UNIVERSIDADE ESTADUAL PAULISTA – UNESP

CÂMPUS DE JABOTICABAL

MODELAGEM AGROMETEOROLÓGICA PARA ESTIMAÇÃO DE PRODUTIVIDADE DE ERVA-MATE (*Ilex paraguariensis* ST. HIL.) NA REGIÃO SUL DO BRASIL

Mary Jane Nunes Carvalho

Engenheira Agrônoma

2020

UNIVERSIDADE ESTADUAL PAULISTA – UNESP

CÂMPUS DE JABOTICABAL

MODELAGEM AGROMETEOROLÓGICA PARA ESTIMAÇÃO DE PRODUTIVIDADE DE ERVA-MATE (*Ilex paraguariensis* ST. HIL.) NA REGIÃO SUL DO BRASIL

Mary Jane Nunes Carvalho

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

C331m

Carvalho, Mary Jane Nunes

Modelagem agrometeorológica para estimação de produtividade de erva-mate (Ilex paraguariensis St. Hil.) na região Sul do Brasil / Mary Jane Nunes Carvalho. -- Jaboticabal, 2020

61 p. : tabs., mapas

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

Orientador: Glauco de Souza Rolim

1. Agrometeorologia. 2. Clima. 3. Modelagem. 4. Modelos. 5. Produtividade. 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.

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: MODELAGEM AGROMETEOROLÓGICA PARA ESTIMAÇÃO DE PRODUTIVIDADE DE ERVA-MATE (*Ilex Paraguariensis* ST. HIL.) NA REGIÃO SUL DO BRASIL

AUTORA: MARY JANE NUNES CARVALHO
ORIENTADOR: GLAUCO DE SOUZA ROLIM

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

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

Dra. ANGÉLICA PRELA PANTANO
Instituto Agronômico de Campinas / APTA / Campinas P/

Profa. Dra. AMANDA LIZ PACÍFICO MANFRIM PERTICARRARI
Departamento de Ciências Exatas / FCAV / UNESP - Jaboticabal P/

Jaboticabal, 27 de março de 2020

DADOS CURRICULARES DA AUTORA

MARY JANE NUNES CARVALHO- Filha de João Batista Pinto Carvalho e Marcelina Diniz Nunes Carvalho, nasceu em 17 de setembro de 1994, na cidade de São Luís, Estado do Maranhão, Brasil. Ingressou no curso de Engenharia Agronômica da Universidade Estadual do Maranhão- UEMA, campus Paulo VI, de São Luís-MA, em agosto de 2012. Onde foi monitora das disciplinas Produção e tecnologia de sementes e Silvicultura no ano de 2016. Participou Laboratório de Extensão (LABEX), fazendo parte do Grupo de Produção vegetal, foi bolsista de projetos de extensão universitária no período de 2013 a 2014. Foi bolsista na modalidade de iniciação científica da Fundação de Amparo à Pesquisa do Estado do Maranhão (FAPEMA), no período de 2014 a 2017. Em janeiro de 2018, obteve o título de Engenheira Agrônoma. Iniciou o curso de pós-graduação *Stricto sensu* na modalidade Mestrado em Agronomia (Ciência do Solo) em agosto de 2018, na Universidade Estadual Paulista "Júlio Mesquita Filho", no Campus de Jaboticabal, no Departamento de Ciências Exatas sob a orientação do Prof. Dr. Glauco de Souza Rolim, atuando em pesquisas na área de Agrometeorologia e Modelagem. É integrante do grupo de pesquisa: "Group of Agrometeorological Studies" (GAS), da Unesp – Câmpus de Jaboticabal. Em março de 2020 submeteu-se à banca para a defesa de Dissertação.

“ O que adquire entendimento ama a sua alma; o que conserva a inteligência achará o bem”

Provérbios 19:8

DEDICO

A Deus, pela dádiva da vida.

Aos meus pais João Batista Pinto Carvalho e Marcelina Diniz Nunes Carvalho, exemplos de vida e dedicação.

OFEREÇO

À toda minha família, pelo incentivo e força nessa caminhada.

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela dádiva da vida, pois sem Ele eu não teria conseguido chegar até aqui.

A minha família pelo amor incondicional, especialmente meus pais, João Batista Pinto Carvalho e Marcelina Diniz Nunes Carvalho por terem me ensinado a ser perseverante e a lutar por aquilo em que acredito.

Aos meus irmãos, Marcy Jane, Mary Diely, Jardson e Jarlison, pelo apoio, pelas palavras amigas, por sempre acreditaram e confiaram em mim.

Ao meu orientador professor Dr. Glauco de Souza Rolim, pela orientação, incentivo, dedicação, pelos seus ensinamentos que foram fundamentais para que pudesse realizar mais essa etapa da minha vida.

As professoras membras da banca de defesa Profa. Dra. Amanda Liz Pacífico Manfrim Perticarrari e Profa. Dra. Angélica Prela Pantano, pelas contribuições atribuídas a minha pesquisa.

Aos meus grandes amigos Jonathan Viana, Aline Moreno, Valter Barbosa, Eliane Nascimento, Maria Elisa Vicentini e Kamila Meneses, obrigada pelo apoio, conselhos, companhia, por tudo que boas amizades são capazes de proporcionar.

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

Aos meus amigos e colegas de departamento, Kárita Almeida, Nayane Maia, Washington Pereira, Tatiana Santos, Lígia Negri, Paulo Alexandre, pela companhia ao longo desse tempo.

As meninas da Rep, Karine, Ana Paula, Áurea, Fernanda pelo convívio e amizade, vocês são incríveis.

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.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrarias e Veterinárias, Campus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Ciência do Solo), pela oportunidade em cursar o mestrado.

Enfim, agradeço a todos, professores, amigos e conhecidos que direta ou indiretamente em algum momento da vida contribuíram para minha formação.

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

Muito obrigada!

SUMÁRIO

Página

RESUMO..... xii
ABSTRACT..... xiii
LISTA DE ABREVIATURAS.....xiv
LISTA DE FIGURAS.....xv
LISTA DE TABELAS.....xvi

CAPÍTULO 1- Considerações Gerais..... 1
1.1 Introdução.....1
1.2 Revisão de Literatura.....3
1.2.1 Importância econômica da erva-mate para o Sul do Brasil 3
1.2.2 Fatores que afetam o desenvolvimento e produtividade dos cultivos.... 4
1.2.2.1 Solo e produtividade da erva-mate..... 4
1.2.2.2 Clima e produtividade da erva-mate 5
1.2.2.3 Altitude e Precipitação 5
1.2.2.4 Temperatura do ar 5
1.2.2.5 Radiação..... 6
1.2.2.6 Déficit hídrico..... 6
1.2.3 Fenologia reprodutiva da erva-mate..... 7
1.2.4 Modelagem e aplicações..... 8
1.2.4.1 O que é modelagem 8
1.2.4.2 Uso de modelos na agricultura 9
REFERÊNCIAS.....**11**
CAPÍTULO 2- Modelagem agrometeorológica para estimação de produtividade de erva-mate (*Ilex paraguariensis* St. Hil.) na região Sul do Brasil.....16
Resumo.....16
Abstract.....17

2.1 Introdução.....18
2.2 Material e Métodos..... 22
2.2.1 Localização e seleção das áreas de estudo.....22
2.2.2 Dados Meteorológicos.....24
2.2.3 Balanço Hídrico.....24
2.2.4 Análise de dados.....25
2.2.5 Avaliação dos modelos.....28
2.3 Resultados e discussão.....30
2.4 Conclusão.....39
Referências.....40

MODELAGEM AGROMETEOROLÓGICA PARA ESTIMAÇÃO DE PRODUTIVIDADE DE ERVA-MATE (*Ilex Paraguariensis* ST. HIL.) NA REGIÃO SUL DO BRASIL

RESUMO – A estimação de produtividade usando modelos agrometeorológicos é uma técnica de estratégia robusta para a realização do planejamento, uma vez que o conhecimento prévio das safras agrícolas facilitam as tomadas de decisões. O Objetivo deste estudo foi identificar e avaliar a influência das variáveis agrometeorológica em diferentes fases de desenvolvimento da cultura, para propor modelos agrometeorológicos com fim de estimar produtividade para erva-mate nos estados do Paraná, Santa Catarina e Rio Grande do Sul. Foram utilizados dados meteorológicos diários de temperatura e precipitação obtidos na plataforma NASA-POWER para um período de 28 anos, referentes a 38 localidades. Realizou-se balanço hídrico para obtenção das variáveis, evapotranspiração, déficit hídrico, excedente e armazenamento. Os dados de produtividade foram obtidos na plataforma IBGE no sistema de Recuperação Automática-SIDRA. Para o entendimento da dispersão espacial foi feita análise de agrupamento utilizando cluster hierárquico aglomerativo. Foi feita estatística descritiva para cada grupo determinado por meio de box plot. Para a modelagem de produtividade de erva-mate foram utilizados modelos de regressão linear múltipla (RLM), e modelos de inteligência artificial como o Random Forest Regressor (RF) e Redes Neurais Multilayer perceptron (MLP) usando sempre as variáveis independentes os elementos meteorológicos decendiais: temperatura e precipitação, e os derivados do balanço hídrico: ARM, ETR, DEF e EXC, e como variável dependente a produtividade. Os resultados mostram que os valores de RLM não apresentaram resultados satisfatórios se comparado aos modelos RF e MLP que apresentaram melhor desempenho. Os modelos agrometeorológicos podem ser utilizados para estimação e previsões de produtividades e permitem ao setor agrícola reduzir riscos na produção e aumentar rentabilidade dos cultivos.

Palavras-chave: agrometeorologia, clima, modelagem, modelos, produtividade

AGROMETEOROLOGICAL MODELING FOR YERBA-MATE PRODUCTIVITY ESTIMATION (*Ilex paraguariensis* ST. HIL.) IN SOUTHERN BRAZIL

ABSTRACT- Productivity estimation using agrometeorological models is a robust strategy technique for planning, since prior knowledge of agricultural crops facilitates decision making. The objective of this study was to identify and evaluate the influence of agrometeorological variables in different stages of crop development, to propose agrometeorological models in order to estimate productivity for yerba mate in the states of Parana, Santa Catarina and Rio Grande do Sul. Daily weather and temperature meteorological data obtained on the NASA-POWER platform for a period of 28 years, referring to 38 locations. Water balance was performed to obtain the variables, evapotranspiration, water deficit, surplus and storage. The productivity data were obtained on the IBGE platform in the SIDRA Automatic Recovery system. For the understanding of spatial dispersion, cluster analysis was performed using an agglomerative hierarchical cluster. Descriptive statistics were made for each group determined using a box plot. For the modeling of yerba mate productivity, multiple linear regression models (RLM) were used, as well as artificial intelligence models such as Random Forest Regressor (RF) and Multilayer Perceptual Neural Networks (MLP), always using the independent variables of the decendial meteorological elements: temperature and precipitation and water balance derivatives: ARM, ETR, DEF and EXC and as a dependent variable, productivity. The results show that those values of RLM did not present satisfactory results when compared to the RF and MLP models that presented better performance. Agrometeorological models can be used to estimate and forecast yields and allow the agricultural sector to reduce risks in production and increase profitability of crops.

Keywords: agrometeorology, climate, models, modeling, productivity

LISTA DE ABREVIATURAS

AHC- Cluster hierárquico aglomerativo

ARM- Armazenamento de água no solo

°C - Graus Celsius

CV- Validação cruzada

DEF- Déficit hídrico

ETP- Evapotranspiração potencial

ETR- Evapotranspiração real

EUR- Eficiência do uso da radiação

EXC- Excedente hídrico

IA- Inteligência Artificial

MLP- Multilayer perceptron

NASA / POWER - NASA's Prediction of Worldwide Energy Resources

P - Precipitação

R2 - Coeficiente de determinação

RF- Random forest regressor

RLM- Regressão Linear Múltipla

RMSE- Raiz quadrada do erro-médio (RMSE - Root Mean Square Error)

RNA- Redes neurais artificiais

SIDRA- Sistema de Recuperação Automática

T- Temperatura do ar

LISTA DE FIGURAS

Página

Figura 1. Principais regiões produtoras de erva-mate,no Sul do Brasil: Paraná (PR), Santa Catarina (SC) e Rio Grande do Sul (RS).....21

Figura 2. Fenologia típica da erva-mate em decêndios das regiões produtivas dos estados do Paraná, Santa Catarina e Rio Grande do Sul. Legenda y-1= Ano anterior, y= Ano de colheita, os números correspondem aos decêndios..... 25

Figura 3. Dendograma de produtividades de erva-mate t ha^{-1}.....29

Figura 4. Mapa com base no índice de similaridade considerando a produtividade de erva-mate (t ha^{-1}) no Rio Grande do Sul, Santa Catarina e Paraná..... 30

Figura 5. Box Plot para as variáveis T, P, ETR, ARM, DEF, EXC e produtividade nos grupos determinados pela análise de cluster.....31

Figura 6. Correlações entre elementos meteorológicos e a fenologia da erva-mate..... 32

Figura 7. Dispersão entre os valores de produtividade estimados e observados do modelo Random Forest Regressor (RF).....35

Figura 8. Dispersão entre os valores de produtividade estimados e observados do modelo de Redes Neurais –MLP..... 36

LISTA DE TABELAS

Página

Tabela 1. Locais, coordenadas geográficas e altitudes, Paraná, Santa Catarina, Rio Grande do Sul.....22

Tabela 2. Modelo de Regressão linear múltipla para os grupos 1,2,3,4 e grupo geral.....33

Tabela 3. Comparação dos modelos de Regressão Linear Múltipla, Random Forest Regressor e Multilayer Perceptron.....37

CAPÍTULO 1- Considerações Gerais

1.1 Introdução

A erva-mate (*Ilex paraguariensis* A. St. Hil.) da família botânica Aquifoliaceae é uma planta arbórea originária das regiões subtropicais e temperadas da América do Sul, encontra-se principalmente no Brasil, Argentina, Paraguai, os principais países do mundo produtores de erva-mate (Ross et al., 2017; Wendling et al., 2013).

De hábito de consumo dos povos indígenas da região Sul-Americana, teve seu consumo difundido pelos colonizadores europeus na forma de bebidas como o chimarrão e o tererê fazendo parte do hábito alimentar, da cultura, das relações comerciais e políticas dos estados da região Sul do Brasil (Freitas et al., 2016).

As principais formas de consumo de erva-mate é o chá tradicional, que é consumido por milhões de pessoas na América do Sul, às vezes substituindo o café, devido ao seu efeito estimulante (Albas et al., 2014; Klering et al., 2008). Na região Sul do país os produtos de erva-mate são consumidos principalmente na forma de chimarrão e tererê, nos Estados Unidos, Alemanha e Síria é utilizada para a produção de “chá” e bebidas energéticas e em outros países como Espanha, Itália, Austrália, França, Japão, Coréia e Rússia o consumo de erva- mate se expandiu devido ao seu sabor e propriedades farmacêuticas (Cardozo Junior e Morand, 2016).

