

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**INFLUÊNCIA CLIMÁTICA NO DESENVOLVIMENTO E
PRODUTIVIDADE DE VIDEIRA (*Vitis vinifera* L.) DESCRITO
POR MODELOS DE APRENDIZAGEM DE MÁQUINA**

Thaís Rayane Gomes da Silva
Ma. Agricultura e Ambiente

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**INFLUÊNCIA CLIMÁTICA NO DESENVOLVIMENTO E
PRODUTIVIDADE DE VIDEIRA (*Vitis vinifera* L.) DESCRITO
POR MODELOS DE APRENDIZAGEM DE MÁQUINA**

Thaís Rayane Gomes da Silva

Orientador: Prof. Dr. Glauco de Souza Rolim

Coorientadora: Profa. Dra. Tatiana Fernanda Canata

**Tese apresentada a Faculdade de Ciências
Agrárias e Veterinárias – UNESP, Câmpus de
Jaboticabal, como parte das exigências para
a obtenção do título de Doutora em
Agronomia (Produção Vegetal)**

S586i Silva, Thaís Rayane Gomes da
Influência climática no desenvolvimento e produtividade de videira (*Vitis vinifera* L.) descrito por modelos de aprendizagem de máquina / Thaís Rayane Gomes da Silva. -- Jaboticabal, 2025
112 p. : tabs., mapas

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Glauco de Souza Rolim
Coorientadora: Tatiana Fernanda Canata

1. Machine learning. 2. Climatologia agrícola. 3. Regiões vinícolas. I. Título.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: INFLUÊNCIA CLIMÁTICA NO DESENVOLVIMENTO E PRODUTIVIDADE DE VIDEIRA
(Vitis vinifera L.) DESCRITO POR MODELOS DE APRENDIZAGEM DE MÁQUINA


AUTORA: THAÍS RAYANE GOMES DA SILVA

ORIENTADOR: GLAUCO DE SOUZA ROLIM

COORDINADORA: TATIANA FERNANDA CANATA

Aprovada como parte das exigências para obtenção do Título de Doutora em Agronomia (Produção Vegetal), pela Comissão Examinadora:

Prof. Dr. GLAUCO DE SOUZA ROLIM (Participação Virtual)
Departamento de Engenharia / FCAV UNESP Jaboticabal



Prof. Dr. AURELIANO NATÁLIO COELHO MALHEIRO (Participação Virtual)
Departamento de Agronomia / Universidade de Trás-os-Montes e Alto Douro (UTAD) - Vila Real/Portugal

Assinado por: AURELIANO NATÁLIO COELHO MALHEIRO
Num. de identificação: 07910015
Data: 2024.11.27 18:32:12+00'00'

Profa. Dra. DENISE CYBIS FONTANA (Participação Virtual)
Universidade Federal do Rio Grande do Sul (UFRGS) / Porto Alegre/RS

Documento assinado digitalmente
DENISE CYBIS FONTANA
Data: 26/11/2024 10:52:32-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. ALEXANDRE BARCELLOS DALRI (Participação Virtual)
Departamento de Engenharia / FCAV UNESP Jaboticabal



Profa. Dra. SABRINA LUZIA CAETANO (Participação Virtual)
Departamento de Engenharia / FCAV UNESP Jaboticabal



Jaboticabal, 21 de novembro de 2024

DADOS CURRICULARES DO AUTOR

Thaís Rayane Gomes da Silva, nascida em Arapiraca, Alagoas, em 10 de setembro de 1997. Possui formação acadêmica em Agronomia (2014 - 2019), pela Universidade Federal de Alagoas, mestrado em Agricultura e Ambiente (2020 - 2021) pela mesma instituição, especialização em Docência para Educação Profissional e Tecnológica (2020 - 2021) pelo Instituto Federal do Amazonas. É doutoranda em Agronomia (Produção Vegetal) (2021 - atual) pela Universidade Estadual Paulista 'Júlio de Mesquita Filho'/Faculdade de Ciências Agrárias e Veterinárias, com foco em Data Science e modelagem de dados meteorológicos para o desenvolvimento de sistemas sustentáveis de produção agrícola. Possui forte atuação em desenvolvimento de projetos e pesquisas voltadas para a agricultura sustentável, utilizando técnicas de modelagem de dados e ciências de dados para otimização de processos e sistemas de produção.

"A previsão não elimina a incerteza, mas nos permite enfrentá-la com sabedoria."

Stephen Hawking

Ao meu avô Augusto, cuja sabedoria me inspirou desde a infância. Seu legado vive em cada passo que dou e em cada conquista que alcanço.

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus por me conceder forças, saúde e serenidade para enfrentar cada desafio desta jornada, iluminando meus passos e guiando minhas escolhas com sabedoria e propósito.

Aos meus pais, Arnaldo Augusto e Marilene Gomes, que sempre me incentivaram a buscar meus sonhos com coragem e determinação, oferecendo apoio incondicional e ensinamentos valiosos.

Aos meus irmãos, Kelly, Bruno e Matheus, cuja presença e companheirismo sempre me deram forças para seguir em frente. Saber que podia contar com o apoio e incentivo de vocês tornou cada desafio mais leve e cada conquista ainda mais significativa.

Ao meu orientador, Prof. Dr. Glauco Rolim, agradeço pela confiança depositada em meu trabalho, pelo suporte técnico e intelectual, e por ter me guiado com paciência e dedicação. Suas orientações foram essenciais para o desenvolvimento desta pesquisa e para o meu crescimento como profissional.

Aos membros da banca de defesa – Prof. Dr. Aureliano, Profa. Dra. Denise, Profa. Dra. Sabrina e Prof. Dr. Alexandre Dalri – expresse minha gratidão pela generosidade em dedicar seu tempo, conhecimento e experiência para avaliar e contribuir com esta tese.

Aos professores e profissionais da Universidade Estadual Paulista "Júlio de Mesquita Filho", sou grata pelo conhecimento compartilhado e pelas oportunidades de aprendizado que enriqueceram minha formação acadêmica.

Aos amigos de caminhada acadêmica, agradeço por todos os momentos de apoio, discussões enriquecedoras e pela parceria nas jornadas longas e desafiadoras. Nossa troca de conhecimentos e experiências me ajudou a enfrentar as adversidades com resiliência e alegria.

Agradeço de coração às minhas amigas, Victória Regina, Mariana Campos, Samira Luns, Thiffany Catosi e Isabel Roncato, que ao longo desta jornada sempre estiveram ao meu lado, compartilhando risos, oferecendo apoio e celebrando cada pequena conquista. A amizade e o carinho de vocês foram fundamentais para que eu

seguisse em frente com confiança e determinação. Minha gratidão por cada uma de vocês é imensa.

Por fim, agradeço aos meus amigos e familiares, em especial às minhas tias Rozilene e Jozilene, que, mesmo distantes, sempre estiveram presentes de coração, oferecendo carinho e apoio emocional nos momentos mais desafiadores. Esta conquista é tanto minha quanto de cada um de vocês.

A realização desta tese é o resultado de uma jornada acadêmica intensa, cheia de desafios, aprendizados e momentos marcantes. Sou profundamente grata a todos aqueles que, de diferentes maneiras, contribuíram para que esta etapa da minha vida fosse concluída com sucesso.

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

SUMÁRIO

Página

CAPÍTULO 1 – Considerações gerais	19
Referências	23
CAPÍTULO 2 – Modelagem agrometeorológica do desenvolvimento e produtividade da videira (Vitis vinifera L.) para vinificação empregando algoritmos de aprendizagem de máquina	27
2.1. Introdução	28
2.2. Material e Métodos	32
2.2.1. Áreas de estudo.....	32
2.2.2. Dataset	36
2.2.3. Fenologia da videira	37
2.2.4. Modelos de Aprendizado de Máquina	38
2.2.4.1. Regressão Linear Múltipla (RLM)	40
2.2.4.2. Random Forest (RF)	41
2.2.4.3. Support Vector Machine (SVM)	41
2.2.4.4. CatBoost (CB).....	42
2.2.5. Métricas de avaliação e análise estatística	42
2.3. Resultados	43
2.3.1. Variáveis climáticas e produtividade	43
2.3.2. Correlação de Spearman entre variáveis climáticas e produtividade	52
2.3.3. Parâmetros de modelos de aprendizado de máquina	55
2.3.4. Seleção de variáveis do modelo	58
2.3.5. Estimativa de produtividade usando modelos de aprendizado de máquina	59
2.4. Discussão	65
2.4.1. Influência do clima na fenologia da videira.....	65
2.4.2. Uso de modelagem para estimativa de produtividade.....	70
2.5. Conclusões	71
Referências	71
CAPÍTULO 3 – Modelagem da produtividade de uvas viníferas com aplicação de regressão não-linear.....	85
3.1. Introdução	86
3.2. Material e Métodos	88
3.2.1. Caracterização da área de estudo.....	88
3.2.2. Dados climáticos e produtividade	89
3.2.3 Métodos estatísticos	90
3.2.4 Modelagem Não-Linear	91
3.2.5 Métricas de desempenho	91

3.3. Resultados	92
3.4. Discussão	100
3.5. Conclusões	101
Referências	102
CAPÍTULO 4 – Considerações finais	107
APÊNDICE A – Principais cultivares de uva por região e os vinhos produzidos	109
APÊNDICE B – Correlação de Spearman	111

INFLUÊNCIA CLIMÁTICA NO DESENVOLVIMENTO E PRODUTIVIDADE DE VIDEIRA (*Vitis vinifera* L.) DESCRITO POR MODELOS DE APRENDIZAGEM DE MÁQUINA

RESUMO – A produção de uvas para vinificação é altamente relevante globalmente e depende de condições meteorológicas específicas, que influenciam a qualidade e produtividade das videiras. Mudanças no clima, como temperaturas elevadas e variações na precipitação, impactam a fenologia e a composição das uvas, afetando a qualidade do vinho. A modelagem agrometeorológica e algoritmos de aprendizagem de máquina têm se mostrado eficazes para prever a produtividade da videira, permitindo adaptações na viticultura e auxiliando na gestão sustentável diante das variabilidades climáticas. A pesquisa analisou dados de produtividade da videira e variáveis climáticas de sete regiões do Sul do Brasil entre 1982 e 2021. Dados climáticos foram obtidos da NASA-Power e de produtividade do Sidras IBGE, permitindo avaliar o impacto climático nos estádios fenológicos da videira. Foram utilizados modelos de aprendizagem de máquina, como Regressão Linear Múltipla, Random Forest, Suporte Vector Machine e CatBoost, com validação cruzada para prever a produtividade. A correlação de Spearman e modelos de regressão não-linear aprofundaram a análise das relações entre clima e produtividade. O estudo mostrou um aumento gradual nas temperaturas ao longo dos estádios fenológicos da videira, com variações regionais na influência dos elementos climáticos sobre a produtividade. Enquanto a temperatura máxima e radiação líquida foram mais relevantes na região de Vinhos de Bituruna, a temperatura do ar e umidade do solo se destacaram na região da Campanha Gaúcha. Utilizando um conjunto de dados consolidado e modelos de aprendizagem de máquina, o CatBoost apresentou os melhores resultados de precisão e adaptabilidade. A análise demonstrou que a umidade relativa tem correlação positiva com a produtividade, e com a evapotranspiração de referência apresenta correlação negativa moderada. Esses resultados destacam a importância de considerar elementos climáticos e geográficos específicos para otimizar a viticultura.

Palavras-chave: fenologia da videira, machine learning, modelos de regressão não-linear, Python, variáveis climáticas, *Vitis vinifera* L.

CLIMATIC INFLUENCE ON THE DEVELOPMENT AND YIELD OF GRAPEVINE (*Vitis vinifera* L.) DESCRIBED BY MACHINE LEARNING MODELS

ABSTRACT – Grape yield for winemaking is highly relevant globally and depends on specific meteorological conditions that influence the quality and yield of vineyards. Climate changes, such as elevated temperatures and variations in precipitation, impact grape phenology and composition, thereby affecting wine quality. Agrometeorological modeling and machine learning algorithms have proven effective in predicting vineyard yield, enabling adaptations in viticulture and supporting sustainable management in the face of climate variability. The research analyzed vineyard yield and climatic variables from seven regions in southern Brazil between 1982 and 2021. Climatic data were obtained from NASA-Power, and yield data from Sidra IBGE, allowing for an assessment of climatic impacts on grapevine phenological stages. Machine learning models, including Multiple Linear Regression, Random Forest, Support Vector Machine, and CatBoost, were employed with cross-validation to predict yield. Spearman correlation and non-linear regression models further deepened the analysis of the relationships between climate and yield. The study revealed a gradual increase in temperatures during the grapevine phenological stages, with regional variations in the influence of climatic elements on yield. While maximum temperature and net radiation were most relevant in the Vinhos de Bituruna region, air temperature and soil moisture stood out in the Campanha Gaúcha region. Using a consolidated dataset and machine learning models, CatBoost demonstrated the best results in terms of accuracy and adaptability. The analysis showed that relative humidity has a positive correlation with yield, while reference evapotranspiration exhibits a moderate negative correlation. These findings underscore the importance of considering specific climatic and geographical elements to optimize viticulture practices.

Palavras-chave: vine phenology, machine learning, vine phenology, Python, climatic variables, *Vitis vinifera* L.

Lista de Abreviaturas

Abreviação	Significado	Unidade de Medida
RLM	Regressão Linear Múltipla	Modelo
RF	Random Forest	Modelo
SVM	Support Vector Machine	Modelo
CB	CatBoost	Modelo
PR	Paraná	Estado
SC	Santa Catarina	Estado
RS	Rio Grande do Sul	Estado
CG	Campanha Gaúcha	Região
AM	Altos Montes	Região
FA	Farroupilha	Região
VV	Vale dos Vinhedos	Região
GGV	Vales das Uvas Goethe	Região
HW	Vinhos de Altitude	Região
BW	Vinhos de Bituruna	Região
PR	Poda	Estágio Fenológico
SP	Brotação	Estágio Fenológico
FL	Floração	Estágio Fenológico
FRB	Frutificação (4 mm)	Estágio Fenológico
FRP	Frutificação (7 mm)	Estágio Fenológico
MA	Maturação	Estágio Fenológico
T	Temperatura Média do Ar a 2 Metros	°C
Tmax	Temperatura Máxima Diária a 2 Metros	°C
Tmin	Temperatura Mínima Diária a 2 Metros	°C
Rn	Radiação Líquida na Superfície da Cultura	MJ m ⁻² dia ⁻¹
Qg	Irradiância Solar Global de Ondas Curtas	MJ m ⁻² dia ⁻¹
PAR	Irradiância Solar Ativamente Fotossintética	MJ m ⁻² dia ⁻¹
P	Precipitação Pluviométrica	mm dia ⁻¹
RH	Umidade Relativa a 2 Metros	%
SH	Umidade do Solo na Zona Radicular	N.U.

ETo	Evapotranspiração de Referência	mm dia ⁻¹
AH	Umidade Absoluta	g água vapor ⁻¹ m ⁻³

Lista de Tabelas

Tabela 1. Caracterização de cada área de estudo.	32
Tabela 2. Faixa de valores testados e valores otimizados dos parâmetros de cada modelo, para a região sul do Brasil (todas as regiões).....	55
Tabela 3. Intervalo de valores testados e valores otimizados dos parâmetros de cada modelo, em cada uma das regiões estudadas.	56
Tabela 4. Variáveis dependentes selecionadas pelos modelos: temperatura média (T), temperatura máxima (Tmax), temperatura mínima (Tmin), radiação líquida na superfície da cultura (Rn), irradiância solar global de onda curta (Qg), irradiância solar fotossinteticamente ativa (PAR), precipitação (P), umidade relativa (RH), umidade do solo na zona radicular (SH), umidade absoluta (AH) e evapotranspiração de referência (ETo) para cada modelo analisado, considerando o conjunto de dados de todas as regiões.	59
Tabela 5. Indicadores de desempenho: erro quadrático médio da raiz (RMSE) e coeficiente de determinação ajustado (R^2_{adj}) relativo aos modelos de Regressão Linear Múltipla (RLM), Random Forest (RF), Support Vector Machine (SVM) e CatBoost (CB) em análise nas diversas regiões estudadas.....	63
Tabela 6. Coeficientes α , β e γ do modelo Holliday (1960), valores ótimos para cada variável e métricas de desempenho correspondentes: coeficiente de determinação ajustado (R^2_{adj}), erro percentual absoluto médio (MAPE) e erro quadrático médio da raiz (RMSE, em $t\ ha^{-1}$).	99

Listas de Figuras

Figura 1. Mapa das principais regiões vinícolas do Brasil utilizadas no trabalho.....	33
Figura 2. Estádios fenológicos médios da videira para o sul do Brasil. Fontes: ¹ Radünz et al. (2015); ² Chavarria et al. (2010); ³ Mandelli et al. (2003); ⁴ Filippon et al. (2017); ⁵ Della Bruna (2021); ⁶ Felippeto et al. (2021); ⁷ Santos et al. (2007).	38
Figura 3. Variáveis dependentes utilizadas nos modelos de aprendizagem de máquina para cada estágio fenológico: Qg (irradiância solar global de onda curta), PAR (irradiância solar fotossinteticamente ativa), T (temperatura média), Tmax (temperatura máxima), Tmin (temperatura mínima), RH (umidade relativa), P (precipitação), SH (umidade do solo na zona radicular), Rn (radiação líquida na superfície da cultura), ET (evapotranspiração de referência) e AU (umidade absoluta), e variável independente: produtividade.	39
Figura 4. Relação entre variáveis dependentes, temperatura média (T), temperatura máxima (Tmax), temperatura mínima (Tmin), radiação líquida na superfície da cultura (Rn), irradiância solar global de onda curta (Qg) e irradiância solar fotossinteticamente ativa (PAR), e os estádios fenológicos, poda (PR), brotação (SP), floração (FL), frutificação (4 mm) (FRB), frutificação (7 mm) (FRP) e maturação (MA).	45
Figura 5. Relação entre as variáveis dependentes, precipitação (P), umidade relativa (RH), umidade do solo na zona radicular (SH), evapotranspiração de referência (ETo), e umidade absoluta (AH), e os estádios fenológicos, poda (PR), brotação (SP), floração (FL), frutificação (4 mm) (FRB), frutificação (7 mm) (FRP) e maturação (MA).	48
Figura 6. Produtividade da videira nas regiões vinícolas, Altos Montes – AM (RS), Farroupilha – FA (RS), Vale dos Vinhedos – VV (RS), Vinhos de Altitude – HW (SC), Vales da Uva Goethe – GGV (SC), Vinhos de Bituruna – BW (PR) e Campanha Gaúcha – CG (RS). As letras indicam o resultado da análise de Tukey no nível de significância de 0,05.	49
Figura 7. Correlação de Spearman entre as variáveis dependentes mais importantes (temperatura média (T), temperatura máxima (Tmax), temperatura mínima (Tmin), radiação líquida na superfície da cultura (Rn), irradiância solar global de onda curta (Qg), irradiância solar fotossinteticamente ativa (PAR), precipitação (P), umidade	

relativa (RH), umidade do solo na zona radicular (SH), umidade absoluta (AH) e evapotranspiração de referência (ET _o) e produtividade ao longo dos estádios fenológicos da uva (a, b, c, d, e, f e g) nas diferentes regiões vinícolas estudadas. Resumo da análise de correlação (h).	55
Figura 8. Estimativas de desempenho do modelo para todas as regiões avaliadas no estudo.	62
Figura 9. Desempenho do modelo CatBoost (CB) em distintas regiões vinícolas.	65
Figura 10. Áreas de estudo.	89
Figura 11. Correlação de Spearman entre as variáveis climáticas, umidade relativa (RH), evapotranspiração de referência (ET _o), temperatura mínima do ar (T _{min}), irradiância solar fotossinteticamente ativa (PAR), umidade do solo (SH), umidade absoluta (AH), radiação líquida na superfície da cultura (R _n), irradiância solar global de onda curta (Q _g), temperatura máxima do ar (T _{max}), temperatura média do ar (T) e precipitação (P), e a produtividade da videira.	93
Figura 12. Produtividade como função de variáveis climáticas: irradiância solar global de onda curta (Q _g) (a), irradiância solar fotossinteticamente ativa (PAR) (b), radiação líquida na superfície da cultura (R _n) (c), temperatura média do ar (T) (d), temperatura máxima do ar (T _{max}) (e) e temperatura mínima do ar (T _{min}) (f), para as regiões estudadas, incluindo Campanha Gaúcha (CG), Altos Montes (AM), Farroupilha (FA), Vale dos Vinhedos (VV), Vale das Uvas Goethe (GGV), Vinhos de Altitude (HW) e Vinhos de Bituruna (BW), aplicada ao modelo de Holliday.	96
Figura 13. Produtividade como função de variáveis climáticas: precipitação (P) (a), umidade relativa (RH) (b), umidade do solo (SH) (c), umidade absoluta (AH) (d) e evapotranspiração de referência (ET _o) (e), para as regiões estudadas, incluindo Campanha Gaúcha (CG), Altos Montes (AM), Farroupilha (FA), Vale dos Vinhedos (VV), Vale das Uvas Goethe (GGV), Vinhos de Altitude (HW) e Vinhos de Bituruna (BW), aplicada ao modelo de Holliday.	98

CAPÍTULO 1 – Considerações gerais

O cultivo da videira (*Vitis vinifera* L.), originária da região do Mediterrâneo, representa uma prática agrícola de grande relevância em diversos países, estando intrinsicamente ligado à produção vinícola (Naulleau et al., 2021). Esta, por sua vez, constitui uma indústria global de alto valor econômico, movimentando bilhões de dólares anualmente e exercendo importante influência cultural e socioeconômico (Schwerz et al., 2023).

A produção de uvas destinadas à vinificação concentra-se majoritariamente em países onde a viticultura está fortemente voltada para essa finalidade, como França (99,6%), Alemanha (99,6%), Espanha (96,0%), Argentina (93,7%), Romênia (93,1%), Austrália (90,9%) e Itália (86,5%), classificados em ordem crescente em termos de volume de produção (Santos et al., 2020).

No Brasil, a viticultura configura-se como um dos setores agrícolas de maior relevância econômica, especialmente na região Sul, que nos últimos anos representou 73,12% da área total destinada ao cultivo da videira no país (Schwerz et al., 2023), o estado do Rio Grande do Sul destaca-se como o maior produtor nacional, abrangendo 62,51% da área total de viticultura, o que corresponde a aproximadamente 46,77 hectares (ha).

Torna-se evidente que a viticultura se estabelece como um setor fundamental nos âmbitos socioeconômico e cultural de inúmeros países e regiões, exercendo expressivo impacto econômico sobre a geração de empregos, produtividade agrícola e comércio internacional (Samuels et al., 2022; Santos et al., 2020). Sua produtividade é amplamente condicionada por variáveis climáticas que desempenham papel decisivo em seu crescimento, desenvolvimento, produção e qualidade (Fraga, 2020; Schwerz et al., 2023).

O cultivo de videiras requer, em geral, temperaturas médias do ar que variam entre 12°C a 22°C durante o ciclo de crescimento, além de uma disponibilidade de radiação solar mínima de pelo 700 a 900 μmol de fótons $\text{m}^{-2} \text{s}^{-1}$, cerca de 600 a 800 mm de precipitação ou irrigação suplementar e um período de crescimento isento de geada (Arias et al., 2022; Zapata et al., 2016). Consequentemente, variáveis como temperatura, radiação solar e precipitação exercem influência substancial sobre a

fenologia, a produtividade e a qualidade dos atributos das bagas de uva (Andreoli et al., 2019; Costa et al., 2019).

Estes elementos atmosféricos destacam-se como determinantes no desenvolvimento fisiológico da videira (Fraga, 2020). Em particular, a temperatura é um fator fundamental no controle do desenvolvimento fenológico e do amadurecimento da videira (Costa et al., 2019). Projeções de aumento na temperatura indicam a tendência de um adiantamento nos estágios fenológicos da videira (Vivin et al., 2017), o que poderá impactar o período de maturação dos frutos. Esse período, geralmente é coincidente com os meses mais quentes do verão, o que se torna vulnerável a perdas de compostos aromáticos e acidez (Costa et al., 2019).

Dessa forma, é fundamental compreender o grau de influência da temperatura sobre os ciclos reprodutivo e vegetativo da videira, além de identificar variações específicas entre cultivares no que tange à fenologia e maturação (Parker et al., 2011). Tratando-se de temperaturas elevadas, as mesmas afetam a composição da parede celular e a composição fenólica dos frutos (Allegro et al., 2021).

Costa et al. (2014) estudando a influência das condições atmosféricas nos parâmetros de qualidade das bagas em três regiões diferentes de Portugal (Alentejo, Douro e Dão), os resultados indicaram que temperaturas mais altas tendem a diminuir o peso das bagas, a acidez titulável, as antocianinas e o teor fenólico total, além de verificar um aumento no pH e no potencial alcoólico, revelando os efeitos da variabilidade térmica na qualidade final das uvas.

As videiras também podem ser suscetíveis aos efeitos do aumento e/ou excesso de precipitação (Heuvel; Centinari, 2021). Em contrapartida, a redução hídrica pode levar à diminuição do tamanho das bagas, embora também possa contribuir a favorecer a maior concentração de compostos fenólicos nas uvas, com potencial impacto na qualidade do vinho (Gutiérrez-Escobar et al., 2021).

Esses elementos desempenham um papel fundamental na localização histórica dos vinhedos e, conseqüentemente, nas práticas de gestão local e nas variedades plantadas (Fraga, 2020). A variabilidade climática ao longo de toda a estação de cultivo da videira apresenta forte correlação com as flutuações anuais na produtividade total (Fraga; Santos, 2017). Além disso, eventos climáticos extremos, como ondas de calor, granizo, geada e inundações, também exercem impactos

adversos significativos sobre a produtividade e qualidade das uvas (Fraga et al., 2020).

