

LARISSA PEREIRA RIBEIRO

**ÍNDICES DE VEGETAÇÃO NO MELHORAMENTO DA SOJA: APLICAÇÕES NA
ESCOLHA DE GENITORES E NA PREDIÇÃO DO CICLO**

Tese apresentada à Universidade Federal de Viçosa,
como parte das exigências do Programa de Pós-
Graduação em Genética e Melhoramento, para
obtenção do título de *Doctor Scientiae*.

VIÇOSA
MINAS GERAIS - BRASIL
2019

**Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa**

T

R484i
2019
Ribeiro, Larissa Pereira, 1995-
Índices de vegetação no melhoramento da soja : aplicações
na escolha de genitores e na predição do ciclo / Larissa Pereira
Ribeiro. – Viçosa, MG, 2019.
viii, 52 f. : il. ; 29 cm.

Inclui apêndice.

Orientador: Leonardo Lopes Bhering.

Tese (doutorado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Glycine max. 2. Soja - Melhoramento genético.
3. Sensoriamento remoto. 4. Inteligência computacional.
5. Otimização combinatória. I. Universidade Federal de Viçosa.
Departamento de Biologia Geral. Programa de Pós-Graduação
em Genética e Melhoramento. II. Título.

CDD 22. ed. 633.342

LARISSA PEREIRA RIBEIRO

**ÍNDICES DE VEGETAÇÃO NO MELHORAMENTO DA SOJA: APLICAÇÕES NA
ESCOLHA DE GENITORES E NA PREDIÇÃO DO CICLO**

Tese apresentada à Universidade Federal de Viçosa,
como parte das exigências do Programa de Pós-
Graduação em Genética e Melhoramento, para
obtenção do título de *Doctor Scientiae*.

APROVADA: 03 de janeiro de 2019.

Cosme Damião Cruz

Leonardo Siqueira Glória

Leonardo de Azevedo Peixoto

Paulo Ricardo dos Santos

Leonardo Lopes Bhering
(Orientador)

A Deus, por me guiar em todo meu caminho

OFEREÇO

Aos meus pais, José Antonio e Marlene, que sempre me apoiaram e se dedicaram à minha formação, me ensinando que as coisas mais importantes na vida são a educação e o conhecimento.

Ao meu esposo, Paulo Eduardo Teodoro, pelo amor, carinho, amizade, companheirismo e incentivo.

DEDICO

AGRADECIMENTOS

Agradeço primeiramente a DEUS, pela vida e por proporcionar tudo que sou e tenho.

Aos meus pais, Marlene Pereira Leite e José Antonio Ribeiro de Oliveira, pelo apoio, incentivo e por todo amor e carinho a mim dedicados.

Ao meu esposo, Paulo Eduardo Teodoro, por todo o amor, carinho, companheirismo e ajuda ao longo da minha formação acadêmica, sendo o meu suporte e minha inspiração durante esta caminhada.

Ao meu orientador, Leonardo Lopes Bhering, pelos ensinamentos, amizade e por ser um modelo de profissional a ser seguido.

Aos membros da banca de qualificação e defesa, pela contribuição na melhoria deste trabalho.

Ao Professor Cosme Damião Cruz pelo brilhantismo, humildade e por ser um exemplo de profissional.

À Universidade Federal de Mato Grosso do Sul, em especial ao Grupo de Estudos em Melhoramento de Plantas (GEMP) e aos professores Fabio Baio e Cid Naudi Campos pela parceria e contribuição na execução dos experimentos.

Ao professor Felipe Lopes da Silva e ao Programa Soja pela parceria e contribuição na execução dos experimentos.

Aos meus amigos Lidiane Aparecida da Silva, Leonardo de Azevedo Peixoto, Bruno Ermelindo Lopes e demais colegas do Laboratório de Biometria pelo companheirismo e aprendizagem.

À Universidade Federal de Viçosa (UFV) e ao Programa de Pós-Graduação em Genética e Melhoramento, pela excelência e oportunidade de prosseguir meus estudos.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de doutorado.

Aos secretários e ao Programa de Pós-graduação em Genética e Melhoramento da Universidade Federal de Viçosa por toda atenção, dedicação e serviços prestados durante o mestrado.

A todos que de alguma forma contribuíram com carinho, atenção, amizade, apoio e incentivo para a conclusão desta importante etapa da minha vida. Deixo aqui meus sinceros e eternos agradecimentos.

*“Os grandes feitos são conseguidos não
pela força, mas pela perseverança.”*

Samuel Johnson

BIOGRAFIA

LARISSA PEREIRA RIBEIRO, filha de José Antonio Ribeiro de Oliveira e Marlene Pereira Leite, nasceu em Campo Grande/MS, no dia 09 de abril de 1995.

Ingressou no curso de Agronomia da Universidade Estadual do Mato Grosso do Sul em fevereiro de 2012, concluindo-o em dezembro de 2016.

Em março de 2017 ingressou no Mestrado em Genética e Melhoramento da Universidade Federal de Viçosa, concluindo-o em fevereiro de 2018.

Em março do mesmo ano ingressou no Doutorado em Genética e Melhoramento da Universidade Federal de Viçosa, submetendo-se à defesa em janeiro de 2019.

SUMÁRIO

RESUMO	vii
ABSTRACT	viii
INTRODUÇÃO GERAL	1
REFERÊNCIAS	3
CAPÍTULO I	6
RESUMO	7
PALAVRAS-CHAVE:	7
INTRODUÇÃO	8
MATERIAL E MÉTODOS	10
Obtenção das progênes na geração F ₁	10
Obtenção das progênes na geração F ₂	11
Condução das progênes na geração F ₂	11
Caracteres avaliados na geração F ₂	12
Análises estatísticas	14
RESULTADOS E DISCUSSÃO	15
CONCLUSÕES	27
REFERÊNCIAS	28
APÊNDICE	33
CAPÍTULO II	34
RESUMO	35
PALAVRAS-CHAVE	35
INTRODUÇÃO	36
MATERIAL E MÉTODOS	38
Condução do experimento	38
Caracteres avaliados	39
Conjunto de dados e modelagem da RNA	41
RESULTADOS E DISCUSSÃO	42
Análise exploratória	42
Regressão linear múltipla <i>versus</i> RNAs	43
Utilização da melhor topologia de RNA para predição do ciclo	47
CONCLUSÃO	48
REFERÊNCIAS	49

RESUMO

RIBEIRO, Larissa Pereira, D.Sc., Universidade Federal de Viçosa, janeiro de 2019. **Índices de vegetação no melhoramento da soja: aplicações na escolha de genitores e na predição do ciclo.** Orientador: Leonardo Lopes Bhering.

O principal objetivo do melhoramento da soja é incrementar a produtividade de grãos, um caráter complexo devido a ação de muitos genes e alto efeito ambiental. Nesse sentido, um novo grupo de caracteres podem ser utilizados: os índices de vegetação (IVs), que são relações entre a radiação refletida de duas ou mais bandas, e se caracterizam como algoritmos simples e eficazes para avaliações quantitativas e qualitativas da cobertura vegetal, vigor e dinâmica de crescimento de espécies vegetais. Esses caracteres podem ser utilizados na predição da produtividade de grãos e de características relacionadas à eficiência fotossintética, pois possuem alta herdabilidade e facilidade de mensuração de forma remota em um grande número de candidatos a seleção. Diante disto, essa pesquisa teve como objetivo geral utilizar índices de vegetação para seleção de genitores e predição de ciclo de genótipos de soja. Para isso, dois experimentos foram conduzidos, o primeiro com o objetivo de estimar a capacidade combinatória de cultivares de soja com base na geração F₂ visando identificar genitores e populações segregantes para caracteres agronômicos, fisiológicos e índices de vegetação (Capítulo I), e o segundo visando avaliar a eficiência das redes neurais artificiais (RNAs) na predição do ciclo de genótipos de soja utilizando IVs (Capítulo II). O primeiro experimento foi conduzido em delineamento de blocos aumentados com duas repetições para os 11 genitores utilizados como testemunha. Foram avaliadas 28 populações F₂ obtidas em esquema de dialelo parcial 4x7 e seus genitores. Os caracteres avaliados foram: número de dias para maturação, número de vagens por planta, número de nós por planta, número de hastes laterais por planta, produtividade de grãos, fotossíntese líquida, condutância estomática, concentração interna de CO₂, transpiração, bandas NIR, Red-edge, Red e Green, e índices de vegetação NDVI e NDRE. Houve predominância de efeitos aditivos no controle destes caracteres. No segundo experimento, 196 populações F_{2:5} e 10 testemunhas foram avaliadas, sendo mensurados os IVs: NDVI, NDRE, GNDVI e SAVI e o ciclo. Os dados foram ampliados para 600 indivíduos e particionado em 80% para treinamento das RNAs e 20% para validação. A arquitetura de rede utilizada foi a Perceptron Multicamadas, com duas camadas ocultas. Após a identificação da melhor topologia de rede neural (algoritmo de treinamento: trainbr, função de ativação: logsig, 10 neurônios na primeira camada oculta e 8 na segunda), esta foi utilizada para a predição do ciclo dos genótipos com base nos dados originais, obtendo R² de 73,97%.

ABSTRACT

RIBEIRO, Larissa Pereira, D.Sc., Universidade Federal de Viçosa, January, 2019. **Vegetation indices in soybean breeding: applications in the choice of parentes and cycle prediction.** Adviser: Leonardo Lopes Bhering.

Soybean production has grown considerably in the last three decades, which has characterized it as the main cultivated crop in Brazil. Among the factors responsible for this expansion stands out the genetic breeding. The main breeding goal is to increase grain yield, a complex trait due to the action of many genes and high environmental effect. In this sense, a new group of traits can be used: vegetation indices (VIs), which are relations between the reflected radiation of two or more bands, and are characterized as simple and effective algorithms for quantitative and qualitative evaluations of the vegetation cover, vigor and growth dynamics of plant species. These traits can be used to predict grain yield and trait related to photosynthetic efficiency, as they have high heritability and ease of measurement remotely in a large number of selection candidates. In view of this, this study had as general objective to use vegetation indices for parent selection and prediction of soybean cycle. For this, two experiments were conducted with the specific objectives of estimating the combining ability of soybean cultivars based on F₂ generation, aiming to identify parents and segregating populations for agronomic, physiological and vegetation indices (Chapter I) and to use artificial neural networks (ANNs) to predict the cycle of soybean genotypes by using VIs (Chapter II). The first experiment was conducted in a augmented block design with two replicates for the 11 parents used as checks. We evaluated 28 F₂ populations obtained in a 4x7 partial diallel scheme and their parents. The evaluated traits were: number of days for maturation, number of pods per plant, number of nodes per plant, number of lateral stems per plant, grain yield, net photosynthesis, stomatal conductance, CO₂ internal concentration, transpiration, Nir, Red-edge, Red and Green bands, and vegetation indices NDVI and NDRE. There was a predominance of additive effects in the control of these traits. In the second experiment, 196 F_{2:5} and 10 control populations were evaluated in DBA. We measured the VIs NDVI, NDRE, GNDVI and SAVI, and the cycle. The data were expanded to 600 individuals and partitioned into 80% for ANN training and 20% for validation. The network architecture used was the Multilayer Perceptron, with two hidden layers. After identifying the best neural network topology (training algorithm: trainbr, activation function: logsig, 10 neurons in the first hidden layer and 8 neurons in the second layer), this was used to predict the cycle based on the original data, obtaining R² of 73.97%.

INTRODUÇÃO GERAL

A soja [*Glycine max* (L.) Merrill] é a oleaginosa de maior importância econômica no mundo. A produção mundial na safra 2017/2018 foi de 338 milhões de toneladas em uma área cultivada de 124 milhões de hectares (USDA, 2018). No Brasil, a produção da cultura cresceu consideravelmente nas últimas três décadas. A produção na safra 2017/2018 foi de 119 milhões de toneladas em 35 milhões de hectares (Conab, 2018), o que representou um aumento de 5,6 vezes na produção em relação ao início da década de 80 (Abag, 2018). O cultivo da soja no país ocorre predominantemente no Cerrado (Silva et al., 2017), que se estende por uma área de 183.890,92 km² e abrange oito estados do Brasil Central: Minas Gerais, Goiás, Tocantins, Bahia, Maranhão, Mato Grosso, Mato Grosso do Sul, Piauí e o Distrito Federal (SojaMaps, 2018).

A obtenção de cultivares produtivas é o principal objetivo do melhoramento da soja (Silva et al., 2017). Contudo, o aumento da eficiência fotossintética tem se tornado alvo de diversos programas de melhoramento da cultura (Manavalan et al., 2009; Ainsworth et al., 2012; Mutava et al., 2015). A correlação positiva entre a taxa fotossintética e a produtividade em soja sugere que a melhoria da eficiência fotossintética pode ser um alvo promissor para novos ganhos de produtividade (Manavalan et al., 2009; Ainsworth et al., 2012; Karyawati et al., 2015). Entretanto, estudos sobre a capacidade combinatória de genótipos de soja para caracteres fisiológicos ainda são escassos na literatura.

Pesquisas mostram que há uma correlação entre as características fisiológicas de uma planta e a partição da radiação incidente em suas folhas (Jensen, 2009; Delegido et al., 2011; Xue e Su, 2017). A radiação solar ao atingir a folha pode ser refletida, absorvida ou transmitida. Este balanço de radiação está diretamente relacionado às características de superfície da folha, bem como a outras características internas da espécie vegetal (Almeida et al., 2005). A quantificação da radiação incidente visando o estudo do estado fisiológico da planta pode ser realizado por meio de índices de vegetação. Os índices de vegetação são relações entre a

radiação refletida de duas ou mais bandas, e se caracterizam como algoritmos simples e eficazes para avaliações quantitativas e qualitativas da cobertura vegetal, vigor e dinâmica de crescimento, entre outras aplicações (Xue e Su, 2017).

Os índices de vegetação podem ser excelentes caracteres secundários para predição da produtividade de grãos e de características relacionadas à eficiência fotossintética, pois possuem alta herdabilidade e facilidade de mensuração de forma remota em um grande número de indivíduos (Rutkoski et al., 2016). Assim, em um programa de melhoramento de soja onde centenas de linhagens são avaliadas anualmente, a mensuração de caracteres agronômicos e fisiológicos é onerosa, pois demanda mão-de-obra e tempo. Por exemplo, para realizar avaliações fisiológicas com precisão é necessário baixa nebulosidade e umidade relativa do ar para estabilização das medições. Tais limitações podem ser superadas com o uso de índices de vegetação. Neste sentido, os índices de vegetação vêm sendo amplamente utilizados na predição da produtividade de grãos, especialmente em trigo (Gutierrez-Rodriguez et al., 2004; Marti et al., 2007; Rutkoski et al., 2016) e soja (Ma et al., 2001; Mourtzinis et al., 2014; Christenson et al., 2016). Contudo, o uso de índices de vegetação como caracteres auxiliares na seleção nos programas de melhoramento é recente, e trabalhos utilizando esta abordagem ainda são escassos na literatura.