Em termos mundiais a Argentina destaca-se como o maior produtor de erva-mate. Os cultivos de erva-mate na Argentina, concentram-se nas províncias de Misiones (85%) e Corrientes (15%), já no Brasil estão concentrados nos estados vizinhos à província de Misiones, Rio Grande do Sul Paraná e Santa Catarina; e no Paraguai, em Itapúa e Alto Paraná del Paraguay, também na fronteira com Misiones. A produção média dos três países é cerca de 500.000 toneladas/ano (Cañete et al., 2017).

O Brasil vem ganhando destaque no cenário produtivo e comercial, produzindo atualmente mais de 500 mil toneladas de folha verde. Em 2018 foram produzidas 546.618 toneladas de erva-mate, em uma área de 77.713 hectares, resultando em uma produção média de 7.033 ton ha^{-1} (IBGE, 2018).

A produção de erva-mate concentra-se nos estados do Rio Grande do Sul, Santa Catarina e Paraná. Sendo o Rio Grande do Sul o estado brasileiro de maior representatividade em termos de produtividade, com 43% de produção nacional e 37% de área cultivada com erva-mate no país (IBGE,2018).

A cadeia produtiva de erva-mate destaca-se no cenário nacional por seu impacto ambiental, social e econômico. O cultivo de erva-mate representa fonte de renda para muitos agricultores, gerando cerca de 700 mil empregos diretos, sendo cultivada em 180 mil propriedades e 480 municípios do país (Medrado e Vilcahuaman, 2014).

A produção de erva-mate assim como outros cultivos agrícolas depende do clima e sua variabilidade. Seca, geada, chuva excessiva, granizo e diversos agentes biológicos, entre outras adversidades, podem afetar diversas culturas em diferentes estágios de desenvolvimento, essas variáveis podem resultar em perdas ou ganhos de produtividades (Ozaki, 2008).

As condições climáticas são determinantes na qualidade da erva produzida (Camotti Bastos et al., 2018). A erva-mate apresenta períodos fenológicos bem definidos, os quais podem ser alterados conforme o microclima de algumas regiões. A temperatura ideal para desenvolvimento das plantas encontra-se em torno de 18ºC. Plantas de erva-mate adultas respondem fortemente à condições de alta luminosidade (monocultura), onde mostram mais intensa emissão de folhas e formação de área foliar do que quando cultivadas sob o sub-bosque (Rakocevic e Martim, 2011). A fisiologia das folhas de erva-mate muda quando as plantas são cultivadas em monocultura (Rakocevic e Martim, 2011), e isso afeta fortemente as características do chimarrão obtido (Rakocevic et al., 2008). Estudos comprovam que o sombreamento é capaz de melhorar a qualidade da erva-mate final. Ressalta-se ainda que a composição química da planta varia com o tipo de solo, clima, época de amostragem, idade da planta e, principalmente, pelas características genéticas (Malavolta, 1980; Brondani et al., 2008).

A crescente demanda em valorizar e qualificar a cadeia produtiva da erva-mate, além de expandir o mercado consumidor, intensificou os estudos sobre a dinâmica do setor ervateiro, melhoramento genético, tecnologias de produção e qualidade dos

produtos (Santin et al., 2019; Santin et al., 2017). Porém, estudos para modelos agrometeorológicos com fins de estimação de produtividades são escassos. Até o momento pouco se foi estudado sobre modelos agrometeorológicos para estimação de produtividade da erva-mate.

Devido à importância econômica e cultural deste cultivo este estudo teve como objetivo desenvolver modelos agrometeorológicos para a estimação de produtividade para erva-mate nos estados do Paraná, Santa Catarina e Rio Grande do Sul.

1.2 Revisão de Literatura

1.2.1 Importância econômica da erva-mate para o Sul do Brasil

A erva-mate (*Ilex paraguariensis* St. Hil.), é uma espécie arbórea ocorre naturalmente no Brasil, Argentina e Paraguai. No Brasil a superfície de abrangência geográfica com presença de *ilex paraguariensis* estende-se desde a latitude de 21º S até 30º S e longitude de 48º 30’ O até 56º 10’ O, abrangendo a região Sul do país, Paraná, Santa Catarina, Rio Grande do Sul e regiões Centro Oeste, no Mato Grosso do Sul (Vieira, 2003) nesses locais ocorre tanto na forma nativa quanto cultivada.

O maior produtor brasileiro de folha verde de erva-mate é o Rio Grande do Sul, seguido de Paraná e Santa Catarina. O cultivo da erva-mate compreende um dos sistemas agroflorestais mais antigos e característicos da Região Sul brasileira, representam significativa importância socioeconômica e ambiental (Oliveira e Waquil, 2015). A espécie é explorada, economicamente, especialmente por suas propriedades fitoquímicas, como bebida estimulante e na produção de fármacos (Sousa et al., 2015, Burris et al., 2012).

Os principais destinos da matéria-prima, composta de folhas e ramos finos, são o chimarrão, o mate gelado e o chá-mate. A indústria química e farmacêutica tem mostrado interesse no uso da erva-mate para fabricação de medicamentos, tintas, desinfetantes e outros (Sá, 2017). Além de apresentar potencial para o uso em refrigerantes, doces e cosméticos (Oliveira e Waquil, 2015).

1.2.2 Fatores que afetam o desenvolvimento e produtividade dos cultivos

O sistema agrícola é complexo e diversos fatores afetam o desenvolvimento e produtividade dos cultivos. A produtividade depende da interação dos fatores genéticos da planta, do clima e solo do local considerado, sob o manejo antrópico (Mota, 1976). Esses fatores afetam diretamente a qualidade do produto final (Dias et al., 1999; Santos, 2002).

Os parâmetros climáticos são os fatores mais importantes que controlam a produtividade e a qualidade das folhas de erva-mate em áreas de plantações. As principais variáveis meteorológicas que afetam o crescimento, o desenvolvimento e a produtividade das culturas são: chuva, temperatura do ar e radiação solar (Hoogenboom, 2000; Jones et al., 2003), havendo ainda a influência no fotoperíodo, umidade do ar e do solo, velocidade e direção do vento (Mavi e Tupper, 2004). Esses fatores podem afetar o crescimento e o desenvolvimento das plantas de diferentes formas e em diversos estádios do ciclo da cultura (Camargo, 2010).

1.2.2.1 Solo e produtividade da erva-mate

A erva-mate é uma espécie considerada tolerante a solos de baixa fertilidade natural, resistente a solos degradados, vegeta preferencialmente em solos úmidos e permeáveis, não ocorrendo em solos hidromórficos, nem em solos que possuem deficiência hídrica, sendo mais frequente em solos com baixo teor de nutrientes trocáveis e alto teor de alumínio. Sua presença é mais frequente em solos de texturas médias (entre 15 e 35% de argila) e argilosa (mais de 35%), sendo raramente encontrada em solos constituídos por areias quartzosas (abaixo de 15% de argila). Tem ocorrência esparsa em solos rasos, preferindo solos medianamente profundos a profundos e com boa quantidade de matéria orgânica (Oliveira e Rotta, 1983). Devido à colheita de folhas e ramos acontecerem sucessivamente a cada dois anos, a intensa exportação foliar tanto de macro como de micronutrientes requer reposição dos nutrientes do solo (Vogel et al., 2006).

Os cultivos de erva-mate apresentam-se de duas formas, os ervais nativos e instalados. Os ervais nativos normalmente estão estabelecidos em solos ácidos, com teores altos de alumínio trocável e baixos de fósforo disponível. A sua ocorrência predominante em solos de alto teor de alumínio parece indicar que este elemento

influencia beneficamente o desenvolvimento das erveiras (Oliveira e Rotta, 1983; Pandolfo et al., 2007). Os ervais instalados estão sobre solos que normalmente já foram calcariados e cultivados com culturas anuais, apresentando melhores condições de fertilidade (Pandolfo et al., 2007).

1.2.2.2 Clima e produtividade da erva-mate

A agricultura, entre todas as atividades econômicas, é a que apresenta maior dependência das condições meteorológicas, principais responsáveis pelas oscilações e frustrações das safras agrícolas (Moraes et al., 1998). As relações entre os parâmetros climáticos e a produção agrícola são bastante complexas, pois os fatores ambientais podem afetar o crescimento e o desenvolvimento das plantas sob diferentes formas nas diversas fases do ciclo da cultura (Marcari et al., 2015).

O crescimento e desenvolvimento da erva-mate é afetado principalmente pela temperatura do ar, radiação solar e déficit hídrico. A espécie caracteriza-se por ser clímax e tolerante a certo grau de sombreamento. Para erva-mate o clima é o fator de maior impacto na produtividade já que observa-se influência na preferência que as indústrias brasileiras tem dado à erva-mate sombreada e/ou nativa, por serem mais suaves e assim mais aceitas pelo consumidor (Mazuchowski et al., 2003).

1.2.2.3 Altitude e Precipitação

A vegetação de erva-mate ocorre naturalmente nos sub-bosques sombreados pela floresta de Araucária, principalmente em altitude entre 500 a 1500 metros acima do nível do mar (Mazuchowski et al., 2003).

No sul do país a erva-mate é produzida com microclima caracterizado por precipitações médias anuais em torno de 1500 mm, variando de 1100 a 2300 mm (Oliveira & Rotta, 1983). O regime de chuvas é uniforme ou estacional na maior parte da área de ocorrência (Região Sul), sendo as chuvas concentradas no verão e as estações secas pouco pronunciadas ou ausentes no inverno.

1.2.2.4 Temperatura do ar

A temperatura média anual do ar nas regiões de cultivo da erva-mate situa-se entre 12 e 24 ºC, com maior ocorrência entre 15 a 18 ºC. A temperatura média do ar

do mês mais frio nas regiões produtoras situa-se entre 8 e 19 ºC, nos locais mais frios pode ocorrer uma alta frequência de geadas (Vieira, 2003).

No mapeamento climático segundo Koppen, fica evidenciado que a distribuição predominante da erva-mate concentra-se nos tipos climáticos Cfb (temperado úmido, com temperatura média do mês mais quente inferior a 22 ºC), seguido pelo Cfa (temperado úmido, com temperatura média do mês mais quente superior a 22 ºC) (Oliveira e Rotta, 1983).

1.2.2.5 Radiação

A erva-mate adapta-se à sombra em qualquer idade, tolerando plena exposição à radiação solar e ao frio na fase adulta. A radiação solar é o parâmetro microclimático de maior efeito sobre a área folhar e produção de fitomassa (Vieira, 2003). Segundo Caron et al. (2014), uma localidade com alta produtividade o fluxo global de radiação solar média é de 2,49 MJ m^{-2} dia^{-1}, com uma variação de 0,01 a 2,49 MJ m^{-2} dia^{-1} para o sistema de consórcio e uma média de 16,60 MJ m^{-2} dia^{-1}, com uma variação de 0,10 a 16,60 MJ m^{-2} dia^{-1} para o sistema monocultivo. A eficiência de conversão da radiação solar em fitomassa é uma variável que pode ser frequentemente utilizada em modelos de simulação do crescimento das culturas (Caron et al., 2014).

As indústrias brasileiras têm dado preferência à erva-mate sombreada e/ou nativa, pois são mais suaves e assim mais aceitas pelo consumidor. Assim, a erva-mate obtida em condições de sombreamento tem gerado melhores preços para o produtor (Mazuchowski et al., 2003).

1.2.2.6 Déficit hídrico

As necessidades hídricas das culturas agrícolas precisam ser satisfeitas nos diversos estádios fenológicos, desde a germinação e estabelecimento da cultura, passando pelo desenvolvimento, floração, formação e crescimento dos grãos ou frutos, até atingir a maturação e a colheita. No cultivo agrícola é imprescindível se conhecer as relações entre as chuvas da pré-estação e período chuvoso para escolha da melhor época de semeadura (Silva et al., 2009).

A deficiência hídrica nos cultivos afeta a evapotranspiração, a extração de umidade das raízes, a distribuição do sistema radicular e o tamanho do dossel

(Aparecido et al., 2016), pois o fechamento dos estômatos das plantas, causado por deficiência hídrica na zona radicular, além de tornar o processo fotossintético limitado, acarreta diretamente em efeito negativo sobre o desenvolvimento vegetal (Lobato et al., 2008, Rao e Chaitanya, 2019).

1.2.3 Fenologia reprodutiva da erva-mate

Para determinar as exigências climáticas de uma planta, são necessários estudos agroclimáticos e de observações fenológicas (Camargo et al., 2010). A identificação dos estádios de desenvolvimento e a quantificação do tempo necessário para atingir cada fase são importantes ferramentas no manejo das culturas (Rosa et al., 2010).

O estudo da fenologia representa uma ótima ferramenta para o entendimento dos fatores que influenciam a reprodução e a sobrevivência das espécies vegetais (Morellato et al., 2010). Os fatores reconhecidos como responsáveis pelo desenvolvimento reprodutivo diferenciado são os genéticos e ambientais (Sousa et al., 2015). Os eventos reprodutivos são regulados pelas suas características endógenas associadas às variações do clima, além de uma série de fatores abióticos como pluviosidade, temperatura e comprimento do dia (Mantovani, 2003).

Os eventos reprodutivos da *Ilex paraguariensis*, desde o botão floral até a maturação dos frutos foram detectados entre setembro e maio, sendo o seu maior índice de botão floral em outubro.

A antese acontece de outubro até novembro, sendo seu maior índice de intensidade em novembro, onde mais de 50% das plantas encontram-se floridas (Pires, 2014).

A floração desta espécie foi registrada acontecendo nos períodos de menor precipitação e de temperatura média acima de 25 ºC (Pires, 2014). O florescimento da planta ocorre de setembro a novembro no Paraná, de setembro a dezembro em Santa Catarina e de setembro a outubro no Rio Grande do Sul (Souza, et al., 2015).

A frutificação ocorre, em geral de dezembro a abril, sendo que em altitudes maiores do que 800 m, pode-se encontrados frutos maduros desde o final de abril até maio. O período de maio a setembro é o ideal para a colheita da erva-mate, em

especial entre junho a agosto, pois ainda não há brotação, as folhas estão maduras e a planta está em repouso fisiológico (Macarri, 2017). A reprodução inicia gradativamente a partir dos dois anos, em plantas propagadas vegetativamente e, dos 5 anos em árvores provenientes de sementes (Daniel, 2018).

Como a planta de erva-mate possui comportamento fenológico associado às estações do ano, têm-se grandes diferenças, em especial quanto à maturação e atributos organolépticos, entre a planta colhida no inverno e a planta colhida no verão (Caron et al., 2014). Essas diferenças afetam o rendimento industrial, o que pode afetar significativamente os custos de produção (Macarri, 2017). A maturação das folhas em erval a pleno sol e em erval cultivado no sub-bosque da floresta diferem entre si. Em erval a pleno sol, as folhas levam aproximadamente 18 meses (um ano e meio) para ficarem maduras. Portanto, é após esse período que se deve fazer à colheita, sendo possível colher a parte baixa e interna (baixeiro) em um determinado período e, em outro, a parte superior dos ramos. Já nos ervais nativos ou sob a proteção da mata, as folhas permanecem na planta por mais tempo, podendo-se fazer a poda entre 2 a 3 anos (Marques, 2013).