A expressão do *terroir* das regiões vinícolas abrange as influências combinadas de características varietais, clima, condições edáficas, práticas de vinificação e as complexas interações entre esses fatores (Bonfante e Brillante, 2022; Iorizzo et al., 2023). Evidencia-se a necessidade de implementação de uma ampla gama de alavancas de adaptação, visando aprimorar a gestão da viticultura diante das condições climáticas projetadas para o futuro (Naulleau et al., 2021). A migração da produção vitivinícola para áreas de maior altitude e/ou maior latitude é considerada como uma estratégia de adaptação viável (Delay et al., 2015; Naulleau et al., 2021).

A modelagem agrometeorológica emerge como uma ferramenta crucial na previsão e otimização da produção agrícola (Ivanyo et al., 2020). A aplicação de modelos atmosféricos de alta resolução propicia uma compreensão mais aprofundada da variabilidade climática nas regiões vinícolas de Marlborough, na Nova Zelândia, contribuindo para a tomada de decisões que promovem a sustentabilidade na indústria vinícola (Sturman et al., 2016).

Os algoritmos de aprendizagem de máquina (ML), como o Random Forest (RF), demonstram potencial significativo na previsão da produtividade da videira, considerando as condições climáticas e as propriedades edáficas (Andrade et al., 2023). Estudos indicam que modelos baseados em ML são capazes de prever com precisão a produtividade da videira, apresentando baixos valores de erro médio quadrático e coeficientes de erro relativo (Sirsat et al., 2019). Tais algoritmos evidenciaram a capacidade significativa de prever a produtividade de diferentes cultivares de videira no Irã, alcançando níveis de precisão superiores a 80% (Panahi et al., 2019).

Para que os modelos de ML sejam treinados de forma adequada e que sua capacidade de generalização seja validada, os dados de treinamento devem se adequar aos parâmetros do modelo, enquanto os dados de teste são utilizados para avaliar o desempenho preditivo dos algoritmos de previsão de séries temporais (Suradhaniwar et al., 2021). Para essa avaliação, são empregadas diversas métricas de precisão, como o erro quadrado médio de raiz (RMSE) e Erro Absoluto Médio

(MAE), que oferecem diferentes perspectivas sobre a eficácia dos modelos preditivos (Suradhaniwar et al., 2021).

Referências

Allegro G, Pastore C, Valentini G, Filippetti I (2021) The evolution of phenolic compounds in *Vitis vinifera* L. red berries during ripening: analysis and role on wine sensory—A review. **Agronomy** 11:999.

Andrade CB, Moura-Bueno JM, Comin JJ, Brunetto G (2023) Grape yield prediction models: approaching different machine learning algorithms. **Hortic.** 9:1294. <https://doi.org/10.3390/horticulturae9121294>.

Andreoli V, Cassardo C, La Iacona T, Spanna F (2019) Description and preliminary simulations with the Italian vineyard integrated numerical model for estimating physiological values (IVINE). **Agronomy** 9:94.

Arias L, Berli F, Fontana A, Bottini R, Piccoli P (2022) Climate change effects on grapevine physiology and biochemistry: benefits and challenges of high altitude as an adaptation strategy. **Front. Plant Sci.** 13. <https://doi.org/10.3389/fpls.2022.835425>.

Bonfante A, Brillante L (2022) Terroir analysis and its complexity. **OENO One** 56:375–388. <https://doi.org/10.20870/OENO-ONE.2022.56.2.5448>.

Costa E, Cosme F, Jordão AM, Mendes-Faia A (2014) Anthocyanin profile and antioxidant activity from 24 grape varieties cultivated in two Portuguese wine regions. **J. Int. Des Sci. De La Vigne Et Du Vin** 48:51–62.

Costa R, Fraga H, Fonseca A, García de Cortázar-Atauri I, Val MC, Carlos C, Reis S, Santos JA (2019) Grapevine phenology of cv. Touriga Franca and Touriga Nacional in the Douro Wine Region: modelling and climate change projections. **Agronomy** 9:210. <https://doi.org/10.3390/agronomy9040210>.

Delay E, Piou C, Quenol H (2015) The mountain environment, a driver for adaptation to climate change. **Land Use Policy** 48:51–62. <https://doi.org/10.1016/j.landusepol.2015.05.008>.

Fraga, H (2020) Climate Change: A New Challenge for the Winemaking Sector. **Agronomy** 10:1465. <https://doi.org/10.3390/agronomy10101465>.

Fraga H, Molitor D, Leolini L, Santos JA (2020) What is the impact of heatwaves on European viticulture? A modelling assessment. **Appl. Sci.** 10:3030. <https://doi.org/10.3390/app10093030>.

Fraga H, Santos JA (2017) Daily prediction of seasonal grapevine production in the Douro wine region based on favourable meteorological conditions. **Aust. J. Grape Wine R** 23:296–304.

Gutiérrez-Escobar R, Aliaño-González MJ, Cantos-Villar E (2021) Wine polyphenol content and its influence on wine quality and properties: A review. **Molecules** 26:718. <https://doi.org/10.3390/molecules26030718>.

Heuvel J, Centinari M (2021) Under-vine vegetation mitigates the impacts of excessive precipitation in vineyards. **Front. Plant Sci.** 12:713135. <https://doi.org/10.3389/fpls.2021.713135>.

Iorizzo M, et al. (2023) Investigating the impact of pedoclimatic conditions on the oenological performance of two red cultivars grown throughout southern Italy. **Front. Plant Sci.** 14:1250208. <https://doi.org/10.3389/fpls.2023.1250208>.

Naulleau A, Gary C, Prévot L, Hossard L (2021) Evaluating strategies for adaptation to climate change in grapevine production: A systematic review. **Front. Plant Sci.** 11:607859. <https://doi.org/10.3389/fpls.2020.607859>.

Panahi B, Mohammadi SA, Doulati-Baneh H (2020) Characterization of Iranian Grapevine Cultivars Using Machine Learning Models. **Proc. Natl. Acad. Sci. India, Sect. B Biol. Sci.** 90:615–621. <https://doi.org/10.1007/s40011-019-01131-8>.

Parker AK, García de Cortázar-Atauri I, van Leeuwen C, Chuine I (2011) General phenological model to characterise the timing of flowering and veraison of *Vitis vinifera* L. **Austr. J. Grape Wine Res.** 17:206–216.

Samuels LJ, Setati ME, Blancquaert EH (2022) Towards a better understanding of the potential benefits of seaweed based biostimulants in *Vitis vinifera* L. cultivars. *Plants* 11:348. <https://doi.org/10.3390/plants11030348>.

Schwerz F, Weber F, Signor F, Schwerz L, Baptista V, Marin D, Rossi G, Conti L, Bambi G (2023) Economic viability and quality of grapes produced with and without plastic covering. **Agronomy** 13:1443. <https://doi.org/10.3390/agronomy13061443>.

Sirsat MS, Mendes-Moreira J, Ferreira C, Cunha M (2019) Machine Learning predictive model of grapevine yield based on agroclimatic patterns. **Eng. Agric. Environ. Food** 12(4):443–450. <https://doi.org/10.1016/j.eaef.2019.07.003>.

Sturman A, McKenzie N, Williams D, Viney N (2017) The application of high-resolution atmospheric modelling to weather and climate variability in vineyard regions. **OENO One** 51:99–105. <https://doi.org/10.20870/oeno-one.2017.51.2.1538>.

Suradhaniwar S, Kar S, Durbha SS, Jagarlapudi A (2021) Time series forecasting of univariate agrometeorological data: A comparative performance evaluation via one-step and multi-step ahead forecasting strategies. **Sensors** 21:2430. <https://doi.org/10.3390/s21072430>

Vivin P, Lebon E, Dai Z, Duchêne E, Marguerit E, García de Cortázar-Atauri I, Zhu J, Simonneau T, Van Leeuwen C, Delrot S (2017) Combining ecophysiological models and genetic analysis: A promising way to dissect complex adaptive traits in grapevine. **OENO One** 51:181.

Zapata D, Salazar-Gutierrez M, Chaves B, Keller M, Hoogenboom G (2016) Predicting key phenological stages for 17 grapevine cultivars (*Vitis vinifera* L.). **Am. J. Enol. Vitic.** 68:60–72. <https://doi.org/10.5344/ajev.2016.15077>.

CAPÍTULO 2 – Modelagem agrometeorológica do desenvolvimento e produtividade da videira (*Vitis vinifera* L.) para vinificação empregando algoritmos de aprendizagem de máquina

RESUMO – A viticultura desempenha um papel vital na economia global, compreender as complexas interações entre elementos climáticos e estádios fenológicos da uva torna-se essencial para a produção vinícola. A aplicação de algoritmos de aprendizagem de máquina na previsão da produtividade da uva não apenas impulsiona a eficácia das decisões agrícolas, mas também promove a sustentabilidade e a viabilidade econômica dos vinhedos, importante em regiões vitivinícolas do Brasil. A pesquisa abrangeu sete regiões distintas, cada uma composta por diferentes municípios. Foram utilizados registros anuais de produtividade da videira no período de 1982 a 2021. Dados meteorológicos históricos das regiões foram obtidos a partir do banco de dados da Nasa-Power, permitindo uma análise da influência dessas variáveis no desenvolvimento vegetativo e na produtividade agrícola. O ciclo completo da videira foi compreendido em seis estádios fenológicos distintos, poda, brotação, florescimento, frutificação (nas etapas de 4 mm e 7 mm de diâmetro) e maturação. Os conjuntos de dados foram submetidos a treinamento e os parâmetros dos algoritmos foram otimizados por meio de uma pesquisa em grade, com validação cruzada (3 folds). Os algoritmos empregados incluíram Regressão Linear Múltipla, Random Forest, Support Vector Machine e CatBoost. A avaliação das performances estimativas dos diferentes modelos foi realizada por meio do coeficiente de determinação ajustado e do erro quadrado médio da raiz. O estudo indicou um aumento gradual nas temperaturas médias, máximas e mínimas do ar ao longo dos diferentes estádios fenológicos da *Vitis vinifera* L. nas principais regiões vitivinícolas. Na análise de correlação, entre as variáveis meteorológicas e a produtividade, destacou-se a influência das variáveis climáticas, como radiação solar, precipitação e evapotranspiração. Em geral, nas regiões mais ao norte (Vinhos de Bituruna) houve maior importância da temperatura máxima do ar e radiação líquida na superfície da cultura, para as regiões ao sul (Campanha Gaúcha) destacou-se temperatura do ar e umidade do solo. Os dados das diversas regiões foram consolidados para formar um conjunto de dados único, permitindo a extração de respostas gerais por meio da

aplicação de modelos de aprendizagem de máquina. Modelos que incorporaram as variáveis dependentes selecionadas mostraram métricas inferiores em comparação com aqueles que incorporaram todas as variáveis dependentes disponíveis. O modelo CatBoost destacou-se com resultados significativos, apresentando capacidade superior de ajuste aos dados. A seleção do modelo CatBoost se deu pela sua consistência e precisão, adaptabilidade aos dados e capacidade de mapeamento robusta. Portanto, é importante compreender a relação entre índices climáticos, produtividade e fatores geográficos, evidenciando a complexidade das interações climáticas com a fenologia da uva, e a necessidade de considerar diferentes regiões para entender os impactos das variabilidades climáticas na produção vitivinícola brasileira.

Palavras-chave: algoritmos otimizados, CatBoost, fenologia da videira, regiões viníferas, Python, variáveis climáticas.

2.1. Introdução

A videira (*Vitis vinifera* L.) destaca-se como uma frutífera de proeminência econômica em escala global, ocupando a quarta posição entre as principais frutíferas em termos de produção mundial (Aguiar et al., 2023; Zang et al., 2024). Em 2021, foi cultivada em 7 milhões de hectares (Mha), resultando em uma produção total de uvas de 78 megatoneladas (Mt) (Andrade et al., 2023), mais de 57% dessa produção foi direcionada para a indústria vinícola.

A Europa é a líder mundial na produção de vinho, abrangendo aproximadamente 63% da produção mundial em 2020, conforme indicado pela Organização Internacional da Vinha e do Vinho (OIV, 2021). Os cinco principais países contribuintes para esse feito são a Itália, com 49,1 milhões de hectolitros (mhl); França, com 46,6 mhl; Espanha, com 40,7 mhl; Alemanha, com 8,4 mhl; e Portugal, com 6,4 mhl (Yang et al., 2022). Em 2022, estimativas indicaram que a produção mundial de vinho variou entre 258 e 263 mhl, com os países europeus – Itália, França e Espanha – emergindo como os três principais produtores (Damásio et al., 2023; OIV, 2022).

Em todo o mundo, a viticultura e a vinificação representam atividades de extrema relevância, exercendo impactos importantes nas economias locais e regionais (Costa et al., 2015). No Brasil, mais de 75 mil hectares de vinhedos foram colhidos em 2022, conforme dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2022). A importância socioeconômica da viticultura no país é destacada por um mercado nacional de vinhos avaliado em BRL 20,3 bilhões, equivalente a cerca de USD 4 bilhões (Andrade et al., 2023; Mello; Machado, 2020).

A qualidade potencial das uvas, aliada aos fatores de produtividade das videiras, desempenham um papel importante no impulsionamento da receita proveniente da produção vinícola (Ohana-Levi et al., 2024). Um sistema complexo e interativo, composto por práticas climáticas e de manejo, exerce uma influência significativa sobre o desenvolvimento da videira (Costa et al., 2015). Este sistema evoluiu para o conceito de *terroir*, definido como “uma área na qual o conhecimento coletivo das interações entre o ambiente físico e biológico identificável e as práticas vitivinícolas aplicadas se desenvolvem, fornecendo características distintivas para os produtos originários desta área” (OIV, 2010; Costa et al., 2015).

O clima é reconhecido como o componente primordial do *terroir*. Um dos mais importantes limiares climáticos é a temperatura, que impulsiona a duração dos estádios fenológicos da videira (Kose, 2014). As altas temperaturas afetam a fotossíntese, a transpiração e a composição da baga de uva (Andrade et al., 2023; Venios et al., 2020), resultando no aumento dos níveis de açúcares, na diminuição dos ácidos orgânicos e na alteração da composição de metabólitos secundários, como antocianinas e precursores de aroma (Arrizabalaga-Arriazu et al., 2020; Cabodevilla et al., 2024).

Do ponto de vista climático, baixas temperaturas durante a floração, eventos de chuvas e alta incidência de geadas na primavera são determinantes para elevados índices de queda de flores e um desenvolvimento inadequado do conjunto frutífero (Ferlito et al., 2023). Esses eventos climáticos adversos exercem influência sobre o estado de dormência do botão, conforme discutido por Anzanello (2019) e North et al. (2022). A precipitação é outro elemento importante, que controla amplamente a disponibilidade de água do solo, afetando o uso da água da videira (Costa et al., 2015; Ferreira et al., 2012).

Juntamente com a umidade, temperatura e a radiação solar, o vento pode ser usado para estimar a evapotranspiração do dossel da videira, refletindo assim o uso de água pelas plantas (Andrade et al., 2023; Jenkins et al., 2023). Além disso, é importante reconhecer que as práticas enológicas exercem uma influência significativa na qualidade do vinho (Costa et al., 2015).

Como tal, embora uma modificação dos tipos de vinho atualmente estabelecidos possa ocorrer, os impactos socioeconômicos da variabilidade climática na qualidade do vinho podem ser bastante diversos (Fraga et al., 2017). A urgência está na decifração dos mecanismos subjacentes à adaptação da videira em face dessas condições em evolução para facilitar a implementação de estratégias de mitigação de curto e longo prazo (Damásio et al., 2023).

A aplicação de modelos estimativos no cultivo de frutas emerge como uma estratégia promissora para aprimorar a eficácia dos processos de tomada de decisão (Andrade et al., 2023). Como resultado, tem havido um interesse considerável da indústria no desenvolvimento de modelos para a estimação de produtividade para videiras, conforme evidenciado por estudos recentes (Arab et al., 2021; Barriguinha et al., 2022; Kadbhane e Manekar, 2021). A tomada de decisão baseada em informações da gestão de campo e práticas precisas para otimização da produtividade podem promover a sustentabilidade a longo prazo da produção de uva e vinho, assegurando a viabilidade econômica dos vinhedos (Azorín and García, 2020; Ohana-Levi et al., 2024).

A abordagem de aprendizado de máquina (ML) é usada como uma estratégia para obter previsões de produtividade em diversos cultivos e regiões em todo o mundo. Em Bangladesh, a utilização de algoritmos supervisionados, Random Forest (RF), Support Vector Machine (SVM) e CatBoost (CB), se destacou na previsão da produção de arroz, batata e trigo (Hasan et al., 2023). Na China, a pimenta vermelha de Sichuan (*Zanthoxylum bungeanum*) foi objeto de estimativa utilizando a abordagem do SVM (Zhang et al., 2024). Além disso, estudos voltados para o estresse abiótico no milho revelaram a eficácia do uso de ML na estimação dos resultados (Nazari et al., 2024). Em um contexto mais amplo, pesquisadores concentraram seus esforços na previsão da produção de batata e milho na Irlanda, empregando métodos como RF e SVM para analisar dados de diversas áreas (Kuradusenge et al., 2023).

No que tange a produtividade e à qualidade, diversas pesquisas têm sido empreendidas para discernir relações estatísticas entre a produção da videira e variáveis ambientais específicas. Para as regiões portuguesas do Porto e Minho, foram encontradas relações estatisticamente significativas entre a produtividade da videira e variáveis como as temperaturas médias mensais ou totais de precipitação (Costa et al., 2015; Fraga et al., 2014; Santos et al., 2011).

Durante os últimos anos, foram feitos esforços para utilizar técnicas de modelagem complexas para analisar efeitos multivariados nos componentes de produtividade da videira (Ohana-Levi et al., 2024; Ohana-Levi et al., 2019; Sirsat et al., 2019). Esses estudos, geralmente, aplicam algoritmos de ML para geração de modelos quando grandes conjuntos de dados multidimensionais são considerados (Barriguinha et al., 2022; Ohana-Levi et al., 2024; Ohana-Levi et al., 2022). O campo de ML emerge como um subconjunto da inteligência artificial que prosperou no contexto recente de tecnologias voltadas para grandes volumes de dados e computação de alto desempenho (Andrade et al., 2023; Liakos et al., 2018).

Em geral, os modelos de aprendizado de máquina (ML) empregam dados históricos relacionados aos atributos da videira como variáveis dependentes, ao passo que os elementos do *terroir* atuam como variáveis independentes (Costa et al., 2015). Tais como a Regressão Linear Múltipla (RLM), que se destaca como um modelo de ML simples e preciso, proporcionando uma relação linear entre as entradas e as saídas (Ehteram and Banadkooki, 2023; Rahnama and Abkooh, 2023). Em contrapartida, algoritmos avançados de ML, como o RF, têm suas próprias funções internas que podem ser usadas para seleção e regressão de variáveis simultaneamente (Luo et al., 2021; Chen et al., 2020).

Muitos pesquisadores têm recorrido a modelos mais avançados, como Support Vector Machine (SVM), para estimar a produtividade agrícola (Hasan et al., 2023), devido a sua acurácia. Destaca-se, também, o modelo CatBoost (CB) pelo seu dimensionamento de variáveis adaptativas, tratamento de valores ausentes e robustez, proporcionando, assim, um aumento na precisão das estimativas e uma redução na complexidade da implementação (Zhai et al., 2023).

Investigações prévias buscaram estimar a produtividade da uva em diversas regiões vinícolas, como evidenciado por Arab et al. (2021) na principal região de

cultivo de uvas na província de Cabul, Afeganistão; Barriguinha et al. (2022) na região vinícola demarcada do Douro, a mais antiga região demarcada por vinho do mundo, localizada no nordeste de Portugal; e Sirsat et al. (2019) com estudo desenvolvido na região vitivinícola do Alentejo, sul de Portugal. Para a região de Lisboa, estudos conduzidos por Malheiro et al. (2013) empregaram modelos de regressão linear para evidenciar a relação entre os estádios fenológicos e as variáveis dependentes, como temperatura do ar.

Nesse contexto, buscou-se desenvolver modelos de aprendizado de máquina voltados à estimação da produtividade em distintas regiões vitivinícolas de relevância no Brasil.

2.2. Material e Métodos

2.2.1. Áreas de estudo

A pesquisa englobou as sete mais importantes regiões vitivinícolas no Brasil, cada uma composta por diferentes municípios (Tabela 1).

Tabela 1. Caracterização de cada área de estudo.

Regiões	Municípios	Latitude	Longitude	Altitude (m)	Área (ha)
Campanha	Dom Pedrito	30°58'57.67" S	54°40'24.32" W	131	95
Gaúcha	Rosário do Sul	30°15'02.20" S	54°55'00.81" W	132	17
- CG	Sant'Ana do Livramento	30°53'17.09" S	55°31'35.07" W	208	48
(44365 km ²)	Uruguiana	29°45'30.26" S	57°05'10.82" W	66	27
Altos Montes					
- AM	Flores da Cunha	29°01'45.73" S	51°10'53.15" W	756	4,82
(174 km ²)					
Farroupilha	Bento Gonçalves	29°10'00.15" S	51°31'01.15" W	690	4,47
- FA	Caxias do Sul	29°13'22.08" S	51°09'58.98" W	817	3,81
(379 km ²)	Farroupilha	29°13'25.77" S	51°20'44.18" W	770	3,80
Vale dos Vinhedos					
- VV	Garibaldi	29°15'27.27" S	51°31'23.09" W	613	2,33
(72 km ²)					
Vales das Uvas	Morro da Fumaça	28°39'14.40" S	49°12'43.26" W	18	54
Goethe	Orleans	28°21'31.15" S	49°17'17.54" W	132	17
-VVG	Urussanga	28°31'17.54" S	49°19'15.16" W	49	91
(459 km ²)					
Vinhos de	Água Doce	26°59'46.87" S	51°33'20.95" W	847	52
Altitude	Arroio trinta	26°55'49.58" S	51°20'10.25" W	840	10

- HW (19676 km ²)	Caçador	26°46'58.77" S	50°59'53.16" W	920	387
	Curitibanos	27°17'34.24" S	50°34'30.23" W	987	7
	Fraiburgo	27°01'24.94" S	50°55'20.45" W	1,048	29
	Pinheiro Preto	27°02'20.02" S	51°12'36.41" W	696	413
	Rio das Antas	26°53'54.73" S	51°04'30.13" W	830	78
Vinhos de Bituruna - BW (1288 km ²)	Bituruna	26°09'24.87" S	51°33'17.51" W	900	30

A seleção das regiões vitivinícolas (Figura 1) compreendeu 20 municípios de destaque no cenário vitivinícola nacional conforme identificado pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) (2024) (Tabela 1). Todas as áreas delineadas e destacadas possuem registro de Indicações de Procedência, atribuída pelo Instituto Nacional da Propriedade Industrial (INPI), e a região dos Vale dos Vinhedos também possui Denominação de Origem.




Figura 1. Mapa das principais regiões vinícolas do Brasil utilizadas no trabalho.

Conforme EMBRAPA (2024) a região denominada Campanha Gaúcha (CG) localizada no bioma Pampa no estado do Rio Grande do Sul (RS), destaca-se como a zona de maior calor e menor índice pluviométrico na região Sul do Brasil. Nesse contexto, os vinhedos, que tradicionalmente adotam o sistema de espaldeiras, são responsáveis pela produção de vinhos finos tranquilos brancos, rosados e tintos, além de espumantes naturais (Apêndice – Tabela A1). A produção de vinhos nesta região é

estritamente vinculada à área delimitada, garantindo que 100% das uvas utilizadas sejam cultivadas no local. O perfil climático vitícola, classificado pelo Sistema de Classificação Climática Multicritérios Geovíticola (CCM) (Tonietto and Carbonneau, 2004), revela um ambiente térmico quente, com gradiente térmico ascendente de sudeste para noroeste, refletindo o impacto da continentalidade. As noites temperadas e o índice subúmido complementam esse panorama climático, corroborando com a classificação climática de Köppen (Cfa – clima subtropical), conforme descrito por Alvares et al. (2014).

A área geográfica denominada Altos Montes (AM) representa a demarcação que engloba as elevações mais proeminentes nas indicações geográficas da Serra Gaúcha, alcançando altitudes que atingem até 885 m. Caracteriza-se por apresentar temperaturas mais moderadas em relação às regiões circundantes. Os produtos oriundos dessa localidade incluem espumantes finos brancos e rosados, moscatel espumante, além de vinhos finos tranquilos brancos, rosados e tintos secos (Apêndice – Tabela A1). Para elaboração desses vinhos, no mínimo, 85% das uvas utilizadas devem ser cultivadas dentro dos limites da área delimitada. O clima predominante, categorizado como mesotérmico do tipo temperado, é caracterizado por um perfil vitícola que varia de temperado quente a temperado no Sistema CCM, apresentando noites temperadas e condições de umidade significativas.

A região Farroupilha (FA) caracteriza-se pela produção exclusiva de vinhos finos moscatéis (Apêndice – Tabela A1). A elaboração destes vinhos está restrita ao uso de uvas das variedades moscatéis autorizadas, as quais devem ser cultivadas na área demarcada. Esta localidade está inserida no domínio do clima mesotérmico, especificamente do tipo temperado. O clima vitícola na região, segundo o Sistema CCM, é identificado como temperado quente, caracterizado por noites temperadas e níveis significativos de umidade, com uma elevada propensão a geadas tardias. A presença desse risco climático destaca-se como um fator relevante na escolha pela cultivar Moscato Branco, reconhecida como uma cultivar de brotação tardia, adaptando-se de maneira eficaz às condições locais (Afavin, 2005).