Os índices de vegetação correlacionam-se de forma não-linear com a maioria das características agronômicas (Panda et al., 2010), além de serem correlacionados entre si. Uma alternativa para o processamento destes dados é o uso de redes neurais artificiais (RNAs). As RNAs são técnicas computacionais inspiradas no cérebro humano, capazes de processar rapidamente uma grande quantidade de dados e de reconhecer padrões com base em sua autoaprendizagem. Esta abordagem tem como principais vantagens a não-linearidade, adaptatividade, generalização e tolerância a falhas (Haykin, 2009). Tais características fazem com que as RNAs produzam modelos preditivos pelo menos tão acurados, ou frequentemente melhores, do que as técnicas estatísticas convencionais (Blackard e Dean, 1999).

REFERÊNCIAS

Abag. 2018. O futuro da soja nacional. Associação Brasileira do Agronegócio. Disponível em: <<http://www.abag.com.br/media/images/0-futuro-da-soja-nacional---ieag---abag.pdf>>. Acesso em: 03/01/2019.

Ainsworth, E.A., Yendrek, C.R., Skoneczka, J.A., Long, S.P. 2012. Accelerating yield potential in soybean: potential targets for biotechnological improvement. *Plant. Cell. Environ.* 35:38-52.

Almeida, T.S., Fontana, D.C., Martorano, L.G., Bergamaschi, H. 2005. Índices de vegetação para a cultura da soja em diferentes condições hídricas e de sistema de manejo do solo. INPE, 17-24p.

Blackard, J.A., Dean, D.J. 1999. Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. *Comput. Electron. Agr.* 24: 131-151.

Christenson, B.S., Schapaugh, W.T., An, N., Price, K.P., Prasad, V., Fritz, A.K. 2016. Predicting soybean relative maturity and seed yield using canopy reflectance. *Crop Sci.* 56:625-643.

Conab. 2018. Acompanhamento da Safra Brasileira de Grãos, v. 12 Safra 2017/18, Décimo segundo levantamento. Companhia Nacional de Abastecimento, Brasília.

Delegido, J., Verrelst, J., Alonso, L., Moreno, J., 2011. Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors* 11:7063–7081.

Gutierrez-Rodriguez, M., Reynolds M.P., Escalante-Estrada J.A., Rodriguez-Gonzalez, M.T. 2004. Association between canopy reflectance indices and yield and physiological traits in bread wheat under drought and well-irrigated conditions. *Aust. J. Agric. Res.* 55:1139-1147.

Haykin, S. 2009. *Neural networks and learning machines*. 3rd ed. Prentice Hall, New York.

- Jensen, J.R. 2009. Remote Sensing of the Environment: An Earth Resource Perspective. Pearson Education India.
- Karyawati, A. S., Sitompul, S. M., Basuki, N. 2015. Combining ability analysis for physiological characters of soybean (*Glycine max* L. Merrill). Inter. J. Plant Res. 5:113-121.
- Ma, B.L., Dwyer, L.M., Costa, C., Cober, E.R., Morrison, M.J. 2001. Early prediction of soybean yield from canopy reflectance measurements. Agron. J. 93:1227–1234.
- Manavalan, L.P., Guttikonda, S.K., Tran, L.S., Nguyen, H.T. 2009. Physiological and molecular approaches to improve drought resistance in soybean. Plant Cell. Physiol 50:1260-1276.
- Marti, J., Bort, J., Slafer, G.A., Araus, J.L. 2007. Can wheat yield be assessed by early measurements of Normalized Difference Vegetation Index? Ann. Appl. Biol. 150:253-257.
- Mourtzinis, S., Rowntree, S.C., Suhre, J.J., Weidenbenner, N.H., Wilson, E.W., Davis, V.M., Specht, J.E. 2014. The use of reflectance data for in-season soybean yield prediction. Agron. J. 106:1159-1168.
- Mutava, R.N., Prince, S.J.K., Syed, N.H., Song, L., Valliyodan, B., Chen, W., Nguyen, H.T. 2015. Understanding abiotic stress tolerance mechanisms in soybean: a comparative evaluation of soybean response to drought and flooding stress. Plant Physiol. Biochem. 86:109-120.
- Panda, S.S., Ames, D.P., Panigrahi, S. 2010. Application of vegetation indices for agricultural crop yield prediction using neural network techniques. Remote Sens. 2:673-696.
- Rutkoski, J., Poland, J., Mondal, S., Autrique, E., Pérez, L.G., Crossa, J, Reynolds, M., Singh, R. 2016. Canopy temperature and vegetation indices from high-throughput phenotyping improve accuracy of pedigree and genomic selection for grain yield in wheat. G3-Genes Genom. Genet. g3-116.

Silva, F.C.S., Sedyama, T., Oliveira, R.C.T., Borém, A., Silva, F.L., Bezerra, A.R.G., Silva, A.F. 2017. Importância econômica e evolução do melhoramento. In: Silva, F.L., Borém, A., Sedyama, T., Ludke, W. (Eds). Melhoramento da Soja. UFV, Viçosa.

SojaMaps. Monitoramento de áreas de soja por meio de imagens de satélite. Geotecnologia Aplicada em Agricultura e Floresta, Universidade do Estado de Mato Grosso. Disponível em: < <http://pesquisa.unemat.br/gaaf/sojamaps> >. Acesso em: 23/11/2018.

USDA. 2018. World Agricultural Production. United States Department of Agriculture-USDA, Circular Series.

Xue, J., Su, B. 2017. Significant remote sensing vegetation indices: A review of developments and applications. J. Sensors 2017:1-17.

CAPÍTULO I

ANÁLISE DIALÉLICA DE CARACTERES AGRONÔMICOS, FISIOLÓGICOS E ÍNDICES DE VEGETAÇÃO EM SOJA

RESUMO

Grande parte dos programas de melhoramento de soja buscam desenvolver cultivares mais produtivas e com alta eficiência fotossintética. Neste sentido, os índices de vegetação surgem como uma abordagem promissora na identificação de genótipos superiores para estes caracteres. O objetivo deste trabalho foi estimar a capacidade combinatória de cultivares de soja com base na geração F₂, visando identificar genitores e populações segregantes para caracteres agronômicos, fisiológicos e índices de vegetação. O experimento foi conduzido na safra 2017/2018 em delineamento de blocos aumentados com duas repetições para os 11 genitores utilizados como testemunha. Foram avaliadas 28 populações F₂ obtidas em esquema de dialelo parcial 4x7 e seus genitores. Os caracteres avaliados foram: número de dias para maturação, número de vagens por planta, número de nós por planta, número de hastes laterais por planta, produtividade de grãos, fotossíntese, condutância estomática, concentração interna de CO₂, transpiração, bandas NIR, Red-edge, Red e Green, e índices de vegetação NDVI e NDRE. Houve efeito significativo de genótipos para todos caracteres avaliados, com exceção das reflectâncias Red e Green. Os efeitos de genótipos foram desdobrados em efeitos de capacidade geral e específica de combinação (CGC e CEC, respectivamente) para os genitores dispostos em dois grupos. Houve predominância de efeitos aditivos no controle destes caracteres. As populações provenientes do cruzamento entre os genitores SYN 13671 IPRO e TMG 7062 IPRO, e os genitores BMX Flecha 6266 RSF IPRO e BMX Bônus 8579RSF IPRO, apresentam maior potencial para obtenção de linhagens superiores para precocidade, produtividade e eficiência fotossintética.

PALAVRAS-CHAVE: *Glycine max*, capacidade de combinação, dialelo parcial, populações segregantes, sensoriamento remoto.

INTRODUÇÃO

Nos últimos anos, a produtividade da soja [*Glycine max* (L.) Merrill] aumentou consideravelmente no Brasil. Dentre os fatores que contribuíram para isto, destaca-se o melhoramento genético (Silva et al., 2017). A primeira etapa de um programa de melhoramento, visando a obtenção de cultivares de soja, é avaliar a diversidade genética em um grupo de genitores para identificar os cruzamentos que proporcionem maior efeito heterótico, aumentando a probabilidade de obtenção de segregantes transgressivos (Bhering et al., 2017). Dentre os métodos fundamentados em modelos biométricos, destinados à avaliação da diversidade de genitores, os principais são os cruzamentos dialélicos.

Por meio deste delineamento genético é possível conhecer o controle genético dos caracteres avaliados, o que auxilia na condução e na seleção das populações segregantes (Baker, 1978). O dialelo também possibilita ao melhorista conhecer informações em relação ao comportamento *per se* dos genitores, denominada capacidade geral de combinação (CGC), e de suas combinações híbridas, denominada capacidade específica de combinação (CEC). A CGC é atribuída a genes com efeitos aditivos, enquanto a CEC está relacionada aos efeitos gênicos não-aditivos, que caracteriza a diferença das combinações híbridas em relação ao comportamento médio dos genitores (Cruz e Vencovsky, 1989). Desta forma, é possível selecionar populações segregantes com alta CEC para os caracteres de interesse e que incluam pelo menos um dos genitores com alta CGC (Cruz et al., 2012).

A soja possui restrição quanto a utilização de plantas na geração F_1 para análise dialélica, devido à baixa disponibilidade de sementes. Esse problema pode ser contornado com a utilização da geração F_2 (Bhullar et al., 1979; Cho e Scott, 2000; Friedrichs et al., 2016). Porém, a cada geração de autofecundação avançada a partir de F_1 , a contribuição do desvio de dominância na média da população é reduzida à metade. Isso pode fazer com que o efeito de CEC não seja significativo nas gerações subsequentes e ocasionar a perda de informação sobre a complementação dos genes entre os genitores utilizados (Pimentel et al., 2013). Contudo, o

uso de dialelo parcial pode ser mais apropriado, uma vez que nesse tipo de dialelo a magnitude da CGC, além de quantificar a frequência de alelos favoráveis, indica a diversidade genética entre o genitor de um grupo e os do grupo oposto (Viana, 2007). O uso desta metodologia para avaliar plantas na geração F_2 têm sido aplicada ao melhoramento de diversas culturas, como trigo (Bhullar et al., 1979; Javaid et al., 2001; Pimentel et al., 2013), soja (Cho e Scott, 2000; Carvalho et al., 2009; Rocha et al., 2018) e feijão (Rosal et al., 2000; Do Vale, 2015).

Grande parte dos programas de melhoramento de soja buscam desenvolver cultivares mais produtivas. Contudo, a produtividade de grãos é um caráter complexo controlado por vários genes, que sofrem alto efeito ambiental. Nesse sentido, cresce a busca de caracteres auxiliares que possuam alta precisão na avaliação e sofram menor efeito ambiental. Dentre estes, podem ser utilizados os índices de vegetação, que são relações matemáticas entre diferentes comprimentos de onda (Baio et al., 2018). Os índices de vegetação têm sido aplicados no monitoramento do estado da cultura e predição de produtividade (Sultana et al., 2014). Devido à sua mensuração em um grande número de candidatos a seleção, oferecendo resultados acurados e em tempo reduzido, o uso de índices de vegetação nos programas de melhoramento se constituem em uma técnica promissora.

Contudo, ainda não existem trabalhos sobre análise dialélica com base em índices de vegetação. O estudo da capacidade combinatória de genótipos baseado em informações sobre índices de vegetação permitirá a compreensão da ação gênica envolvida na herança destes caracteres, contribuindo para uma maior eficiência de programas voltados ao melhoramento fisiológico da soja.

O objetivo deste trabalho foi estimar a capacidade combinatória de cultivares de soja com base na geração F_2 , visando identificar genitores e populações segregantes superiores para caracteres agrônômicos, fisiológicos e índices de vegetação.

MATERIAL E MÉTODOS

Obtenção das progênies na geração F₁

A obtenção dos híbridos foi realizada em casa de vegetação do Programa Soja do Departamento de Fitotecnia, na Universidade Federal de Viçosa (20°45'14"S; 42°52'53"W, 649 metros de altitude), entre os meses de outubro de 2016 a janeiro de 2017. Para montagem dos blocos de cruzamentos, foram selecionados genitores contrastantes para cor de flor, sendo os machos portadores de alelos para cor de flor roxa (dominante) e as fêmeas portadoras de alelos para cor de flor branca (recessiva). A divergência quanto ao grupo de maturidade relativa (GMR) também foi tomada como critério de seleção dos genitores (Tabela 1).

Tabela 1. Características das 11 cultivares de soja utilizados como genitores em cada grupo: cor da flor, cor do hipocótilo, grupo de maturidade relativa (GMR) e número referente ao genótipo no experimento (NG).

Cultivar	Cor da flor	Cor do hipocótilo	GMR	NG
Grupo I (genitores masculinos)				
BMX Prisma IPRO	Roxa	Roxo	7.5	1
M6952 IPRO	Roxa	Roxo	7.2	2
BMX Bônus IPRO	Roxa	Roxo	7.9	3
BMX Flecha IPRO	Roxa	Roxo	6.6	4
M6410 IPRO	Roxa	Roxo	6.4	5
NS 6909 IPRO	Roxa	Roxo	6.9	6
M7739 IPRO	Roxa	Roxo	7.7	7
Grupo II (genitores femininos)				
BMX Ponta IPRO	Branca	Verde claro	6.1	8
DM 6563 RSF IPRO	Branca	Verde claro	6.3	9
SYN 13671 IPRO	Branca	Verde claro	7.1	10
TMG 7062 IPRO	Branca	Verde claro	6.2	11

Com base nas características citadas, foram selecionados 11 genitores transgênicos (portadores da tecnologia Intacta RR2 PRO™) e estes alocados em dois grupos: genitores masculinos (grupo I) e genitores femininos (grupo II).

Obtenção das progênies na geração F₂

A condução dos híbridos F₁ foi realizada em casa de vegetação do Programa Soja do Departamento de Fitotecnia, na Universidade Federal de Viçosa (20°45'14"S; 42°52'53"W, 649 metros de altitude), entre os meses de fevereiro de 2017 a junho de 2017. Os híbridos foram semeadas em vaso plástico de 3 L, sendo mantida uma planta por vaso após identificação das plantas híbridas caracterizadas pela cor roxa do hipocótilo. Os cruzamentos 11x5, 11x6, 9x2 e 9x6 foram perdidos devido a produção de poucas sementes pelas plantas, totalizando assim 24 populações segregantes. O controle de pragas e doenças foi realizado conforme recomendações técnicas para a cultura.

Condução das progênies na geração F₂

A condução das populações F₂ foi realizada no campo experimental da Universidade Federal de Mato Grosso do Sul, Campus de Chapadão do Sul (18°46'26"S, 52°37'28"W e altitude média de 810 m), no período de novembro de 2017 a fevereiro de 2018. Três meses antes da semeadura, a saturação por bases do solo da área experimental foi elevada para 60% por meio de uma calagem. Para implantação do experimento, foi utilizado preparo convencional do solo com uma aração e duas gradagens (com grade destorroadora e niveladora). A abertura e a adubação das linhas foram realizadas de forma mecanizada com uma semeadora John Deere® de cinco linhas no espaçamento de 0,45 m entre linhas. A adubação de base utilizada foi 300 kg ha⁻¹ do formulado 04-14-08. A semeadura foi realizada manualmente com a distribuição de 15 sementes por metro.