A influência do clima mostra-se bastante complexa, uma vez que cada elemento climático pode ter um peso diferente na fenologia das espécies (Ferraz, 1999). Conhecer a fisiologia da planta é fundamental, pois há variações na composição química da planta de erva-mate em função da época do ano, indicando que a colheita em diferentes épocas gera produtos diferentes do ponto de vista químico e nutritivo (Caron et al., 2014).

1.2.4 Modelagem e aplicações

1.2.4.1 O que é modelagem

Modelagem é uma ferramenta científica baseada na representação simplificada de um sistema que, na maioria dos casos, pode ser composta por um conjunto de símbolos e relações matemáticas logicamente ordenadas (Corrêa et al., 2011).

Para realizar modelagem deve-se partir da definição do problema a ser elucidado, simplificação e formulação de hipóteses, dedução do modelo, resolução do problema, calibração e validação do modelo e por fim aplicação do modelo (Manzione,

2017). Na literatura é possível encontrar inúmeros trabalhos utilizando modelagem, que demonstram sua utilidade e importância (Pagani et al., 2017; Asseng et al., 2014).

1.2.4.2 Uso de modelos na agricultura

A modelagem agrometeorológica é uma importante ferramenta para quantificar o efeito do clima sob o crescimento e desenvolvimento da planta e, consequentemente, prever e estimar produtividades e produção por planta (Klering et al., 2008).

Os modelos agrometeorológicos relacionados com crescimento, desenvolvimento e produtividade das culturas fornecem dados que permitem ao setor agrícola tomar importantes decisões, tais como melhor planejamento do uso do solo, adaptação de culturas, monitoramento e previsão de safras, controle de pragas e doenças, planejamento estratégia de pesquisa, entre outros (Moraes et al., 1998).

O uso de modelos agrometeorológicos vem crescendo ao longo dos anos e são amplamente utilizados para estimação e previsão de produtividades em diversos cultivos (Jones et al., 2017). No Brasil, a quantificação dos efeitos da variabilidade climática em culturas agrícolas e, consequentemente, o impacto sobre a produção são realizados de duas maneiras. Na primeira, inteiramente subjetiva, a safra é estimada com informações baseadas em opiniões de agentes técnicos e econômicos do setor agrícola. Na segunda, a safra é estimada em razão da produtividade com base em modelos agrometeorológicos e agrometeorológicos-espectrais, quando se utilizam informações multiespectrais de imagens de satélites para calcular algumas variáveis intrínsecas ao modelo (Rosa, 2010). Além de fornecer dados para alimentar os sistemas estimação de previsão de safras agrícolas, permitem identificar estresse hídrico ao longo do ciclo da cultura, cujos impactos na produtividade podem ser detectados e avaliados (Rosa, 2010).

Os modelos agrometeorológicos fundamentam-se na relação estatística entre variáveis dependentes, que deverão ser estimadas (por exemplo, produtividade de grãos ou desenvolvimento fenológico), e variáveis meteorológicas (precipitação pluvial, temperatura do ar e radiação solar) (Junges & Fontana, 2011).

Na literatura são encontrados modelos agrometeorológios para diversos cultivos, tais como, arroz, café, trigo e outros como exemplo podemos citar Klering et al. (2008), e Klering et al. (2016), que desenvolveram trabalhos de modelagem agrometeorológica para estimação de produtividade de arroz irrigado no Rio Grande do Sul, Nunes et al. (2010) com modelos agrometeorológicos de estimativa da duração do estádio floração maturação para três cultivares de café arábica, Junges e Fontana (2011) que desenvolveram modelos agrometeorológico-espectrais de estimativa de produtividade de grãos de trigo no Rio Grande do Sul e Rolim et al. (2011) usando modelagem agrometeorológica para estimação do desenvolvimento e da produção de jiló.

Na literatura são encontrados poucos trabalhos utilizando modelos para erva-mate, como podemos citar os modelos desenvolvidos por Peralta e Schmalko (2007), utilizando modelos para estimação de transferência de calor e massa no processo de tratamento térmico da erva-mate, Vuaden et al. (2009), utilizando modelos para estimar a biomassa comercial de brotos de *ilex paraguariensis* e Abitante, (2007) utilizando modelo matemático envolvendo a simulação da secagem em secadores de esteira. No entanto, até o presente momento nenhum modelo agrometeorológico para estimação de produtividade da erva-mate foi encontrado.

Referências

Abitante AL (2007) **Modelagem dinâmica e análise de um sistema de controle de umidade de folhas de erva-mate em secadores contínuos de esteira** 78f. Dissertação (Mestrado em Engenharia) - Programa de Pós-graduação em Engenharia, Universidade Federal do Paraná, PR.

Albas CS (2014) Avaliação da genotoxicidade do *Ilex paraguariensis* (erva mate) pelo teste do micronúcleo. **Revista Brasileira de Plantas Medicinais,** 16: 345-349.

Aparecido LEO (2016) **Produtividade e qualidade de bebida natural do cafeeiro cafeeiro**. 90f. Dissertação (Mestrado em Agronomia- Produção Vegetal)- Unesp, Jaboticabal.

Asseng S, Ewert F, Zhu Y (2014) Rising temperatures reduce global wheat production. **Nature Climate Change** 5:143-147.

Brondani GE 2008. Distribuição de N P K em um povoamento de *Ilex paraguariensis* A. St. Hil. **Floresta** 38: 267-275.

Burris KP, Harte FM, M P, Neal S JrC, & Zivanovic S (2012) Composition and Bioactive Properties of Yerba Mate (*Ilex paraguariensis* A. St.-Hil.): A Review. **Chilean journal of agricultural research,** *72*: 268-275.

Camargo MBP (2010) The impact of climatic variability and climate change on arabic coffee crop in Brazil. **Bragantia**, v: 239-247.

Camotti BM, Cherobim VF (2018) Reissmann CB, Fernandes Kaseker J, Gaiad S. Yerba mate: Nutrient levels and quality of the beverage depending on the harvest season. **J Food Compos Anal. Elsevier** 69:1–6.

Cañete LA, Argüello B del, Román ABP (2017) Estudio de la flora microbiana de la yerba mate durante las etapas de su elaboración. **Revista de Ciencia y Tecnología** 27: 51–57.

Cardozo Junior EL, Morand C (2016) Interest of mate (*Ilex paraguariensis* A. St.-Hil.) as a new natural functional food to preserve human cardiovascular health - A review. **Journal of functional foods** 21:440–454.

Caron BO, Schmidt D, Manfron PA, Behling AEE, Busanello C (2014) Efficiency of the use of solar radiation for plants *Ilex paraguariensis* cultivadas sob sombreamento e a pleno sol. **Ciência Florestal** 24:257–265.

Corrêa STR, Lorençoni R, Neto DD, Scarpere FV, Vivian R, Ruiz ET (2011) Aplicações e limitações da modelagem em agricultura- Revisão. **Brazilian Journal of agriculture** 86: 1-13.

Daniel O (2009) Erva-mate, Sistema de produção e processamento industrial; Dourados, Mato Grosso do Sul, UFGD; UEMS 288p.

Dias FLF, Mazza JA, Matsuoka S, Perecin D, Maule RF (1999) Produtividade da cana-de-açúcar em relação a clima e solos da região noroeste do estado de São Paulo. **Revista Brasileira de Ciência do Solo**, *23*:627-634.

Ferraz DK, Artes R, Mantovani W, Magalhães LM (1999) Fenologia de árvores em fragmento de mata em São Paulo. **Revista Brasileira Biologia** 59: 305-317.

Freitas R, Marques S, Souza T, Nogueira C, Silva A, Borges J, Souza J (2016) O consumo de chimarrão e o câncer de esôfago. **BrazilianJournal of Surgery and Clinical Research**14:118–123.

Hoogenboom G, Porter CHV, Shelia KJ, Boote U, Singh JW, White LA Hunt R, Ogoshi, JI Lizaso, J. Koo, S. Asseng, A. Singels LM e JJ. Sistema de Suporte à Decisão para Transferência de Agrotecnologia (DSSAT) Versão 4.7.5 478 (https://DSSAT.net). **Gainesville,** Flórida, EUA, 2019.

IBGE, (2019). 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** 155:269-288.

Junges AH, Fontana DC (2011) Modelo agrometeorológico-espectral de estimativa de rendimento de grãos de trigo no Rio Grande do Sul. **Revista Ceres** 58:09-16.

Klering EV, Fontana DC, Berlato MA, Filho AC (2008) Modelagem agrometeorológica do rendimento de arroz irrigado no Rio Grande do Sul. **Pesquisa Agropecuaria Brasileira** 43:549–558.

Klering EV, Fontana DC, Roglio VC, Alves RCM, Berlato MA (2016) Modelo agrometeorológico-espectral para estimativa da produtividade de grãos de arroz irrigado no Rio Grande do Sul. ***Bragantia*** *75*:247-256.

Lima VMP, Oliveira GC, Severiano EC, Oliveira LFC (2009) Intervalo hídrico ótimo e porosidade de solos cultivados em área de proteção ambiental do sul de Minas Gerais. **Revista Brasileira de Ciência do Solo** 33:1087-1095.

Lobato AKS ,Costa RCL ,Oliveira Neto CF ,Santos Filho BG ,Cruz FJR, Freitas JMN ,Cordeiro FC (2008). Alterações morfológicas na soja sob estresse hídrico progressivo. **Revista Internacional de Botânica** 4:231-235.

Maccari Jr , Queiroz MR, Maccari LDR, Rucker NG (2017) Indústria ervateira no estado do paraná ii - fornecimento de matéria-prima. **Revista Acadêmica Ciência Animal** 3:4-9.

Malavolta, E (1980) Elementos de nutrição mineral de plantas. São Paulo: **Agronômica Ceres** 1:251.

Manzione, RL (2017) Modelagem Matemática e Estatística Aplicada a Hidrogeografia a Agrometeorologia. **Irriga,** Botucatu 22:847-85.

Mavi HS, Tupper GJ (2004) Agrometeorology – Principles and application of climate studies in agriculture. New York: **Food Products Press** 364p.

Mazuchowski JZ., Maccari AJES (2003) Influência de diferentes condições de radiação solar sobre o crescimento morfológico da erva-mate (*Ilex paraguariensis* A. St. Hill.). **Anais** Congresso sul-americano da erva-mate, p.256–257.

Medrado MJS e Vilcahhuaman LJM (2014) Cultivo da Erva-Mate. Sistemas de Produção, Embrapa, 1ª ISSN 1678-8281.

Moraes AVC, Camargo MBP, Mascarenhas AA, Miranda MAC, Pereira JCVN (1998) Teste e análise de modelos agrometeorológicos de estimativa de produtividade para a cultura da soja na região de Ribeirão Preto. **Bragantia** 57:393-406.

Morellato LPC, Camargo MGG. D'eça NFF, Luize BG, Mantovani AH (2010) The influence of sampling method, sample size, and frequency of observations on plant phenological patterns and interpretation in tropical forest trees. Phenological research: methods for environmental and climate change analysis. Dordrecht, Springer, 99-121.

Mota FS (1976) Meteorologia Agrícola, São Paulo: Nobel, 379p.

Nunes FL, Camargo MB, Fazuoli LC, Rolim GS, Pezzopane JRM (2010). Modelos agrometeorológicos de estimativa da duração do estádio floração maturação para três cultivares de café arábica. **Bragantia** 4:1011-1018.

Oliveira SV, Waquil PD (2017) Dinâmica de produção e comercialização da erva-mate no Rio Grande do Sul, Brasil. **Ciência Rural** 45: 750-756.

Oliveira YMM, Rotta E (1983) Área de Distribuição natural da erva-mate. In: Seminário Sobre Atualidades e Perspectivas Florestais. **Anais...** Curitiba: **EMBRAPA/Cnpflorestas**,10: 17-36.

Ozaki V (2008) Análise espacial da produtividade agrícola no Estado do Paraná: implicações para o seguro agrícola. **Revista de Economia e Sociologia Rural** 46:869-886.

Pagani V, Guarneri T, Fumagalli D, Movedi E, Testi L, Klein T, Calanca P, Villalobos F, Bernal AL, Niemeyer S, Bellocchi G, Confalonieri (2017) Improving cereal yilde forecast in Europe – The impact of weather extremes. **European Journal of Agronomy** 89:97-106.

Pandolfo CM, Floss PA, Croce MD, Dittrich RC (2007). Resposta da erva-mate (*ilex paraguariensis* st. Hil.) À adubação mineral e Orgânica em um latossolo vermelho aluminoférrico. **Ciência Floresta** 13:37-45.

Peralta J M., & Schmalko M E (2007) Modeling heat and mass transfer in the heat treatment step of yerba maté processing. **Brazilian Journal of Chemical Engineering**, *24*: 71-82.

Pires, EZ, Stedille LIB, Machado S, Mantovani A, Bortoluzzi RLC (2014) Biologia reprodutiva de erva-mate (*Ilex paraguariensis* A. St. Hil) em remanescentes de Floresta Ombrófila Mista Altomontana. **Journal of Agroveterinay Sciences** 13:171-180.

Rakocevic M, Martim SF(2011) Time series in analysis of yerba-mate biennial growth modified by environment. **International Journal Biometeorology** 55:161–171.

Rakocevic M, Medrado MJS, Lucambio F, Valduga AT (2008) Intensity of bitterness of processed yerba-mate leaves originated in two contrasted light environments. **Brazilian Archives of Buology and Technology** 51: 569–579.

Rao DE, Chaitanya KV (2019) Morphological and Physiological Responses of Seven Different Soybean (Glycine Max L. Merr.) Cultivars to Drought Stress. **Journal of Crop Science and Biotechnology** 22: 355-362.

Rolim GDS, Novo MCSS, Pantano AP, Trani PE (2011) Modelagem agrometeorologica para estimação do desenvolvimento e da produção de jilo. **Revista Brasileira de Engenharia Agrícola e Ambiental** 8:832–837.

Rosa VGC, Moreira MA, Rudorff BFT, Adami M (2010) Estimativa da produtividade de café com base em um modelo agrometeorologico-espectral. **Pesquisa Agropecuária Brasileira** 45:1478-1488.

Ross S, Arriaga ME, Pechi E (2017) Establecimiento in vitro de Yerba mate (*Ilex paraguariensis* A. St.-Hil.) nativa de Uruguay. **Agrociencia Uruguay** 21:15-23.

Sá FP, Portes DC, Wendling I, Zufferellato-Ribas KC (2018). Ministaquia de erva-mate em quatro épocas do ano. **Ciência Florestal** 28:1431-1442.

