

RESSALVA

Atendendo solicitação do(a) autor(a), o texto completo desta dissertação será disponibilizado somente a partir de 03/08/2020.

UNIVERSIDADE ESTADUAL PAULISTA – UNESP

CÂMPUS DE JABOTICABAL

**ESTIMAÇÃO E PREVISÃO DE PRODUTIVIDADE DE
SOJA POR REDES NEURAIS NO MATOPIBA**

Valter Barbosa dos Santos

Engenheiro Agrônomo

2020

UNIVERSIDADE ESTADUAL PAULISTA – UNESP

CÂMPUS DE JABOTICABAL

**ESTIMAÇÃO E PREVISÃO DE PRODUTIVIDADE DE
SOJA POR REDES NEURAIS NO MATOPIBA**

Valter Barbosa dos Santos

Orientador: Prof. Dr. Glauco de Souza Rolim

Dissertação apresentada à Faculdade de Ciências Agrárias e Veterinárias – Unesp, Câmpus de Jaboticabal, como parte das exigências para a obtenção do título de mestre em Agronomia (Ciência do Solo).

2020

S237e

Santos, Valter Barbosa dos

Estimação e previsão de produtividade de soja por redes neurais no MATOPIBA / Valter Barbosa dos Santos. -- Jaboticabal, 2020

70 p. : tabs., mapas

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: Glauco de Souza Rolim

1. Inteligência artificial. 2. Soja. 3. Produtividade agrícola. 4. Python (Linguagem de programação de computador). I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO


TÍTULO DA DISSERTAÇÃO: ESTIMAÇÃO E PREVISÃO DE PRODUTIVIDADE DE SOJA POR REDES NEURAIS NO MATOPIBA

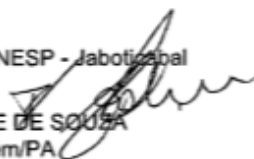
AUTOR: VALTER BARBOSA DOS SANTOS

ORIENTADOR: GLAUCO DE SOUZA ROLIM

Aprovado como parte das exigências para obtenção do Título de Mestre em AGRONOMIA (CIÊNCIA DO SOLO), pela Comissão Examinadora:


Prof. Dr. GLAUCO DE SOUZA ROLIM
Departamento de Ciências Exatas / FCAV / UNESP - Jaboticabal


Prof. Dr. ROGÉRIO TEIXEIRA DE FARIA
Departamento de Engenharia Rural / FCAV / UNESP - Jaboticabal


Prof. Dr. PAULO JORGE DE OLIVEIRA PONTE DE SOUZA
Universidade Federal Rural da Amazônia / Belém/PA

Jaboticabal, 03 de fevereiro de 2020

DADOS CURRICULARES DO AUTOR

Valter Barbosa dos Santos- Filho de José Carlos dos Santos e Severina Barbosa (In memoriam). Nasceu em São José de Ribamar, Maranhão, no dia 22 de fevereiro de 1990. Técnico em Agropecuária pela Escola Agrotécnica Federal do Maranhão (2009), cursou engenharia Agrônômica na Universidade Estadual do Maranhão-UEMA, câmpus Paulo VI, de São Luís-MA, de 2010 a 2017. Bolsista de iniciação científica pela PIBIC/UEMA em 2014-2015, atuando principalmente nos seguintes temas: manejo, potássio, adubação orgânica, agricultura familiar, Fertilidade do Solo. Trabalhou como Servidor público, concursado no cargo de Fiscal Ambiental (2013-2018). Em março de 2018, ingressou no Curso de Mestrado em Agronomia (Ciência do Solo), na Faculdade de Ciências Agrárias e Veterinárias – UNESP. É integrante do grupo de pesquisa: “Group of Agrometeorological Studies” (GAS), da Unesp – Câmpus de Jaboticabal. Em fevereiro de 2020, submeteu-se à banca para a defesa de Dissertação.

DEDICO

A Deus, pela dádiva da vida pois sem ele eu não teria traçado o meu caminho e feito a minha escolha pela Agronomia.

Aos meus pais, José Carlos e Severina Barbosa **(In memoriam)** pelo apoio e confiança, mesmo distantes. A minha esposa e filho pela companhia nessa jornada.

