leituras de plantas daninhas por radiômetro e, para os campos de agricultores 248 leituras de plantas daninhas. Além disso, foram coletadas 75 leituras de radiômetro de resíduos de culturas (soja, milho e aveia preta), 30 leituras de solo argiloso e 39 leituras de solo arenoso em experimento de campo e em agricultores.

As análises deram-se utilizando *Linear Discriminant analysis* (LDA) com todos os comprimentos de onda, posteriormente foram agrupadas em bandas espectrais, azul costal (400 – 450 nm), azul (450 – 510 nm), verde (510 – 580 nm), amarelo (585 – 625 nm), vermelho (630 – 690 nm), limite do vermelho (705 – 745 nm) e infravermelho próximo (770 – 900 nm).

Utilizando as bandas espectrais foram empregas árvore de decisão bem como o algoritmo *Random Forest*, para aferições de eficiência das bandas espectrais para diferenciação das plantas daninhas de outros alvos.

Ao final foram calculados os índices de vegetação: *enhanced vegetation index* (EVI), *enhanced vegetation index 2* (EVI2), *optimized soil adjusted vegetation index* (OSAVI), *soil adjusted vegetation index* (SAVI), *normalized difference vegetation index* (NDVI), diferença entre vermelho e infravermelho próximo (NIR-RED), e simples razão entre NIR e RED (NIR/RED). Foram treinadas e posteriormente testadas com os bancos de dados de treinamento e validação respectivamente utilizando programa R (R CORE TEAM, 2019).

2. ARTIGO - PRE-PLANTING WEED DETECTION BASED ON GROUND FIELD SPECTRAL DATA

Artigo originalmente em revisão para revista Pest Management Science. Todos direitos reservados à revista Pest Management Science, Wiley Online Library.

Luan Pierre Pott, Telmo Jorge Carneiro Amado, Raí Augusto Schwalbert, Elodio Sebem, Mithila Jugulam, Ignacio Antonio Ciampitti

ABSTRACT

BACKGROUND: Site-specific weed management (SSWM) demands higher resolution data for mapping weeds in fields, but the success of this tool relies on the efficiency of optical sensors to discriminate weeds relative to other targets (soils, and residues) before cash crop establishment. The objectives of this study were to i) evaluate the accuracy of spectral bands to differentiate weeds (target) and other non-targets; ii) access vegetation indices (VIs) to assist in the discrimination process; and iii) evaluate the accuracy of the thresholds to distinguish weeds relative to non-targets for each VI using training and validation data sets.

RESULTS: The main outcomes of this study for effectively distinguishing weeds from other non-targets are: (i) training and validation data exhibited similar spectral curves; (ii) red and near-infrared (NIR) spectral bands presented greater accuracy relative to the other bands; (iii) the tested VIs increased the discrimination accuracy related to single bands, with an overall accuracy above 95% and a kappa above 0.93.

CONCLUSION: This study provided a novel approach to distinguish weeds from other non-targets utilizing a ground-level sensor before cash crop planting based on field spectral data. However, the limitations of this study are related to the spatial resolution to distinguish weeds that might be closer to the one this study presented, and also related to the soil and crop residues conditions at the time of collecting the readings. Overall the results presented contribute to an improved understanding of spectral signatures from different targets (weeds, soils, and residues) before planting time supporting SSWM.

Keywords: site-specific weed management (SSWM); spectral curves, spectral bands; vegetation indices.

INTRODUCTION

Weeds reduce crop growth and yield by competing with field crops for environmental resources such as light, water, and nutrients.^{1,2,3} The cash crop yield reduction is increased when weed competition occurs in early growth stages. In overall, weed infestation contribute to the largest potential yield losses (34%) relative to other plant pests such as insects or pathogens.^{4,5}

Generally, the distribution of weeds in a crop field are in patches;⁶⁻⁷ however, herbicides are applied uniformly across fields. Chemical methods such as the use of herbicides is the most effective for weed control in modern agriculture.⁹ The concept of site-specific weed management (SSWM) has the bias to cope with the heterogeneity occurring within fields by treating only weed patches.¹⁰ The SSWM may result in lower use of herbicides with reduction in environmental hazard, and can save input costs, depending on the level of weed infestation.¹⁰ Previous studies reported that with SSWM, herbicide savings range from 53 to 75% relative to uniformly applied herbicide across the field.^{11,12}

Conventional weed mapping operations are costly in commercial large-scale farms and time-consuming in small farms.^{13,14} Use of remote sensing, more specifically, sensor-based systems can offer an alternative (e.g., SSWM) to conventional weed mapping. Use of the ground-level hyperspectral systems to scout weeds presents benefits such as non-contact detection, fast response, high reliability, and low power consumption, making this method a simple and easy real-time procedure.¹⁵⁻¹⁹

Distinguishing weeds relative to other non-targets, such as crop residues and types of soil (e.g., textural classes), for pre-planting applications is of great interest to improve weed identification and therefore, effective weed control in site specific management. Previous studies have found that the use of spectral bands help to differentiate plants from other non-targets.²⁰ Huete *et al.* reported the spectral response of a plant canopy with different soil backgrounds.²¹ Langner *et al.* utilizing a camera, reported a special vegetation index (VI), which has a red threshold criterion aggregate in the normalized difference vegetation index (NDVI) calculation.²² Scotford and Miller investigated the utilization of spectral reflectance techniques using vegetation and soil spectral curves.¹⁶ Therefore, testing spectral bands and/or VIs and setting thresholds for distinguishing weeds using ground-level sensors is a key strategy to improve identification of weedy patches.¹⁵

Plant leaves and canopy, in general, are mainly affected by plant pigments including chlorophyll (e.g., chlorophyll a and b), carotenes and xanthophylls in visible light reflectance.²³⁻
²⁵ The combination of chlorophyll, a strong scattering of light, and internal cellular plant structure affect the red-edge band reflectance.^{24,26} In the near infrared (NIR) band, internal leaf

structure and multiple leaf layers influence the reflectance properties of the canopy.^{23,24,27} In senescent plants, the chlorophyll can gradually show a decrease in the content which has greater reflectance in blue and red bands.^{25,28,29}

Recording hyperspectral information about different targets when scouting for weeds can be a challenge, due to the high amount of auto correlated data. For that reason, in recent years, multivariate analyses, such as linear discrimination, have been employed to discriminate crops versus weeds.³⁰⁻³² Decision tree-based analyses are another class of algorithms that have the potential for helping researches to interpret hyperspectral data. Conditional inference tree is a decision tree algorithm for recursive binary splitting. It embeds the framework in a well-defined statistical environment based on permutation tests, attempting to distinguish between significant and insignificant improvements.³³ Random forests algorithm is one of the most powerful machine-learning techniques.³⁴ Recent studies utilized random forest in remote sensing with multiple applications such as land cover classification, tree species mapping, and vegetation classification.^{27,35,36} Therefore, these techniques can greatly contribute to the identification of spectral bands for discriminating weeds versus other non-targets such as soil and plant residue.

The objectives of this study were to: i) evaluate the accuracy of spectral bands to discriminate weeds and other targets (soils and residues) in pre-planting applications utilizing ground-level sensing; ii) access VIs to assist in the discrimination between weeds and other non-targets; iii) evaluate the accuracy improvement of the thresholds to distinguish the weeds relative to other non-targets for each VI using training and validation data sets.

MATERIALS AND METHODS

Training dataset

Two sources of data were collected and used in this study, i) field trials (herein termed as ‘training data’), and ii) on-farm (herein termed as ‘validation data’) data. Training data were collected from a field trial carried out during the 2016/17 soybean growing season (November 2016 to April 2017) at the Federal University of Santa Maria, Rio Grande do Sul, Brazil. The study comprises of eight species (seven weeds and one cash crop): *Amaranthus hybridus* L., *Bidens pilosa* L., *Urochloa plantaginea* (Link) R. D. Webster., *Euphorbia heterophylla* L., *Glycine max* (L.) Merr. (soybean), *Ipomoea grandifolia* (Dammer) O'Donell, *Panicum maximum* Jacq., and *Sida rhombifolia* L. The experimental design was completely randomized with four replications. The plot dimensions were 3 x 2 m. All species were sown on November

10th in a four-row arrangement with 0.5 m between rows. The plant density was adjusted to 300,000 plants ha⁻¹ for each specie trough manual plant thinning.