Santin D, Benedetti EL, Barros NF, Almeida IC, Simiqueli GF, Neves JCL, Wendling I, Reissmann CB (2019) Adubação nitrogenada e intervalos de colheita na produtividade e nutrição da erva-mate e em frações de carbono e nitrogênio do solo. **Ciência Florestal** 29:1199.

Santin D, Benedetti EL, de Barros NF, de Almeida IC, Wendling I (2017) Intervalos de colheita e adubação potássica influenciam a produtividade da erva-mate (*Ilex paraguariensis*) no Estado do Paraná. **Floresta** 46:509-518.

Santos A O & Prado H (2002) Análise de interações solo-planta-clima em zonas diferenciadas de área de cultivo de milho. **Revista Brasileira de Engenharia Agrícola e Ambiental,** *6*101-106.

Silva LL, da Costa RF, Campos JHB DC, Dantas RT (2009) Influence of precipitations on agricultural productivity in Paraíba State. **Revista Brasileira Engenharia Agricola e Ambiental** 13:454-461.

Sousa VA, Aguiar AV, Spoladore J (2015). Metodologia para a polinização controlada em *Ilex paraguariensis* A. St. Hil. - Aquifoliaceae. **Revista Árvore,** *39*:315-323.

Toumi J, Er-rakI S, Ezzahar J, Khabba S, Jarlan LC (2016) Avaliação do desempenho do modelo AquaCrop para estimativa da evapotranspiração, teor de água no solo e rendimento de grãos do trigo de inverno em Tensift Al Haouz (Marrocos): aplicação ao manejo da irrigação. **Agricultural Water Management** 163:219-235.

Vieira ARR. Influência do microclima de um sistema agroflorestal na cultura da erva-mate (*Ilex paraguariensis* St. Hil) (2003) **Revista Brasileira de Agrometeorologia.** 11:91–97.

Vogel HLM, Schumacher M V, Trüby, P (2006) Quantificação da biomassa em uma floresta estacional decidual em Itaara, RS, Brasil. **Ciência Florestal,** Santa Maria, 3: 419-425.

Vuaden E, Fleig FD, Selle GL, Lana MD, Silva GF, Vargas JF (2009) Estimativa da biomassa comercial de brotos de *Ilex paraguariensis* A.St.-Hil. **Ciência Florestal** *19*:279-291.

Wendling I, Brondani GE, Biassio AD, Leonardo F (2013) Vegetative propagation of adult *Ilex paraguariensis* trees through epicormic shoots. **Acta Scientiarum Agronomy** 35:117-125.

CAPÍTULO 2 - Modelagem agrometeorológica para estimação de produtividade de erva-Mate (*Ilex paraguariensis* St. Hil.) na região Sul do Brasil

RESUMO – O uso de modelagem agrometeorológica é uma importante ferramenta para quantificar o efeito do clima sob o crescimento e desenvolvimento das plantas e consequentemente estimar produtividade dos cultivos. Este estudo teve como objetivo modelagem agrometeorológica para a estimação de produtividade para erva-mate nos estados do Paraná, Santa Catarina e Rio Grande do Sul. Foram testados modelo de regressão linear múltipla (RLM), usando variáveis selecionadas por stepwise e métodos de aprendizado de máquina com random forest regressor (RF) e redes neurais do tipo multilayer perceptron (MLP). As variáveis agrometeorológicas decendias utilizadas para testar os modelos foram temperatura do ar, precipitação, evapotranspiração potencial, evapotranspiração real, armazenamento de água no solo, déficit hídrico e excedente hídrico de uma série histórica de 1989-2017 para um total de 38 localidades. O modelo geral de RLM apresentou precisão (R^2) de 0,062. Entretanto, os modelos de machine learning RF e MLP apresentaram melhor desempenho com RMSE de 0,40 kg ha^{-1} e 0,47 kg ha^{-1}, respectivamente R^2 de 0,83 e 0,77. Os modelos agrometerológicos de machine learning foram eficientes para estimação de produtividade da erva-mate. Os modelos agrometeorológicos podem ser utilizados para estimação e previsões de produtividades, pois permitem ao setor agrícola reduzir riscos na produção e aumentar rentabilidade dos cultivos. Os modelos são importantes para órgãos públicos, afim de estimar produtividades de erva-mate em três estados do Brasil.

Palavras-chave: agrometeorologia, clima, modelos, modelagem, produtividade

AGROMETEOROLOGICAL MODELING FOR YERBA-MATE PRODUCTIVITY ESTIMATION (*Ilex paraguariensis* ST. HIL.) IN SOUTHERN BRAZIL

ABSTRACT - The use of agrometeorological modeling is an important tool to quantify the effect of climate on plant growth and development and consequently to estimate crop productivity. This study aimed at agrometeorological modeling to estimate the productivity of yerba mate in the states of Paraná, Santa Catarina and Rio Grande do Sul. Multiple linear regression model (RLM) were tested, using variables selected by stepwise and methods of learning machine with random forest regressor (RF) and multilayer perceptron neural networks (MLP). The variable agrometeorological decendial used to test the models were air temperature, precipitation, potential evapotranspiration, real evapotranspiration, water storage in the soil, water deficit and water surplus in a historical series from 1989-2017 for a total of 38 locations. The general RLM model showed an accuracy (R^2) of 0.062. However, the machine learning RF and MLP models performed better with RMSE of 0.40 kg ha-1 and 0.47 kg ha-1, respectively R^2 of 0.83 and 0.77. The agrometerological models of machine learning were efficient for estimating the productivity of yerba mate. Agrometeorological models can be used to estimate and forecast yields, as they allow the agricultural sector to reduce risks in production and increase profitability of crops. The models are important for public agencies in order to estimate yerba mate productivity in three states in Brazil.

Keywords: agrometeorology, climate, models, modeling, productivity

2.1 Introdução

A erva-mate (*Ilex paraguariensis* St. Hil.), é uma espécie arbórea encontrada naturalmente na Argentina, Brasil, Paraguai (Wendling et al., 2013). O cultivo da erva-mate compreende um dos sistemas agroflorestais mais antigos e característicos da Região Sul do Brasil, ostentando significativa importância socioeconômica e ambiental, considerada parte da identidade cultural da região (Oliveira & Waquil, 2015). No Brasil a erva-mate é consumida na forma de chimarrão e chá, na Califórnia é encontrado nos supermercados na forma de bebida energética e na Europa é vendido em combinação com outras ervas como chá energético ou como auxiliar de redução de peso (Bracesco, et al., 2011).

Em termos mundiais a Argentina é o maior exportador de erva-mate (Oliveira & Waquil, 2015) e o Uruguai o maior consumidor, consumindo de 6 a 8 kg pessoa^{-1} ano^{-1} (Bracesco et al., 2011). No Brasil é cultivada principalmente nos estados do Rio Grande do Sul, Santa Catarina e Paraná ocupando uma área de 77.713 ha, produzindo cerca de 546.618 toneladas de folhas verdes, o que resulta em uma produtividade média de 7.033 ton ha^{-1} (IBGE, 2018). O Rio Grande do Sul destaca-se como o maior produtor nacional de folha verde de erva-mate com uma produção média de 232.971 ton ano^{-1}, seguido do Paraná com 214.309 ton ano^{-1} e Santa Catarina com 98.045 ton ano^{-1} (IBGE, 2018).

A agricultura, entre todas as atividades econômicas, é a que apresenta maior dependência das condições meteorológicas, sendo as principais responsáveis pelas oscilações e frustrações das safras agrícolas (Moreto et al., 2018; Rolim et al., 2007). O cultivo de erva-mate assim como outros cultivos está fortemente relacionada às condições de manejo e ambiente. A produtividade de erva-mate é fortemente afetada pela temperatura do ar, radiação solar e déficit hídrico (Mazuchowski et al., 2003) esses fatores determinam a produtividade e a qualidade da erva produzida.

A temperatura do ar é um elemento meteorológico fundamental para o crescimento e desenvolvimento das plantas, condicionando a duração das fases fenológicas e do ciclo das culturas (Bardin et al., 2010). É uma das variáveis independentes mais utilizadas em modelos agrometeorológica, tanto pela facilidade de obtenção quanto pela sua relação com a quantidade de radiação fotossinteticamente ativa necessária para a planta completar o seu ciclo (Assis et al.,

2006). O cultivo de erva-mate ocorre em locais onde a temperatura média anual do ar situa-se entre 12 °C e 24 ºC (Vieira et al., 2003).

A radiação solar é o elemento que desencadeia o processo fotossintético que determina o crescimento das plantas (Caron et al., 2014). A radiação fotossinteticamente ativa interceptada por um cultivo é convertida em fitomassa em taxas descritas pela eficiência do uso da radiação (EUR).

A erva-mate adapta-se à sombra em qualquer idade, tolerando plena exposição à radiação solar e ao frio na fase adulta. Em estudo avaliando a EUR, Caron et al. (2014) encontrou eficiência de conversão de fitomassa seca aérea de plantas de *Ilex paraguariensis* em relação à quantidade de radiação solar fotossinteticamente ativa interceptada acumulada de 0,83 g MJ^{-1} no sistema consórcio e de 0,23 g MJ^{-1} no sistema solteiro.

O déficit hídrico (DEF) é considerado fator limitante para o crescimento e desenvolvimento das plantas. O DEF afeta a evapotranspiração, a extração da água no solo pelas raízes, a distribuição do sistema radicular, o tamanho do dossel, as taxas de desenvolvimento dos cultivos, e por fim, a produtividade (Feng et al., 2019; Aparecido et al., 2019).

As necessidades hídricas das culturas agrícolas precisam ser supridas nos diversos estádios fenológicos, desde a germinação e estabelecimento da cultura, passando pelo desenvolvimento, floração, formação e crescimento dos grãos ou frutos, até atingir a maturação e a colheita (Silva et al., 2009). Na erva-mate o déficit hídrico pode afetar o crescimento e desenvolvimento como, por exemplo número de folhas e altura do caule.

Uma forma de quantificar os efeitos das condições climáticas no desenvolvimento e produtividade dos cultivos é através do uso da modelagem (Jones et al., 2017). Com a utilização dos modelos agrometeorológicos consegue-se conhecer previamente as safras agrícolas, através de estimação e previsões, sendo considerada uma questão estratégica no momento do planejamento (Martins et al., 2014; Zhao et al., 2019).

A modelagem é uma ferramenta científica baseada na representação simplificada de um sistema que, na maioria dos casos, pode ser composta por um conjunto de símbolos e relações matemáticas logicamente ordenadas com um objetivo específico (Corrêa et al., 2011). Existem diversas classificações de tipos de modelos. Uma dessas formas de classificação é a separação de modelos mecanísticos, estatísticos e de inteligência artificial (Acock e Acock, 1991).

Os modelos mecanísticos são aqueles que procuram simular um sistema buscando o entendimento das causas e efeitos de vários processos ou fenômenos que compõem um problema (Dourado-Neto et al., 1998). Como exemplos de modelos mecanísticos pode-se citar o AQUACRO (Steduto e Hsiao, 2019; Toumi, et al., 2016, Jiang et al., 2019), o DSSAT (Hoogenboom et al., 2019; Jones et al., 2003), APSIM (Holzworth et al., 2014, Chimonyo et al., 2016, Keating et al., 2003), entre outros. Esses modelos têm com características serem descritivo dos fenômenos por isso utilizam muitos parâmetros, dificultando sua aplicação em áreas sem os dados iniciais.

Os modelos estatísticos são baseados em análises de regressão simples ou múltiplas, além de outras análises multivariadas, são essencialmente práticos e visam estimar o desenvolvimento dos cultivos (Passioura, 1973).

Os modelos de inteligência artificial (IA) são modelos matemáticos/ estatísticos, entretanto, o próprio algoritmo, por métodos heurísticos, aprende a estimar ou prever uma variável de interesse, cabendo ao pesquisador escolher quais variáveis de entrada devem ser escolhidas (Zeron e Serrano Júnior, 2019).

A forma mais comum de trabalhar com inteligência artificial é por meio de modelos de machine learning (ML) com redes neurais artificiais (RNA) e modelos de random forest (RF) que atualmente estão sendo utilizadas em diversos estudos (Bocco, M., 2010; King 2017; Gopal, 2019).

As redes neurais artificiais (RNAs) são amplamente aplicadas em pesquisas devido à sua capacidade de modelar sistemas altamente não-lineares nos quais as relações entre variáveis são desconhecidas ou muito complexas (Russel & Norviq, 2009). Na ciência agronômica as RNAs podem ser utilizadas para obtenção de modelos para fins de estimação de severidade e identificação de pragas e doenças,

otimizaçao de recursos econômicos, auxílio em tomadas de decisão, determinação de preços, otimização de rotas/logística, otimização de datas de semeadura, produtividade, entre outros (Tavares et al., 2018; Meier et al., 2018; Guimarães et al., 2015; Alves et al., 2018).

O randon forest é um modelo robusto, muito utilizado, devido sua capacidade de evitar problemas de overfitting (Woznicki et al., 2019). É um meta-estimador que ajusta várias árvores de decisão em várias subamostras do conjunto de dados escolhendo a árvore com maior acurácia (Janitza; Tutz; Boulesteix, 2016).

O random forest regressor também é utilizado para investigar os mesmos problemas agrícolas já citados para RNA (Everingham et al., 2016; Feng et al., 2019), sendo considerado um método em geral mais preciso do que as análises de regressão (Wang et al., 2016).

A modelagem agrometeorológica pode ser enquadrada em todas essas classes de modelos, sendo uma importante ferramenta para quantificar o efeito do clima no crescimento e desenvolvimento dos cultivos e, consequentemente, estimação ou previsão da produtividade (Silva-Fuzzo et al.,2015; Rolim et al., 2011; Klering et al., 2008).

Estimação é a quantificação de um evento atual a partir de dados atuais. Metodologias de estimação antecipada podem ser utilizadas para melhorarias de sistemas de alerta precoce para segurança alimentar, mitigar o impacto da escassez de alimentos, além de ajudar na elaboração de planejamento estratégico para atender às demandas de alimentos (Leroux et al., 2019).

Os resultados das estimativas de produtividades podem ser utilizadas por órgãos públicos, instituições de assistência técnica para estimativas e previsões de safra para diversos cultivos (Victorino et al., 2016). Podem ainda ajudar a fornecer aos gerentes de terras e formuladores de políticas públicas, ferramentas para extrapolar resultados experimentais para locais onde existem falta de informações (Basso et al., 2013). Temos como, por exemplo, o principal órgão de financiamento para cultivo da cana de açúcar na Austrália (Sugar Research Australia) tem investido nessa área de

pesquisa (Everingham et al., 2016). Entretanto, até o momento nenhum modelo agrometeorológico foi encontrado para estimação de produtividade da erva-mate.

Devido à importância econômica e cultural do cultivo da erva-mate, este estudo teve como objetivo desenvolver modelos agrometeorológicos para a estimação de produtividade para erva-mate nos estados do Paraná, Santa Catarina e Rio Grande do Sul.