OFEREÇO

À minha família, pelo incentivo e força nessa caminhada.

À professora Ana Maria Araújo da Silva, por ter acreditado no meu potencial desde 2014, despertando o lado científico das ciências agrônômicas através das orientações em projetos de iniciação científica.

AGRADECIMENTOS

Agradeço primeiramente a **Deus**, pela dádiva da vida pois sem ele eu não teria traçado o meu caminho e feito a minha escolha pela Agronomia.

A minha **família** pelo amor incondicional, especialmente meus pais e meus irmãos, acreditando, apoiando e confiando em mim mesmo distantes, aos meus sobrinhos e a toda família Moreno e Barbosa dos Santos.

A minha esposa e filho, Aline e Samuel pelo amor, companheirismo e amizade, e principalmente por me acompanharem nessa jornada.

Ao meu orientador professor Glauco de Souza Rolim, por sua amizade, dedicação pelos seus ensinamentos que me possibilitou realizar mais essa etapa da minha vida.

A professora Dr^a. Ana Maria Silva de Araújo, pelos ensinamentos, amizade, disposição, e paciência, por ter acreditado no meu potencial desde 2014 quando começamos a trabalhar juntos, me despertando o lado científico das ciências agrônomicas através das orientações em projetos de iniciação científica entre os anos de 2014 a 2015.

Aos professores Rogério Teixeira de Faria e Paulo Jorge de Oliveira Ponte de Souza membros da banca de qualificação pelas importantes sugestões.

A meus amigos e parceiros científicos, José Reinaldo da Silva Cabral de Moraes, Tayanara Tuany Borges Valeriano, Mary Jane Nunes Carvalho, Kárita Almeida Silva, Paulo Alexandre da Silva e Kamila Cunha de Meneses.

Ao Grupo de Pesquisa em Agrometeorologia da Unesp – GAS, pelo recebimento no grupo e pelos conhecimentos compartilhados.

A meus amigos e colegas de departamento, Gustavo André, Thiago Águas, pela disponibilidade em ajudar sempre que foi necessário.

Aos funcionários do Departamento de Ciências Exatas, Maria José Servidone Trizólio, Shirley Aparecida Martineli de Sousa, Adriana Elisabete Takakura, por me receberem bem no departamento, e pelo carinho.

Ao programa de Pós-Graduação em Agronomia (Ciência do Solo), pela oportunidade em cursar o mestrado.

À Fundação de Amparo à Pesquisa e ao Desenvolvimento Científico e Tecnológico do Maranhão - FAPEMA, pela concessão da bolsa de mestrado no país e, pelo apoio para o desenvolvimento da pesquisa.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

SUMÁRIO

RESUMO	x
ABSTRACT	xi
LISTA DE ABREVIATURAS E SIGLAS	xii
LISTA DE FIGURAS	xiii
LISTA DE TABELAS	xvi
CAPÍTULO 1 – Considerações gerais	1
1.1 Introdução	1
1.2 Revisão de Literatura	2
1.2.1 Importância econômica do MATOPIBA.....	2
1.2.2 Cultivo da Soja.....	4
1.2.3 Importância da modelagem.....	6
1.2.3.1 Modelagem	7
1.2.3.2 Redes neurais artificiais (RNAs)	9
REFERÊNCIAS	11
CAPITULO 2 – ESTIMAÇÃO E PREVISÃO DE PRODUTIVIDADE DE SOJA POR REDES NEURAS	19
Resumo	19
Abstract	20
2.1 Introdução	21
2.2 Material e Métodos	24
2.2.1 Localização e caracterização da área de estudo	24
2.2.2 Seleção dos locais de estudo	25
2.2.3 Dados Meteorológicos	27
2.2.4 Balanço Hídrico	28
2.2.5 Análise de dados	28
2.2.6 Avaliação do modelo	31
2.3 Resultados e Discussão	32
2.4 Conclusões	49
Referências	50