In order to perform the crop residue (mulch) readings, corn (*Zea mays* L.), soybean, and black oat (*Avena sativa* L.) were all grown during the 2016/17 season, and after crop harvest, the measurements were done. Measurements in all three types of crop residues were collected to form the target residue. In the field trials, we collected soil samples at 0.10 m depth to identify the soil texture, and classified as sandy soil (clay 18%, silt 22% and sand 60%), according to the United States Department of Agriculture (USDA) soil texture triangle.³⁷

Validation dataset

The validation data set was built by collecting radiometer readings at five on-farm sites located in a radius of 200 km (Não-Me-Toque, Tapera, Cruz Alta, Júlio de Castilhos and Itaara counties) (Fig. 1). Evaluations were carried in those fields from February 2016 until March 2018. The radiometer readings of weeds were collected over two years, in both summer and winter crops, to compose the data set for validation. In addition, radiometer readings were collected from sandy soil sample, residues as well as a different soil type (clay 58%, silt 22%, and sand 20%), classified as clay soil, based on the soil texture triangle.³⁷

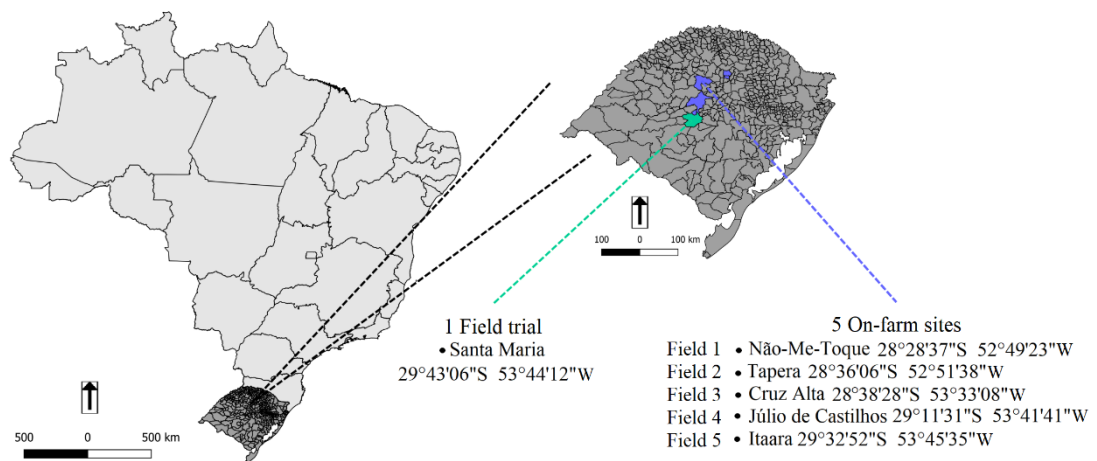


Fig. 1 - Field trials were located in the South of Brazil, the Rio Grande do Sul, comprising a training (one field study, Santa Maria) and validation data sets (five on-farm fields).

Data collection

Reflectance was measured utilizing the FieldSpec[®] HandHeld 2[™] ASD Inc. spectroradiometer (passive sensor with evaluations collected in the zenith position, 0.3 m from

the target) ranging from 325 to 1075 nm, with an accuracy of ± 1 nm and a resolution of <3 nm at 700 nm. The sensor has a 25-degree full conical angle field-of-view, capable of collecting spectral data of 277.71 cm² for each measure. The readings were performed in points only on sunny days, in the absence of clouds at noon (12 pm). Before starting the measurements, and every half hour the sensor was properly calibrated with Spectralon[®] board following the manufacturer recommendations.³⁸

In the field trials (training data), all weeds and crops were evaluated at three different phenological growth stages according to the BBCH scale:³⁹ stage 13 (3 leaves); stage 17 (7 leaves); and stage 51 (inflorescence or flower buds visible). For all the on-farm sites, plants phenological growth stages ranged from 11 (1 leaf) to 59 (first flower petals visible).

For the field research data, 393 radiometer weed readings were collected, and for the on-farm fields, 248 weed readings. Additionally, 75 radiometer readings were collected from crop residues (soybean, corn, and black oats mulch), 30 readings from clay soil, and 39 readings from sandy soil in field research and on-farm fields (Table 1). The readings were collected taking full (100%) of field-of-view of each target/non-target.

Table 1 - The number of readings for each target evaluated in field trial and on-farm fields (5 total).

Target	Field trial	Field 1	Field 2	Field 3	Field 4	Field 5
<i>Amaranthus hybridus</i>	52	-	-	-	-	9
<i>Avena sativa</i>	-	-	-	-	9	-
<i>Avena strigosa</i> Schreb.	-	-	-	-	9	-
<i>Bidens Pilosa</i>	52	-	-	-	-	-
<i>Urochloa plantaginea</i>	48	-	-	-	-	-
<i>Brassica napus</i> L.	-	-	-	-	9	-
<i>Conyza bonariensis</i> L.	-	9	9	-	-	-
<i>Echium plantagineum</i> L.	-	-	-	-	9	-
<i>Euphorbia heterophylla</i>	52	-	-	-	-	-
<i>Glycine max</i>	34	-	-	41	-	-
<i>Ipomoea grandifolia</i>	52	-	-	-	-	-
<i>Lolium multiflorum</i> Lam.	-	-	-	-	36	-
<i>Panicum maximum</i>	51	-	-	-	-	-
<i>Polygonum convolvulus</i> L.	-	9	-	-	-	9
<i>Raphanus silvestris</i> Lam.	-	-	-	-	9	-
<i>Richardia brasiliensis</i> Gomes	-	-	9	-	-	-
<i>Sida rhombifolia</i>	52	9	-	-	9	-
<i>Solanum americanum</i> Mill.	-	9	-	-	9	18
<i>Sonchus oleraceus</i> L.	-	-	-	-	9	-
<i>Triticum aestivum</i> L.	-	-	-	-	9	-

Total Weeds	393	36	18	41	117	36
Residues	25	-	-	50	-	-
Clay soil	-	20	10	-	-	-
Sandy soil	39	-	-	-	-	-

Field trial: Santa Maria; On-farm fields, Field 1: Não-Me-Toque; Field 2: Tapera; Field 3: Cruz Alta; Field 4: Júlio de Castilhos; Field 5: Itaara.

Data analyses

The LDA (only using training data) was executed to separate classes among the targets evaluated in this study when using the full electromagnetic spectrum. Discriminant analysis, a multivariate technique, was utilized to separate groups based on the measured k variables in each sample, finding one or more linear combinations of the selected variables.⁴⁰ The *ade4* package was used to perform the analysis within the R environment.^{41,42}