O experimento foi conduzido em delineamento de blocos aumentados com duas repetições para os 11 genitores utilizados como testemunha. A unidade experimental constou de três linhas de três metros para cada tratamento, espaçadas em 0,45 m. O controle de plantas daninhas, pragas e doenças foi realizado conforme recomendações técnicas para a cultura. A Figura 1 contém as condições climáticas observadas no decorrer do experimento.




Figura 1. Condições climáticas vigentes no período de condução do experimento.

Caracteres avaliados na geração F₂

Aos 60 dias após a emergência (DAE) foram analisados os caracteres fisiológicos com analisador portátil de fotossíntese (IRGA), modelo LCpro-SD da marca ADC. Foi utilizado fluxo de fótons fotossinteticamente ativos de $1000 \mu\text{mol m}^{-2} \text{s}^{-1}$ e concentrações de CO_2 ambiente ($372 \pm 10 \text{ mol s}^{-1} \text{ m}^{-2}$). As avaliações foram realizadas às 8:30 horas da manhã, em cinco plantas de cada unidade experimental, sendo obtidos os seguintes caracteres fisiológicos:

fotossíntese líquida (A , $\text{mmol CO}_2 \text{ m}^{-2} \text{ s}^{-1}$), transpiração (E , $\text{mmol H}_2\text{O s}^{-1} \text{ m}^{-2}$), condutância estomática (g_s , $\text{mmol m}^{-2} \text{ s}^{-1}$) e concentração interna de CO_2 (C_i , $\text{mmol m}^{-2} \text{ s}^{-1}$).

Além destas variáveis, foram avaliados aos 60 DAE os seguintes índices de vegetação (IVs): NDVI (*Normalized Difference Vegetation Index*) e NDRE (*Normalized Difference Red Edge Index*). Foi utilizada a aeronave remotamente pilotada (RPA) de asa fixa Sensefly eBee RTK, com controle autônomo de decolagem, plano de voo e aterrissagem. O eBee está equipado com o sensor multiespectral Sensefly Sequoia. O sensor multiespectral Sequoia faz aquisição da reflectância nos comprimentos de onda do verde (550 nm - Green), vermelho (660 nm - Red), infravermelho próximo (735 nm - NIR) e red-edge (790 nm), possuindo um sensor de luminosidade que permite a calibração dos valores adquiridos. As imagens foram mosaicadas e ortoretificadas pelo programa computacional Pix4Dmapper. A acurácia posicional das ortomagens foi verificada com pontos de controle em campo (GCP – *Ground Control Points*), levantados com o RTK. Os IVs estudados em função da maior correlação com a massa vegetal, segundo Raper e Varco (2015), estão contidos na Tabela 2.

Tabela 2. Relação dos índices de vegetação calculados pelo uso do sensor multiespectral Sequoia.

Índice de Vegetação	Índice de Vegetação	Equação	Referências
NDVI	Índice de vegetação pela diferença normalizada	$\frac{(R_{NIR} - R_{RED})}{(R_{NIR} + R_{RED})}$	Rouse et al. (1974)
NDRE	Índice de vegetação pela diferença normalizada à transição do vermelho (<i>Red-edge</i>)	$\frac{(R_{NIR} - R_{EDGE})}{(R_{NIR} + R_{EDGE})}$	Gitelson e Merzlyak (1994)

R_{NIR} : reflectância na faixa do infravermelho próximo; R_{RED} : reflectância na faixa do vermelho; R_{EDGE} : reflectância na faixa de transição do vermelho (Red-edge).

Os caracteres agronômicos avaliados foram: número de dias para maturação fisiológica (NDM), número de vagens por planta (NVP), número de nós por planta (NNP), número de hastes laterais por planta (NHL) e produtividade de grãos (PROD). O NDM correspondeu ao número de dias entre a germinação e a maturação em mais de 50% de plantas da parcela. Para avaliação dos demais caracteres foram selecionadas 15 plantas aleatoriamente em cada unidade experimental devido à baixa disponibilidade de sementes. Após a contagem dos caracteres NVP, NNP e NHL, a PROD foi obtida pela coleta e trilha individual destas plantas, sendo a massa expressa em g planta⁻¹ após correção da umidade dos grãos para 13%.

Análises estatísticas

Inicialmente, os dados foram submetidos a análise de variância conforme modelo estatístico de análise de blocos aumentados (Equação 1).

$$Y_{ij} = \mu + B_j + T_i + \varepsilon_{ij} \quad (1)$$

em que: Y_{ij} é o valor do caráter para o i -ésimo tratamento no j -ésimo bloco; μ é a média geral; B_j é o efeito do j -ésimo bloco; T_i é o efeito do i -ésimo tratamento, que pode ser decomposto em: t_i : efeito da i -ésima testemunha e P_i : efeito da i -ésima população F_2 ; ε_{ij} é o erro aleatório.

Devido ao desbalanceamento genético pela perda dos cruzamentos 11x5, 11x6, 9x2 e 9x6, os valores para estas populações em cada caráter foram estimados pelo modelo descrito na Equação 2:

$$\hat{Y}_{ij} = \hat{\mu} + \hat{g}_i + \hat{g}_j \quad (2)$$

em que: \hat{Y}_{ij} é média estimada para cada cruzamento perdido; $\hat{\mu}$ é a média geral do dialelo; \hat{g}_i é a estimativa do i -ésimo progenitor do grupo I, expressa por $\bar{Y}_i - \bar{Y}_{..}$, em que \bar{Y}_i é a média do i -ésimo progenitor do grupo I e $\bar{Y}_{..}$ é a média geral; \hat{g}_j é a estimativa do j -ésimo progenitor do grupo II, expressa por $\bar{Y}_j - \bar{Y}_{..}$, em que \bar{Y}_j é a média do j -ésimo progenitor do grupo II.

A análise do dialelo parcial foi realizada de acordo com o modelo proposto por Griffing (1956), adaptado a dialelo parcial por Geraldi e Miranda Filho (1988). O efeito de tratamento,

considerado como fixo, foi decomposto em capacidade geral de combinação (CGC) e capacidade específica de combinação (CEC) de acordo com o modelo estatístico descrito na Equação 3.

$$Y_{ij} = \mu + \frac{1}{2} (d_1 + d_2) + g_i + g_j + S_{ij} + \bar{\varepsilon} \quad (3)$$

em que: Y_{ij} é média envolvendo o i-ésimo progenitor do grupo I e o j-ésimo progenitor do grupo II; μ é a média geral do dialelo; d_1, d_2 são contrastes envolvendo médias dos grupos I e II e a média geral; g_i é o efeito da capacidade geral de combinação do i-ésimo progenitor do grupo I; g_j é o efeito da capacidade geral de combinação do j-ésimo progenitor do grupo II; S_{ij} é o efeito da capacidade específica de combinação; e $\bar{\varepsilon}$ é o erro experimental médio.

A soma de quadrados de tratamentos foi desdobrada em soma de quadrados de CGC dos grupos I e II e CEC. A magnitude dos efeitos aditivo e não aditivo foram inferidas por meio da relação das somas de quadrados entre as CGC (grupos I + II) e a CEC, pois o quadrado médio não apresenta decomposição ortogonal (Bueno, 2017).

Todas as análises foram realizadas com o software Genes (Cruz, 2013), seguindo os procedimentos recomendados em Cruz et al. (2012).

RESULTADOS E DISCUSSÃO

Houve efeito significativo ($P < 0.05$) de genótipos para todos os caracteres agronômicos e fisiológicos (Tabela 3). Para as reflectâncias e índices de vegetação, houve efeito significativo para NIR, Red-edge, NDVI e NDRE. Tais resultados indicam a existência de variabilidade genética entre os genótipos para os caracteres avaliados, com exceção das reflectâncias Red e Green. Os coeficientes de variação (CVs) foram inferiores a 11% para os caracteres agronômicos, o que revela boa precisão experimental, e são inferiores a outros trabalhos com competição de genótipos de soja (Stülp et al., 2009; Teodoro et al., 2015; Rocha et al., 2018).

Tabela 3. Quadrados médios dos caracteres número de dias para maturação (NDM), número de vagens por planta (NVP), número de nós por planta (NNP), número de hastes laterais por planta (NHL), produtividade de grãos (PROD), fotossíntese (A), condutância estomática (gs), concentração interna de CO₂ (Ci), transpiração (E), bandas NIR, Red-edge, Red e Green, e índices de vegetação NDVI e NDRE, avaliados em populações F₂ de soja e seus genitores.

Fontes de variação	GL	Caracteres agrônômicos					
		NDM	NVP	NNP	NHL	PROD	
Blocos	1	2,81	33,99	3,75	1,05	0,01	
Genótipos	34	32,98*	128,21*	2,79*	0,99*	13,37*	
Resíduo	10	0,01	40,90	0,80	0,07	2,78	
Média – Testemunhas		108,00	59,33	15,77	3,50	21,76	
Médias – Populações		105,00	58,30	16,04	3,83	21,80	
CV (%)		1,05	10,87	5,63	7,40	7,64	
Fontes de variação	GL	Caracteres fisiológicos					
		A	gs	Ci	E		
Blocos	1	0,04	0,06	43,85	0,22		
Genótipos	34	23,22*	0,19*	1010,42*	0,82*		
Resíduo	10	0,39	0,01	16,33	0,04		
Média – Testemunhas		54,88	1,16	416,34	6,78		
Médias – Populações		55,53	1,39	437,78	7,29		
CV (%)		1,14	3,85	0,94	2,75		
Fontes de variação	GL	Reflectâncias e índices de vegetação					
		NIR	Red-edge	Red	Green	NDVI	NDRE
Blocos	1	0,01	0,10	0,01	0,01	0,01	0,10
Genótipos	34	0,10*	0,08*	0,10 ^{ns}	0,02 ^{ns}	0,09*	0,20*
Resíduo	10	0,01	0,01	0,40	0,01	0,01	0,01
Média – Testemunhas		0,43	0,39	0,03	0,06	0,85	0,04
Médias – Populações		0,46	0,42	0,03	0,06	0,87	0,05
CV (%)		3,37	3,67	19,14	4,98	0,82	11,05

^{ns} e * : não significativo e significativo a 5% de probabilidade pelo teste F, respectivamente; GL: graus de liberdade; CV: coeficiente de variação.

Do mesmo modo, os baixos CVs (inferiores a 4%) obtidos para os caracteres fisiológicos evidenciam alta precisão experimental, sendo inferiores aos valores encontrados na literatura (Thompson et al., 1996; Zobiolo et al., 2010; Oliveira et al., 2018). Para as reflectâncias e índices de vegetação, os CVs foram inferiores a 20 e 12%, respectivamente, os

quais estão de acordo com os valores recomendados na literatura (Clevers e Gitelson, 2013; Baio et al., 2018).

Com base nos resultados obtidos pela análise de variância, é possível comprovar que o delineamento de blocos aumentados foi capaz de explorar a variabilidade genética presente nos genótipos em estudo. O delineamento de blocos aumentados foi apontado por Peternelli et al. (2009) como um delineamento eficiente quando há restrições de recursos, como a baixa disponibilidade de sementes observada nas plantas da geração F₁ obtidas neste experimento.

Os efeitos de genótipos foram desdobrados em efeitos de CGC dos grupos I e II e CEC (Tabela 4). Os quadrados médios de CGC dos grupos I e II foram significativos para todos os caracteres agrônômicos e fisiológicos. A análise em gerações avançadas de um dialelo parcial é justificada em razão da possibilidade de ocorrer viés nas estimativas de CGC devido a predominância de desvios de dominância, quando se utiliza a geração F₁ (Vencovsky, 1978).

Para os índices de vegetação, houve efeito significativo de CGC dos dois grupos para Red-edge, NDVI e NDRE. Nos casos em que a CGC é significativa, pode-se inferir que pelo menos um dos genitores difere dos demais quanto à concentração de alelos favoráveis (Cruz et al., 2012; Pimentel et al., 2013). Sendo assim, a significância dos efeitos de CGC é um indicativo da existência de genitores que contribuem com uma maior quantidade de alelos favoráveis para estes caracteres transmitidos aos descendentes (Ramalho et al., 2012).

De modo similar aos efeitos de CGC, houve efeito significativo de CEC dos dois grupos para todos os caracteres agrônômicos e fisiológicos, e para os índices de vegetação considerando os dois grupos, houve significância para Red-edge, NDVI e NDRE. Efeitos significativos de CEC evidenciam que há desvios de comportamento dos híbridos com relação ao que era esperado com base na CGC dos genitores (Cruz e Vencovsky, 1989). A CGC é atribuída a genes com efeitos aditivos, enquanto a CEC está relacionada aos efeitos gênicos não aditivos (Cruz et al., 2012). Portanto, a presença de efeitos significativos de CGC e CEC

revelam a importância tanto de componentes genéticos aditivos quanto de não-aditivos no controle das características em estudo.

Tabela 4. Quadrados médios obtidos pela análise dialélica para os caracteres número de dias para maturação (NDM), número de vagens por planta (NVP), número de nós por planta (NNP), número de hastes laterais por planta (NHL), produtividade de grãos (PROD), fotossíntese (A), condutância estomática (gs), concentração interna de CO₂ (Ci), transpiração (E), bandas NIR, Red-edge, Red e Green, e índices de vegetação NDVI e NDRE, avaliados em populações F₂ de soja e seus genitores.

Fontes de variação	GL	Caracteres agronômicos					
		NDM	NVP	NNP	NHL	PROD	
CGC – Grupo I	3	47,23*	318,11*	5,71*	2,48*	15,03*	
CGC – Grupo II	6	71,23*	181,46*	11,97*	3,44*	13,92*	
CEC – Grupo I x Grupo II	28	34,66*	246,63*	1,77*	1,24*	28,58*	
Fontes de variação	GL	Caracteres fisiológicos					
		A	gs	Ci	E		
CGC – Grupo I	3	46,38*	0,32*	720,16*	0,51*		
CGC – Grupo II	6	74,89*	0,24*	1218,28*	2,04*		
CEC – Grupo I x Grupo II	28	25,86*	0,24*	1149,90*	1,11*		
Fontes de variação	GL	Reflectâncias e índices de vegetação					
		NIR	Red-edge	Red	Green	NDVI	NDRE
CGC – Grupo I	3	0,08*	0,08*	0,00 ^{ns}	0,01 ^{ns}	0,09*	0,30*
CGC – Grupo II	6	0,06*	0,17*	0,01 ^{ns}	0,00 ^{ns}	0,09*	0,10*
CEC – Grupo I x Grupo II	28	0,04*	0,08*	0,00 ^{ns}	0,00 ^{ns}	0,10*	0,30*

^{ns} e * : não significativo e significativo a 5% de probabilidade pelo teste F, respectivamente; GL: graus de liberdade.