ESTIMAÇÃO E PREVISÃO DE PRODUTIVIDADE DE SOJA POR REDES NEURAIS NO MATOPIBA

RESUMO: A demanda por alimento se torna cada vez maior e para atendê-la em tempo hábil e quantidade suficiente, utilizamos redes neurais artificiais para previsão de produtividade. Dentre essas técnicas, a mais comumente empregada para prever a produtividade da soja é a Rede Neural Artificial. O objetivo dessa pesquisa foi estimar e prever a produtividade de soja utilizando redes neurais artificiais e informações climáticas mensais da temperatura do ar, precipitação, radiação global, e componentes do balanço hídrico como evapotranspiração de cultivo, armazenamento, evapotranspiração real de cultivo, deficiência e excedentes hídricos durante o ciclo do cultivo para os estados do Maranhão, Tocantins, Piauí e Bahia, que juntos formam a fronteira agrícola do MATOPIBA no Brasil, produtividade média para a região durante o período avaliado é de 2.575 kg ha⁻¹. Os resultados mostram que a RNA ajustada para estimação apresentou erros de até 100 kg ha⁻¹ (sub e superestimando) em grande parte (27) das localidades, 10 municípios apresentam produtividade subestimada, e 15 apresentam resultados superestimados. Enquanto que a RNA ajustada para previsão mostrou que 30 localidades apresentam produtividades com erros até 100 kg ha⁻¹, 8 e 14 municípios com produtividade subestimada e superestimada, respectivamente.

Palavras – Chave: inteligência artificial, balanço hídrico, soja, produtividade agrícola

ESTIMATION AND FORECAST OF SOYBEAN YIELD BY NEURAL NETWORKS IN MATOPIBA

ABSTRACT – The demand for food becomes increasing and to meet it in a timely and sufficient amount, we use artificial neural networks to predict productivity. Among these techniques, the most commonly used to predict soybean yield is the Artificial Neural Network. The objective of this research was to estimate and predict soybean yield using artificial neural networks and monthly climatic information of air temperature, precipitation, global radiation, and water balance components such as crop evapotranspiration, storage, real crop evapotranspiration, deficiency and water surpluses during the cultivation cycle for the states of Maranhão, Tocantins, Piauí and Bahia, which together form the agricultural frontier of MATOPIBA in Brazil, average productivity for the region during the period evaluated is 2,575 kg ha⁻¹. The results show that the RNA adjusted for estimation presented errors of up to 100 kg ha⁻¹ (under and overestimation) in large part (27) of the localities, 10 municipalities presented underestimated productivity, and 15 presented overestimated results. While the RNA adjusted for forecasting showed that 30 localities present productivity with errors up to 100 kg ha⁻¹, 8 and 14 municipalities with underestimated and overestimated productivity, respectively.

Keywords: Artificial Intelligence, water balance, soybeans, agricultural productivity