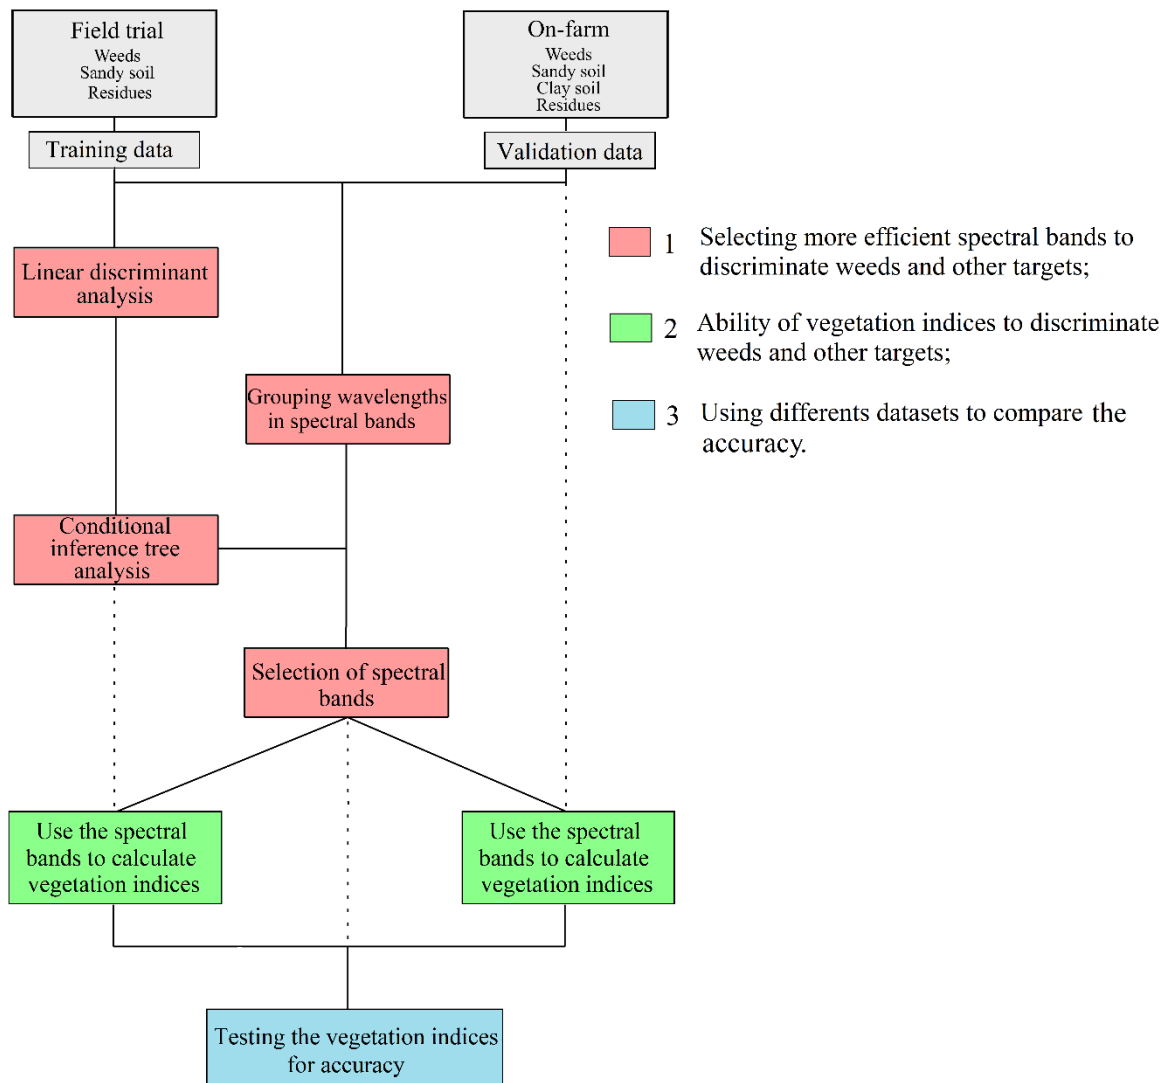


Fig. 2 - Theoretical framework for the study.

Considering that most of the spectral sensors developed for agricultural purposes (e.g., GreenSeeker®, WeedSeeker®, OptRx®, WEEDit®) have a limited radiometer resolution, recording only a few bands (usually two or three) relative to the FieldSpec, individual wavelengths (recorded by FieldSpec) were grouped in order to form spectral bands (Table 2). The definition of the spectral bands were based on the spectral bands from WorldView-2, which agrees with the critical spectral bands identified for future spectral capabilities to satellites.⁴³

Table 2 - Separation of wavelengths in spectral bands. Centered refers to the medium wavelength of each spectral band.

Band	Centered	Range
Coastal blue	425	400-450
Blue	480	450-510
Green	545	510-580
Yellow	605	585-625
Red	660	630-690
Red edge	725	705-745
Near infrared (NIR)	835	770-900

All spectral bands (only using training data) were subjected to conditional inference tree analysis within the *partykit* package in R in order to select spectral bands that allow a more evident separation between weeds and other targets.⁴⁴ These analysis are based on hierarchically ordered and recursively repeated binary splits, where the strength of each association is measured by a P-value. The terminal nodes account for the final subset of density points in each target. One of the main advantages of this technique is the possibility of exploration of complex interactions with control over overfitting issues.⁴⁵

Random forest analysis (using both training and validation data) was performed using *randomForest* package in R to analyze the separation capacity of the targets by the selected bands.⁴⁶ Mean decrease accuracy (MDA) was assessed to select the most important spectral bands to accomplish VIs. The MDA utilizes permuting out-of-bag (OOB) samples to compute the importance of the variable. The OOB sample is the set of observations which are not used for building the current tree. It is used to estimate the prediction error and to evaluate variable importance.^{46,47} The OOB is the mean prediction error on each training sample, using only the trees that did not have in their bootstrap sample.⁴⁷

To test if the data collected in the field trial is comparable with the one gathered from the on-farm sites, the average, minimum and maximum spectral curves were plotted.

Lastly, the VIs: enhanced vegetation index (EVI), enhanced vegetation index 2 (EVI2), optimized soil adjusted vegetation index (OSAVI), soil adjusted vegetation index (SAVI), normalized difference vegetation index (NDVI), difference between NIR and RED (NIR-RED), and ratio between NIR and RED (NIR/RED) (Table 3) were determined to test the potential of combination of the different spectral bands as well as to improve the accuracy in weed discrimination relative to the other targets. As a criterion, overall accuracy and kappa coefficients were performed using the *caret* package.⁴⁸

Table 3 - Vegetation indices and their respective equations evaluated in this study.

Index	Equation	Reference
EVI	$2.5(R_{NIR} - R_{Red}) / (R_{NIR} + 6R_{Red} - 7.5R_{Blue} + 1)$	Huete et al. ⁴⁹
EVI2	$2.4 (R_{NIR} - R_{Red}) / (R_{NIR} + R_{Red} + 1)$	Jiang et al. ⁵⁰
OSAVI	$1.16(R_{NIR} - R_{Red}) / (R_{NIR} - R_{Red} + 0.16)$	Rondeaux et al. ⁵¹
SAVI	$1.5(R_{NIR} - R_{Red}) / (R_{NIR} - R_{Red} + 0.5)$	Huete ⁵²
NDVI	$(R_{NIR} - R_{Red}) / (R_{NIR} + R_{Red})$	Rouse et al. ⁵³
NIR - RED	$R_{NIR} - R_{Red}$	Vogelmann et al. ⁵⁴
NIR / RED	R_{NIR} / R_{Red}	Vogelmann et al. ⁵⁴

R = reflectance.

RESULTS

Spectral curves

Reflectance readings (average) and its variation (minimum to maximum) for each target, i.e., weeds, residue, clay, and sandy soils were recorded (Fig. 3). The living plants (weeds) presented the highest reflectance in the green band (501-565 nm) and absorption peaks at blue (441-485 nm) and red (626-690 nm) bands in the visible light. The red edge (691-750 nm) band presented a broad rate of variation (minimum to maximum) in the spectral curves. The NIR band presented the highest reflectance for weeds, with a broad range of variation, relative to the soil texture (clay and sandy) and residue types (Fig. 3). The crops residues and soil types presented the narrowest variation on the spectral reflectance curves, with the reflectance rising as the wavelength increases from 400 nm onwards (to 900 nm). Among the soils type, sandy soil texture presented the highest reflectance values compared to clay soil.

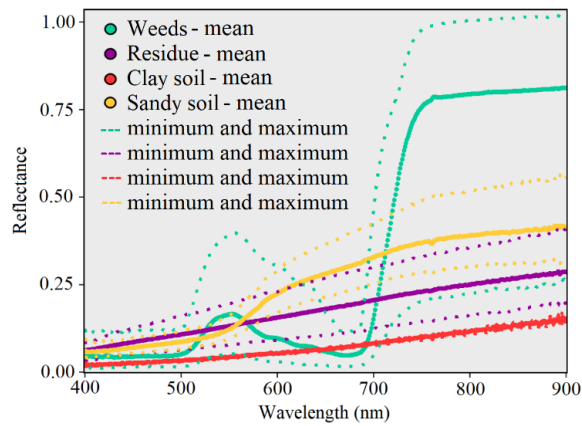


Fig. 3 - Spectral reflectance curves (mean, minimum and maximum) for weeds, residue, and soil type (clay, sandy) classes for the range of wavelength from 400 to 900 nm for the field trial.

Comparison between field trials and on-farm fields

The reflectance for weeds, crop residues, and sandy soil were greater for the field trial relative to the on-farm sites, but overall there was an overlap between the curves without reflecting a significant difference in mean values of the spectral curves for the classes between these two data sources evaluated in this study (Fig. 4). The target clay soil was collected only in on-farm fields.