2.2 Material e Métodos

2.2.1 Localização e seleção das áreas de estudo

A área de estudo compreende uma região de ocorrência natural de erva-mate abrangendo os Estados do Paraná, Santa Catarina, Rio Grande do Sul (Figura 1).

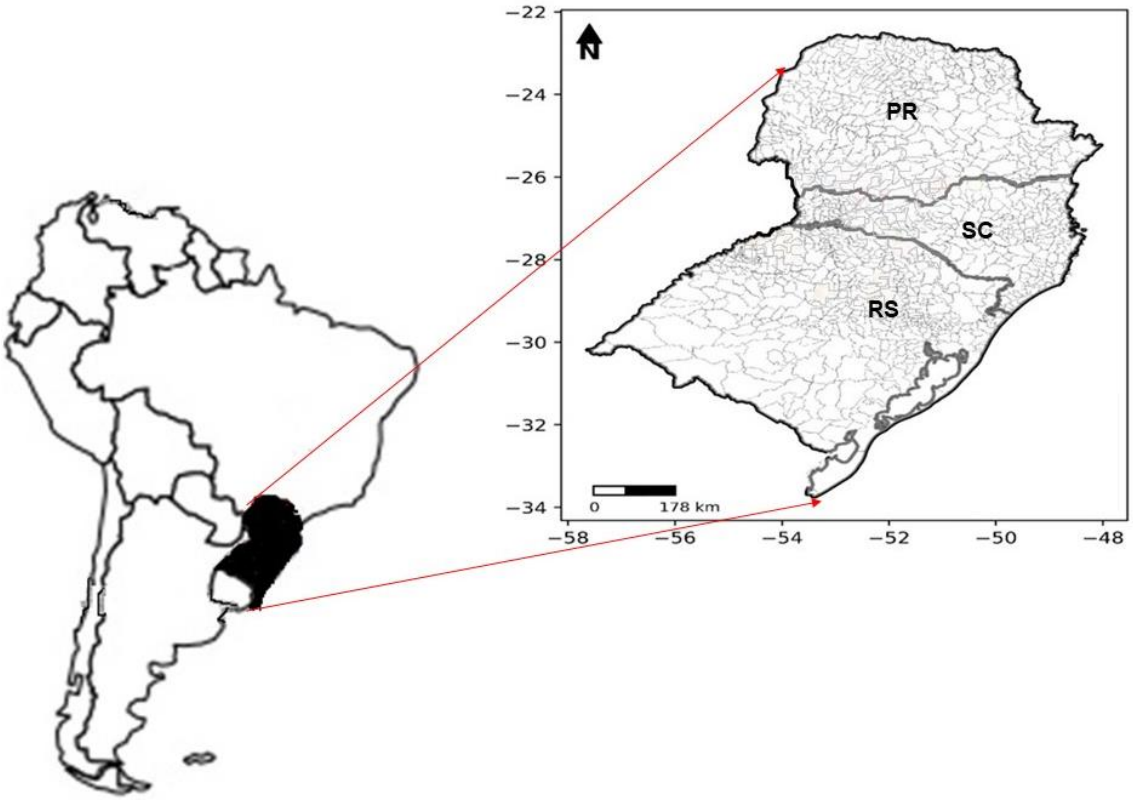

Figura 1. Principais regiões produtoras de erva-mate,no Sul do Brasil: Paraná (PR), Santa Catarina (SC) e Rio Grande do Sul (RS).

Foi utilizado uma série histórica de 28 anos com dados climáticos e de produtividade de 38 localidades do Sul do Brasil nos estados do Paraná, Santa Catarina e Rio Grande do Sul, principais produtores de erva-mate do Brasil, correspondendo a um período de 1989 a 2017 (Tabela 1).

Tabela 1. Locais, coordenadas geográficas e altitudes, Paraná, Santa Catarina, Rio Grande do Sul.

Locais	Latitude(Sul)	Longitude(Oeste)	Altitude(m)
Paraná			
Barracão	26º25’26”	53º63’05”	705
Bituruna	26º16’08”	51º55’65”	990
Dois Vizinhos	25º74’06”	53º05’48”	533
Francisco Beltrão	26º07’85”	53º05’61”	662
General Carneiro	26º42’58”	51º31’69”	912
Itapejara d' Oeste	25º97’09”	52º81’39”	563
Mangueirinha	25º94’03”	52º17’63”	892
Mariópolis	26º35’58”	52º55’77”	828
Marmeleiro	26º14’87”	53º02’62”	758
Palmas	26º48’15”	51º98’88”	1080
Pato Branco	26º23’00”	52º67’74”	718
Paula Freitas	26º22’01”	50º93’47”	796
Pranchita	26º01’57”	53º74’26”	507
Renascença	26º15’62”	52º97’22”	707
União da Vitória	26º22’84”	51º09’06”	915
Rio Grande do Sul			
Anta Gorda	28º97’09”	52º01’58”	452
Arvorezinha	28º87’03”	52º17’95”	612
Fontoura Xavier	28º98’22”	52º34’5”	592
Fortaleza dos Valos	28º78’79”	53º23’55”	367
Humaitá	27º56’15”	53º97’65”	447
Ilópolis	28º92’92”	5212’22”	658
Paim Filho	27º70’33”	51º76’16”	627
Três Passos	27º45’62”	53º92’97”	363
Santo Augusto	27º85’35”	53º77’88”	488
Santo Cristo	27º81’99”	54º66’87”	253
Três de Maio	27º77’97”	54º23’53”	275

Putinga	28º99’88”	52º15’99”	518
Tucunduva	27º65’01”	54º43’31”	222
Tuparendi	27º75’41”	54º47’85”	225
Vila Maria	28º53’33”	52º16’35”	505
Santa Catarina			
Canoinhas	26º17’88”	50º39’78”	831
Ipira	27º40’97”	51º77’09”	582
Ipumirim	27º06’83”	52º14’05”	751
Lindóia do Sul	27º04’75”	52º08’09”	800
Itá	27º28’18”	52º32’92”	429
Peritiba	27º37’73”	51º90’98”	588
Piratuba	27º41’06”	51º75’86”	539
Ponte Serrada	26º87’49”	52º01’45”	1021

2.2.2 Dados Meteorológicos

Os dados climáticos diários das localidades foram obtidos na plataforma NASA POWER coletados automaticamente por script utilizando a linguagem de programação Python com uso de API disponibilizado pela NASA conforme recomendação de Stackhouse et al. (2017). Foram coletados dados de temperatura do ar (T, ºC) e precipitação (P, mm dia $^{-1}$), esses dados foram organizados na escala decendial para o cálculo de evapotranspiração potencial de referência (ETP) determinado através da equação de Penman-Monteith (Allen et al., 1998).

2.2.3 Balanço Hídrico

Para cálculo de balanço hídrico segundo Thornthwaite & Mather (1955), foram utilizados os dados de ETP, a capacidade de água disponível foi de 100 mm. Determinou-se então os componentes do balanço hídrico: armazenamento de água no solo (ARM), evapotranspiração real (ETR), deficiência hídrica (DEF), excedente hídrico (EXC).

Para representar a fenologia da erva-mate os cálculos foram realizados em escala decendial.

2.2.4 Análise de dados

Os dados de produtividades anuais para cada local foram obtidos na plataforma IBGE no sistema de Recuperação Automática-SIDRA (IBGE, 2019). Para realizar a RLM o banco de dados foi dividido em 80% dos anos para treinamento e 20% para teste.

Para o entendimento da dispersão espacial da produtividade nos estados do Paraná, Santa Catarina e Rio Grande do Sul foi feita uma análise de agrupamento utilizando cluster hierárquico aglomerativo (AHC) e o método Ward (Ward, 1963) para minimizar a perda associada a cada grupo.

O AHC é um algoritmo de aprendizado de máquina não supervisionado, foi usado para agrupar pontos de dados não rotulados com características semelhantes. Nesse método os pontos de dados foram agrupados usando uma abordagem de baixo para cima (bottom-up). Para formação do dendograma cada ponto de dado é tratado como um cluster, depois formam-se clusters juntando dois pontos de dados mais próximos, forma-se mais clusters juntando aos dois clusters mais próximos seguindo-se dessa forma o processo repete-se até que um grande cluster seja formado e o dendograma possa ser formado (Murtagh, 1983).

Após a análise de cluster para identificar os locais com produtividades similares foi feita estatística descritiva por meio de box plot para cada grupo determinado pelo cluster, apresentando a variabilidade de T, P, ETP, ARM, DEF e EXC.

Para a modelagem de produtividade de erva-mate foram utilizados modelos de regressão linear múltipla (RLM), e modelos de inteligência artificial como o Random Forest Regressor (RF) e Redes Neurais Multilayer perceptron (MLP). Sendo sempre as variáveis independentes (ou features) os elementos meteorológicos decendiais durante o ciclo do cultivo: T, P e ETP, e os derivados do balanço hídrico: ARM, ETR, DEF e EXC.

As variáveis independentes foram coletadas entre o sétimo decêndio do ano anterior, correspondendo ao início do período vegetativo, ao trigésimo sexto decêndio do ano de colheita, correspondendo ao final da colheita, totalizando 65 decêndios com um total de 455 variáveis (7 elementos meteorológicos X 65 decêndios) (Figura 2).

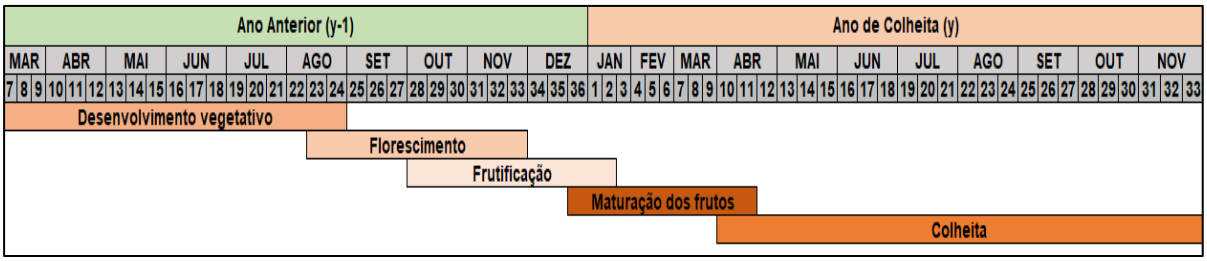

Figura 2. Fenologia típica da erva-mate em decêndios das regiões produtivas dos estados do Paraná, Santa Catarina e Rio Grande do Sul. Legenda y-1= Ano anterior, y= Ano de colheita, os números correspondem aos decêndios.

A seleção de variáveis independentes para treinar o modelo de RLM para estimação de produtividade significativos foi realizada utilizando o método stepwise forward (Moreto et al., 2018). O método consiste em selecionar quais variáveis mais influenciam o conjunto de saída (Produtividade) podendo assim diminuir o número de variáveis a compor a equação de regressão (equação 1).

$$Y = a \times X_1 + b \times X_2 + c \times X_3 + \cdots + CL \quad (1)$$

na qual, Y é produtividade t ha^{-1}, $a, b, c, \ldots$, são os coeficientes de cada variável explicativa do modelo. X_1, X_2, X_3, ..., são as variáveis meteorológicas selecionadas no período do ciclo do cultivo (Figura 1) e *CL* é o coeficiente linear.

Para os modelos de inteligência artificial, foram utilizados os métodos de aprendizagem de máquina com Random Forest Regressor (RF) e Multilayer perceptron (MLP). Os algoritmos foram programados na linguagem de programação Python 3.7 usando as bibliotecas de computação científica scipy, numpy e scikit-learn para os algoritmos de regressão e as abordagens de validação cruzada.

O modelo Random Forest Regressor foi escolhido por sua facilidade de implementação e apresentar maior acurácia em relação a outros métodos de regressão (Wang et al., 2016). O modelo RF mostra algumas vantagens em relação à maioria dos métodos estatísticos de modelagem, como, habilidade para a modelagem de relações dimensionais altamente não lineares, utilização de variáveis categóricas e contínuas, resistência ao overfitting, relativa robustez ante a presença de “ruídos” nos dados, fornecimento de uma medida imparcial da taxa de erro, determinação da importância das variáveis utilizadas, e a exigência de poucos parâmetros para ser implementado (Breiman, 2001; Liaw e Wiener, 2002).

O RF é limitado a interpretação dos resultados, já que as relações entre os preditores e as respostas não podem ser examinadas individualmente, para cada árvore na floresta (Grimm et al., 2008; Bhering et al.,2016).

O algoritmo baseado em RF ajusta várias árvores de decisão a partir de várias subamostras do conjunto de dados e usa uma árvore média para melhorar a precisão preditiva e controlar o ajuste excessivo (Breiman,2001).

Ajustou-se os parâmetros 'max depth' que compreende a profundidade máxima da árvore na floresta, quanto mais profunda, mais divisões ela tem, foi usado 'max depth' de 20. O 'n-estimators' que representa o número de árvores na floresta, no caso igual a 80, quanto maior o número de árvores que compõem a floresta, melhores serão os resultados, porém o tempo de execução do ajuste torna-se maior.

A MLP é uma rede neural multicamadas de aprendizado supervisionado para alimentação conectada com funções de ativação que quando treinada minimiza um erro quadrático (Bocco, 2010). Apresenta três características que a distingue das demais: cada neurônio da rede apresenta uma função de ativação não linear; a rede contém uma ou mais camadas ocultas, que são diferentes da camada de entrada e de saída. Os neurônios dessas camadas ocultas são responsáveis pela capacidade de aprendizagem de problemas complexos e existe um alto grau de conectivade entre os neurônios. Isso significa que um neurônio de qualquer camada da rede está conectado a todos os neurônios da camada anterior (Haykin, 2008).

A rede neural artificial MLP foi treinada com quatro camada ocultas, considerando cinco neurônios cada uma. A função de ativação considerada para a camada oculta foi a tangente hiperbólica.

As entradas da rede (variáveis independentes ou features) foram dados de T, P, ETR, DEF, ARM e EXC decendiais durante o ciclo do cultivo para estimação de produtividade (variável dependente ou target). O treinamento do MLP utilizou uma técnica de aprendizado supervisionado com um algoritmo de treinamento de backpropagation multicamadas. Uma MLP com *N* camadas, *H* neurônios ocultos e um neurônio de saída (equação 2).

$$y = S_k \left(\Sigma_{h=1}^{H} O_h \, W_h \, W_o \right) \quad (2)$$

em que y = a saída; O_h = valor de saída do neurônio oculto (equação 3); W_h são os pesos sinápticos entre os neurônios ocultos do RNA, e *Wo* são os valores iniciais do algorítmo de formação de RNA.

$$O_h = S_K\,(\Sigma_{h=1}^{H}\, X_n\, W_{nh}\, W_{oh}\,) \tag{3}$$

sendo, *Xn* são a entrada do RNA; W_{nh} são os pesos sinápticos entre os neurônios de saída, e W_{oh} são os valores iniciais do algorítmo de treinamento de RNA.