Com base na análise dialélica, é possível avaliar a importância relativa dos efeitos gênicos aditivos (expressos pelos efeitos de CGC), bem como os efeitos devidos à dominância (associados à CEC). Essa informação é útil no estabelecimento da melhor estratégia de melhoramento (Bhering et al., 2017). Os quadrados médios de CGC foram superiores aos quadrados médios de CEC para todos os caracteres avaliados, com exceção de PROD. Isto revela a predominância de efeitos aditivos no controle destes caracteres, embora efeitos não

aditivos também possam estar envolvidos (Baker, 1978). Quando os efeitos aditivos são pronunciados, ganhos de maior magnitude serão previstos (Bhering et al., 2017). Adicionalmente, os efeitos aditivos dos genes são cumulativos ao longo de gerações e são as principais fontes de variação genética explorada pela maioria dos programas de melhoramento (Isik et al., 2003), uma vez que é responsável pela fixação das características de interesse. Assim, a seleção visando precocidade e eficiência fotossintética pode ser realizada nas gerações iniciais, em razão da predominância de efeitos aditivos em F₂.

Conforme mencionado, os efeitos envolvidos no controle de NDVI e NDRE são predominantemente aditivos. Tais resultados são de grande relevância, uma vez que não há estudos sobre a ação gênica envolvida na herança de índices de vegetação em soja. Sendo assim, com base nas estimativas de CGC e CEC e na compreensão acerca do modo de herança destes caracteres, é possível afirmar que a seleção com base nestes caracteres é promissora.

As estimativas de CGC dos genitores dos grupos I e II estão contidas na Tabela 5. Para o NDM, é desejável genótipos que apresentem média reduzida, refletindo em maior precocidade. Neste sentido, é importante que pelo menos um dos genitores apresente valor negativo de CGC. Os genitores 2, 4 e 5 (grupo I) que apresentaram estimativas de CGC negativas significativas para NDM foram. Para o grupo II, destacaram-se os genitores 10 e 11. Isto evidencia uma alta concentração de alelos favoráveis à redução do ciclo na cultura da soja por esses genitores.

As populações oriundas dos cruzamentos 5x8, 7x9, 2x10, 3x10, 4x10, 1x11, 2x11, 3x11 e 7x11 destacaram-se na redução do número de dias para a maturação, apresentando as menores estimativas de CEC (Tabela 6). É possível constatar que, com exceção da população 7x9, as demais progênies possuem pelo menos um dos genitores com baixas estimativas de CGC. Portanto, os genitores 2, 4, 5, 10 e 11 caracterizam-se como populações promissoras para extração de linhagens precoces.

Tabela 5. Estimativas da capacidade geral de combinação dos genitores dos grupos I e II para os caracteres número de dias para maturação (NDM), número de vagens por planta (NVP), número de nós por planta (NNP), número de hastes laterais por planta (NHL), produtividade de grãos (PROD), fotossíntese líquida (A), condutância estomática (gs), concentração interna de CO₂ (Ci), transpiração (E), bandas NIR e Red-edge e índices de vegetação NDVI e NDRE, avaliadas em soja.

Genitor (grupo I)	Caracteres agrônômicos					Caracteres fisiológicos				Reflectâncias e índices de vegetação			
	NDM	NVP	NNP	NHL	PROD	A	gs	Ci	E	NIR	Red-edge	NDVI	NDRE
1	0,33	4,25*	0,73*	0,66*	0,04	0,18	0,02	-2,10	-0,04	0,017*	0,012*	-0,002	0,001
2	-0,45*	-1,92	0,42	-0,43*	-0,08	0,12	-0,02	0,07	-0,14*	-0,009*	-0,004	-0,005*	-0,001
3	4,07*	2,72	1,35*	-0,12	0,02	-1,31*	-0,08*	0,02	-0,47*	0,022*	0,012*	0,014*	0,004*
4	-0,65*	0,78	-0,10	0,03	0,66	0,65	0,11*	3,35*	0,12*	0,000	0,000	-0,007*	-0,001
5	-3,05*	-3,28*	-0,92*	0,28*	-1,97*	-3,97*	0,03	12,81*	0,64*	-0,005	-0,003	0,006*	-0,002
6	-0,33	-4,76*	-0,74*	-0,70*	0,67	1,52*	-0,22*	-16,48*	-0,28*	-0,022*	-0,017*	-0,004*	0,002
7	0,09	2,21	-0,74*	0,28*	0,66	2,80*	0,16*	2,34*	0,17*	-0,003	0,000	-0,001	-0,003*
Genitor (grupo II)	NDM	NVP	NNP	NHL	PROD	A	gs	Ci	E	NIR	Red-edge	NDVI	NDRE
8	2,17*	1,65*	0,55*	0,07	0,80*	-2,10*	-0,08*	-5,21*	0,05	-0,001	0,005	-0,006*	-0,005*
9	-0,41	-5,51*	-0,16	-0,32*	-1,16*	0,30	-0,07*	-4,62*	-0,15*	-0,007	-0,008*	-0,005*	-0,001
10	-0,85*	3,13*	0,24	0,44*	0,12	0,59	-0,03	4,04*	0,19*	0,008*	0,005	0,008*	0,003*
11	-0,91*	0,72	-0,63*	-0,19*	0,24	1,22*	0,18*	5,78*	-0,09	0,001	-0,001	0,003	0,003*

*: difere de zero a 5% de probabilidade pelo teste t. 1: BMX Prisma IPRO; 2: M6952 IPRO; 3: BMX Bônus IPRO; 4: BMX Flecha IPRO; 5: M6410 IPRO; 6: NS 6909 IPRO; 7: M7739 IPRO; 8: BMX Ponta IPRO; 9: DM 6563 IPRO; 10: SYN 13671 IPRO; 11: TMG 7062 IPRO.

Além da precocidade, os programas de melhoramento de soja visam a obtenção de linhagens altamente produtivas. Os caracteres NVP, NNP e NHL possuem relação de causa e efeito direto e positivo sobre a PROD (Teodoro et al., 2015). Com isto, altas estimativas de CGC e CEC para estes caracteres são de interesse. Dentre os genitores do grupo I, o genitor 1 apresentou maiores estimativas de CGC para três caracteres agronômicos (NVP, NNP e NHL), destacando-se em relação aos genitores 3 (maiores estimativas somente para NNP), 5 e 7 (com maiores estimativas somente para NHL).

Para os genitores do grupo II, os genitores com maiores estimativas para os caracteres agronômicos foram 10 (com maiores estimativas para NVP e NHL) e 8, o qual se destacou por apresentar maiores estimativas para NVP, NNP e PROD. O genitor 8 foi o único que apresentou estimativas significativas de CGC para PROD. Contudo, merecem destaque os genitores 1 e 10, os quais apresentaram altas estimativas para NVP. O número de vagens por planta tem grande importância na seleção, uma vez que apresenta alta correlação com a produção de grãos (Almeida et al., 2010; Teodoro et al., 2015). Portanto, os genitores 1, 8 e 10 mostram-se promissores para a obtenção de cultivares produtivas. As populações 1x8, 2x8, 6x8, 7x8, 3x9, 4x9, 5x9 e 4x10 apresentaram as maiores estimativas de CEC para NVP. A população 7x8 se destacou para todos os caracteres agronômicos, apresentando estimativas significativas de CEC para NVP, NNP, NHL e PROD, além de apresentar as maiores estimativas de CEC para NVP, NNP e PROD.

As populações 6x8 e 3x9 também se destacaram por apresentarem maiores estimativas para NNP e PROD, além da população 4x10, que apresentou maiores estimativas para NHL e PROD. Neste sentido, a seleção com base no caráter NVP parece ser eficiente para a identificação de genótipos com maior CEC para caracteres relacionados à produção em soja. Vale destacar que as populações 6x8 e 4x10, além de apresentarem maior CGC para NVP, NNP e PROD, possuem como um de seus progenitores linhagens com alta CGC para NVP (8 e 10, respectivamente).

Tabela 6. Estimativas da capacidade específica de combinação para os caracteres número de dias para maturação (NDM), número de vagens por planta (NVP), número de nós por planta (NNP), número de hastes laterais por planta (NHL) e produtividade de grãos (PROD), avaliados em populações F₂ de soja.

População F ₂ (♂ x ♀)	NDM	NVP	NNP	NHL	PROD
1x8	-0,85	5,24*	-0,52	2,49*	0,82
2x8	-0,27	4,63*	-0,15	-0,68	0,94
3x8	-0,69	-0,21	0,21	-0,48	1,54
4x8	-0,97	-18,29*	-0,69	-0,98	-5,00*
5x8	-4,76*	-15,13*	-1,87*	0,38	-4,77*
6x8	-0,09	7,05*	1,15*	-0,14	2,39*
7x8	3,79*	31,30*	2,21*	1,01*	9,40*
1x9	-0,28	-4,44*	-0,46	-0,58	-1,59
2x9	-0,44	0,93	0,23	0,08	0,06
3x9	0,48	12,58*	2,22*	0,31	4,72*
4x9	1,40*	10,25*	0,33	1,19*	4,68*
5x9	0,10	4,20*	0,56	0,15	1,31
6x9	0,77	1,60	0,09	0,01	0,73
7x9	-6,14*	-16,51*	-0,39	-0,20	-5,22*
1x10	4,13*	3,44	-0,08	-0,30	-0,45
2x10	-3,49*	-1,29	-0,26	0,69	-2,03*
3x10	-4,20*	-9,55*	-0,56	-0,15	-4,04*
4x10	-3,29*	17,71*	-0,15	1,33*	7,73*
5x10	0,42	-9,35*	-0,58	-1,05*	-3,04*
6x10	2,29*	-5,95*	-0,31	-0,24	-2,09*
7x10	0,37	-2,84	0,53	-0,26	-0,57
1x11	-2,58*	-4,92*	0,17	-0,25	2,51*
2x11	-2,50*	-0,13	0,54	0,39	0,23
3x11	-8,22*	-10,80*	-1,15*	-0,06	-4,08*
4x11	9,39*	-1,85	0,70	-0,32	0,28
5x11	-0,86	-3,10	-0,29	-0,05	-1,04
6x11	0,81	-1,21	0,21	-0,23	0,31
7x11	-6,54*	-7,17*	-0,50	-0,53	-2,52*

*: difere de zero a 5% de probabilidade pelo teste t. 1: BMX Prisma IPRO; 2: M6952 IPRO; 3: BMX Bônus IPRO; 4: BMX Flecha IPRO; 5: M6410 IPRO; 6: NS 6909 IPRO; 7: M7739 IPRO; 8: BMX Ponta IPRO; 9: DM 6563 IPRO; 10: SYN 13671 IPRO; 11: TMG 7062 IPRO.

Embora não tenha apresentado estimativas significativas para os caracteres NVP, NNP e NHL, a população 1x11 apresentou estimativas significativas de CEC para PROD. Esta

combinação, juntamente com a população 4x10, também apresentou menores estimativas de CEC para NDM. Portanto, as populações 1x11 e 4x10 são promissoras para a obtenção de segregantes transgressivos considerando precocidade e produtividade.

A taxa fotossintética é positivamente correlacionada com a produtividade em soja (Ainsworth et al., 2012). O rendimento de uma cultura é afetado pela radiação fotossinteticamente ativa incidente, das eficiências com as quais a planta intercepta a radiação e a converte em biomassa, e da eficiência com a qual a biomassa é convertida em sementes (Zhu et al., 2010). A eficiência fotossintética está relacionada não só à fotossíntese líquida como também aos mecanismos de condutância estomática, concentração interna de CO₂ e transpiração, daí a importância da avaliação destes caracteres. Com relação à fotossíntese líquida (A), as maiores estimativas de CGC do grupo I foram obtidas pelos genitores 6 e 7, enquanto que para o grupo II a maior estimativa foi observada para o genitor 11. As maiores estimativas de CEC para A foram obtidas pelas populações 4x8, 5x8, 7x8, 1x9, 5x9, 3x10, 4x10, 6x10, 1x11 e 2x11 (Tabela 7). Destas, destacaram-se 7x8, 6x10, 1x11 e 2x11, as quais apresentam pelo menos um de seus genitores com alta CGC para o caráter.

A condutância estomática (gs) é uma medida da relação entre a passagem de dióxido de carbono (CO₂) que entra e o vapor de água que sai pelos estômatos de uma folha (Roche, 2015). Em condições não limitantes para a disponibilidade de água e temperaturas ambiente abaixo dos níveis de estresse térmico, a máxima condutância estomática de um genótipo maximizará as taxas fotossintéticas. Isto porque a primeira resposta a um déficit hídrico é a alteração da gs, limitando conseqüentemente a fotossíntese (Flexas e Medrano, 2002). A importância da gs nas respostas iniciais ao estresse hídrico tem sido relatada na literatura (Flexas e Medrano, 2002; Medrano et al., 2002; Damour et al., 2010). Como a gs está relacionada ao turgor foliar e este, por sua vez, depende do equilíbrio entre a perda de água através da transpiração e fornecimento de água para a folha a partir do solo (Tuzet et al., 2003), pode-se inferir que a gs está negativamente correlacionada com a transpiração. Neste sentido, genótipos com maior

assimilação de CO₂ e menores taxas de transpiração são desejáveis, uma vez que exibirão maior eficiência no uso da água.

Tabela 7. Estimativas da capacidade específica de combinação para os caracteres número fotossíntese líquida (A), condutância estomática (gs), concentração interna de CO₂ (Ci), transpiração (E), bandas NIR e Red-edge e índices de vegetação NDVI e NDRE, avaliados em populações F₂ de soja.