A região Vale dos Vinhedos (VV) ostenta o título de primeira indicação geográfica reconhecida no Brasil. As especialidades oriundas desta localidade incluem vinhos tranquilos brancos e tintos, bem como vinhos espumantes finos

(Apêndice – Tabela A1). Os espumantes finos são elaborados exclusivamente pelo “Método Tradicional”, caracterizado pela segunda fermentação na garrafa. Adicionalmente, os produtos que passam por processo de envelhecimento em madeira são submetidos exclusivamente a barris de carvalho. Sob o domínio do clima mesotérmico do tipo temperado, essa região é marcada por um perfil climático vitícola caracterizado como temperado quente. Este último apresenta noites que variam de temperadas a quentes, acompanhadas de níveis significativos de umidade, conforme delineado pelo Sistema CCM.

A região Vales da Uva Goethe (GGV) situada entre as encostas da Serra Geral e o litoral Sul Catarinense, constitui uma área de produção vitivinícola. Os vinhedos, de modo tradicional, são cultivados em latadas, proporcionando um cenário específico para a elaboração de produtos distintos. Os itens produzidos nesta localidade incluem vinho branco, vinho leve branco, espumante e vinho licoroso (Apêndice – Tabela A1). A singularidade dessa região reside no uso exclusivo de uvas da variedade Goethe, que tem sido cultivada na região desde o início do século XX. A produção de espumantes na área pode ocorrer mediante a aplicação dos métodos tradicional ou *charmat*. No que concerne ao clima, é classificado como subtropical úmido. Este perfil climático é caracterizado pela ausência de uma estação seca e por verões marcados por temperaturas elevadas, conformando assim um ambiente propício para o cultivo vitícola na região.

A região vitivinícola denominada Vinhos de Altitude (HW) encontram-se situada na porção mais fria e elevada do sul do Brasil. Os vinhedos nessa localidade são concentrados em altitudes que variam entre 900 m a 1,400 m, sendo cultivados de maneira convencional em espaldeiras ou no formato de Y. Os produtos resultantes dessa região abrangem vinho fino, nobre e licoroso, além de espumante natural e vinho moscatel espumante (Apêndice – Tabela A1). É imperativo destacar que, para a elaboração desses vinhos, a totalidade das uvas utilizadas deve ser provenientes da área delimitada, especialmente de vinhedos localizados em altitudes superiores a 840 m. Essa diretriz reforça a ênfase na influência específica das condições climáticas e altimétricas na composição dos produtos vinícolas.

A região Vinhos de Bituruna (BW) se destaca pelo cultivo dos vinhedos, empregando os sistemas de cultivo Y ou latada. Nesse contexto, são contemplados

os vinhos provenientes da *Vitis labrusca*, especialmente das variedades Bordô e Martha (Apêndice – Tabela A1). Os vinhos produzidos nesta região apresentam características marcantes, evidenciadas por uma coloração mais tinta, na tonalidade bordô, e um aroma acentuado de frutas tropicais. Tais atributos são intrínsecos às técnicas de cultivo, métodos de plantio da uva e procedimentos na produção do vinho adotados na região, os quais, em conjunto com as particularidades do microclima local conferem singularidade aos produtos vinícolas.

2.2.2. Dataset

Os registros anuais de produtividade da videira no período de 1982 a 2021, conforme divulgados pelo Sistema IBGE de Recuperação Automática (Sidra IBGE) (<https://sidra.ibge.gov.br/pesquisa/pam/tabelas>), foram utilizados para a realização deste estudo. Os dados meteorológicos históricos diários dos municípios foram coletados no sistema NASA-Power (<https://power.larc.nasa.gov/data-access-viewer/>). É relevante destacar que essa base de dados é amplamente empregada, a exemplo da pesquisa realizada por Jamei et al. (2022).

As variáveis de entrada consideradas compreenderam a temperatura média do ar (T, em °C), temperatura máxima (T_{max}, em °C), temperatura mínima (T_{min}, em °C), irradiância solar global de onda curta (Q_g, em MJ m⁻² dia⁻¹), irradiância solar fotossinteticamente ativa (PAR, em MJ m⁻² dia⁻¹), precipitação (P, em mm dia⁻¹), umidade relativa (RH, em %), umidade do solo na zona radicular (SH, em N.U.), ao longo de uma série temporal de 39 anos. As variáveis radiação líquida na superfície da cultura (R_n, em MJ m⁻² dia⁻¹) e umidade absoluta (AH, em g água vapor⁻¹ m⁻³) foram calculadas de acordo com a Eq.1 e Eq.2, respectivamente.

$$R_n = (1 - r) \times Q_g - \left(1.35 \times \frac{Q_o}{Q_{oCORR}} - 0.35 \right) \times (0.35 - 0.14 \times \sqrt{es}) \times (5.67 \times 10^{-8}) \times \left(\frac{T_{max}^4 + T_{min}^4}{2} \right) \quad (1)$$

$$AU = \frac{2168 \times ea}{273.17 + T} \quad (2)$$

onde r é a fração refletida da radiação solar incidente, Q_o é a radiação solar extraterrestre em MJ m⁻² dia⁻¹, Q_{oCORR} é a correção para a radiação solar

extraterrestre em $\text{MJ m}^{-2} \text{ dia}^{-1}$, e_s é a pressão de vapor de saturação em kPa e e_a é a pressão de vapor real em kPa.

Com base nas variáveis meteorológicas adquiridas por meio do NASA-Power, a pesquisa procedeu à estimativa da evapotranspiração de referência (ET, em mm dia^{-1}) (Eq.3), empregando a equação de Penman-Monteith (PM). Na prática agrícola, o método de Penman-Monteith da FAO (FAO-PM), conforme delineado por Allen et al. (1998), destaca-se como a abordagem padrão para a estimação da taxa de evapotranspiração.

$$ET = \frac{0,408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0,34 u_2)} \quad (3)$$

onde Δ é a tangente à curva de saturação em $\text{kPa } ^\circ\text{C}^{-1}$, G é a densidade do fluxo de calor do solo em $\text{MJ m}^{-2} \text{ dia}^{-1}$, γ é a constante psicrométrica em kPa e u_2 é a velocidade do vento a 2 m de altura em m s^{-1} .

O conjunto de dados final, abrangendo, aproximadamente, 180.000 registros, foi constituído por 11 variáveis dependentes ao longo de 21 semanas de ciclo de cultivo da uva, contemplando 20 locais distintos, derivado de um período de observação de 39 anos.

2.2.3. Fenologia da videira

Sabe-se que para cada região estudada existe uma variação dos períodos dos estádios fenológicos devido às condições meteorológicas e ao manejo, e consequentemente para o ciclo total de produção, como relatado por vários autores (Figura 2). Entretanto, para facilidade no entendimento e discussão foi considerado período médio igual para todas as regiões.

	Aug	Sep	Oct	Nov	Dec	Jan	Phenological stadiums
Campanha Gaúcha - RS ¹	PR	SP	FL	FRB	FRP	MA	Pruning - PR
Altos Montes - RS ²	PR	SP	FL	FRB	FRP	MA	Sprouting - SP
Farroupilha - RS ³	PR	SP	FL	FRB	FRP	MA	Flowering - FL
Vineyards Valley - RS ⁴	PR	SP	FL	FRB	FRP	MA	Fructification (4 mm) - FRB
Goethe Grape Valleys - SC ⁵	PR	SP	FL	FRB	FRP	MA	Fructification (7 mm) - FRP
Highland Wines - SC ⁶	PR	SP	FL	FRB	FRP	MA	Fructification (7 mm) - FRP
Bituruna Wines - PR ⁷	PR	SP	FL	FRB	FRP	MA	Fructification (7 mm) - FRP
Average	PR	SP	FL	FRB	FRP	MA	Maturation - MA

Figura 2. Estádios fenológicos médios da videira para o sul do Brasil. Fontes: ¹Radünz et al. (2015); ²Chavarria et al. (2010); ³Mandelli et al. (2003); ⁴Filippon et al. (2017); ⁵Della Bruna (2021); ⁶Felippeto et al. (2021); ⁷Santos et al. (2007).

A duração média dos estádios fenológicos na escala semanal iniciou em agosto, considerado o período mais propício para a implementação do cultivo da videira na região sul do país. O ciclo completo se encerra em janeiro do ano subsequente. Compreendendo seis estádios fenológicos distintos, poda (PR), brotação (SP), floração (FL), frutificação, subdividida em frutificação com tamanho da baga 4 mm (FRB) e frutificação com tamanho da baga 7 mm (FRP), e maturação (MA). Cada estágio apresenta um intervalo médio para seu desenvolvimento, resultando em ciclo total de 21 semanas.

O início de cada uma destes seis estádios corresponde a simbologia proposta por Eichhorn e Lorenz (número E-L) (Coombe, 1995), a saber: Poda, EL-1; Brotação, EL-4; Floração, EL-19; Frutificação, EL-29 e EL-31.

2.2.4. Modelos de Aprendizado de Máquina

Os dados passaram por uma organização prévia, contemplando as seguintes etapas: 1. limpeza de dados: nesta fase, foram realizadas operações relacionadas a gestão de valores ausentes para as variáveis, por meio de análise de dados (regressão), e a tratamento de outliers para a target, utilizando médias dos valores anteriores e posteriores; 2. integração dos dados: considerando dois tipos distintos de dados, a saber, variáveis meteorológicas e produtividade; 3. redução da dimensionalidade: eliminação de dados desnecessários como duplicados e com variância muito baixa, importante para permitir a eficácia dos modelos de ML; e 4. padronização independente de dados. Para todos os modelos de ML, as variáveis dependentes foram as variáveis meteorológicas semanais, enquanto a variável independente foi a produtividade da uva (Figura 3).

Meteorological variables - Features															Target		
Pruning			Sprouting			Flowering			Frutication (4 mm)			Frutication (7 mm)			Maturation		
PR1	...	PR3	SP1	...	SP4	FL1	...	FL3	FRB1	...	FRB3	FRP1	...	FRP4	MA1	...	MA4
Qg-PR1	...	Qg-PR3	Qg-SP1	...	Qg-SP4	Qg-FL1	...	Qg-FL3	Qg-FRB1	...	Qg-FRB3	Qg-FRP1	...	Qg-FRP4	Qg-MA1	...	Qg-MA4
PAR-PR1	...	PAR-PR3	PAR-SP1	...	PAR-SP4	PAR-FL1	...	PAR-FL3	PAR-FRB1	...	PAR-FRB3	PAR-FRP1	...	PAR-FRP4	PAR-MA1	...	PAR-MA4
T-PR1	...	T-PR3	T-SP1	...	T-SP4	T-FL1	...	T-FL3	T-FRB1	...	T-FRB3	T-FRP1	...	T-FRP4	T-MA1	...	T-MA4
Tmax-PR1	...	Tmax-PR3	Tmax-SP1	...	Tmax-SP4	Tmax-FL1	...	Tmax-FL3	Tmax-FRB1	...	Tmax-FRB3	Tmax-FRP1	...	Tmax-FRP4	Tmax-MA1	...	Tmax-MA4
Tmin-PR1	...	Tmin-PR3	Tmin-SP1	...	Tmin-SP4	Tmin-FL1	...	Tmin-FL3	Tmin-FRB1	...	Tmin-FRB3	Tmin-FRP1	...	Tmin-FRP4	Tmin-MA1	...	Tmin-MA4
RH-PR1	...	RH-PR3	RH-SP1	...	RH-SP4	RH-FL1	...	RH-FL3	RH-FRB1	...	RH-FRB3	RH-FRP1	...	RH-FRP4	RH-MA1	...	RH-MA4
P-PR1	...	P-PR3	P-SP1	...	P-SP4	P-FL1	...	P-FL3	P-FRB1	...	P-FRB3	P-FRP1	...	P-FRP4	P-MA1	...	P-MA4
SH-PR1	...	SH-PR3	SH-SP1	...	SH-SP4	SH-FL1	...	SH-FL3	SH-FRB1	...	SH-FRB3	SH-FRP1	...	SH-FRP4	SH-MA1	...	SH-MA4
Rn-PR1	...	Rn-PR3	Rn-SP1	...	Rn-SP4	Rn-FL1	...	Rn-FL3	Rn-FRB1	...	Rn-FRB3	Rn-FRP1	...	Rn-FRP4	Rn-MA1	...	Rn-MA4
ET-PR1	...	ET-PR3	ET-SP1	...	ET-SP4	ET-FL1	...	ET-FL3	ET-FRB1	...	ET-FRB3	ET-FRP1	...	ET-FRP4	ET-MA1	...	ET-MA4
AU-PR1	...	AU-PR3	AU-SP1	...	AU-SP4	AU-FL1	...	AU-FL3	AU-FRB1	...	AU-FRB3	AU-FRP1	...	AU-FRP4	AU-MA1	...	AU-MA4

Yield (kg ha⁻¹)

Figura 3. Variáveis dependentes utilizadas nos modelos de aprendizagem de máquina para cada estágio fenológico: Qg (irradiância solar global de onda curta), PAR (irradiância solar fotossinteticamente ativa), T (temperatura média), Tmax (temperatura máxima), Tmin (temperatura mínima), RH (umidade relativa), P (precipitação), SH (umidade do solo na zona radicular), Rn (radiação líquida na superfície da cultura), ET (evapotranspiração de referência) e AU (umidade absoluta), e variável independente: produtividade.

Após a padronização dos dados, procedeu-se ao treinamento dos conjuntos de dados disponíveis. Destaca-se que a divisão convencional entre dados de treinamento e teste não foi realizada devido ao baixo número de dados de produtividades em alguns locais.

Com o propósito de otimizar os parâmetros desses modelos de forma semelhante para todas as regiões, procedeu-se uma pesquisa em grade com validação cruzada tripla, conforme usada em pesquisas de previsão de produtividade de pastagens (Paruelo et al., 2024) e estimação da produtividade do trigo (Shehzad et al., 2022). Essa abordagem de validação cruzada foi empregada para proteger a modelagem do overfitting, buscando assegurar robustez aos modelos.

O método convencional de ajuste de parâmetros para modelos de aprendizado de máquina (ML), *GridSearchCV* da biblioteca *scikit-learn* (Tabelas 2 e 3), foi empregado, constituindo-se em uma técnica robusta e eficaz para essa finalidade.

Todas as operações relacionadas aos algoritmos e à análise de dados foram executadas utilizando a linguagem de programação Python v.3.9.6, através do ambiente de desenvolvimento Jupyter Notebook. Para a implementação dos quatro algoritmos distintos de ML, a biblioteca Python Scikit-learn (versão 0.24.0) foi utilizada. Os modelos escolhidos compreendem a Regressão Linear Múltipla (RLM) (Scikit-learn: `LinearRegression`), Random Forest (RF) (Scikit-learn:

RandomForestRegressor), Support Vector Machine (SVM) (Scikit-learn: SVC) e CatBoost (CB) (CatBoostRegressor), sendo aplicados para a estimação da produtividade da videira.

Os modelos de Regressão Linear Múltipla (RLM), Random Forest (RF), Support Vector Machine (SVM) e CatBoost (CB) foram treinados com e sem seleção de variáveis dependentes, resultando em um total de oito modelos diferentes. Inicialmente, cada modelo foi treinado utilizando todas as variáveis dependentes. Em seguida, dentro de cada modelo, foi realizada uma seleção de variáveis dependentes e o modelo foi treinado novamente. No processo de seleção de variáveis dependentes, o método *stepwise forward* foi utilizado para a RLM, enquanto RF e CB utilizaram o método *feature_importances*, e SVM utilizou *permutation_importance*. O objetivo de treinar cada modelo duas vezes (todas variáveis dependentes e com as variáveis dependentes selecionadas) foi devido a uma tentativa de ajuste dos modelos com as novas variáveis dependentes.

2.2.4.1. Regressão Linear Múltipla (RLM)

A Regressão Linear Múltipla (RLM) é amplamente empregada na estimação de resultados de uma variável de resposta por meio de diversas variáveis explicativas. Este modelo, de natureza linear, utiliza coeficientes de regressão para estabelecer a relação entre as entradas e as saídas (Yates et al., 2023). Um modelo de Regressão Linear Múltipla (RLM) otimiza os coeficientes de regressão com o intuito de minimizar o erro de previsão, sendo menos suscetível a se ajustar excessivamente aos dados de treinamento, especialmente quando o número de dados disponíveis é pequeno em comparação ao número de características.

Contudo, devido a ausência de operadores avançados e ser sensível a outliers, a Regressão Linear Múltipla (RLM) pode apresentar limitações na previsão de fenômenos complexos e reduzir a precisão do modelo. Porém, é uma técnica valiosa para modelar relações lineares entre variáveis.

As principais bibliotecas em Python adotadas para este modelo foram: Pandas 2.0.3, Seaborn 0.13.2, Pingouin 0.5.3, Numpy 1.26.3 e Statsmodels.api 0.14.0. O teste Sequential Feature Selector (SFS) foi aplicado na análise.

2.2.4.2. Random Forest (RF)

O modelo de Random Forest (RF) demonstra um desempenho superior ao anterior durante o treinamento em sistemas complexos. É constituído por conjuntos de árvores de decisão, nos quais o espaço atribuído a cada variável é subdividido ainda mais em subespaços progressivamente menores, resultando em uma uniformização do espaço para cada dado/variável. Este modelo avalia variáveis de alto nível, proporcionando resultados acurados mediante a aplicação da técnica de aprendizado por conjunto (ensemble learning) (Elbeltagi et al., 2023).

A eficácia das combinações de árvores individuais e sua correlação são determinantes no erro de generalização do Random Forest (RF). As principais vantagens da técnica de RF incluem seu alto desempenho, redução de *overfitting*, uma menor susceptibilidade a valores de atributos e validação cruzada integrada (Karimi et al., 2020). Contribuindo para a redução da variância total do modelo, culminando em descobertas confiáveis.

O principal aspecto a ser ponderado ao introduzir dados neste algoritmo consiste na magnitude do conjunto de dados de treinamento e na quantidade de árvores geradas durante a fase de processamento. Os pontos negativos do RF compreendem o tamanho do modelo, que tende a ser maior em comparação com modelos lineares mais simples, e a sensibilidade aos parâmetros. O desempenho do RF pode variar com a escolha adequada dos parâmetros, como o *n_estimators* e a *max_depth*.

2.2.4.3. Support Vector Machine (SVM)

O Support Vector Machine (SVM) é um algoritmo de otimização fundamentado em aprendizado supervisionado com boa capacidade de generalização (Li et al., 2024), evidenciando resultados satisfatórios na abordagem de amostras de pequena dimensão e padrões de alta dimensionalidade, especialmente quando confrontados com não linearidades.

As vantagens do Support Vector Machine (SVM) incluem sua eficácia em cenários onde o número de dimensões é maior do que o número de amostras e sua versatilidade, pois permite a especificação de diferentes funções de Kernel para a

função de decisão (Tabelas 2 e 3). Por outro lado, as desvantagens do SVM compreendem as dificuldades em lidar com conjuntos de dados desbalanceados, onde uma classe é significativamente mais dominante que a outra, o que pode resultar em um peso desproporcional atribuído à classe dominante. Apesar de ser um algoritmo poderoso e versátil, é importante considerar suas limitações.

As principais bibliotecas em Python utilizadas para os modelos de Support Vector Machine (SVM) e Random Forest (RF) foram: Pandas 2.0.3, Seaborn 0.13.2 e Numpy 1.26.3.

2.2.4.4. CatBoost (CB)

O modelo de *Categorical Boosting*, conhecido como CatBoost (CB), representa uma evolução do algoritmo Gradient Boosted Decision Trees (GBDT). Sua concepção foi inicialmente introduzida pela equipe de pesquisadores e engenheiros do Yandex em 2017 e é fundamentada na estrutura de reforço, de acordo com Prokhorenkova et al. (2017).

O CatBoost (CB) é uma biblioteca de código aberto de alto desempenho para aumento de gradiente em árvores de decisão. Amplamente utilizado na realização de tarefas de classificação, previsão e recomendação, o CB oferece várias vantagens. Proporciona excelente qualidade sem ajuste de parâmetros, possui suporte a recursos categóricos, resultando em uma precisão aprimorada e previsões rápidas. No entanto, é importante destacar que o CB também apresenta desvantagens, como complexidade computacional e ser menos interpretável em comparação com modelos mais simples.

As bibliotecas em Python utilizadas nesse modelo foram semelhantes às utilizadas nos modelos de Support Vector Machine (SVM) e Random Forest (RF), com a adição da biblioteca CatBoost 1.2.

2.2.5. Métricas de avaliação e análise estatística

Os desempenhos, de cada método de modelagem, foram avaliados mediante a utilização da equação do R^2 ajustado (R^2_{ajustado}) (Eq. 4) e da equação de erro quadrático médio da raiz (RMSE) (Eq. 5), métricas de precisão e acurácia,

respectivamente. No entanto, torna-se necessário determinar previamente o coeficiente de determinação padrão (R^2) (Eq. 3) para o cálculo do R^2_{ajustado} .

$$R^2 = \left[\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \right]^2 \quad (3)$$

$$R^2_{\text{ajustado}} = 1 - \frac{(1 - R^2)(n-1)}{n-k-1} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad (5)$$

onde n representa o número total de amostras, x_i indica o i -ésimo valor medido, y_i denota o i -ésimo valor estimado e k o número de variáveis independentes no modelo.

O R^2 explica a proporção da variabilidade dos valores estimados pelo modelo. Um valor mais alto de R^2 sugere que o modelo realiza estimações mais precisas, estando mais próximo do valor real. O R^2_{ajustado} fornece uma visão mais robusta do desempenho do modelo em dados independentes, pois leva em consideração o n e o número de parâmetros do modelo. Em termos simples, essa métrica de precisão, indica o quão bem os dados se ajustam em torno da linha de regressão, ou seja, quão próximos os valores observados estão dos valores estimados pelo modelo.

O RMSE reflete o grau de dispersão dos erros entre os valores estimados e observados. Quanto menor o valor do RMSE, maior é a acurácia das estimativas em relação aos valores observados. Essa métrica de acurácia é definida como a medida dos valores estimados em relação aos valores observados.

Foram realizadas análises estatísticas utilizando o teste de Tukey a 0.05 de significância, para comparar os valores de produtividade entre as diferentes regiões estudadas, e correlação de Spearman, com o intuito de examinar a relação entre as variáveis e os estádios fenológicos.


2.3. Resultados

2.3.1. Variáveis climáticas e produtividade

A variação térmica ao longo do ciclo de crescimento da videira demonstrou um aumento progressivo nas variáveis temperatura média do ar (T), máxima (T_{max}) e

mínima (T_{min}) (Figura 4a; Figura 4b; Figura 4c, respectivamente), saindo de valores aproximados de 13 a 14 °C na poda (PR), chegando a 20 a 24 °C na maturação (MA), para a temperatura média do ar (T), na região Sul do Brasil. O estágio de PR iniciou em agosto, enquanto o estágio de MA se encerrou no início de janeiro (Figura 2).

A região da Campanha Gaúcha (CG) se destaca como a região vitivinícola mais quente do Sul do Brasil (Figura 4a; Figura 4b). Essa distinção é atribuída não apenas as elevadas temperaturas, mas também à baixa incidência de precipitação pluviométrica e baixa RH (Figura 5a). Destaca-se também a região dos Vale dos Vinhedos (VV) que apresentou T_{min} superior em comparação com as demais regiões (Figura 4c). Uma análise abrangente das variáveis R_n , Q_g e PAR de agosto a janeiro, em todas as regiões investigadas, revelou que as características relacionadas a estas variáveis exibiram uma variabilidade semelhante ao longo do tempo e em diferentes localidades (Figura 4d; Figura 4e; Figura 4f, respectivamente).






Figura 4. Relação entre variáveis dependentes, temperatura média (T), temperatura máxima (T_{max}), temperatura mínima (T_{min}), radiação líquida na superfície da cultura (R_n), irradiância solar global de onda curta (Q_g) e irradiância solar fotossinteticamente ativa (PAR), e os estádios fenológicos, poda (PR), brotação (SP), floração (FL), frutificação (4 mm) (FRB), frutificação (7 mm) (FRP) e maturação (MA).

Algumas diferenças foram encontradas nas regiões vitivinícolas investigadas durante o estudo (Figura 5) em relação à disponibilidade hídrica. A temporada de maior índice pluviométrico (P) ocorre durante o período de FL e o estágio inicial de FRB das videiras (Figura 5a), revelando-se propício para o desenvolvimento do cultivo, uma vez que nesse intervalo temporal é imprescindível que o solo disponibilize


uma maior quantidade de água, dado que a planta necessita suprir suas demandas metabólicas e gerar cachos de elevada qualidade. A concentração de precipitação nesses estádios críticos do ciclo de vida das videiras é essencial para garantir as condições ideais de crescimento e maturação dos frutos, contribuindo assim para o sucesso e qualidade da produção vitivinícola. As três regiões com maiores índices de P, a partir da FL, foram HW, BW e FA.

No estágio de poda (PR), a precipitação (P) inicia-se em níveis baixos, com elevada umidade relativa (RH), baixa taxa de evapotranspiração de referência (ET_o) e elevada humidade do solo (SH) (Figura 5a; Figura 5b; Figura 5d; Figura 5c, respectivamente). Esse cenário experimenta variações ao longo do ciclo de crescimento da planta, com a P atingindo níveis elevados durante a FL, a RH permanecendo alta, embora com tendência a decrescer, especialmente na região da CG. A ET_o aumenta consideravelmente, assim como a SH, porém, já se inicia uma trajetória descendente, fato que se reflete no estágio de MA.