LISTA DE ABREVIATURAS E SIGLAS

ML – Machine learning

RNAs – Redes Neurais Artificiais

DNNs – Redes Neurais Profundas

CNNs- Redes Neurais Convolucionais

LSTMs - Long Short Term Memory

MLP - Multilayer Perceptron

GEE - Google Earth Engine

RUE - Eficiência no uso da radiação

T – Temperatura °C – Graus

Celsius

P – Precipitação

AWC – Capacidade de água disponível

CET – Evapotranspiração da cultura

AET – Evapotranspiração real

STO – Armazenamento

DEF – Déficit

EXC – Excedente

BH – Balanço Hídrico

CV – Cros - validation

LISTA DE FIGURAS

	Página
Figura 1 (Capítulo 1) - Rede neural perceptron de múltiplas camadas.....	22
Figura 1 (Capítulo 2) - Localização da área de estudo, A) Brasil, B) Estados que compõem a Fronteira agrícola do MATOPIBA e C) Delimitação territorial do MATOPIBA.	38
Figura 2 (Capítulo 2) - Representação dos dados na camada de entrada (input) relativo a um ano	42
Figura 3 (Capítulo 2) - Esquema das Features para as Redes Neurais Artificiais para estimação (A) e previsão (B) de produtividade de soja para o MATOPIBA.	43
Figura 4 (Capítulo 2) - Precipitação dos meses de A) novembro, B) dezembro, C) janeiro, D) fevereiro, E) março e F) precipitação acumulada do período. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guaraí-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA.....	46
Figura 5 (Capítulo 2) - Temperatura dos meses de A) novembro, B) dezembro, C) janeiro, D) fevereiro, E) março e F) temperatura média do período. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guaraí-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA.....	47
Figura 6 (Capítulo 2) - Evapotranspiração da cultura dos meses de A) novembro, B) dezembro, C) janeiro, D) fevereiro, E) março e F) evapotranspiração media da cultura no período. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guaraí-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA	48
Figura 7 (Capítulo 2) - Evapotranspiração real dos meses de A) novembro, B) dezembro, C) janeiro, D) fevereiro, E) março e F) evapotranspiração média do período. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guaraí-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA.....	49

Figura 8 (Capítulo 2) - Deficiência hídrica nos meses de A) novembro, B) dezembro, C) janeiro, D) fevereiro, E) março e F) Deficiência hídrica acumulada do período. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guarai-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA..... 50

Figura 9 (Capítulo 2) - Armazenamento de água no solo nos meses de A) novembro, B) dezembro, C) janeiro, D) fevereiro, E) março e F) armazenamento médio do período. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guarai-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA..... 51

Figura 10 (Capítulo 2) - Excedente hídrico nos meses de A) novembro, B) dezembro, C) janeiro, D) fevereiro, E) março e F) excedente médio do período. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guarai-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA..... 52

Figura 11 (Capítulo 2) - Correlação entre as variáveis meteorológicas mensais e a produtividade de soja para o município de: A) Anapurus – MA com clima seco e B) Alvorada – TO com clima úmido 53

Figura 12 (Capítulo 2) - Desempenho do modelo de Redes Neurais Profundas (DNNs) para estimação de produtividade de soja para o MATOPIBA..... 56

Figura 13 (capítulo 2) – A) Produtividade observada (OBS), B) produtividade estimada (EST) e C) diferença entre a produtividade estimada e observada. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guarai-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA..... 57

Figura 14 (Capítulo 2) - Distribuição de Erros de estimação por redes neurais profundas para a região do MATOPIBA. Observação: as cores correspondem a escala da figura 13-C. 58

Figura 15 (capítulo 2) – Ajuste do modelo de Redes Neurais Profundas (DNNs) para previsão de produtividade de soja. 59

Figura 16 (Capítulo 2) - A) Produtividade observada, B) produtividade predita e C) diferença entre a produtividade predita e observada. 1) Anapurus-MA, 2) Sucupira do Norte-MA, 3) Balsas-MA, 4) Estreito-MA, 5) Guaraí-TO, 6) Alvorada-TO, 7) Dianópolis-TO, 8) Porto Nacional-TO, 9) B Jesus-PI, 10) Sebastião Leal-PI, 11) Alto Parnaíba-MA, 12) Formosa do Rio Preto-BA, 13) São Desidério-BA..... 60

Figura 17 (capítulo 2) – Distribuição de Erros de previsão por redes neurais profundas para a região do MATOPIBA. Observação: as cores correspondem a escala da figura 16-C. 61

LISTA DE TABELAS

Página

Tabela 1 (Capítulo 1) - Área (km ² e %) das características predominantes nos municípios do Matopiba com grande participação na produção nacional de soja, milho e algodão em 2012	16
Tabela 2 (Capítulo 1) - - Estádios vegetativos e reprodutivos da soja. Adaptado de RITCHIE, 1998	19
Tabela 1 (Capítulo 2) – Municípios selecionados conforme critério da série histórica nos estados do Maranhão - MA, Tocantins – TO, Piauí – PI e Bahia BA, seguidos de área plantada em ha e produtividade média da série histórica em kg ha ⁻¹	39
Tabela 2 (Capítulo 2) - Coeficiente de cultivo da soja	41
Tabela 3 (Capítulo 2) – Hiperparâmetros ajustados na Rede Neural Artificial Multilayer Perceptron – RNA-MLP. O MLPRegressor é um método disponível no pacote Scikit-learn (autor, ano) da linguagem Python	43
Tabela 4 (Capítulo 2) – Hiperparâmetros ajustados e métricas de desempenho dos modelos de Redes Neurais Artificiais para estimação e previsão de produtividade de soja para o MATOPIBA55