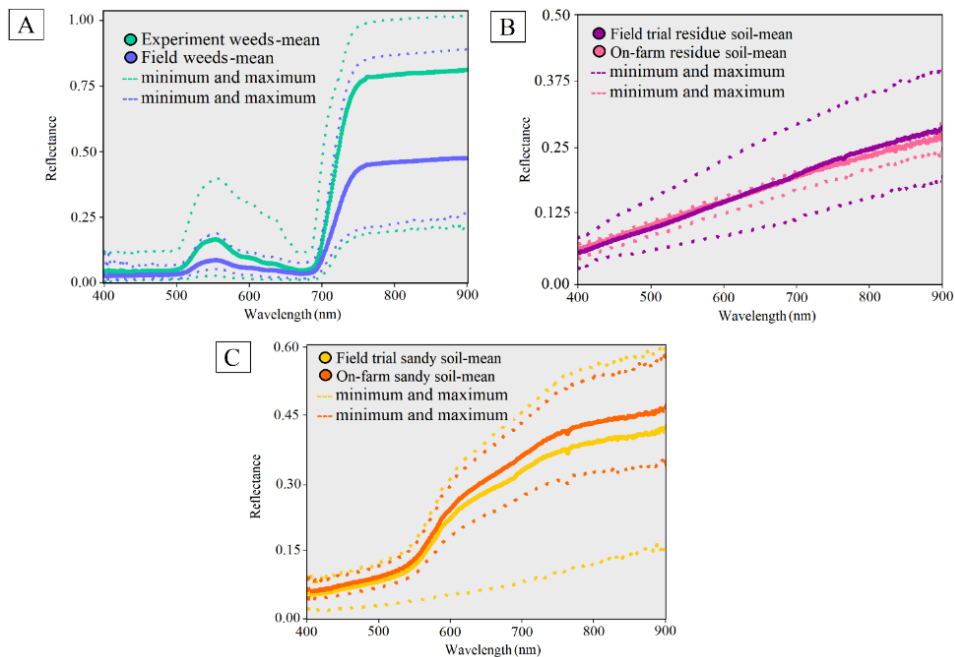


Fig. 4 - Comparison of training (data from one field trial) and validation (data from five on-farm sites) spectral curves, portraying minimum and maximum spectral curves, for the weeds class (A), residues (B), and sandy soil (C).

Linear discriminant analysis (LDA)

The LDA was able to differentiate all the targets (weeds, residue, and sandy soil) (Fig. 5). There was no overlapping among classes, indicating a high degree of separation when considering the full-electromagnetic spectrum.




Fig. 5 - Linear discriminant analysis (LDA) for all the classes evaluated in this study for the field research (residue, sandy soil, and weeds). Ellipses represent the confidence regions around the mean of canonical scores at the 95% confidence level.

Conditional inference tree analysis

Conditional inference tree analysis resulted in four inner nodes (1, 2, 5, and 7) and five terminal nodes (3, 4, 6, 8, and 9) (Fig. 6). The spectral bands differentiating classes were: red, NIR, red edge and green (Fig. 6). The class for weeds was identified and separated by the bands red (inner node 1) and NIR (inner node 2). The conditions applied to classify the target as weeds were: $\text{red} \leq 0.13$ and $\text{NIR} > 0.233$. Following these conditions (nodes), a total of 99.5% of all the radiometric readings from the weeds were obtained in the terminal node 4. For the sandy soil, three spectral bands were used: red (inner node 1), red edge (inner node 5) and green (inner node 7). For this soil texture, the classification conditions were $\text{red} > 0.13$, $\text{red edge} > 0.266$ and $\text{green} \leq 0.144$, obtaining 100% of the total sandy soil database in the terminal node 8. Residues were obtained overlapping of targets in their classification (nodes 3, 6 and 9). For

most of the crop residue (77.3%), the classification occurred with the bands: red > 0.13 and red edge ≤ 0.266 , terminal node 6 (Fig. 6).

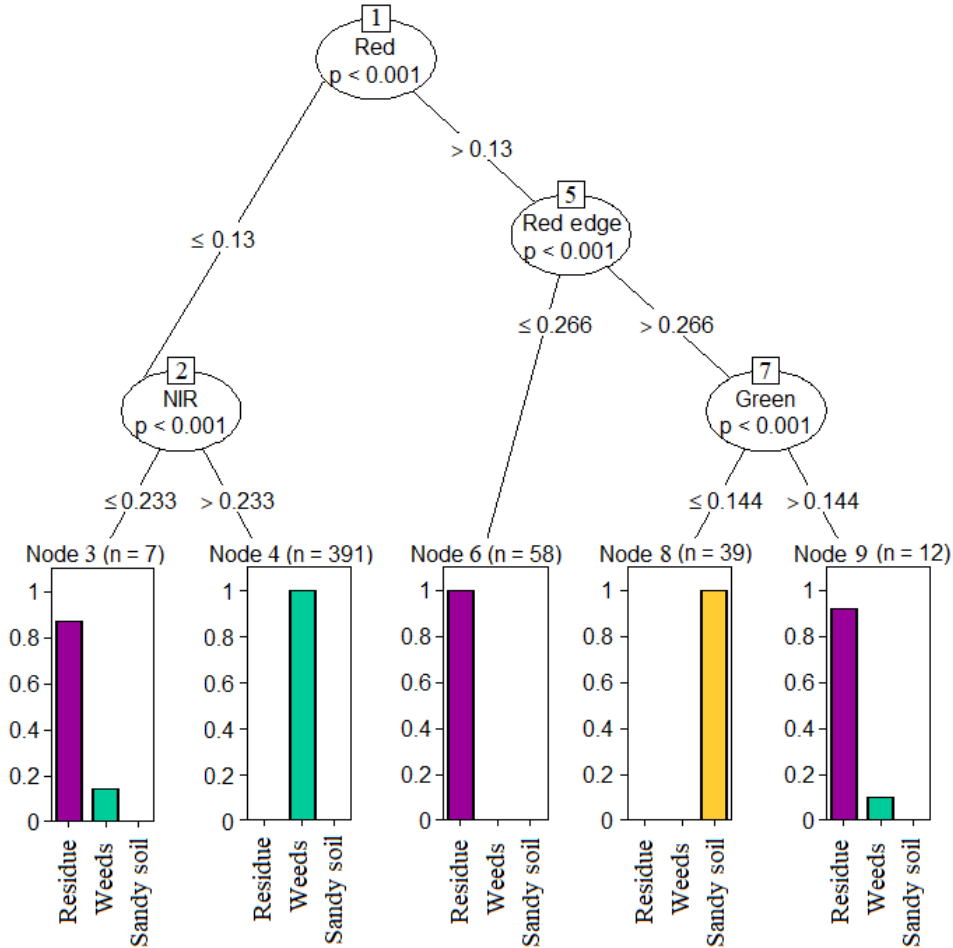


Fig. 6 - Conditional inference tree analysis using the bands: coastal blue, blue, green, yellow, red, red edge, and near-infrared. Bars at the bottom of the figure represent the density of points for each target. The values of conditions for classification are reflectance values.

Random forest analysis (training and validation data)

For the random forest analysis confirmed for both data sets that the red and NIR bands are of great relevancy when identifying weeds versus other targets, as reported by the MDA (Fig. 7). After removing the red spectral band, the model accuracy decreased to the value 31.0% followed by the spectral band NIR with the accuracy 19.8% (Fig 7). The other spectral bands presented lower impacts on model performance relative to both red and NIR bands.

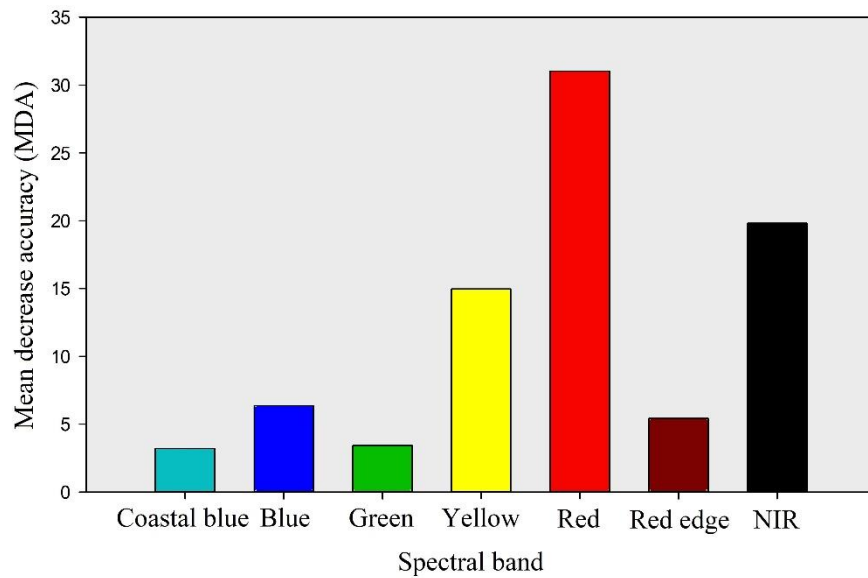


Fig. 7 - Mean decrease accuracy (MDA) of the spectral bands utilizing training and validation data in random forest analysis.

Vegetation indices

The VIs: EVI, EVI2, OSAVI, SAVI, NDVI, NIR-RED, and NIR/RED improved the discrimination of weeds relative to the other targets in comparison with the utilization of the isolated spectral bands. The values of each index had no overlap between weeds and the other targets (Fig. 8) for the training data.