Durante a maturação (MA), a precipitação (P) volta a aumentar, a umidade relativa (RH) permanece alta, mas com continuação com declínio para a região da Campanha Gaúcha (CG). Simultaneamente, a ET_o registra um acréscimo notável. Ressalta-se, ainda, a região da CG, onde a SH diminui, delineando assim dois grupos distintos: o primeiro englobando as regiões de FA e HW, caracterizadas por uma maior umidade, e o segundo compreendendo as demais regiões estudadas, a saber, CG, AM, VV, GGV e BW, que apresentam uma menor umidade (Figura 5c).

Na região da Campanha Gaúcha (CG), verifica-se uma correlação inversa entre a umidade relativa (RH) em níveis mais baixos e a evapotranspiração de referência (ET_o) em níveis mais elevados. Esse fenômeno pode ser explicado pelo processo de perda de água, que ocorre tanto na superfície do solo quanto na planta, e é direcionado para a atmosfera. Em situações de reduzida RH, a tendência é que a taxa de ET_o seja mais pronunciada (Figura 5b; Figura 5d).

O comportamento climatológico nas regiões de Farroupilha (FA) e Altos Montes (AM) foi similar em todas as variáveis dependentes analisadas (Figura 4; Figura 5). Além disso, as variáveis de radiação (R_n, Q_g e PAR) apresentaram valores semelhantes para as três regiões, incluindo a dos VV.






Figura 5. Relação entre as variáveis dependentes, precipitação (P), umidade relativa (RH), umidade do solo na zona radicular (SH), evapotranspiração de referência (ET_o), e umidade absoluta (AH), e os estádios fenológicos, poda (PR), brotação (SP), floração (FL), frutificação (4 mm) (FRB), frutificação (7 mm) (FRP) e maturação (MA).

A menor produtividade obtida foi na região da Campanha Gaúcha (CG) (Figura 6) e pode ser atribuída a uma interação complexa das variáveis dependentes, destacando-se notadamente as elevadas temperaturas experimentadas durante o ciclo fenológico da uva. A T_{max} da CG foi maior que a partir do estágio da FL (Figura 4b), essa inferência encontra respaldo na análise comparativa com outras regiões, em que se constata uma relação inversa entre produtividade e temperatura. Destaca-se a disparidade significativa na produtividade entre a região da CG e outras localidades (Figura 6), reforçando a influência negativa das condições térmicas na produção vinícola.

As regiões de Altos Montes (AM), Farroupilha (FA) e Vale dos Vinhedos (VV) (Figura 6) apresentaram semelhanças na produtividade pela análise de Tukey. Isto pode ser parcialmente atribuída à proximidade geográfica entre essas áreas (Figura 1), indicando uma homogeneidade de condições ambientais, a saber: T, T_{max}, T_{min}, P, RH, SU e AU, das regiões de AM e FA (Figura 4a; Figura 4b; Figura 4c; Figura 5a; Figura 5b; Figura 5c; Figura 5e, respectivamente), RN, Qg, PAR e ET_o, das regiões de AM, FA e VV (Figura 4d; Figura 4e; Figura 4f; Figura 5d, respectivamente) que pode contribuir para a uma mesma produtividade.




Figura 6. Produtividade da videira nas regiões vinícolas, Altos Montes – AM (RS), Farroupilha – FA (RS), Vale dos Vinhedos – VV (RS), Vinhos de Altitude – HW (SC), Vales da Uva Goethe – GGV (SC), Vinhos de Bituruna – BW (PR) e Campanha Gaúcha – CG (RS). As letras indicam o resultado da análise de Tukey no nível de significância de 0,05.

Uma síntese da variabilidade climática e agrônômica ao longo dos diferentes estádios fenológicos da videira, englobando todas as regiões estudadas, é relevante.

A região da Campanha Gaúcha (CG), conhecida como a principal área vitivinícola no sul do Brasil, destaca-se pelo seu macroclima propício à adaptação de diversas variedades de videira (Apêndice – Tabela A1), desde as mais precoces até as mais tardias. Esse cenário climático singular contribui para a produção de vinhos distintos, dotados de uma identidade própria. Os verões ensolarados, associado ao cultivo em espaldeira, viabilizam a produção de uma ampla gama de cultivares, as quais encontram na região condições ideais para atingir completa maturação das uvas destinadas à produção de vinhos finos (Tonietto et al., 2022).

No segmento de vinhos brancos, é notável a presença de uma moderada acidez, atribuído aos dias e noites quentes de verão, proporcionando um bom equilíbrio de sabor (Tonietto et al., 2022), entre os tintos, destaca-se a variedade Tannat, cuja excelência na maturação (MA) é notável nas condições do bioma da Campanha Gaúcha (CG), particularmente devido ao seu clima e solo distintivos. A prática da viticultura nesta área fundamenta-se em um seleto número de cultivares francesas adaptadas ao clima frio, incluindo Chardonnay, Sauvignon Blanc e Pinot

Noir. Investigações sobre com Cabernet Sauvignon na CG foram abordadas em publicações relevantes (Brunetto et al., 2007; Silveira et al., 2023). As regiões de AM e VV possuem cultivares em comum com a CG, tais regiões têm uma tradição vinícola estabelecida e são conhecidas pela produção de vinhos de qualidade, com uma ampla variedade de castas cultivadas.

A região de Altos Montes (AM) é caracterizada por um clima temperado com influências continentais, a região experimenta verões quentes e invernos frios, criando uma boa amplitude térmica diária para o desenvolvimento das uvas. Os vinhos originários dessa refletem as características atribuídas pelas variáveis da Serra Gaúcha, destacando-se pela sua expressão de *terroir* e pela variedade de estilos de vinhos. Relevante no segmento dos vinhos brancos a produção de Riesling Itálico, Chardonnay e Gewürztraminer (Apêndice – Tabela A1). No cenário dos tintos, sobressaem-se o Merlot e o Cabernet Franc. Além destas cultivares, diversos outros varietais autorizados, como o Pinot Noir, desenvolvem boa coloração na região demarcada, que se molda às peculiaridades climáticas e geográficas dessa região (Tonietto; Falcade, 2013).

Na região de Farroupilha (FA), além do clima ser influenciado pela proximidade com a Serra Gaúcha, o atributo preponderante que determina as características distintivas dos vinhos dessa região é a utilização de cultivares moscatéis (Apêndice – Tabela A1). Dentre as diversas cultivares, cultivadas de forma tradicional, destaca-se a Moscato Branco. Cabe ressaltar que, segundo pesquisa conduzida pela EMBRAPA (Tonietto et al., 2022) a Moscato Branco é atualmente exclusivamente cultivada no território brasileiro, inexistindo registros de sua produção em outros países.

A viticultura na região dos Vale dos Vinhedos (VV) baseia-se em um conjunto de cultivares francesas, bem adaptadas ao clima frio, incluindo Pinot Noir (Apêndice – Tabela A1). Os invernos são moderadamente frios, mas não extremos, permitindo um período de dormência adequado para as vinhas. E os verões são quentes, com temperaturas médias elevadas, proporcionando condições ideais para o amadurecimento das uvas. Dentre as variedades cultivadas, utilizando cultivo em espaldeiras, no qual facilita a exposição ao sol e circulação do ar, incluem-se aquelas com histórico robusto de produção e aptidão às condições locais, como a Merlot, e aquelas cujo plantio mais recente revelou um notável potencial enológico, como

Tannat, Cabernet Sauvignon e Chardonnay. Investigações científicas foram conduzidas no âmbito da viticultura, particularmente em relação a variedade Merlot (Alba et al., 2017) e Cabernet Sauvignon (Santos et al., 2010) no contexto dos VV.

As cultivares e os estilos de vinho produzidos na região dos Vales da Uva Goethe (GGV) contribuem para a riqueza e reputação dessa região como uma área vinícola de destaque no Brasil. Possui estações bem definidas, com verões quentes e úmidos, enquanto os invernos são frios e secos. A amplitude térmica diária favorece a maturação das uvas. Os vinhos produzidos a partir das variedades Goethe, Goethe Primo e Goethe Cristal (Apêndice – Tabela A1) são apreciados por sua versatilidade e capacidade de expressar características únicas do *terroir* da região. As regiões de GGV e HW possuem características climáticas e geográficas semelhantes, como clima temperado com influências marítimas e áreas montanhosas.

A prática da viticultura na região de Vinhos de Altitude (HW) fundamenta-se em um número de variedades de uva de origem francesa, especialmente adaptadas às condições climáticas frias, destacando-se as variedades Chardonnay, Sauvignon Blanc e, sobretudo, Pinot Noir (Apêndice – Tabela A1) (Brighenti et al., 2013). Suas altitudes elevadas proporcionam maiores amplitudes térmicas diárias por registrarem temperaturas mais baixas durante a noite. Essas baixas temperaturas favorecem a maturação mais lenta das uvas, resultando em vinhos com maiores concentrações de aromas e sabores. A região de HW e AM compartilham características semelhantes devido ao seu relevo montanhoso e altitudes elevadas, em comparação com as outras regiões.

A região de Vinhos de Bituruna (BW) é localizada em uma área propícia para o cultivo de videiras, permitindo um amadurecimento gradual das uvas e a preservação da acidez natural, fundamental para a qualidade dos vinhos. As variedades Bordô e Martha (Apêndice – Tabela A1) contribuem para a diversidade dos vinhos produzidos na região. Possui clima subtropical úmido, com invernos frios e geadas ocasionais. Os verões são quentes e chuvosos, com alta umidade relativa. Tanto a região de BW quanto o GGV as condições climáticas se assemelham, pois variam entre verões quentes e invernos frios, proporcionando um ciclo de crescimento adequado para as videiras.

2.3.2. Correlação de Spearman entre variáveis climáticas e produtividade

Este estudo conduziu uma análise de correlação visando examinar as relações entre uma variável dependente, a produtividade, e diversas variáveis independentes, nomeadamente temperatura média (T), temperatura máxima (Tmax), temperatura mínima (Tmin), precipitação (P), radiação líquida na superfície da cultura (Rn), umidade absoluta (AH), irradiância solar global de onda curta (Qg), irradiância solar fotossinteticamente ativa (PAR), umidade relativa (RH), umidade do solo na zona radicular (SH) e evapotranspiração de referência (ETo), ao longo do ciclo fenológico da videira (Apêndice – Figura A1). A utilização da correlação de Spearman proporcionou uma compreensão mais aprofundada das interações entre as variáveis investigadas.

As três variáveis de maior incidência na análise de correlação foram irradiância solar fotossinteticamente ativa (PAR), umidade relativa (RH) e precipitação (P) (Figura 7h).

A Campanha Gaúcha (CG) apresenta correlações positivas entre a radiação líquida na superfície da cultura (Rn) e os estádios de frutificação, com coeficientes de +0,11 e +0,09 (Figura 7a). A análise revela um aumento notável nos valores de Rn, Qg e PAR desde o estágio de SP até a conclusão do ciclo (Figura 4d; Figura 4e; Figura 4f). Essa tendência destaca que elevadas temperaturas podem resultar em estresse térmico nas plantas, enquanto níveis inadequados de radiação solar podem limitar tanto a fotossíntese quanto o desenvolvimento do cultivo, como visto na produtividade da região da CG (Figura 6).

Adicionalmente, é possível verificar correlações negativas significativas durante os períodos de floração (FL), frutificação com 4 mm e 7 mm (FRB e FRP, respectivamente) em relação à temperatura média (T), com valores de -0,19, -0,16 e -0,27, respectivamente (Figura 7a). Em tais estádios, a sensibilidade à temperatura pode exercer impactos adversos na formação das flores e no desenvolvimento dos frutos. A CG é caracterizada por um clima continental, evidenciado por invernos frios e verões quentes. Essa variação sazonal exerce influência significativa no desenvolvimento das uvas e, consequentemente afetando os períodos críticos do cultivo.

Na região de Altos Montes (AM), a precipitação (P) apresentou uma correlação positiva significativa de +0,40 durante o estágio de brotação (SP), e de +0,16 no estágio de frutificação (FRP) (Figura 7b). Investigações dedicadas à análise da variedade Cabernet Sauvignon (Apêndice – Tabela A1) revelaram que a produtividade na colheita é intrinsecamente dependente da quantidade de água recebida pelas vinhas no início da temporada (Yu et al., 2020), especialmente em vinhedos sujeitos a regimes pluviométricos (Pérez-Álvarez et al., 2021). Por outro lado, a variável PAR exibiu correlações negativas notáveis de -0,40 durante o estágio de SP e de -0,26 durante o estágio de FL. Destaca-se a relevância da quantidade de radiação solar que incide na superfície da planta, sendo um fator importante para seu crescimento vegetativo.

Na região de Farroupilha (FA), as temperaturas foram positivas em diferentes estádios fenológicas, com os valores de temperatura máxima (Tmax) na poda (PR) e maturação (MA) apresentando incrementos de +0,28 e +0,23, respectivamente (Figura 7c). Além disso, a variável T também revelou uma correlação positiva significativa durante o estágio de FL, registrando +0,22.

Na região de Vale dos Vinhedos (VV), a temperatura mínima (Tmin) apresentou correlação positiva durante o estágio de floração (FL) com um coeficiente de correlação de +0,34 (Figura 7d). A Tmax apresentou correlação negativa durante o estágio de FRB com um coeficiente de -0,15. As variáveis de P e Rn apresentaram correlação positiva (+0,45 e +0,17, respectivamente) durante os estádios de SP e FRP.

Na região de Vales da Uva Goethe (GGV), a temperatura mínima (Tmin) obteve correlação positiva (+0,34) (Figura 7e). A variável PAR, por sua vez, apresenta uma correlação negativa notável desde o estágio de SP até o estágio de MA. Este padrão sugere que o excesso de radiação solar durante esse período pode induzir estresses nas plantas. Níveis elevados de radiação podem ocasionar danos fotoinibitórios, comprometendo a eficiência da fotossíntese e o desenvolvimento das uvas.

Na região de Vinhos de Altitude (HW), destaca-se a correlação positiva da temperatura máxima (Tmax) com o estágio de floração (FL), evidenciando um coeficiente de +0,31 (Figura 7f). Por outro lado, a P apresentou uma correlação negativa durante o estágio de FL, registrando um coeficiente de -0,07.

Na região de Vinhos de Bituruna (BW) houve uma correlação positiva para radiação líquida na superfície da cultura (R_n) e temperatura média (T) (Figura 7g). Ao passo que, a variável RH apresentou correlação negativa durante os estádios de FRB, FRP e MA, com valores de -0,38, -0,26 e -0,24, respectivamente. Uma correlação negativa da SH durante o estágio de FL também foi obtida.

a) Campanha Gaúcha - CG (Rio Grande do Sul State)

	Pruning (PR)	Sprouting (SP)	Flowering (FL)	Frutification (4 mm - FRB)	Frutification (7 mm - FRP)	Maturation (MA)
T			-0.19	-0.16	-0.27	
Tmax						
Tmin						-0.23
Rn				+0.11	+0.09	
Qg						
PAR						
P		+0.07	+0.09			
RH						+0.12
SH	-0.20	-0.13				
ET	+0.14					
AH						

b) Altos Montes - AM (Rio Grande do Sul State)

	Pruning (PR)	Sprouting (SP)	Flowering (FL)	Frutification (4 mm - FRB)	Frutification (7 mm - FRP)	Maturation (MA)
T						
Tmax						
Tmin						
Rn						
Qg						
PAR		-0.40	-0.26			
P		+0.40		-0.33	+0.16	
RH	-0.37		+0.16			
SH						-0.19
ET	+0.26			+0.50		+0.36
AH					-0.24	

c) Farroupilha - FA (Rio Grande do Sul State)

	Pruning (PR)	Sprouting (SP)	Flowering (FL)	Frutification (4 mm - FRB)	Frutification (7 mm - FRP)	Maturation (MA)
T			+0.22			
Tmax	+0.28					+0.23
Tmin						
Rn					+0.11	
Qg						
PAR		-0.36	-0.21			
P		+0.35				
RH						
SH	-0.32			-0.17		-0.16
ET				+0.21		
AH					-0.18	

d) Vineyards Valley - VV (Rio Grande do Sul State)

	Pruning (PR)	Sprouting (SP)	Flowering (FL)	Frutification (4 mm - FRB)	Frutification (7 mm - FRP)	Maturation (MA)
T						
Tmax				-0.15		
Tmin			+0.34			
Rn					+0.17	
Qg						
PAR		-0.48	-0.29			
P		+0.45				
RH	-0.33					-0.19
SH						
ET	+0.32			+0.17		+0.27
AH					-0.17	

e) Goethe Grape Valleys - GGV (Santa Catarina State)

	Pruning (PR)	Sprouting (SP)	Flowering (FL)	Frutification (4 mm - FRB)	Frutification (7 mm - FRP)	Maturation (MA)
T						
Tmax						
Tmin			+0.34			
Rn	+0.18					
Qg						
PAR		-0.39	-0.30	-0.25	-0.34	-0.42
P	-0.14					
RH				+0.25	+0.23	
SH						
ET						
AH		+0.41				+0.19

f) Highland Wine - HW (Santa Catarina State)

	Pruning (PR)	Sprouting (SP)	Flowering (FL)	Frutification (4 mm - FRB)	Frutification (7 mm - FRP)	Maturation (MA)
T	+0.08			+0.12		
Tmax			+0.313			
Tmin						
Rn						
Qg						
PAR		-0.15		-0.09	-0.12	
P			-0.07		+0.07	
RH						-0.04
SH	-0.08					
ET						+0.10
AH		+0.17				

g) Bituruna Wines - BW (Paraná State)

	Pruning (PR)	Sprouting (SP)	Flowering (FL)	Frutification (4 mm - FRB)	Frutification (7 mm - FRP)	Maturation (MA)
T						
Tmax		+0.34			+0.21	+0.10
Tmin						
Rn	+0.11		+0.09	+0.16		
Qg						
PAR						
P						
RH		-0.21		-0.38	-0.26	-0.24
SH			-0.21			
ET						
AH	-0.19					

h) Number of occurrences of features




Figura 7. Correlação de Spearman entre as variáveis dependentes mais importantes (temperatura média (T), temperatura máxima (Tmax), temperatura mínima (Tmin), radiação líquida na superfície da cultura (Rn), irradiância solar global de onda curta (Qg), irradiância solar fotossinteticamente ativa (PAR), precipitação (P), umidade relativa (RH), umidade do solo na zona radicular (SH), umidade absoluta (AH) e evapotranspiração de referência (ET)) e produtividade ao longo dos estádios fenológicos da uva (a, b, c, d, e, f e g) nas diferentes regiões vinícolas estudadas. Resumo da análise de correlação (h).

2.3.3. Parâmetros de modelos de aprendizado de máquina

Os dados provenientes de todas as regiões foram consolidados em um único conjunto de dados, com o propósito de extrair uma resposta geral por meio da aplicação de modelos (Tabela 2). No contexto do modelo de RF, foram configurados os parâmetros de *max_depth*, variando de 10 a 50 em intervalos de 10 unidades. Dentre essas opções, o modelo foi treinado utilizando o valor de 30 para *max_depth*. De forma semelhante, utilizando o método *GridSearchCV* da biblioteca *scikit-learn*, foi feito para todos os parâmetros.

Tabela 2. Faixa de valores testados e valores otimizados dos parâmetros de cada modelo, para a região sul do Brasil (todas as regiões).

Modelos	Parâmetros	Faixa de valores testados	Valores otimizados
Random Forest (RF)	max_depth	[10,20,30,40,50]	30
	n_estimators	[30,35,40,45]	45
	min_impurity_decrease	[0,1,2,3]	0
	criterion	'friedman_mse','poisson'	friedman_mse
Support Vector Machine (SVM)	kernel	'linear','rbf','poly','sigmoid'	poly
	degree	[1,2,3,4,5]	3
	C	[6,7,8,9,10]	8
	gamma	[0.1]	0.1
	epsilon	[0.01,0.1,1.0]	0.01
	cache_size	[200]	200
	max_iter	[-1]	-1

CatBoost (CB)	iterations	[1000]	1000
	learning_rate	[0.03,.01]	0.1
	depht	[2,4,6,8,9,10]	9

Da mesma forma o processo de ajuste dos parâmetros foi feita para cada região produtora de uva no Brasil (Tabela 3).

Tabela 3. Intervalo de valores testados e valores otimizados dos parâmetros de cada modelo, em cada uma das regiões estudadas.

Modelos	Regiões	Parâmetros	Faixa de valores testados	Valores otimizados
Random Forest (RF)	Campanha Gaúcha	max_depth	[10,20,30,40,50]	20
		n_estimators	[30,35,40,45]	45
		min_impurity_decrease	[0,1,2,3]	0
		criterion	'friedman_mse','poisson'	friedman_mse
	Altos Montes	max_depth	[10,20,30,40,50]	10
		n_estimators	[30,35,40,45]	40
		min_impurity_decrease	[0,1,2,3]	0
		criterion	'friedman_mse','poisson'	friedman_mse
	Farroupilha	max_depth	[10,20,30,40,50]	20
		n_estimators	[30,35,40,45]	30
		min_impurity_decrease	[0,1,2,3]	3
		criterion	'friedman_mse','poisson'	friedman_mse
	Vale dos Vinhedos	max_depth	[10,20,30,40,50]	10
		n_estimators	[30,35,40,45]	30
		min_impurity_decrease	[0,1,2,3]	0
		criterion	'friedman_mse','poisson'	friedman_mse
	Vales da Uva Goethe	max_depth	[10,20,30,40,50]	10
		n_estimators	[30,35,40,45]	45
		min_impurity_decrease	[0,1,2,3]	0
		criterion	'friedman_mse','poisson'	friedman_mse
	Vinhos de Altitude	max_depth	[10,20,30,40,50]	10
		n_estimators	[30,35,40,45]	30
		min_impurity_decrease	[0,1,2,3]	3
		criterion	'friedman_mse','poisson'	poisson
	Vinhos de Bituruna	max_depth	[10,20,30,40,50]	20
		n_estimators	[30,35,40,45]	35
		min_impurity_decrease	[0,1,2,3]	0
		criterion	'friedman_mse','poisson'	friedman_mse
Support Vector Machine (SVM)	Campanha Gaúcha	kernel	'linear','rbf','poly','sigmoid'	rbf
		degree	[3,4,5]	3
		coef0	[1]	1
		C	[3000]	3000
		gamma	[0.1]	0.1
		epsilon	[0.01,0.1]	0.01
		cache_size	[400]	400
		max_iter	[10000]	10000
		kernel	'linear','rbf','poly','sigmoid'	poly
		degree	[1,2,3,4,5]	5
	Altos Montes	C	[6,7,8]	8
		gamma	[0.1]	0.1
		epsilon	[0.01]	0.01
		cache_size	[400]	400

CatBoost (CB)	Farroupilha	max_iter	[-1]	-1
		kernel	'linear','rbf','poly','sigmoid'	poly
		degree	[10]	10
		coef0	[2.2,2.5,3]	3
		C	[1000]	1000
	Vale dos Vinhedos	epsilon	[1000]	1000
		kernel	'linear','rbf','poly','sigmoid'	rbf
		degree	[10]	10
		C	[8200]	8200
		gamma	[0.1]	0.1
		epsilon	[.1,.2,.3,.4,.5,.6,.7,.8,.9,.95 ,.99]	0.99
		cache_size	[400]	400
	Vales da Uva Goethe	max_iter	[-1]	-1
		kernel	'linear','rbf','poly','sigmoid'	poly
		degree	[10]	10
		coef0	[3,3.5,4]	3
		C	[1]	1
	Vinhos de Altitude	cache_size	[400]	400
		kernel	'linear','rbf','poly','sigmoid'	rbf
		degree	[10]	10
		coef0	[1]	1
		C	[10000]	10000
		epsilon	[.01,.1,1]	1
		cache_size	[400]	400
	Vinhos de Bituruna	max_iter	[10000]	10000
		kernel	'linear','rbf','poly','sigmoid'	poly
		degree	[1,2,3,4,5]	5
		C	[6,7,8]	8
		gamma	[0.1]	0.1
		epsilon	[.01]	0.01
		cache_size	[400]	400
	Campanha Gaúcha	max_iter	[-1]	-1
		iterations	[1000]	1000
		learning_rate	[0.03,.1]	0.1
	Altos Montes	depht	[2,4,6,8,9,10]	2
		iterations	[1000]	1000
		learning_rate	[0.03,.1]	0.03
	Farroupilha	depht	[2,4,6,8,9,10]	2
		iterations	[1000]	1000
		learning_rate	[0.03,.1]	0.1
	Vale dos Vinhedos	depht	[2,4,6,8,9,10]	6
		iterations	[1000]	1000
		learning_rate	[0.03,.1]	0.1
	Vales da Uva Goethe	depht	[2,4,6,8,9,10]	2
		iterations	[1000]	1000
		learning_rate	[0.03,.1]	0.03
	Vinhos de Altitude	depht	[2,4,6,8,9,10]	2
		iterations	[1000]	1000
		learning_rate	[0.03,.1]	0.1
	Vinhos de Bituruna	depht	[2,4,6,8,9,10]	6
		iterations	[1000]	1000
		learning_rate	[0.03,.1]	0.03

2.3.4. Seleção de variáveis do modelo

Nos modelos empregados no presente estudo, Regressão Linear Múltipla (RLM), Random Forest (RF), Support Vector Machine (SVM) e CatBoost (CB), procedeu-se à seleção de variáveis inerentes a cada um, dentro do conjunto de dados que continham todas as regiões. Tais métodos selecionaram, com base em seus respectivos critérios de importância, as variáveis que melhor se ajustaram aos modelos (Tabela 4). Contudo, é relevante destacar que essas variáveis selecionadas não apresentam relação com as correlações entre variáveis climáticas e produtividade, conforme delineado nos diversos estádios fenológicos (Figura 7). A seleção de variáveis em questão reflete, portanto, as preferências individuais de cada modelo, desvinculadas da correlação entre as variáveis climáticas e a produtividade.