População F ₂ (♂ x ♀)	A	gs	Ci	E	NIR	Red-edge	NDVI	NDRE
1x8	-0,32	0,19	13,85*	0,24	0,019	0,011	0,009	-0,004
2x8	-2,95*	-0,23*	-11,00*	-0,92*	-0,005	-0,003	0,002	0,007
3x8	-5,11*	-0,04	6,68	-0,60	-0,026*	-0,019	-0,017*	0,002
4x8	4,00*	0,03	-4,20	0,79	0,027*	0,014	0,014	-0,003
5x8	4,50*	-0,02	-0,46	1,16*	0,002	0,007	-0,009	-0,012*
6x8	-1,41	0,24*	17,71*	0,27	0,048*	0,031*	0,021*	0,004
7x8	4,41*	-0,26*	-15,87*	-0,48	-0,021*	-0,007	-0,012	-0,001
1x9	5,76*	-0,01	-0,78	0,01	-0,024*	-0,023	-0,026*	-0,004
2x9	-0,62	0,13	8,13	-0,14	0,006	0,004	0,004	0,005
3x9	-3,64*	-0,05	2,62	-0,18	0,041*	0,027*	0,018*	0,002
4x9	-6,18*	0,24*	26,25*	-0,58	-0,016	-0,001	-0,011	-0,013*
5x9	3,74*	0,02	-1,27	0,11	-0,011	-0,008	-0,014	-0,002
6x9	-0,12	0,08	5,05	-0,11	0,003	0,001	0,001	0,003
7x9	1,44	0,86*	22,52*	0,38	0,037*	0,009	0,033*	0,020*
1x10	-1,01	-0,06	15,74*	0,29	0,018	0,021	0,013	0,004
2x10	-1,18	0,13	17,40*	-0,41	0,044*	0,027*	0,026*	0,016*
3x10	2,20*	0,48*	25,08*	1,37*	0,003	-0,009	0,016	0,000
4x10	2,88*	0,53*	31,30*	0,99*	0,026*	0,014	0,028*	0,015*
5x10	-6,40*	-0,26*	7,54	-1,08*	0,031*	0,017	0,025*	0,006
6x10	2,41*	-0,01	3,96	-0,34	-0,013	-0,010	-0,016*	0,002
7x10	0,06	-0,21*	11,37*	1,38*	-0,042*	-0,027*	-0,039*	-0,022*
1x11	5,17*	-0,51*	-53,85*	-0,30	0,064*	0,034*	0,041*	0,009
2x11	2,05*	0,52*	24,99*	1,01*	0,010	0,010	0,014	0,011
3x11	-1,39	0,10	9,77	-0,62	0,039*	0,024	0,025*	0,016*
4x11	-4,27*	0,35*	27,55*	-0,04	-0,048*	-0,033*	-0,014	-0,019*
5x11	-0,48	0,04	4,60	0,06	0,008	0,005	0,006	0,002
6x11	0,34	-0,02	-1,51	-0,16	0,006	0,003	0,004	0,005
7x11	-0,69	-0,21*	-1,60	0,86	0,024*	0,017	0,020	0,013*

*: difere de zero a 5% de probabilidade pelo teste t. 1: BMX Prisma IPRO; 2: M6952 IPRO; 3: BMX Bônus IPRO; 4: BMX Flecha IPRO; 5: M6410 IPRO; 6: NS 6909 IPRO; 7: M7739 IPRO; 8: BMX Ponta IPRO; 9: DM 6563 IPRO; 10: SYN 13671 IPRO; 11: TMG 7062 IPRO.

Estimativas significativas de CGC para gs foram observadas para os genitores 4 e 7 (grupo I) e 11 (grupo II). As maiores estimativas de CEC para este caráter foram obtidos pelas populações 6x8, 4x9, 7x9, 3x10, 4x10, 2x11 e 4x11. Destas, destacaram-se 4x9, 7x9, 4x10, 7x10, 2x11 e 4x11, por apresentar pelo menos um de seus genitores com maiores estimativas de CGC.

Para a concentração interna de CO₂ (Ci), os genitores 4, 5 e 7 (grupo I) e 10 e 11 (grupo II) apresentaram estimativas significativas de CGC. As populações com maiores estimativas de CEC foram 1x8, 6x8 4x9, 7x9, 1x10, 2x10, 3x10, 4x10, 7x10, 2x11 e 4x11, das quais apenas 1x8 e 6x8 não apresentaram pelo menos um de seus genitores com altas estimativas de CGC. Por fim, os genitores com estimativas negativas de CGC para transpiração (E) foram 2, 3 e 6 (grupo I) e 9 (grupo II). As maiores estimativas de CEC para E foram obtidas pelas populações 2x8 e 5x10, sendo que apenas a população 2x8 apresentou um de seus genitores com menores estimativas de CEC.

Com base nos resultados obtidos para os caracteres fisiológicos, é possível constatar a superioridade do genótipo 11 para A, gs e Ci. Este fato também pode ser confirmado ao se observar o desempenho de sua progênie 2x11, a qual apresentou alta CEC para estes caracteres. Neste sentido, o genótipo 11 (TMG 7062 IPRO) mostra-se promissor para uso como genitor em programas de melhoramento visando a obtenção de populações com maior eficiência fotossintética e do uso da água. Além disso, conforme mencionado anteriormente, este genótipo também se caracteriza como um genitor potencial para a obtenção de linhagens precoces.

A reflectância foliar também é uma das características relacionadas à eficiência no uso da água. Quanto maior a presença de água nas estruturas celulares da planta, maior é a reflectância no comprimento de onda do infravermelho próximo (NIR) (Silva Junior et al., 2018). Neste sentido, maiores valores de NIR indicam plantas mais vigorosas quanto ao estado hídrico. Por outro lado, a banda Red-edge fornece informações sobre o conteúdo de clorofila na planta (Delegido et al., 2011). Os comprimentos de onda nas faixas do Red e Red-edge são

utilizados para o processo fotossintético, havendo uma maior absorção destes comprimentos de onda pelas plantas (Silva Junior et al., 2018). Plantas com maiores taxas de fotossíntese terão menor reflectância nestas faixas. Portanto, baixos valores de Red-edge são desejáveis, pois são indicativos de genótipos com taxa fotossintética adequada.

Os genitores 1 e 3 (grupo I) e 10 (grupo II) apresentaram as maiores estimativas de CGC para NIR. As populações com maiores estimativas de CEC para NIR foram 4x8, 6x8, 3x9, 7x9, 2x10, 4x10, 5x10, 1x11, 3x11 e 7x11, das quais 3x9, 2x10, 4x10, 5x10, 1x11 e 3x11 possuem um de seus genitores com altas estimativas de CGC. Com relação ao Red-edge, em que baixas estimativas são desejáveis, os genitores que se destacaram para CGC foram 6 (grupo I) e 9 (grupo II). As menores estimativas de CEC para Red-edge foram obtidas pelas populações 7x10 e 4x11, contudo, nenhuma população apresentou pelo menos um dos genitores com baixa CGC.

Altos valores de NDVI e NDRE estão relacionados à vegetação saudável e densa, a qual apresenta baixos valores de refletância na faixa de onda vermelha (Red e Red-edge) e altos valores de refletância na faixa de onda NIR (Xue e Su, 2017). Com base no NDVI, as linhagens 3 e 5 (grupo I) e 10 (grupo II) apresentaram as maiores estimativas de CGC. As populações com maiores estimativas de CEC para NDVI foram 6x8, 3x9, 7x9, 2x10, 4x10, 5x10, 1x11, 2x10, 3x9 e 3x11, destacando-se as populações 3x9, 3x11, 2x10, 4x10, 5x10, por apresentarem como um de seus progenitores as linhagens 10 ou 3, as quais obtiveram altas estimativas de CGC. Para o NDRE, os genitores 3 (grupo I) e 10 e 11 (grupo II) apresentaram as maiores estimativas de CGC. As maiores estimativas de CEC para NDRE foram obtidas pelas populações 7x9, 2x10, 4x10, 3x11 e 7x11, sendo que todas apresentaram pelo menos um genitor com alta CGC.

É possível constatar que o genitor 10 (SYN 13671 IPRO), além de ser promissor para precocidade e para número de vagens por planta e número de hastes laterais por planta, caracteres correlacionados com a produtividade (Almeida et al., 2010; Teodoro et al., 2015), apresentou boa capacidade de combinação para Ci e para os índices de vegetação. Isto reforça

a hipótese de que genótipos com maior precocidade, produtividade e concentração interna de CO₂ são mais vigorosos e, conseqüentemente, exibem maiores valores para NDVI e NDRE. Tais resultados também revelam que o uso de índices de vegetação no melhoramento de plantas é promissor, uma vez que seu uso pode auxiliar a seleção.

Com base nas estimativas de CGC, as populações oriundas dos cruzamentos entre os genitores 10 (SYN 13671 IPRO), 11 (TMG 7062 IPRO) e 8 (BMX Ponta IPRO), pertencentes ao grupo II, com os genitores 4 (BMX Flecha IPRO) e 3 (BMX Bônus IPRO), do grupo I, são promissores para a obtenção de linhagens precoces, produtivas e com maior eficiência fotossintética.

CONCLUSÕES

Há predominância de efeitos aditivos no controle dos caracteres agrônômicos, fisiológicos e índices de vegetação avaliados.

A cultivar SYN 13671 IPRO pode ser utilizada como genitor em blocos de cruzamento visando obter maior precocidade, número de vagens por planta, eficiência fotossintética e valores de índices de vegetação adequados.

As populações provenientes do cruzamento entre os genitores SYN 13671 IPRO, TMG 7062 IPRO e BMX Ponta IPRO, com os genitores BMX Flecha IPRO e BMX Bônus IPRO, apresentam maior potencial para obtenção de linhagens superiores para precocidade, produtividade e eficiência fotossintética.

REFERÊNCIAS

- Ainsworth, E.A., Yendrek, C.R., Skoneczka, J.A., Long, S.P. 2012. Accelerating yield potential in soybean: potential targets for biotechnological improvement. *Plant. Cell. Environ.* 35:38-52.
- Almeida, R.D., Peluzio, J.M., Afférrri, F.S. 2010. Correlações fenotípicas, genotípicas e ambientais em soja cultivada sob condições várzea irrigada, sul do Tocantins. *Biosc. J.* 26:95-99.
- Baio, F.H.R., Silva, E E., Vrech, M.A., Souza, F.H.Q., Zanin, A.R., Teodoro, P.E. 2018. Vegetation Indices to Estimate Spray Application Rates of Crop Protection Products in Corn. *Agron. J.* 1:1254-1259.
- Baker, R.J. 1978. Issues in diallel analysis. *Crop Sci.* 18: 533–536.
- Bhering, L.L., Peixoto, L.A., Cruz, C.D. 2017. Seleção de genitores. In: Silva, F.L., Borém, A., Sedyama, T., Ludke, W. (Eds). *Melhoramento da Soja*. UFV, Viçosa.
- Bhullar, K.S., K.S. Gill, A.S. Khehra. 1979. Combining ability analysis over F₁-F₅ generations in diallel crosses of bread wheat. *Theor Appl Genet* 55: 77–80.
- Bueno, T.V. 2017. Capacidade combinatória de genitores de soja nas gerações F₁ e F₂ visando melhoramento para precocidade e produtividade de grãos. Dissertação de Mestrado (Pós-Graduação em Genética e Melhoramento). Universidade Federal de Viçosa, Viçosa.
- Carvalho, A.D.F., Geraldi, I.O., Santos, V.S. 2009. Evaluation of F_{2:4} and F_{4:6} progenies of soybeans and perspectives of using early generation testing for grain yield. *Bragantia* 68: 857-861.
- Cho, Y., Scott, R.A. 2000. Combining ability of seed vigor and seed yield in soybean. *Euphytica* 112: 145-150.

- Clevers, J.G.P.W., Gitelson, A. 2013. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. *Inter. J. Appl. Earth. Observ. Geoinf.* 23:344–351.
- Cruz, C.D. 2013. Genes: a software package for analysis in experimental statistics and quantitative genetics. *Acta Sci. Agron.* 35:271-276.
- Cruz, C.D., Vencovsky, R. 1989. Comparação de alguns métodos de análise dialélica. *Rev. Bras. Gen.* 12:425-438.
- Cruz, C.D., Regazzi, A.J., Carneiro, P.C.S. 2012. Modelos biométricos aplicados ao melhoramento genético. UFV, Viçosa.
- Damour, G., Simonneau, T., Cochard, H., Urban, L. 2010. An overview of models of stomatal conductance at the leaf level. *Plant Cell. Environ.* 33:1419-1438.
- Delegido, J., Verrelst, J., Alonso, L., Moreno, J., 2011. Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors* 11:7063–7081.
- Do Vale, N.M. 2015. Melhoramento de feijão carioca com ênfase em precocidade. Tese de Doutorado (Pós-Graduação em Genética e Melhoramento). Universidade Federal de Viçosa, Viçosa.
- Flexas, J. Medrano, H. 2002. Drought-inhibition of photosynthesis in C3 plants: Stomatal and non-stomatal limitations revisited. *Ann. Bot.* 89:183-189.
- Friedrichs, M.R., Burton, J.W., Brownie, C. 2016. Heterosis and Genetic Variance in Soybean Recombinant Inbred Line Populations. *Crop Sci.* 56:2072-2079.
- Geraldi, I., Miranda Filho, J. 1988. Adapted models for the analysis of combining ability of varieties in partial diallel crosses. *Rev. Bras. Gen.* 11:419-430.

- Gitelson, A., Merzlyak, M.N. 1994. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. J. Plant Physiol. 143:286-292.
- Griffing, B. 1956. Concept of general and specific combining ability in relation to diallel crossing systems. Austr. J. Biol. Sci. 9:463-493.
- Isik, F., Li, B., Frampton, J. 2003. Estimates of additive, dominance and epistatic genetic variances from a clonally replicated test of loblolly pine. Forest Sci. 49:77-88.
- Javaid, A., Masood, S., Minhas, N.M. 2001. Analysis of combining ability in wheat (*Triticum aestivum* L.) using F2 generation. Pakist. J. Biol. Sci. 4:1303-1305.
- Medrano, H., Escalona, J.M., Bota, J., Gulias, J., Flexas, J. 2002. Regulation of photosynthesis of C-3 plants in response to progressive drought: Stomatal conductance as a reference parameter. Ann. Bot. 89:895-905.
- Oliveira, T.B., Azevedo, L.P., Teodoro, P.E., Alvarenga, A.A., Bhering, L.L., Campo, C.B.H. 2018. The number of measurements needed to obtain high reliability for traits related to enzymatic activities and photosynthetic compounds in soybean plants infected with *Phakopsora pachyrhizi*. PloS one 13:e0206485.
- Peternelli, L.A., Maia de Souza, E.F., Pereira Barbosa, M.H., Pisaroglo de Carvalho, M. 2009. Delineamentos aumentados no melhoramento de plantas em condições de restrições de recursos. Cienc. Rural 39-1:6.
- Pimentel, A.J.B., Souza, M.A., Carneiro, P.C.S., Rocha, J.R.A.S.C., Machado, J.C., Ribeiro, G. 2013. Análise dialélica parcial em gerações avançadas para seleção de populações segregantes de trigo. Pesq. Agropec. Bras. 48: 1555-1561.
- Ramalho, M.A.P., Ferreira, D.F., Oliveira, A.C. 2012. Experimentação em genética e melhoramento de plantas. UFLA, Lavras.