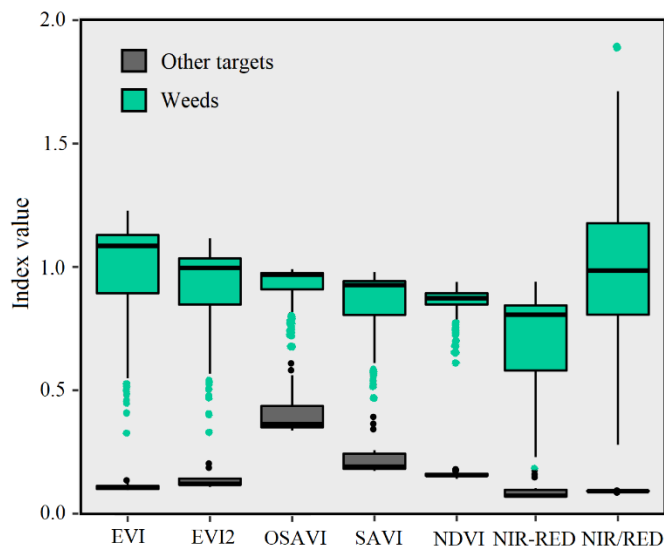


Fig. 8 - Boxplot representing data distribution for different bands and indices for training data. The lower and upper hinges correspond to the first and third quartiles (the 25th and 75th

percentiles). The upper whisker extends from the hinge to the largest value no further than 1.5 * inter-quartile range (IQR) from the hinge. The lower whisker extends from the hinge to the smallest value at most 1.5 * IQR of the hinge. Data beyond the end of the whiskers are considered outliers. NIR/RED values were divided by 15 to better fit in y axis.

Conditional inference trees with training data were developed for each index separately in order to compare their capacity of discriminating weeds from other targets and to establish VI-specific thresholds (Fig. 9). The EVI had 0.138 as a threshold value, EVI2 had 0.221, OSAVI had 0.166, SAVI had 0.162, NDVI had 0.197, NIR - RED had 0.137, and NIR/RED had 1.485.

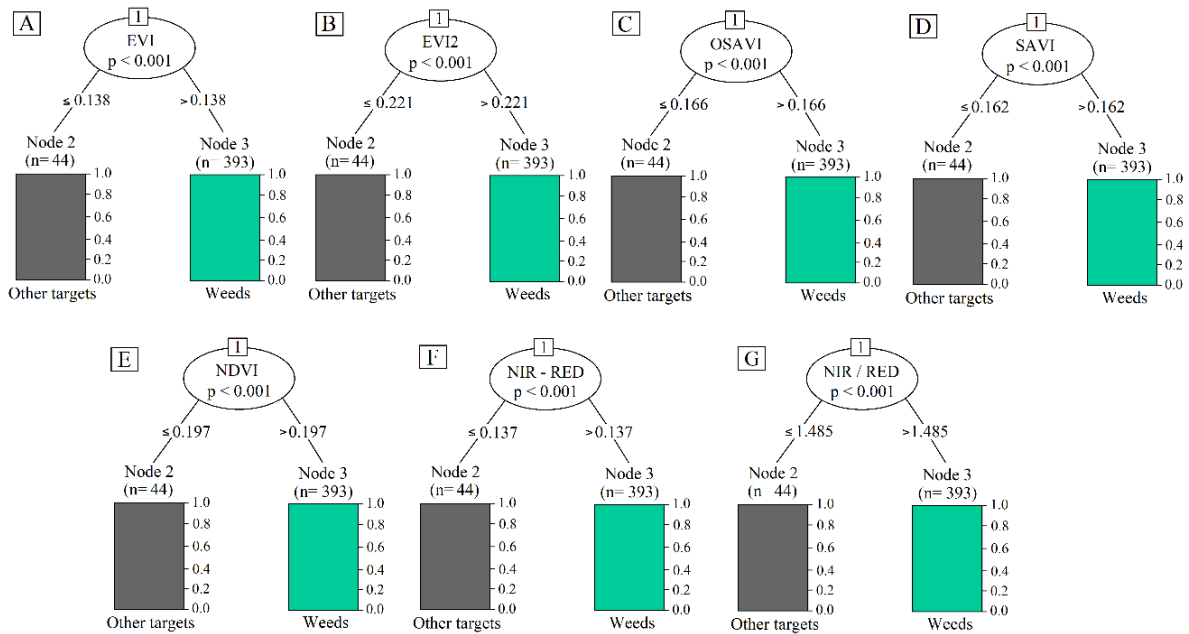


Fig. 9 - Condition inference tree of EVI (A), EVI2 (B), OSAVI (C), SAVI (D), NDVI (E), NIR – RED (F) and NIR/RED (G).

The thresholds from the training data were applied over the validation data in order to calculate the overall accuracy and kappa coefficients from the confusion matrix. The OSAVI had 100% of overall accuracy and kappa equal 1, and the other indices: EVI, EVI2, SAVI, NDVI, NIR – RED and NIR/RED also presented high values of accuracy, with overall accuracy > 95%, and kappa > 0.93 (Table 4).

Table 4 - Statistics of training threshold when analyzed the validation data.

Index	Statistics	
EVI	Overall accuracy	98.5%

	Kappa	0.97
EVI2	Overall accuracy	98.1%
	Kappa	0.97
OSAVI	Overall accuracy	100%
	Kappa	1
SAVI	Overall accuracy	99.2%
	Kappa	0.98
NDVI	Overall accuracy	95.6%
	Kappa	0.93
NIR - RED	Overall accuracy	98.1%
	Kappa	0.97
NIR/RED	Overall accuracy	95.3%
	Kappa	0.93

DISCUSSION

Remote sensing of weeds relative to other targets before soybean planting is a newer approach with potential of weed management improvement by reducing environmental risk and cutting cost. To full perform SSWM, it is necessary to discriminate accurately weeds from other targets in order to allow only target spraying (applying herbicide only where it is necessary).⁸ Discrimination of weeds relative to other targets can be assessed at pre-planting and, in early and late during the growing season, at post-emergence applications. Researchers have been studying alternatives to discriminate plants relative to soil targets, such as the use of different VIs from multispectral cameras.^{22,51,52} More recently, remote sensing was used to distinguish weeds relative to cash crops, such as corn, cabbage (*Brassica olearacea* var. *capitata*), sugar beet (*Beta vulgaris* L.) and soybean.^{15,18,27,32,55,56} Several studies have provided insights for developing sprayers based on the SSWM approach, with limitations mainly related to identify weeds and the spatial resolution for discriminating other non-target.^{6,72,73}

Considering the scientific literature on spectral information for different targets before planting, an important outcome of this study was related to the similarity of spectral curves between training (field trial) and validation (on-farm) data sets, to assess weeds, soil texture, and crop residues. This relevant finding shows that hyperspectral data collected in experimental and on-farm conditions (training and validation data) can be used to develop models to discriminate weeds from other targets in field condition. Plant canopy reflectance is governed by the concentration and distribution of biochemical compounds, internal structure of the tissue, as well as the leaf surface properties.²⁷ Daughtry reported that spectral curves of three different crop residues and five soil types had similar behavior but differ only in their amplitude of reflectance.⁵⁷ The reflectance of soils and crop residues rising as the wavelength increase from

400 nm onwards to 900 nm. Thus, the reflectance is generally lower in the visible range (400-690 nm) and higher in the NIR region (691-900 nm) in these selected targets.⁵⁸ Soil texture has high reflectance for sandy soils, most likely due to the high amount of quartz in the sand fraction, increasing the intensity of spectral reflectance.^{58,59}

The second outcome of this study was connected to perfect discrimination among weeds and the other non-targets - residues, sandy and clay texture soils - using all wavelengths reported by the LDA approach. Spectral curves often carry a more detailed information compared to wavelength aggregated in spectral bands.²⁷ The LDA has been recently used for hyperspectral data target classification.³⁰⁻³² Conditional inference tree and random forest analyses reported that red and NIR bands were the most important spectral bands to discriminate weeds relative to other targets. Similar results were reported by Rondeaux *et al.* in a study with vegetation and soil reflectances.⁵¹ According to Langner *et al.* the reflectance of green vegetation is very low in the red band, in contrast with the high reflectance in NIR.²² Soils on the other hand, have a reflectance with minimum difference between red and NIR bands. The results are in line with the commercial sensors that use the red and NIR spectral bands to weed identification.⁶⁰

The selection of VIs was defined related to their relevancy for agricultural purposes, composing the spectral bands which had the greater values to distinguish weeds relative to other targets (spectral bands: red and NIR).⁶¹ Using VIs relative to the individual spectral bands improved the performance (overall accuracy and kappa coefficient) for discriminating weeds. The third outcome of this study was related to the ability of the indices: EVI, EVI2, OSAVI, SAVI, NDVI, NIR - RED and NIR/RED to discriminate weeds from other targets. The VIs are related to several properties of plants and those VIs are frequently used to other aims as disease detection, plant stress, nutrition, yield forecast and phenology.⁶¹⁻⁶⁶

From all the VIs tested on this study, OSAVI presented the greatest accuracy when comparing training and validation data sets. The OSAVI was built to optimized soil-adjusted vegetation index (SAVI) with the aim of reducing the sensitivity of the NDVI to soil background and atmospheric effects.^{51,52} Recently, the OSAVI has also been used for canopy stress detection, chlorophyll content estimation, monitoring nitrogen (N) status and estimating vegetal biomass and canopy coverage.⁶⁷⁻⁷¹ However, all the VIs tested on this study presented high values of accuracy, effectively distinguishing weeds relative to other targets before planting (with 277.71 cm² of spatial resolution).