CAPÍTULO 1 – Considerações gerais

1.1 Introdução

A inteligência artificial (IA) é definida como o campo científico que dá às máquinas a capacidade de aprender sem serem estritamente programadas. Este conhecimento poderá causar um efeito disruptivo em diferentes atividades da civilização humana. A IA aplicada em problemas agrícolas é recente, entretanto, já se vislumbra que o potencial preditivo, reconhecimento de padrões como os de imagem, robótica, entre outros, causará também uma transformação da agricultura mundial (Patricio, 2018).

A agricultura de precisão começou a ser desenvolvida na década de 1980 (Finger, 2019) e aborda o desafio de adaptar o gerenciamento das características do local, do cultivo e do ambiente (Lowenberg-DeBoer, 2015) lidando com heterogeneidades de áreas produtivas.

A união da IA com a agricultura de precisão define o que hoje é chamado de agricultura digital, que surge como um novo campo científico utilizando grande quantidade de dados, auxiliando o planejamento e decisões estratégicas para impulsionar a produtividade agrícola minimizando seu impacto ambiental (Liakos, 2018).

Uma das técnicas da inteligência artificial é o aprendizado de máquina (ML) que surgiu juntamente com as tecnologias de big data e a computação de alto desempenho para criar novas oportunidades para entender, quantificar e estimar/prever diversos processos ou fenômenos (Samuel, 2000).

Dentre as técnicas de ML, as Redes Neurais Artificiais (ANNs) são as mais utilizadas na literatura. As MLs são modelos supervisionados que normalmente são usados para problemas de regressão e classificação, geralmente utilizando a unidade de processamento chamada por Rosenblatt (1958) de 'perceptron'. As ANNs são divididas em duas categorias: ANNs tradicionais, com apenas uma camada escondida, e ANNs profundas, com mais camadas. As RNAs profundas são conhecidas como aprendizado profundo ou redes neurais profundas (DNNs) (Lecun, 2015).

O potencial preditivo possibilitado pelas DNNs poderá causar efeito significativo no melhoramento do monitoramento e das previsões agrícolas, tanto em áreas agrícolas tradicionais como em fronteiras agrícolas como o MATOPIBA

no Brasil. As previsões de produtividade agrícolas têm forte importância relacionadas à especulação de estoques, preços, sustentabilidade e segurança alimentar, regulando os mercados agrícolas, permitindo o planejamento da redução dos impactos ambientais e fazer frente à variabilidade e mudanças climáticas (Gusso et al, 2017).

2.4 Conclusões

As Redes Neurais Artificiais Profundas (DNNs) ajustadas foram capazes de estimar com $R^2=0.88$ e $RMSE= 167.85 \text{ kg ha}^{-1}$ e prever com $R^2=0.86$ e $RMSE= 185.86 \text{ kg ha}^{-1}$ a produtividade da soja para o MATOPIBA.

Foi possível a previsão de produtividade em até 2 meses antes da colheita utilizando DNNs.

A DNN mostrou-se robusta, uma vez que atingiu resultados acurados usando apenas variáveis de clima e componentes do balanço hídrico. Isso mostra a importância dos fatores climáticos na produtividade de soja na região do MATOPIBA.

REFERÊNCIAS

Allen RG, Pereira LS, Raes D, Smith M. Crop evapotranspiration: Guidelines for computing crop water requirements. Rome: FAO, 1998. 300 p. (FAO – Irrigation and Drainage Paper, 56).

