



UNIVERSIDADE REGIONAL DO NOROESTE DO ESTADO DO RIO GRANDE DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

VANESSA PANSERA

**MODELAGEM MATEMÁTICA DOS EFEITOS DA ÉPOCA DE
SEMEADURA DA AVEIA NA DEFINIÇÃO DE UM ZONEAMENTO DE
ESCAPE ÀS DOENÇAS FOLIARES**

IJUÍ-RS, 2022

Vanessa Pansera

**MODELAGEM MATEMÁTICA DOS EFEITOS DA ÉPOCA DE
SEMEADURA DA AVEIA NA DEFINIÇÃO DE UM ZONEAMENTO DE
ESCAPE ÀS DOENÇAS FOLIARES**

Tese de Doutorado submetida ao Programa de Pós-Graduação em Modelagem Matemática e Computacional da Universidade Regional do Noroeste do Estado do Rio Grande do Sul - UNIJUÍ - como parte dos requisitos necessários para a obtenção do Grau de Doutora em Modelagem Matemática.

José Antonio Gonzalez da Silva
Professor Orientador

Ijuí-RS, 2022

Catalogação na Publicação

P196m

Pansera, Vanessa

Modelagem matemática dos efeitos da época de semeadura da aveia na definição de um zoneamento de escape às doenças foliares / Vanessa Pansera . – Ijuí, 2022.

171 f. : il. ; 30 cm.

Tese (doutorado) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul (Campus Ijuí). Modelagem Matemática e Computacional.

“Orientador: José Antonio Gonzalez da Silva.”

1. Matemática aplicada. 2. Modelagem computacional. 3. Inteligência artificial. 4. Avena sativa. 5. Fungicida. I. Silva, José Antonio Gonzalez da. II. Título.

CDU: 510.67:633.13

Cristina Libert Wiedtkenper

CRB 10/2651

UNIJUÍ - Universidade Regional do Noroeste do Estado do Rio Grande do Sul

A Comissão Examinadora, abaixo assinada, aprova a Tese

**Modelagem Matemática dos efeitos da época de
semeadura da Aveia na definição de um zoneamento de
escape às doenças foliares**

Elaborada por


VANESSA PANSERA

Como requisito parcial para a obtenção do título de Doutora em Modelagem Matemática

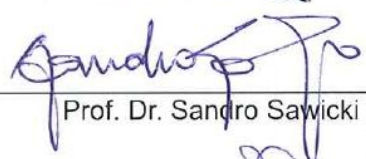
Comissão Examinadora



Prof. Dr. José Antonio Gonzalez da Silva (Orientador/UNIJUÍ)



Prof. Dr. Manuel Osorio Bino (UNIJUÍ)




Prof. Dr. Sandro Sawicki (UNIJUÍ)



Profª. Drª. Jana Koefender (UNICRUZ)



Prof. Dr. André Schöffel (UNICRUZ)



Profª. Drª. Ângela Teresinha Wcschinski de Mamann (IFRS)

Ijuí, RS, 28 de outubro de 2022.

AGRADECIMENTOS

A Deus, pela segurança em todas as viagens e pela serenidade e sabedoria nos momentos turbulentos. Também pela saúde e segurança, minhas e de meus familiares e amigos, durante a pandemia.

Aos meus pais, Marinês e Valdo, por todo o apoio e amor recebidos. Também ao meu irmão Fernando, minha cunhada Janaíne e minha sobrinha que está a caminho. Sou grata por ter essa família!

Ao meu amor, Albeneir, por sempre me apoiar e estar ao meu lado. Que possamos colher juntos os frutos dos nossos esforços, sendo muito felizes. Amo você!

Ao meu melhor amigo, Odenis, por ser o meu parceiro nessa jornada matemática e da vida. Com certeza a sua presença nessa caminhada acadêmica tornou-a mais leve e feliz. Você, além de ser o meu melhor amigo, é um ótimo amigo!

Ao meu professor orientador, José, pelo aprendizado e por me proporcionar a oportunidade de fazer parte de um ótimo grupo de pesquisa.

Aos professores do Programa de Pós-Graduação em Modelagem Matemática e Computacional, pelos ensinamentos.

Ao Grupo de Pesquisa Sistemas Técnicos de Produção Agropecuária, pela parceria durante essa caminhada.

Ao Bruno, pela parceria durante a implantação e desenvolvimento das atividades experimentais. Além de conhecermos um ótimo funcionário, ganhamos um amigo.

Às secretárias, Jéssica e Luana, pela disponibilidade e disposição em nos atender.

Aos colegas professores e gestores da EMEF Arlindo de Souza Mattos, da EMEF Zeferino Demétrio Costi e da Secretaria Municipal de Educação de Passo Fundo, pelo apoio e carinho recebidos durante a trajetória.

A todos os meus amigos e familiares que torcem pelo meu sucesso.

À Capes pela bolsa de estudos concedida.

À Secretaria Municipal de Educação de Passo Fundo, pela licença-estudo semanal concedida.

À UNIJUÍ e ao IRDeR que disponibilizaram toda a estrutura necessária para o desenvolvimento dessa pesquisa.

Aos professores integrantes da banca de defesa desta tese, pela disponibilidade e importantes contribuições.

Gostaria também de agradecer à vida pela sorte e bênçãos recebidas. Sou uma pessoa de sorte! Como costumo dizer, “tenho tanta sorte que, até quando tenho azar, (acontece algo para mostrar que) tenho sorte”.

RESUMO

A modelagem matemática, por meio de abordagens estatísticas e de inteligência artificial, permite descrever fenômenos naturais, podendo ser aplicada a diversas áreas do conhecimento. Por meio de modelos e métodos é possível retratar, caracterizar, quantificar, realizar previsões e otimizar processos, o que auxilia na tomada de decisões, configurando a modelagem matemática como um meio eficiente no estudo de sistemas complexos. Na agricultura, a aveia é um cereal que tem seu cultivo realizado em estação fria e possui múltiplos propósitos de uso. Entretanto, a ocorrência de doenças foliares, causadas por patógenos fúngicos, pode prejudicar significativamente a produtividade e a qualidade de grãos de aveia. Fatores como a temperatura e a umidade do ar influenciam na ocorrência destas doenças, sendo que as principais são a ferrugem da folha e a helmintosporiose, causadas pelos patógenos *Puccinia coronata* e *Drechslera avenae*, respectivamente. O controle destas doenças normalmente é realizado mediante a aplicação de agrotóxicos fungicidas, entretanto, seu uso pode causar contaminação nos grãos e poluição ambiental. Estudos apontam que os efeitos nocivos de agrotóxicos podem estar relacionados com as taxas de óbitos por câncer na região noroeste do estado do Rio Grande do Sul. Destaca-se que cada vez mais busca-se uma agricultura mais sustentável com menor uso de defensivos agrícolas. Neste contexto, o ajuste da época de semeadura da aveia pode ser uma proposta inovadora na obtenção de uma zona de escape aos patógenos fúngicos, baseada em períodos com menores temperaturas, para um controle satisfatório das doenças foliares em aveia, minimizando os efeitos destas moléstias. A modelagem matemática, por meio de modelos estatísticos e de inteligência artificial, pode auxiliar na indicação de uma época de semeadura que possibilite o controle natural às doenças foliares da aveia. Deste modo, o objetivo deste estudo é modelar matematicamente os efeitos da época de semeadura da aveia, determinando a época ideal que possibilite o aproveitamento de uma zona de escape natural às doenças foliares, promovendo um cultivo produtivo e mais sustentável, na condição da região noroeste do estado do Rio Grande do Sul. Para o desenvolvimento do estudo, foi realizado um experimento em condições reais de cultivo, em blocos casualizados e esquema fatorial 2x7, compreendendo duas condições de aplicação de fungicida e sete épocas de semeadura, com 3 repetições. As épocas de semeadura consideradas foram 15 de abril, 01 de maio, 15 de maio, 01 de junho, 15 junho, 01 de julho e 15 de julho e as condições de uso de fungicida foram a ausência e a presença de uma aplicação na fase de paniculamento. Os dados experimentais foram obtidos em quatro anos agrícolas, de 2018 a 2021, com três cultivares de aveia, URS Corona, URS Taura e URS Guria, no sistema de sucessão soja-aveia. Em cada ano agrícola, foi determinada uma zona de escape às doenças foliares em razão da temperatura do ar, analisando o ciclo de desenvolvimento da aveia e seus resultados em cada cenário de semeadura. Os dados experimentais foram avaliados por meio de análise de regressão, de modelos de adaptabilidade e estabilidade, de modelos de análise de contribuição relativa, de métodos de seleção de variáveis e de inteligência artificial. As semeaduras de 01 de maio até 01 de junho evidenciaram os melhores resultados para a área foliar necrosada e produtividade de grãos na maioria das análises. Houve destaque para as épocas de 01 de maio e 15 de maio, que por meio da zona de escape, demonstraram condições para um controle satisfatório sobre as doenças foliares, com proteção até os 105 dias após a emergência, evidenciando também as maiores médias de produtividade de grãos. Uma aplicação de fungicida no paniculamento não foi eficiente tendo em vista os custos e os impactos à saúde a longo prazo. Com base nos resultados das análises estatísticas e de inteligência artificial, foi possível reposicionar a época de recomendação de semeadura da aveia. Dessa forma, o período ideal de semeadura da aveia na região noroeste do Rio Grande do Sul ocorre de 25 de abril a 10 de maio, anterior à atual recomendação, podendo ser estendido até 01 de junho.

Palavras-chave: Matemática aplicada, Modelagem computacional, Inteligência artificial, *Avena sativa*, Fungicida.

ABSTRACT

Mathematical modeling, through statistical approaches and artificial intelligence, allows the description of natural phenomena and can be applied to different areas of knowledge. Through models and methods, it is possible to portray, characterize, quantify, make predictions and optimize processes, which helps in decision making, configuring mathematical modeling as an efficient means of studying complex systems. In agriculture, oat is a cereal that is cultivated in the cold season and has multiple purposes of use. However, the occurrence of foliar diseases, caused by fungal pathogens, can significantly impair the productivity and quality of oat grains. Factors such as temperature and humidity influence the occurrence of these diseases, the main ones being leaf rust and helminthsporiosis, caused by the pathogens *Puccinia coronata* and *Drechslera avenae*, respectively. The control of these diseases is usually performed through the application of fungicide pesticides, however, their use can cause contamination in grains and environmental pollution. Studies indicate that the harmful effects of pesticides may be related to cancer death rates in the northwest region of the state of Rio Grande do Sul. It is noteworthy that increasingly more people are looking for a more sustainable agriculture with less use of pesticides. In this context, the adjustment of the oat sowing season can be an innovative proposal to obtain an escape zone for pathogens, based on periods with lower temperatures, for a satisfactory control of foliar diseases in oats, minimizing the effects of these diseases. Mathematical modeling, through statistical models and artificial intelligence, can help to indicate a sowing time that allows natural control of oat foliar diseases. Thus, the objective of this study is to mathematically model the effects of the oat sowing time, determining the ideal time that allows the use of a natural escape zone to foliar diseases, promoting a productive and more sustainable cultivation, in the condition of the northwest region, of the state of Rio Grande do Sul. For the development of the study, an experiment was performed in real growing conditions, in randomized blocks and a 2x7 factorial scheme, comprehending two conditions of fungicide application and seven sowing dates, with 3 replications. The sowing times considered were April 15th, May 01st, May 15th, June 01st, June 15th, July 1st and July 15th, and the conditions for fungicide use were the absence and presence of an application in the panicle. Experimental data were obtained in four agricultural years, from 2018 to 2021, with three oat cultivars, URS Corona, URS Taura and URS Guria, in the soybean-oat succession system. In each agricultural year, an escape zone for foliar diseases was determined through the air temperature, analyzing the oat development cycle and its results in each sowing scenario. The experimental data were evaluated using regression analysis, adaptability and stability models, relative contribution analysis models, variable selection methods and artificial intelligence. Sowings from May 1st to June 1st showed good results in most analyses. The seasons of May 1 and May 15 were highlighted which through the escape zone demonstrated conditions for satisfactory control foliar diseases, with protection up to 105 days after emergence, also showing the highest grain productivity averages. A fungicide application on the panicle was not efficient in view of the costs and long-term health impacts. Based on the results of statistical and artificial intelligence analyses, it was possible to reposition the oat sowing recommendation time. Thus, the ideal period for sowing oats in the northwest region of Rio Grande do Sul occurs from April 25th to May 10th, prior to the current recommendation, and can be extended until June 1st.

Keywords: Applied mathematics, Computer modeling, Artificial intelligence, *Avena sativa*, Fungicide.

LISTA DE TABELAS

Tabela 1 – Análise de variância da regressão linear simples.....	34
Tabela 2 – Área foliar necrosada ao longo do ciclo e produtividade de grãos em cada época de semeadura, ano de cultivo e cultivar, na condição sem fungicida.	75
Tabela 3 – Indicadores do ciclo de desenvolvimento de cultivares de aveia em diferentes épocas de semeadura nos anos agrícolas.	82
Tabela 4 – Médias de área foliar necrosada sem aplicação de fungicida ao longo do ciclo de cultivo da aveia em cada época de semeadura, cultivar e ano de cultivo.	85
Tabela 5 – Médias da área foliar necrosada e da produtividade de grãos sem fungicida por época de semeadura, ano de cultivo, cultivar e independente de cultivar de aveia.	87
Tabela 6 - Adaptabilidade e estabilidade das épocas de semeadura sobre a área foliar necrosada e a produtividade de grãos, sem fungicida, em cada cultivar e independente de cultivar.	92
Tabela 7 – Momento de aplicação de fungicida em dias após a emergência, coincidente ao paniculamento, em cada época de semeadura, cultivar e ano de cultivo.	97
Tabela 8 – Médias da área foliar necrosada e da produtividade de grãos da URS Corona em diferentes épocas de semeadura, anos de cultivo e condições de aplicação de fungicida.	98
Tabela 9 – Médias da área foliar necrosada e da produtividade de grãos da URS Taura em diferentes épocas de semeadura, anos de cultivo e condições de aplicação de fungicida.	101
Tabela 10 – Médias da área foliar necrosada e da produtividade de grãos da URS Guria em diferentes épocas de semeadura, anos de cultivo e condições de aplicação de fungicida.	103
Tabela 11 – Adaptabilidade e estabilidade das épocas de semeadura sobre a área foliar necrosada aos 90 dias após a emergência nas condições de uso de fungicida por cultivar de aveia.	107
Tabela 12 - Adaptabilidade e estabilidade das épocas de semeadura sobre a produtividade de grãos nas condições de uso de fungicida por cultivar de aveia.	109
Tabela 13 – Médias da produtividade de grãos em cada época de semeadura, condição de aplicação de fungicida, cultivar e ano de cultivo.	113
Tabela 14 – Médias de caracteres de produtividade por época de semeadura, condição de aplicação de fungicida, cultivar e ano de cultivo.	115
Tabela 15 – Médias de caracteres de qualidade industrial por época de semeadura, condição de aplicação de fungicida, cultivar e ano de cultivo.	117
Tabela 16 – Médias de caracteres de qualidade química por época de semeadura, condição de aplicação de fungicida, cultivar e ano de cultivo.	119
Tabela 17 – Regressões e contribuição relativa de caracteres de produtividade de grãos, industrial e química, pelo efeito do dia de semeadura.	121

Tabela 18 – Médias da temperatura mínima, máxima e média, em períodos quinzenais durante o ciclo, em cada época de semeadura e ano agrícola.....	130
Tabela 19 – Temperaturas mínima e máxima em períodos quinzenais e soma térmica acumulativa no decorrer do ciclo, em cada época de semeadura e ano agrícola.....	132
Tabela 20 – Médias da umidade mínima, máxima e média, em períodos quinzenais durante o ciclo, em cada época de semeadura e ano agrícola.....	134
Tabela 21 – Umidade relativa mínima e máxima em períodos quinzenais e precipitação acumulativa no decorrer do ciclo, em cada época de semeadura e ano agrícola.....	136
Tabela 22 – Médias de área foliar necrosada ao longo do ciclo e de produtividade de grãos, sem e com aplicação de fungicida, em cada época de semeadura e ano agrícola, independente de cultivar.	137
Tabela 23 – Coeficientes, erros médios e coeficientes de determinação dos modelos de regressão linear múltipla, independente de ano e de cultivar, nas condições sem e com fungicida.	139
Tabela 24 – Erros quadráticos médios e coeficientes de regressão do treino, validação e teste de arquiteturas de rede neural artificial, com variável dependente relativa à área foliar necrosada. ...	141
Tabela 25 – Validação da rede neural artificial de arquitetura 10-11-1 na simulação da área foliar necrosada em cada época de semeadura e ano agrícola sem aplicação de fungicida.	142
Tabela 26 – Validação da rede neural artificial de arquitetura 10-11-1 na simulação da área foliar necrosada em cada época de semeadura e ano agrícola com uma aplicação de fungicida.	143
Tabela 27 – Otimização da época de semeadura por algoritmo genético, com minimização da área foliar necrosada aos 90 dias após a emergência.....	144
Tabela 28 - Erros quadráticos médios e coeficientes de regressão do treino, validação e teste de arquiteturas de rede neural artificial, com variável dependente relativa à produtividade de grãos.	145
Tabela 29 – Validação das redes neurais artificiais de arquitetura 4-8-1 na simulação da produtividade de grãos em cada época de semeadura e ano agrícola, sem e com uso de fungicida.....	146
Tabela 30 – Otimização da época de semeadura por algoritmo genético, com maximização da produtividade de grãos.....	147

LISTA DE FIGURAS

Figura 1 – Dados meteorológicos históricos de 10 anos e zona de escape teórica para as doenças foliares durante o ciclo de desenvolvimento da aveia, considerando diferentes épocas de semeadura.	17
Figura 2 – Croqui do campo experimental localizado no IRDeR-UNIJUÍ e composição de uma parcela experimental.	22
Figura 3 – Organização do campo experimental e o processo de semeadura.	24
Figura 4 – Adubação em cobertura e controle manual de plantas daninhas.	25
Figura 5 – Aplicação de fungicida no período de paniculamento.	25
Figura 6 – Procedimentos de análise foliar.	26
Figura 7 – Colheita de grãos.	27
Figura 8 – Análise da produtividade de grãos.	27
Figura 9 – Neurônio artificial.	47
Figura 10 – Exemplo de rede de camadas múltiplas.	50
Figura 11 – Estrutura de uma rede neural e notações.	52
Figura 12 – Configuração de um neurônio.	52
Figura 13 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura no ano de 2018.	65
Figura 14 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura no ano de 2019.	67
Figura 15 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura no ano de 2020.	69
Figura 16 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura no ano de 2021.	71
Figura 17 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura independente de ano agrícola.	73
Figura 18 - Comportamento da área foliar necrosada e da produtividade de grãos sem fungicida em função da época de semeadura, independente de ano de cultivo.	90
Figura 19 – Comportamento da área foliar necrosada e da produtividade de grãos sem e com aplicação de fungicida em função da época de semeadura, independente de ano de cultivo.	105

SUMÁRIO

1. INTRODUÇÃO.....	13
2. OBJETIVOS.....	19
2.1. OBJETIVO GERAL	19
2.2. OBJETIVOS ESPECÍFICOS	19
2.2.1. <i>Objetivo Especifico I</i>	19
2.2.2. <i>Objetivo Especifico II</i>	19
2.2.3. <i>Objetivo Especifico III</i>	19
2.2.4. <i>Objetivo Especifico IV</i>	20
2.2.5. <i>Objetivo Especifico V</i>	20
3. MATERIAIS E MÉTODOS EXPERIMENTAIS	21
3.1. PROCEDIMENTOS EXPERIMENTAIS	21
3.2. VARIÁVEIS MENSURADAS	27
4. MODELOS MATEMÁTICOS	30
4.1. ANÁLISE DE VARIÂNCIA	30
4.2. MODELO DE AGRUPAMENTO DE MÉDIAS DE SCOTT E KNOTT	32
4.3. MODELOS DE REGRESSÃO	33
4.3.1. <i>Modelo de Regressão Linear Simples</i>	33
4.3.2. <i>Modelo de Regressão Quadrático</i>	35
4.3.3. <i>Máxima Eficiência Técnica</i>	36
4.3.4. <i>Modelo de Regressão Linear Múltipla</i>	36
4.4. ADAPTABILIDADE E ESTABILIDADE	37
4.4.1. <i>Modelo de Eberhart e Russel</i>	38
4.4.2. <i>Modelo de Cruz, Torres e Vencovsky</i>	38
4.5. MODELO DE SINGH	41
4.7. INTELIGÊNCIA ARTIFICIAL.....	46
4.7.1. <i>Redes Neurais Artificiais (RNAs)</i>	46
4.7.2. <i>Algoritmos Genéticos</i>	59
5. DESEMPENHO DE DISTINTAS ÉPOCAS DE SEMEADURA DA AVEIA NA DEFINIÇÃO DE UMA ZONA DE ESCAPE NATURAL NO CONTROLE DE DOENÇAS FOLIARES	63
5.1. INTRODUÇÃO	63
5.2. MATERIAIS E MÉTODOS.....	63
5.3. RESULTADOS E DISCUSSÃO	64
5.4. CONCLUSÕES	78
6. AJUSTE DA ÉPOCA DE SEMEADURA DA AVEIA POR MODELOS DE REGRESSÃO E DE ADAPTABILIDADE E ESTABILIDADE NA AUSÊNCIA DE FUNGICIDA	79
6.1. INTRODUÇÃO	79
6.2. MATERIAIS E MÉTODOS.....	80
6.3. RESULTADOS E DISCUSSÃO	81
6.4. CONCLUSÕES	94

7. AJUSTE DA ÉPOCA DE SEMEADURA DA AVEIA POR MODELOS DE ADAPTABILIDADE E ESTABILIDADE BASEADOS EM REGRESSÃO LINEAR E BISSEGMENTADA NA AUSÊNCIA E PRESENÇA DE FUNGICIDA	95
7.1. INTRODUÇÃO	95
7.2. MATERIAIS E MÉTODOS.....	96
7.3. RESULTADOS E DISCUSSÃO	97
7.4. CONCLUSÕES	111
8. REGRESSÃO LINEAR E CONTRIBUIÇÃO RELATIVA DOS EFEITOS DA ÉPOCA DE SEMEADURA DA AVEIA SOBRE INDICADORES DE PRODUTIVIDADE E DE QUALIDADE DE GRÃOS NA AUSÊNCIA E PRESENÇA DE FUNGICIDA	112
8.1. INTRODUÇÃO	112
8.2. MATERIAIS E MÉTODOS.....	112
8.3. RESULTADOS E DISCUSSÃO	113
8.4. CONCLUSÕES	123
9. INTELIGÊNCIA ARTIFICIAL POR REDES NEURAIS ARTIFICIAIS E ALGORITMO GENÉTICO NA DEFINIÇÃO DA ÉPOCA MAIS AJUSTADA DE SEMEADURA DA AVEIA NA AUSÊNCIA E PRESENÇA DE FUNGICIDA	124
9.1. INTRODUÇÃO	124
9.2. MATERIAIS E MÉTODOS.....	125
9.3. RESULTADOS E DISCUSSÃO	129
9.4. CONCLUSÕES	148
10. CONSIDERAÇÕES FINAIS	149
11. REFERÊNCIAS	150

1. INTRODUÇÃO

A modelagem matemática permite a representação de fenômenos reais através de formulações algébricas, estruturas lógicas ou outros procedimentos matemáticos, utilizando também de símbolos, conceitos e notações (BARBOSA, 2009; BICUDO, 2014). Sua importância está ligada ao fato de possibilitar a quantificação, caracterização, simulação e otimização de processos, permitindo ainda ao pesquisador realizar previsões, o que auxilia na tomada de decisões (SILVA, J. P., 2018). Devido às suas vantagens, a modelagem vem sendo empregada em diversas áreas do conhecimento, dentre elas, estão as ciências agrárias (MELO et al., 2016; LOPES, CHAVARETTE, COSSI, 2017; EIGENTLER, SHERRATT, 2018; GONTIJO, 2018).