- Raper, T.B., Varco, J.J. 2015. Canopy-scale wavelength and vegetative index sensitivities to cotton growth parameters and nitrogen status. *Precision Agric* 16:62-76.
- Rocha, G.A.F., Pereira, F.A.C., Vello, N.A. 2018. Potential of soybean crosses in early inbreeding generations for grain yield. *Crop Breed. Appl. Biotechnol.* 18: 267-275.
- Roche, D. 2015. Stomatal conductance is essential for higher yield potential of C3 crops. *Critical Rev. Plant Sci.* 34:429-453.
- Rosal, C.J.S., Ramalho, M.A.P., Gonçalves, F.M.A., Abreu, A.F.B. 2000. Early selection for common bean grain yield. *Bragantia* 59:189-195.
- Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W., Harlan, J.C. 1974. Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. NASA, Greenbelt.
- Silva, F.C.S., Sedyama, T., Oliveira, R.C.T., Borém, A., Silva, F.L., Bezerra, A.R.G., Silva, A.F. 2017. Importância econômica e evolução do melhoramento. In: Silva, F.L., Borém, A., Sedyama, T., Ludke, W. (Eds). *Melhoramento da Soja*. UFV, Viçosa.
- Silva Junior, C.A., Nanni, M.R., Shakir, M., Teodoro, P.E., de Oliveira-Júnior, J.F., Cezar, E., Shiratsuchi, L.S. 2018. Soybean varieties discrimination using non-imaging hyperspectral sensor. *Infrared Phys. Technol.* 89:338-350.
- Stülp, M., Braccini, A.D., Albrecht, L.P., Ávila, M.R., Scapim, C.A., Schuster, I. 2009. Desempenho agrônômico de três cultivares de soja em diferentes épocas de semeadura em duas safras. *Cienc Agrotec* 33:1240-1248.
- Sultana, S.R., Ali, A., Ahmad, A., Mubeen, M., Zia-Aul-Haq, M., Ahmad, S., Ercisli, S., Jaafar, H. Z. E. 2014. Normalized difference vegetation index as a tool for wheat yield estimation: a case study from Faisalabad, Pakistan. *Scie Word J* 2014: 725326.

- Teodoro, P.E., Ribeiro, L.P., Corrêa, C.C.G., Luz Júnior, R.A.A., Zanuncio, A.S., Capristo, D.P., Torres, F.E. 2015. Path analysis in soybean genotypes as function of growth habit. *Biosci. J.* 31:794-799.
- Thompson, J.A., Schweitzer, L.E., Nelson, R.L. 1996. Association of specific leaf weight, an estimate of chlorophyll, and chlorophyll concentration with apparent photosynthesis in soybean. *Photosynth. Res.* 49:1-10.
- Tuzet, A., Perrier, A., Leuning, R. 2003. A coupled model of stomatal conductance, photosynthesis and transpiration. *Plant, Cell. Environ.* 26:1097-1116.
- Vencovsky, R. 1978. Herança quantitativa. In: Paterniani, E. (Ed.). *Melhoramento e produção do milho no Brasil*. Fundação Cargill, Campinas.
- Viana, J.M.S. 2007. Heterosis and combining ability analyses from the partial diallel. *Bragantia* 66:641-647.
- Xue, J., Su, B. 2017. Significant remote sensing vegetation indices: A review of developments and applications. *J. Sensors* 2017:1-17.
- Zobiole, H.S, Oliveira, L., Morgan, R.S., Huber, D.M., Constantin, J., Castro, C., Oliveira, F.A., Oiveira Jr, A. 2010. Glyphosate reduces shoot concentrations of mineral nutrients in glyphosate-resistant soybeans. *Plant Soil* 328: 57-69.
- Zhu, X.G., Long, S.P., Ort, D.R. 2010. Improving photosynthetic efficiency for greater yield. *Ann. Rev. Plant Biol.* 61:235-261.

APÊNDICE

Tabela S1. Médias dos caracteres número de dias para maturação (NDM), número de vagens por planta (NVP), número de nós por planta (NNP), número de hastes laterais por planta (NHL), produtividade de grãos (PROD), fotossíntese (A), condutância estomática (gs), concentração interna de CO₂ (Ci), transpiração (E), bandas NIR e Red-edge, e índices de vegetação NDVI e NDRE, avaliados em populações F₂ de soja e seus genitores.

Genótipo	NDM	NVP	NNP	NHL	PROD	A	gs	Ci	E	NIR	Red-edge	NDVI	NDRE
1	108,00	68,40	17,80	4,30	21,85	49,99	1,72	453,06	6,63	0,46	0,42	0,85	0,06
2	110,00	53,65	16,55	2,55	22,65	56,02	1,17	425,13	6,76	0,42	0,39	0,84	0,04
3	122,00	69,00	18,25	3,60	23,40	55,78	1,09	422,73	5,90	0,48	0,43	0,88	0,06
4	103,00	57,20	15,60	3,10	19,90	57,51	1,13	410,99	6,49	0,47	0,42	0,85	0,07
5	104,00	64,70	15,15	4,50	22,25	45,81	1,66	465,16	7,97	0,44	0,40	0,88	0,06
6	105,00	49,30	13,85	2,55	23,10	56,85	0,91	399,18	6,44	0,40	0,37	0,86	0,06
7	112,00	61,60	13,50	4,20	23,20	57,42	1,73	441,21	6,08	0,46	0,42	0,87	0,05
8	104,00	54,45	16,15	3,70	18,50	56,11	1,08	419,31	7,61	0,44	0,40	0,87	0,05
9	104,00	52,60	13,30	2,75	19,05	58,75	0,83	394,89	7,52	0,43	0,40	0,86	0,04
10	110,00	62,70	17,65	3,75	24,75	52,82	0,65	347,97	6,46	0,41	0,40	0,82	0,02
11	108,20	59,05	15,70	3,50	20,75	56,74	0,83	400,37	6,76	0,38	0,36	0,80	0,02
1x8	104,30	70,14	16,32	7,23	22,65	55,92	1,48	445,45	7,53	0,50	0,44	0,88	0,05
2x8	104,10	63,36	16,38	2,97	22,65	53,23	1,02	422,78	6,27	0,45	0,41	0,87	0,06
3x8	108,20	63,16	17,68	3,47	23,35	49,64	1,15	440,41	6,26	0,46	0,41	0,87	0,06
4x8	103,20	43,14	15,32	3,13	17,45	60,70	1,40	432,85	8,24	0,49	0,43	0,88	0,05
5x8	97,00	42,24	13,32	4,73	15,05	56,58	1,28	446,06	9,12	0,46	0,42	0,87	0,04
6x8	104,40	62,94	16,52	3,23	24,85	56,16	1,29	434,93	7,32	0,49	0,43	0,89	0,06
7x8	108,70	94,16	17,58	5,37	31,85	63,27	1,17	420,17	7,02	0,44	0,41	0,86	0,05
1x9	104,80	58,04	15,52	3,53	20,35	62,62	1,49	432,57	7,02	0,45	0,40	0,84	0,05
3x9	109,30	73,54	18,82	3,63	26,65	51,73	1,35	438,09	6,39	0,52	0,45	0,90	0,06
4x9	105,50	69,26	15,48	4,67	27,25	51,15	1,83	465,05	6,59	0,44	0,41	0,85	0,04
5x9	101,80	59,16	14,88	3,87	21,25	56,45	1,53	446,99	7,79	0,44	0,40	0,86	0,05
7x9	98,70	43,94	14,12	3,53	17,35	60,92	2,50	460,31	7,59	0,49	0,42	0,90	0,07
1x10	112,30	66,86	17,08	4,07	22,05	52,54	1,18	438,10	7,45	0,49	0,45	0,87	0,05
2x10	103,90	55,96	16,58	3,97	20,35	52,31	1,33	441,93	6,64	0,49	0,44	0,88	0,06
3x10	107,70	52,34	17,22	3,43	18,45	54,26	1,62	449,56	8,09	0,48	0,42	0,89	0,05
4x10	103,90	77,66	16,18	5,07	30,85	56,89	1,86	459,10	8,30	0,48	0,43	0,88	0,06
5x10	105,20	46,54	14,92	2,93	17,45	43,00	0,99	444,81	6,75	0,48	0,43	0,89	0,05
6x10	109,80	48,46	15,38	2,77	21,05	57,29	1,00	411,94	6,57	0,42	0,39	0,84	0,05
7x10	108,30	58,54	16,22	3,73	22,55	56,23	1,17	438,17	8,74	0,41	0,39	0,82	0,02
1x11	103,00	51,34	16,62	3,73	23,05	61,12	0,74	369,10	6,65	0,53	0,45	0,90	0,06
2x11	102,30	49,96	16,68	3,27	20,65	57,94	1,73	450,11	7,85	0,45	0,41	0,87	0,06
3x11	101,10	43,94	15,92	3,13	16,45	53,07	1,25	434,84	5,90	0,51	0,44	0,90	0,07
4x11	114,00	50,94	16,32	3,03	21,45	52,14	1,69	455,95	7,07	0,40	0,37	0,84	0,03
7x11	98,80	47,06	14,48	3,07	18,65	57,88	1,18	425,79	8,01	0,47	0,42	0,88	0,06

CAPÍTULO II

PREDIÇÃO DO CICLO DE GENÓTIPOS DE SOJA UTILIZANDO ÍNDICES DE VEGETAÇÃO E INTELIGÊNCIA COMPUTACIONAL

RESUMO

Os índices de vegetação vêm sendo amplamente utilizados na predição da produtividade de grãos em soja, contudo, a sua aplicação em estudos visando a predição do ciclo é recente. Uma alternativa para o processamento destes dados é o uso de redes neurais artificiais (RNAs). Este trabalho teve como objetivo utilizar redes neurais artificiais (RNAs) para prever o ciclo de genótipos de soja utilizando índices de vegetação. Para este fim, 196 populações F_{2:5} e 10 testemunhas foram avaliadas em delineamento de blocos aumentados. Foram mensurados os IVs: NDVI (*Normalized Difference Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*), GNDVI (*Green Normalized Difference Vegetation Index*) e SAVI (*Soil Adjusted Vegetation Index*). Os dados foram ampliados para 600 indivíduos e particionado em 80% para treinamento das RNAs e 20% para validação. A arquitetura de rede utilizada foi a Perceptron Multicamadas, com duas camadas ocultas. Para as RNAs, foram testados 486 cenários distintos, obtidos pela combinação entre 9 possibilidades de neurônios na primeira camada (2-10 neurônios) x 9 possibilidades de neurônios na segunda camada (2-10 neurônios) x três funções de ativação (logsig, tansig e purelin) x dois algoritmos de treinamento (trainbr e trainlm). Foi realizada análise de regressão múltipla do ciclo em função dos IVs. O coeficiente de determinação (R^2) das análises foi utilizado como medida de acurácia seletiva de cada modelo. Após a identificação da melhor topologia de rede neural (algoritmo de treinamento: trainbr, função de ativação: logsig, 10 neurônios na primeira camada oculta e 8 na segunda), esta foi utilizada para a predição do ciclo dos genótipos com base nos dados originais, obtendo R^2 de 73,97%.

PALAVRAS-CHAVE: precocidade, *Glycine max*, redes neurais artificiais, regressão múltipla, coeficiente de determinação.

INTRODUÇÃO

A soja [*Glycine max* (L.) Merrill] representa atualmente um dos principais produtos de exportação do agronegócio brasileiro, contribuindo de forma significativa para a balança comercial. O cultivo da soja no país ocorre predominantemente no Cerrado (Silva et al., 2017), cujo clima predominante é o tropical sub-úmido, caracterizado por pequena variação da temperatura média diária e forte estacionalidade de chuvas (Silva et al., 2008).

No Cerrado brasileiro são desejáveis cultivares de soja que possuam precocidade, além da alta produtividade de grãos (Meotti et al., 2012). Isso ocorre porque os produtores desta região têm a possibilidade de cultivar o milho ou o algodão na segunda safra, entre os meses de fevereiro e julho. Além disso, os genótipos de ciclo precoce permanecem menos tempo no campo, e estão sujeitos à menor pressão de doenças. Um complexo de doenças, chamadas de doenças de final de ciclo da soja, provoca reduções consideráveis no rendimento da cultura (Finoto et al., 2011). Portanto, a precocidade nas cultivares de soja é uma das principais características atualmente exigida pelo mercado, uma vez que possibilita a redução de custos com a cultura no campo e minimiza os riscos que podem surgir em função de fatores bióticos e abióticos (Teixeira, 2017).

Existem dez genes que controlam o tempo de florescimento e maturidade, e estão relacionados à determinação do ciclo da soja (Bernard, 1971; Watanabe et al., 2012; Kong et al., 2014). Entretanto, o ciclo da soja também é influenciado por diversos fatores ambientais, tais como fotoperíodo, temperatura e estresse hídrico (Zhang et al., 2009). Assim, uma cultivar pode ter o seu ciclo alterado em função da data de semeadura, do local de cultivo e das condições climáticas vigentes durante seu desenvolvimento. Adicionalmente, diferenças de data de floração também podem ocorrer entre cultivares semeadas na mesma data e latitude, em virtude da resposta diferencial dos genótipos ao fotoperíodo (Embrapa, 2013).

A caracterização da precocidade é uma atividade que demanda tempo e mão-de-obra, uma vez que é necessária a contagem à campo do número de dias da emergência até o

florescimento ou maturação de cada genótipo. Isso ocorre porque anualmente são avaliados centenas de genótipos de soja e o monitoramento quanto ao ciclo de cada parcela deve ser realizado diariamente. Neste sentido, técnicas de sensoriamento remoto surgem como instrumento de elevado potencial, fornecendo informações específicas e confiáveis com relação ao estado das lavouras (Mercante et al., 2009). O monitoramento das culturas agrícolas pode ser realizado com base em índices de vegetação, definidos como combinações de dados espectrais de duas ou mais bandas capazes de quantificar a cobertura vegetal, vigor e dinâmica de crescimento de espécies vegetais, entre outras aplicações (Xue e Su, 2017; Silva Junior et al., 2018). Os índices de vegetação vêm sendo amplamente utilizados na predição da produtividade de grãos em soja (Ma et al., 2001; Mourtzinis et al., 2014; Christenson et al., 2016). Contudo, a sua aplicação em estudos visando a predição do ciclo é recente, e trabalhos utilizando esta abordagem ainda são escassos na literatura.

Os índices de vegetação, em geral, estão relacionados de forma não-linear com a maioria das características agronômicas (Panda et al., 2010), além do fato dos diferentes índices serem correlacionados entre si. Neste sentido, uma técnica adequada de construção de modelo para previsão de caracteres como ciclo é essencial. Uma alternativa para o processamento destes dados é o uso de redes neurais artificiais (RNAs). O uso de RNAs para predição em cultivos agrícolas vem crescendo consideravelmente nos últimos anos (Blackard e Dean, 1999; Zhang et al., 2009). Elizondo et al. (1994) utilizaram RNAs para predizer a floração e a maturidade fisiológica da soja em três locais, e constataram a viabilidade do desenvolvimento de modelos de redes neurais para predizer a floração e a maturidade fisiológica da soja. A viabilidade das RNAs para predição do estágio fenológico da soja em função do grupo de maturidade, da data de plantio e do estágio de crescimento foi avaliada por Zhang et al. (2009). Segundo estes autores, a RNA forneceu a maior acurácia na predição do estágio fenológico, indicando que esta técnica pode ser efetivamente aplicada na modelagem de culturas. Diante do exposto, o

objetivo deste trabalho foi avaliar a eficiência das RNAs na predição do ciclo de genótipos de soja utilizando índices de vegetação.