Alves GR, Teixeira IR, Melo FR, Souza, RTG, Silva, AG (2018). Estimating soybean yields with artificial neural networks. **Acta Scientiarum Agronomy**, 40. <http://dx.doi.org/10.4025/actasciagron.v40i1.35250>

Anochi JÁ, Velho HC (2016). Mesoscale Precipitation Climate Prediction for Brazilian South Region by Artificial Neural Networks. **American Journal of Environmental Engineering**, 6(4A), 94-102. doi: 10.5923/s.ajee.201601.14

Aparecido LEO, Rolim GS, Lamparelli RAC, Souza PS, Santos, ER (2017). Agrometeorological models for forecasting coffee yield. **Agronomy Journal**, 109(1), 249-258. doi:10.2134/agronj2016.03.0166

Araújo, ECD, Uribe-Opazo MA, Johann JA (2014). Modelo de regressão espacial para estimativa da produtividade da soja associada a variáveis agrometeorológicas na região oeste do estado do Paraná. **Engenharia Agrícola**, 34(2), 286-299. <http://dx.doi.org/10.1590/S0100-69162014000200010>

CAMARGO AP. Balanço hídrico no Estado de São Paulo. Campinas: IAC, 1971. 24 p. (Boletim Técnico, 116)

Ceglar A, Toreti A, Lecerf R, Van der Velde M, Dentener F (2016). Impact of meteorological drivers on regional inter-annual crop yield variability in France. **Agricultural and forest meteorology**, 216, 58-67. <https://doi.org/10.1016/j.agrformet.2015.10.004>

Choi DH, Ban HY, Seo BS, Lee KJ, Lee BW (2016). Phenology and seed yield performance of determinate soybean cultivars grown at elevated temperatures in a temperate region. **PloS one**, 11(11), e0165977. <https://doi.org/10.1371/journal.pone.0165977>

Chunjing Y, Yueyao Z, Yaxuan Z, Liu H (2017). Application of convolutional neural network in classification of high resolution agricultural remote sensing images. The International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**, 42. doi: 10.5194/isprs-archives-XLII-2-W7989-2017

Companhia Nacional De Abastecimento (CONAB). 2018. Perspectivas para a agropecuária, v.6, Safra 2018/2019, Brasília. Disponível em:

https://www.conab.gov.br/perspectivas-para-aagropecuaria/item/download/22780_ee707c6e6d44f06fe7b6a86ce6141652. Acesso em: 13 de novembro de 2019.

Companhia Nacional De Abastecimento (CONAB). 2019. Calendário de Plantio e Colheita de Grãos no Brasil 2019, Brasília. 73 p. Disponível em: <https://www.conab.gov.br/institucional/publicacoes/outras-publicacoes/item/7694-calendario-agricola-plantio-e-colheita.pdf>. Acesso em: 13 de novembro de 2019.

De Boeck H J, Kimball BA, Miglietta F, Nijs I (2012). Quantification of excess water loss in plant canopies warmed with infrared heating. **Global change biology**, 18(9), 2860-2868. <https://doi.org/10.1111/j.1365-2486.2012.02734.x>

Diogo AA, Ferraz SET, Streck NA, Cardoso ADO, Alencar JZ (2019). Indicadores Climáticos e a Produtividade de Soja no Rio Grande do Sul. **Revista Brasileira de Meteorologia**, 34(2), 191-200. <http://dx.doi.org/10.1590/0102-77863340024>

Dutra LF, Tavares S, Sartoretto L, Vahl L (1995). Resposta do feijoeiro ao fósforo em dois níveis de umidade no solo. **Current Agricultural Science and Technology**, 1(2). <http://dx.doi.org/10.18539/cast.v1i2.125>

Evangelista BA, da SILVA FAM, Simon J, Campos LJM (2017). Zoneamento de risco climático para determinação de épocas de semeadura da cultura da soja na região MATOPIBA. Embrapa Pesca e Aquicultura-Boletim de Pesquisa e Desenvolvimento (INFOTECA-E).

Farias JRB, Nepomuceno AL, Neumaier N (2007). Ecofisiologia da soja. Embrapa Soja-Circular Técnica (INFOTECA-E).

Filippi P, Jones EJ, Wimalathunge NS, Somarathna PD, Pozza LE, Ugbaje SU, Bishop TF (2019). An approach to forecast grain crop yield using multi-layered, multi-farm data sets and machine learning. **Precision Agriculture**, 1-15.

Haykin S (1999). Multilayer perceptrons. **Neural networks: a comprehensive foundation**, 1999, 2: 156-255.