Na agricultura, modelos e métodos matemáticos ligados à estatística são utilizados no estudo de culturas variadas, pois através da análise de amostras é possível inferir resultados para populações. A análise de variância (ANOVA) é capaz de indicar se há diferença estatística entre diferentes tratamentos, analisando a significância de efeitos principais de manejos e suas interações (MORETTIN, BUSSAB, 2013; DVOŘÁČEK et al., 2021). Após a utilização da ANOVA, os modelos de agrupamento de médias, como o de Scott e Knott, são eficazes na indicação de quais tratamentos possuem igualdade ou diferença estatística, favorecendo uma análise mais detalhada dos resultados (CRUZ, 2006b; CASTILHO et al., 2021).

Os modelos de regressão são capazes de descrever o comportamento de caracteres de plantas em relação a variáveis que podem ou não ser controladas pelo pesquisador, estes modelos assumem desde formas lineares até estruturas não lineares, oferecendo distintas vantagens (ELITH, LEATHWICK, 2009; CARVALHO et al., 2014). A regressão linear ou regressão simples é um modelo polinomial de grau 1 que possibilita estimar taxas de variação da variável dependente em relação à independente (FREITAS et al., 2008; ROSA et al., 2009). Dentre os modelos não lineares, há a regressão quadrática, correspondente a uma função polinomial de grau 2, que permite estimar o ponto em que ocorre o valor de máximo ou de mínimo da variável de interesse, caracterizando-se como uma alternativa à otimização de manejos (MORAIS et al., 2008; MAROLLI et al., 2017).

Além de modelos polinomiais, as regressões podem ser exponenciais, logarítmicas, de potência ou hiperbólicas (PONTES et al., 2018). Usualmente, na análise de regressão a variável dependente está em função de apenas uma independente, entretanto, há também a regressão linear múltipla, capaz de relacionar uma variável a duas ou mais variáveis independentes, que podem ou não estar associadas a elementos meteorológicos (ALVES, 2016; LOPES, CHAVARETTE, COSSI, 2017).

Fundamentando-se em modelos de regressão é possível verificar também a adaptabilidade e estabilidade de plantas e manejos por meio da análise de parâmetros. A adaptabilidade indica a

capacidade de adaptação aos estímulos do ambiente, que podem ser favoráveis ou desfavoráveis, enquanto a estabilidade aponta se há comportamento estável, permitindo a previsibilidade sobre variáveis. Dentre os modelos fundamentados em regressão, pode-se citar o modelo de Tai, o de Eberhart e Russel, o de Theil e o de Finlay e Wilkinson (CARGNELUTTI FILHO et al., 2009; CARVALHO et al., 2014).

Diversas são as categorias de modelos de adaptabilidade e estabilidade. Há modelos que se baseiam em ANOVA, como o modelo Tradicional, o de Wricke, de Plaisted e Peterson, de Schmidt et al., e Annicchiarico (CARVALHO et al., 2014). Há modelos de adaptabilidade e estabilidade apoiados em regressão bissegmentada, em que se pode apontar o modelo de Cruz, Torres e Vencovsky, o de Silva e Barreto, e o de Verma, Chahal e Murty (CARVALHO et al., 2014). O modelo AMMI também é empregado e considera efeitos aditivos principais e de interação multiplicativa entre fatores de tratamento (SZARESKI et al., 2018; SANTOS et al., 2019).

A utilização de modelos diferentes nos estudos de adaptabilidade e estabilidade é indicada devido a garantir maior consistência e confiabilidade nos resultados (BORNHOFEN et al., 2017; MELO et al., 2018). Nesse sentido, há destaque para os modelos de Eberhart e Russel (1966) e de Cruz, Torres e Vencovsky (1989), amplamente utilizados por apresentarem resultados de modo simples e de fácil interpretação, além de demonstrarem eficiência na determinação da adaptabilidade e estabilidade de genótipos ou de tratamentos avaliados (AMARAL et al., 2014; AFFÉRI et al., 2020).

Em processos relacionados à agricultura, diversos são os fatores que influenciam no desenvolvimento de plantas e muitas também são as respostas que estas fornecem sob distintos manejos. Deste modo, podem ser utilizadas abordagens estatísticas para tratar estas informações. O modelo de contribuição relativa de Singh permite identificar em um conjunto os caracteres que são mais influenciados por tratamentos (LUCENA, DANTAS, 2015; SOBRAL et al., 2018).

Quanto mais variáveis são consideradas em um processo de modelagem matemática, mais acurados se tornam os modelos (HAIR JR. et al., 2009; LOPES, CHAVARETTE, COSSI, 2017; FERREIRA et al., 2018). Entretanto, é importante empregar variáveis que apresentam influência significativa sobre os caracteres de resposta da planta, selecionando variáveis eficientes e relevantes no processo, evitando o uso demasiado e redundante. O método de seleção de variáveis de Stepwise, aliado à regressão linear múltipla, auxilia na tomada de decisão neste processo de seleção de variáveis para compor modelos satisfatórios, sejam eles lineares ou com outra estrutura (MILOSAVLJEVIC, ESSER, CROWDER, 2016).

Na modelagem matemática de fenômenos relacionados à agricultura, a inteligência artificial pode ser empregada na simulação e otimização de processos, podendo, inclusive, ser beneficiada pelo uso de técnicas estatísticas, como o método de seleção de Stepwise e por estruturas verificadas pela

análise de regressão linear múltipla (ALVES, LOTUFO, LOPES, 2013). Redes neurais artificiais, fundamentadas em estruturas inteligentes biológicas, são capazes de reconhecer padrões através de dados experimentais, generalizar as informações e reproduzir o conhecimento adquirido, possibilitando a realização de simulações (OLIVEIRA et al., 2013; CAMPOS et al., 2017; LOPES, CHAVARETTE, COSSI, 2017). Algoritmos genéticos, por sua vez, são baseados na evolução natural de seres vivos e permitem otimizar manejos, maximizando ou minimizando variáveis de interesse (ZHENG et al., 2017; AMADOR et al., 2018).

Uma cultura agrícola que tem recebido destaque em pesquisas é a aveia, um cereal de inverno que possui múltiplos propósitos de uso. Na agricultura e agropecuária, a aveia é utilizada na rotação e sucessão de culturas, coberta de solos e na alimentação animal através da produção de ração, pastagem, feno e silagem (AGOSTINETTO et al., 2015; MOREIRA et al., 2017; FORTE et al., 2018). Na indústria farmacêutica, este cereal pode ser utilizado na produção de cosméticos (MALANCHEN et al., 2019). Outra importante aplicação da aveia ocorre na alimentação humana, devido a possuir fibras solúveis, com destaque para a betaglucana, e insolúveis, que em conjunto apresentam diversas vantagens à saúde, sendo capazes de normalizar a microflora intestinal, reduzir o nível de colesterol LDL no sangue e a pressão arterial, atenuar a resposta glicêmica e insulinêmica pós-prandial, regular o apetite e diminuir o risco de doenças cardiovasculares (CÉSAR et al., 2006; BORGES, ZAIDEN, CRUZ, 2015; DOLINSKY et al., 2015; MA et al., 2017; COELHO et al., 2018; LIU et al., 2018).

Temperaturas do ar mais elevadas durante o ciclo de desenvolvimento da aveia, aliadas à umidade, podem prejudicar o desenvolvimento da planta devido ao ataque de doenças foliares causadas por fungos. Dentre estas doenças, recebem destaque a ferrugem da folha e a helmintosporiose, causadas pelos patógenos *Puccinia coronata* e *Drechslera avenae*, respectivamente, que podem causar perdas elevadas na qualidade e na produtividade de grãos (LORENCETTI et al., 2004; FOLLMANN et al., 2016; GORASH et al., 2017; NAZARENO et al., 2018). A ferrugem da folha, doença mais relevante do cultivo da aveia, tende a se desenvolver com maior intensidade com temperaturas do ar acima de 18°C, sendo o período ótimo de 18°C a 22°C, com molhamento foliar de 6 horas, e a helmintosporiose tende a ocorrer em temperaturas de 18°C a 25°C e molhamento foliar de 24 a 48 horas (KIMATI et al., 2005; BASSO et al., 2022). Devido a aveia ser uma cultura de inverno, são comuns períodos de maior umidade, no entanto, mesmo não sendo esperadas temperaturas mais elevadas, as mesmas ocorrem em estágios de alongação da planta e de enchimento de grãos, oportunizando a ocorrência das moléstias (BASSO et al., 2022). Normalmente, o controle destas doenças é realizado através da aplicação de agrotóxicos fungicidas, visto que a resistência genética das plantas não é duradoura, devido à velocidade de mutação dos patógenos fúngicos (NERBASS JUNIOR et al., 2010; NAZARENO et al., 2018).

Geralmente, os fungicidas utilizados no controle de doenças foliares da aveia são sistêmicos, ou seja, translocam no interior das plantas, podendo ser direcionados aos grãos (SCHEER, 2021). Além disso, uma maneira comum de comercialização da aveia para consumo humano ocorre na forma de flocos, em que o cereal se encontra *in natura*, deste modo, a utilização indiscriminada de agrotóxicos pode gerar a contaminação dos grãos, pondo em risco a segurança alimentar ao afetar a qualidade de alimentos (SILVA et al., 2015; TEIXEIRA, 2017; DORNELLES, 2018). Estudos, como os realizados por Peres e Moreira (2007) e por Jardim e Andrade (2009), indicam que existe relação entre doenças e o consumo de alimentos com contaminação residual por agrotóxicos. Morin e Stumm (2018) ainda destacam os riscos que o uso de agrotóxicos pode trazer aos agricultores, comprometendo a saúde física e psíquica dos trabalhadores. Além disso, o uso indiscriminado de agrotóxicos pode acarretar na poluição do ambiente e da água que é utilizada no abastecimento de cidades (TONIAL et al., 2006; FRANÇA et al., 2016; MORIN, STUMM, 2018).

Jobim et al. (2010), para investigar os efeitos nocivos de agrotóxicos, realizaram um estudo comparando as taxas de óbitos por câncer na microrregião de Ijuí com as taxas correspondentes ao estado do Rio Grande do Sul e ao Brasil, utilizando de dados anuais do Sistema do Departamento de Estatística do Sistema Único de Saúde, relacionando a um estudo ecológico de série temporal (1979 a 2003) realizado nas regiões mencionadas. Os autores concluíram que deve ser considerada a possibilidade de uma relação positiva entre o uso crônico de agrotóxicos e a maior incidência de câncer na microrregião de Ijuí. Deste modo, dado o crescente avanço da agricultura, o uso de agrotóxicos pode representar um problema para a saúde pública, principalmente na região noroeste do Rio Grande do Sul (RS), relacionada à microrregião de Ijuí, visto que a região é uma das maiores produtoras de aveia do estado.

Portanto, evidencia-se a necessidade de serem empregados manejos no cultivo da aveia na região noroeste do RS, que possibilitem reduzir a incidência das doenças foliares e o uso de fungicidas. Ou seja, manejos que possibilitem um cultivo mais sustentável, diminuindo a contaminação ambiental e promovendo a segurança alimentar, com a produção de alimentos seguros. Uma possível alternativa para isto pode ser o ajuste da época de semeadura da aveia de modo que durante o ciclo não haja temperaturas elevadas que, juntamente à ocorrência de umidade, favoreçam o surgimento de doenças foliares, estabelecendo uma zona de escape aos patógenos fúngicos.

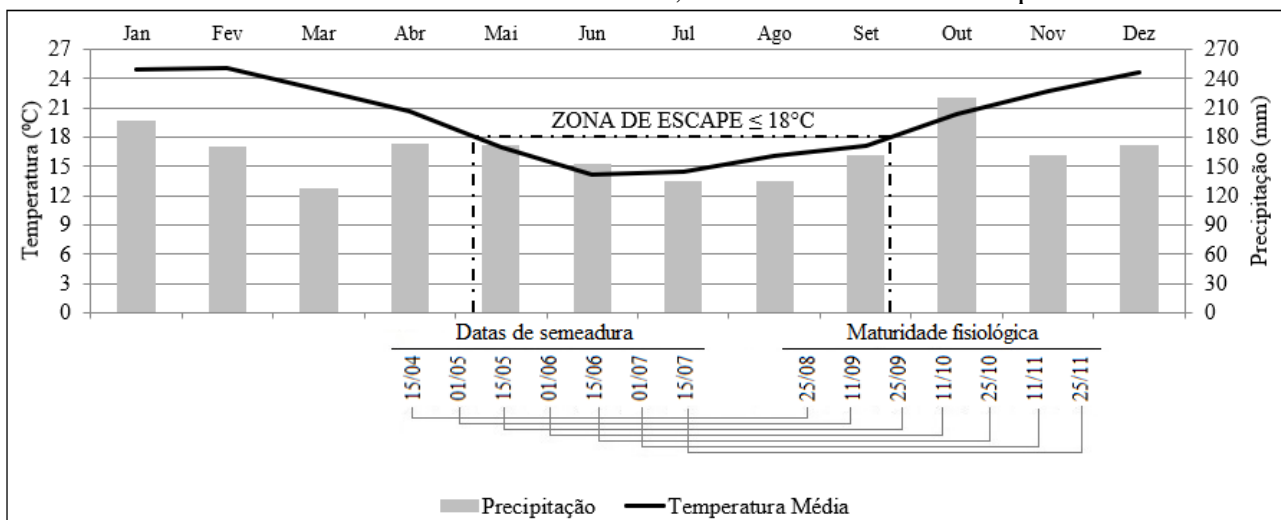
Define-se como zona (ou zoneamento) de escape natural, o período do ano agrícola com temperaturas médias do ar reduzidas, abaixo de 18°C, que dificultem a instalação e o desenvolvimento de inóculos fúngicos que causam doenças foliares na cultura da aveia. A zona de escape também pode ser tratada como um período de proteção natural pela temperatura. Destaca-se também que a zona de escape, ou período de proteção, visa proporcionar condições de controle às

doenças foliares, não se referindo a um controle total, mas sim satisfatório, que minimize os efeitos das doenças.

A hipótese de ajuste da época de semeadura está fundamentada na Figura 1, em que foi construída uma zona de escape teórica a patógenos fúngicos, considerando que doenças foliares na aveia não tendem a ocorrer com intensidade quando a temperatura do ar está abaixo de 18°C (KIMATI et al., 2005). São apresentados dados climáticos observados na região noroeste do RS, referentes ao período compreendido do ano de 2009 até o ano de 2018, totalizando 10 anos. Essas informações foram registradas pela estação meteorológica presente no Instituto Regional de Desenvolvimento Rural (IRDeR), que pertence à Universidade Regional do Noroeste do Estado do Rio Grande do Sul (UNIJUÍ).

Na figura são indicadas épocas de semeadura com intervalos de 15 dias entre uma e outra, com datas pertencentes à recomendação de cultivo para a região, ou seja, de 15 de maio até 15 de junho (LÂNGARO; CARVALHO, 2014). Além disso, há épocas que representam situação de atraso na semeadura, como 01 de julho e 15 de julho, e épocas em que se presume que o ciclo de cultivo possa ser protegido pela zona de escape às doenças foliares, como nas datas de 15 de abril e 01 de maio. São considerados ciclos com duração média de 120 dias, da emergência até a maturação fisiológica e tempo médio entre a semeadura e a emergência de 10 dias. A zona de escape indicada tem como base o período em que a temperatura média do ar se encontra abaixo de 18°C, apresentando as épocas 15 de abril, 1 de maio e 15 de maio como as mais promissoras para um controle satisfatório às doenças fúngicas. Isso porque essas épocas possuem maior parte do ciclo na zona de escape, com destaque para o período de enchimento de grãos, que antecede a maturação fisiológica, momento em que o enchimento de grãos se estabiliza.

Figura 1 – Dados meteorológicos históricos de 10 anos e zona de escape teórica para as doenças foliares durante o ciclo de desenvolvimento da aveia, considerando diferentes épocas de semeadura.



Fonte: autoria própria.

Os objetivos de desenvolvimento sustentável (ODS), publicados pela Organização das Nações Unidas (ONU, 2015), destacam a importância de um cultivo sustentável na agricultura, contribuindo para a segurança alimentar. A Embrapa ressalta a crescente demanda de produção de alimentos com menor impacto aos agroecossistemas, que considere a saúde dos agricultores e dos consumidores. Inclusive, destaca a necessidade de um sistema agrícola sustentável apresentar, além de adequada produtividade, maior resistência a fatores bióticos, em lógica inversa a materiais genéticos altamente dependentes de fitoprotetores (MEDEIROS et al., 2018). Isso evidencia a relevância de manejos que auxiliem na redução da incidência de patógenos no cultivo de plantas.

O uso de modelagem matemática, através da aplicação de modelos estatísticos e via inteligência artificial, pode auxiliar no estudo e determinação da melhor época de semeadura da aveia, que auxilie na contenção de doenças foliares durante o ciclo. O objetivo deste estudo é modelar matematicamente os efeitos da época de semeadura da aveia, determinando a época ideal que possibilite o aproveitamento de uma zona de escape natural às doenças foliares, promovendo um cultivo produtivo e mais sustentável, na condição da região noroeste do estado do Rio Grande do Sul.

2. OBJETIVOS

Para o desenvolvimento desta pesquisa, foram determinados o objetivo geral e os objetivos específicos norteadores, que são apresentados a seguir.

2.1. Objetivo Geral

Modelar matematicamente os efeitos da época de semeadura da aveia, determinando a época ideal que possibilite o aproveitamento de uma zona de escape natural às doenças foliares, promovendo um cultivo produtivo e mais sustentável, na condição da região noroeste do estado do Rio Grande do Sul.

2.2. Objetivos Específicos

Para atingir o objetivo geral descrito, definiu-se os seguintes objetivos específicos.

2.2.1. Objetivo Específico I

Definir uma zona de escape natural às doenças fúngicas, com base na temperatura média do ar, na análise de distintas épocas de semeadura da aveia na região noroeste do RS, determinando os cenários de semeadura mais favoráveis ao controle dos patógenos, que demonstrem também resultados satisfatórios quanto à produtividade de grãos.

2.2.2. Objetivo Específico II

Analisar o comportamento da área foliar necrosada, decorrente do ataque de doenças fúngicas, e da produtividade de grãos de aveia, em função de distintas épocas de semeadura, na ausência de fungicida. Identificar as épocas de semeadura com adaptabilidade às condições de ano agrícola, que possibilitem a redução da incidência de doenças foliares e o aumento da produtividade de grãos com estabilidade, também em um cenário sem uso de fungicida.

2.2.3. Objetivo Específico III

Avaliar o efeito de distintas épocas de semeadura da aveia sobre o comportamento da área foliar necrosada, decorrente de doenças foliares, e da produtividade de grãos, sem e com o uso de

fungicida. Determinar a época de semeadura que possibilita elevar a produtividade de grãos e reduzir a área foliar necrosada, demonstrando adaptabilidade e estabilidade diante das condições dos anos agrícolas, na ausência e presença de uma aplicação de fungicida.

2.2.4. Objetivo Específico IV

Avaliar o comportamento de variáveis relacionadas à produtividade e à qualidade industrial e química de grãos, em função de diferentes épocas de semeadura da aveia, analisando também a contribuição relativa das épocas sobre estas variáveis, na ausência e presença de fungicida.

2.2.5. Objetivo Específico V

Selecionar as variáveis meteorológicas que mais influenciam na progressão da área foliar necrosada, simular a necrose foliar e otimizar a época de semeadura, com minimização da incidência de doenças fúngicas na aveia, sem e com o uso de fungicida. Simular a produtividade de grãos e otimizar a época de semeadura, com maximização da produtividade, também em cenários de ausência e de presença de fungicida, indicando o período de semeadura ideal da aveia.

3. MATERIAIS E MÉTODOS EXPERIMENTAIS

Neste capítulo estão descritos os procedimentos experimentais e as variáveis mensuradas no estudo.

3.1. Procedimentos experimentais

O experimento referente a esta pesquisa foi desenvolvido na área experimental pertencente ao Instituto Regional de Desenvolvimento Rural (IRDeR), estabelecido no município de Augusto Pestana - RS, na região noroeste. A localização geográfica é de 28° 26' 30'' de latitude S e 54° 00' 58'' de longitude W, e altitude aproximada de 400 m. O IRDeR pertence à Universidade Regional do Noroeste do Estado do Rio Grande do Sul (UNIJUÍ).

A pesquisa foi realizada em quatro anos de cultivo, 2018, 2019, 2020 e 2021, que foram analisados individualmente e também de modo concomitante. Anteriormente à implantação do experimento, em cada um dos quatro anos, foi realizada uma análise de solo, identificando as características químicas do local, de modo que os resultados obtidos foram similares. Desta maneira, os resultados médios identificados foram: pH= 6,3; P=34,1 mg dm⁻³; K= 198 mg dm⁻³; MO= 3,2%; Al= 0 cmol_c dm⁻³; Ca = 6,5 cmol_c dm⁻³ e Mg=2,5 cmol_c dm⁻³. O solo da área experimental se caracteriza por um Latossolo Vermelho distroférico típico, com um perfil profundo, bem drenado, coloração vermelho escuro, com altos teores de argila e predominância de argilominerais 1:1 e óxi-hidróxidos de ferro e alumínio.

De acordo com a classificação climática de Köppen, o clima da região se enquadra na descrição de Cfa, com ocorrência de verões quentes e sem ocorrência de estiagens prolongadas (KUINCHTNER, BURIOL, 2001). Apresenta ainda invernos frios e úmidos, com ocorrência frequente de geadas. Os meses de janeiro e fevereiro são os meses mais quentes do ano, enquanto junho e julho são os meses mais frios, conforme dados da estação meteorológica presente no IRDeR. Quanto ao volume de pluviosidade, a estação meteorológica registrou uma média próxima aos 1600 mm anuais, nos quatro anos de cultivo considerados nesta pesquisa, com ocorrência de maior precipitação no inverno. Observando o histórico da área, se percebe nos últimos vinte anos uma média de 1800 mm de precipitação. Além disso, a área se caracteriza como um sistema de semeadura direta consolidado. No período do verão a área é ocupada com soja e outras culturas. O sistema de cultivo considerado nesta pesquisa foi a sucessão soja-aveia, envolvendo cobertura de solo com resíduo vegetal de reduzida relação Carbono/Nitrogênio.