No estágio de poda (PR), as variáveis mais proeminentes foram umidade absoluta (AH) e precipitação (P), nos modelos de Regressão Linear Múltipla (RLM), Random Forest (RF) e Support Vector Machine (SVM). O modelo de CB não identificou nenhuma variável significativa nesse estágio fenológico. No estágio de SP, a variável Qg foi a única presente em três modelos: RLM, SVM e CB, destacando-se, sobretudo, no modelo CB, onde foi a única variável selecionada. No estágio de FL, a variável Tmin foi comum a todos os modelos analisados, enquanto Qg apareceu em três deles (RLM, SVM e CB). No estágio inicial de frutificação (FRB), as variáveis AH e Tmin estiveram presentes em todos os modelos, enquanto as variáveis P e PAR apareceram em três modelos, RLM, SVM e RF para P, e RLM, RF e SVM para PAR. No estágio subsequente de frutificação (FRP), as variáveis PAR e Qg foram identificadas nos modelos RLM, RF e SVM para PAR, e RLM, SVM e CB para Qg. Nota-se que, mais uma vez, a variável escolhida pelo modelo CB foi única para este estágio fenológico. No último estágio fenológico, MA, a variável RH destacou-se, sendo selecionada por todos os modelos, enquanto as variáveis Tmin e PAR foram incluídas em alguns deles, especificamente RLM, RF e SVM.

É notório destacar que cada modelo exibe um número variável de variáveis selecionadas, sendo esta uma magnitude dinâmica e não uma constante, influenciada pela ponderação de cada variável no contexto de cada modelo. Em consonância com a ordenação decrescente, o modelo de SVM apresentou 50 variáveis, de um total de 66 variáveis consideradas. O modelo de RLM com 40 variáveis, seguido pelo modelo

de RF com 30 variáveis. O modelo que registrou o menor número de variáveis selecionadas foi o de CB, totalizando 10 variáveis.

Tabela 4. Variáveis dependentes selecionadas pelos modelos: temperatura média (T), temperatura máxima (Tmax), temperatura mínima (Tmin), radiação líquida na superfície da cultura (Rn), irradiância solar global de onda curta (Qg), irradiância solar fotossinteticamente ativa (PAR), precipitação (P), umidade relativa (RH), umidade do solo na zona radicular (SH), umidade absoluta (AH) e evapotranspiração de referência (ETo) para cada modelo analisado, considerando o conjunto de dados de todas as regiões.

Modelos	Poda (PR)	Brotação (SP)	Floração (FL)	Frutificação (4 mm) (FRB)	Frutificação (7 mm) (FRP)	Maturação (MA)
Regressão Linear Múltipla (RLM)	AH	Tmin	AH	AH	AH	Rn
	ETo	RH	Rn	Rn	Rn	SU
	Rn	PAR	RH	SU	Tmax	RH
	P	Qg	SU	P	PAR	Tmin
	SU	-	Tmin	Tmin	Qg	T
	RH	-	Tmax	T	T	Tmax
	Tmax	-	Qg	PAR	-	PAR
	Tmin	-	-	Qg	-	-
Random Forest (RF)	T	Tmax	T	PAR	Tmin	Qg
	Tmin	T	Tmin	AH	SU	PAR
	Tmax	RH	P	RH	RH	RH
	P	SU	Tmax	Tmin	PAR	AH
	AH	AH	RH	Qg	-	Tmin
	RH	-	-	-	-	-
Support Vector Machine (SVM)	Rn	SU	SU	Tmin	ET	Tmin
	Qg	Rn	T	T	PAR	RH
	SU	Tmax	AH	ET	Qg	ETo
	ET	Qg	ET	SU	Rn	T
	PAR	ETo	Rn	PAR	SU	PAR
	P	P	Qg	P	RH	SU
	AH	Tmin	Tmin	Qg	P	Qg
	-	T	PAR	Rn	Tmin	AH
	-	-	-	AH	T	-
	-	Qg	Qg	Tmin	Qg	RH
CatBoost (CB)	-	-	PAR	P	-	-
	-	-	P	AH	-	-
	-	-	Tmin	-	-	-
	-	-	-	-	-	-

2.3.5. Estimativa de produtividade usando modelos de aprendizado de máquina

Os modelos com as variáveis dependentes selecionadas (Tabela 4) tiveram desempenho semelhantes aqueles com todas as variáveis dependentes, pois os RMSEs foram próximos, com exceção do modelo CatBoost (Figura 8).


Na análise comparativa dos modelos de Regressão Linear Múltipla (RLM), Random Forest (RF), Support Vector Machine (SVM) e CatBoost (CB), apresentaram-se resultados significativos nas métricas de ajuste e erro. Os resultados da RLM, tanto com quanto sem o uso do método *stepwise*, revelaram R^2_{adj} de 0,41 e 0,40, respectivamente, com valores de RMSE de 3656,62 kg ha⁻¹ e 3612,06 kg ha⁻¹ (Figura 8a; Figura 8b). A introdução do *stepwise* não demonstrou melhoria substancial nos resultados. Por outro lado, o modelo de RF destacou-se alcançando R^2_{adj} de 0,89 e RMSE de 1543,22 kg ha⁻¹ sem seleção de variáveis dependentes (Figura 8c), enquanto com seleção de variáveis dependentes apresentou R^2_{adj} de 0,69 e RMSE de 2644,85 kg ha⁻¹ (Figura 8d). Esses resultados sugerem uma capacidade superior do RF em ajustar-se aos dados, mesmo com a redução de variáveis.

No caso do Support Vector Machine (SVM), os resultados foram menos favoráveis, evidenciando R^2_{adj} de 0,42 e 0,27, e RMSE de 3534,56 kg ha⁻¹ e 3974,75 kg ha⁻¹, sem e com seleção de variáveis dependentes, respectivamente (Figura 8e; Figura 8f). O desempenho inferior do SVM indica sua limitação na modelagem do conjunto de dados em questão. Finalmente, o modelo CB destacou-se como o mais eficaz entre os analisados. Sem seleção de variáveis dependentes, obteve R^2_{adj} de 0,97 e RMSE de 771,57 kg ha⁻¹ (Figura 8g), enquanto com seleção de variáveis dependentes registrou R^2_{adj} de 0,76 e RMSE de 2277,08 kg ha⁻¹ (Figura 8h).

Esses resultados indicam uma capacidade notável do CatBoost (CB) em explicar a variabilidade dos dados, especialmente quando comparado aos outros modelos avaliados. Assim, com base nas métricas apresentadas, o modelo CB emerge como a escolha mais promissora para a estimação do resultado desejado, destacando-se pela sua consistência.

A superioridade das métricas nos modelos desprovidos de seleção de variáveis dependentes em comparação com aqueles que incorporam tal procedimento pode ser adequadamente justificada em virtude das dimensões do conjunto de dados. Este fenômeno decorre do fato de que a seleção de variáveis dependentes pode resultar em uma redução substancial da informação disponível para o modelo. No contexto da

seleção de variáveis dependentes, a exclusão de determinadas variáveis pode ocasionar a perda de informações relevantes para o processo de estimação. Há, portanto, casos em que a preservação de todas as variáveis se revela benéfica para o desempenho geral do modelo, visto que a retenção integral do conjunto de variáveis contribui para evitar a perda de informações relevantes, potencialmente otimizando a capacidade estimativa do modelo em questão.






Figura 8. Estimativas de desempenho do modelo para todas as regiões avaliadas no estudo.

Na região da Campanha Gaúcha (CG), os modelos de Random Forest (RF) e Support Vector Machine (SVM) exibiram valores próximos de RMSE de 984,22 kg ha⁻¹ e 952,17 kg ha⁻¹, respectivamente (Tabela 5). O modelo de RLM, por outro lado, registrou o desempenho menos satisfatório, evidenciado pelo R^2_{adj} mais baixo de 0,27 e um RMSE mais elevado de 1899,37 kg ha⁻¹. Na região de AM, tanto o modelo de CB quanto o SVM apresentaram valores iguais de R^2_{adj} , ambos atingindo 0,99. A RLM, embora ligeiramente inferior, ainda exibiu um R^2_{adj} de 0,91. A distinção entre esses modelos na escolha do melhor para a região foi no valor de RMSE, em que o CB registrou 48,00 kg ha⁻¹ e o SVM 115,08 kg ha⁻¹. O modelo com menor desempenho foi o RF, evidenciado pelo RMSE mais elevado de 1671,84 kg ha⁻¹.

Na região de Farroupilha (FA), destaca-se o modelo CatBoost (CB) que continuou demonstrando o menor RMSE, com um valor de 238,86 kg ha⁻¹. Em contrapartida, os demais modelos apresentaram RMSEs significativamente mais altos, 1409,19 kg ha⁻¹, 1805,59 kg ha⁻¹ e 1639,93 kg ha⁻¹ para os modelos RF, RLM e SVM, respectivamente. Além disso, o SVM obteve o menor R^2_{adj} , 0,56. Já na região dos VV, os modelos CB e SVM exibiram R^2_{adj} idênticos, enquanto divergiram em relação ao RMSE, com valores de 0,05 kg ha⁻¹ e 211,10 kg ha⁻¹, respectivamente. Os modelos RLM e RF demonstraram valores próximos tanto para o R^2_{adj} , registrando 0,78 e 0,75, quanto para o RMSE, apresentando 1294,94 kg ha⁻¹ e 1282,05 kg ha⁻¹, respectivamente.

Na região de Vales da Uva Goethe (GGV), o R^2_{adj} atingiu seu ponto máximo com o modelo de CatBoost (CB), registrando um valor de 0,81. Em contrapartida, o

modelo SVM apresentou o menor desempenho, evidenciado pelo R^2_{adj} mínimo de 0,01. Todos os modelos exibiram valores elevados de RMSE, variando de 1600 a 1800 kg ha⁻¹, para os métodos de CB e RF, enquanto ultrapassaram 2200 kg ha⁻¹ para RLM e SVM. Na região de HW, os valores de R^2_{adj} foram inferiores em comparação com as outras regiões estudadas. O modelo de CB obteve o maior R^2_{adj} , alcançando 0,59, com o menor valor de RMSE sendo de 2883,21 kg ha⁻¹. No entanto, os demais modelos apresentaram valores de RMSE superiores a 3500 kg ha⁻¹.


Na região de Vinhos de Bituruna (BW), os R^2_{adj} foram aproximados para três modelos, a saber: CatBoost (CB), Support Vector Machine (SVM) e Regressão Linear Múltipla (RLM), exibindo valores de 0,99, 0,99 e 0,98, respectivamente. O menor RMSE foi para o modelo CB, alcançando 2,75 kg ha⁻¹. Os valores foram próximos para SVM e RF, enquanto o modelo RF apresentou o maior valor, atingindo 1555,7 kg ha⁻¹.

Tabela 5. Indicadores de desempenho: erro quadrático médio da raiz (RMSE) e coeficiente de determinação ajustado (R^2_{adj}) relativo aos modelos de Regressão Linear Múltipla (RLM), Random Forest (RF), Support Vector Machine (SVM) e CatBoost (CB) em análise nas diversas regiões estudadas.

Campanha Gaúcha – GC (RS)			Altos Montes – AM (RG)			Farroupilha – FA (RS)		
Models	RMSE	R^2_{adj}	Model s	RMSE	R^2_{adj}	Model s	RMSE	R^2_{adj}
CB	0,08	0,99	CB	48,00	0,99	CB	238,86	0,99
RF	984,22	0,79	SVM	115,08	0,99	RF	1409,19	0,89
SVM	952,17	0,68	RLM	925,44	0,91	RLM	1805,59	0,71
RLM	1899,37	0,27	RF	1671,84	0,78	SVM	1639,93	0,56
Vale dos Vinhedos – VV (RS)			Vales da Uva Goethe – GGV (SC)			Vinhos de Altitude – HW (SC)		
Models	RMSE	R^2_{adj}	Model s	RMSE	R^2_{adj}	Model s	RMSE	R^2_{adj}
CB	0,05	0,99	CB	1637,14	0,81	CB	2883,21	0,59
SVM	211,10	0,99	RLM	2227,90	0,50	RLM	3738,24	0,24
RLM	1294,94	0,78	RF	1845,80	0,41	RF	3741,14	0,15
RF	1282,05	0,75	SVM	2389,01	0,01	SVM	3511,52	0,05
			Vinhos de Bituruna – BW (PR)					
			Model s	RMSE	R^2_{adj}			
			CB	2,75	0,99			
			SVM	100,66	0,99			
			RLM	119,96	0,98			
			RF	1555,75	0,76			

Quanto à seleção do modelo mais apropriado, o modelo CatBoost (CB) apresentou destaque, evidenciado pelos valores médios mais elevados para R^2_{adj} e os valores mais baixos para RMSE (em kg ha^{-1}), em todas as regiões investigadas (Figura 9), em comparação com os outros modelos.

O menor R^2_{adj} foi 0,59 para a região de Vinhos de Altitude (HW) e o maior valor registrado foi de 0,99 para as regiões da Campanha Gaúcha (CG), Altos Montes (AM), Farroupilha (FA), Vale dos Vinhedos (VV) e Vinhos de Bituruna (WB), diferindo apenas a região de Vinhos de Altitude (HW) com 0,81. Valores de R^2 semelhantes para estimativa da biomassa acima do solo de milho, no Condado de Xinxiang, China, variando de 0,45 a 0,90 (Zhai et al., 2023).






Figura 9. Desempenho do modelo CatBoost (CB) em distintas regiões vinícolas.

2.4. Discussão

2.4.1. Influência do clima na fenologia da videira

As implicações do clima sobre a produtividade e qualidade da uva e, consequentemente, sobre a qualidade do vinho, bem como os riscos inerentes aos vinhedos, foram examinados em termos potenciais mediante a interpretação de

índices climáticos (Figura 4; Figura 5). Pesquisas conduzidas para a análise comparativa diante de variações climáticas, a exemplo do estudo realizado em três locais no centro-sul da Itália, constituem uma valiosa contribuição para a compreensão dos limites adaptativos inerentes aos territórios atualmente dedicados ao cultivo de videiras e *terroirs* (Ferlito et al., 2023).

Este panorama aponta para a complexidade inerente as interações climáticas e geográficas, enfatizando a necessidade de considerar distintas regiões e suas particularidades para uma análise mais abrangente e precisa dos impactos potenciais da variabilidade climática sobre a produção vitivinícola no Brasil.

Variáveis dependentes como radiação, precipitação e temperatura, exercem um controle substancial sobre o crescimento e desenvolvimento da videira, desempenhando influência significativa na taxa de fotossíntese, conforme descrito por Santos et al. (2011). As quais tais variáveis climáticas, PAR, RH e P se destacaram na análise de correlação (Figura 7).

No sul do Brasil, os valores médios, propícios para o bom desenvolvimento da videira, da irradiância solar fotossinteticamente ativa (PAR) variam de 14 a 20 MJ m⁻² dia⁻¹ durante a estação de crescimento. Em geral, a videira é favorecida por níveis elevados de radiação solar durante o período de crescimento ativo, especialmente durante os estádios de FL, FRB e FRP. Os valores de PAR, nas diferentes regiões estudadas, variaram de 5 a 12 MJ m⁻² dia⁻¹, abaixo do esperado. Justifica-se seu destaque negativo na correlação de Spearman na maioria das regiões, a saber: AM, FA, VV, GGV e HW (Fig. 7).

A PAR ao exercer uma correlação negativa durante o ciclo da videira, região de GGV, pode prejudicar sua qualidade final, em que o acúmulo de açúcar solúvel em frutas carnudas, como as uvas, resulta da interação complexa de três processos principais: importação de açúcar, metabolismo do açúcar e diluição da água (Yuan e Chen, 2024). A partir do meio da temporada, a maioria dos fotoassimilados é direcionada para o amadurecimento de bagas (Lebon et al., 2008). Assim, a importação de açúcar pelas bagas torna-se fortemente dependente da atividade fotossintética das folhas (Yuan e Chen, 2024).

No caso da região de Vales da Uva Goethe (GGV) a consideração da temperatura mínima (Tmin) torna-se importante, uma vez que desempenha um papel

relevante na compreensão da qualidade das uvas (Tonietto; Carbonneau, 2004). Enquanto as temperaturas médias são geralmente ponderadas, as mínimas desempenham um papel distintivo na análise, contribuindo para a percepção abrangente do fenômeno em estudo. Além disso, é válido ressaltar que temperaturas máximas elevadas podem ter efeitos adversos nas videiras, potencialmente resultando em substanciais reduções percentuais na produtividade (Monteverde; Sales, 2020).

A correlação entre as variáveis climáticas que se destacaram ao longo do ciclo fenológico da videira, com a produtividade para cada região estudada ressalta a relevância do entendimento das condições climáticas regionais, com foco nos riscos e potencialidades apresentados por tais variáveis climáticas, para orientar as decisões do vitivinicultor em todas as fases do processo, desde o plantio e a seleção de áreas e variedades apropriadas até o manejo do vinhedo (Ohana-Levi et al., 2024).

A formação de flores de videira, a partir do primórdio da inflorescência, ocorre concomitantemente à explosão do botão na temporada subsequente (Vasconcelos et al., 2009). Para otimizar o número de primórdios de inflorescência, é imprescindível a presença de condições térmicas elevadas, intensa irradiação solar, estresse nitrogenado e um suprimento adequado de água (Gutiérrez-Gamboa et al., 2021). Essa relação sugere a importância de variáveis climáticas críticas, como o SH e P, durante momentos importantes do ciclo de crescimento, ressaltando sua relevância em conjunto com as condições climáticas durante a FL e a MA (Gardner et al., 2021; Llanaj e McGregor, 2022). Esta observação enfatiza a importância de considerar múltiplas variáveis dependentes para uma compreensão abrangente e precisa dos fenômenos relacionados ao cultivo de videiras na região de HW.

A variação térmica ao longo do ciclo de crescimento da videira demonstrou um aumento progressivo nas variáveis temperatura média do ar (T), máxima (Tmax) e mínima (Tmin) (Figura 4a; Figura 4b; Figura 4c, respectivamente), saindo de valores aproximados de 13 a 14 °C na poda (PR), chegando a 20 a 24 °C na maturação (MA). O aumento térmico ao longo do ciclo da videira reflete as condições climáticas em evolução, influenciando diretamente o desenvolvimento do cultivo durante esse período específico. Em geral, o aumento moderado na temperatura pode ser benéfico para o desenvolvimento da videira, visto que pode acelerar o crescimento vegetativo,

o desenvolvimento das uvas e a maturação. Também pode favorecer a atividade metabólica da planta, resultando em uma boa produção de açúcares e sabores mais intensos.

Porém, em cenários climáticos futuros caracterizados por temperaturas mais elevadas, é plausível que a elevação extrema das temperaturas exerça uma inibição sobre o processo de biossíntese de antocianinas (Buttrose et al., 1971), acarretando consequências relevantes para as características cromáticas e olfativas dos frutos (Downey et al., 2006). Adicionalmente, é possível antever que, sob as condições de aquecimento projetadas, ocorra um incremento nas concentrações de açúcar e uma diminuição na acidez (Fraga et al., 2017).

Pesquisas têm evidenciado que tendências de aquecimento resultam em produtividades mais baixas (Wang et al., 2023a), fenômeno que pode, em parte, explicar a produtividade inferior registrada na região da Campanha Gaúcha (CG) (Figura 6). Este contexto ressalta a relevância de compreender os efeitos térmicos na fenologia da videira para antecipar e mitigar possíveis impactos na produção vinícola frente às alterações climáticas em curso. A influência global sobre a produção será contingente às concentrações de variáveis climáticas, tais como temperatura, radiação solar e precipitação (Fraga et al., 2017).

Para a região do Douro em Portugal, diversos estudos corroboram com a perspectiva de incremento nas produtividades da videira e na produção de vinho em cenários climáticos futuros (Santos et al., 2011). No entanto, é importante salientar que essas investigações foram conduzidas considerando a porção mais úmida da região (Baixo-Corgo), enquanto as projeções para as áreas mais secas sugerem uma tendência à redução nas produtividades (Cima-Corgo e Douro-Superior) (Fraga et al., 2017).

Em regiões vitícolas de clima frio, o aumento das temperaturas demonstra potencial para aprimorar a qualidade do vinho, atribuída ao aumento do acúmulo de flavonóis nas uvas (Gutiérrez-Gamboa et al., 2021). As temperaturas ideais para a produção de uva destinadas a vinificação variam entre 18 °C e 22 °C durante o período de maturação das uvas. Fator importante para a região de FA com correlação positiva de temperaturas em diferentes estádios fenológicos.

Os resultados deste estudo enfatizam a importância de compreender o impacto das variações térmicas no *timing* e na eficácia dos processos nos estádios de floração (FL) e frutificação (FRB e FRP) (Tekeri; Soltekin, 2023). A influência das temperaturas durante o estágio de FL emerge como um fator importante, com potencial impacto na polinização, influenciando o número de cachos de uva e na quantidade de bagas por cacho (Pagay; Collins, 2017), na faixa entre 15 °C e 25 °C.

As frutas frescas, durante seu desenvolvimento, emitem vapor de água de forma contínua para a atmosfera circundante por meio do processo de transpiração (Yuan; Chen, 2024). As bagas de uva apresentam baixa densidade estomática na superfície, com menos de um estoma por mm², adicionalmente, à medida que as uvas amadurecem, os estômatos podem tornar-se parcial ou completamente recobertos por ceras epicuticulares, resultando em sua infuncionalidade (Dimopoulos et al., 2020). Devido a essa falta de regulação estomática da transpiração, a perda de água nas bagas ocorre predominantemente através da cutícula, sendo suscetível a variações significativas conforme as condições ambientais, tais como T e RH (Cabodevilla et al., 2024).

O aumento da temperatura, portanto, pode representar uma ameaça à saúde das uvas (Bahr et al., 2021), com a perspectiva de que algumas regiões vinícolas possam se tornar inadequadas para a viticultura no futuro devido aos extremos de calor (Hannah et al., 2013). Vale destacar que uma correlação negativa da Tmax foi obtida no estágio FRB na região de VV. Porém, ressalta-se, também, as correlações positivas, em que essas variáveis estão intimamente relacionadas à qualidade da uva para vinificação, sendo elas estado hídrico, radiação solar e temperatura (Ubeda et al., 2020).

No caso de condições de alta umidade relativa (RH), as plantas podem manifestar taxas de respiração mais elevadas no final do ciclo, influenciando o equilíbrio entre o crescimento vegetativo e a formação dos frutos. Além disso, altos níveis de umidade podem prejudicar a eficiência da polinização, afetando negativamente a formação dos cachos e a quantidade de uvas produzidas.

Tanto a radiação solar quanto a temperatura desempenham papéis parciais na determinação do potencial fotossintético das plantas, e estudos indicam uma relação linear entre a evolução dos sólidos solúveis, principalmente açúcares, e o acúmulo de

calor (Duchêne et al. 2020). A exposição do cacho a temperaturas elevadas e radiação solar intensa pode resultar no aumento da síntese de antocianinas, flavonóis e flavanóis nas uvas, atribuindo-se a este fenômeno ao incremento na atividade da enzima fenilalanina amônio liase (Flamini et al., 2013).

2.4.2. Uso de modelagem para estimativa de produtividade

As diferentes combinações de variáveis de entrada influenciaram o desempenho dos modelos de maneira heterogênea. A pesquisa conduzida por Ohana-Levi et al. (2024) baseia-se na suposição de que diversas variáveis exercem influências, embora amplamente variáveis, sobre os componentes de desempenho das videiras. Um modelo de ML é influenciado pela aplicação de estudos de caso específicos. Porém, as diferentes respostas obtidas nesse estudo possam ser justificadas pelo desempenho dos modelos de ML depender do conjunto de dados de treinamento, mas o conjunto de dados pode possuir uma representatividade limitada da produtividade, como discutido por Wang et al. (2023b).

A análise de Regressão Linear Múltipla (RLM), com seleção de 40 variáveis dependentes e o modelo com 60 variáveis dependentes, não apresentou diferença significativa no coeficiente de determinação ajustado em relação à produtividade da videira. A produtividade de alguns cultivos usando RLM, com 45 variáveis dependentes, obteve R^2_{adj} de 0,95 na China (Liu et al., 2021), o que difere dos resultados deste estudo, com R^2_{adj} de 0,40.

No contexto da produtividade da videira em Israel, o modelo SVM alcançou um R^2 de 0,94 e um RMSE de 0,03 t ha⁻¹ (Ohana-Levi et al., 2024). Este estudo revelou uma similaridade nos resultados para as regiões de AM e VV, no que diz respeito ao R^2 , divergindo, entretanto, no RMSE, com o valor mínimo registrado de 0,115 t ha⁻¹ para a região de AM. Vale ressaltar que o SVM demonstra eficiência computacional e destaca-se em ambientes de elevada dimensionalidade (Zhao et al., 2024).

O modelo de Random Forest (RF) foi usado para prever a produtividade da uva a partir de dados meteorológicos na região da Campanha Gaúcha (CG), sul do Brasil (Andrade et al., 2023). O seu desempenho na estimativa se revelou menos eficaz em relação ao método de CB, em estudos de previsão de demanda de água de plantas em áreas úmidas da China (Zhao et al., 2024), corroborando os achados desta

pesquisa. O modelo de RF usado para selecionar combinações de fatores ideais, com validação cruzada (10 folds), e otimização de parâmetros resultou em uma previsão de alta precisão na resposta no cultivo do arroz na China (Wang e Li, 2023).