MATERIAL E MÉTODOS

Condução do experimento

O experimento foi conduzido no campo experimental da Universidade Federal de Mato Grosso do Sul, Campus de Chapadão do Sul ($18^{\circ}46'26''S$, $52^{\circ}37'28''W$ e altitude média de 810 m), município de Chapadão do Sul-MS, no período de novembro de 2017 a fevereiro de 2018. O clima da região de acordo com a classificado de Koppen é do tipo Aw, definido como tropical úmido, com estação chuvosa no verão e seca no inverno. A Figura 1 contém as condições climáticas observadas no decorrer do experimento.

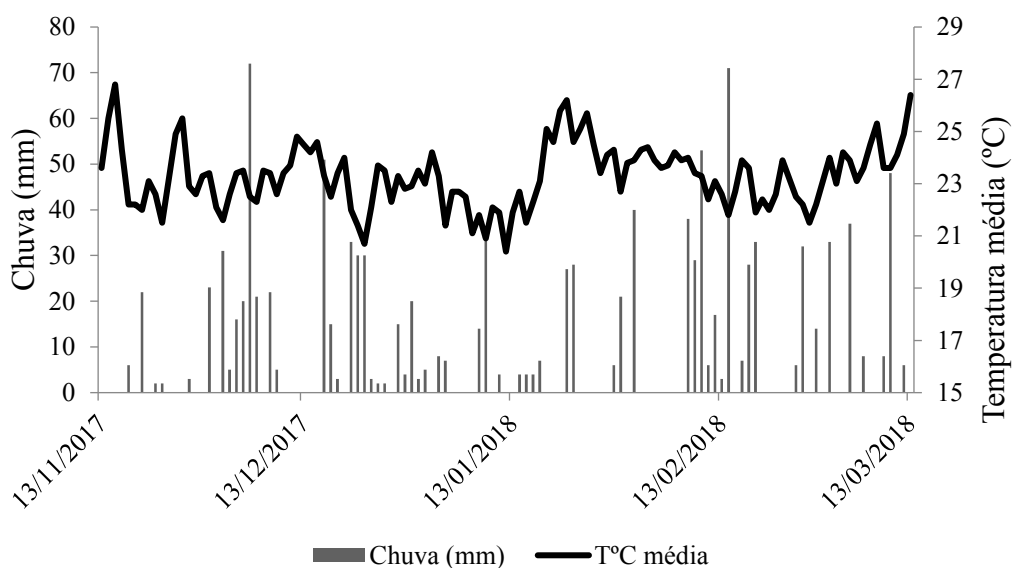


Figura 1. Condições climáticas observadas na área no decorrer do experimento.

Três meses antes da semeadura, a saturação por bases do solo da área experimental foi elevada para 60% por meio de calagem. Para implantação do experimento, foi utilizado preparo convencional do solo com uma aração e duas gradagens (com grade destorroadora e

niveladora). A abertura e a adubação das linhas foram realizadas de forma mecanizada com uma semeadora-adubadora John Deere® 2109, com cinco linhas instaladas no espaçamento de 0,45 m entre linhas. A adubação de base utilizada foi 300 kg ha⁻¹ do formulado 04-14-08. A semeadura foi realizada manualmente com a distribuição de 15 sementes por metro.

O experimento foi instalado em delineamento de blocos aumentados com 196 populações F_{2:5} do Programa Soja da Universidade Federal de Viçosa e 10 testemunhas, com cinco repetições para cada testemunha (Tabela 1). A unidade experimental constou de uma linha de 3,0 m para cada tratamento. O controle de plantas daninhas, pragas e doenças foi realizado conforme recomendações técnicas para a cultura.

Tabela 1. Relação das cultivares de soja usadas como testemunhas.

Cultivar	Empresa	Cultivar	Empresa
M 7211	Monsoy	1168	TMG
M 7908	Monsoy	123	TMG
M 9144	Monsoy	7262	TMG
NS 5959 IPRO	Nidera	UFVS Citrino	UFV
ST 815	Bayer	UFVS Turquesa	UFV

Caracteres avaliados

Aos 60 dias após a emergência, foi utilizada a aeronave remotamente pilotada (RPA) de asa fixa Sensefly eBee RTK, com controle autônomo de decolagem, plano de voo e aterrissagem. O eBee está equipado com o sensor multiespectral Parrot Sequoia. O sensor multiespectral Sequoia faz aquisição da reflectância nos comprimentos de onda do verde (550 nm), vermelho (660 nm), infravermelho próximo (735 nm) e infravermelho (790 nm), possuindo um sensor de luminosidade que permite a calibração dos valores adquiridos. As informações obtidas nesses comprimentos de ondas permitem o cálculo dos diversos mapas dos

índices de vegetação a serem utilizados nos algoritmos computacionais. As imagens foram mosaicadas e ortorretificadas pelo programa computacional Pix4Dmapper. A acurácia posicional das ortoimagens foi verificada com pontos de controle em campo (GCP – *Ground Control Points*), levantados com o RTK. Os índices de vegetação calculados foram: NDVI (*Normalized Difference Vegetation Index*), NDRE (*Normalized Difference Red Edge Index*), GNDVI (*Green Normalized Difference Vegetation Index*) e SAVI (*Soil Adjusted Vegetation Index*). Os índices de vegetação estudados em função da maior correlação com a massa vegetal, segundo Raper e Varco (2015), estão contidos na Tabela 2.

Tabela 2. Relação dos índices de vegetação calculados pelo uso do sensor multiespectral Sequoia.

Índice de Vegetação	Índice de Vegetação	Equação	Referências
NDVI	Índice de vegetação pela diferença normalizada	$\frac{(R_{NIR} - R_{RED})}{(R_{NIR} + R_{RED})}$	Rouse et al. (1974)
NDRE	Índice de vegetação pela diferença normalizada à transição do vermelho (<i>Red-edge</i>)	$\frac{(R_{NIR} - R_{EDGE})}{(R_{NIR} + R_{EDGE})}$	Gitelson e Merzlyak (1994)
GNDVI	Índice de vegetação pela diferença normalizada ao verde	$\frac{(R_{NIR} - R_{GREEN})}{(R_{NIR} + R_{GREEN})}$	Gitelson et al. (1996)
SAVI	Índice de vegetação ajustado pela presença de solo	$\frac{(1 + L)(R_{NIR} - R_{RED})}{(R_{NIR} + R_{RED} + L)}$	Huete (1988)

R_{NIR} : reflectância na faixa do infravermelho próximo; R_{GREEN} : reflectância na faixa do verde; R_{RED} : reflectância na faixa do vermelho; R_{EDGE} : reflectância na faixa de transição do vermelho (*Red-edge*); L: fator de correção do efeito do solo.

O número de dias para maturação (NDM) correspondeu ao número de dias entre a germinação e a maturação em mais de 50% de plantas da parcela. Com base no ciclo observado nas condições edafoclimáticas em Chapadão do Sul, foram adotados os seguintes critérios para classificação dos genótipos de soja quanto ao ciclo: genótipos de ciclo precoce possuem NDM menor ou igual a 105 dias; genótipos de ciclo médio possuem NDM entre 106 e 120 dias; genótipos de ciclo tardio possuem NDM superior a 120 dias. Com base nesses critérios, o conjunto de dados original foi composto por 73 genótipos de ciclo precoce, 45 de ciclo médio e 88 de ciclo tardio.

Conjunto de dados e modelagem da RNA

Para obter uma boa capacidade de generalização das diferentes arquiteturas das RNAs avaliadas, o conjunto de dados foi ampliado de modo que cada grupo (precoce, médio e tardio) fosse composto por 200 genótipos. Esse processo foi realizado de forma individual para cada grupo de modo que a média, a variância das variáveis e a covariância entre elas não fossem alteradas em relação aos dados originais. A ampliação foi realizada pelo software Genes (Cruz, 2013). Após ampliação do conjunto de dados, foram construídos boxplot para cada variável em função dos grupos estabelecidos.

As RNAs foram aplicadas ao conjunto ampliado de 600 indivíduos contendo o NDM como variável principal e os respectivos valores dos índices de vegetação. A arquitetura de rede utilizada foi a Perceptron Multicamadas. O conjunto de dados ampliados foi particionado em 80% para treinamento da rede e 20% para validação, e posteriormente a rede foi utilizada para a predição dos dados reais (conjunto teste). A camada de entrada foi composta pelos índices de vegetação; duas camadas ocultas, onde o número de neurônios testados em cada camada variou entre 2 a 10; a camada de saída foi composta por um único neurônio, representado por um vetor de elementos conhecidos, uma vez que o processo de aprendizado é supervisionado. Foram testadas as funções de ativação tangente hiperbólica (tansig), logística (logsig) e limiar

(purelin). Além disso, foram avaliados os algoritmos de treinamento *trainbr* (*Bayesian regulation backpropagation*) e *trainlm* (*Levenberg-Marquardt backpropagation*), com um número de épocas igual a 3000.

Portanto, foram testados 486 cenários distintos, obtidos pela combinação entre 9 possibilidades de neurônios na primeira camada x 9 possibilidades de neurônios na segunda camada x três funções de ativação x dois algoritmos de treinamento. Após testes destas possibilidades, foi escolhida a topologia que apresentou os maiores coeficientes de determinação (R^2) no treinamento e validação para a predição do NDM.

Para comparar os resultados de predição do NDM, foi realizada análise de regressão múltipla desta variável em função dos índices de vegetação, sendo avaliada a significância dos coeficientes de regressão do modelo pelo teste t e o R^2 . O R^2 das análises foi utilizado como medida de acurácia seletiva de cada modelo. As análises foram processadas pelos softwares Matlab (Mathworks, 2012), a partir de scripts do aplicativo Genes (Cruz, 2013), e Rbio (Bhering, 2017).

RESULTADOS E DISCUSSÃO

Análise exploratória

A Figura 2 contém a análise exploratória das variáveis avaliadas em função do ciclo dos genótipos. Os genótipos do grupo precoce, médio e tardio apresentaram média de 104, 115 e 128 dias para a maturação, respectivamente. De modo geral, os valores dos índices de vegetação avaliados decresceram em função do ciclo dos genótipos, onde os maiores valores foram obtidos pelos genótipos mais precoces. Esse resultado pode ser atribuído ao período para fechamento do dossel, que é mais rápido em cultivares de ciclo precoce. Desse modo, cultivares mais tardias possuem maior tempo para formação de área foliar, e conseqüentemente, maior tempo para atingir os valores máximos para os índices de vegetação avaliados.




Figura 2. Boxplot dos índices de vegetação (NDVI, SAVI, GNDVI e NDRE) avaliados em função do ciclo dos genótipos.

Observou-se também menor variabilidade dos valores de índices de vegetação amostrados para os genótipos de ciclo precoce, e tendência de maior variabilidade para os genótipos de ciclo tardio. Menores valores de índices de vegetação estão associados a menor taxa fotossintética das plantas de soja, devido à menor massa foliar (Kross et al., 2015), principalmente devido à maior absorção da energia luminosa do espectro na região do vermelho.

Regressão linear múltipla *versus* RNAs

De 600 genótipos gerados via ampliação dos dados (200 para cada ciclo), 480 foram utilizados para treinamento do modelo e 120 para sua validação em cada situação. A Figura 3 demonstra os valores preditos e observados pela análise de regressão múltipla do NDM em função dos índices de vegetação avaliados. Nesta análise houve significância ($p < 0,05$) de todos

os coeficientes de regressão do modelo $NDM = 117,26 - 2,51NDRE - 60,92GNDVI + 44,08SAVI + 24,52NDVI$, gerado com os dados ampliados. O coeficiente de determinação (R^2) foi 38,24% no treinamento e 10,33% na validação do modelo. Apesar da influência dos índices de vegetação sobre o NDM, esses resultados demonstram que não é possível prever esta variável com precisão utilizando o modelo de regressão múltipla construído.

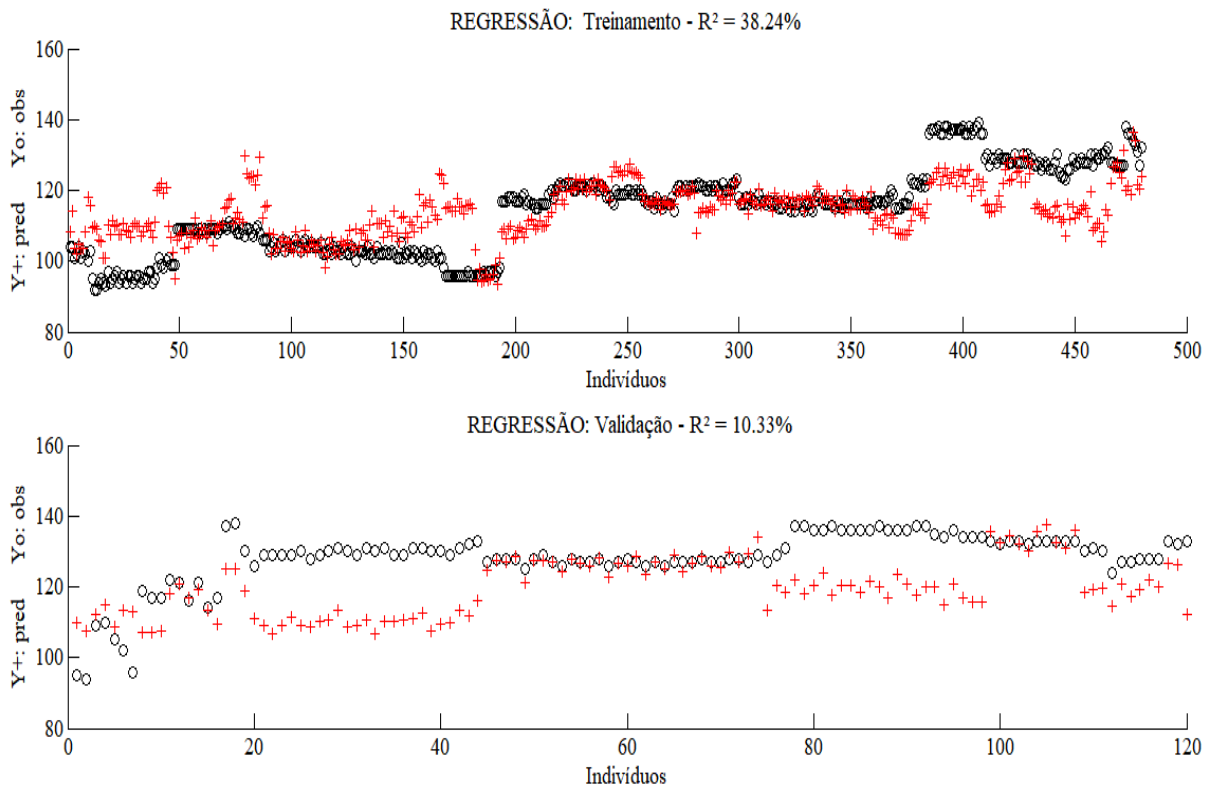


Figura 3. Valores observados (o) e preditos (+) do NDM em genótipos de soja obtidos pela análise de regressão múltipla em função dos índices de vegetação NDRE, GNDVI, SAVI e NDVI.