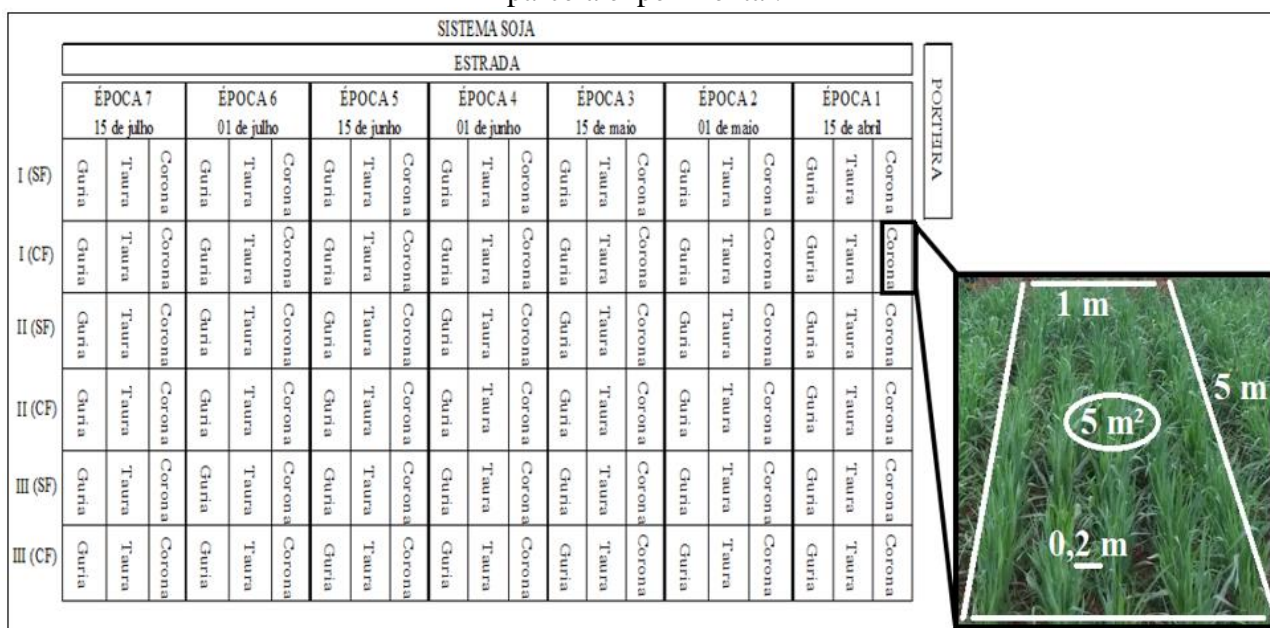
Na determinação das épocas de semeadura da aveia no estudo, foi considerado um período de 30 dias anteriores e 30 dias posteriores à atual recomendação de semeadura da aveia branca na região

noroeste do Rio Grande do Sul, que é de 15 de maio a 15 de junho (LÂNGARO; CARVALHO, 2014). Deste modo, as semeaduras do experimento foram realizadas com semeadora-adubadora do período de 15 de abril até 15 de julho, variando de 15 em 15 dias, totalizando sete épocas de semeadura, nas seguintes datas de referência: 15 de abril, 01 de maio, 15 de maio, 01 de junho, 15 de junho, 01 de julho e 15 de julho.

O delineamento experimental foi de blocos casualizados (STORCK et al., 2006) com três repetições, num esquema fatorial 2 x 7 com duas condições de aplicação de fungicida (zero e uma aplicação na fase de paniculamento) e sete épocas de semeadura (15 de abril, 01 de maio, 15 de maio, 01 de junho, 15 de junho, 01 de julho e 15 de julho). Cada parcela experimental foi constituída de 5 linhas com 5 m de comprimento cada e espaçamento entre linhas de 0,20 m, correspondendo a uma unidade experimental de 5 m². A densidade de semeadura utilizada foi de 400 sementes viáveis por metro quadrado, de modo que os grãos foram submetidos a um teste de germinação e vigor para a obtenção da densidade desejada.

Na amostragem da parcela, para a análise da área foliar necrosada decorrente do ataque de doenças foliares, foram consideradas 3 plantas selecionadas aleatoriamente, dentre as três linhas centrais da parcela. Quanto à produtividade de grãos, foram colhidas as três linhas centrais de cada parcela, consideradas como a área útil. Estas metodologias são semelhantes às utilizadas por Alessi et al. (2018a) e por Dornelles et al. (2021). Na Figura 2 é possível observar o croqui do campo experimental e a estrutura de uma parcela.

Figura 2 – Croqui do campo experimental localizado no IRDeR-UNIJUÍ e composição de uma parcela experimental.



IRDeR: Instituto Regional de Desenvolvimento Rural; UNIJUÍ: Universidade Regional do Noroeste do Estado do Rio Grande do Sul; A enumeração dos blocos ocorre pela numeração romana; SF: sem fungicida; CF: com fungicida.

Fonte: autoria própria.

Foram empregadas três cultivares de aveia, a URS Corona, a URS Taura e a URS Guria. A cultivar URS Corona foi selecionada devido a demonstrar adequada produtividade de biomassa e de grãos, sendo apropriada na utilização como pastagem e na produção de silagem. Conforme as indicações técnicas para a cultura da aveia, a URS Corona possui as seguintes características agronômicas: ciclo médio, estatura alta, a posição da folha bandeira é decumbente, não possui aristas, a forma da panícula é equilátera, os grãos apresentam a cor amarela e o hábito de crescimento é intermediário. Esta cultivar é resistente à ferrugem da folha e à ferrugem do colmo, moderadamente resistente à geada e moderadamente suscetível ao acamamento (LÂNGARO, CARVALHO, 2014).

A cultivar URS Taura foi definida por possuir adequado padrão industrial, sendo uma das mais cultivadas no estado do Rio Grande do Sul. Como características agronômicas, apresenta ciclo precoce, estatura baixa, a posição da folha bandeira é ereta, não possui frequência de aristas, a forma da panícula é equilátera, a cor do grão é amarela e o hábito de crescimento é ereto. Esta cultivar é suscetível à ferrugem da folha e à ferrugem do colmo, moderadamente resistente à geada e resistente ao acamamento (LÂNGARO, CARVALHO, 2014).

A cultivar URS Guria foi selecionada por apresentar alta produtividade de grãos e maior resistência a doenças foliares. Esta cultivar apresenta, como características agronômicas, ciclo precoce, estatura alta, a posição da folha bandeira é intermediária, a frequência de aristas é baixa, a forma da panícula é equilátera, a cor dos grãos é amarela e o hábito de crescimento é semiereto. Esta cultivar é moderadamente resistente à ferrugem da folha e do colmo, moderadamente resistente à geada e suscetível ao acamamento (LÂNGARO, CARVALHO, 2014).

Na Figura 3 é possível observar a delimitação do campo experimental e o processo de semeadura.

Figura 3 – Organização do campo experimental e o processo de semeadura.




A: posicionamento de estacas; B: marcação de linhas para delimitar as parcelas; C: vista superior da semeadora-adubadora durante a semeadura; D: realização do processo de semeadura.

Fonte: autoria própria.

Nos experimentos, aplicou-se na semeadura doses de P_2O_5 e K_2O , de 45 e 30 $kg\ ha^{-1}$, respectivamente, com base nos teores de P e K no solo. O nitrogênio foi aplicado na base e em cobertura no estágio fenológico indicado de quarta folha expandida, com emprego da fonte ureia para expectativa de rendimento de grãos de 3 $t\ ha^{-1}$. O controle de plantas daninhas foi efetuado com herbicida metsulfuron-metil e capina adicional quando necessário. Na Figura 4, estão apresentados os momentos de adubação em cobertura e de controle de plantas daninhas por meio de capina.

Figura 4 – Adubação em cobertura e controle manual de plantas daninhas



A: adubação em cobertura pela fonte ureia; B: realização de capina nas parcelas experimentais.
Fonte: autoria própria.

Durante a execução do experimento, no período de paniculamento da aveia foi efetuada a aplicação de fungicida de princípio ativo tebuconazol (concentração de 43%), fungicida sistêmico do grupo químico Triazol, conforme orientações da bula, na dose de 350 mL ha⁻¹. Na Figura 5 é possível observar esse processo.

Figura 5 – Aplicação de fungicida no período de paniculamento



Fonte: autoria própria.

A análise foliar ocorreu aos 60 dias após a emergência (DAE), 75 DAE, 90 DAE, 105 DAE e 120 DAE, considerando três plantas de cada parcela e a soma das áreas das três folhas superiores de cada planta, de modo que posteriormente foi obtido o valor médio dos resultados das três plantas.

Após o escaneamento das folhas, a mensuração da área foliar necrosada, sadia e total foi obtida com auxílio do software WinDias (Copyright 2012, Delta-T Devices Limited) em cm^2 , com posterior estimativa da área foliar necrosada para valores percentuais em relação à área foliar total. Na Figura 6 é possível observar os procedimentos de coleta e estimativa da área foliar.

Figura 6 – Procedimentos de análise foliar



A: coleta de plantas a campo; B: Identificação de necrose foliar no software WinDias.

Fonte: autoria própria.

A colheita de grãos ocorreu após a maturação fisiológica, com umidade de grãos em torno de 15%. Em 2018, a colheita dos experimentos para a estimativa da produtividade de grãos ocorreu pelo corte manual das três linhas centrais de cada parcela, trilhadas posteriormente em trilhadeira estacionária. Nos anos de 2019, 2020 e 2021, as três linhas centrais foram colhidas com uma colheitadeira de parcelas (Figura 7).

Figura 7 – Colheita de grãos



A: corte das linhas centrais da parcela; B: organização dos feixes de cada parcela; C: trilha do material colhido; D: colheita das linhas centrais da parcela pela colheitadeira; E: obtenção do material colhido. A, B e C ilustram a colheita em 2018. D e E ilustram a colheita em 2019, 2020 e 2021.

Fonte: autoria própria.

Após a colheita, os grãos foram direcionados ao laboratório para correção da umidade para 13% para posterior mensuração de caracteres de produtividade (Figura 8).

Figura 8 – Análise da produtividade de grãos



Fonte: autoria própria.

3.2. Variáveis Mensuradas

Nesta seção é possível observar as variáveis mensuradas e sua forma de obtenção para a realização da pesquisa.

a) Caráter Indicador da Produtividade

PG (kg ha⁻¹) – produtividade de grãos. Determinada pela massa de grãos proveniente da colheita das três linhas centrais de cada parcela, posterior pesagem em balança de precisão e conversão para kg ha⁻¹.

b) Caráter de Incidência de doenças

AFN (%) – área foliar necrosada. Para obtenção desta variável foram utilizadas 3 plantas de cada parcela, selecionadas aleatoriamente ao longo da parcela, dentre as três linhas centrais. Foram consideradas as somas da área foliar total, sadia e necrosada das três folhas superiores de cada planta e obtida a média dos resultados das três plantas coletadas. A AFN (%) foi determinada pelo percentual de área necrosada (cm²) em relação à área foliar total (cm²).

c) Caracteres da Qualidade Industrial

MMG (g) – massa de mil grãos. Determinada pela pesagem de 250 grãos em balança de precisão e posterior cálculo da proporção para 1000 grãos;

MH (kg hl⁻¹) – massa do hectolitro. Massa de grãos contidos no volume de 0,1 m³ ou 100 litros. Obtida pela massa de grãos de volume conhecido da amostra da colheita da parcela;

NG>2mm (%) – número de grãos com espessura maior que 2 mm em um conjunto de 100 grãos. Definido através da contagem de 100 grãos que são colocados em uma peneira de malha de 2 mm e considerados os que ficam acima desta dimensão;

ID (g g⁻¹) – índice de descasque. Determinado pela razão da massa de 30 grãos sem casca pela massa dos mesmos 30 grãos com casca, dentre os grãos com espessura maior que 2 mm;

PI (kg ha⁻¹) – produtividade industrial. Determinada pelo produto da produtividade de grãos com o índice de descasque e o número de grãos maiores que 2 mm em percentual na forma fracionária, ou seja,

$$PI = PG \cdot ID \cdot \frac{NG > 2mm}{100} \quad (1)$$

d) Caracteres da Qualidade Química de Grãos

PT (g kg⁻¹) – proteína total;

AM (g kg⁻¹) – amido;

FT (g kg⁻¹) – fibra total.

As análises químicas foram realizadas por meio da espectrofotometria do infravermelho proximal - NIR (Near infrared Reflectance), um equipamento de alta precisão que realiza análises de alimentos através da emissão de radiação eletromagnética, caracterizando substâncias orgânicas, fundamentado em aplicações da matemática à química analítica. O uso da espectroscopia de refletância no infravermelho próximo é um método moderno e preciso, que executa simultaneamente várias análises com velocidade (BORGES; FERREIRA; SALIBA, 2001). Para as avaliações foram utilizadas amostras de cerca de 300 grãos não descascados, provenientes de cada parcela. O material colhido foi analisado em espectrômetro de reflectância no infravermelho proximal (NIRS), marca Perten, modelo Diode Array DA7200, no laboratório de bromatologia da Universidade Regional do Noroeste do Estado do Rio Grande do Sul.

e) Caracteres Meteorológicos

Os dados meteorológicos foram obtidos na Estação Total Automática instalada a 200 metros da implantação do experimento.

\bar{T}_{min} (°C) – temperatura mínima média do ar;

\bar{T}_{max} (°C) – temperatura máxima média do ar;

\bar{T}_{med} (°C) – temperatura média do ar;

T_{min} (°C) – temperatura mínima do ar;

T_{max} (°C) – temperatura máxima do ar;

\bar{U}_{min} (%) – umidade relativa mínima média;

\bar{U}_{max} (%) – umidade relativa máxima média;

\bar{U}_{med} (%) – umidade relativa média;

U_{min} (%) – umidade relativa mínima;

U_{max} (%) – umidade relativa máxima;

PP (mm) – precipitação pluviométrica;

ST (°C dia⁻¹) – soma térmica. Calculada por

$$ST = \sum_{i=1}^n (T_{med_i} - TB) \quad (2)$$

em que T_{med_i} é a temperatura média do ar no dia i , n é a quantidade de dias e TB é a temperatura basal do desenvolvimento da aveia, considerada neste estudo igual a 4 °C (CASTRO; COSTA; FERRARI NETO, 2012).

4. MODELOS MATEMÁTICOS

Neste capítulo são apresentados os modelos e métodos matemáticos utilizados para o desenvolvimento da pesquisa.

4.1. Análise de Variância

A análise de variância, também conhecida como ANOVA (ANalysis Of VAriance), é um método estatístico que analisa médias de amostras provindas de distintas populações, testando a hipótese de as médias serem iguais estatisticamente, possibilitando estender o resultado às populações. Os dados a serem submetidos à ANOVA são resultados de experimentos, os quais são caracterizados pela presença de repetições no processo, ou seja, mais de um ensaio experimental. Através deste método, é possível dividir o efeito dos tratamentos aplicados pelo pesquisador dos efeitos decorrentes do acaso (erro experimental) sobre as variáveis de interesse mensuradas (FAVERO et al., 2009; MAGALHÃES, LIMA, 2013; MORETTIN, BUSSAB, 2013). Para o emprego da ANOVA, é necessário que as amostras sejam independentes, ou seja, que uma observação não interfira na outra. Além disso, é necessário que os resíduos possuam distribuição normal e homogeneidade nas variâncias amostrais. Nesta pesquisa, a normalidade e a homogeneidade foram testadas, respectivamente, pelos modelos de Shapiro-Wilk e de Bartlett (FÁVERO, BELFIORE, 2017).

Quanto ao desenvolvimento do experimento, se no processo não houver ponto de heterogeneidade, diz-se que o delineamento experimental é completamente casualizado ou inteiramente ao acaso. Caso haja um ponto de heterogeneidade, o delineamento experimental é de blocos ao acaso ou blocos casualizados. Se existirem dois pontos de heterogeneidade, o delineamento é de quadrado latino. Os delineamentos que prevêm heterogeneidade dividem os tratamentos em subgrupos homogêneos internamente e heterogêneos entre si. Além disso, é possível classificar um experimento quanto ao número de fatores analisados pelo pesquisador, se houver apenas um, o experimento é unifatorial e, se houver mais de um fator, o experimento é fatorial, podendo-se ainda indicar se o fatorial é duplo, triplo, etc (CRUZ, 2006b; STORCK et al., 2006).

Na agricultura, geralmente é utilizado o delineamento experimental de blocos casualizados (VIEIRA, 1999; STORCK et al., 2006). Deste modo, o principal modelo de ANOVA a ser utilizado nesta pesquisa é dado pela equação (3), de modo que foram considerados os resultados das amostras representativas de cada unidade experimental nas variáveis correspondentes do modelo

$$Y_{ijk} = \mu + E_i + FG_j + E_i \times FG_j + B_k + \varepsilon_{ijk} \quad (3)$$

em que Y_{ijk} é a variável dependente, μ é a média geral, E_i é a época de semeadura, FG_j é a condição de aplicação de fungicida, $E_i \times FG_j$ é a interação entre as épocas de semeadura e as condições de aplicação de fungicida, B_k é o bloco casualizado e ε_{ijk} é o erro experimental. Cabe acrescentar que esse modelo pode ser ajustado quanto aos fatores no desenvolvimento desta pesquisa, conforme necessário. Além disso, em alguns casos foi realizada ANOVA unifatorial, em que são considerados apenas os termos relacionados à média geral, ao fator, ao bloco e ao erro.

A ANOVA é baseada no cálculo de uma estatística F para decidir entre aceitar ou rejeitar a hipótese que afirma que as médias são iguais estatisticamente. Considerando o modelo definido na equação (3), para obter o valor desta estatística, inicialmente são calculadas as somas de quadrados dos fatores SQ_E e SQ_{FG} , da interação $SQ_{E \times FG}$, dos blocos SQ_B , total SQ_{tot} , e do erro SQ_ε , dadas, respectivamente, por

$$SQ_E = \frac{1}{jk} \sum_i Y_{i..}^2 - C \quad (4)$$

$$SQ_{FG} = \frac{1}{ik} \sum_j Y_{.j.}^2 - C \quad (5)$$

$$SQ_{E \times FG} = \frac{1}{k} \sum_{ij} Y_{ij.}^2 - C - SQ_E - SQ_{FG} \quad (6)$$

$$SQ_B = \frac{1}{ij} \sum_k Y_{..k}^2 - C \quad (7)$$

$$SQ_{tot} = \sum_{ijk} Y_{ijk}^2 - C \quad (8)$$

$$SQ_\varepsilon = SQ_{tot} - SQ_E - SQ_{FG} - SQ_{E \times FG} - SQ_B \quad (9)$$

em que Y é a variável resposta, i , j e k , respectivamente, referem-se a cada nível do fator E e do fator FG e a cada bloco, e C é o fator de correção (STORCK et al., 2006).

O valor de quadrado médio (QM) em cada caso é dado pela razão entre sua soma de quadrados (SQ) e seu grau de liberdade (GL). O cálculo da estatística F de cada fator e da interação é obtido através da razão entre o seu respectivo valor de quadrado médio e o valor do quadrado médio do erro.

Para decidir entre aceitar ou rejeitar a hipótese de igualdade estatística entre os níveis de cada fator ou da não interação entre fatores, deve-se determinar um valor de F crítico em cada caso, obtido em tabela, que depende do grau de liberdade do fator (ou da interação), do grau de liberdade do resíduo e do nível de significância estabelecido. Quando analisados os níveis de um fator, se a estatística F calculada for igual ou superior ao valor crítico definido, rejeita-se a hipótese de que há igualdade estatística e, quando analisada a interação entre os fatores de tratamento, se a estatística calculada superar o valor crítico, rejeita-se a hipótese de não interação, ou seja, pode-se concluir que há interação significativa entre as épocas de semeadura e as condições de aplicação de fungicida em aveia (FAVERO et al., 2009).

4.2. Modelo de agrupamento de médias de Scott e Knott

A análise de variância indica se há diferença estatística entre as médias de pelo menos dois tratamentos, entretanto, não aponta em quais médias há divergência. Deste modo, após sua aplicação podem ser empregados modelos (ou testes) de agrupamento de médias, a fim de apontar onde ocorrem as diferenças existentes. Um modelo utilizado para este fim é o de Scott e Knott, que visa dividir os tratamentos de forma que médias iguais estatisticamente pertençam a agrupamentos em comum e médias distintas encontrem-se em grupos distintos (CRUZ, 2006b). A vantagem deste modelo é o fato de que não há a ocorrência de uma média em mais de um agrupamento, diferente do que pode ser observado em testes de comparação de médias, como o teste de Tukey.

Para a aplicação do modelo de Scott e Knott, é estabelecido um valor de qui-quadrado $\chi^2_{(\alpha, \nu_0)}$ referencial, obtido em função do nível de significância determinado e do número de graus de liberdade ν_0 , dado por

$$\nu_0 = \frac{n}{\pi - 2} \quad (10)$$

em que n é o número de médias.

Posteriormente, é definido um parâmetro λ , calculado através de

$$\lambda = \frac{\pi B_0}{2(\pi - 2)\sigma_0^2} \quad (11)$$

em que B_0 é o valor máximo da soma de quadrados entre grupos, considerando todas as possíveis divisões do conjunto total de tratamentos em dois grupos, e σ_0^2 é a variância, dada por

$$\hat{\sigma}_0^2 = \frac{1}{n+v} \left[\sum_{i=1}^n (\bar{Y}_i - \bar{Y})^2 + v s_y^2 \right] \quad (12)$$

em que \bar{Y}_i é a média do tratamento i , \bar{Y} é a média geral dos tratamentos, v é o número de graus de liberdade do resíduo, e s_y^2 é dado pela razão entre o quadrado médio do resíduo e o número de repetições que originaram as médias a serem agrupadas.

Para estabelecer os grupos, compara-se os valores de λ com o de $\chi_{(\alpha, v_0)}^2$. Se λ for inferior ao $\chi_{(\alpha, v_0)}^2$, as médias são consideradas homogêneas e não são realizadas novas partições dentro do grupo considerado, visto que as mesmas não diferem significativamente. Caso λ seja maior que $\chi_{(\alpha, v_0)}^2$, os dois grupos diferem significativamente e devem ser testadas novas possibilidades de divisões em cada um. Os agrupamentos normalmente são indicados através das primeiras letras do alfabeto e é realizado até que haja grupos com apenas uma média ou com médias homogêneas (CRUZ, 2006b).

4.3. Modelos de Regressão

Modelos de regressão possibilitam estabelecer relações existentes entre uma variável dependente e uma ou mais variáveis independentes. As regressões podem assumir formas lineares ou não lineares, podendo ser polinomiais ou não, agregando distintas vantagens de utilização. Nesta seção são apresentados os modelos polinomiais de graus 1 e 2 (regressão linear e quadrática, respectivamente) e a regressão linear múltipla.

4.3.1. Modelo de Regressão Linear Simples

A regressão linear ou regressão simples descreve o comportamento da variável dependente, usualmente indicada por Y , em relação à independente, geralmente indicada por X , através de uma equação polinomial de grau 1, de maneira que é possível estimar os valores esperados de Y , dados os valores de X , considerando o intervalo de domínio utilizado (CRUZ, 2006b). Em experimentos agrícolas, considerando os dados obtidos, pode-se utilizar da regressão linear para a representação da relação entre variáveis, de modo que o modelo estatístico para tal é

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (13)$$

em que β_0 é o coeficiente linear, β_1 é o coeficiente angular ou coeficiente de regressão e ε é o erro aleatório.