Em relação ao modelo CatBoost (CB), é demonstrado uma robusta capacidade de mapeamento (Zhai et al., 2023), essa característica decorre da habilidade do CB em aprimorar a acurácia do modelo por meio da correção e atualização contínua dos pesos das amostras, além de controlar o erro ao aprender as características do conjunto de treinamento.

2.5. Conclusões

As condições climáticas têm influência significativa na fenologia da videira e, conseqüentemente na produtividade. Esta influência é diferente em cada região produtora. O aumento progressivo nas temperaturas, ao longo do ciclo da videira, influencia diretamente seu desenvolvimento. A temporada de maior índice pluviométrico durante os estádios de frutificação é essencial para garantir as condições ideais de crescimento e maturação dos frutos.

Nos estádios de poda, frutificação (bagas com 4 mm de diâmetro) e maturação, a variável dependente com destaque positivo foi a evapotranspiração de referência (correlação de até 0,32, 0,50 e 0,36, respectivamente), no estágio de brotação destacou-se a variável dependente precipitação (correlação até 0,45), no estágio de floração a variável dependente de destaque foi temperatura mínima (correlação até 0,34), e no estágio seguinte, frutificação (bagas com 7 mm de diâmetro), a radiação líquida na superfície da cultura foi a variável dependente com maior frequência de correlação positiva (até 0,17).

O uso de modelagem para estimação da produtividade da uva indicou que o CatBoost se destacou como o modelo mais eficaz entre os modelos Regressão Linear Múltipla, Random Forest e Support Vector Machine, apresentando RMSE mínimo igual a 771,57 kg ha⁻¹, evidenciando superioridades em todas as regiões estudadas.

Referências

Afavin (2005) **Indicação de Procedência Farroupilha, vinhos finos moscatéis**. Farroupilha, Rio Grande do Sul.

Aguiar AC, Higuchi MT, Yamashita F, Roberto SR (2023) SO₂-generating pads and packaging materials for postharvest conservation of table grapes: A review. **Hortic.** 9:724–738. <https://doi.org/10.3390/horticulturae9060724>.

Alba JMF, Flores CA, Miele A (2017) Geotechnologies and soil mapping for delimitation of management zones as an approach to precision viticulture. **Appl. Environ. Soil Sci.** 4180965. <https://doi.org/10.1155/2017/4180965>.

Allen RG, Pereira LS, Raes D, Smith M (1998) **FAO irrigation and drainage paper Nº. 56**. Food and Agriculture Organization of the United Nations, Rome.

Alvares CL, Stape JL, Sentelhas PC, Gonçalves JLM, Sparovek G (2014) Köppen's climate classification map for Brazil. **Meteorol. Z.** 22:711–728. <https://doi.org/10.1127/0941-2948/2013/0507>.

Andrade CB, Moura-Bueno JM, Comin JJ, Brunetto G (2023) Grape yield prediction models: approaching different machine learning algorithms. **Hortic.** 9:1294. <https://doi.org/10.3390/horticulturae9121294>.

Anzanello R (2019) Evolution of the grapevine bud dormancy under different thermal regimes. **Semin. Cienc. Agrar.** 40:3419. <https://doi.org/10.5433/1679-0359.2019v40n6Supl3p3419>.

Arab ST, Noguchi R, Matsushita S, Ahamed T (2021) Prediction of grape yields from time-series vegetation indices using satellite remote sensing and a machine-learning approach. **Remote Sens. Appl. Soc. Environ.** 22:100485. <https://doi.org/10.1016/j.rsase.2021.100485>.

Arrizabalaga-Arriazu M, Gomès E, Morales F, Irigoyen JJ, Pascual I, Hilbert G (2020) High temperature and elevated carbon dioxide modify berry composition of different clones of grapevine (*Vitis vinifera* L.) cv. Tempranillo. **Front. Plant Sci.** 11:1–18. <https://doi.org/10.3389/fpls.2020.603687>.

Azorín PR, García JG (2020) The productive, economic, and social efficiency of vineyards using combined drought-tolerant rootstocks and efficient low water volume deficit irrigation techniques under Mediterranean semiarid conditions. **Sustain.** 12:1930. <https://doi.org/10.3390/SU12051930>.

Bahr C, Schmidt D, Kahlen K (2021) Missing links in predicting berry sunburn in future vineyards. **Front. Plant Sci.** 12:715906. <https://doi.org/10.3389/fpls.2021.715906>.

Barriguiha A, Jardim B, Castro Neto M, Gil A (2022) Using NDVI, climate data and machine learning to estimate yield in the Douro wine region. **Int. J. Appl. Earth Obs. Geoinf.** 114:103069. <https://doi.org/10.1016/j.jag.2022.103069>.

Brighenti AF, Brighenti E, Bonin V, Rufato L (2013) Caracterização fenológica e exigência térmica de diferentes variedades de uvas viníferas em São Joaquim, Santa Catarina – Brasil. **Ciênc. Rural** 43:1162–1167.

Brunetto G, Ceretta CA, Kaminski J, Melo GEB, Lourenzi CR, Furlanetto V, Moraes A (2007) Application of nitrogen in grapevines in the campaign of the Rio Grande do Sul: productivity and chemical characteristics of the grape must. **Ciênc. Rural** 37:389–393. <https://doi.org/10.1590/S0103-84782007000200014>.

Buttrose MS, Hale CR, Kliewer WM (1971) Effect of temperature on the composition of ‘Cabernet Sauvignon’ berries. **Am. J. Enol. Vitic.** 22:71–75. <https://doi.org/10.5344/ajev.1971.22.2.71>.

Cabodevilla A, Morales F, Pascual I (2024) Bunch transpiration is involved in the hastening of grape berry ripening under elevated temperature and low relative humidity

conditions. **Plant Physiol. Bioche.** 206:108258.
<https://doi.org/10.1016/j.plaphy.2023.108258>.

Chavarria G, Santos HP, Zanús MC, Marodin GAB, Chalaça MZ, Zorzan C (2010) Maturação de uvas Moscato Giallo sob cultivo protegido. **Ver. Bras. Frutic.** 32:151–160. <https://doi.org/10.1590/S0100-29452010005000014>.

Chen Z, Jia K, Xiao C, Wei D, Wang L (2020) Leaf area index estimation algorithm for GF-5 hyperspectral data based on different feature selection and Machine Learning methods. **Remote Sens.** 12:2110. <https://doi.org/10.3390/rs12132110>.

Coombe BG (1995) Adoption of a system for identifying grapevine growth stages. **Aust. J. Grape Wine Res.** 1:100–110.

Costa R, Fraga H, Malheiro AC, Santos JA (2015) Application of crop modelling to Portuguese viticulture: implementation and added-values for strategic planning. **Ciênc. Téc. Vitiv.** 30:29–42. <http://dx.doi.org/10.1051/ctv/20153001029>.

Damásio M, Barbosa M, Deus J, Fernandes E, Leitão A, Albino L, Fonseca F, Silvestre J (2023) Can grapevine leaf water potential be modelled from physiological and meteorological variables? A machine learning approach. **Plants** 12:4142. <https://doi.org/10.3390/plants12244142>.

Della Bruna E (2021) **Manual de produção da uva Goethe**. Epagri, Florianópolis.

Dimopoulos N, et al. (2020) Drought stress modulates cuticular wax composition of the grape berry. **J. Exp. Bot.** 71:3126–3141. <https://doi.org/10.1093/jxb/eraa046>.

Downey MO, Dokoozlian NK, Krstic MP (2006) Cultural practice and environmental impacts on the flavonoid composition of grapes and wine: a review of recent research. **Am. J. Enol. Vitic.** 57:257–268. <https://doi.org/10.5344/ajev.2006.57.3.257>.

Duchêne É, et al. (2020) Genetic variations of acidity in grape berries are controlled by the interplay between organic acids and potassium. **Theor. Appl. Genet.** 133:993–1008. <https://doi.org/10.1007/s00122-019-03524-9>.

Enteram M, Banadkooki FB (2023) A developed Multiple Linear Regression (MLR) model for monthly groundwater level prediction. **Water** 15:3940. <https://doi.org/10.3390/w15223940>.

Elbeltagi A, Srivastava A, Kushwaha NL, Juhász C, Tamás J, Nagy A (2023) Meteorological data fusion approach for modeling crop water productivity based on ensemble Machine Learning. **Water** 15:30. <https://doi.org/10.3390/w15010030>.

EMBRAPA (2024) **Geographical indications of wines** [Online]. Embrapa Grape e Wine. Disponível em: <<https://www.embrapa.br/en/uva-e-vinho/indicacoes-geograficas-de-vinhos-do-brasil>>. Acesso em: 22 jan. 2024.

Felippeto J, Caliar V, Brighenti E, Nesi CN (2021) Requerimento térmico e características físico-químicas de diferentes variedades de videira em São Joaquim, SC. **Agropecu. Catarin.** 34:61–66.

Ferlito F, Nicolosi E, Sicilia A, Villano C, Aversano R, Lo Piero AR (2023) Physiological and productive responses of two *Vitis vinifera* L. cultivars across three sites in central-south Italy. **Hortic.** 9:1321. <https://doi.org/10.3390/horticulturae9121321>.

Ferreira MI, Silvestre J, Conceição N, Malheiro AC (2012) Crop and stress coefficients in rainfed and deficit irrigation vineyards using sap flow techniques. **Irrig. Sci.** 30:433–44. <https://doi.org/10.1007/s00271-012-0352-2>.

Filippon F, Dillon AJP, Laguna SE, Dutra SV, Spinelli FR, Balardin PB, Vanderlinde R (2017) Poda mista e em cordão esporonado e sua influencia na composição fenólica da uva Cabernet Sauvignon. **Ver. Bras. Vitic. Enol.** 9:10–16.

Flamini R, Mattivi F, De Rosso M, Arapitsas P, Bavaresco L (2013) Advanced knowledge of three important classes of grape phenolics: Anthocyanins, stilbenes and flavonols. **Int. J. Mol. Sci.** 14:19651–19669. <https://doi.org/10.3390/ijms141019651>.

Fraga H, Atauri IGC, Malheiro AC, Moutinho-Pereira J, Santos JA (2017) Viticulture in Portugal: A review of recent trends and climate change projections. **Oeno One** 51:61–69. <https://doi.org/10.20870/oeno-one.2017.51.2.1621>.

Fraga H, Malheiro AC, Moutinho-Pereira J, Santos JA (2014) Climate factors driving wine production in the Portuguese Minho region. **Agric. For. Meteorol.** 185:26–36. <https://doi.org/10.1016/j.agrformet.2013.11.003>.

Gardner AS, Gaston KJ, Maclean IMD (2021) Accounting for inter-annual variability alters long-term estimates of climate suitability. **J. Biogeogr.** 48:1960–1971. <https://doi.org/10.1111/jbi.14125>.

Gutiérrez-Gamboa G, Zheng W, Toda FM (2021) Current viticultural techniques to mitigate the effects of global warming on grape and wine quality: A comprehensive review. **Food Res. Int.** 139:109946. <https://doi.org/10.1016/j.foodres.2020.109946>.

Hannah L, Roehrdanz PR, Ikegami M (2013) Climate change, wine, and conservation. **Proc. Nati. Acad. Sci. U. S. A.** 10:6907–6912. <https://doi.org/10.1073/pnas.1210127110>.

Hasan M, Marjan MA, Uddin MP, Afjal MI, Kardy S, Ma S, Nam Y (2023) Ensemble machine learning-based recommendation system for effective prediction of suitable agricultural crop cultivation. **Front. Plant Sci.** 14:1234555. <https://doi.org/10.3389/fpls.2023.1234555>.

IBGE (2022) **Systematic Survey of Agricultural Production** [Online]. Brazilian Institute of Geography and Statistics. Disponível em: <

<https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9201-levantamento-sistematico-da-producao-agricola.html>>. Acesso em: 5 jan. 2024.

Jamei M, Karbasi M, Malik A, Jamei M, Kisi O, Yaseen ZM (2022) Long-term multi-step ahead forecasting of root zone soil moisture in different climates: Novel ensemble-based complementary data-intelligent paradigms. **Agric. Water Manag.** 269:107679. <https://doi.org/10.1016/j.agwat.2022.107679>.

Jenkins M, Mannsfeld A, Nikzad S, Lambert JJ, Miller K, Burns M, Earles JM, Block DE (2023) Novel algorithms for high-resolution prediction of canopy evapotranspiration in grapevine. **Oeno One** 57:315–326. <https://doi.org/10.20870/oeno-one.2023.57.3.7251>.

Kadhbane SJ, Manekar VL (2021) Development of agro-climatic grape yield model with future prospective. **Ital. J. Agrometeorol.** 1:89–103. <https://doi.org/10.36253/ijam-406>.

Karimi SM, Kisi O, Porrajabali M, Rouhani-Nia F, Shiri J (2020) Evaluation of the support vector machine, random forest and geo-statistical methodologies for predicting long-term air temperature. **ISH J. Hydraul. Eng.** 26:376–386. <https://doi.org/10.1080/09715010.2018.1495583>.

Kose B (2014) Phenology and ripening of *Vitis vinifera* L. and *Vitis labrusca* L. varieties in the maritime climate of Samsun in Turkey's Black Sea region. **S. Afr. J. Enol. Vitic.** 35:90–102. <https://doi.org/10.21548/35-1-988>.

Kuradusenge M, Hitimana E, Hanyurwimfura D, Rukundo P, Mtonga K, Mukasine A, Uwitonze C, Ngabonziza J, Uwamahoro A (2023) Crop yield prediction using machine learning models: case of Irish potato and maize. **Agric.** 13:225. <https://doi.org/10.3390/agriculture13010225>.

Lebon C, Wojnarowicz G, Holzapfel B, Fontaine F, Vaillant-Gaveau N, Clément C (2008) Sugars and flowering in the grapevine (*Vitis vinifera* L.). **J. Exp. Bot.** 59:2565–2578. <https://doi.org/10.1093/jxb/ern135>.

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

Li P, Li TSL, Wang Y (2024) Optimization of the selection of suitable harvesting periods for medicinal plants: taking *Dendrobium officinale* as an example. **Plant Methods** 20:43. <https://doi.org/10.1186/s13007-024-01172-9>.

Liu Y, Heuvelink GBM, Bai Z, Ele P, Xu X, Ding W, Huang Z (2021) Analysis of spatio-temporal variation of crop yield in China using stepwise Multiple Linear Regression. **F. Crop. Res.** 264:108098. <https://doi.org/10.1016/j.fcr.2021.108098>.

Llanaj C, McGregor G (2022) Climate change, grape phenology, and frost risk in Southeast England. **Aust. J. Grape Wine Res.** 9835317. <https://doi.org/10.1155/2022/9835317>.

Luo M, Wang Y, Xie Y, Zhou L, Qiao J, Qiu S, Sun Y (2021) Combination of feature selection and CatBoost for prediction: The first application to the estimation of aboveground biomass. **For.** 12:216. <https://doi.org/10.3390/f12020216>.

Malheiro A.C., Campos R., Fraga H., Eiras-Dias J., Silvestre J., Santos J.A. (2013) Winegrape phenology and temperature relationships in the Lisbon Wine Region, Portugal. **Oeno One** 47:287–299. <https://doi.org/10.20870/oeno-one.2013.47.4.1558>.

Mandelli F, Berlato MA, Tonietto J, Bergamaschi H (2003) Fenologia da videira na Serra Gaúcha. **Pesq. Agrop. Gaúcha** 9:129–144.

Mello LMR, Machado CAE (2020) **Brazilian Winemaking: Panorama 2019**. Embrapa Uva e Vinho, Brasil.

Monteverde C, Sales F (2020) Impacts of global warming on southern California's winegrape climate suitability. **Adv. Clim. Chang. Res.** 11:279–293. <https://doi.org/10.1016/j.accre.2020.08.002>.

Nazari L, Zinati Z, Bagnaresi P (2024) Identification of biomarker genes from multiple studies for abiotic stress in maize through machine learning. **J. Biosci.** 49:1–15. <https://doi.org/10.1007/s12038-023-00392-w>.

North M, Workmaster BA, Atucha A (2022) Effects of chill unit accumulation and temperature on woody plant deacclimation kinetics. **Physiol. Plant.** 174: e13717. <https://doi.org/10.1111/ppl.13717>.

Ohana-Levi N, Bahat I, Peeters A, Shtein A, Netzer Y, Cohen Y, Ben-Gal A (2019) A weighted multivariate spatial clustering model to determine irrigation management zones. **Comput. Electron. Agric.** 162:719–731. <https://doi.org/10.1016/J.COMPAG.2019.05.012>.

Ohana-Levi N, Cohen Y, Munitz S, Michaelovsky R, Mintz DF, Hagag N, Getz Y, Netzer Y (2024) The response of yield, number of clusters, and cluster weight to meteorological factors and irrigation practices in grapevines: A multi-experiment study. **Sci. Hortic.** 326:11276. <https://doi.org/10.1016/j.scienta.2023.112761>.

Ohana-Levi N, Mintz DF, Hagag N, Stern Y, Munitz S, Friedman-Levi Y, Shacham N, Grünzweig JM, Netzer Y (2022) Grapevine responses to site-specific spatiotemporal factors in a Mediterranean climate. **Agric. Water Manag.** 259:107226. <https://doi.org/10.1016/J.AGWAT.2021.107226>.

OIV (2010) **Resolution OIV/VITI 333/2010** [Online]. International Organization of Vine and Wine. Disponível em: <<https://www.oiv.int/public/medias/379/viti-2010-1-en.pdf>>. Acesso em: 8 jan. 2024.

OIV (2021) **State of the Vitiviniculture World Market** [Online]. International Organization of Vine and Wine. Disponível em: <<https://www.oiv.int/en/technical-standards-and-documents/statistical-analysis/state-of-vitiviniculture>>. Acesso em: 8 jan. 2024.

OIV (2022) **World Wine Production Outlook** [Online]. International Organization of Vine and Wine. Disponível em: <<https://www.oiv.int>>. Acesso em: 8 jan. 2024.

Pagay V, Collins C (2017) Effects of timing and intensity of elevated temperatures on reproductive development of field-grown Shiraz grapevines. **OENO One** 51:409–421. <https://doi.org/10.20870/oeno-one.2017.51.4.1066>.

Paruelo JM, Teixeira M, Tomasel F (2024) Hybrid modeling for grassland productivity prediction: A parametric and machine learning technique for grazing management with applicability to digital twin decision systems. **Agric. Syst.** 214:103847. <https://doi.org/10.1016/j.agry.2023.103847>.

Pérez-Álvarez EP, Intrigliolo DS, Vivaldi GA, García-Esparza MJ, Lizama V, Álvarez I (2021) Effects of the irrigation regimes on grapevine cv. Bobal in a Mediterranean climate: I. Water relations, vine performance and grape composition. **Agric. Water Manag.** 248:106772. <https://doi.org/10.1016/j.agwat.2021.106772>.

Prokhorenkova L, Gusev G, Vorobev A, Dorogush AV, Gulin A (2017) CatBoost: unbiased boosting with categorical features. **arXiv Prepr.** 706:09516. <https://doi.org/10.48550/arXiv.1706.09516>.

Radünz AL, Schöffel ER, Borges CT, Malgarim MB, Pötter GH (2015) Necessidades térmicas de videiras na região da Campanha do Rio Grande do Sul – Brasil. **Ciênc. Rural** 45:626–632. <http://dx.doi.org/10.1590/0103-8478cr20140134>.

Rahnama MR, Abkooh SS (2023) Prediction of CO pollutant in Mashhad metropolis, Iran: Using Multiple Linear Regression. **Geogr. J.** 189:715–728. <https://doi.org/10.1111/geoj.12534>.

Santos CEI, Silva LRM, Bouffleur LA, Debastiani R, Stefenon CA, Amaral L, Yoneama ML, Dias JF (2010) Elemental characterisation of Cabernet Sauvignon wines using Particle-Induced X-ray Emission (PIXE). **Food Chem** 121:244–250. <https://doi.org/10.1016/j.foodchem.2009.11.079>.

Santos CZ, Roberto SR, Sato AJ, Jubileu BZ (2007) Caracterização da fenologia e da demanda térmica das videiras ‘Cabernet Sauvignon’ e ‘Tannat’ para a região norte do Paraná. **Acta Sci. Agron.** 29:361–366.

Santos J.A, Malheiro A.C, Karremann M.K, Pinto J.G (2011) Statistical modelling of grapevine yield in the Port Wine region under present and future climate conditions. **Int. J. Biometeorol.** 55:119–131. <https://doi.org/10.1007/s00484-010-0318-0>.

Shehzad F, Islam M, Omar M, Shah SIH, Ahmed R, Sohail N (2022) Optimizations of modified machine learning algorithms using K-fold cross validations for wheat productivity: A hyper parametric approach. **Sarhad J Agric** 38:271–278. <https://dx.doi.org/10.17582/journal.sja/2022/38.5.271.278>.

Silveira JM, Rombaldi CV, Aguila JSD, Gabbardo M, Cunha WM (2023) Agronomic and physicochemical parameters of must and wine as a function of changes in ‘Cabernet Sauvignon’ grapevine canopy. **Acta Sci. Agron.** 45: e56441. <https://doi.org/10.4025/actasciagron.v45i1.56441>.

Sirsat M, Mendes-Moreira J, Ferreira C, Cunha M (2019) Machine learning predictive model of grapevine yield based on agroclimatic patterns. **Eng. Agric. Environ. Food** 12:443–450. <https://doi.org/10.1016/J.EAEF.2019.07.003>.

Teker T, Soltekin O (2023) Berry shattering phenomena in vineyards: The influence of maximum temperatures during flowering period in an extreme year. **Sci. Hortic.** 321:112278. <https://doi.org/10.1016/j.scienta.2023.112278>.

Tonietto J, Carbonneau A (2004) A multicriteria classification system for grape-growing regions worldwide. **Agric. For. Meteorol.** 124:81–97. <https://doi.org/10.1016/j.agrformet.2003.06.001>.

Tonietto J, Falcade I, Guerra CC, Zanús MC (2022) As indicações geográficas de vinhos do Rio Grande do Sul, In: Ferronato EM (Org.) **Indicações geográficas do Rio Grande do Sul registradas até março de 2021**. Brasília: MAPA, p.71–95.

Tonietto J, Falcade I (2013) **Vinhos dos Altos Montes**: Flores da Cunha, Nova Pádua, Serra Gaúcha. Apromontes, Altos Montes.

Ubeda C, Hornedo-Ortega R, Cerezo AB, Garcia-Parrilha MC (2020) Chemical hazards in grapes and wine, climate change and challenges to face. **Food Chem.** 314:126222. <https://doi.org/10.1016/j.foodchem.2020.126222>.

Vasconcelos MC, Greven M, Winefield CS, Trought MCT, Raw V (2009) The flowering process of *Vitis vinifera*: A review. **Am. J. Enol. Vitic.** 60:411–434. <https://doi.org/10.5344/ajev.2009.60.4.411>.

Venios X, Korkas E, Nisiotou A, Banilas G (2020) Grapevine responses to heat stress and global warming. **Plants** 9:1754. <https://doi.org/10.3390/plants9121754>.

Yang C, Menz C, Fraga H, Costafreda-Aumedes S, Leolini L, Ramos MC, Molitor D, Leewen C, Santos JA (2022) Assessing the grapevine crop water stress indicator over the flowering-veraison phase and the potential yield loss rate in important European wine regions. **Agric. Water Manag.** 261:107349. <https://doi.org/10.1016/j.agwat.2021.107349>.

Yates LA, Aandahl Z, Richards SA, Brook BW (2023) Cross validation for model selection: A review with examples from ecology. **Ecol. Monogr.** 93:e1557. <https://doi.org/10.48550/arXiv.2203.04552>.

Yuan Y, Chen X (2024) Vegetable and fruit freshness detection based on deep features and principal component analysis. **Curr. Res. Food Sci.** 8:100656. <https://doi.org/10.1016/j.crfs.2023.100656>.

Yu R, Brillante L, Martínez-Lüscher J, Kurtural SK (2020) Spatial variability of soil and plant water status and their cascading effects on grapevine physiology are linked to berry and wine chemistry. **Front. Plant Sci.** 11:790. <https://doi.org/10.3389/fpls.2020.00790>.

Wang J, Chen J, Zhang J, Yang S, Zhang S, Bai Y, Xu R (2023b) Consistency and uncertainty of remote sensing-based approaches for regional yield gap estimation: A comprehensive assessment of process-based and data-driven models. **F. Crop. Res.** 302:109088. <https://doi.org/10.1016/j.fcr.2023.109088>.

Wang Y, Li Y (2023) Mapping the ratoon rice suitability region in China using random forest and recursive feature elimination modeling. **F. Crop. Res.** 301:109016.

Wang Y, et al. (2023a) Environmental impact of organic and conventional wine grape production, a case study from Wuwei wine region, Gansu Province, China. **Ecol. Indic.** 154:110730. <https://doi.org/10.1016/j.ecolind.2023.110730>.

Zang R, Bian Z, Wu P, Liu Y, Li B, Xiong J, Zhang Y, Zhu B (2024) Nondestructive prediction of fruit detachment force for investigating postharvest grape abscission. **Postharvest Biol Technol** 209:112691. <https://doi.org/10.1016/j.postharvbio.2023.112691>.