A função tangente hiperbólica foi usada para ativar os neurônios (equação 4):

$$f(x) = \frac{e^{px} - e^{-px}}{e^{px} + e^{-px}} = \tanh(px) \tag{4}$$

Os dados foram padronizados para reduzir as disparidades entre os valores nominais das variáveis independentes e treinar os algoritmos (equação 5).

$$Z = \frac{X - \bar{X}}{S} \tag{5}$$

A padronização utilizada em que *Z* é o valor padronizado; *X*, a variável de entrada; $\bar{X}$, a média da amostra; e *S*, o desvio padrão amostral.

2.2.5 Avaliação dos modelos

Para a calibração da rede neural, utilizou-se no algoritmo o total de 455 variáveis meteorológicas. Como nossa base de dados é de tamanho reduzido utilizamos a validação cruzada para obter melhores estimativas de acurácia.

A validação dos modelos RF e MLP foi realizada por validação cruzada. A validação cruzada consiste em um dos métodos estatísticos utilizado para divisão dos dados entre conjunto de treinamento e teste. Este método consiste em particionar o conjunto de dados em subconjuntos mutuamente exclusivos, gerando assim um subconjunto para estimação dos parâmetros do modelo (dados de treinamento) e o restante dos subconjuntos (dados de teste) é empregado na validação do modelo. Essa técnica é utilizada quando o número de observações é pequeno (Witten e Eibe, 2005). A técnica consistiu em dividir a base de dados em 10 subconjunto de tamanhos equivalentes.

A construção do modelo foi realizada utilizando 9 dos 10 subconjuntos e validada no subconjunto restante, sendo esse processo repetido 10 vezes, onde em cada etapa um subconjunto diferente foi deixado de fora para validação e os demais foram utilizados para a construção do modelo. A acurácia final do modelo foi obtida pela média das acurácias de cada um dos modelos parciais. O método de validação cruzada foi aplicado por divisão de dados em 10 subconjuntos.

O desempenho dos modelos para estimação de novos dados foi feito usando as métricas de avaliação R^2 (equação 6), RMSE (equação 7) e Validação cruzada (CV_score).

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(Y_i - \hat{Y}_i)^2}{\sum_{i=1}^{N}(Y_i - \bar{Y}_i)^2} \tag{6}$$

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(Y_i - \hat{Y}_i)^2} \tag{7}$$

sendo, *N* é o tamanho total da amostra, Y_i é o valor estimado , $\hat{Y}_i$ é o valor observado e $\bar{Y}_i$ é o valor médio observado.

2.3 Resultados e Discussão

A análise de cluster mostrou as diferenças de produtividade de cada local através das distâncias de ligações que integram cada grupo. As linhas de corte identificaram no dendograma 4 grupos (Figura 3).

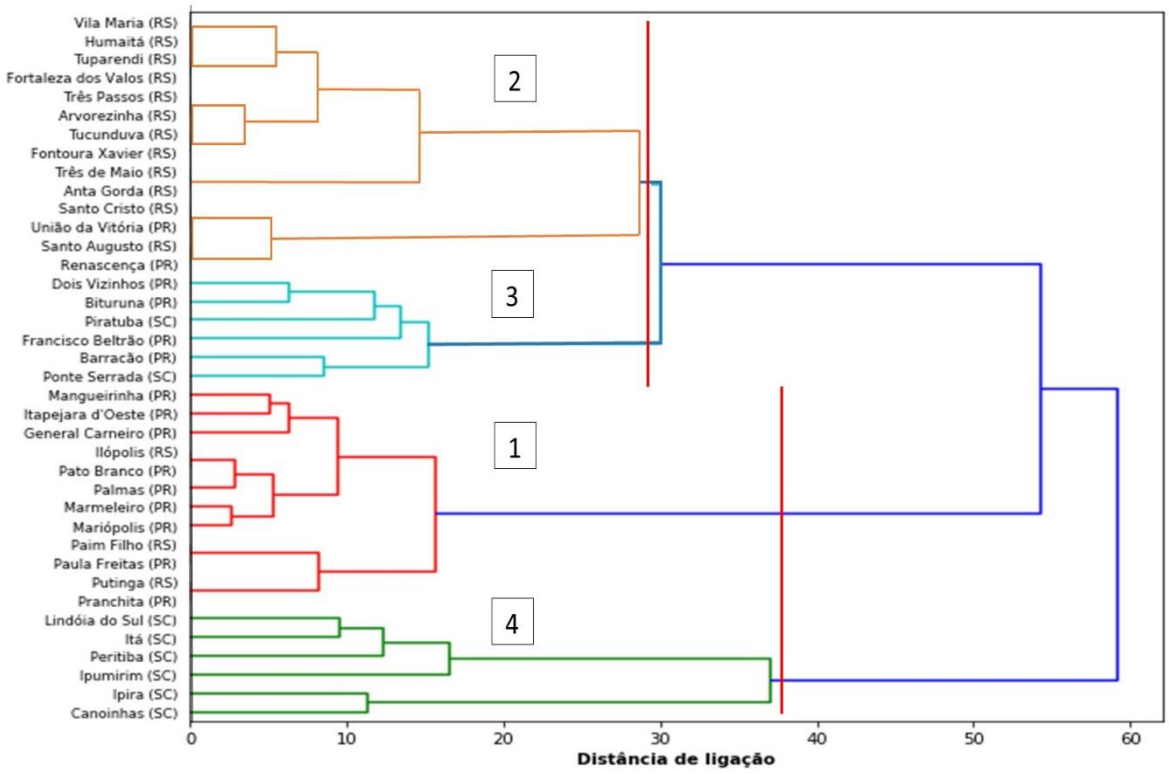

Figura 3. Dendograma de produtividades de erva-mate t ha^{-1}.

Foi construído um mapa para representar os grupos obtidos segundo a análise de agrupamento das produtividades (Figura 4).

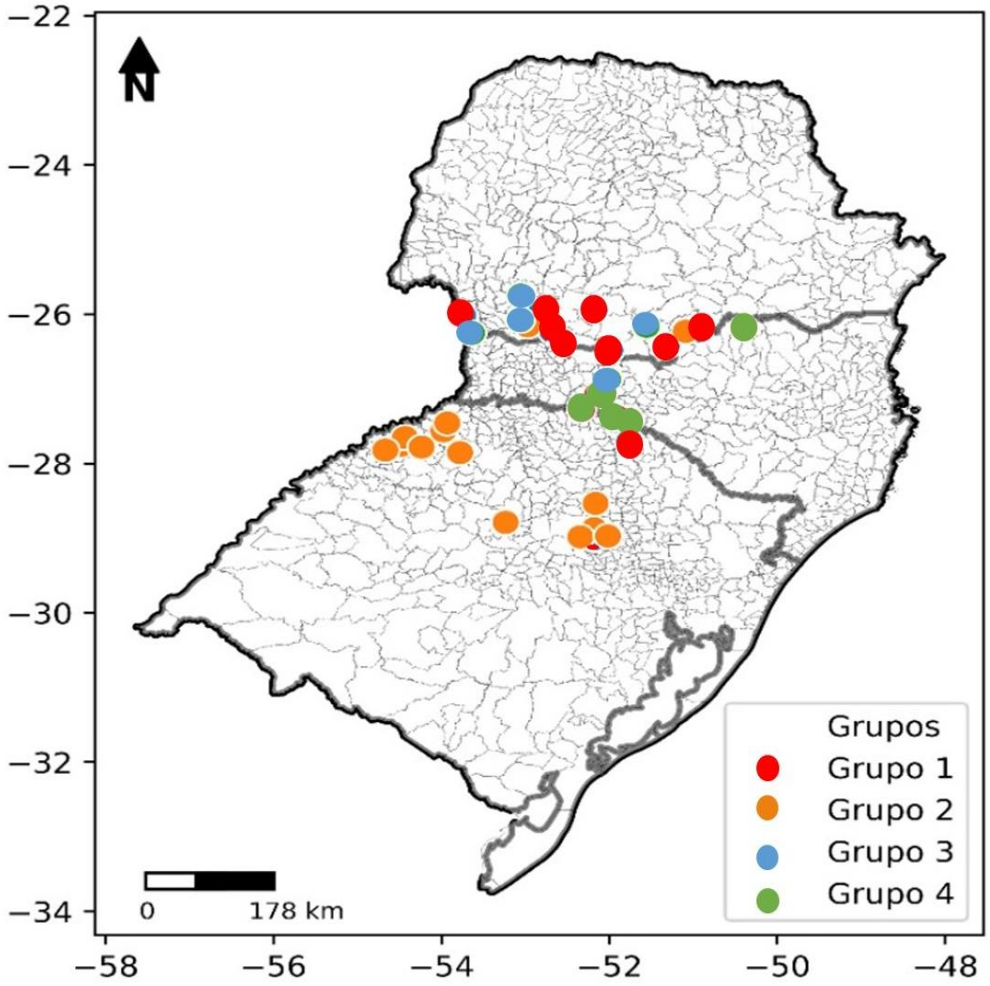

Figura 4. Mapa com base no índice de similaridade considerando a produtividade de erva-mate (t ha^{-1}) no Rio Grande do Sul, Santa Catarina e Paraná.

Segundo a análise de cluster podemos verificar que os grupos 1 e 3 se concentram no estado do Paraná, o grupo 2 no Rio Grande do Sul e o grupo 4 em Santa Catarina. A partir do cluster foi realizada a estatística descritiva do comportamento das variáveis climáticas, T, P, ETR, ARM, DEF, EXC para cada grupo.

Com as análises de box plot foi possível observar que os 4 grupos apresentaram temperaturas médias, máximas e minímas bem semelhantes (Figura 5. A). Os grupos foram muito semelhantes climaticamente com exceção para a DEF (Figura 4. E). O grupo com maior DEF foi o 2, seguido pelos grupos 3,4, e 1. Esses resultados estão de acordo com Alves et al., (2018) que afirma que a erva-mate é

adaptada para regiões com verão apresentando temperaturas mais amenas < 24 °C e inverno chuvoso > 100 mm o que promove maiores produtividades.

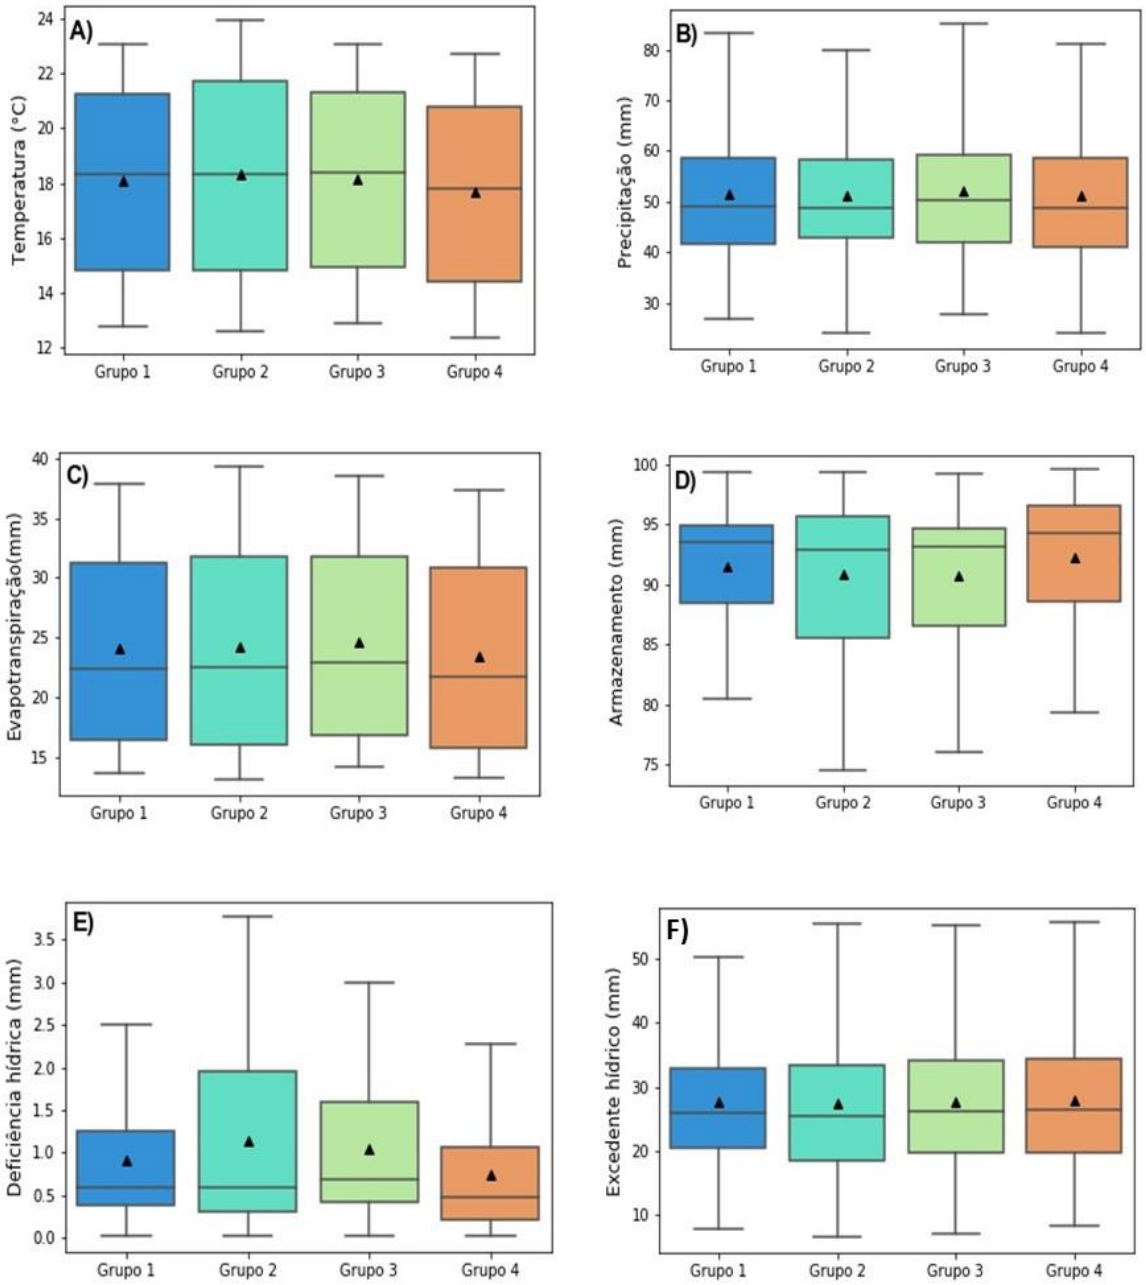

Figura 5. Box Plot para as variáveis T, P, ETR, ARM, DEF, EXC e produtividade nos grupos determinados pela análise de cluster.

A análise de correlação (Figura 6) indicou que as variáveis de maior peso no período de maior importância foram T e ARM de setembro a abril correspondendo aos

períodos de florescimento, frutificação e maturação dos frutos. O segundo período de maior importância corresponde ao início do período vegetativo.