Os parâmetros podem ser estimados através do método dos mínimos quadrados (COSTA NETO, 2002), por

$$\begin{cases} n\beta_0 + \beta_1 \sum X_i = \sum Y_i \\ \beta_0 \sum X_i + \beta_1 \sum X_i^2 = \sum X_i Y_i \end{cases} \quad (14)$$

em que n é a quantidade de pares (X, Y) .

Por meio da resolução do sistema é possível obter a seguinte solução (TRIOLA, 1999; CRUZ, 2006b; SPIEGEL, STEPHENS, 2009)

$$\hat{\beta}_0 = \bar{Y} - \beta_1 \bar{X} \quad (15)$$

$$\hat{\beta}_1 = \frac{n \sum_{i=1}^n X_i Y_i - \sum_{i=1}^n X_i \sum_{i=1}^n Y_i}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2}. \quad (16)$$

A análise de variância da regressão simples tem sua estrutura da seguinte maneira (Tabela 1) (CRUZ, 2006b)

Tabela 1 – Análise de variância da regressão linear simples.

FV	GL	SQ	QM	F
Regressão	1	SQ_{Reg}	Q_{Reg}	Q_{Reg}/Q_{Des}
Desvio	n-2	SQ_{Des}	Q_{Des}	
Total	n-1	SQ_{To}		

FV: fonte de variação; GL: grau de liberdade; SQ: soma de quadrados; QM: quadrado médio; F: estatística F; SQ_{Reg} : soma de quadrados da regressão; SQ_{Des} : soma de quadrados do desvio; SQ_{To} : soma de quadrados total; Q_{Reg} : quadrado médio da regressão; Q_{Des} : quadrado médio do desvio; n: repetições.

em que SQ_{To} , SQ_{Reg} e SQ_{Des} são a soma de quadrados total, da regressão e do desvio, respectivamente, obtidas por

$$SQ_{To} = \sum_{i=1}^n Y_i^2 - \frac{(\sum_{i=1}^n Y_i)^2}{n} \quad (17)$$

$$SQ_{Reg} = \hat{\beta}_1 \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \quad (18)$$

$$SQ_{Des} = SQ_{To} - SQ_{Reg} \quad (19)$$

e o quadrado médio da regressão Q_{Reg} e do desvio Q_{Des} são dados por

$$Q_{Reg} = \frac{SQ_{Reg}}{1} \quad (20)$$

$$Q_{Des} = \frac{SQ_{Des}}{n-2}. \quad (21)$$

Ainda, o coeficiente de determinação pode ser estimado por

$$R^2(\%) = 100 \frac{SQ_{Reg}}{SQ_{To}}. \quad (22)$$

4.3.2. Modelo de Regressão Quadrático

Através da análise de regressão polinomial de grau 2, pode-se estabelecer a relação entre a variável dependente Y e independente X , do seguinte modo (COSTA NETO, 2002; SPIEGEL, STEPHENS, 2009)

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \varepsilon. \quad (23)$$

Considerando o método de mínimos quadrados, obtém-se o sistema de equações

$$\begin{cases} \sum Y_i = n\beta_0 + \beta_1 \sum X_i + \beta_2 \sum X_i^2 \\ \sum X_i Y_i = \beta_0 \sum X_i + \beta_1 \sum X_i^2 + \beta_2 \sum X_i^3 \\ \sum X_i^2 Y_i = \beta_0 \sum X_i^2 + \beta_1 \sum X_i^3 + \beta_2 \sum X_i^4 \end{cases} \quad (24)$$

que possibilita encontrar os valores de β_0 , β_1 e β_2 , de modo análogo à regressão linear.

4.3.3. Máxima Eficiência Técnica

O modelo de máxima eficiência técnica (MET) baseia-se em uma regressão quadrática e visa identificar o manejo que proporciona maior ou menor valor da variável de interesse em função da variável independente, conforme desejo do pesquisador (FREITAS et al., 2008; MANTAI et al., 2015).

Considerando

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2, \quad (25)$$

sabe-se que um ponto crítico da função em que ocorre o valor de máximo ou de mínimo acontece quando a derivada é nula, deste modo

$$Y' = \beta_1 + 2\beta_2 X = 0 \quad (26)$$

logo, o valor de X que indica a MET é determinado por

$$X_{MET} = -\frac{\beta_1}{2\beta_2}. \quad (27)$$

e o valor máximo, ou mínimo, da variável de interesse é dado por

$$Y(X_{MET}) = \beta_0 + \beta_1 X_{MET} + \beta_2 X_{MET}^2 = \beta_0 + \beta_1 \left(-\frac{\beta_1}{2\beta_2}\right) + \beta_2 \left(-\frac{\beta_1}{2\beta_2}\right)^2 \quad (28)$$

ou ainda, realizando algumas simplificações,

$$Y(X_{MET}) = \beta_0 - \frac{\beta_1^2}{2\beta_2} + \frac{\beta_1^2}{4\beta_2}. \quad (29)$$

4.3.4. Modelo de Regressão Linear Múltipla

O modelo de regressão linear múltipla permite a inclusão de duas ou mais variáveis independentes no modelo, de modo que o modelo pode ser dado por

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} + \varepsilon_i \quad (30)$$

em que X_p é a p-ésima variável observada, β_p é o coeficiente associado à p-ésima variável, e $\varepsilon = Y - \hat{Y} = Y - \beta_0 - \beta_1 X_1 - \dots - \beta_p X_p$ é o erro (CRUZ, 2006b).

Na forma matricial:

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_n \end{bmatrix}; X = \begin{bmatrix} 1 & X_{11} & X_{21} & \dots & X_{p1} \\ 1 & X_{12} & X_{22} & \dots & X_{p2} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & X_{1n} & X_{2n} & \dots & X_{pn} \end{bmatrix}; \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \dots \\ \beta_p \end{bmatrix} \text{ e } \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_n \end{bmatrix}.$$

A partir das matrizes, podem ser obtidos os valores dos coeficientes de regressão, por meio de

$$\hat{\beta} = (X'X)^{-1}X'Y. \quad (31)$$

Quanto ao teste de hipótese, as hipóteses $H_0: \beta_i = 0$ e $H_A: \beta_i \neq 0$ são avaliadas por meio de

$$t = \frac{\hat{\beta}_i - \beta_i}{\sqrt{\hat{V}(\hat{\beta}_i)}} \quad (32)$$

O coeficiente de determinação é estimado pela seguinte expressão:

$$R^2 = \frac{SQ_{Reg} \cdot 100}{SQ_{Total}} \quad (33)$$

em que SQ_{Reg} e SQ_{Total} são a soma de quadrados da regressão e a soma de quadrados total (CRUZ, 2006b), respectivamente, dadas por

$$SQ_{Reg} = \hat{\beta}'X'Y - C \quad (34)$$

$$SQ_{Total} = Y'Y - C. \quad (35)$$

4.4. Adaptabilidade e Estabilidade

Os modelos de adaptabilidade e estabilidade, através da análise de parâmetros, indicam a capacidade de um genótipo ou manejo em responder favoravelmente a distintas condições ambientais e possibilitam também verificar se há previsibilidade sobre o cultivo. Nesta seção, serão abordados

os modelos de Eberhart e Russel, baseado em regressão linear, e de Cruz, Torres e Vencovsky, fundamentado em regressão bissegmentada.

4.4.1. Modelo de Eberhart e Russel

O modelo de Eberhart e Russel (1966) é baseado em regressão e permite identificar a estabilidade e adaptabilidade de genótipos ou tratamentos. O modelo utilizado é dado por

$$Y_{ij} = b_{0i} + b_{1i}I_j + \delta_{ij} + \bar{\varepsilon}_{ij} \quad (36)$$

em que Y_{ij} é a média do genótipo i no ambiente j , b_{0i} é a média geral do genótipo i , b_{1i} é o coeficiente de regressão linear, que mede a resposta do i -ésimo genótipo à variação do ambiente, I_j é o índice ambiental codificado, δ_{ij} é o desvio da regressão e $\bar{\varepsilon}_{ij}$ é o erro experimental médio (CRUZ; REGAZZI, 2001).

O parâmetro de estabilidade σ^2 é estimado pelo método da análise de variância, sendo dado por

$$\sigma^2 = \frac{QMD_i - QMR}{r} \quad (37)$$

em que QMD_i é o desvio da regressão de cada genótipo e QMR é o quadrado médio do resíduo (CRUZ; REGAZZI, 2001).

O estimador do parâmetro de adaptabilidade é dado por:

$$b_{1i} = \frac{\sum_j Y_{ij}I_j}{\sum_j I_j^2} \quad (38)$$

em que a significância do parâmetro é avaliada pelo teste t , considerando as seguintes hipóteses: $H_0: b_{1i} = 1$ e $H_1: b_{1i} \neq 1$.

O parâmetro b_0 refere-se à média geral, sendo dado por

$$b_{0i} = \bar{Y}_i$$

Geralmente, um tratamento é considerado ideal se apresentar média com magnitude desejada pelo pesquisador, estabilidade ($\sigma^2 = 0$) e adaptabilidade geral ($b_1 = 1$).

4.4.2. Modelo de Cruz, Torres e Vencovsky

O modelo de Cruz, Torres e Vencovsky (1989), através de regressão bissegmentada, caracteriza a adaptabilidade e estabilidade de tratamentos experimentais em ambientes favoráveis e

desfavoráveis (CRUZ, REGAZZI, 2001; BORÉM, MIRANDA, 2005; CRUZ, 2006a). Sua estrutura é dada por

$$Y_{ij} = \beta_{0i} + \beta_{1i}I_j + \beta_{2i}T(I_j) + \delta_{ij} + \bar{\varepsilon}_{ij} \quad (39)$$

em que β_{0i} é a média geral, β_{1i} é o coeficiente angular para ambientes desfavoráveis, $\beta_{1i} + \beta_{2i}$ é o coeficiente angular para ambientes favoráveis, I_j é o índice de ambiente codificado, δ_{ij} são os desvios da regressão, $\bar{\varepsilon}_{ij}$ é o erro experimental e $T(I_j)$ é dado por

$$T(I_j) = \begin{cases} 0, & I_j < 0 \\ I_j - \bar{I}_+, & I_j > 0 \end{cases} \quad (40)$$

com \bar{I}_+ igual a média dos índices I_j positivos.

A estabilidade é indicada pelo componente de variância atribuído aos desvios da regressão $\hat{\sigma}^2$, enquanto a adaptabilidade tem como parâmetros β_{0i} , β_{1i} e $\beta_{1i} + \beta_{2i}$.

As constantes e os coeficientes de regressão são estimados através de

$$\hat{\beta}_{0i} = \bar{Y}_i \quad (41)$$

$$\hat{\beta}_{1i} = \frac{\sum_j Y_{ij}I_j - \sum_j Y_{ij}T(I_j)}{\sum_j I_j^2 - \sum_j T^2(I_j)} \quad (42)$$

$$\hat{\beta}_{2i} = \frac{\sum_j I_j^2 \sum_j Y_{ij}T(I_j) - \sum_j T^2(I_j) \sum_j Y_{ij}I_j}{\sum_j T^2(I_j) [\sum_j I_j^2 - \sum_j T^2(I_j)]} \quad (43)$$

$$\hat{\beta}_{1i} + \hat{\beta}_{2i} = \frac{\sum_j Y_{ij}T(I_j)}{\sum_j T^2(I_j)} \quad (44)$$

os quais estão relacionados às seguintes variâncias

$$\hat{V}(\hat{\beta}_{0i}) = \frac{\hat{\sigma}^2}{ar} \quad (45)$$

$$\hat{V}(\hat{\beta}_{1i}) = \frac{\hat{\sigma}^2}{r[\sum_j I_j^2 - \sum_j T^2(I_j)]} \quad (46)$$

$$\hat{V}(\hat{\beta}_{2i}) = \frac{\hat{\sigma}^2 \sum_j I_j^2}{r \sum_j T^2(I_j) [\sum_j I_j^2 - \sum_j T^2(I_j)]} \quad (47)$$

$$\hat{V}(\hat{\beta}_{1i} + \hat{\beta}_{2i}) = \frac{\hat{\sigma}^2}{r[\sum_j T^2(I_j)]} \quad (48)$$

em que $\hat{\sigma}^2$ é o quadrado médio do resíduo da análise de variância conjunta, a é o número de ambientes e r é o número de repetições do experimento.

A independência entre os parâmetros de adaptabilidade pode ser assegurada devido ao fato de as covariâncias residuais serem nulas, ou seja,

$$Cov(\hat{\beta}_{0i}, \hat{\beta}_{1i}) = 0 \quad (49)$$

$$Cov(\hat{\beta}_{0i}, \hat{\beta}_{1i} + \hat{\beta}_{2i}) = 0 \quad (50)$$

$$Cov(\hat{\beta}_{1i}, \hat{\beta}_{1i} + \hat{\beta}_{2i}) = 0. \quad (51)$$

Quanto às somas de quadrados para a análise de variância conjunta, pode-se obtê-las através de

$$SQ(A/G_i) = r \left[\sum_j Y_{ij}^2 - \frac{r Y_i^2}{a} \right], \text{ para todo } i \quad (52)$$

$$SQ(\text{regressao})_i = \frac{r [\sum_j Y_{ij} I_j - \sum_j Y_{ij} T(I_j)]^2}{\sum_j I_j^2 - \sum_j T^2(I_j)} + \frac{r [\sum_j Y_{ij} T(I_j)]^2}{\sum_j T^2(I_j)} \quad (53)$$

$$SQ(\text{desvio})_i = SQ(A/G_i) - SQ(\text{regressao})_i. \quad (54)$$

As estatísticas t , associadas ao nível de significância e graus de liberdade, para a avaliação das hipóteses são dadas a seguir. Para a primeira hipótese,

$$H_0: \beta_{1i} = 1 \quad (55)$$

tem-se o valor de t

$$t = \frac{\hat{\beta}_{1i}-1}{\sqrt{\hat{v}(\hat{\beta}_{1i})}}. \quad (56)$$

Para

$$H_0: \beta_{1i} + \beta_{2i} = 1 \quad (57)$$

tem-se

$$t = \frac{\hat{\beta}_{1i}+\hat{\beta}_{2i}-1}{\sqrt{\hat{v}(\hat{\beta}_{1i}+\hat{\beta}_{2i})}}. \quad (58)$$

E para a hipótese

$$H_0: \beta_{2i} = 0 \quad (59)$$

tem-se a estatística

$$t = \frac{\hat{\beta}_{2i}}{\sqrt{\hat{v}(\hat{\beta}_{2i})}}. \quad (60)$$

É indicado como ideal o tratamento que apresentar média elevada ou reduzida (conforme o desejo do pesquisador), $\beta_1 < 1$ (adaptabilidade a ambiente desfavorável), $\beta_1 + \beta_2 > 1$ (adaptabilidade a ambiente favorável) e $\sigma^2 = 0$ (estabilidade) (CRUZ, REGAZZI, 2001; CRUZ, 2006a).

4.5. Modelo de Singh

O modelo de contribuição relativa de Singh visa indicar caracteres que apresentam maior influência sobre a divergência genética, quantificando a contribuição de maneira percentual, podendo inclusive ser empregado na verificação do peso de variáveis independentes sobre variáveis-resposta.

Este modelo (SINGH, 1981) baseia-se na distância D^2 de Mahalanobis, que pode ser dada por

$$D^2 = \sum_{i=1}^p \sum_{j=1}^p \omega_{ij} d_i d_j \quad (61)$$

em que ω_{ij} é o elemento da linha i e coluna j na matriz recíproca da variância-covariância da população, p é o número de caracteres e d é a diferença entre médias para um caráter. Ainda, o número total n dos pares de populações é dado por

$$n = t(t + 1)/2 \quad (62)$$

em que t é o número de populações.

Para a avaliação numérica de D^2 , apresentada na equação (61), é seguido um método mais simples que consiste em usar variáveis não correlacionadas transformadas. Usando este método, o valor de D^2 é obtido como uma soma de quadrados de valores de p das variáveis não correlacionadas, tendo

$$D^2 = \sum_{i=1}^p f_i^2 \quad (63)$$

em que f_i é a diferença entre as médias Y dos caracteres não correlacionados transformados.

Para maximização da soma de todos os n valores possíveis de D^2 , deve-se definir P como uma função das diferenças d_i entre as médias de duas populações em relação aos caracteres originais X_i , dada por

$$P = \sum_{i=1}^p l_i d_i \quad (64)$$

em que l_i são constantes a serem determinadas.

Para que a soma de todos os n valores possíveis de D^2 seja a máxima, é estabelecida a condição

$$[B - \lambda W]l = 0 \quad (65)$$

em que B e W são as matrizes de variância-covariância "entre" e "dentro" das populações respectivamente, λ é uma constante e l é o vetor correspondente constituído por elementos l_i , conforme equação (64).

Pode-se simplificar a equação (65), obtendo-se

$$[W^{-1}B - \lambda I]l = 0 \quad (66)$$

em que I é a matriz identidade.

Os elementos de l são afetados pelas unidades particulares dos caracteres X_i , devido a isto eles devem ser padronizados pela multiplicação de cada elemento com o desvio padrão do caráter correspondente, que é obtido a partir de variâncias "internas". Estes novos elementos são denominados pesos padronizados e os elementos do vetor destes pesos são dados por

$$l_i^* = \sqrt{w_{ii}}l_i. \quad (67)$$

A comparação dos valores de l_i^* indica a contribuição relativa dos caracteres X_i para a divergência.

Para mostrar que W^* e B^* são as matrizes das variáveis transformadas correspondentes a W e B das variáveis originais X_i , segue-se a condição para máxima média de D^2

$$[B^* - \lambda W^*]c = 0 \quad (68)$$

em que c é um vetor a ser determinado. Se as variáveis Y_i forem padronizadas para possuírem variância unitária, a relação pode ser simplificada como

$$[B^* - \lambda I]c = 0. \quad (69)$$

A relação entre as variáveis não correlacionadas Y_i e as variáveis originais X_i pode ser dada por

$$Y = VX \quad (70)$$

em que V é uma matriz triangular cujos elementos são funções de variâncias e covariâncias "dentro" das populações. Para a obtenção apenas do vetor correspondente à maior raiz canônica, pode-se utilizar

$$l = c(V^T)^{-1} \quad (71)$$

em que c é o vetor canônico correspondente à maior raiz de B^* das variáveis não correlacionadas.

Para o cálculo dos valores percentuais dos caracteres para a divergência, considerando a soma das colunas ou linhas da matriz dadas por $S_{i1}, S_{i2}, \dots, S_{ip}$, a equação (61) pode ser reescrita por

$$D_i^2 = \sum_{j=1}^p S_{ij} \quad (72)$$

em que i indica o número do par das duas populações.

Os valores de S_{ij} para um dado i indicará a quantidade de contribuição feita pelos diferentes caracteres para a determinação de D_i^2 . Ainda, os valores de D_i^2 podem ser adicionados sobre todos os n pares possíveis para obter o valor total de divergência, obtendo-se

$$\sum_{i=1}^n D_i^2 = \sum_{i=1}^n \sum_{j=1}^p S_{ij} \quad (73)$$

ou então

$$\sum_{i=1}^n D_i^2 = \sum_{j=1}^p S_{.j} \quad (74)$$

em que $S_{.j}$ é o total sobre todos os n valores para o caráter X_j , de modo que os valores de p dos totais de $S_{.j}$, garantem uma boa indicação da importância relativa de diferentes caracteres para a divergência geral.

Por fim, a metodologia pode ser sintetizada pelos passos: (i) obtenção das variâncias “dentro” das populações; (ii) obtenção da matriz triangular V da transformação dos valores X_i em Y_i ; (iii) obter o vetor canônico c da matriz B^* das variáveis não corrigidas, correspondendo à maior raiz canônica. Após isso, devem ser calculadas: a matriz inversa V^{-1} e a sua transposta $(V^{-1})'$, obtendo o vetor l pela equação $l = c(V^{-1})'$ (se desejado, o vetor l pode ser padronizado dividindo cada um dos seus elementos pela soma dos quadrados). Então encontra-se o vetor de pesos padronizados e os resultados podem ser confirmados pelo cálculo de W^{-1} da relação $W^{-1} = V'V$, obtendo os valores de $S_{.j}$ e identificando o caráter correspondente ao maior valor de $S_{.j}$ (SINGH, 1981).

4.6. Stepwise

Na construção de modelos matemáticos representativos de processos agrícolas é indicado que sejam utilizadas variáveis independentes que influenciem significativamente nas variáveis de resposta, evitando redundâncias e reduzindo de modo seguro o número de variáveis a serem empregadas na modelagem (CRUZ, 2006b). Um método utilizado para tal finalidade é o de Stepwise que é realizado de forma iterativa, adicionando (passo *forward*) e removendo variáveis (passo *backward*), a partir de um critério de seleção fundamentado no teste F, podendo também ter outros critérios de seleção (CRUZ, 2006b; ALVES, LOTUFO, LOPES, 2013).

O procedimento de inclusão ou exclusão de variáveis verifica as estatísticas F parciais, testando a importância de cada uma com a variável dependente. São introduzidas variáveis x_i na regressão, uma a uma, até que a equação seja considerada satisfatória. O método de seleção passo a passo tem a vantagem de permitir o reexame, a cada fase ou estágio da análise, do papel das variáveis incorporadas nos estágios anteriores. Uma variável pode ter sido a melhor para incorporação na regressão em um dado estágio anterior e se tornar supérflua em fase posterior, por causa de suas relações com outras incorporadas posteriormente. Este reexame é feito através do teste F-parcial, para cada variável presente na equação, em qualquer fase da análise. A variável x_i mais altamente correlacionada com a variável dependente y é a escolhida e a primeira regressão é estimada, sendo $\hat{y} = f(x_k)$.

O procedimento pode ser descrito da seguinte forma. Considerando f_{entra} ser o valor da variável aleatória F para adicionar uma variável ao modelo e f_{sai} ser o valor da variável aleatória F para remover uma variável do modelo, a regressão em etapas começa formando um modelo com uma variável, usando o regressor que tenha a mais alta correlação com a variável de resposta Y . Essa variável será também o regressor que produz a maior estatística F. Por exemplo, supondo que nessa etapa x_1 seja selecionada. Na segunda etapa, as outras variáveis são examinadas através da estatística parcial F, conforme o modelo

$$F_j = \frac{SQ_R(\beta_j | \beta_1, \beta_0)}{MQ_E(x_j, x_1)}. \quad (75)$$

A nova variável será adicionada à equação desde que $f_j > f_{entra}$. Se esse procedimento indicar que x_2 deverá ser adicionada ao modelo, o algoritmo de regressão em etapas determinará se a variável x_1 adicionada na primeira etapa deverá ser removida. Isso é feito pelo novo cálculo da estatística F

$$F_1 = \frac{SQ_R(\beta_1 | \beta_2, \beta_0)}{MQ_E(x_1, x_2)}. \quad (76)$$

Se o valor calculado f_1 for menor que f_{sai} , a variável x_1 é removida, caso contrário, ela será retida e se tentará adicionar um regressor ao modelo contendo x_1 e x_2 . Em geral, em cada etapa, examina-se o conjunto dos candidatos restantes a regressores. O regressor com a maior estatística parcial F é adicionado ao modelo, desde que o valor observado de f exceda f_{entra} . Então a estatística parcial F para cada regressor no modelo é calculado e o regressor com o menor valor observado de F será removido se o F observado for menor que f_{sai} . O procedimento continua até que nenhum outro regressor possa ser adicionado ou removido do modelo (CRUZ, 2006b; MONTEIRO, 2016).