Zhai W, Li C, Fei S, Liu Y, Ding F, Cheng Q, Chen Z (2023) CatBoost algorithm for estimating maize above-ground biomass using unmanned aerial vehicle-based multi-

source sensor data and SPAD values. **Comput. Electron. Agric.** 214:108306. <https://doi.org/10.1016/j.compag.2023.108306>.

Zhang D, Lin Z, Xuan L, Lu M, Shi B, Shi J, He F, Battino M, Zhao L, Zou X (2024) Rapid determination of geographical authenticity and pungency intensity of the red Sichuan pepper (*Zanthoxylum bungeanum*) using differential pulse voltammetry and Machine Learning algorithms. **Food Chem.** 439:137978. <https://doi.org/10.1016/j.foodchem.2023.137978>.

Zhao Z, Islam F, Waseem LA, Tariq A, Nawaz M, Islam IU, Bibi T, Rehman NU, Ahmad W, Aslam RW, Raza D, Hatamleh WA (2024) Comparison of three machine learning algorithms using Google Earth Engine for land use land cover classification. **Rangel. Ecol. Manag.** 92:129–137. <https://doi.org/10.1016/j.rama.2023.10.007>.

CAPÍTULO 3 – Modelagem da produtividade de uvas viníferas com aplicação de regressão não-linear

RESUMO – A videira (*Vitis vinifera* L.) é um dos cultivos mais relevantes globalmente, com as uvas sendo utilizadas principalmente para a produção de vinhos. Variáveis climáticas, como temperatura do ar e radiação solar, desempenham um papel crucial na produtividade e qualidades das uvas, influenciando diretamente o *terroir*. Modelos de regressão não-linear são amplamente utilizados para estimar a produtividade da videira, considerando a complexa interação entre múltiplas variáveis climáticas, o que é fundamental para otimizar a viticultura em diferentes regiões. Nessa perspectiva, objetiva-se aprofundar o entendimento das relações não lineares entre as variáveis climáticas e a produtividade da videira. Foram analisadas sete regiões vitivinícolas do Sul do Brasil, usando dados climáticos históricos (1982 – 2021) obtidos do NASA-Power e dados de produtividade da uva do Sidras IBGE. Na análise utilizou-se a correlação de Spearman para identificar as relações entre as variáveis climáticas e a produtividade, e modelos de regressão não-linear, especificamente o modelo de Holliday, para modelar a relação entre estas variáveis. A avaliação dos modelos incluiu métricas de desempenho como o coeficiente de determinação ajustado, erro percentual absoluto médio e erro quadrático médio da raiz, proporcionando uma visão detalhada da adequação e precisão das estimativas. A correlação de Spearman releva que a umidade relativa tem a maior correlação positiva, indicando que maiores níveis dessa variável estão associados a maiores produtividades. Em contraste, a evapotranspiração de referência apresenta uma correlação moderada negativa, em que aumentos na evapotranspiração de referência diminuem a produtividade. O modelo Holliday destaca a produtividade é otimizada dentro de faixas específicas para cada variável climática, indicando que variáveis como irradiância solar global de onda curta e temperatura média do ar têm um bom ajuste. A correlação e o desempenho do modelo para cada variável climática fornecem insights valiosos para otimizar práticas agrícolas e manejo de cultivos.

Palavras-chave: modelos de regressão não-linear, produtividade da uva, regiões vitivinícolas, variáveis climáticas, *Vitis vinifera* L.

3.1. Introdução

A videira (*Vitis vinifera* L.) é um dos cultivos de maior relevância global, destacando-se significativamente no cenário mundial (Semiromi et al., 2024). As bagas de uva são empregadas em uma ampla gama de atividades, dentre elas o mercado global de vinhos, que é um dos principais segmentos do consumo, avaliado em US\$ 326 bilhões, com uma Taxa de Crescimento Anual Composta (CAGR) projetada de 4,4% para o período de 2021 a 2026 (Lu et al., 2024; Li et al., 2021).

A Organização Internacional de Vinha e Vinho (OIV) estimou a produção média mundial em 260 milhões de hectolitros (Grazia et al., 2023; OIV, 2020). Em 2023, a área total global de vinhedos era de aproximadamente 7,20 milhões de hectares (Statista, 2024). Espanha, França e Itália são responsáveis por cerca de 53% da produção mundial de vinho (OIV, 2020). De acordo com os dados mais recentes do Our World in Data, em 2022, a produção de uva do Brasil foi de 1,45 milhões de toneladas, com a região sul do país responsável por 90% dessa produção de uvas vinícola (Brilinger et al., 2024; Our World in Data, 2024).

As videiras são cultivos sensíveis a fatores externos e internos (Mark Kliwer, Dokoozlian, 2005). A interação complexa entre esses fatores deu origem ao conceito de *terroir*, específico da viticultura (VanderWeide et al., 2021). Quando outros componentes do *terroir* são mantidos relativamente constantes, o clima exerce a influência mais significativa na adequação de uma região ou local para a produção de uvas de alta qualidade (Meggio, 2022).

A temperatura, em particular, é uma das variáveis climáticas mais importantes do *terroir*, afetando o crescimento, desenvolvimento, produtividade e qualidade das videiras, além de determinar as mudanças na fenologia (Su et al., 2024). Estudos de dados históricos de produtividade e clima indicam que o aumento das temperaturas durante a estação de crescimento tem impactado negativamente os rendimentos (Burroughs et al., 2023; Eck et al., 2020).

A exposição à luz solar desempenha um papel fundamental na formação da qualidade dos cachos de uva e bagas, afetando significativamente as vias fisiológicas e metabólicas das videiras, e influenciando o acúmulo de açúcar nas uvas (Lu et al., 2024). Portanto, alcançar uma exposição ideal à luz solar é essencial para maximizar

o teor de açúcar e melhorar a qualidade da uva, fatores cruciais para a qualidade final do vinho (Reynolds, 2022).

Dada a sua importância para o equilíbrio geral da videira, qualidade da uva e produtividade, é fundamental entender as relações hídricas em qualquer região vinícola (Meggio, 2022). A umidade atmosférica exerce uma influência substancial, impactando a demanda por evapotranspiração. Além disso, a precipitação é um fator crítico para o balanço hídrico do vinhedo; no entanto, precipitações intensas e persistentes podem impactar os vinhedos, resultando em escoamento superficial de nutrientes e água, e provocando perdas no solo por erosão (Meggio, 2022).

A formação do rendimento da videira é, portanto, uma questão complexa, envolvendo diversas variáveis (Merot et al., 2022). Modelos de previsão de produtividade frequentemente consideram a relação entre o rendimento e as variáveis climáticas (Schaber; Badeck, 2003), fundamentando-se em bases estatísticas (Semiromi et al., 2024).

Em termos concretos, o objetivo final de uma tarefa de regressão é prever um valor y a partir de um vetor de observações x (Huang et al., 2014). Para isso, é necessário adotar modelos de Regressão Não-Linear (LNR) que sejam capazes de capturar dados dinâmicos e a interação entre múltiplos fatores (Antonucci et al., 2021). Esses modelos devem ser aptos a lidar com séries temporais e a representar a complexa interação entre diversas variáveis (Ohana-Levi et al., 2020).

A Regressão Não-Linear (LNR) ocorre quando a função de regressão é representada graficamente por curvas de diferentes formas (Li et al., 2023). Em muitos problemas práticos, as funções de regressão tendem a ser não lineares e complexas, tornando seu uso amplamente difundido (Li et al., 2023).

Diversos estudos foram realizados com Regressão Não-Linear (LNR) em diferentes contextos agrícolas. No nordeste da Itália, modelos de NLR foram aplicados a séries temporais de parâmetros de maturação em cultivares de videira, como Merlot, Cabernet-Sauvignon, Glera e Garganega (Meggio, 2022). Na previsão fenológica da videira (*Vitis vinífera* L.), modelagens com parâmetros mínimos baseados na temperatura foram desenvolvidas no Irã (Semiromi et al., 2024). Ohana-Levi et al. (2020) destacaram o uso de modelos não lineares para avaliar a evapotranspiração do cultivo (ETc) e seus impactos na transpiração da videira.

Além da viticultura, a Regressão Não-Linear (LNR) também foi empregada em outros cultivos. Nos Estados Unidos, especificamente em Illinois, modelos não lineares foram utilizados para estudar o rendimento da soja em função do aumento da temperatura (Burroughs et al., 2023). Na Espanha, em Sevilha, modelos fenológicos de ervas daninhas (*Centaurea diluta*) baseados em respostas de crescimento a variáveis meteorológicas como temperatura e umidade foram desenvolvidos utilizando NLR (Sousa-Ortega et al., 2024). Adicionalmente, modelos não lineares foram aplicados para estimar temperaturas cardeais das sementes de chia (*Salvia hispanica* L.) (Cabrera-Santos et al., 2022).

A viticultura busca otimizar os vinhedos de acordo com os recursos naturais disponíveis (Meggio, 2022). Uma aplicação fundamental de modelos para determinar a relação entre a produtividade com as variáveis climáticas ajuda a entender esses efeitos e as interações entre o clima e a produtividade do cultivo. Nesse contexto, objetiva-se aumentar o entendimento das relações não lineares entre as variáveis climáticas e a produtividade da videira.

3.2. Material e Métodos

3.2.1. Caracterização da área de estudo

Sete regiões vitivinícolas diferentes, localizadas no Sul do Brasil, foram o alvo deste estudo (Figura 10). As regiões da Campanha Gaúcha (CG), Vale dos Vinhedos (VV), Farroupilha (FA) e Altos Montes (AM) estão localizadas no estado do Rio Grande do Sul – RS. As regiões de Vale das Uvas Goethe (GGV) e Vinhos de Altitude (HW) pertencentes ao estado de Santa Catarina, e a região de Vinhos de Bituruna (BW) faz parte do estado Paraná.




Figura 10. Áreas de estudo.

3.2.2. Dados climáticos e produtividade

Para este estudo foi considerado o período histórico: 1982 – 2021, a partir dos dados climáticos disponíveis no NASA-Power (<https://power.larc.nasa.gov/data-access-viewer/>). O conjunto de dados foi complementado com dados de produtividade do cultivo da uva, com a mesma série histórica, no Sidras IBGE (<https://sidra.ibge.gov.br/home/pimpfbr/brasil>). O Instituto Brasileiro de Geografia e Estatística (IBGE) é uma instituição pública que fornece diversas informações, incluindo dados produtivos dos principais cultivos do país.

Os dados climáticos históricos consistiram em irradiância solar global de onda curta (Q_g , $\text{MJ m}^{-2} \text{dia}^{-1}$), irradiância solar fotossinteticamente ativa (PAR, $\text{MJ m}^{-2} \text{dia}^{-1}$), radiação líquida na superfície da cultura (R_n , $\text{MJ m}^{-2} \text{dia}^{-1}$) (Eq. 1), temperatura média do ar (T , $^{\circ}\text{C}$), temperatura mínima do ar ($T_{\min}$, $^{\circ}\text{C}$), temperatura máxima do ar ($T_{\max}$, $^{\circ}\text{C}$), precipitação (P , mm dia^{-1}), umidade relativa a 2 metros (RH, %), umidade do solo na zona radicular (SH, N.U.), umidade absoluta (AH, $\text{g água vapor}^{-1} \text{m}^{-3}$) (Eq. 2) e evapotranspiração referência (E_{To} , mm dia^{-1}) (Eq. 3), calculada pelo método de Penman-Monteith FAO (Allen et al., 1998).

$$R_n = (1 - r) \times Q_g - \left(1.35 \times \frac{Q_o}{Q_{o_{CORR}}} - 0.35 \right) \times (0.35 - 0.14 \times \sqrt{es}) \times (5.67 \times 10^{-8}) \times \left(\frac{T_{\max}^4 + T_{\min}^4}{2} \right) \quad (1)$$

$$AH = \frac{2168 \times ea}{273.17 + T} \quad (2)$$

$$ET_o = \frac{0,408 \times \Delta \times (R_n - G) + \gamma \times \frac{900}{T+273} \times u_2 \times (e_s - e_a)}{\Delta + \gamma \times (1 + 0.34 \times u_2)} \quad (3)$$

onde r é a fração refletida da radiação solar incidente, Q_g é a radiação solar extraterrestre ($\text{MJ m}^{-2} \text{ dia}^{-1}$), $Q_{o\text{CORR}}$ é a correção para a radiação solar extraterrestre ($\text{MJ m}^{-2} \text{ dia}^{-1}$), e_s é a pressão de vapor de saturação (kPa), e_a é a pressão de vapor real (kPa), Δ é a tangente à curva de saturação ($\text{kPa } ^\circ\text{C}^{-1}$), G é a densidade de fluxo de calor do solo ($\text{MJ m}^{-2} \text{ dia}^{-1}$), γ é a constante psicométrica (kPa) e u_2 é a velocidade do vento a 2 m de altura (m s^{-1}).

As variáveis climáticas foram tratadas como variáveis dependentes no modelo, enquanto a produtividade da uva foi definida como a variável independente. O conjunto de dados incluiu onze variáveis dependentes e uma variável independente, abrangendo sete regiões distintas e uma série histórica de 39 anos.

3.2.3 Métodos estatísticos

Para a análise estatística, utilizou-se a correlação de Spearman, uma técnica estatística não paramétrica que avalia a relação monotônica entre duas variáveis. Este método examina se, à medida que uma variável aumenta, a outra tende a aumentar ou diminuir de forma consistente, independente de uma relação linear entre elas.

A análise de correlação de Spearman foi realizada em ambiente de programação Python (v.3.9.6), utilizando as bibliotecas Pandas (v.2.0.3), Numpy (v.1.26.3), Matplotlib (v.3.7.2) e Seaborn (v.0.13.2). Foram utilizados os valores máximos de cada variável climática para o cálculo de correlação, utilizando o método 'spearman'. Os dados foram organizados em uma coluna de valores absolutos e ordenados de forma decrescente.

Na interpretação dos resultados, o coeficiente de correlação de Spearman varia entre -1 e 1. O valor de 1 indica uma correlação perfeita positiva, sugerindo que, à medida que a variável climática aumenta, a produtividade também tende a aumentar. O valor de -1 indica uma correlação perfeita negativa, em que um aumento na variável climática está associado a uma diminuição na produtividade. Um valor de 0 refere-se à ausência de correlação monotônica entre as variáveis.

3.2.4 Modelagem Não-Linear

Modelos não lineares são preferidos em relação aos modelos empíricos, uma vez que seus parâmetros geralmente possuem interpretações práticas significativas (O'Brien, Silcox, 2024). A análise do *dataset* foi conduzida utilizando técnicas de regressão não-linear também no ambiente de programação Python (v.3.9.6), com as mesmas bibliotecas utilizadas na análise de correlação de Spearman.

Os valores máximos e mínimos de cada *feature* foram determinados, com intervalos específicos representados em nove faixas. Posteriormente, foi aplicado o modelo de Holliday (1960) (Eq. 4), com três parâmetros:

$$Y = \frac{X}{\alpha + b \cdot \beta + \gamma \cdot X^2} \quad (4)$$

onde α é o valor máximo de Y (t ha⁻¹), β é o intercepto (valor inicial quando X é igual a zero) e γ é a taxa média de crescimento.

Para o ajuste do modelo, foi criada a função objetivo e definidos os limites de busca dos parâmetros. Os valores finais desses parâmetros dependem dos limites a eles atribuídos. Utilizou-se o 'scipy.optimize.brute' para encontrar os parâmetros ótimos, aplicando um método de força bruta.

3.2.5 Métricas de desempenho

Para a avaliação dos modelos, foram utilizadas diversas métricas de desempenho, incluindo o coeficiente de determinação ajustado (R^2_{adj}) (Eq. 6), derivado do coeficiente de determinação (Eq. 5), o erro percentual absoluto médio (MAPE) (Eq. 7) e o erro quadrático médio da raiz (RMSE) (Eq. 8).

$$R^2 = \left[\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \right]^2 \quad (5)$$

$$R^2_{adj} = 1 - \frac{(1 - R^2)(n-1)}{n-k-1} \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad (8)$$

onde n representa o número total de amostras, x_i indica o i -ésimo valor medido, y_i denota o i -ésimo valor estimado, p_i é o valor previsto para a amostra i e k o número de variáveis independentes no modelo.

A métrica de R^2_{adj} é utilizada para avaliar a adequação dos modelos ajustados e sua capacidade de explicar a variabilidade dos dados, variando de 0 a 1.

O MAPE foi calculado para quantificar a precisão das estimativas em termos percentuais, oferecendo uma medida da magnitude do erro de estimação como uma porcentagem dos valores reais, o que permite uma interpretação relativa da precisão do modelo.

O RMSE foi calculado para quantificar a magnitude média dos erros de estimação, fornecendo uma medida da discrepância média entre os valores estimados e reais, com a mesma unidade de medida dos dados originais ($t \text{ ha}^{-1}$).

3.3. Resultados

A correlação de Spearman (Figura 11) mostra a relação entre as variáveis climáticas estudadas com a produtividade da videira, apresentando tanto correlações positivas quanto negativas, variando de -1 a +1. A variável umidade relativa (RH) obteve a maior correlação, com um valor de +0,78, indicando uma correlação positiva forte com a produtividade da videira. Esse resultado sugere que aumentos na produtividade estão associados a aumentos na RH. A evapotranspiração de referência (ET_o) apresentou a segunda maior correlação, com um valor de -0,68, indicando uma correlação negativa moderada com a produtividade. Isso implica que aumentos na ET_o estão associados a diminuição na produtividade. A temperatura mínima do ar (T_{min}) apresentou uma correlação positiva moderada de +0,47, sugerindo que aumentos na T_{min} estão moderadamente associados a aumentos na produtividade da videira.




Figura 11. Correlação de Spearman entre as variáveis climáticas, umidade relativa (RH), evapotranspiração de referência (ETo), temperatura mínima do ar (Tmin), irradiância solar fotossinteticamente ativa (PAR), umidade do solo (SH), umidade absoluta (AH), radiação líquida na superfície da cultura (Rn), irradiância solar global de onda curta (Qg), temperatura máxima do ar (Tmax), temperatura média do ar (T) e precipitação (P), e a produtividade da videira.

As correlações derivadas da irradiância solar fotossinteticamente ativa (PAR) tornam-se progressivamente mais fracas, com PAR apresentando uma correlação negativa de $-0,23$. Isso indica que o aumento de PAR está fracamente e negativamente associado a mudanças na produtividade. Para a umidade do solo (SH) e a umidade absoluta (AH), ambas as correlações foram positivas, $+0,20$ e $+0,18$, respectivamente. Esse resultado sugere que os aumentos em ambas as variáveis estão levemente associados com o aumento na produtividade, embora a correlação seja fraca.

As correlações de $-0,17$, $-0,12$, $-0,07$ e $-0,05$ para as variáveis radiação líquida na superfície da cultura (Rn), irradiância solar global de onda curta (Qg), temperatura máxima do ar (Tmax) e temperatura média do ar (T), respectivamente, foram negativas e fracas em relação a produtividade. Isso indica que mudanças na produtividade são pouco influenciadas por essas variáveis, de acordo com a correlação de Spearman. Por outro lado, a precipitação (P) não apresentou correlação significativa com a produtividade.

É importante considerar a variabilidade temporal e espacial das variáveis climáticas, visto que a correlação de Spearman foi realizada a partir dos valores máximos de cada variável, o que deve ser levado em consideração variações importantes que podem estar associadas a diferentes períodos ou regiões estudadas.


A análise da relação entre cada variável climática e a produtividade, juntamente com a curva ajustada do modelo Holliday (1960) com parâmetros otimizados para cada região estudada (Figura 3; Figura 4), proporciona uma compreensão detalhada dessas interações. Essas decisões são fundamentadas nos ajustes dos modelos para cada variável específica, auxiliando na tomada de decisões informadas para práticas agrícolas e manejo de cultivos.

A variável irradiância solar global de onda curta (Q_g) maximiza a produtividade na faixa de valores ótimos de 16,30 a 18,10 MJ m⁻² day⁻¹ (Tabela 6), alcançando uma produtividade máxima de 29,50 t ha⁻¹, que corresponde ao valor de α , um dos coeficientes de ajuste do modelo estudado. Na região da Campanha Gaúcha (CG) os valores de Q_g foram mais elevados, resultando em menores produtividades (Figura 12a). Nas demais regiões, como Altos Montes (AM), Farroupilha (FA), Vale dos Vinhedos (VV), Vale das Uvas Goethe (GGV) e Vinhos de Altitude (HW), os valores de Q_g estão concentrados em uma faixa aproximada, enquanto a região de Vinhos de Bituruna (BW) apresenta uma produtividade reduzida em comparação às outras regiões.

As variáveis irradiância solar fotossinteticamente ativa (PAR) e radiação líquida na superfície da cultura (R_n) (Figura 12b; Figura 12c) alcançaram suas máximas produtividades nas faixas de 88,00 a 93,00 MJ m⁻² day⁻¹, com uma produtividade de 24,30 t ha⁻¹ para PAR, e de 13,80 a 14,80 MJ m⁻² day⁻¹, com uma produtividade de 28,10 t ha⁻¹ para R_n . As regiões apresentaram comportamentos semelhantes aos observados para a variável Q_g , indicando padrões consistentes de resposta da produtividade às condições de PAR e R_n .

Para a temperatura média do ar (T) (Figura 12d), a faixa ótima está localizada entre 17,10 e 18,10 °C, atingindo uma produtividade máxima de 31,20 t ha⁻¹, que corresponde ao coeficiente α do modelo Holiday (1960) (Tabela 6). A maioria das regiões se concentra dentro dessa faixa de valores ótimos, com exceção da Campanha Gaúcha (CG), que apresenta temperaturas mais altas, e da região de

Vinhos de Altitude (HW), que apresenta temperaturas mais baixas, resultando em produtividades menores em ambos os casos. A temperatura máxima do ar (Tmax) (Figura 12e) apresenta valores ótimos entre 22,50 e 24,50 °C, destacando novamente a região da CG. Em relação à temperatura mínima do ar (Tmin) (Figura 12f), a faixa ótima de valores foi de 12,50 a 13,50 °C, com as regiões concentradas em uma faixa de valores semelhantes.







Figura 12. Produtividade como função de variáveis climáticas: irradiância solar global de onda curta (Qg) (a), irradiância solar fotossinteticamente ativa (PAR) (b), radiação líquida na superfície da cultura (Rn) (c), temperatura média do ar (T) (d), temperatura máxima do ar (Tmax) (e) e temperatura mínima do ar (Tmin) (f), para as regiões estudadas, incluindo Campanha Gaúcha (CG), Altos Montes (AM), Farroupilha (FA), Vale dos Vinhedos (VV), Vale das Uvas Goethe (GGV), Vinhos de Altitude (HW) e Vinhos de Bituruna (BW), aplicada ao modelo de Holliday.

A análise dos gráficos mostra que a produtividade é altamente dependente da faixa ótima de cada variável climática. As regiões que se mantêm dentro dessas faixas tendem a alcançar produtividades maiores.

A precipitação (P) apresentou valores ótimos para a maximização da produtividade, alcançando um coeficiente α de 28,30 t ha⁻¹, dentro da faixa 29 a 38 mm day⁻¹ (Tabela 6). A distribuição dos valores para todas as regiões analisadas concentra-se nesta faixa (Figura 13a). No entanto, a variável umidade relativa (RH) exibe um comportamento diferencial entre as regiões estudadas, destacando-se a região da Campanha Gaúcha (CG).

Em contraste com as variáveis umidade do solo (SH) (Figura 13c) e umidade absoluta (AH) (Figura 13d), em que os valores entre as regiões são relativamente próximos, com a faixa ótima para SH variando de 0,70 a 0,75 e para AH entre 12,00 a 12,70 g água vapor⁻¹ m⁻³ a variável evapotranspiração de referência (ETo) exibe um padrão diferente. Os valores ótimos para ETo situam-se entre 23,00 e 27,00 mm day⁻¹.

¹, sendo que a região da Campanha Gaúcha apresenta maiores valores de ETo e os menores índices de produtividade (Figura 13e).






Figura 13. Produtividade como função de variáveis climáticas: precipitação (P) (a), umidade relativa (RH) (b), umidade do solo (SH) (c), umidade absoluta (AH) (d) e evapotranspiração de referência (ETo) (e), para as regiões estudadas, incluindo Campanha Gaúcha (CG), Altos Montes (AM), Farroupilha (FA), Vale dos Vinhedos (VV), Vale das Uvas Goethe (GGV), Vinhos de Altitude (HW) e Vinhos de Bituruna (BW), aplicada ao modelo de Holliday.

A variação dos valores de α (Tabela 6) na redução da produtividade em função de cada variável climática é ajustada através da modelagem. Os valores dos parâmetros β e γ também variam conforme o ajuste aplicado, sendo que para γ , cada unidade adicional da variável climática resulta em um aumento na produtividade. Especificamente, para a variável Q_g , cada $\text{MJ m}^{-2} \text{ day}^{-1}$ e T , cada $^{\circ}\text{C}$, contribuem para um incremento de $0,10 \text{ t ha}^{-1}$ na produtividade, enquanto para AH , cada $\text{g água vapor } ^{-1} \text{ m}^{-3}$ resulta em um aumento de $0,20 \text{ t ha}^{-1}$.

Para avaliar o desempenho de cada variável, foram empregadas métricas de avaliação como o coeficiente de determinação ajustado (R^2_{adj}), o erro percentual absoluto médio (MAPE) e o erro quadrático médio da raiz (RMSE). O R^2_{adj} reflete a proporção da variabilidade dos dados que é explicada pelo modelo Holiday (1960). Os valores mais elevados desta métrica foram 0,95, 0,90 e 0,81, das variáveis R_n , T_{min} e Q_g , respectivamente, indicando que o modelo explica de forma substancial a variabilidade dos dados. Em contraste, para as variáveis P , ET , AH e RH , os valores de R^2_{adj} foram relativamente baixos, 0,36, 0,35, 0,30 e 0,24, respectivamente, sugerindo que o modelo explica de forma limitada a variabilidade dessas variáveis.