One of the constraints of this study was related to the spatial resolution utilized with the sensor for collecting the spectral data, limiting the extrapolation of this information to lower scale of spatial resolution. Another limitation is related to the soil and crop residues conditions

at the time of collecting the readings. The spectral curves of soil and residues were determined by the cumulative property resulting from heterogenic combinations of mineral and organic material and their moisture.^{74,75} Daughtry showed that crop residues and soil have similar behavior for the spectral curves under different water content, but both targets presented an increase in the reflectance values when the presented contrasting moisture levels (dry vs. wet conditions).⁵⁷ This complex interaction between the targets and the environmental conditions should be explored in future studies.

CONCLUSIONS

The results of this research provided useful pre-planting data source for distinguishing weeds related to other targets using high spatial resolution ground-sensing. The findings could support further field applications of spectral data in the field for improving SSWM.

The main outcomes of this study were that: (i) spectral curves of weeds, sandy soil, and crop residues were similar for both training and validation data sets permitting evaluate a large database for discriminating weeds relative to other targets; (ii) spectral bands, red and NIR had greater values of accuracy to discriminate weeds relative to crop residues, sandy and clay texture soils; (iii) the VIs: EVI, EVI2, OSAVI, SAVI, NDVI, NIR - RED and NIR/RED had the greater values of accuracy to discriminate weeds relative to others targets when compared with single spectral bands.

The thresholds of VIs defined in this study might provide values of classification of weeds relative to other targets in the fields using multiples alternatives sensors according with the presented results.

The next step on SSWM studies will be to aggregate different spatial resolutions with multiples platforms (such as satellites, unmanned aerial vehicle (UAV) and proximal sensors) to analyze the influence the VIs when considered several weed densities in pre-planting cash crop. In addition, future investigations should look into the performance of the remote sensing tools for identifying weeds when considering more environmental and soil factors as variables to be included in the analyses.

Author Contributions: Conceptualization, L. P. P., T. J. C. A. and I. A. C.; L. P. P. led the writing of the paper; L. P. P. and R. A. S. lead the statistical analysis; T. J. C. A. and R. A. S. contributed to the data discussion; E. S., M. J. and I. A. C. contributed in writing-review and editing the paper; I. A. C. led the study and contributed to the data analysis/discussion.

Funding:

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES) Finance Code 001. Aquarius project (<http://w3.ufsm.br/projetoaquarius/index.php/pt/>) and Kansas Corn Commission.

Conflicts of Interest:

The authors declare no conflict of interest.

REFERENCES

1. Harper, J. L. (1977). The population biology of plants. Academic Press, London, UK.
2. Swanton CJ, Nkoa R, and Blackshaw RE, Experimental Methods for Crop–Weed Competition Studies, *Weed Sci* **63**:2–11 (2015).
3. Jha P, Kumar V, Godara RK, and Chauhan BS, Weed management using crop competition in the United States: A review, *Crop Prot* **95**:31–37, Elsevier Ltd (2017).
4. Oerke EC, Crop losses to pests, *J Agric Sci* **144**:31–43 (2006).
5. Gharde Y, Singh PK, Dubey RP, and Gupta PK, Assessment of yield and economic losses in agriculture due to weeds in India, *Crop Prot* **107**:12–18, Elsevier (2018).
6. Slaughter DC, Giles DK, and Downey D, Autonomous robotic weed control systems: A review, *Comput Electron Agric* **61**:63–78 (2008).
7. Pantazi XE, Moshou D, and Bravo C, Active learning system for weed species recognition based on hyperspectral sensing, *Biosyst Eng* **146**:193–202, Elsevier Ltd (2016).
8. Shirzadifar A, Bajwa S, Mireei SA, Howatt K, and Nowatzki J, Weed species discrimination based on SIMCA analysis of plant canopy spectral data, *Biosyst Eng* **171**:143–154, Elsevier Ltd (2018).
9. Harker KN and O’Donovan JT, Recent Weed Control, Weed Management, and Integrated Weed Management, *Weed Technol* **27**:1–11 (2013).

10. Andújar D, Rueda-Ayala V, Moreno H, Rosell-Polo JR, Escolà A, Valero C, *et al.*, Discriminating crop, weeds and soil surface with a terrestrial LIDAR sensor, *Sensors (Switzerland)* **13**:14662–14675 (2013).
11. Gerhards R and Christensen S, Real-time weed detection, decision making and patch spraying in maize, sugarbeet, winter wheat and winter barley, *Weed Res* **43**:385– 392 (2003).
12. Young DL, Kwon TJ, Smith EG, and Young FL, Site-specific herbicide decision model to maximize profit in winter wheat Special Issue Number 3 on the European Conferences on Precision Agriculture, *Precis Agric* **4**:227–238 (2003).
13. Rew LJ and Cousens RD, Spatial distribution of weeds in arable crops: Are current sampling and analytical methods appropriate?, *Weed Res* **41**:1–18 (2001).
14. Barroso J, Fernandez-Quintanilla C, Maxwell BD, and Rew LJ, Simulating the effects of weed spatial pattern and resolution of mapping and spraying on economics of site-specific management, *Weed Res* **44**:460–468 (2004).
15. Peteinatos GG, Weis M, Andújar D, Ayala VR, Gerhards R, Potential use of ground-based sensor technologies for weed detection, *Pest Manag Sci* **70**:190-199 (2013).
16. Scotford IM and Miller PCH, Applications of spectral reflectance techniques in northern European cereal production: A review, *Biosyst Eng* **90**:235–250 (2005).
17. Huang Y, Lee MA, Thomson SJ, and Reddy KN, Ground-based hyperspectral remote sensing for weed management in crop production, *Int J Agric Biol Eng* **9**:98–109 (2016).
18. Akbarzadeh S, Paap A, Ahderom S, Apopei B, and Alameh K, Plant discrimination by Support Vector Machine classifier based on spectral reflectance, *Comput Electron Agric* **148**:250–258 (2018).
19. Rogalski A, Infrared detectors: Status and trends, *Prog Quantum Electron* **27**:59– 210 (2003).
20. Wang N, Zhang N, Peterson DE, and Dowell FE, Design of an optical weed sensor using

- plant spectral characteristics, *Biolog. Qual. Prec. Agric. II* **4203**: 409-419 (2001).
21. Huete AR, Jackson RD, and Post, DF, Spectral response of a plant canopy with different soil backgrounds, *Remote Sens Environ* **17**:37–53 (1985).
 22. Langner HR, Böttger H, and Schmidt H, A special vegetation index for the weed detection in sensor based precision agriculture, *Environ Monit Assess* **117**:505–518 (2006).
 23. Gausman H. Plant leaf optical properties. Texas Tech Press, Lubbock, Texas. (1985).
 24. Fletcher RS and Reddy KN, Random forest and leaf multispectral reflectance data to differentiate three soybean varieties from two pigweeds, *Comput Electron Agric* **128**:199–206 (2016).
 25. Dordas C, Nitrogen nutrition index and leaf chlorophyll concentration and its relationship with nitrogen use efficiency in barley (*Hordeum vulgare* L.), *J Plant Nutr* **40**:1190–1203 (2017).
 26. Ray T, Murray B, Chehbouni A, and Njoku E, The red edge in arid region vegetation: 340–1060 nm spectra. Summaries of the 4th Annual JPL Airborne Geoscience Workshop. Ed.1. AVIRIS Workshop. Jet Propulsion Laboratory, Pasadena, CA (1993).
 27. Gao J, Nuyttens D, Lootens P, He Y, and Pieters JG, Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery, *Biosyst Eng* **170**:39–50 (2018).
 28. Dordas CA and Sioulas C, Safflower yield, chlorophyll content, photosynthesis, and water use efficiency response to nitrogen fertilization under rainfed conditions, *Ind Crops Prod* **27**:75–85 (2008).
 29. Ziadi N, Brassard M, Bélanger G, Claessens A, Tremblay N, Cambouris AN, *et al.*, Chlorophyll measurements and nitrogen nutrition index for the evaluation of corn nitrogen status, *Agron J* **100**:1264–1273 (2008).