4.7. Inteligência Artificial

Nesta seção são abordados os métodos de inteligência artificial empregados durante o desenvolvimento desta pesquisa.


4.7.1. Redes Neurais Artificiais (RNAs)

As redes neurais artificiais são um método da inteligência artificial baseado no aprendizado de redes de neurônios biológicos e apresentam um modelo matemático capaz de realizar o aprendizado computacional e o reconhecimento de padrões. As redes neurais artificiais apresentam uma estrutura em que há entradas, simulando os dendritos, estas entradas podem ser múltiplas, como na estrutura biológica. Estes sinais de entrada são multiplicados por valores que são chamados de pesos sinápticos, devido a simularem as sinapses no processo biológico. Os produtos referentes às entradas e respectivos pesos sinápticos são processados em um somatório e o resultado é comparado a um certo limite (threshold), podendo gerar um sinal excitatório ou inibitório que será usado como argumento em uma função de ativação, simulando o limiar de disparo de um neurônio biológico. Após a aplicação da função de ativação, é gerado um sinal de saída que pode ser o sinal de entrada em outros neurônios que estão na camada seguinte, formando assim, uma rede neural (FERNANDES, 2005; SILVA, SPATTI, FLAUZINO, 2010; ALMEIDA, NAKAO, 2014; DORNELLES et al., 2018).

Na modelagem, pode ser utilizado um grande número de neurônios artificiais interconectados, os quais são organizados em camadas de saída ou intermediárias, chamadas também de camadas escondidas ou ocultas. As entradas recebem excitações do exterior, podendo ser comparadas aos órgãos dos sentidos. Os neurônios de saída têm suas respostas usadas para alterar, de alguma forma, o mundo exterior, ou seja, os neurônios biológicos que excitam os músculos. Os neurônios das camadas escondidas, isto é, os neurônios internos, têm grande importância no processamento de dados, de modo que quanto maior o número de camadas escondidas, mais precisa se tornará a rede neural artificial. Entretanto, deve haver um equilíbrio quanto à quantidade de neurônios presentes nas camadas escondidas, visto que um número elevado de neurônios pode causar overfitting, em que a modelagem não reconhece os padrões de modo eficaz, criando restrições demasiadas e desnecessárias em relação aos dados. Em contrapartida, um número muito baixo pode ocasionar underfitting, em que não há neurônios suficientes para o aprendizado e reconhecimento de padrões (GHASEMIAN, HOSSEINMARDI, CLAUSET, 2018).

O neurônio artificial é o elemento mais básico de uma rede neural e corresponde a uma unidade de processamento completa que atua em paralelo com outros neurônios na rede, sua representação é apresentada na literatura conforme a Figura 9

Figura 9 – Neurônio artificial



x_1, x_2, \dots, x_n : sinais de entrada; w_1, w_2, \dots, w_n : pesos sinápticos; θ : limiar de ativação; Σ : somatório; u : potencial de ativação; g : função de ativação; y : sinal de saída.

Fonte: Silva, Spatti, Flauzino (2010)

em que x_1, x_2, \dots, x_n são os sinais de entrada. São sinais ou medidas advindas do meio externo e que representam os valores assumidos pelas variáveis de uma aplicação específica. Os sinais de entrada são usualmente normalizados visando incrementar a eficiência computacional dos algoritmos de aprendizagem. As notações w_1, w_2, \dots, w_n são os pesos sinápticos. São valores que servem para ponderar cada uma das variáveis de entrada da rede, permitindo-se quantificar as suas relevâncias em relação à funcionalidade do respectivo neurônio. O somatório é o combinador linear e tem como função agregar todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos, a fim de produzir um valor de potencial de ativação. θ é o limiar de ativação. É uma variável que especifica o patamar apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção à saída do neurônio. u representa o potencial de ativação. É o resultado produzido pela diferença do valor produzido entre o combinador linear e o limiar de ativação. Se o valor é positivo, então o neurônio produz um potencial excitatório, caso contrário, o potencial será inibitório. g é a função de ativação. Seu objetivo é limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela própria imagem funcional. Por fim, y indica o sinal de saída, que é o valor final produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada, podendo ser também utilizado por outros neurônios que estão sequencialmente interligados (SILVA, SPATTI, FLAUZINO, 2010).

O resultado produzido pelo neurônio artificial pode ser representado pelas equações a seguir (McCULLOCH, PITTS, 1943)

$$u = \sum_{i=1}^n w_i x_i - \theta \quad (77)$$

$$y = g(u). \quad (78)$$

Dessa forma, pode-se assumir o funcionamento de um neurônio artificial por meio da apresentação de um conjunto de valores que representam as variáveis de entrada, multiplicação de cada entrada do neurônio pelo seu respectivo peso sináptico, obtenção do potencial de ativação produzido pela soma ponderada dos sinais de entrada, subtraindo-se o limiar de ativação, aplicação de uma função de ativação apropriada, tendo-se como objetivo limitar a saída do neurônio e compilar a saída a partir da aplicação da função de ativação neural em relação ao seu potencial de ativação.

Silva, Spatti e Flauzino (2010) apontam as características a seguir como as mais relevantes envolvidas com a aplicação de redes neurais artificiais.

- Adaptação por experiência: as adaptações dos parâmetros internos da rede, tipicamente seus pesos sinápticos, são ajustadas a partir da apresentação sucessiva de exemplos (padrões, amostras, medidas) relacionados ao comportamento do processo, possibilitando a aquisição do conhecimento por experimentação;
- Capacidade de aprendizado: por intermédio da aplicação de um método de treinamento, a rede consegue extrair o relacionamento existente entre as diversas variáveis que compõem a aplicação;
- Habilidade de generalização: após o processo de treinamento da rede, essa é capaz de generalizar o conhecimento adquirido, possibilitando estimar soluções que eram até então desconhecidas;
- Organização de dados: baseada em características intrínsecas envolvendo determinado conjunto de informações a respeito de um processo, a rede é capaz de realizar a sua organização interna visando possibilitar o agrupamento de padrões que apresentam particularidades em comum;
- Tolerância a falhas: devido ao elevado nível de interconexões entre os neurônios artificiais, a rede neural torna-se um sistema tolerante a falhas quando parte de sua estrutura interna é sensivelmente corrompida;
- Armazenamento distribuído: o conhecimento a respeito do comportamento de determinado processo dentro de uma arquitetura neural é realizado de forma distribuída entre as diversas sinapses de seus neurônios artificiais, permitindo então um incremento da robustez da arquitetura frente a eventuais neurônios que se tornem inoperantes;
- Facilidade e prototipagem: a implementação da maioria das arquiteturas neurais pode ser facilmente, dependendo da especificidade da aplicação, prototipada em hardware ou em software, pois, após o processo de treinamento, os seus resultados são normalmente obtidos por algumas operações matemáticas elementares.

Funções de Ativação Totalmente Diferenciáveis

A função de ativação, representada por g , é responsável pela obtenção da resposta do neurônio, limitando-a a um valor finito, definindo a saída produzida pela rede neural. Dependendo do objetivo do problema modelado, pode ser escolhida uma ou mais funções de ativação para cada camada ou cada neurônio. As funções de ativação totalmente diferenciáveis são aquelas cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio. As quatro principais funções pertencentes a este grupo e que podem ser empregadas em redes neurais artificiais são a função degrau, a linear, a logística e a tangente hiperbólica.

Arquitetura de Redes Neurais Artificiais

A arquitetura de uma rede neural artificial é a forma com que os neurônios são organizados em uma rede, caracterizando-se como um parâmetro importante. A arquitetura de uma rede neural artificial define a forma como os seus diversos neurônios estão arranjados, ou dispostos, uns em relação aos outros. Esses arranjos são essencialmente estruturados através do direcionamento das conexões sinápticas dos neurônios. Redes neurais artificiais com apenas duas camadas de neurônios, por exemplo, só conseguem resolver problemas linearmente separáveis. Redes recorrentes, por sua vez, são mais apropriadas para resolver problemas que envolvem processamento temporal (BRAGA, CARVALHO, LUDEMIR, 2000; SILVA, SPATTI, FLAUZINO, 2010).

O treinamento de uma arquitetura específica consiste da aplicação de um conjunto de passos ordenados com o intuito de ajustar os pesos e os limiares de seus neurônios. Logo, o processo de ajuste, também conhecido como algoritmo de aprendizagem, visa sintonizar a rede para que as suas respostas estejam próximas dos valores desejados (SILVA, SPATTI, FLAUZINO, 2010). Sabe-se que nas entradas são recebidos os valores iniciais de dados de cada caso, processados e transmitidos para as camadas intermediárias ou ocultas e as camadas de saída recebem os valores da camada intermediária, calculam o valor de saída e emitem o valor final. Enquanto as camadas intermediárias ou ocultas são um conjunto de nós utilizados pela rede neural para representar relações mais complexas do que apenas uma relação de um-a-um entre entrada e saída. São as camadas ocultas e a função de ativação que permitem à rede neural representar facilmente relações não lineares, as quais são muito problemáticas para técnicas multivariadas (ALMEIDA, NAKAO, 2014).

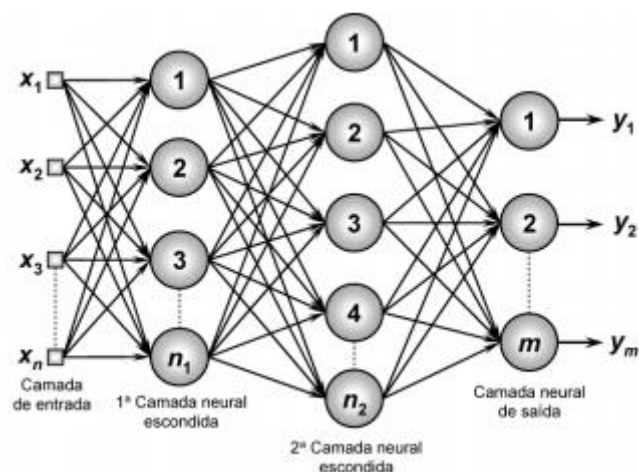
Em uma rede neural com apenas uma camada, a função de ativação já modela a saída da rede neural, entretanto, dado um problema não-linear o mais indicado é a utilização da rede neural Perceptron de múltiplas camadas, em que o sinal de entrada é propagado sucessivamente pelas camadas através da rede, até produzir uma saída. As principais arquiteturas de redes neurais artificiais,

considerando a disposição de seus neurônios, assim como suas formas de interligação entre eles e a constituição de suas camadas, podem ser divididas em: redes *feedforward* (alimentação à frente) de camada simples, redes *feedforward* de camadas múltiplas, redes recorrentes e redes reticuladas (SILVA, SPATTI, FLAUZINO, 2010; BATISTA et al., 2018).

Arquitetura *Feedforward* de Camadas Múltiplas

A rede de múltiplas camadas consiste em um modelo sem realimentação formado por camadas de neurônios Perceptron. Cada neurônio possui uma função de ativação não-linear continuamente diferenciável. A Figura 10 ilustra uma rede *feedforward* de camadas múltiplas formada por uma camada de entrada composta de n sinais, duas camadas neurais escondidas constituídas respectivamente de n_1 e n_2 neurônios e, finalmente, uma camada neural de saída composta de m neurônios representando os valores de saída da aplicação (SILVA, SPATTI, FLAUZINO, 2010).

Figura 10 – Exemplo de rede de camadas múltiplas



x_n : entradas da rede; n_1 : neurônios da primeira camada oculta; n_2 : neurônios da segunda camada oculta; m : neurônios da camada de saída; y_m : saídas da rede.

Fonte: Silva, Spatti, Flauzino (2010).

Entre os principais tipos de redes com arquiteturas de camadas múltiplas se encontra o Perceptron múltiplas camadas (multilayer Perceptron – MLP) e as redes de base radial (radial basis function – RBF), cujos algoritmos de aprendizado utilizados em seus processos de treinamento são, respectivamente, baseados na regra delta generalizada e na regra delta competitiva (SILVA, SPATTI, FLAUZINO, 2010).

Redes Perceptron de Múltiplas Camadas

As redes Perceptron de múltiplas camadas (MLP) são caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, situada entre a camada de entrada e a camada neural de saída. Essa rede tem elevada aplicabilidade em diversos tipos de problemas relacionados a diferentes áreas do conhecimento, sendo sua arquitetura considerada uma das mais versáteis (SILVA, SPATTI, FLAUZINO, 2010).

O algoritmo de aprendizado aplicado no decorrer do processo de treinamento das redes MLP é denominado *backpropagation* ou algoritmo de retropropagação do erro.

Algoritmo *Backpropagation*


O algoritmo mais popular das redes neurais artificiais é o de retropropagação do erro, cuja fundamentação é corrigir os erros conforme a regra de aprendizagem. A maioria dos métodos de aprendizado para redes neurais artificiais utiliza variações deste algoritmo (BRAGA, CARVALHO, LUDEMIR, 2000).

O algoritmo de retropropagação do erro é baseado na regra delta generalizada. Este algoritmo propõe uma forma de definir o erro dos nós das camadas intermediárias, possibilitando o ajuste de seus pesos. Os ajustes dos pesos são realizados utilizando-se o método do gradiente.

Pode-se dividir o algoritmo em dois passos: o direito e o reverso. No passo direito, o vetor de entrada é aplicado e seu efeito se propaga através das camadas da rede neural, produzindo uma saída, com os pesos todos fixos. No passo reverso, os pesos são reajustados de acordo com a regra de aprendizado por correção de erro. A resposta fornecida pela rede é subtraída da resposta desejada, produzindo um sinal de erro, sendo esse sinal propagado de volta através dos mesmos neurônios do passo direito, mas no sentido contrário do fluxo de sinais das conexões. Os pesos são ajustados de forma que a resposta a ser produzida pela rede se aproxime da resposta esperada.

Para a compreensão da funcionalidade do algoritmo *backpropagation*, será necessário partir da definição de diversas variáveis e parâmetros auxiliares, conforme observados na Figura 11.

Figura 11 – Estrutura de uma rede neural e notações

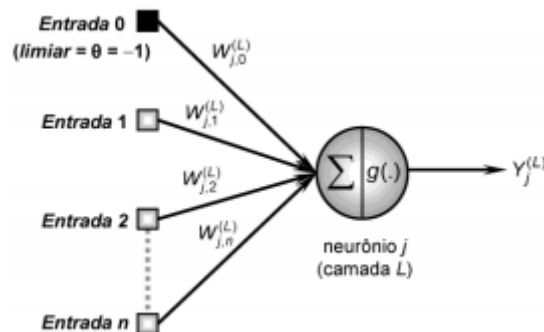


x_n : entradas da rede; n_1 : neurônios da primeira camada oculta; n_2 : neurônios da segunda camada oculta; n_3 : neurônios da camada de saída; $W_{ji}^{(n)}$: matriz de pesos; $I_j^{(L)}$: vetor de entradas ponderadas; $Y_j^{(L)}$: vetor de elementos de saída.

Fonte: Silva, Spatti, Flauzino (2010).

Será visto cada neurônio pertencente a uma das camadas da topologia ilustrada na Figura 11 como um Perceptron simples como mostra a Figura 12.

Figura 12 – Configuração de um neurônio



$W_{jn}^{(L)}$: matriz de pesos; $Y_j^{(L)}$: vetor de elementos de saída; $g(\cdot)$: função de ativação; Σ : somatório.

Fonte: Silva, Spatti, Flauzino (2010)

em que $g(\cdot)$ representa uma função de ativação que deve ser contínua e diferenciável em todo o seu domínio, $W_{ji}^{(L)}$ são matrizes de pesos cujos elementos denotam o valor do peso sináptico conectando o j -ésimo neurônio da camada L ao i -ésimo neurônio da camada $L - 1$, $W_{ji}^{(3)}$ é o peso sináptico conectando o j -ésimo neurônio da camada de saída ao i -ésimo neurônio da camada 2, $W_{ji}^{(2)}$ é o peso sináptico conectando o j -ésimo neurônio da camada escondida 2 ao i -ésimo neurônio da camada 1, $W_{ji}^{(1)}$ é o peso sináptico conectando o j -ésimo neurônio da camada escondida 1 ao i -ésimo neurônio

da camada de entrada, $I_j^{(L)}$ são vetores cujo os elementos denotam a entrada ponderada em relação ao j -ésimo neurônio da camada L , os quais são definidos por

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} \cdot x_i \Leftrightarrow I_j^{(1)} = W_{j,0}^{(1)} \cdot x_0 + W_{j,1}^{(1)} \cdot x_1 + \dots + W_{j,n}^{(1)} \cdot x_n \quad (79)$$

$$I_j^{(2)} = \sum_{i=0}^n W_{ji}^{(2)} \cdot y_i^{(1)} \Leftrightarrow I_j^{(2)} = W_{j,0}^{(2)} \cdot y_0^{(1)} + W_{j,1}^{(2)} \cdot y_1^{(1)} + \dots + W_{j,n}^{(2)} \cdot y_n^{(1)} \quad (80)$$

$$I_j^{(3)} = \sum_{i=0}^n W_{ji}^{(3)} \cdot y_i^{(2)} \Leftrightarrow I_j^{(3)} = W_{j,0}^{(3)} \cdot y_0^{(2)} + W_{j,1}^{(3)} \cdot y_1^{(2)} + \dots + W_{j,n}^{(3)} \cdot y_n^{(2)} \quad (81)$$

e $Y_j^{(L)}$ são vetores cujos elementos denotam a saída do j -ésimo neurônio em relação à camada L , os quais são definidos por

$$Y_j^{(1)} = g(I_j^{(1)}) \quad (82)$$

$$Y_j^{(2)} = g(I_j^{(2)}) \quad (83)$$

$$Y_j^{(3)} = g(I_j^{(3)}). \quad (84)$$

Todo o processo de treinamento da Perceptron Múltiplas Camadas é em função do sinal de erro, expresso por

$$e_j(k) = d_j(k) - y_j(k) \quad (85)$$

em que $d_j(k)$ é a resposta desejada para o neurônio j , e $y_j(k)$ é a resposta calculada para o neurônio j .

Ainda, assume-se a função erro quadrático para medir o desempenho local associado aos resultados produzidos pelos neurônios de saída à referida amostra, ou seja

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} (d_j(k) - y_j^{(3)}(k))^2 \quad (86)$$

em que $y_j^{(3)}(k)$ é o valor produzido pelo j -ésimo neurônio de saída da rede considerando-se a k -ésima amostra de treinamento, enquanto que $d_j(k)$ é o seu respectivo valor desejado.

Assumindo um conjunto de treinamento composto por p amostra, o “erro quadrático médio” é definido como

$$E(k) = \frac{1}{p} \sum_{k=1}^p E(k). \quad (87)$$

O método utilizado para o ajuste dos pesos e limiares é baseado no gradiente da função erro quadrático.

Pesos da Camada de Saída

De acordo com Silva, Spatti e Flauzino (2010), o objetivo do processo de treinamento para a camada neural de saída é determinar o gradiente $\nabla E^{(3)}$, para aplicar a correção $\Delta W_{ji}^{(3)}$ na matriz de pesos $W_{ji}^{(3)}$ com o intuito de minimizar o erro entre a saída produzida pela rede e sua respectiva saída desejada. De acordo com a regra da cadeia do cálculo, pode expressar esse gradiente como

$$\nabla E^{(3)} = \frac{\partial E}{\partial W_{ji}^{(3)}} = \frac{\partial E}{\partial Y_j^{(3)}} \cdot \frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} \cdot \frac{\partial I_j^{(3)}}{\partial W_{ji}^{(3)}} \quad (88)$$

assim, por intermédio das definições anteriores temos que

$$\frac{\partial I_j^{(3)}}{\partial W_{ji}^{(3)}} = Y_i^{(2)} \quad (89)$$

$$\frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} = g'(I_j^{(3)}) \quad (90)$$

$$\frac{\partial E}{\partial Y_j^{(3)}} = -(d_j - Y_j^{(3)}) \quad (91)$$

em que $g'(\cdot)$ denota a derivada de primeira ordem da função de ativação considerada.