A métrica de precisão, MAPE, avalia a acurácia do modelo em termos percentuais. Valores baixos de MAPE indicam maior precisão do modelo. Neste contexto, as variáveis SH, PAR e T apresentaram os melhores desempenhos com MAPE de 23,25, 23,55 e 24,19, respectivamente. Em contraste, as variáveis RH, P e AH apresentaram valores de MAPE mais elevados, de 57,24, 48,51 e 46,42, indicando menor precisão do modelo para essas variáveis.

Para o RMSE, que mede a diferença entre os valores estimados e observados, quanto menores os valores, melhor a precisão do modelo. As previsões mais precisas foram obtidas para T, Tmax e PAR, com RMSE de 3,29, 4,74 e 4,82 t ha⁻¹, respectivamente. Por outro lado, as previsões com menor precisão foram obtidas para ETo, Rn e Qg, com RMSE de 8,85, 7,56 e 7,35 t ha⁻¹, respectivamente.

Tabela 6. Coeficientes α , β e γ do modelo Holliday (1960), valores ótimos para cada variável e métricas de desempenho correspondentes: coeficiente de determinação ajustado (R^2_{adj}), erro percentual absoluto médio (MAPE) e erro quadrático médio da raiz (RMSE, em t ha⁻¹).

Variáveis	α	β	γ	Valores ótimos	R^2_{adj}	MAPE	RMSE
RH (%)	29,30	-0,55	0,03	77,00 – 82,00	0,24	57,24	6,70
ETo (mm day ⁻¹)	29,65	-2,40	0,05	23,00 – 27,00	0,35	44,94	8,85
Tmin (°C)	34,20	-3,85	0,15	12,50 – 13,50	0,90	27,07	6,47
PAR (MJ m ⁻² dia ⁻¹)	24,30	-0,50	0,03	88,00 – 93,00	0,25	23,55	4,82
SH (N.U.)	27,00	0,05	0,01	0,70 – 0,75	0,79	23,25	5,86
AH (g água vapor ⁻¹ m ⁻³)	30,40	-4,90	0,20	12,00 – 12,70	0,30	46,42	5,77
Rn (MJ m ⁻² dia ⁻¹)	28,10	-2,80	0,10	13,80 – 14,80	0,95	36,62	7,56
Qg (MJ m ⁻² dia ⁻¹)	29,50	-3,40	0,10	16,30 – 18,10	0,81	29,54	7,35
Tmax (°C)	28,50	-2,35	0,05	22,50 – 24,50	0,54	40,14	4,74
T (°C)	31,20	-3,50	0,10	17,10 – 18,10	0,70	24,19	3,29
P (mm dia ⁻¹)	28,30	-0,10	0,01	29,00 – 38,00	0,36	48,51	5,73

O modelo ideal é caracterizado por altos valores da métrica R^2_{adj} e baixos valores das métricas MAPE e RMSE. No caso da variável Qg, o R^2_{adj} elevado (0,81) indica uma explicação robusta da variabilidade dos dados. No entanto, o MAPE moderado (29,54) sugere que a precisão do modelo pode ser aprimorada, e o RMSE relativamente alto (7,35) aponta para a possibilidade de melhorias na previsão do modelo. Para a variável temperatura (T), o R^2_{adj} é satisfatório (0,70), demonstrando

uma boa explicação da variabilidade dos dados. O MAPE é moderado (24,19), enquanto o RMSE é baixo (3,29), ambos sugerem que o modelo oferece previsões relativamente precisas.

Em resumo, para a variável Qg, o modelo apresenta uma boa explicação dos dados, mas com potencial para melhorias na precisão; para a variável T, o modelo apresenta um equilíbrio favorável entre a explicação da variabilidade e a precisão das previsões. Para as demais variáveis, há uma correlação inversa entre o MAPE e o R^2_{adj} , em que maiores valores de MAPE estão associados a menores valores de R^2_{adj} .

3.4. Discussão

O cultivo da videira para a vinificação está intrinsicamente ligado às condições climáticas (Arias et al., 2022). No entanto, a extensão com que os fatores ambientais influenciam a produtividade da viticultura varia de maneira significativa entre diferentes regiões (Schultz, 2022).

As temperaturas mínimas e máximas ótimas foram encontradas em 12,50 °C e 22,5 °C (Tabela 6), alinhando-se com as faixas de temperaturas médias do ar recomendadas para a videira, que variam entre 12 a 22 °C ao longo do ciclo de crescimento (Arias et al., 2022). Essas temperaturas são comparáveis a encontradas em estudos prévios, como os reportados para vinhedos em La Rioja, Espanha, onde as temperaturas máximas e mínimas ideais foram de 24,10 e 12,8 °C, respectivamente (Ramos; Martínez de Toda, 2019).

Modelagens climáticas realizadas no sul da Austrália indicam que a temperatura média durante a estação de crescimento é um preditor significativo para a data de colheita (Webb et al., 2012). A temperatura é uma das principais impulsionadoras da evolução do ciclo de crescimento, maturidade e composição da baga das uvas (Kaya et al., 2024). Seu aumento contínuo está associado a elevações nos níveis de álcool, diminuições na acidez e alterações na maturação dos taninos, resultado em características menos refinadas (Li et al., 2024), impactando a produtividade da videira (Arias et al., 2022).

À medida que as temperaturas foram aumentando, de 15 a 21 °C, a evapotranspiração de referência (ET_o) também aumentou, variando de 20 a 45 mm dia⁻¹, particularmente nas regiões de Vinhos de Altitude (HW), Vinhos de Bituruna

(BW) e Campanha Gaúcha (CG) (Figura 12d; Figura 13e). Esse fenômeno sugere que o aumento da temperatura pode intensificar a evapotranspiração (Ramos e Martínez de Toda, 2019).

Os efeitos das variáveis climáticas na qualidade da uva, com foco na radiação solar, foram modelados na região do Vale do Mosela, na Alemanha (Ashenfelter; Storchmann, 2010). O aumento dos níveis de radiação solar também exerce uma influencia direta sobre a qualidade das uvas e do vinho nas regiões vitícolas europeias (Grazia et al., 2023).

O aumento na radiação solar pode afetar a composição das uvas de vinhos e, consequentemente, na qualidade do vinho (Grazia et al., 2023). No entanto, enquanto a água não for um fator limitante, a fotossíntese da videira aumenta com a intensidade da luz até um terço da radiação máxima e depois se nivela (Jiang et al., 2025), a quantidade de antocianina nas cascas de uva também aumenta com a luz, mas é afetada negativamente pelas altas temperaturas.

A faixa de umidade relativa máxima (RH) de 77,00 a 82,00 % (Tabela 1) está em consonância com os valores encontrados para a videira Santa Catarina, Brasil, que variam entre 65,00 a 90,00 % (Brilinger et al., 2024). De maneira similar, um valor de 78,00% foi registrado para a videira 'Niagara Rosada' no estado de São Paulo, Brasil (Pedro Júnior et al., 2011).

Os produtores de uva podem utilizar essas informações para ajustar suas práticas de manejo. Como por exemplo, sabendo que a umidade relativa tem um forte impacto positivo, podem-se implementar estratégias para manter ou aumentar a umidade relativa ao redor das videiras. Por outro lado, a correlação negativa da evapotranspiração de referência pode indicar a necessidade de práticas que reduzam a perda de água do solo, como o uso de coberturas mortas ou técnicas de irrigação eficientes.

Regiões que apresentam valores fora dessas faixas, como Vinhos de Altitude (HW) e Campanha Gaúcha (CG), tendem a ter produtividades menores, sugerindo que ajustes nas práticas agrícolas ou intervenções climáticas podem ser necessárias para otimizar a produção.

3.5. Conclusões

A umidade relativa, temperatura mínima do ar, umidade do solo e umidade absoluta apresentaram correlações de Spearman positiva com a produtividade da videira, indicando que aumentos nestas variáveis estão associados a aumentos na produtividade. Na análise dos modelos, as variáveis com melhores desempenhos foram irradiância solar global de onda curta e temperatura média do ar, resultando em um equilíbrio entre a explicação da variabilidade dos dados e a precisão das estimações.

A correlação e o desempenho do modelo para cada variável climática fornecem insights valiosos para otimizar práticas agrícolas e manejo de cultivos. A variação da faixa de valores ótimos para cada variável climática em diferentes regiões vitivinícolas sugere que a produtividade da videira é dependente das condições climáticas específicas de cada região. Como a Campanha Gaúcha, que apresentou valores extremos em algumas variáveis o que afetou negativamente a produtividade.

Referências

Allen RG, Pereira LS, Raes D, Smith M (1998) **FAO irrigation and drainage paper Nº. 56**. Food and Agriculture Organization of the United Nations, Rome.

Antonucci G, Croci M, Miras-Moreno B, Fracasso A, Amaducci S (2021) Integration of gas exchange with metabolomics: high-throughput phenotyping methods for screening biostimulant-elicited beneficial responses to short-term water deficit. **Front. Plant Sci.** 12. <https://doi.org/10.3389/fpls.2021.678925>.

Arias LA, Berli F, Fontana A, Bottini R, Piccoli P (2022) Climate change effects on grapevine physiology and biochemistry: benefits and challenges of high altitude as an adaptation strategy. **Front. Plant Sci.** 13. <https://doi.org/10.3389/fpls.2022.835425>.

Ashenfelter O, Storchmann K (2010) Using hedonic models of solar radiation and weather to assess the economic effect of climate change: The case of Mosel Valley vineyards. **Rev. Econ. Stat.** 92(2):333–349. <https://doi.org/10.1162/rest.2010.11377>.

Brilinger D, Arioli CJ, Werner SS, Wertheim B, Boff MIC (2024) *Drosophila suzukii* (Diptera: Drosophilidae): An exotic pest of small fruits in Cabernet Sauvignon vineyards of Santa Catarina State, Brazil. **Crop Protect.** 182:105081. <https://doi.org/10.1016/j.cropro.2024.106738>.

Burroughs CH, Montes CM, Moller CA, Mitchell NG, Michael AM, Peng B, Kimm H, Pederson TL, Lipka AE, Bernacchi CJ, Guan K, Ainsworth EA (2023) Reductions in leaf area index, pod production, seed size, and harvest index drive yield loss to high temperatures in soybean. **J. Exp. Bot.** 74(5):1629–1641. <https://doi.org/10.1093/jxb/erac503>.

Cabrera-Santos D, Ordoñez-Salanueva CA, Sampayo-Maldonado S, Campos JE, Orozco-Segovia A, Flores-Ortiz CM (2022) Quantifying cardinal temperatures of chia (*Salvia hispanica* L.) using Nonlinear Regression models. **Plants** 11:1142. <https://doi.org/10.3390/plants11091142>.

Eck MA, Murray AR, Ward AR, Konrad CE (2020) Influence of growing season temperature and precipitation anomalies on crop yield in the southeastern United States. **Agric. For. Meteorol.** 291:108053. <https://doi.org/10.1016/j.agrformet.2020.108053>.

Grazia D, Mazzocchi C, Ruggeri G, Corsi S (2023) Grapes, wines, and changing times: A bibliometric analysis of climate change influence. **Aust. J. Grape Wine Res.** <https://doi.org/10.1155/2023/9937930>.

Huang H, Windig JJ, Vereijken A, Calus MP (2014) Genomic prediction based on data from three-layer lines using Nonlinear Regression models. **Genetics Selection Evolution** 46(1):75. <https://doi.org/10.1186/s12711-014-0075-3>.

Jiang H, Zhao S, Li S, Wang H, Han X, Guan W (2025) Effect of alternating magnetic field on ice crystal nucleation and its application for near-freezing temperature storage of grapes. **J. Future Foods** 5(2):193–199. <https://doi.org/10.1016/j.jfutfo.2024.05.008>.

Kaya O, Yilmaz T, Ates F, Kustutan F, Hatterman-Valenti H, Hajizadeh HS, Turan M (2024) Improving organic grape production: the effects of soil management and organic fertilizers on biogenic amine levels in *Vitis vinifera* cv., “Royal” grapes. **Chem. Biol. Technol. Agric.** 11(1). <https://doi.org/10.1186/s40538-024-00564-2>.

Li D, Yang J, Dai Z, Chen Y, Shao Z, Wang C, Jin X, Wang Y, Feng L (2024) Prohexadione-calcium improves grape quality by regulating endogenous hormones, sugar and acid metabolism and related enzyme activities in grape berries. **BMC Plant Biol.** 24(1):122. <https://doi.org/10.1186/s12870-024-04803-4>.

Li X, et al. (2023) Soybean leaf estimation based on RGB images and machine learning methods. *Plant Methods* 19(1):59. <https://doi.org/10.1186/s13007-023-01023-z>

Li YM, Forney C, Bondada B, Leng F, Xie Z (2021) The molecular regulation of carbon sink strength in grapevine (*Vitis vinifera* L.). **Front. Plant Sci.** 11. <https://doi.org/10.3389/fpls.2020.606918>.

Lu L, Delrot S, Liang Z (2024) From acidity to sweetness: a comprehensive review of carbon accumulation in grape berries. **Mol. Hortic.** 4(1). <https://doi.org/10.1186/s43897-024-00100-8>

Kliewer WK, Dokoozlian NK (2005) Leaf area/crop weight ratios of grapevines: influence on fruit composition and wine quality. **Am. J. Enol. Vitic.** 56(2).

Meggio F (2022) The interplay between grape ripening and weather anomalies in Northern Italy – A modelling exercise. **OENO One** 56(2):353–373. <https://doi.org/10.20870/oeno-one.2022.56.2.5438>.

Merot A, Metay A, Smits N, Thiolllet-Scholtus M (2022) Adaptation of the regional agronomic diagnosis for grapevine yield analysis. **OENO One** 56(1):87–99. <https://doi.org/10.20870/oeno-one.2022.56.1.4568>.

O'Brien TE, Silcox JW (2024) Nonlinear Regression modelling: a primer with applications and caveats. **Bull. Math. Biol.** 86(4):40. <https://doi.org/10.1007/s11538-024-01274-4>.

Ohana-Levi N, Munitz S, Ben-Gal A, Netzer Y (2020) Evaluation of within-season grapevine evapotranspiration patterns and drivers using generalized additive models. *Agric. Water Manag.* 228:105808. <https://doi.org/10.1016/j.agwat.2019.105808>.

Our World in Data (2024) **Grape production**. Food and Agriculture Organization of the United Nations. Disponível em: < <https://ourworldindata.org/grapher/grapes-production?time=2022> >. Acesso em: 08 jan. 2024.

Pedro Júnior MJ, Hernandez JL, Rolim GS de S (2011) Sistema de condução em Y com e sem cobertura plástica: microclima, produção, qualidade do cacho e ocorrência de doenças fúngicas na videira “Niagara Rosada.” **Bragantia** 70(1):228–233. <https://doi.org/10.1590/S0006-87052011000100030>.

Ramos MC, Martínez de Toda F (2019) Variability of Tempranillo grape composition in the Rioja DOCa (Spain) related to soil and climatic characteristics. **J. Sci. Food Agric.** 99(3):1153–1165. <https://doi.org/10.1002/jsfa.9283>.

Reynolds AG (2022) **Viticultural and vineyard management practices and their effects on grape and wine quality**. In *Managing Wine Quality*. Elsevier, pp. 443–539.

Schaber J, Badeck FW (2003) Physiology-based phenology models for forest tree species in Germany. **Int. J. Biometeorol.** 47(4):193–201. <https://doi.org/10.1007/s00484-003-0171-5>.

Schultz H (2022) Soil, vine, climate change; the challenge of predicting soil carbon changes and greenhouse gas emissions in vineyards and is the 4 per 1000 goal

realistic? **OENO One** 56(2):251–263. <https://doi.org/10.20870/oeno-one.2022.56.2.5447>.

Semiromi J, Amirizadeh S, Meighani H (2024) New simple approach to the site-specific prediction of grapevine (*Vitis vinifera*) phenological phases (The case of Kerman, Iran). **Agric. Forest Meteorol.** 353. <https://doi.org/10.1016/j.agrformet.2024.110057>.

Sousa-Ortega C, Alcántara C, Leon RG, Barranco-Elena D, Saavedra M (2024) The impact of burial depth on *Centaurea diluta* emergence and modelling of its growth using a Nonlinear Regression and artificial neural network. **Pest Manag. Sci.** 80(3):1182–1192. <https://doi.org/10.1002/ps.7848>.

Statista (2024) **Grape production worldwide from 2012/2013 to 2023/2024**. Disponível em: <https://www.statista.com/statistics/193913/top-10-grape-producing-us-states/>>. Acesso em: 08 jan. 2024.

Su Y, Li X, Cao Z, Gao Z, Du Y (2024) Effects of long-term high temperatures in the root zone on the physiological characteristics of grapevine leaves and roots: implications for viticulture practices. **Horticulturae** 10(3):245. <https://doi.org/10.3390/horticulturae10030245>

VanderWeide J, Gottschalk C, Schultze SR, Nasrollahiazar E, Poni S, Sabbatini P (2021) Impacts of pre-bloom leaf removal on wine grape production and quality parameters: A systematic review and meta-analysis. **Front. Plant Sci.** 11. <https://doi.org/10.3389/fpls.2020.621585>

Webb LB, Whetton PH, Bhend J, Darbyshire R, Briggs PR, Barlow EWR (2012) Earlier wine-grape ripening driven by climatic warming and drying and management practices. **Nat. Clim. Change** 2(4):259–264. <https://doi.org/10.1038/nclimate1417>.

CAPÍTULO 4 – Considerações finais

A presente tese representa um avanço significativo na compreensão das interações entre as variáveis climáticas e a produtividade da videira, um tema de grande relevância no contexto atual acerca da variabilidade climática e suas implicações para a agricultura. Ao explorar as influências das condições climáticas na fenologia da videira e na produtividade em diferentes regiões, a pesquisa introduz novas perspectivas sobre como a variabilidade climática afeta o cultivo da videira, oferecendo uma base sólida para futuras investigações e práticas agrícolas mais sustentáveis, enfatizando a importância de considerar o contexto regional na viticultura.

Os avanços técnicos proporcionados pela pesquisa realizada se manifestam na adoção de modelos de aprendizagem de máquina, como o CatBoost, que demonstraram uma capacidade preditiva superior em relação a modelos tradicionais. Esta abordagem não apenas aprimora a precisão das estimativas de produtividade, mas também oferece uma plataforma para o desenvolvimento de ferramentas de tomada de decisão baseadas em dados, essenciais para a modernização da agricultura. A utilização dessas técnicas pode ser expandida para outros contextos agrícolas, favorecendo a inovação na gestão de cultivos.

Os resultados obtidos têm importantes aplicações socioeconômicas, especialmente em regiões vitivinícolas, onde a produção de vinho é uma atividade econômica significativa. Ao proporcionar uma compreensão mais clara das relações entre as variáveis climáticas e a produtividade, a pesquisa pode auxiliar os produtores na adoção de práticas mais eficientes e sustentáveis, contribuindo para a redução de perdas e aumento da qualidade dos produtos. Isso não apenas beneficia os agricultores, mas também impacta positivamente a economia local e regional, promovendo um desenvolvimento mais sustentável da viticultura.

O universo científico no qual este trabalho se insere é de extrema relevância, contribuindo para o avanço do conhecimento na área de modelagem agrometeorológica. O desenvolvimento de soluções inovadoras e sustentáveis para a viticultura exige um compromisso contínuo com a pesquisa e a aplicação prática do conhecimento, promovendo uma agricultura mais resiliente e sustentável.

APÊNDICES

APÊNDICE A – Principais cultivares de uva por região e os vinhos produzidos


Tabela A1. Cultivares de uvas e vinhos produzidos nas principais regiões vinícolas do Brasil.

Cultivares	Vinhos/Espumantes
Campanha Gaúcha ¹ – CG (Rio Grande do Sul)	
Cabernet Franc	Vinho Fino Tinto Seco
Cabernet Sauvignon	Vinho Fino Tinto/Vinho Fino Rosé
Chardonnay	Vinho Fino Branco/Espumante Fino
Gewürztraminer	Vinho Fino Branco
Malbec	Vinho Fino Tinto Seco
Merlot	Vinho Fino Tinto/Vinho Fino Rosé/Espumante Fino
Petit Verdot	Vinho Fino Tinto Seco
Pinot Grigio (Pinot Gris)	Vinho Fino Branco
Pinot Noir	Vinho Fino Tinto/ Vinho Fino Rosé/Espumante Fino
Pinotage	Vinho Fino Tinto Seco
Riesling Renano	Espumante Fino
Sauvignon Blanc	Vinho Fino Branco/Espumante Fino
Syrah	Vinho Fino Tinto Seco
Tannat	Vinho Fino Tinto Seco
Tempranillo (Tinta Roriz, Aragonês)	Vinho Fino Tinto Seco
Altos Montes ² – AM (Rio Grande do Sul)	
Ancellota	Vinho Fino Tinto Seco
Cabernet Franc	Vinho Fino Tinto Seco
Cabernet Sauvignon	Vinho Fino Tinto Seco
Chardonnay	Espumante Fino Branco/Espumante Fino Rosé/ Vinho Fino Tinto Seco
Gewürztraminer	Vinho Fino Tinto Seco
Malvasia de Cândia	Vinho Fino Tinto Seco
Marselan	Vinho Fino Tinto Seco
Merlot	Vinho Fino Tinto Seco/ Vinho Fino Rosé Seco
Moscato Giallo	Vinho Fino Tinto Seco
Pinot Noir	Espumante Fino Branco/Espumante Fino Rosé/ Vinho Fino Tinto Seco
Refosco	Vinho Fino Tinto Seco
Riesling Itálico	Espumante Fino Branco/Espumante Fino Rosé/ Vinho Fino Tinto Seco
Sauvignon Blanc	Vinho Fino Branco Seco
Tannat	Vinho Fino Tinto Seco
Trebbiano	Espumante Fino Branco/Espumante Fino Rosé
Farroupilha ³ – FA (Rio Grande do Sul)	
Malvasia Bianca	

Malvasia de Cândia (aromática)	
Moscatel de Alexandria	Vinho Muscatel/
Moscato Bianco	Vinho Fino Branco Muscatel/
Moscato Branco (tradicional)	Espumante Muscatel/
Moscato Giallo	Vinho Licoroso Muscatel/
Moscato de Hamburgo	Mistela Simples Muscatel/
Moscato Rosado	
Vineyards Valley ⁴ – VV (Rio Grande do Sul)	
Cabernet Franc	Vinho Fino Tinto Seco
Cabernet Sauvignon	Vinho Fino Tinto Seco
Chardonnay	Vinho Fino Branco Seco/Espumante Fino Branco/ Espumante Fino Rosé
Merlot	Vinho Fino Tinto Seco
Pinot Noir	Espumante Fino Branco/Espumante Fino Rosé
Riesling Itálico	Vinho Fino Branco Seco/Espumante Fino Branco/ Espumante Fino Rosé
Tannat	Vinho Fino Tinto Seco
Goethe Grape Valleys ⁵ – GGV (Santa Catarina)	
Goethe (Roger 1)	Vinho Branco Seco/Suave ou Vinho Branco Semi-Seco/
Goethe Primo	Vinho Branco Seco Leve/Suave ou Vinho Branco Semi-Seco
Goethe Cristal	Espumante e Vinho Semi-Seco/
Highland Wines ⁶ – HW (Santa Catarina)	
Cabernet Franc	Vinho Tinto
Cabernet Sauvignon	Vinho Tinto
Chardonnay	Vinho Branco
Gewürztraminer	Vinho Branco
Merlot	Vinho Tinto
Pinot Noir	Vinho Tinto
Sangiovese	Vinho Tinto
Sauvignon Blanc	Vinho Branco
Bituruna Wines ⁷ – BW (Paraná)	
Bordô	Vinho de Mesa Branco Suave, Seco ou Semi-Seco/
Martha	Vinho de Mesa Suave, Seco ou Semi-Seco

¹ <https://www.gov.br/inpi/pt-br/servicos/indicacoes-geograficas/arquivos/cadernos-de-especificacoes-tecnicas/CampanhaGacha.pdf>; ² <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/94888/1/doc085.pdf>; ³ <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/168084/1/Doc107.pdf>; ⁴ <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/94689/1/doc084.pdf>; ⁵ <https://www.gov.br/inpi/pt-br/servicos/indicacoes-geograficas/arquivos/cadernos-de-especificacoes-tecnicas/ValesdaUvaGoethe.pdf>; ⁶ http://revistas.inpi.gov.br/pdf/Indicacoes_Geograficas2634.pdf; ⁷ http://revistas.inpi.gov.br/pdf/Indicacoes_Geograficas2702.pdf.

APÊNDICE B – Correlação de Spearman






Figura A1. Correlação entre variáveis climáticas e produtividade ao longo dos estágios fenológicos da uva. Variáveis dependentes: irradiância solar global de onda curta (Qg), temperatura média do ar (T), temperatura mínima (Tmin), precipitação (P), radiação líquida na superfície da cultura (RN), umidade absoluta (AH), irradiância solar fotossinteticamente ativa (PAR), temperatura máxima (Tmax), umidade relativa (RH), umidade do solo na zona das raízes (SH) e evapotranspiração de referência (ETo). Estágios fenológicos: poda (PR), brotação (SP), floração (FL), frutificação (4 mm – FRB), frutificação (7 mm – FRP) e maturação (MA).