O ARM é diretamente proporcional a produtividade, enquanto a T apresenta-se inversamente proporcional. O ETR apresenta-se inversamente proporcional no início e torna-se nula no meio do ciclo. A produtividade não é fortemente correlacionada ao DEF, nas regiões existe disponibilidade hídrica suficiente para o desenvolvimento do cultivo.

Figura 6. Correlações entre elementos meteorológicos e a fenologia da erva-mate.

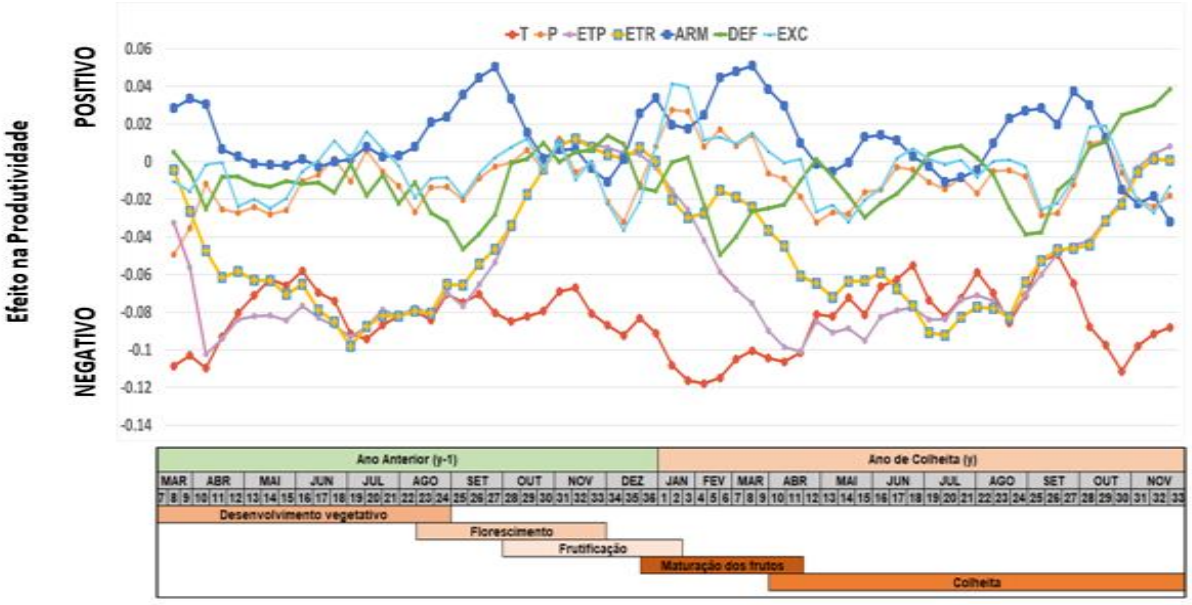

Para construção do modelo de Regressão Linear Múltipla fez-se a seleção das variáveis utilizando o método de stepwise e prosseguiu-se utilizando-se as variáveis pré-selecionadas.

As variáveis selecionadas por stepwise para a RLM que mais influenciaram a produtividade no ano anterior (y-1) foram T18, ETR9, T28 e EXC25 e no ano de colheita (y) foram T14, P33 e EXC 11. Todas as variáveis foram significativas, pois os *p- valores* ficaram entre 0.0032 e 0.0091.

Os modelos de Regressão Linear Múltipla (Tabela 2) apresentaram valores pouco significativos. De acordo com Sayes et al. (2015) valores de R^2 entre 0,50 e 0,65 indicam modelos pouco significativos enquanto que valores de R^2 de 0,66 a 0,80

indicam modelos aceitáveis; de 0,81 a 0,90 indicam modelos acurados, e por fim, valores maiores que 0,9 indicam excelentes modelos de estimação.

Tabela 2. Modelo de Regressão linear múltipla para os grupos 1,2,3,4 e grupo geral.

Grupos	Modelo	R^2
1	$Y = -0.3034 * T18_{(y-1)} - 0.0306 * ETR9_{(y-1)} - 0.1204 * T14_{(y)} - 0.0230 * EXC11_{(y)} - 0.0230 * P33_{(y)} - 0.0887 * T28_{(y-1)} - 0.0115 * EXC25_{(y-1)} + 14.3474$	0.042
2	$Y = -0.1372 * T18_{(y-1)} - 0.0054 * ETR9_{(y-1)} - 0.1703 * T14_{(y)} - 0.0092 * EXC11_{(y)} - 0.0048 * P33_{(y)} - 0.1633 * T28_{(y-1)} - 0.0057 * EXC25_{(y-1)} + 11.1563$	0.016
3	$Y = -0.2434 * T18_{(y-1)} - 0.0388 * ETR9_{(y-1)} - 0.2435 * T14_{(y)} - 0.0140 * EXC11_{(y)} - 0.0095 * P33_{(y)} - 0.1669 * T28_{(y-1)} - 0.0094 * EXC25_{(y-1)} + 14.1958$	0.311
4	$Y = -0.0763 * T18_{(y-1)} + 0.0763 * ETR9_{(y-1)} + 0.0372 * T14_{(y)} - 0.0002 * EXC11_{(y)} - 0.0025 * P33_{(y)} - 0.0492 * T28_{(y-1)} - 0.0001 * EXC25_{(y-1)} + (-0.1509)$	0.021
Geral	$Y = -0.2976 * T18_{(y-1)} - 0.0757 * ETR9_{(y-1)} - 0.1940 * T14_{(y)} - 0.0172 * EXC11_{(y)} - 0.0128 * P33_{(y)} - 0.1087 * T28_{(y-1)} - 0.0076 * EXC25_{(y-1)} + 15.9538$	0.062

Apesar da baixa acurácia dos modelos de RLM as variáveis selecionadas têm relação com os estádios fenológicos importantes para o cultivo. No ano anterior as variáveis T18 e ETR9 tiveram maior influência no período de desenvolvimento vegetativo, já que o crescimento das plantas depende do saldo de matéria seca acumulada pela fotossíntese (Caron et al., 2014). As variáveis T28 e EXC25

correspondem a outubro, fase de florescimento exigindo períodos de menores precipitações e temperaturas médias acima de 25 °C (Pires et al., 2014). As variáveis T14, P33 e EXC11 foram importantes no ano de colheita, fase que exige altas temperaturas, visto que as plantas são altamente afetadas por baixas temperaturas, baixas precipitações e baixo excedente hídrico.

O modelo de RLM desenvolvido não foi capaz de capturar a variabilidade dos dados para fazer estimações, dessa forma foi utilizado modelos de machine learning como random forest regressor e redes neurais do tipo multilayer perceptron para obter modelos mais acurados.

O modelo de RF apresentou para estimação de produtividade de erva-mate para os estados do sul do Brasil, acurácia RMSE=0,40 t ha^{-1}, precisão R^2=0.83 e CV-score correspondente ao R^2 de 0,54. Apresentou subestimação dos valores de produtividade em até 1,5 t ha^{-1}, o que indica que produtividades futuras podem ser menores que o previsto (Figura 7). Em seu estudo Wang et al. (2016), obtiveram estimativa de biomassa de trigo mais precisas usando o modelo RF se comparado ao modelo de redes neurais.

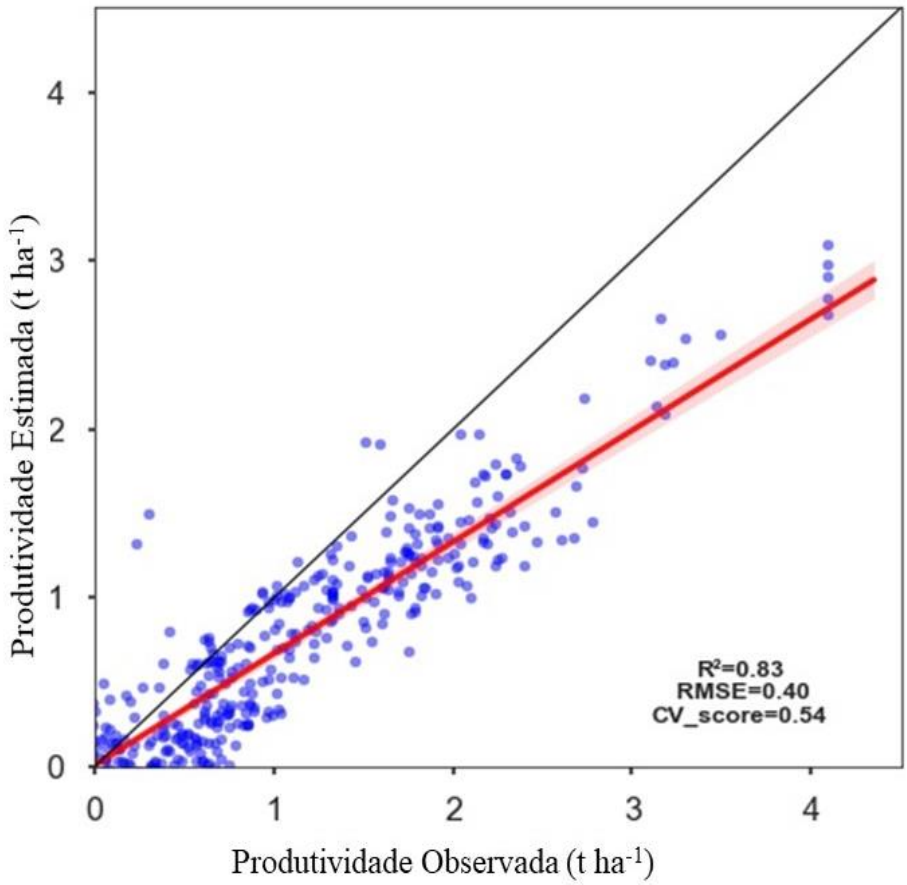

Figura 7. Dispersão entre os valores de produtividade estimados e observados do modelo Random Forest Regressor (RF).

A rede neural foi precisa nas estimativas apresentando, acurácia RMSE de 0,47 t ha^{-1} e precisão R^2 de 0,77 e CV-score de 0,99. Assim como o RF, também apresenta subestimação de valores superiores a 2,5 t ha^{-1} (Figura 8). Comparada ao modelo RF a MLP mostra desempenho inferior. Segundo Wang et al. (2016), isso se deve ao fato do modelo de rede neural ser aplicado com maior frequência a grandes quantidades de dados, enquanto o modelo de RF é mais adequado a pequenas quantidades de dados, Bocco et al. (2017), em seu estudo com modelos de redes neurais e regressões lineares obteve consideradas combinações alternativas de parâmetros meteorológicos.

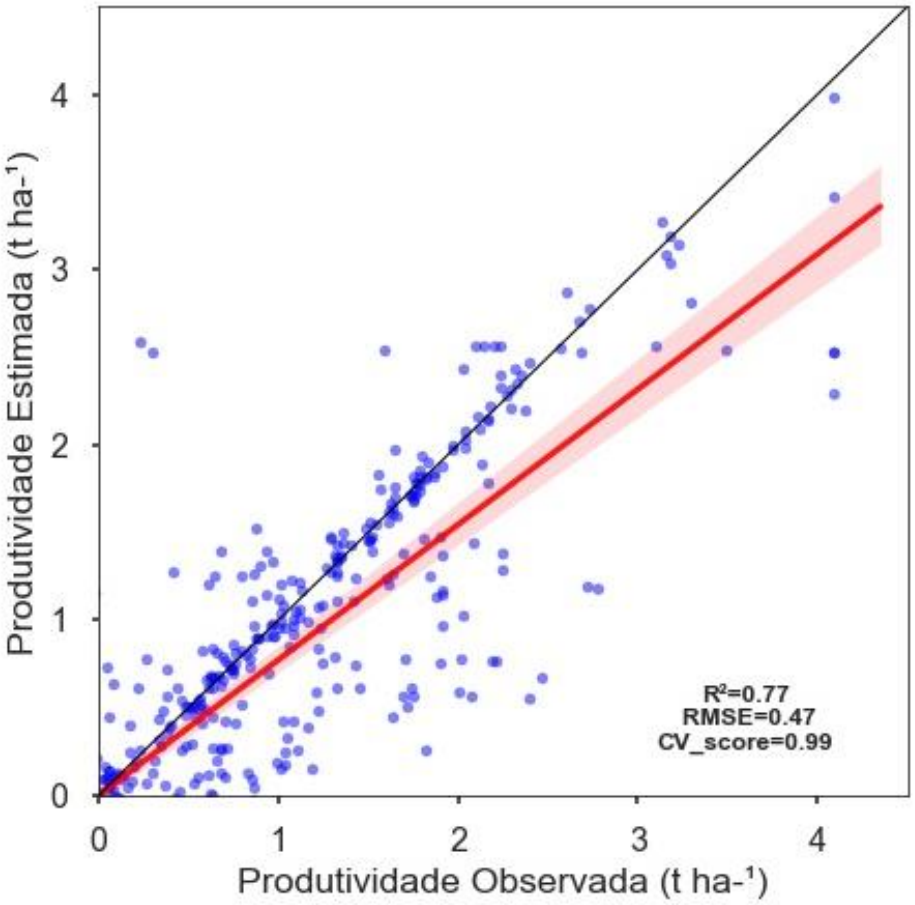

Figura 8. Dispersão entre os valores de produtividade estimados e observados do modelo de Redes Neurais –MLP.

Os modelos RF e MLP apresentaram alta precisão, tendência com valores subestimados para produtividade o que diminui a acurácia dos modelos. O MLP proporciona variabilidade maior, com uma dispersão maior dos dados o que causou diminuição do R^2 de 0,83 para 0,77 em relação ao modelo de RF (Tabela 3). O MLP apresenta menor precisão. Os modelos não fazem boa estimativa para produtividades acima de 2,5 t ha^{-1}.

Tabela 3. Comparação dos modelos de Regressão Linear Múltipla, Random Forest Regressor e Multilayer Perceptron.

MODELOS	R^2	RMSE	CV-SCORE
RLM	0.062	-	-
RF	0.83	0.40	0.54
MLP	0.77	0.47	0.99

Os modelos agrometeorológicos têm demonstrado que com uso das variáveis climáticas para estimação da produtividade dos cultivos, há redução nos riscos, tornando as atividades agrícolas mais rentáveis (Breiman, 2001). Os modelos agrometeorológicos utilizados para estimação e previsões de produtividades permitem ao setor agrícola reduzir riscos na produção e aumentar a produtividade dos cultivos. Os modelos são importantes para estimar produtividades de erva-mate em três estados do Brasil.

2.4 Conclusão

Os modelos de Machine Learning utilizados foram eficientes para estimativa de produtividade da erva-mate. O modelo Random Forest Regressor fornece estimativas mais precisas de produtividade em relação à Regressão Linear Múltipla e Multilayer Perceptron.

Referências

Acock B, Acock MC (19991) Potential for Using Long-Term Field Research Data to Develop and Validate Crop Simulators. **Agronomy Journal** 83:56-61.