Substituindo os resultados das equações (89), (90) e (91) na equação (88), tem-se

$$\frac{\partial E}{\partial W_{ji}^{(3)}} = -(d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \cdot Y_i^{(2)}. \quad (92)$$

Assim, o ajuste da matriz de pesos $W_{ji}^{(3)}$ deve ser efetuado em direção oposta ao gradiente afim de minimizar o erro, ou seja

$$\Delta W_{ji}^{(3)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(3)}} \Leftrightarrow \Delta W_{ji}^{(3)} = \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (93)$$

em que η é a taxa de aprendizagem do algoritmo *backpropagation* e $\delta_j^{(3)}$ determina o gradiente local em relação ao j -ésimo neurônio de camada de saída d e é dado por

$$\delta_j^{(3)} = (d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}). \quad (94)$$

Ainda, pode-se escrever a expressão (93) no seguinte procedimento recursivo

$$W_{ji}^{(3)}(t+1) = W_{ji}^{(3)}(t) + \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)}. \quad (95)$$

Pesos das Camadas Intermediárias

O ajuste dos neurônios das camadas intermediárias é realizado mediante estimativas de erros de saída produzidos por neurônios da camada imediatamente posterior, os quais já foram previamente ajustados. Isso ocorre, pois diferentemente dos neurônios da camada de saída, os neurônios das camadas intermediárias não têm acesso de forma direta aos valores desejados para as suas saídas. Desta forma, o ajuste dos pesos sinápticos da segunda camada escondida tem como objetivo o processo de treinamento que consiste em ajustar a matriz de pesos $W_{ji}^{(2)}$ com o intuito de minimizar o erro entre a saída produzida pela rede em relação à retropropagação do erro advindo dos ajustes dos neurônios da camada neural de saída. Dessa forma, tem-se

$$\nabla E^{(2)} = \frac{\partial E}{\partial W_{ji}^{(2)}} = \frac{\partial E}{\partial Y_j^{(2)}} \cdot \frac{\partial Y_j^{(2)}}{\partial I_j^{(2)}} \cdot \frac{\partial I_j^{(2)}}{\partial W_{ji}^{(2)}} \quad (96)$$

mediante o uso das definições anteriores tem-se que

$$\frac{\partial I_j^{(2)}}{\partial W_{ji}^{(2)}} = Y_i^{(1)} \quad (97)$$

$$\frac{\partial Y_j^{(2)}}{\partial I_j^{(2)}} = g'(I_j^{(2)}) \quad (98)$$

$$\frac{\partial E}{\partial Y_j^{(2)}} = \sum_{k=1}^{n_3} \frac{\partial E}{\partial I_k^{(3)}} \cdot \frac{\partial I_k^{(3)}}{\partial Y_j^{(2)}} = \sum_{k=1}^{n_3} \frac{\partial E}{\partial I_k^{(3)}} \cdot \frac{\partial \left(\sum_{k=1}^{n_3} W_{kj}^{(3)} \cdot Y_j^{(2)} \right)}{\partial Y_j^{(2)}}, \quad (99)$$

considerando que

$$\frac{\partial \left(\sum_{k=1}^{n_3} W_{kj}^{(3)} \cdot Y_j^{(2)} \right)}{\partial Y_j^{(2)}} = W_{kj}^{(3)} \quad (100)$$

tem-se

$$\frac{\partial E}{\partial Y_j^{(2)}} = \sum_{k=1}^{n_3} \frac{\partial E}{\partial I_k^{(3)}} \cdot W_{kj}^{(3)} \quad (101)$$

por outro lado,

$$\frac{\partial E}{\partial Y_j^{(2)}} = \frac{\partial E}{\partial Y_j^{(3)}} \cdot \frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} \rightarrow \frac{\partial E}{\partial I_j^{(3)}} = - \left(d_j - Y_j^{(3)} \right) \cdot g'(I_j^{(3)}) = -\delta_j^{(3)} \quad (102)$$

substituindo (102) em (101), obtém-se

$$\frac{\partial E}{\partial Y_j^{(2)}} = - \sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)}. \quad (103)$$

Ao substituir as equações (97), (98) e (101), na equação (96), chega-se a

$$\frac{\partial E}{\partial W_{ji}^{(2)}} = - \left(\sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)} \right) g'(I_j^{(2)}) \cdot Y_i^{(1)}. \quad (104)$$

Consequentemente, o ajuste da matriz de pesos $W_{ji}^{(2)}$ deve ser efetuado em direção oposta ao gradiente, a fim de minimizar o erro, ou seja

$$\Delta W_{ji}^{(2)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(2)}} \Leftrightarrow \Delta W_{ji}^{(2)} = \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (105)$$

em que $\delta_j^{(2)}$ é definido como o gradiente local em relação ao j -ésimo neurônio da segunda camada intermediária, e é dado por

$$\delta_j^{(2)} = \sum_{k=1}^{n_3} (\delta_k^{(3)} \cdot W_{kj}^{(3)}) \cdot g'(I_j^{(2)}) \quad (106)$$

de forma complementar pode-se escrever a equação (106) no seguinte procedimento iterativo

$$W_{ji}^{(2)}(t+1) = W_{ji}^{(2)}(t) + \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)}. \quad (107)$$

O ajuste dos pesos sinápticos da primeira camada escondida tem como objetivo o processo de treinamento que consiste em ajustar a matriz de pesos $W_{ji}^{(1)}$ com o intuito de minimizar o erro entre a saída produzida pela rede em relação à retropropagação do erro advindo dos ajustes dos neurônios da segunda camada neural. Assim tem-se

$$\nabla E^{(1)} = \frac{\partial E}{\partial W_{ji}^{(1)}} = \frac{\partial E}{\partial Y_j^{(1)}} \cdot \frac{\partial Y_j^{(1)}}{\partial I_j^{(1)}} \cdot \frac{\partial I_j^{(1)}}{\partial W_{ji}^{(1)}} \quad (108)$$

por meio das definições anteriores tem-se

$$\frac{\partial I_j^{(1)}}{\partial W_{ji}^{(1)}} = x_i \quad (109)$$

$$\frac{\partial Y_j^{(1)}}{\partial I_j^{(1)}} = g'(I_j^{(1)}) \quad (110)$$

$$\frac{\partial E}{\partial Y_j^{(1)}} = \sum_{k=1}^{n_2} \frac{\partial E}{\partial I_k^{(2)}} \cdot \frac{\partial I_k^{(2)}}{\partial Y_j^{(1)}} = \sum_{k=1}^{n_2} \frac{\partial E}{\partial I_k^{(2)}} \cdot \frac{\partial \left(\sum_{k=1}^{n_2} W_{kj}^{(2)} \cdot Y_j^{(1)} \right)}{\partial Y_j^{(1)}}. \quad (111)$$

De maneira semelhante ao ajuste anterior, observa-se que

$$\frac{\partial \left(\sum_{k=1}^{n_2} W_{kj}^{(2)} \cdot Y_j^{(1)} \right)}{\partial Y_j^{(1)}} = W_{kj}^{(2)} \quad (112)$$

logo,

$$\frac{\partial E}{\partial Y_j^{(1)}} = \sum_{k=1}^{n_2} \frac{\partial E}{\partial I_k^{(2)}} \cdot W_{kj}^{(2)}. \quad (113)$$

Por outro lado, tem-se

$$\frac{\partial E}{\partial Y_j^{(2)}} = \frac{\partial E}{\partial Y_j^{(2)}} \cdot \frac{\partial Y_j^{(2)}}{\partial I_j^{(2)}} \rightarrow \frac{\partial E}{\partial I_k^{(2)}} = - \left(\sum_{k=1}^{n_2} \delta_k^{(2)} \cdot W_{kj}^{(2)} \right) g'(I_j^{(2)}) = -\delta_j^{(2)} \quad (114)$$

substituindo (114) em (113),

$$\frac{\partial E}{\partial Y_j^{(1)}} = - \sum_{k=1}^{n_2} \delta_k^{(2)} \cdot W_{kj}^{(2)} \quad (115)$$

e substituindo as equações (109), (110) e (115), na equação (108),

$$\frac{\partial E}{\partial W_{ji}^{(1)}} = - \left(\sum_{k=1}^{n_2} \delta_k^{(2)} \cdot W_{kj}^{(2)} \right) \cdot g'(I_j^{(1)}) \cdot x_i. \quad (116)$$

Consequentemente, o ajuste da matriz de pesos $W_{ji}^{(1)}$ deve ser efetuado em direção oposta ao gradiente, a fim de minimizar o erro, ou seja

$$\Delta W_{ji}^{(1)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(1)}} \Leftrightarrow \Delta W_{ji}^{(1)} = \eta \cdot \delta_j^{(1)} \cdot x_i \quad (117)$$

em que $\delta_j^{(1)}$ é o gradiente local em relação ao j -ésimo neurônio da primeira camada intermediária, dado por

$$\delta_j^{(1)} = \sum_{k=1}^{n_2} (\delta_k^{(2)} \cdot W_{kj}^{(2)}) \cdot g'(I_j^{(1)}). \quad (118)$$

De forma complementar pode-se escrever a expressão (118) no seguinte procedimento iterativo

$$W_{ji}^{(1)}(t+1) = W_{ji}^{(1)}(t) + \eta \cdot \delta_j^{(1)} \cdot x_i. \quad (119)$$

A resposta almejada em todas as camadas escondidas deve ser determinada em função dos neurônios da camada imediatamente posterior que estão diretamente conectados e já foram previamente ajustados no passo anterior.

As explicações acima demonstram os cálculos em uma rede com duas camadas ocultas. Nesta pesquisa, no entanto, foi utilizada apenas uma camada oculta.

4.7.2. Algoritmos Genéticos

O algoritmo genético (AG) é um método de otimização do campo da inteligência artificial inspirado na evolução de seres vivos. Os AGs são uma subclasse dos algoritmos evolucionários, em que os elementos do espaço de busca são baseados em mecanismos genéticos de organismos biológicos que se adaptam a mudanças em ambientes altamente competitivos (GOMES et al., 2017; MOREIRA, MARTINS, WANNER, 2017).

Nestes algoritmos, a troca de informação gera um procedimento de busca capaz de encontrar a melhor solução para uma série de problemas por meio da combinação de conceitos de seleção natural e operadores genéticos. O algoritmo genético é um algoritmo matemático fortemente paralelizável e permite transformar uma população (conjunto de possíveis soluções), cujos indivíduos têm uma aptidão associada, em uma nova população (seguinte geração). Essa transformação é feita

utilizando operações baseadas nos princípios darwinianos de reprodução e sobrevivência dos melhores indivíduos (os mais aptos). As principais razões de uso dos algoritmos genéticos são a sua ampla aplicabilidade e ótimo desempenho (GOLDBERG, 1989; KOZA, 1994; GOLDBARG et al., 2005).

Dentre os principais procedimentos que constituem o funcionamento de um algoritmo genético, destaca-se a geração de uma população de soluções, a mutação dos indivíduos, a aplicação dos operadores genéticos, a definição da função objetivo e da função aptidão. A otimização com o uso dos algoritmos genéticos inicia com a geração de uma população de indivíduos, os quais são formados por um conjunto aleatório de cromossomos, representando possíveis soluções do problema a ser resolvido. Durante o processo evolutivo, a população é avaliada e cada indivíduo recebe uma nota, refletindo a qualidade da solução que ele representa. Após, são aplicados os operadores genéticos para criar uma nova população. Em geral, os indivíduos mais aptos são selecionados e os menos aptos são descartados. Os membros selecionados podem sofrer modificações em suas características fundamentais através dos operadores de crossover e mutação, gerando descendentes para a próxima geração. Este processo é repetido até que uma solução satisfatória seja encontrada. Na terminologia de funcionamento de um algoritmo genético, um ciclo de operações é conhecido como uma geração (LINDEN, 2012; SINGH, MISRA, 2017).

Os algoritmos genéticos possuem três principais operadores genéticos: cruzamento, mutação e seleção. Estes operadores dominam o processo de busca. Sendo que se inicia com a seleção dos pais, o cruzamento (crossover) dos pais para gerar novos indivíduos (filhos) e a mutação que altera em maior ou menor medida o cromossomo dos novos filhos. Cada um destes passos é implementado dentro do algoritmo como um operador diferente.

População Inicial

A inicialização da população é realizada randomicamente e então são aplicadas ações dos passos subsequentes do processo. A codificação de cada indivíduo corresponde a um conjunto de cromossomos, e o caráter do cromossomo equivale a um gene. O termo genótipo é a estrutura codificada do cromossomo, enquanto o termo fenótipo representa a interação do conteúdo genético com o ambiente, interação esta que se dá através do conjunto de parâmetros do algoritmo (LINDEN, 2012).

Cruzamento

O operador de cruzamento, também chamado operador de crossover, é responsável por realizar a combinação de dois indivíduos para gerar dois ou mais filhos. A eficiência da busca depende em grande parte da diversidade da população e da necessidade seletiva. Destaca-se que os principais métodos de cruzamento são: cruzamento em ponto único e cruzamento em múltiplos pontos (GOLDBARG et al., 2005).

O método de cruzamento em um ponto único consiste em escolher aleatoriamente um ponto ao longo da cadeia de genes, os genes à esquerda deste ponto são copiados de um dos pais e os genes a direita são copiados do outro. O cruzamento em múltiplos pontos é uma generalização do cruzamento em ponto único, em que muitos pontos de cruzamento podem ser utilizados na cadeia de genes, gerando novos filhos.

Mutação

O operador de mutação permite a alteração do código genético de forma aleatória, acrescentando novas informações ao processo de pesquisa. Seu principal objetivo é garantir a diversidade das populações, a fim de reduzir as chances de o algoritmo ficar preso em mínimos locais (GOMES et al., 2017).

O operador de mutação tem normalmente associada uma probabilidade extremamente baixa, sendo sorteado um número entre 0 e 1 (0 e 100%). Se ele for menor que a probabilidade predeterminada então o operador atua sobre o gene em questão, alterando-lhe o valor aleatoriamente. Além disso, o valor da probabilidade deve ser baixo, pois se ele for muito alto, a população degenerará rapidamente e dificilmente o algoritmo genético convergirá para uma solução (LINDEN, 2012).

Função Aptidão ou *Fitness*

A partir da população inicial são realizadas várias gerações visando obter melhores indivíduos. Durante este processo evolutivo, cada um dos indivíduos da população é avaliado em cada geração. Neste processo, atribui-se a cada indivíduo uma nota ou valor de *fitness*. Neste caso, quanto maior o valor do *fitness* melhor é a aptidão. A função aptidão é modelada de acordo com o problema, fornecendo um valor de qualidade dos cromossomos. Isto significa que os indivíduos com maior aptidão terão maior probabilidade de serem selecionados como candidatos para uma nova população (FERREIRA NETO et al., 2011).

Métodos de Seleção de Cromossomos para o Cruzamento

Por meio deste operador, é possível selecionar, por diferentes procedimentos, indivíduos da população (pais) para participar do processo de reprodução. O conjunto dos indivíduos selecionados dará origem aos filhos, depois de aplicar-lhe os operadores de cruzamento e mutação (LINDEN, 2012). Dentre os principais métodos de seleção, está o método por torneio.

A seleção por torneio consiste em selecionar uma série de indivíduos da população e fazer com que eles entrem em competição direta pelo direito de ser pai, usando como arma a sua avaliação. Neste método, existe um parâmetro denominado tamanho do torneio k , o qual define quantos indivíduos são selecionados aleatoriamente dentro da população para competir. Uma vez definidos os competidores, aquele dentre eles que possui a melhor avaliação é selecionado para a aplicação do operador genético. O valor mínimo atribuído para k é 2, pois do contrário não haverá competição, mas não há nenhum limite teórico para o valor máximo deste parâmetro. Caso seja escolhido o valor igual ao tamanho da população n o vencedor será sempre o mesmo (o melhor de todos os indivíduos) e se forem escolhidos valores muito altos (próximos do tamanho da população), os $n - k$ indivíduos tenderão a predominar, uma vez que sempre um deles será o vencedor do torneio. Assim, os indivíduos são selecionados para participar do torneio de forma completamente aleatória. A vantagem que os melhores indivíduos da população têm é que, se selecionados, eles vencerão o torneio (LINDEN, 2012).

5. DESEMPENHO DE DISTINTAS ÉPOCAS DE SEMEADURA DA AVEIA NA DEFINIÇÃO DE UMA ZONA DE ESCAPE NATURAL NO CONTROLE DE DOENÇAS FOLIARES

5.1. Introdução

A aveia é um cereal de múltiplos propósitos, podendo ser utilizada na rotação e sucessão de culturas, na alimentação animal como pastagem, ração, feno e silagem, na alimentação humana na forma de flocos, farelo ou farinha e também na produção de cosméticos (AGOSTINETTO et al., 2015; MA et al., 2017; MALANCHEN et al., 2019). No entanto, esta planta pode ter seu cultivo prejudicado devido ao ataque de patógenos fúngicos, que causam doenças foliares, dentre as quais pode-se destacar a ferrugem da folha e a helmintosporiose (FOLLMANN et al., 2016).

As doenças foliares surgem e se desenvolvem em condições de aumento da temperatura do ar aliadas à elevada umidade relativa do ar. O controle geralmente é realizado com aplicação de fungicidas, no entanto, seu uso indiscriminado pode acarretar em problemas à saúde pública, com a contaminação do ambiente, da água e dos alimentos, bem como, ao produtor rural, devido ao contato próximo com os agrotóxicos (PEREIRA et al., 2020).

Na região noroeste do estado do Rio Grande do Sul (RS), normalmente se observa elevação das temperaturas ao final do ciclo de cultivo da aveia nas sementeiras no período de recomendação que ocorre de 15 de maio a 15 de junho (Figura 1, Capítulo 1), o que pode gerar maior pressão de inóculo e aplicação de fungicidas na fase de enchimento de grãos. O ajuste na época de sementeira pode propiciar que o desenvolvimento da planta ocorra com incidência de menores temperaturas, reduzindo a ocorrência de doenças foliares e o uso de fungicidas, favorecendo um cultivo mais sustentável da aveia. Deste modo, o objetivo deste capítulo é definir uma zona de escape natural às doenças fúngicas, com base na temperatura média do ar, na análise de distintas épocas de sementeira da aveia na região noroeste do RS, determinando os cenários de sementeira mais favoráveis ao controle dos patógenos, que demonstrem também resultados satisfatórios quanto à produtividade de grãos.

5.2. Materiais e métodos

Os dados meteorológicos foram apresentados para a análise das épocas de sementeira, destacando os momentos de emergência, paniculamento, maturação fisiológica e colheita em cada cenário. Para uma análise robusta, foi verificado o desempenho das épocas de sementeira em cada ano agrícola, considerando também os resultados de todos os anos agrícolas simultaneamente. Nestas análises foram considerados os resultados médios dos indicadores do ciclo de desenvolvimento da aveia das três cultivares, URS Corona, URS Taura e URS Guria, na ausência de fungicida.


Com base nas informações presentes na literatura, relacionadas às características meteorológicas que garantem redução do desenvolvimento dos fungos, foram consideradas temperaturas do ar menores ou iguais a 18°C na definição da zona de escape aos patógenos fúngicos no cultivo da aveia (NERBASS JUNIOR et al., 2010). A temperatura média observada foi apresentada juntamente ao seu comportamento simulado por meio de regressão quadrática, o qual possibilitou demarcar a zona de escape em cada ano de cultivo e também independente de ano. Posteriormente, os resultados da zona de escape também foram confrontados com as médias de área foliar necrosada observadas dos 60 aos 120 dias após a emergência e com os valores de produtividade de grãos obtidos, em cada época de semeadura, cultivar, ano agrícola e também em uma análise com os efeitos de todos os anos. A fim de verificar o agrupamento das médias de produtividade de grãos por Scott e Knott, a influência da época de semeadura sobre essa variável foi verificada pela ANOVA (não apresentado) em cada ano e cultivar individualmente, além de também considerar os efeitos de todos os anos simultaneamente em cada cultivar.

As descrições detalhadas das variáveis estudadas neste capítulo podem ser observadas no Capítulo 3. Os modelos utilizados, por sua vez, estão descritos no Capítulo 4 e foram empregados utilizando o software livre Genes. Em todas as análises estatísticas foi considerado nível de significância de 5%. Também foram empregados softwares do pacote Microsoft Office.

5.3. Resultados e discussão

Na Figura 13, há os dados meteorológicos do ano de 2018, a zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura considerada na pesquisa.

Figura 13 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura no ano de 2018.



Fonte: autoria própria.

Em 2018, na semeadura de 15 de abril, anterior à recomendação de cultivo, a zona de escape com temperaturas do ar abaixo de 18°C inicia-se aos 27 dias após a emergência (DAE) das plântulas de aveia, ultrapassando o período de maturidade fisiológica e a colheita de grãos. Na semeadura realizada no dia 01 de maio, também anterior à recomendação de cultivo, a zona de escape inicia aos 13 DAE, se estendendo até poucos dias anteriores à colheita, em torno de 133 DAE. Quando realizada

a semeadura em 15 de maio, a zona de escape iniciou anterior à emergência, se estendendo aos 112 DAE, próximo ao ponto de maturidade fisiológica das plantas e colheita. Destaca-se que 15 de maio representa o período de início da recomendação de semeadura para o cultivo de aveia.


Ainda dentro do período de recomendação, na semeadura de 01 de junho, o intervalo de cultivo pertencente à zona de escape começa a demonstrar uma redução. Parte do período de proteção acontece antes da emergência das plantas, havendo desperdício da zona de escape, reduzindo a proteção ao final do ciclo. Deste modo, logo após o paniculamento há temperaturas superiores a 18°C, concentrando o desenvolvimento das doenças próximo à maturação fisiológica e à colheita. Destaca-se que na fase final de desenvolvimento é mais importante o controle pela zona de escape, visto que a aplicação de fungicidas pode gerar contaminação residual nos grãos. Pereira et al. (2020) evidenciam que as doenças não são controladas totalmente pelas características genéticas das plantas, e que o aparecimento das moléstias é influenciado pelo aumento da temperatura do ar e pela presença de umidade, que são condições marcantes no final da estação fria, em que as cultivares estão em estádios finais de desenvolvimento.

Na semeadura realizada no dia 15 de junho, época que sinaliza o fim do período de recomendação de semeadura da aveia para a região noroeste do RS, aumenta-se ainda mais a zona de escape anterior à emergência das plântulas, que não é aproveitada no cultivo. O período de proteção finda no paniculamento, sendo que em toda a fase de enchimento de grãos não ocorre um controle das doenças, indicando a necessidade de manejos com uso de fungicida, visto que não há resistência genética suficiente nas cultivares de aveia (KIMATI et al., 2005).

Na semeadura de 01 de julho, configurando uma situação de atraso na semeadura, comum em regiões produtoras devido a períodos prolongados de chuvas, percebe-se que a amplitude da zona de escape durante o cultivo reduz consideravelmente, encerrando anteriormente ao paniculamento. Isso indica maior fase de pressão de inóculo sobre o desenvolvimento das plantas e necessidade de aplicação de fungicidas entre o paniculamento e enchimento de grãos (NERBASS JUNIOR et al., 2010; NAZARENO et al., 2018). Em um cenário mais drástico, com semeadura em 15 de julho, que também pode ser observado em situações reais de cultivo, mais da metade da zona de escape está exterior ao ciclo de desenvolvimento da aveia. Cerca de 53 DAE pertencem à zona de escape, mas toda a fase de alongação, paniculamento e enchimento de grãos acontece com grande pressão de inóculo, por não estar no período de proteção natural pela temperatura.

Na Figura 14, são apresentados os dados meteorológicos do ano de 2019, a zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura.

Figura 14 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura no ano de 2019.



Fonte: autoria própria.

Avaliando os distintos cenários no ano de 2019, na semeadura de 15 de abril, a maior parte do ciclo da aveia está dentro da zona de escape, com proteção a partir dos 31 DAE, ultrapassando a colheita. Na semeadura de 01 de maio, a zona de escape inicia logo após a emergência, aos 14 DAE, e se estende até a colheita, evidenciando também máxima proteção durante o ciclo. Destaca-se que


ambas as sementeiras, de 15 de abril e 01 de maio, são anteriores ao período de recomendação, que inicia em 15 de maio.

No cenário de abertura do período de recomendação, observa-se proteção natural desde a emergência até cerca de 10 dias após a maturação fisiológica, sendo que não há mais deposição de reserva nos grãos, indicando que não há necessidade de uso de fungicida. Na sementeira em 01 de junho, o ciclo de cultivo fica na zona de escape até os 108 DAE, protegendo parte do período de enchimento de grãos. Cerca de 13 dias anteriores à maturidade fisiológica se encontram sem proteção natural, o que pode indicar possível pressão de inóculo e necessidade de aplicação de fungicida. Em 15 de junho, que é o limite do período de recomendação da sementeira de aveia para a região noroeste do estado do Rio Grande do Sul, há um aproveitamento menor da zona de escape durante o cultivo em relação às épocas anteriores. Cerca da metade do período entre o paniculamento e a maturidade fisiológica ocorre após o término do período de proteção às doenças, indicando possível necessidade no uso de agrotóxicos no controle de doenças, devido ao aumento da temperatura (PEREIRA et al., 2020).

Na sementeira em 01 de julho, posterior ao período de recomendação, percebe-se o paniculamento próximo ao fim da zona de escape, evidenciando o enchimento de grãos sem adequado controle às doenças. Em 15 de julho, a zona de escape se encerra aos 65 DAE, com as fases de paniculamento, enchimento de grãos e maturação fisiológica desprotegidas. Nestas épocas posteriores à recomendação, há fortes indícios de necessidade de aplicação de fungicidas para o controle das doenças foliares da aveia. De modo semelhante, Lau et al. (2011) destacam que na cultura do trigo a incidência de algumas doenças fúngicas ocorrem com maior intensidade em cultivares de maturação tardia ou quando a sementeira é tardia.

Na Figura 15, são apresentados os dados meteorológicos para o ano de 2020, a zona de escape e o ciclo de cultivo da aveia em cada época de sementeira.

Figura 15 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura no ano de 2020.



Fonte: autoria própria.