30. Imani M and Ghassemian H, Two Dimensional Linear Discriminant Analyses for Hyperspectral Data, *Photogramm Eng Remote Sens* **81**:777–786 (2015).
31. Henry WB, Shaw DR, Reddy KR, Bruce LM, and Tamhankar HD, Spectral reflectance curves to distinguish soybean from common cocklebur (*Xanthium strumarium*) and sicklepod (*Cassia obtusifolia*) grown with varying soil moisture, *Weed Sci* **52**:788-796 (2004).
32. Gray CJ, Shaw DR, and Bruce LM, Utility of Hyperspectral Reflectance for Differentiating Soybean (*Glycine max*) and Six Weed Species, *Weed Technol* **23**:108–119 (2009).
33. Sardá-Espinosa A, Subbiah S, and Bartz-Beielstein T, Conditional inference trees for knowledge extraction from motor health condition data, *Eng Appl Artif Intell* **62**:26– 37 (2017).
34. Breiman, L, Random forests, *Mach Learn* **45**:5-32 (2001).
35. Belgiu M and Drăgu L, Random forest in remote sensing: A review of applications and future directions, *ISPRS J Photogramm Remote Sens* **114**:24–31 (2016).
36. Nitze I, Barrett B, and Cawkwell F, Temporal optimisation of image acquisition for land cover classification with random forest and MODIS time-series, *Int J Appl Earth Obs Geoinf* **34**:136–146, Elsevier B.V. (2015).
37. Shirazi MA and Boersma L, A Unifying Quantitative Analysis of Soil Texture1, *Soil Sci Soc Am J* **48**:142 (2010).
38. FieldSpec® HandHeld 2™ Spectroradiometer User Manual. ASD Document 600860 Rev. D. (2010). Available online: <http://www.geo-informatie.nl/courses/grs60312/material2017/manuals/600860-dHH2Manual.pdf> accessed on 02/02/2019)
39. Hess M, Barralis G, Bleiholder H, Buhr L, Eggers T, Hack H, *et al.*, Use of the extended BBCH scale - General for the descriptions of the growth stages of mono- and dicotyledonous weed species, *Weed Res* **37**:433–441 (1997).

40. Alkarkhi AFM and Alqaraghuli WAA, Discriminant Analysis and Classification, *Easy Stat Food Sci with R* **1**:161–175 (2018).
41. Dray S and Dufour A, The ade4 package: implementing the duality diagram for ecologists. *J Stat Softw* **22**:1–20 (2007).
42. R Core Team, R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria (2018). Available online: <https://www.R-project.org/> (accessed on 02/01/2019).
43. Wu Z, Snyder G, Vadnais C, Arora R, Babcock M, Stensaas G, Doucette P, Newman, T, User needs for future Landsat missions, *Remote Sens Environ* **231**:111214 (2019).
44. Zeileis A and Hothorn T, partykit: A toolkit for recursive partytioning. *J Mach Learn Res* **16**:3905–3909 (2015).
45. Hothorn T, Hornik K, and Zeileis A, Unbiased recursive partitioning: A conditional inference framework, *J Comput Graph Stat* **15**:651–674 (2006).
46. Liaw A, Wiener M, Classification and regression by randomForest, *R News* **1**:18- 22 (2002).
47. Genuer R, Poggi JM, and Tuleau-Malot C, Variable selection using random forests, *Pattern Recognit Lett* **31**:2225–2236 (2010).
48. Kuhn M, caret: Classification and Regression Training, *J Stat Softw* **28**:1-26 (2008).
49. Huete A, Didan K, Miura T, Rodriguez EP, Gao X, and Ferreira LG, Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens Environ* **83**:195–213 (2002).
50. Jiang Z, Huete AR, Didan K, and Miura T, Development of a two-band enhanced vegetation index without a blue band, *Remote Sens Environ* **112**:3833–3845 (2008).
51. Rondeaux G, Steven M, and Baret F, Optimization of soil-adjusted vegetation indices, *Remote Sens Environ* **55**:95–107 (1996).

52. Huete AR, A soil-adjusted vegetation index (SAVI), *Remote Sens Environ* **25**:295– 309 (1988).
53. Rouse JW, Haas RH, Schell JA, and Deering DW, Monitoring vegetation systems in the great plains with ERTS. In Third ERTS-1 Symposium, section A, NASA, Washington, DC, 1st ed., 309-317, (1973).
54. Vogelmann JE, Rock BN, and Moss DM, Red edge spectral measurements from sugar maple leaves, *Int J Remote Sens* **14**:1563–1575 (1993).
55. Deng W, Huang YB, Zhao CJ, and Wang X, Identification of seedling cabbages and weeds using hyperspectral imaging, *Int J Agric Biol Eng* **8**:65–72 (2015).
56. Garcia-Ruiz FJ, Wulfsohn D, and Rasmussen J, Sugar beet (*Beta vulgaris* L.) and thistle (*Cirsium arvensis* L.) discrimination based on field spectral data, *Biosyst Eng* **139**:1–15 (2015).
57. Daughtry CST, Agroclimatology: Discriminating crop residues from soil by shortwave infrared reflectance, *Agron J* **93**:125–131 (2001).
58. Conforti M, Froio R, Matteucci G, and Buttafuoco G, Visible and near infrared spectroscopy for predicting texture in forest soil: An application in southern italy, *IForest* **8**:339–347 (2015).
59. White K, Walden J, Drake N, Eckardt F, and Settle, J. Mapping the iron oxide content of dune sands, Namib Sand Sea, Namibia, using Landsat thematic mapper data. *Remote Sens Environ* **62**:30-39 (1997).
60. GRDC - Grains Research and Development Corporation. Spray application manual for grain growers. Module 20. Target-selectable sprayers, how they work and set-up considerations. 2017. Available online: https://grdc.com.au/data/assets/pdf_file/0024/234654/20grdcsm20targetselectablesprayers.pdf (accessed on

02/02/2019).

61. Hatfield JL, Gitelson AA, Schepers JS, and Walthall CL, Application of spectral remote sensing for agronomic decisions, *Agron J* **100**: S-117-S-131 (2008).
62. Cao Z, Yao X, Liu H, Liu B, Cheng T, Tian Y, *et al.*, Comparison of the abilities of vegetation indices and photosynthetic parameters to detect heat stress in wheat, *Agr Forest Meteorol* **265**:121-136 (2019).
63. Wang W, Yao X, Yao X, Tian Y, Liu X, Ni J, *et al.*, Estimating leaf nitrogen concentration with three-band vegetation indices in rice and wheat. *Field Crops Research* **129**:90–98 (2012).
64. Zhao B, Duan A, Ata-Ul-Karim ST, Liu Z, Chen Z, Gong Z, *et al.*, Exploring new spectral bands and vegetation indices for estimating nitrogen nutrition index of summer maize, *Eur J Agron* **93**:113–125 (2018).
65. Schwalbert RA, Amado TJC, Nieto L, Varela S, Corassa GM, Horbe TAN, *et al.*, Forecasting maize yield at field scale based on high-resolution satellite imagery, *Biosyst Eng* **171**:179–192 (2018).
66. Almeida J, Santos JA, Miranda WO, Alberton B, Morellato LPC, and Torres RS, Ecological informatics deriving vegetation indices for phenology analysis using genetic programming, *Ecol Inform* **26**:61–69 (2015).
67. Suárez L, Zarco-Tejada PJ, Sepulcre-Cantó G, Pérez-Priego O, Miller JR, Jiménez-Muñoz JC, *et al.*, Assessing canopy PRI for water stress detection with diurnal airborne imagery, *Remote Sens Environ* **112**:560–575 (2008).
68. Wu C, Niu Z, Tang Q, and Huang W, Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation, *Agric For Meteorol* **148**:1230–1241 (2008).
69. Gabriel JL, Zarco-Tejada PJ, López-Herrera PJ, Pérez-Martín E, Alonso-Ayuso M,

and Quemada M, Airborne and ground level sensors for monitoring nitrogen status in a maize crop, *Biosyst Eng* **160**:124–133 (2017).