Hoogenboom G, Jones JW, Wilkens PW, Porter CH, Hunt LA, Singh U, Koo J (2015). Decision Support System for Agrotechnology Transfer (DSSAT) version 4.5. DSSAT Foundation. Prosser, Washington. <http://dssat.net>.

Hussain MZ, Hamilton SK, Bhardwaj AK, Basso B, Thelen KD, Robertson GP (2019). Evapotranspiration and water use efficiency of continuous maize and maize and soybean in rotation in the upper Midwest US. **Agricultural Water Management**, 221, 92-98. <https://doi.org/10.1016/j.agwat.2019.02.049>

IBGE, (2018). Produção Agrícola Municipal – PAM In: IBGE. Sidra: sistema IBGE de recuperação automática. Rio de Janeiro, 2019. Disponível em: <https://sidra.ibge.gov.br/tabela/1612>

Jones JW, Antle JM, Basso B, Boote KJ, Conant RT, Foster I, Keating BA (2017). Toward a new generation of agricultural system data, models, and knowledge products: State of agricultural systems science. **Agricultural systems**, 155, 269288. <https://doi.org/10.1016/j.agsy.2016.09.021>

Jumrani K, Bhatia VS (2018). Impact of combined stress of high temperature and water deficit on growth and seed yield of soybean. **Physiology and Molecular biology of Plants**, 24(1), 37-50. <https://doi.org/10.1007/s12298-017-0480-5>

Kamilaris A, Kartakoullis A, Prenafeta-Boldú FX (2017). A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, 143, 23-37. <https://doi.org/10.1016/j.compag.2017.09.037>

Khaki S, Wang L (2019). Crop yield prediction using deep neural networks. **Frontiers in plant science**, 10. doi: 10.3389/fpls.2019.00621

Kingma DP, Ba J (2014). Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**.

Lamba V, Dhaka VS (2014). Wheat yield prediction using artificial neural network and crop prediction techniques (A Survey). **IJRASET**, 2(IX).

Liakos KG, Busato P, Moshou D, Pearson S, Bochtis D (2018). Machine learning in agriculture: A review. **Sensors**, 18(8), 2674. <https://doi.org/10.3390/s18082674>

Martin TN, Dourado Neto D, Vieira Junior PA, Pereira AR, Manfron PA, Christoffoleti PJ (2012). Modified crop model estimation of depleted and potential soybean yield. **Acta Scientiarum. Agronomy**, 34(4), 369-378. <http://dx.doi.org/10.4025/actasciagron.v34i4.15274>

Miranda EE. Matopiba: desenvolver a agricultura ou os agricultores? *Correio Brasiliense*, 30 abr. 2015.

Monteiro JE (2009). Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola. Brasília, DF: INMET.

Monteiro LA, Sentelhas PC (2014). Calibration and testing of an agrometeorological model for the estimation of soybean yields in different brazilian regions. **Acta Scientiarum. Agronomy** . 36(3), 265-272.

Nath A, Karunakar AP, Wanjari S, Kumar A (2018). Application of the

CROPGRO-Soybean Model (DSSAT V 4.5) for the Assessment of the Environmental Modification Effect on Soybean Productivity in the Akola region of Vidarbha, India. **International Journal of Bio-Resource & Stress Management**, 9(4). <https://doi.org/10.23910/IJBSM/2018.9.4.1865b>

Oikawa RT, Ishiki HM (2013). Modelos estatísticos e de redes neurais artificiais utilizados na previsão de precipitação. *Periódico Eletrônico Fórum Ambiental da Alta Paulista*, ISSN 1980-0827. <http://dx.doi.org/10.17271/19800827982013463>

Paredes P, Wei Z, Liu Y, Xu D, Xin Y, Zhang B, Pereira LS (2015). Performance assessment of the FAO AquaCrop model for soil water, soil evaporation, biomass and yield of soybeans in North China Plain. **Agricultural Water Management**, 152, 57-71. <https://doi.org/10.1016/j.agwat.2014.12.007>

Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Vanderplas J (2011). Scikit-learn: Machine learning in Python. **Journal of machine learning research**, 12(Oct), 2825-2830.

Reboita MS, Gan MA, da Rocha RP, Ambrizzi T (2010). Regimes de precipitação na América do Sul: uma revisão bibliográfica. **Revista Brasileira de Meteorologia**, 25(2).