Os R^2 obtidos no treinamento e validação das melhores topologias quanto ao número de neurônios para os algoritmos de treinamento e funções de ativação avaliados estão contidos na Tabela 3. A melhor topologia de rede para predição do ciclo incluiu 10 neurônios na primeira camada e 8 na segunda utilizando o algoritmo de treinamento trainbr e a função de ativação

logsig. Essa topologia está representada na Figura 4A, cujos R^2 de treinamento e validação foram de 96,76 e 96,96%, respectivamente (Figura 4B).

Tabela 3. Coeficientes de determinação (R^2) obtidos no treinamento e validação das melhores topologias quanto ao número de neurônios para os algoritmos de treinamento e funções de ativação avaliados para predição do ciclo de genótipos de soja em função dos índices de vegetação NDRE, GNDVI, SAVI e NDVI.

Algoritmo de treinamento	Função de ativação para todas camadas	Número de neurônios	R^2 (%) Treinamento	R^2 (%) Validação
trainbr	logsig	10:8	96,76	96,96
trainbr	Tansig	10:10	96,63	95,99
trainbr	purelin	2:2	37,28	37,28
trainlm	logsig	8:6	62,99	62,99
trainlm	Tansig	2:10	56,86	43,87
trainlm	purelin	4:10	38,24	10,33

Baseado nos R^2 obtidos nos modelos de predição do NDM em função dos índices de vegetação, fica evidente a superioridade das RNAs em relação à regressão linear múltipla quanto ao reconhecimento de padrões e capacidade de predição. Estes resultados corroboram relatos como os de Egrioglu et al. (2015), que mencionaram que as RNAs apresentam vantagens sobre as técnicas convencionais devido sua capacidade de generalização, paralelismo e a possibilidade de aprendizagem. A metodologia de regressão requer suposições sobre a variação e distribuição de dados, que nem sempre são válidas. Diferentemente da análise de regressão e de alguns outros modelos estatísticos, as RNAs não requerem hipóteses sobre a distribuição das variáveis, e por isso os modelos de RNAs podem superar o modelo de regressão (Zhang et al., 2009).


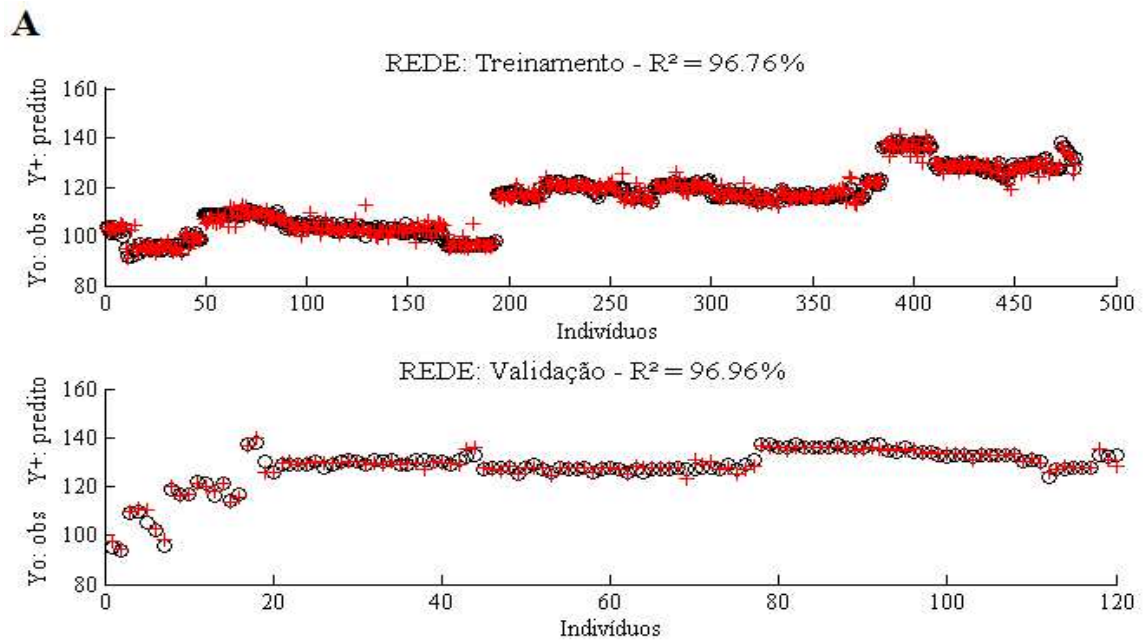


Figura 4. Valores observados (o) e preditos (+) do número de dias para maturação (A) em genótipos de soja obtidos pela melhor topologia (B) da rede neural em função dos índices de vegetação NDRE, GNDVI, SAVI e NDVI.

É possível constatar que o algoritmo trainbr apresentou R^2 superiores, considerando todas as funções de ativação. Segundo Kayri (2016), o algoritmo trainlm foi desenvolvido especialmente para uma convergência mais rápida. Apesar de ser considerado um dos mais

rápidos, o algoritmo trainlm tem dificuldade em determinar a estrutura ideal da rede neural e está propenso a sobreajuste (*overfitting*) (Burden e Wincker, 2008; Bui et al., 2012). Por outro lado, o algoritmo trainbr é mais robusto, e por esta razão proporciona resultados mais acurados (Bui et al., 2012). Okut et al. (2011) e Kayri (2016), comparando a capacidade de predição destes dois algoritmos, também constataram um melhor desempenho do trainbr em termos de capacidade preditiva.

Utilização da melhor topologia de RNA para predição do ciclo

Após a identificação da melhor topologia de rede neural (algoritmo de treinamento: trainbr, função de ativação: logsig, 10 neurônios na primeira camada e 8 na segunda), esta foi utilizada para a predição do ciclo dos genótipos com base nos dados originais (Figura 5). É possível observar que a melhor RNA encontrada obteve R^2 de 73.97%.




Figura 5. Utilização da melhor topologia (algoritmo de treinamento: trainbr, função de ativação: logsig, 10 neurônios na primeira camada e 8 na segunda) para predição do ciclo de 206 genótipos de soja com base nos dos índices de vegetação (NDVI, SAVI, GNDVI e NDRE).

Christenson et al. (2014) observaram relações significativas entre grupo de maturidade de genótipos de soja e as reflectâncias nas regiões espectrais do vermelho e NIR. De modo similar, os resultados obtidos revelam a existência de uma relação entre ciclo e índices de vegetação e que, conseqüentemente, o NDM pode ser predito a partir do uso de índices de vegetação. Isto é importante do ponto de vista dos programas de melhoramento de soja, uma vez que a precocidade de genótipos pode ser inferida por meio desta técnica de sensoriamento remoto. Com o uso de índices de vegetação, o ciclo dos genótipos pode ser determinada por uma única avaliação, substituindo as mensurações periódicas à campo realizadas na avaliação convencional do NDM e possibilitando os programas de melhoramento avaliar um número maior de linhagens e selecioná-las quanto a precocidade.

Devido à sua estrutura não-linear, as RNAs podem capturar os recursos mais complexos do conjunto de dados e não exigem informações detalhadas sobre o processo a ser modelado devido ao seu auto-aprendizado (Haykin, 2009). Além disso, as redes neurais não exigem ausência de multicolinearidade dos dados (Burden e Wincker, 2008; Kayri, 2016). Este fato pode ser uma das explicações para as diferenças nos resultados observados entre as técnicas utilizadas. Os índices de vegetação mensurados são correlacionados entre si, o que faz com que os dados utilizados apresentem multicolinearidade. Neste sentido, as RNAs proporcionam modelos preditivos mais precisos do que a regressão linear múltipla, uma vez que a ausência de multicolinearidade é um dos pressupostos destas técnicas convencionais.

CONCLUSÃO

O uso de redes neurais artificiais possibilita a predição do número de dias para a maturação em soja em com base em índices de vegetação.

REFERÊNCIAS

- Bhering, L.L. 2017. Rbio: A tool for biometric and statistical analysis using the R platform. *Crop Breed. Appl. Biotechnol.* 17:187-190.
- Blackard, J.A., Dean, D.J. 1999. Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. *Comput. Electron. Agr.* 24: 131-151.
- Bui, D.T., Pradhan, B., Lofman, O., Revhaug, I., Dick, O.B. 2012. Landslide susceptibility assessment in the Hoa Binh province of Vietnam: a comparison of the Levenberg–Marquardt and Bayesian regularized neural networks. *Geomorphology* 171:12-29.
- Burden F., Winkler, D. 2008. Bayesian Regularization of Neural Networks. In: Livingstone D.J. (eds). *Artificial Neural Networks. Methods in Molecular Biology™*, Humana Press.
- Christenson, B.S., Schapaugh, W.T., An, N., Price, K.P., Fritz, A.K. 2014. Characterizing changes in soybean spectral response curves with breeding advancements. *Crop Sci.* 54:1585-1597.
- Christenson, B.S., Schapaugh, W.T., An, N., Price, K.P., Prasad, V., Fritz, A.K. 2016. Predicting soybean relative maturity and seed yield using canopy reflectance. *Crop Sci.* 56:625-643.
- Cruz, C.D. 2013. Genes: a software package for analysis in experimental statistics and quantitative genetics. *Acta Sci. Agron.* 35:271-276.
- Egrioglu, E., Yolcu, U., Aladag, C.H., Bas, E. 2015. Recurrent multiplicative neuron model artificial neural network for non-linear time series forecasting. *Neural Process Lett* 41:249-258.
- Elizondo, D.R., McClendon, R.W., Hoogenboom, G. 1994. Neural network models for predicting flowering and physiological maturity of soybean. *Trans ASAE* 37:981–988.

Empresa Brasileira de Pesquisa Agropecuária. 2013. Tecnologias de produção de Soja Região Central do Brasil. Embrapa Soja, Londrina.

Finoto, E.L., Carrega, W.C., Sedyama, T., de Albuquerque, J.A.A., Cecon, P.R., Reis, M.S. 2011. Efeito da aplicação de fungicida sobre caracteres agronômicos e severidade das doenças de final de ciclo na cultura da soja. *Rev. Agroamb.* 5:44-49.

Gitelson, A., Kaufman, Y.J., Merzlyak, M.N. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sens. Environ.* 58:289-298.

Gitelson, A., Merzlyak, M.N. 1994. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. *J. Plant. Physiol.* 143:286-292.

Haykin, S. 2009. *Neural networks and learning machines*. 3rd ed. Prentice Hall, New York.

Huete, A.R 1988. A soil adjusted vegetation index (SAVI). *Remote Sens. Environ.* 25:295-309.

Kayri, M. 2016. Predictive abilities of bayesian regularization and Levenberg–Marquardt algorithms in artificial neural networks: a comparative empirical study on social data. *Math. Comput. Appl.* 21:20.

Kong, F., Nan, H., Cao, D., Li, Y., Wu, F., Wang, J., Luab, S., Yuana, X., Coberd, L.R., Abee, J., Liu, B. 2014. A new dominant gene conditions early flowering and maturity in soybean. *Crop. Sci.* 54:2529-2535.

Kross, A., McNairn, H., Lapen, D., Sunohara, M., Champagne, C. 2015. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. *Int. J. Appl. Earth Obs Geoinf* 34:235-248.

Ma, B.L., Dwyer, L.M., Costa, C., Cober, E.R., Morrison, M.J. 2001. Early prediction of soybean yield from canopy reflectance measurements. *Agron. J.* 93:1227–1234.

MathWorks, I. 2012. *MATLAB and statistics toolbox release*. The MathWorks, Natick, MA.

- Meotti, G.V., Benin, G., Silva, R.R., Beche, E., Munaro, L.B. 2012. Épocas de semeadura e desempenho agrônômico de cultivares de soja. *Pesq. Agropec. Bras.* 47:14-21.
- Mercante, E, Lamparelli, R.A.C, Uribe-Opazo, M.A., Rocha, J.V. 2009. Características espectrais da soja ao longo do ciclo vegetativo com imagens Landsat 5/TM área agrícola no oeste do Paraná. *Eng. Agríc.* 29:328-338.
- Mourtzinis, S., Rowntree, S.C., Suhre, J.J., Weidenbenner, N.H., Wilson, E.W., Davis, V.M., Specht, J.E. 2014. The use of reflectance data for in-season soybean yield prediction. *Agron. J.* 106:1159-1168.
- Okut, H., Gianola, D., Rosa, G.J., Weigel, K.A. 2011. Prediction of body mass index in mice using dense molecular markers and a regularized neural network. *Genetics Res.* 93:189-201.
- Panda, S.S., Ames, D.P., Panigrahi, S. 2010. Application of vegetation indices for agricultural crop yield prediction using neural network techniques. *Remote Sens.* 2:673-696.
- Raper, T.B., Varco, J.J. 2015. Canopy-scale wavelength and vegetative index sensitivities to cotton growth parameters and nitrogen status. *Precis. Agric.* 16:62-76.
- Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W., Harlan, J.C. 1974. Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. NASA, Greenbelt.
- Silva, F.A.M., Assad, E.D., Steinke, E.T., Müller, A.G. 2008. Clima do Bioma Cerrado. In: Albuquerque, A. C. S., da Silva, A. G (Eds). *Agricultura tropical: quatro décadas de inovações tecnológicas, institucionais e políticas*. Embrapa Informação Tecnológica, Brasília.
- Silva, F.C.S., Sediyaama, T., Oliveira, R.C.T., Borém, A., Silva, F.L., Bezerra, A.R.G., Silva, A.F. 2017. Importância econômica e evolução do melhoramento. In: Silva, F.L., Borém, A., Sediyaama, T., Ludke, W. (Eds). *Melhoramento da Soja*. UFV, Viçosa.

Silva Junior, C. A., Nanni, M. R., Shakir, M., Teodoro, P. E., de Oliveira-Júnior, J. F., Cezar, E., Shiratsuchi, L. S. (2018). Soybean varieties discrimination using non-imaging hyperspectral sensor. *Infrared Phys. Technol.* 89:338-350.

Teixeira, F.G. 2017. Herança da precocidade e de caracteres agronômicos em soja e seleção de linhagens com base em índices de seleção. Dissertação (Mestrado em Agronomia), Universidade Federal de Uberlândia.

Watanabe, S., Harada, K., Abe, J. 2012. Genetic and molecular bases of photoperiod responses of flowering in soybean. *Breed. Sci.* 61:531-543.

Xue, J., Su, B. 2017. Significant remote sensing vegetation indices: A review of developments and applications. *J. Sensors* 2017:1-17.

Zhang, J.Q., Zhang, L.X., Zhang, M.H., Watson, C. 2009. Prediction of soybean growth and development using artificial neural network and statistical models. *Acta Agron. Sin.* 35:341-347.