70. Fern RR, Foxley EA, Bruno A, and Morrison ML, Suitability of NDVI and OSAVI as estimators of green biomass and coverage in a semi-arid rangeland, *Ecol Indic* **94**:16– 21 (2018).

71. Ren H and Zhou G, Estimating green biomass ratio with remote sensing in arid grasslands, *Ecol Indic* **98**:568–574 (2019).

72. Christensen S, SØgaard HT, Kudsk P, NØrremark M, Lund I, Nadimi ES, *et al.*, Site-specific weed control technologies, *Weed Res* **49**:233–241 (2009).

73. Hansen KD, Garcia-Ruiz F, Kazmi W, Bisgaard M, La Cour-Harbo A, Rasmussen J, *et al.*, An autonomous robotic system for mapping weeds in fields, *IFAC Proc Vol* **8**:217–224 (2013).

74. Stoner ER and Baumgardner MF, Characteristic Variations in Reflectance of Surface Soils¹, *Soil Sci Soc Am J* **45**:1161 (2010).

75. Demattê JAM, Terra FS, Quartaroli CF, Spectral behavior of some modal soil profiles from São Paulo state, Brazil, *Bragantia* **71**:413–23 (2012).

3. CONCLUSÃO

Os sensores ópticos são capazes de diferir alvos agrícolas e não-agrícolas através da distinção em curvas espectrais, possibilitando controle de plantas daninhas em sítio-específico, em pré-semeadura de culturas agrícolas.

A distinção pode ser realizada utilizando bandas espectrais mais eficientes na diferenciação de plantas daninhas de outros alvos, bem como índices de vegetação que utilizam bandas espectrais para sua confecção.

A utilização de ferramentas de agricultura de precisão como sensores ópticos possibilitam a maior eficiência na identificação e tornam-se uma ferramenta para manejo de plantas daninhas em sítio-específico, podendo obter maior eficiência na utilização de herbicidas, bem como atenuando questões ambientais.

Futuros estudos com sensores de plantas daninhas devem focar em investigações sobre diferenças de resolução espacial e suas interferências na reflectância dos alvos com diferentes densidades de plantas daninhas, bem como exploração de maiores níveis de variação de solos, condições de umidade do solo e resíduos vegetais, entre outros.

REFERÊNCIAS

- ANTUNIASSI U. R. et al. Tecnologia de aplicação de defensivos. **Manual de manejo e controle de plantas daninhas**, 2010.
- BALASTREIRE, L. A.; BAILO, F. H. R. Avaliação de uma metodologia prática para o mapeamento de plantas daninhas. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 5, n. 2, p. 349-352, 2001.
- CARDINA, J. et al. Spatial relationships between seed bank and seedling populations of common lambsquarter (*Chenopodium album*) and annual grasses. **Weed Science**, v.44, p. 298-308, 1996.
- CARTER, G.A.; KNAPP, A.K. Leaf optical properties in higher plants: Linking spectral characteristics to stress and chlorophyll concentration. **American Journal of Botany**, v. 88, p. 677–684, 2001.
- CHIBA, M. K.; FILHO, O. G.; VIEIRA, S. R. Variabilidade espacial e temporal de plantas daninhas em Latossolo Vermelho argiloso sob semeadura direta. **Acta Scientiarum. Agronomy**, v. 32, n. 4, p. 735-742, 2010.
- DESSAINT, F. et al. Spatial pattern analysis of weed seeds in the cultivated soil seed bank. **Journal of Applied Ecology**, v. 28, p.721-730, 1991.
- FEYAERTS, F.; VAN GOOL, L. Multi-spectral vision system for weed detection. **Pattern Recognition Letters**, v. 22, p. 667–674, 2001.
- GERHARDS, R. et al. Spatial Stability of weed patches in agricultural fields. In: THE INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE. **Proceedings. Wisconsin: ASA: CSSA: SSSA**, p. 495-504, 1996.
- GIRMA, K. et al. Identification of optical spectral signatures for detecting cheat and ryegrass in winter wheat. **Crop Science**, v. 45, p. 477–485, 2005.
- HERRMANN, I. et al. Ground-level hyperspectral imagery for detecting weeds in wheat fields. **Precision Agriculture**, v. 14, p. 637–659, 2013.
- HUANG, Y. et al. Ground-based hyperspectral remote sensing for weed management in crop production. **International Journal of Agricultural and Biological Engineering**, v. 9, p. 98, 2016.
- JENSEN, J. R. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. Tradução da 2ª edição por (pesquisadores do INPE): José Carlos N. Epiphanyo (coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese, pp. 672, 2009.
- LAMB, D.W.; BROWN, R.B. Remote-sensing and mapping of weed in crops. **Journal of Agricultural Engineering Research**, v. 78, p. 117-125, 2001.

LÓPEZ-GRANADOS, F. et al. Early season weed mapping in sunflower using UAV technology: Variability of herbicide treatment maps against weed thresholds. **Precision Agriculture**, v. 17, p. 183–199, 2016.

LOTTE, P. et al. UAV-based crop and weed classification for smart farming. In Proceedings of the IEEE International Conference on Robotics and Automation (ICRA), **Anais Singapore**, 2017.

LOUARGANT, M. et al. Weed detection by UAV: Simulation of the impact of spectral mixing in multispectral images. **Precision Agriculture**, v. 18, p. 932–951, 2017.

LUTMAN, P.J.W.; PERRY, N.H. Methods of weed patch detection in cereal crops. In: THE BRIGHTON CONFERENCE- WEEDS, Brighton, 1999. **Anais Brighton**, p. 627-634, 1999.

MOLIN, J.P. et al. **Agricultura de precisão**. 1ª Edição, São Paulo, p.225, 2015.

MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação. São José dos Campos, 2001. **Instituto Nacional de Pesquisas Espaciais (INPE)**. 208pp.

NOVO, E.M.L.M. Sensoriamento remoto: princípios e aplicações. São Paulo, Edgard Blücher, 1989.

PEÑA, J.M. et al. Quantifying efficacy and limits of unmanned aerial vehicle (UAV) technology for weed seedling detection as affected by sensor resolution. **Sensors**, v. 15, p. 5609–5626, 2015.

PEÑA, J.M. et al. Weed mapping in early-season maize fields using object-based analysis of unmanned aerial vehicle (UAV) images. **PLoS ONE**, v. 8, e77151, 2013.

PÉREZ-ORTIZ, M. et al. Selecting patterns and features for between-and within-crop-row weed mapping using UAV-imagery. **Expert System with Applications**, v. 47, p. 85–94, 2016.

POTT, L. P. et al. Novas perspectivas no controle de plantas daninhas com base na agricultura de precisão. **Revista plantio direto**, v. 152, p. 14-21, 2006.

POTT, L. P. et al. Variabilidade espacial da planta daninha azevém em cultivo de trigo utilizando diferentes malhas amostrais. **Revista Tecno-Lógica**, v. 23, n. 2, p. 93-99, 2019.

POTT, L. P. et al. Utilização de reflectância de alvos para detecção de plantas daninhas em pré-semeadura In: **Livro Digital Congresso Sul Americano De Agricultura De Precisão E Máquinas Precisas**.1 ed. CESPOL, p. 112-115, 2018.

R DEVELOPMENT CORE TEAM. R: A Language and Environment for Statistical Computing. Vienna, R Foundation for Statistical Computing. 2019. Disponível em: <<https://www.r-project.org/>>. Acessado em 11 de setembro de 2019.

SCHAFFRATH, V. R. et al. Variabilidade espacial de plantas daninhas em dois sistemas de manejo de solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 11, n 1, p. 53-60, 2007.

SHAPIRA, U. et al. Field spectroscopy for weed detection in wheat and chickpea fields. **Int. J. Remote Sensing**, v. 34, p. 6094–6108, 2013.

SHIRATSUCHI L.S. et al. **Mapeamento da variabilidade espacial das plantas daninhas**. 1ª Edição, 2003.

TORRES-SÁNCHEZ, J. et al. Configuration and specifications of an unmanned aerial vehicle (UAV) for early site specific weed management. **Precision Agriculture**, v. 8, p. 58210, 2013.

VRINDTS, E. et al. Weed detection using canopy reflection. **Precision Agriculture**, v. 3, n. 1, p. 63-80, 2002.

WESTWOOD, J. H. et al. Weed management in 2050: perspectives on the future of weed science. **Weed Science**, v. 66, p. 275–285, 2017.

ZHANG, C.; KOVACS, J.M. The application of small unmanned aerial systems for precision agriculture: A review. **Precision Agriculture**, v. 13, p. 693–712, 2012.