Rhee J, Im J (2017). Meteorological drought forecasting for ungauged areas based on machine learning: Using long-range climate forecast and remote sensing data. **Agricultural and Forest Meteorology**, 237, 105-122. <https://doi.org/10.1016/j.agrformet.2017.02.011>

Robbins, H, Monro, S. A Stochastic Approximation Method. *The Annals of Mathematical Statistics*, Vol. 22, No. 3. (Sep., 1951), pp. 400-407.

Schlenker W, Roberts M J (2009). Nonlinear temperature effects indicate severe damages to US crop yields under climate change. **Proceedings of the National Academy of sciences**, 106(37), 15594-15598. <https://doi.org/10.1073/pnas.0906865106>

Sentelhas PC, Battisti R, Câmara GMS, Farias JRB., Hampf AC, Nendel C (2015). The soybean yield gap in Brazil—magnitude, causes and possible solutions for sustainable production. **The journal of agricultural science**, 153(8), 1394-1411. <https://doi.org/10.1017/S0021859615000313>

Silva, VPR, Silva, RA, Maciel, GF, Souza, EP, Braga, CC, Holanda, RM. (2020). Soybean yield in the Matopiba region under climate changes. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 24(1), 8-14. Epub December 09, 2019. <https://dx.doi.org/10.1590/1807-1929/agriambi.v24n1p8-14>.

Shook J, Wu L, Gangopadhyay T, Ganapathysubramanian B, Sarkar S, Singh, AK (2018). Integrating genotype and weather variables for soybean yield prediction using deep learning. **bioRxiv**. doi: 10.1101/331561

Stackhouse PW, Westberg D, Hoell JM, Chandler WS, Zhang T (2015). Prediction Of Worldwide Energy Resource (POWER)-Agroclimatology Methodology-(1.0 Latitude by 1.0 Longitude Spatial Resolution). Technical Report of NASA Langley Research Center and SSAI/NASA Langley Research Center, 1-46.

Stackhouse PW, Jr, Minnis P, Perez R, et al., 2016: An Assessment of New Satellite Data Products for the Development of a Long-term Global Solar Resource at 10-100 km. ASES National Solar Conference, San Francisco, CA, 10-13 July, 2016.

Sun J, Di L, Sun Z, Shen Y, Lai Z (2019). County-Level Soybean Yield Prediction Using Deep CNN-LSTM Model. **Sensors**, 19(20), 4363. <https://doi.org/10.3390/s19204363>

Teixeira, WWR, Battisti, R, Sentelhas, PC, de Moraes, MF, de Oliveira Junior, A. (2019). Uncertainty assessment of soya bean yield gaps using DSSAT-CSM-CROPGRO-Soybean calibrated by cultivar maturity groups. **Journal of Agronomy and Crop Science**, 205(5), 533-544.

Thornthwaite CW, Mather JR (1955). The water balance. Centerton, NJ: Drexel Institute of Technology - Laboratory of Climatology. 104p. (Publications in Climatology, vol. VIII, n.1)

Wiebbecke, CE, Graham MA, Cianzio SR, Palmer RG (2012). Day temperature influences the male-sterile locus ms9 in soybean. **Crop science**, 52(4), 15031510. doi:10.2135/cropsci2011.08.0410

Xu Y, Yu L, Cai Z, Zhao J, Peng D, Li C, Gong P (2019). Exploring intra-annual variation in cropland classification accuracy using monthly, seasonal, and yearly sample set. **International Journal of Remote Sensing**, 1-16. <https://doi.org/10.1080/01431161.2019.1620377>

You J, Li X, Low M, Lobell D, Ermon S (2017, February). Deep gaussian process for crop yield prediction based on remote sensing data. In Thirty-First AAAI Conference on Artificial Intelligence.

Yuan W, Chen Y, Xia J, Dong W, Magliulo V, Moors E, Zhang H (2016). Estimating crop yield using a satellite-based light use efficiency model. **Ecological indicators**, 60, 702-709. <https://doi.org/10.1016/j.ecolind.2015.08.013>