Allen RG, Pereira LS, Raes D, Smith M (1998) Crop evapotranspiration - guidelines for computing crop water requirements – FAO - paper 56. Rome, 297p.

Alves GR, Teixeira IR, Melo FR, Souza, RTG, Silva, AG (2018). Estimating soybean yields with artificial neural networks. **Acta Scientiarum Agronomy**, 40:1-9.

Aparecido LEO (2016) **Produtividade e qualidade de bebida natural do cafeeiro**. 90f. Dissertação (Mestrado em Agronomia - Produção Vegetal) - Unesp, Jaboticabal.

Aparecido LEO, Reinaldo JC, Rolim GDS, Martotato LG, Meneses KC, Valeriano TTB (2016) Neural networks in climate spatialization and their application in the agricultural zoning of climate risk for sunflower in different sowing dates. **Archives of Agronomy and Soil Science**, 65: 1477-1492.

Assis JP, Dourado Neto D, Reichardt K, Manfron PA, Martin TM, Bonnecarrère RAG (2006) Dados climáticos simulados e produtividade potencial do milho. **Pesquisa Agropecuária Brasileira** 41:731-737.

Bardin L, Pedro Júnior MJ, Moraes JFL de (2010) Estimativa das temperaturas máximas e mínimas do ar para a região do Circuito das Frutas, SP. **Revista Brasileira de Engenharia Agrícola e Ambiental** 14:618–624.

Basso BD, Cammarano EC (2013) Revisão dos métodos de previsão do rendimento das culturas e dos sistemas de alerta precoce. Em Anais da primeira reunião do comitê consultivo científico da estratégia global para melhorar as estatísticas agrícolas e rurais, sede da FAO, Roma, Itália 18-19.

Bhering, SB, Chagas CS, Carvalho J, Waldir P, Nilson R, Calderano FB, Pinheiro HSK. (2016). Mapeamento digital de areia, argila e carbono orgânico por modelos Random Forest sob diferentes resoluções espaciais. **Pesquisa Agropecuária Brasileira** 9:1359-1370.

Bocco M, Willington E, Arias M (2010) Comparison of Regression and Neural Networks Models to Estimate Solar Radiation. **Chilean journal of agricultural research** 70:428–435.

Bracesco N, Sanchez AG, Contreras V, Menini TAG (2011) Avanços recentes na pesquisa de *Ilex paraguariensis* St: **Minireview. Jornal de Etnofarmacologia** 136:376–384.

Breiman L (2001) **Random forests**. Machine Learning. Califórnia, 5–32p.

Camotti BM, Cherobim VF, Reissmann CB, Fernandes Kaseker J, Gaiad S (2018) Yerba mate: Nutrient levels and quality of the beverage depending on the harvest season. **Journal Food Composition and Analysis** 69:1–6.

Cañete L, Argüello B del, Pucciarelli Román A (2017) Estudio de la flora microbiana de la yerba mate durante las etapas de su elaboración. **Revista Ciencia y Tecnología** 27: 51–57.

Cardozo Junior EL, Morand C 92016) Interest of mate (*Ilex paraguariensis* A. St.-Hil.) as a new natural functional food to preserve human cardiovascular health - A review. **Journal of Functional Foods** 21:440–454.

Caron BO, Schmidt D, Manfron PA, Behling A, Eloy E, Busanello C (2014) Efficiency of the use of solar radiation for plants *Ilex paraguariensis*. **Ciência Florestal** 24:257–265.

Chimonyo VGP, Modi AT, Mabhaudhi T (2016) Assessment of sorghum-cowpea intercrop system under water-limited conditions using a decision support tool. **Water SA** 42:1-15.

Corrêa STR, Lorençoni R, Neto DD, Scarpere FV, Vivian R, Ruiz ET (2011) Aplicações e limitações da modelagem em agricultura- Revisão. **Brazilian Journal of agriculture** 86: 1-13.

Daniel O (2009) **Erva-mate Sistema de produção e processamento industrial**, Dourado: UEMS 288p.

Dourado-Neto D, Teruel DA, Reichardt K, Nielsen DR, Frizzone JA, Bacchi OOS (1998) Principles of crop modeling and simulation: I. uses of mathematical models in agricultural science. **Scientia Agricola** 55:46–50.

Everingham Y, Sexton J, Skocaj D, Inman-Bamber G (2016) Accurate prediction of sugarcane yield using a random forest algorithm. **Agronomy Sustainable Development** 36: 27.

Feng P, Wang B, Lui LD, Waters C, Yu Q (2019) Incorporating machine learning with biophysical model can improve the evaluation of climate extremes impacts on wheat yield in south-eastern Australia. **Agricultural and Forest Meteoroly** 275: 100-113.

Freitas RA, Marques SSS, Souza TN, Silveira CCN, Silva ALN, Borges JFC, Souza JHK (2016) O consumo de chimarrão e o câncer de esôfago. **Brazilian Journal of Surgery and Clinical Research** 14:118–123.

Gopal OS, Bhargavi R (2019) Uma nova abordagem para a previsão eficiente da produção agrícola. **Computers and Electronics in Agriculture** 165:1–22.

Grimm R, BEHRENS T, MÄRKER M, ELSENBEER H (2008) Soil organic carbon concentrations and stocks on Barro Colorado Island - Digital soil mapping using Random Forests analysis **Geoderma** 146:102-113.

Guimarães AM, Caires EF, da Silva KS, da Rocha JCF (2015) Estimating gypsum equirement under no-till based on machine learning technique. **Revista Ciência Agronomica** 46:250–257.

Haykin S (2008). Redes neurais: Princípios e prática. **Bookman**.

Holzworth DP, Neil IH, Peter GV, Eric JZ, Neville IH, Greg McLean, Karine C, “APSIM - Evolução para uma nova geração de simulação de sistemas agrícolas". **Modelagem e Software Ambiental** 327–350.

Hoogenboom G, Porter CHV, Shelia KJ, Boote U, Singh JW, White LA Hunt R, Ogoshi, JI Lizaso, J. Koo, S. Asseng, A. Singels LM e JJ. Sistema de Suporte à Decisão para Transferência de Agrotecnologia (DSSAT) Versão 4.7.5 478 (https://DSSAT.net). **Gainesville,** Flórida, EUA, 2019.

IBGE, (2019). 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.

Janitza S, Tutz G, Boulesteix AL (2016) Random forest for ordinal responses: prediction and variable selection. **Computational Statistics & Data Analysis** 9: 57-73.

Jiang RHW, Zhou W, Hou Y, Yang JY, He P (2019) Explorando estratégias de manejo para melhorar a produtividade do milho e a eficiência do uso de nitrogênio no nordeste da China, usando os modelos DNDC e DSSAT. **Computers and Electronics in Agriculture** 166: 104-988.

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: 269-288.

Jones, JW, G. Hoogenboom, CH Porter, KJ Boote, WD Batchelor, LA Hunt P, Wilkens, U. Singh AG e JR (2003) Harvesting System Model DSSAT. **European Journal Agronomy 8:235–265.**

Keating BA, Carberry OS, Hammer GL, Probert ME, Robertson MJ, Holzworth D & McLean G (2003) An overview of APSIM, a model designed for farming systems simulation. **European journal of agronomy** 18: 267-288.

King A (2017) The future of agriculture. **Nature**, v. 544, n. 7651, p. 21-23.

Klering EV, Fontana DC, Berlato MA, Filho AC (2008) Modelagem agrometeorológica do rendimento de arroz irrigado no Rio Grande do Sul. **Pesquisa Agropecuaria Brasileira** 43:549-558.

Leroux L, Castets M, Baron C, Escorihuela MJ, Begue A, Visto D (2019) Maize Yilde estimation in West Africa from crop process- induced combinations of multi-domain remote sensing índices. European Journa of Agronomy 108:11-26.

Liaw A, Wiener M (2002) Classification and regression by random Forest. **R News** 2:18-21.

Martins FB, Pereira RA de A, Pinheiro MVM, Abreu MC (2014) Desenvolvimento foliar em duas cultivares de oliveira estimado por duas categorias de modelos. **Revista Brasileira de Meteorologia** 29:505–514.

Mazuchowski, J.Z., Maccari, A. Junior. E. S (2003) Influência de diferentes condições de radiação solar sobre o crescimento morfológico da erva-mate (*Ilex paraguariensis* A. St. Hill.) Congresso sul-americano da erva-mate 3:256–257.

Meier M, Souza E de, Francelino MR, Fernandes Filho EI, Schaefer CEGR (2018) Digital Soil Mapping Using Machine Learning Algorithms in a Tropical Mountainous Área. **Revista Brasileira Ciência do Solo** 42:1–22.

Moreto VB, Aparecido LEO, Rolim GS, Moraes JR da SC (2018) Agrometeorological models for estimating sweet cassava yield**. Pesquisa Agropecuária Tropical** 48:43–51.

Murtagh FA (1983) Survey of recente advances in hierarchical clustering algorithms. **Computer Journal** 26:354–359.

Oliveira SV, Waquil PD (2017) Dinâmica de produção e comercialização da erva-mate no Rio Grande do Sul, Brasil. **Ciência Rural** 45: 750-756.

Passioura JB (1973) Sense and nonsense in crop simulation. **Journal of the Australian Institute of Agricultural Science** 39:181-183.

Pires, EZ, Stedille LIB, Machado S, Mantovani A, Bortoluzzi RLC (2014) Biologia reprodutiva de erva-mate (*Ilex paraguariensis* A. St. Hil) em remanescentes de Floresta Ombrófila Mista Altomontana. **Journal of Agroveterinay Sciences** 13:171-180.

Rakocevic M, Martim SF (2011) Time series in analysis of yerba-mate biennial growth modified by environment. **International Journal Biometeorology** 55:161–171.

Rolim GDS, Novo MCSS, Pantano AP, Trani PE (2011) Modelagem agrometeorologica para estimação do desenvolvimento e da produção de jilo. **Revista Brasileira de Engenharia Agrícola e Ambiental** 8:832–837.

Rolim GS, Camargo MBP, Grosselilania D, De Moraes JFL (2007) Classificação climática de koppen e de thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo. **Bragantia** 66:711–720.

Rosa VGC, Moreira MA, Rudorff BFT, Adami M (2010) Estimativa da produtividade de café com base em um modelo agrometeorologico-espectral. **Pesquisa Agropecuária Brasileira** 45:1478–1488.

Ross S, Arriaga ME, Pechi E (2017) Establecimiento in vitro de Yerba mate (*Ilex paraguariensis* A. St.-Hil.) nativa de Uruguay. **Agrociencia Uruguay** 21:15–23.

Russell S & Norvig P (2009). Inteligência Artificial: uma abordagem moderna Londres, Reino Unido, Prentice-Hall, 905p.

Santin D, Benedetti EL, Barros NF de, Almeida IC de Simiqueli GF, Neves JCL, Wendling I, Reissmann CB (2019) Adubação nitrogenada e intervalos de colheita na produtividade e nutrição da erva-mate e em frações de carbono e nitrogênio do solo. **Ciência Florestal** 29:1199.

Santin D, Benedetti EL, de Barros NF, de Almeida IC, Wendling I (2017) Intervalos de colheita e adubação potássica influenciam a produtividade da erva-mate (*Ilex paraguariensis*) no Estado do Paraná. **Ciência Florestal** 46:509–518.

Sayes W, Mouazen AM, Ramon H (2015) Potencial for onsite and online analysis of pig manire using visible and near infrared reflectance spectroscopy. **Biosystems Engineering** 91:393-402.

Silva LL, da Costa RF, Campos JHB d. C, Dantas RT (2009) Influence of precipitations on agricultural productivity in Paraíba State. **Revista Brasileira de Engenharia Agrícola e Ambiental** 13:454–461.

Silva-Fuzzo D, Prela-Pantano A, Camargo MBP (2015) Uso de dados do satélite trmm para testes de modelos agrometeorológicos de e estimativa de produtividade da cultura da soja. **Irriga** 20:490–501.

Stackhouse JR., J Barnett, T. Bristow, W Chandler, J Hoell., D Westberg., T. Zhang M, Tisdale BT e BQ (2017) A revitalized GIS-enabled NASA POWER web site with featuring updated data parameters, expanded data accessibility, and analysis functionality for the renewable energy and other applications. **Am Sol Energy Soc Meet** 1:9-13.

Steduto P, Hsiao TC, Raes D, Fereres E (2009) AquaCrop – The FAO crop model to simulate yield response to water: I. Concepts and underlying principles. **Agronomy Journal** 101:426-43.

Tavares RLM, Oliveira SRM, Barros FMM, Farhate CVV, Souza ZM, La Scala Junior NL (2018) Previsão do fluxo de CO2 do solo em sistemas de manejo de cana-de-açúcar usando a abordagem Random Forest. **Scientia Agricola** 74:281–287.

Thornthwaite CW, Mather JR (1955) The water balance. Centerton, NJ: Drexel Institute of Technology - Laboratory of Climatology**. Climatology** 8: 104.

Toumi J, Er-rakI S, Ezzahar J,Khabba S, Jarlan LC (2016) Avaliação do desempenho do modelo AquaCrop para estimativa da evapotranspiração, teor de água no solo e rendimento de grãos do trigo de inverno em Tensift Al Haouz (Marrocos): aplicação ao manejo da irrigação. **Agricultural Water Management** 163:219–235.

Victorino EC, Carvalho LG, Ferreira DF (2016) Modelagem agrometeorológica para a previsão de produtividade de cafeeiros na região sul do estado de minas gerais. **Coffee Scienc** 11:211–220.

Vieira ARR (2003) Influência do microclima de um sistema agroflorestal na cultu ra da erva-mate (*Ilex paraguariensis St* St. Hil). **Revista Brasileira de Agrometeorologia** 11:91–97.

Wang L, Zhou X, Zhu X, Dong Z, Guo W (2016) Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. **Crop Journal Elsevier** 4:212–219.

Ward JH (1963) Hierarchical grouping to optimize an objective function. **Journal of America Statistical Association** 58:236-244.

Wendling I, Brondani GE, Biassio AD, Leonardo F (2013) Vegetative propagation of adult *Ilex paraguariensis* St trees through epicormic shoots. **Acta Scientiarum Agronomy** 35:117-125.

Witten IH, Eibe F (2005) Data Mining: Pratical Machine Learning Tools and techniques, **Elsevier** 633p.

Woznicki SA, Baynes J, Panlasigui S, Mehaffey M, Neale A (2019) Development of a spatially complete floodplain map of the conterminous United States using random forest. **Science of the total environment** 647:942-953.

Zeron RMC, Serrano Junior CV (2016) Artificial intelligence in the diagnosis of cardiovascular disease. **Revista de Associação Médica Brasileira** 65:1438–1441.

Zhao Y, Justina DDD, Watanabe J, Rocha JV, Graziano P, Lamparelli RAC (2018) Multivariety sugarcane sucrose estimation using a combination of spectral and agrotechnology methods. Remote Sensing for Agriculture, Ecosystems, and Hydrology XX. 107830L. doi: 10.1117/12.2326705, 2018.