Em 2020, na semeadura de 15 de abril, anterior à recomendação de semeadura da aveia para a região noroeste do RS, o período de zona de escape inicia logo após a emergência, aos 6 DAE, se estendendo próximo à colheita de grãos. Neste cenário, o período de proteção seria suficiente para o controle satisfatório de doenças fúngicas. A semeadura em 01 de maio também se mostra eficiente,

de modo que a zona de escape inicia antes da emergência das plântulas, ultrapassando a maturidade fisiológica, indicando que não haveria necessidade do uso de agrotóxicos fungicidas.


No início do período de recomendação, com semeadura em 15 de maio, há uma fase da zona de escape anterior à emergência que se estende até cerca de 110 DAE, com parte do enchimento de grãos acontecendo após o término da zona de escape. Na semeadura em 01 de junho, é maior o período de zona de escape desperdiçado anteriormente à emergência, com término do período de proteção natural logo após o paniculamento, evidenciando grande parte do enchimento de grãos fora da zona de proteção. Este cenário de aumento na temperatura apresenta possível necessidade de aplicação de fungicidas para garantia da produtividade e estrutura de grãos adequada à indústria (SILVA et al., 2015; PEREIRA et al., 2020).

Quando realizada semeadura em 15 de junho, que sinaliza o fim do período de recomendação, maior é a zona de escape desperdiçada anteriormente à emergência, com término da proteção anterior ao paniculamento. Todas as fases de paniculamento, fecundação e enchimento de grãos acontecem sem proteção por zona de escape aos patógenos, acarretando a necessidade de manejos com uso de fungicidas nessa fase. Em semeaduras tardias, de 01 de julho e 15 de julho, destaca-se que toda a fase anterior ao paniculamento está sem proteção pela temperatura, indicando que haverá grande pressão de inóculo e necessidade de mais de uma aplicação de fungicida para garantia da qualidade e produtividade de grãos (SILVA et al., 2015; FOLLMANN et al., 2016).

Os resultados de 2020 evidenciam, assim como nos anos anteriores, 2018 e 2019, que os cenários de semeadura de 15 de abril até 15 de maio, ou próximos a 01 de junho, têm apresentado grande garantia de zona de escape com proteção pela temperatura em períodos próximos à maturidade fisiológica, em que não há mais deposição de reservas pela planta. Destaca-se que não está sendo observado o efeito da geada, o que pode acarretar problemas se ocorrer de maneira intensa no desenvolvimento da aveia (NERBASS JUNIOR et al., 2010).

Buscando maior efetividade na definição da zona de escape às doenças foliares no cultivo de aveia na região noroeste do RS, foi realizado mais um ano de pesquisa, em 2021 (Figura 16), configurando quatro anos para análise.

Figura 16 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura no ano de 2021.



Fonte: autoria própria.

O ano de 2021 mostrou-se similar aos demais anos, em que a semeadura em 15 de abril obteve zona de escape desde a emergência até próximo à colheita de grãos. Na semeadura de 01 de maio, a emergência ocorreu dentro da zona de escape, com proteção natural muito próxima à maturidade fisiológica. Em 15 de maio, quando se inicia a recomendação de semeadura de aveia, verifica-se a ocorrência da zona de escape da emergência até cerca de 112 DAE, período próximo à maturidade de

grãos. Embora haja um período sem proteção, há possibilidades de cultivo de aveia sem aplicação de fungicidas.


Considerando o cenário de cultivo na região noroeste, onde é cultivada uma área relevante de aveia, a redução de aplicações de fungicida caracteriza uma grande redução no uso de agrotóxicos, que não serão direcionados ao ambiente, evitando a contaminação de rios, lagos ou outros compartimentos ambientais, além de reduzir a exposição de agricultores e da sociedade em geral a estes resíduos tóxicos (JOBIM et al., 2010; NERBASS JUNIOR et al., 2010; PEREIRA et al., 2020).

Na semeadura de 01 de junho, a zona de escape se estende da emergência até cerca de 7 dias após o paniculamento, com período de enchimento de grãos sem proteção pela temperatura. E no cenário de final de recomendação de semeadura, em 15 de junho, a zona de escape finaliza pouco antes do paniculamento, indicando que neste período, na fecundação e no enchimento de grãos não haverá proteção natural. Com maior pressão de inóculo de fungos nestas fases, possivelmente haja a necessidade de aplicações de fungicida para garantia da produtividade de grãos, o que pode comprometer a segurança alimentar dos produtos (SILVA et al., 2015; PEREIRA et al., 2020).

Após o término da recomendação, em situações de necessidade de atraso da semeadura, na data de 01 de julho e em um cenário mais extremo, de 15 de julho, o fim da zona de escape ocorre anterior ao paniculamento. Isto pode acarretar na forte pressão de inóculo e grande redução da produtividade de grãos, configurando cenários inadequados de cultivo, com uso significativo de fungicidas (BASSO et al., 2022).

Com base nos resultados médios dos anos agrícolas apresentados, foi definida a zona de escape às doenças foliares da aveia independente de ano agrícola, com o ciclo de desenvolvimento da aveia em cada época de semeadura considerada neste estudo (Figura 17).

Figura 17 – Dados meteorológicos, zona de escape às doenças fúngicas e o ciclo de desenvolvimento da aveia em cada época de semeadura independente de ano agrícola.



Fonte: autoria própria.

Na Figura 17, observando a semeadura em 15 de abril, anterior à recomendação para a região noroeste do RS, observa-se que a zona de escape inicia cerca de 16 dias após a emergência (DAE), estendendo-se após a colheita de grãos. Na semeadura de 01 de maio, também antes da recomendação, a partir da emergência das plântulas já há proteção natural pela temperatura, de modo que a zona de

escape se prolonga após a maturação fisiológica, período em que já há estabilidade no enchimento de grãos.

Na semeadura de 15 de maio, sinalizando o início do período de recomendação, a zona de escape se aproxima da maturação fisiológica, período em que não há mais deposição de reserva nos grãos, o que não indica necessidade de aplicação de fungicidas. Quando realizada a semeadura em 01 de junho, a zona de escape se estende até cerca de 100 DAE, com proteção até 15 dias após o paniculamento. Na semeadura de 15 de junho, que indica o fim do período de recomendação, uma parte significativa da zona de escape acontece anteriormente à emergência das plântulas, não podendo ser aproveitada durante o ciclo. A proteção natural pela temperatura se estende até cerca de 6 dias após o paniculamento, de modo que praticamente todo o período de enchimento de grãos não terá proteção, o que indica possível necessidade de uso de agrotóxicos fungicidas para controle das doenças foliares da aveia (BASSO et al., 2022).

Em situações de atraso, observando as semeaduras de 01 de julho e, em uma situação mais extrema, em 15 de julho, percebe-se que a zona de escape termina ainda antes do período de paniculamento. Isso indica grande possibilidade de forte pressão de inóculo durante os períodos de paniculamento, fecundação e enchimento de grãos, necessitando possivelmente de mais de uma aplicação de fungicida no controle das doenças.

As relações entre as condições meteorológicas e as doenças em plantas têm sido abordadas em diferentes estudos (GHINI, HAMADA, BETTIOL, 2008). Nancarrow et al. (2014) investigaram o impacto das temperaturas em uma doença viral na cultura do trigo. Bhardwaj, Banyal e Roy (2021) desenvolveram um modelo de regressão logística na avaliação do alto risco de oídio em aveia, utilizando dados climáticos e de doenças. A temperatura e a umidade relativa do ar possuem forte influência na ocorrência de doenças fúngicas na cultura da aveia e estudos têm sido desenvolvidos com enfoque nessas relações. Sánchez-Martín et al. (2017) estudaram o desempenho de cultivares de aveia sob condições mediterrâneas, incluindo a resistência à ferrugem da coroa, verificando o impacto das variáveis climáticas sobre as características agrônômicas e a adaptação de cultivares a fatores ambientais. Schöneberg et al. (2018) ressaltam que a previsão precoce dos níveis de micotoxinas, substâncias químicas tóxicas produzidas por fungos, é importante para os agricultores e a indústria de cereais para minimizar o risco de alimentos e rações contaminados. Os autores também estudaram os efeitos da temperatura e umidade sobre a ocorrência de doenças, analisando o período do ciclo em que a aveia é mais suscetível ao ataque dos patógenos.

Na Tabela 2, buscando efetividade da definição de zona de escape, com base nos dados da bioexperimentação em condições reais de cultivo, são apresentados os resultados da progressão das doenças entre os 60 e 120 DAE, por meio da área foliar necrosada, e os valores de produtividade de grãos, para as três cultivares nas épocas de semeadura.

Tabela 2 – Área foliar necrosada ao longo do ciclo e produtividade de grãos em cada época de semeadura, ano de cultivo e cultivar, na condição sem fungicida.

Época	AFN (%) / DAE					PG (kg ha ⁻¹)	AFN (%) / DAE					PG (kg ha ⁻¹)	AFN (%) / DAE					PG (kg ha ⁻¹)
	SMD	60	75	90	105		120	60	75	90	105		120	60	75	90	105	
	URS Corona						URS Taura						URS Guria					
	2018																	
15/04	0	0	0	22	59	917a	0	0	1	17	58	1128a	0	0	0	6	83	1539a
01/05	0	0	0	9	65	907a	0	0	2	6	53	991a	0	0	0	4	50	1578a
15/05	0	0	2	11	89	878a	0	1	2	11	78	984a	0	0	1	10	85	1244b
01/06	1	2	5	70	99	775b	1	1	5	55	99	965a	0	1	2	55	100	1125b
15/06	3	4	22	97	-	531c	2	3	49	97	-	640b	1	2	30	97	-	1034b
01/07	3	9	91	-	-	434c	2	17	91	-	-	579b	1	12	96	-	-	622c
15/07	4	51	100	-	-	130d	14	57	100	-	-	155c	6	73	100	-	-	108d
	2019																	
15/04	2	8	39	50	77	202c	3	9	49	72	96	200c	2	6	38	60	96	210c
01/05	1	3	6	40	85	1170a	2	3	6	39	82	1302a	1	1	2	35	77	1500a
15/05	2	3	5	47	96	969b	3	3	8	45	97	1100a	1	2	3	44	99	1510a
01/06	3	5	8	64	99	1376a	3	4	12	59	91	1126a	2	2	11	64	98	1562a
15/06	3	5	25	78	-	842b	3	5	26	75	-	716b	3	4	31	88	-	947b
01/07	4	8	80	-	-	254c	4	7	72	-	-	157c	4	13	91	-	-	376c
15/07	6	60	96	-	-	128c	4	59	86	-	-	101c	14	70	96	-	-	162c
	2020																	
15/04	0	0	2	7	45	1516b	0	1	2	4	51	1178c	0	1	1	14	87	1651a
01/05	1	1	2	7	45	1741a	0	1	2	8	51	1242c	1	1	3	8	61	1754a
15/05	1	1	3	8	76	1755a	2	2	3	8	55	1912a	1	2	3	14	73	1849a
01/06	2	2	3	44	97	1449b	2	2	5	25	97	1578b	2	3	4	24	98	1683a
15/06	2	3	16	94	-	1211c	2	3	19	99	-	1307c	3	4	18	94	-	1435b
01/07	2	14	88	-	-	631d	3	13	77	-	-	580d	3	14	90	-	-	639c
15/07	3	53	100	-	-	514d	5	64	100	-	-	411d	3	49	100	-	-	575c
	2021																	
15/04	0	0	1	6	22	1394a	0	0	0	6	37	2180a	0	0	1	7	29	1946a
01/05	1	2	3	6	24	1427a	1	1	3	6	39	1908a	0	0	2	8	34	1720a
15/05	1	2	3	7	32	1447a	1	2	5	8	42	1339b	1	1	2	11	38	1612a
01/06	2	2	4	7	77	1124b	1	2	9	28	88	1085c	1	2	3	14	76	1376b
15/06	3	4	5	54	-	508c	4	5	10	63	-	535d	1	2	5	62	-	674c
01/07	3	13	74	-	-	438c	5	12	69	-	-	453d	3	12	71	-	-	576c
15/07	4	45	82	-	-	297d	5	55	84	-	-	226e	4	45	90	-	-	257d
	2018 + 2019 + 2020 + 2021																	
15/04	0	2	11	21	51	1007b	1	3	13	25	60	1172b	1	2	10	22	74	1337b
01/05	1	1	3	15	55	1311a	1	1	3	15	56	1361a	1	1	2	14	55	1638a
15/05	1	2	3	18	73	1262a	1	2	4	18	68	1334a	1	1	2	20	74	1554a
01/06	2	3	5	46	93	1181a	2	3	8	42	94	1189b	1	2	5	39	93	1437b
15/06	3	4	17	81	-	773c	3	4	26	83	-	800c	2	3	21	85	-	1023c
01/07	3	11	83	-	-	439d	3	12	77	-	-	442d	3	13	87	-	-	553d
15/07	4	52	94	-	-	267e	7	59	93	-	-	223e	7	59	96	-	-	276e

-: ausência de dados devido ao término do ciclo de cultivo; Médias seguidas pela mesma letra na coluna são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott; DAE: dias após a emergência; SMD: semeadura; AFN: área foliar necrosada; PG: produtividade de grãos.

Na Tabela 2, em 2018 nas cultivares URS Corona, URS Taura e URS Guria, observa-se que a amplitude da zona de escape às doenças foliares ocorrida durante o ciclo, em semeaduras de 15 de

abril até 15 de maio, garantiu área foliar necrosada praticamente nula até os 90 DAE, período próximo ao paniculamento. A progressão de doenças torna-se mais efetiva, mas ainda reduzida, em torno de 105 DAE, quando há o período de enchimento de grãos, e é mais significativa próxima à maturação fisiológica aos 120 DAE, em que há estabilidade na deposição de reserva nos grãos. Estes fatores indicam que não haveria, na zona de escape estabelecida (Figura 13), necessidade de uso de fungicidas nas duas épocas que antecedem a recomendação e na época que marca o início do período recomendado de semeadura.

Por outro lado, na semeadura realizada em 01 de junho, época que também pertence à recomendação de semeadura da aveia, há forte incidência de área foliar necrosada no período de enchimento de grãos aos 105 DAE, com valor de 70% na URS Corona e de 55% na URS Taura e URS Guria, indicando possível necessidade no uso de fungicidas. A semeadura no fim do período de recomendação em 15 de junho e semeaduras mais tardias implicaram em colheitas mais precoces, principalmente em 01 de julho e 15 de julho, com necrose próxima a 100% aos 90 DAE, evidenciando a necessidade de aplicação de fungicidas nestas épocas.

Estes resultados vêm ao encontro das produtividades de grãos observadas. Na URS Corona, são obtidas as médias mais elevadas de 15 de abril a 15 de maio, na URS Taura de 15 de abril a 01 de junho e na URS Guria em 15 de abril e 01 de maio. A partir destas semeaduras, se percebe um comportamento decrescente nas médias de produtividade em cada cultivar.

No ano de 2019, analisando as três cultivares (Tabela 2), verifica-se que a progressão de doenças foi mais reduzida quando analisadas semeaduras de 01 de maio até 01 de junho, com maior incidência de necrose aos 120 DAE, próximo à maturidade fisiológica. A partir de 15 de junho há uma progressão mais efetiva da doença, de modo que em semeaduras mais tardias, após a recomendação de cultivo, há forte área foliar necrosada aos 90 DAE, com valores próximos a 100%, o que acarreta na necessidade de uso de fungicida. Na URS Corona, as maiores produtividades de grãos foram observadas nas semeaduras em 01 de maio e 01 de junho, enquanto nas cultivares URS Taura e URS Guria se destacam 01 de maio, 15 de maio e 01 de junho. Ressalta-se também a reduzida produtividade de grãos obtida na semeadura de 15 de abril nas três cultivares, em virtude de geada ocorrida no início do ciclo e no emborrachamento, o que comprometeu significativamente a produtividade. Deste modo, destaca-se que os altos índices de área foliar necrosada presentes nas três cultivares nesta data de semeadura não se deve ao ataque de patógenos fúngicos, mas sim à ocorrência de geada de forte intensidade, pois a semeadura em 15 de abril não permitiu às plantas de aveia adequada aclimação ao frio.

O dano pela geada ocorre quando há congelamento no interior das plantas, acarretando em danos celulares, podendo ocasionar a morte das plantas ou danos severos. Cardoso et al. (2021) destacam que os zoneamentos agrícolas de riscos climáticos, instrumentos de política agrícola para

fins de concessão de seguro e crédito rural, promovem a indicação de regiões e épocas de plantio baseada em riscos climáticos. Os autores ressaltam que o risco de geada é um dos mais importantes critérios dos zoneamentos, de modo que, em culturas estabelecidas nos meses mais frios do ano, como trigo, centeio, cevada, aveia, triticale e canola, considera-se o risco de ocorrência de geadas para indicar as épocas de semeadura nas diferentes regiões do Rio Grande do Sul. Roberti et al. (2013) em seu estudo relataram a morte de plântulas de aveia devido à geada, em eventos em que houve formação de geada com velocidade do vento muito baixa.

Além do dano da geada, mais severo, há também danos ao cultivo da aveia pelo resfriamento, que estão atrelados à temperatura basal. A temperatura basal da aveia é de 4°C e abaixo da mesma as plantas possuem desenvolvimento nulo ou muito reduzido (CASTRO; COSTA; FERRARI NETO, 2012). Guzzatti et al. (2015) indicam que menores taxas de acúmulo de biomassa para a aveia podem ser parcialmente atribuídas à ocorrência de baixas temperaturas observadas ao longo do cultivo, uma vez que ocorrem temperaturas abaixo da temperatura basal de desenvolvimento. Deste modo, evidencia-se a influência de temperaturas muito reduzidas no cultivo da aveia, interferindo negativamente no desenvolvimento das plantas (BORELLA et al., 2020).

Ainda na Tabela 2, no ano de 2020, para a cultivar URS Corona há uma adequada atuação da zona de escape, favorecendo o controle das doenças foliares até 90 DAE, considerando as semeaduras de 15 de abril até 01 de junho. Há destaque para as semeaduras de 15 de abril até 15 de maio que mantém esse controle até 105 DAE, de modo que a progressão que ocorre aos 120 DAE está próxima à maturidade fisiológica, não necessitando do uso de fungicidas. Os maiores valores de produtividade de grãos foram evidenciados nas semeaduras de 01 de maio e 15 de maio, seguidas de 15 de abril e 01 de junho. Na cultivar URS Taura também há um controle adequado sobre a progressão de doenças, de modo semelhante à cultivar URS Corona. A maior produtividade de grãos nesta cultivar acontece na semeadura de 15 de maio. Na análise da cultivar URS Guria, observa-se reduzida necrose foliar nas semeaduras de 15 de abril até 01 de junho, datas que também apresentaram os melhores resultados para a produtividade de grãos.

Por fim, em 2021 (Tabela 2), nas cultivares URS Corona e URS Guria, destaca-se que a progressão da doença foi reduzida de 15 de abril a 15 de maio, que também foram os períodos que apresentaram maior produtividade de grãos. Para a cultivar URS Taura, o mesmo comportamento foi observado para a área foliar necrosada, com destaque para as semeaduras de 15 de abril e 01 de maio, anteriores à recomendação, que evidenciaram as maiores médias de produtividade de grãos.

De modo geral, observando a análise com os efeitos de todos os anos agrícolas (Tabela 2), nas três cultivares, percebe-se que as semeaduras anteriores à recomendação, 15 de abril e 01 de maio, e o início da recomendação, em 15 de maio, apresentaram adequado controle às doenças fúngicas até 105 DAE, havendo também a possibilidade de considerar um controle satisfatório na semeadura de

01 de junho até 90 DAE. Esses resultados confirmam os apresentados para as zonas de escape apresentadas nas Figuras 13, 14, 15, 16 e 17, evidenciando as datas citadas como as épocas com maior produtividade de grãos, na ausência de uso de fungicida. No entanto, cabe ressaltar que a semeadura de 15 de abril pode trazer riscos à produtividade, devido à geada. As plantas iniciam o ciclo em condições de temperaturas mais elevadas e não possuem a capacidade de percepção celular sobre o frio, de modo que a drástica redução das temperaturas acarretam em maior sensibilidade nas plantas. Embora semeaduras em 01 de maio e 15 de maio também sejam precoces e haja a ocorrência de geadas, nestas épocas as plantas já possuem condições mais estáveis, com temperaturas amenas, configurando em períodos de aclimação para percepção celular, conferindo resistência a fatores de estresse por frio.

Deste modo, a análise dos anos agrícolas evidencia o potencial de semeaduras realizadas em 01 de maio e 15 de maio como intervalos mais propícios no controle de patógenos fúngicos pela zona de escape. Estas épocas demonstram tolerância ao frio e maior produtividade de grãos, na ausência de uso de agrotóxicos na cultura da aveia. Isso pode ser confirmado quando observados os resultados das três cultivares analisadas, URS Corona, URS Taura e URS Guria.

O estudo da época de semeadura se faz importante, visto sua influência sobre o desenvolvimento das plantas. Na cultura do trigo, Silva, E. R. et al. (2018) identificaram a melhor época de semeadura para a região Centro-Sul Mato-Grossense, avaliando o potencial de rendimento da cultura. Magnabosco e Amaral (2018) analisaram o comportamento de cultivares de trigo em diferentes épocas de semeadura, considerando a incidência de brusone, uma doença fúngica. No cultivo da soja, Toller et al. (2018) avaliaram cultivares em diferentes épocas de semeadura quanto à eficiência de uso de potássio para teor e rendimento de carboidratos, visando a produção de etanol na região centro-sul do Estado do Tocantins. Cunha et al. (2019), por sua vez, estudaram a influência da época de semeadura na severidade de doenças foliares e na produtividade do milho safrinha, na região norte do Estado do Paraná. Essas pesquisas evidenciam a relevância do estudo da época de semeadura em diversas culturas agrícolas, envolvendo variadas finalidades.

5.4. Conclusões

A determinação da zona de escape às doenças foliares, considerando a temperatura média do ar abaixo de 18°C, permite a avaliação do desempenho de diferentes épocas de semeadura da aveia na região noroeste do estado do Rio Grande do Sul. As semeaduras de 01 de maio e 15 de maio, mais precoces em relação à atual recomendação de semeadura para a região noroeste do RS, recebem destaque, pois evidenciam maior controle da necrose foliar pelo ataque de doenças até 105 DAE, com as maiores médias de produtividade de grãos.

6. AJUSTE DA ÉPOCA DE SEMEADURA DA AVEIA POR MODELOS DE REGRESSÃO E DE ADAPTABILIDADE E ESTABILIDADE NA AUSÊNCIA DE FUNGICIDA

6.1. Introdução

A modelagem matemática permite a descrição de processos, favorecendo a análise de dados e auxiliando na tomada de decisões. Devido à sua empregabilidade, a modelagem vem sendo muito utilizada no contexto agrícola, podendo descrever o efeito de manejos empregados no cultivo de plantas, como também, efeitos alheios ao controle do pesquisador, como os elementos meteorológicos (CARGNIN, SOUZA, FOGAÇA, 2008; ROSA et al., 2009; MEDEIROS et al., 2018).

As regressões polinomiais podem apresentar distintas vantagens, como a determinação da taxa de variação de uma variável em relação a outra e a otimização de manejos (MORAIS et al., 2008; MAROLLI et al., 2017). Os modelos de adaptabilidade e estabilidade, através da análise de parâmetros, permitem observar genótipos ou manejos que respondem favoravelmente a estímulos positivos ou negativos do ambiente (adaptabilidade) e que possuem comportamento estável, permitindo a previsibilidade (estabilidade) (MONTEIRO et al., 2015; BICALHO et al., 2018).

Uma cultura agrícola que vem recebendo destaque em pesquisas é a aveia. Este cereal possui múltiplos propósitos de uso, podendo ser utilizada na alimentação humana, trazendo benefícios como a redução do colesterol LDL (popularmente conhecido como colesterol ruim), redução do risco de doenças cardiovasculares, regulação do apetite e auxílio na flora intestinal (MA et al., 2017; LIU et al., 2018). Pode ser empregado também na alimentação animal, na forma de pastagem, ração, silagem e feno, além de ser utilizado na indústria farmacêutica e na produção de cosméticos (MOREIRA; MARTINS; WANNER, 2017; MALANCHEN et al., 2019).

Entretanto, o cultivo da aveia pode ser acometido por doenças foliares fúngicas, que prejudicam o desenvolvimento da planta, acarretando na redução da expressão da produtividade de grãos e afetando também a qualidade química e industrial. Os principais patógenos causadores destas doenças são a *Puccinia coronata* e a *Drechslera avenae*, causadores da ferrugem da folha e da helmintosporiose, respectivamente (NAZARENO et al., 2018; SILVA et al., 2020).

A aveia fica suscetível a estas doenças em condições meteorológicas favoráveis ao desenvolvimento de fungos, como o calor e a umidade. A ocorrência de umidade é bastante comum em períodos de frio, em que se cultiva a aveia, entretanto, pode haver momentos de elevação da temperatura do ar, que permitem o ataque dos patógenos. Sendo assim, uma alternativa para o controle destas doenças acontece com a aplicação de agrotóxicos fungicidas. Esse manejo faz-se necessário visto que as doenças podem trazer grandes prejuízos, entretanto, sua aplicação indiscriminada pode ocasionar a contaminação de grãos, trazendo riscos à saúde (JOBIM et al., 2010;

TEIXEIRA, 2019). O uso indiscriminado de agrotóxicos também pode contaminar o ambiente de cultivo, acarretando na poluição do solo e de lençóis freáticos (FONSECA et al., 2019).

Uma alternativa de controle das doenças foliares pode ser o ajuste da época de semeadura da aveia, na busca de uma zona de escape natural às condições meteorológicas que favorecem a ocorrência das doenças, reduzindo conseqüentemente a aplicação de fungicidas. Os modelos de regressão podem auxiliar na análise do comportamento de indicadores de incidência de doenças, como a área foliar necrosada, e de rendimento de grãos na cultura da aveia em função de distintas épocas de semeadura do cereal, na ausência de fungicida. A regressão quadrática propicia a indicação de um intervalo de semeadura ideal visando maximizar a produtividade de grãos e reduzir o ataque de doenças foliares fúngicas. Os parâmetros de adaptabilidade e estabilidade de Eberhart e Russel podem auxiliar na determinação de épocas de semeadura com respostas satisfatórias em relação à produtividade de grãos e à área foliar necrosada.

A modelagem matemática, por meio de modelos estatísticos, pode auxiliar na determinação de uma época de semeadura que favoreça um cultivo mais sustentável da aveia. Assim, o objetivo deste capítulo é analisar o comportamento da área foliar necrosada, decorrente do ataque de doenças fúngicas, e da produtividade de grãos de aveia, em função de distintas épocas de semeadura, na ausência de fungicida. Identificar também as épocas de semeadura com adaptabilidade às condições de ano agrícola, que possibilitem a redução da incidência de doenças foliares e o aumento da produtividade de grãos com estabilidade, também em um cenário sem uso de fungicida.

6.2. Materiais e métodos

No desenvolvimento deste capítulo, inicialmente foram analisados indicadores do ciclo de cultivo da aveia. As variáveis observadas foram as quantidades de dias da emergência ao paniculamento (DEP), de dias do paniculamento à colheita (DPC) e de dias da emergência à colheita (DEC). Todas as análises deste capítulo foram realizadas considerando a ausência do uso de fungicida.

As médias percentuais de área foliar necrosada foram organizadas por época e cultivar em cada ano de cultivo, observando sua evolução a partir dos 60 dias após a emergência (DAE), em períodos quinzenais, até 120 DAE. Na definição do melhor ponto de análise da necrose foliar, foi considerada a maior variabilidade da área foliar necrosada em relação às épocas de semeadura, por meio da observação da magnitude do desvio-padrão em cada ponto determinado do ciclo.

Após definido o ponto de análise da necrose, foi empregada ANOVA (não apresentado) na observação dos efeitos da época de semeadura sobre a área foliar necrosada e a produtividade de grãos, individualmente em cada ano e cultivar e também independente de cultivar. Na sequência, foi

empregado o modelo de Scott e Knott no agrupamento das médias dessas variáveis em cada cenário. A relação entre essas variáveis também foi verificada analisando o comportamento de ambas em função da época de semeadura, por meio de regressões quadráticas, considerando os resultados médios dos anos de cultivo. Na construção das regressões, a variável independente x foi relacionada ao dia de semeadura, de modo que x foi considerado como o número de dias a partir de 15 de abril. Com isso, tendo como base a máxima eficiência técnica, foi possível identificar a data de semeadura ótima e seus respectivos valores de área foliar necrosada e de produtividade de grãos.

As significâncias dos efeitos das épocas de semeadura, dos anos de cultivo e da interação destes fatores foram verificadas pela ANOVA (não apresentado). Após isso, a adaptabilidade e estabilidade das épocas de semeadura sobre a área foliar necrosada e a produtividade de grãos foram verificadas pelo modelo de Eberhart e Russel, com resultados para cada cultivar e independente de cultivar, considerando como índice ambiental o efeito de todos os anos agrícolas.

As descrições detalhadas das variáveis estudadas neste capítulo podem ser observadas no Capítulo 3. Os modelos utilizados, por sua vez, estão descritos no Capítulo 4 e foram empregados utilizando o software livre Genes. Em todas as análises estatísticas foi considerado nível de significância de 5%. Também foram empregados softwares do pacote Microsoft Office.

6.3. Resultados e discussão

Na Tabela 3 podem ser observados os indicadores do ciclo de desenvolvimento da aveia, em cada época de semeadura, cultivar e ano de cultivo, na ausência de fungicida.

Tabela 3 – Indicadores do ciclo de desenvolvimento de cultivares de aveia em diferentes épocas de semeadura nos anos agrícolas.

Cultivar	Variável	Épocas de Semeadura						
		15/04	01/05	15/05	01/06	15/06	01/07	15/07
2018								
URS Corona	DEP	80	86	92	85	79	75	71
	DPC	61	59	50	41	34	30	25
	DEC	141	144	142	127	113	105	96
URS Taura	DEP	78	87	92	84	81	74	71
	DPC	61	59	49	43	33	29	25
	DEC	139	145	141	127	114	103	96
URS Guria	DEP	79	88	92	85	80	76	71
	DPC	62	60	49	43	35	30	25
	DEC	141	148	141	128	115	106	96
2019								
URS Corona	DEP	77	90	91	86	80	78	75
	DPC	64	55	52	44	37	32	27
	DEC	141	146	144	130	116	110	101
URS Taura	DEP	75	90	92	88	80	79	76
	DPC	63	56	50	43	37	32	25
	DEC	139	147	142	131	118	111	101
URS Guria	DEP	76	90	92	88	80	80	75
	DPC	62	57	52	44	37	31	26
	DEC	138	146	144	132	117	111	101
2020								
URS Corona	DEP	80	90	93	88	81	71	64
	DPC	60	52	48	43	39	34	28
	DEC	141	142	141	131	119	105	92
URS Taura	DEP	80	90	93	86	81	71	65
	DPC	60	52	48	44	40	34	29
	DEC	139	143	141	131	121	104	93
URS Guria	DEP	79	90	93	86	81	70	65
	DPC	61	54	47	45	39	34	28
	DEC	140	144	140	131	120	105	93
2021								
URS Corona	DEP	79	88	91	81	78	71	68
	DPC	60	55	48	48	37	34	28
	DEC	139	144	140	129	115	106	96
URS Taura	DEP	79	88	91	81	79	72	68
	DPC	59	55	48	47	37	34	28
	DEC	138	143	140	128	116	106	96
URS Guria	DEP	79	88	93	81	78	73	67
	DPC	59	55	49	47	38	34	29
	DEC	139	143	142	128	116	107	96

DEP: dias da emergência ao paniculamento; DPC: dias do paniculamento à colheita; DEC: dias da emergência à colheita.

Observando a Tabela 3, percebe-se que independente do ano de cultivo, as cultivares URS Corona, URS Taura e URS Guria mostram similaridade de resultados nos períodos do ciclo. A quantidade de dias da emergência ao paniculamento (DEP) apresenta uma tendência de aumento, da

semeadura realizada em 15 de abril até 15 de maio, que marca o início do período de recomendação de semeadura da aveia na região noroeste do RS. Nas semeaduras de 15 de abril, os DEP ficam entre 75 e 80 dias, chegando a 93 dias em semeaduras realizadas em 15 de maio. Após a semeadura de 15 de maio, há um decréscimo nos DEP até a semeadura de 15 de julho, que apresenta valores entre 64 e 76 dias.

O fotoperíodo, intervalo em que há luz durante o dia, influencia no tempo de floração das plantas e, conseqüentemente, tem impacto sobre o paniculamento da aveia. Há culturas agrícolas que são de dias longos, ou seja, têm sua floração acelerada devido ao aumento do dia (VAZ, SANTOS, ZAIDAN, 2008). Pivetta (2019) destaca que a aveia é uma planta de dia longo, visto que as plantas são induzidas à ocorrência mais precoce do florescimento em função de maiores temperaturas e fotoperíodo. Führ (2014) constatou que plantas de aveia crescendo em condições de fotoperíodos longos e altas temperaturas, observadas em épocas de semeadura tardias, reduzem o número de dias ao florescimento e o peso médio de panículas, influenciando no rendimento final, o que vai ao encontro dos resultados obtidos nesta pesquisa.

Quando analisados os dias do paniculamento à colheita (DPC), percebe-se que há uma diminuição à medida que se adia a data de semeadura, com os maiores valores nas semeaduras de 15 de abril, variando de 59 a 64 dias, e os menores nas semeaduras de 15 de julho, variando de 25 a 29 dias. Em relação ao ciclo total, ou seja, os dias da emergência à colheita (DEC), percebe-se um leve aumento desta variável da semeadura de 15 de abril, com valores em torno de 140 dias, à semeadura de 01 de maio, com resultados próximos de 145 dias. A partir deste momento de semeadura, há uma tendência de redução nos DEC, apresentando na semeadura de 15 de junho, que sinaliza o fim do período de recomendação, resultados em torno de 117 dias e chegando a demonstrar na semeadura mais tardia, de 15 de julho, resultados próximos de 96 dias.

Destaca-se que a redução drástica do ciclo que ocorre em semeaduras tardias acarreta na redução de estatura e prejudica a planta na elaboração de componentes ligados à produtividade (FÜHR, 2014). Desse modo, é importante ressaltar que embora o atraso na semeadura proporcione maior pressão de inóculo na fase de paniculamento e enchimento de grãos, a condição estabelecida de atraso já acarreta em problemas relacionados aos componentes de produtividade, principalmente em semeaduras após o período de recomendação.

A época de semeadura pode influenciar no ciclo de cultivo e nas características de plantas de diversas culturas agrícolas, cultivadas tanto em períodos frios, como em períodos quentes. Ludwig et al. (2010) avaliaram o ciclo de cultivares de soja, a altura de plantas, dentre outras variáveis e verificaram alterações nestes caracteres em razão de modificações na época de semeadura. Ferreira et al. (2015) concluíram que a semeadura tardia do algodoeiro reduziu a altura de plantas, número de capulhos por área e produtividade de fibra. Rosa et al. (2020) observaram que atrasar a época de

semeadura de híbridos de canola reduziu o ciclo e seus subperíodos, como emergência ao início do florescimento, duração do florescimento e duração da maturação.

Na Tabela 4 há as médias de área foliar necrosada obtidas em cada época de semeadura, cultivar e ano de cultivo, dos 60 DAE até os 120 DAE. Também foram calculados os valores médios e os desvios-padrão pra cada ponto, em função das épocas de semeadura.

Tabela 4 – Médias de área foliar necrosada sem aplicação de fungicida ao longo do ciclo de cultivo da aveia em cada época de semeadura, cultivar e ano de cultivo.

Época Semeadura	AFN (%) URS CORONA/ DAE					AFN (%) URS TAURA/ DAE					AFN (%) URS GURIA/ DAE				
	60	75	90	105	120	60	75	90	105	120	60	75	90	105	120
2018															
15/04	0	0	0	22	59	0	0	1	17	58	0	0	0	6	83
01/05	0	0	0	9	65	0	0	2	6	53	0	0	0	4	50
15/05	0	0	2	11	89	0	1	2	11	78	0	0	1	10	85
01/06	1	2	5	70	99	1	1	5	55	99	0	1	2	55	100
15/06	3	4	22	97	-	2	3	49	97	-	1	2	30	97	-
01/07	3	9	91	-	-	2	17	91	-	-	1	12	96	-	-
15/07	4	51	100	-	-	14	57	100	-	-	6	73	100	-	-
Média	2	10	32	42	78	3	11	36	37	72	1	13	33	34	79
DP	2	19	44	39	19	5	21	44	39	21	2	27	46	41	21
2019															
15/04	2	8	39	50	77	3	9	49	72	96	2	6	38	60	96
01/05	1	3	6	40	85	2	3	6	39	82	1	1	2	35	77
15/05	2	3	5	47	96	3	3	8	45	97	1	2	3	44	99
01/06	3	5	8	64	99	3	4	12	59	91	2	2	11	64	98
15/06	3	5	25	78	-	3	5	26	75	-	3	4	31	88	-
01/07	4	8	80	-	-	4	7	72	-	-	4	13	91	-	-
15/07	6	60	96	-	-	4	59	86	-	-	14	70	96	-	-
Média	3	13	37	56	89	3	13	37	58	91	4	14	39	58	93
DP	2	21	37	15	10	1	20	33	16	7	5	25	40	20	11
2020															
15/04	0	0	2	7	45	0	1	2	4	51	0	1	1	14	87
01/05	1	1	2	7	45	0	1	2	8	51	1	1	3	8	61
15/05	1	1	3	8	76	2	2	3	8	55	1	2	3	14	73
01/06	2	2	3	44	97	2	2	5	25	97	2	3	4	24	98
15/06	2	3	16	94	-	2	3	19	99	-	3	4	18	94	-
01/07	2	14	88	-	-	3	13	77	-	-	3	14	90	-	-
15/07	3	53	100	-	-	5	64	100	-	-	3	49	100	-	-
Média	2	11	30	32	66	2	12	30	29	63	2	10	31	31	80
DP	1	19	44	38	25	1	23	41	40	22	1	18	44	36	16
2021															
15/04	0	0	1	6	22	0	0	0	6	37	0	0	1	7	29
01/05	1	2	3	6	24	1	1	3	6	39	0	0	2	8	34
15/05	1	2	3	7	32	1	2	5	8	42	1	1	2	11	38
01/06	2	2	4	7	77	1	2	9	28	88	1	2	3	14	76
15/06	3	4	5	54	-	4	5	10	63	-	1	2	5	62	-
01/07	3	13	74	-	-	5	12	69	-	-	3	12	71	-	-
15/07	4	45	82	-	-	5	55	84	-	-	4	45	90	-	-
Média	2	10	25	16	39	2	11	26	22	52	2	9	25	20	44
DP	1	16	37	21	26	2	20	35	25	24	2	16	39	23	22

-: ausência de dados devido ao término do ciclo de cultivo; AFN: área foliar necrosada; DAE: dias após a emergência; DP: desvio-padrão.

Analisando a Tabela 4, percebe-se que as três cultivares analisadas, URS Corona, URS Taura e URS Guria, demonstram comportamentos similares para a progressão da área foliar necrosada nas épocas de semeadura realizadas e anos de cultivo. Em 2018, as cultivares apresentaram valores

reduzidos de área foliar necrosada até 90 DAE, nas sementeiras de 15 de abril até 01 de junho. A progressão começa a crescer aos 105 DAE, mas ainda com valores reduzidos nas sementeiras de 15 de abril a 15 de maio, apresentando resultados relevantes no controle natural de doenças pela temperatura do ar. Por outro lado, considerando a área foliar necrosada aos 120 DAE, há dificuldade de uma conclusão mais efetiva em razão da senescência da planta que pode ser confundida com necrose.

Em 2019, valores mais expressivos de necrose acontecem na sementeira de 15 de abril, em comparação a esta mesma data de sementeira nos outros anos de cultivo, de modo que esses valores se devem principalmente ao dano ocasionado pela ocorrência de geada de forte intensidade no emborrachamento, conforme descrito no Capítulo 5. Sementeiras de 01 de maio até 01 de junho mantêm médias baixas de necrose até 90 DAE, evidenciando progresso de doença a partir deste ponto. No ano de 2020, percebe-se um controle satisfatório da área foliar necrosada até 105 DAE, nas sementeiras de 15 de abril até 15 de maio, cenário que já contempla a fase de enchimento de grãos. Há controle satisfatório também na sementeira de 01 de junho até 90 DAE. Em 2021, as menores médias acontecem nas sementeiras de 15 de abril até 15 de junho até 90 DAE, com aumento moderado da progressão aos 105 DAE na sementeira até 01 de junho e crescimento mais significativo neste ponto considerando sementeira em 15 de junho.

É possível observar que a sementeira de 15 de junho, embora ainda pertença ao período de recomendação, mostra relevante progressão de doenças durante o enchimento de grãos na maioria dos cenários apresentados. Os resultados ainda indicam que sementeiras mais antecipadas, de 01 de maio até 01 de junho, tendem a demonstrar maior controle sobre doenças devido à zona de escape, inclusive mostrando que há uma tendência de recomendação deste período para a sementeira da aveia na região noroeste do RS.

Ainda na Tabela 4, destaca-se que a variabilidade da área foliar necrosada em relação à época de sementeira, nas três cultivares e quatro anos agrícolas do estudo, foi determinada pelos valores de desvio-padrão obtidos em cada cenário. Analisando estes resultados, percebe-se que o ponto de 90 DAE evidencia o maior desvio-padrão em todos os casos, demonstrando que este é o momento mais oportuno de análise da necrose foliar, a fim de avaliar as épocas de sementeira.

Assim, na Tabela 5 há as médias de área foliar necrosada aos 90 DAE, juntamente às médias de produtividade de grãos, pra cada cultivar e também independente das cultivares, em cada época de sementeira e ano de cultivo. Além disso, é apresentada para cada variável a análise de agrupamento de médias pelo modelo de Scott e Knott em cada cenário.

Tabela 5 – Médias da área foliar necrosada e da produtividade de grãos sem fungicida por época de semeadura, ano de cultivo, cultivar e independente de cultivar de aveia.

Época Semeadura	AFN (%) (90 DAE)/ Ano de cultivo					PG (kg ha ⁻¹)/ Ano de cultivo				
	2018	2019	2020	2021	Média	2018	2019	2020	2021	Média
URS Corona										
15/04	0c	39b	2c	1b	11	917a	202c	1516b	1394a	1008
01/05	0c	6c	2c	3b	3	907a	1170a	1741a	1427a	1311
15/05	2c	5c	3c	3b	3	878a	969b	1755a	1447a	1262
01/06	5c	8c	3c	4b	5	775b	1376a	1449b	1124b	1181
15/06	22b	25b	16b	5b	17	531c	842b	1211c	508c	773
01/07	91a	80a	88a	74a	83	434c	254c	631d	438c	439
15/07	100a	96a	100a	82a	94	130d	128c	514d	297d	267
URS Taura										
15/04	1c	49b	2d	0c	13	1128a	200c	1178c	2180a	1172
01/05	2c	6d	2d	3c	3	991a	1302a	1242c	1908a	1361
15/05	2c	8d	3d	5c	4	984a	1100a	1912a	1339b	1334
01/06	5c	12d	5d	9c	8	965a	1126a	1578b	1085c	1188
15/06	49b	26c	19c	10c	26	640b	716b	1307c	535d	800
01/07	91a	72a	77b	69b	77	579b	157c	580d	453d	442
15/07	100a	86a	100a	84a	93	155c	101c	411d	226e	223
URS Guria										
15/04	0c	38b	1c	1c	10	1539a	210c	1651a	1946a	1336
01/05	0c	2c	3c	2c	2	1578a	1500a	1754a	1720a	1638
15/05	1c	3c	3c	2c	2	1244b	1510a	1849a	1612a	1554
01/06	2c	11c	4c	3c	5	1125b	1562a	1683a	1376b	1437
15/06	30b	31b	18b	5c	21	1034b	947b	1435b	674c	1022
01/07	96a	91a	90a	71b	87	622c	376c	639c	576c	553
15/07	100a	96a	100a	90a	96	108d	162c	575c	257d	276
URS Corona + URS Taura + URS Guria										
15/04	0c	42b	2d	1b	11	1195a	204c	1448c	1840a	1172
01/05	1c	5c	2d	3b	3	1159a	1324a	1579b	1685a	1437
15/05	2c	5c	3d	3b	3	1035b	1193a	1839a	1466b	1383
01/06	4c	10c	4d	5b	6	955b	1355a	1570b	1195c	1269
15/06	34b	27b	18c	7b	21	735c	835b	1318c	572d	865
01/07	93a	81a	85b	71a	83	545d	262c	617d	489d	478
15/07	100a	93a	100a	85a	95	131e	130c	500d	260e	255

Médias seguidas pela mesma letra na coluna são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott; AFN: área foliar necrosada; PG: produtividade de grãos; DAE: dias após a emergência.

Observando a Tabela 5, percebe-se que as cultivares URS Corona, URS Taura e URS Guria, juntamente à análise concomitante das cultivares, apresentaram as menores médias de área foliar necrosada aos 90 DAE nas semeaduras realizadas de 15 de abril até 01 de junho nos quatro anos de cultivo. No entanto, nas semeaduras de 15 de abril em 2019, foram observados valores de necrose foliar com maior magnitude em decorrência de geadas que acometeram o cultivo. Deste modo, os valores de área foliar necrosada neste cenário se devem a fatores abióticos, ligados à condição meteorológica e não à ação de doenças foliares (NERBASS JUNIOR et al, 2010). Percebe-se também que, de maneira geral, valores intermediários de necrose foram observados nas semeaduras em 15 de junho, data que representa o fim do período de recomendação de semeadura da aveia. Por fim, as

maiores médias de área foliar necrosada ocorreram nas semeaduras mais tardias, de 01 de julho e 15 de julho.

A fim de corroborar os resultados de necrose foliar com os dados de produtividade de grãos, ainda na Tabela 5, estão apresentados os resultados de produtividade nos diferentes cenários. Analisando a cultivar URS Corona, nos anos de 2018 e 2021, os maiores valores ocorrem nas semeaduras de 15 de abril até 15 de maio, com segundo maior valor na semeadura de 01 de junho. No ano de 2019, os valores mais expressivos de produtividade ocorrem nas semeaduras realizadas em 01 de maio e 01 de junho, seguidas das semeaduras de 15 de maio e 15 de junho. Neste período, geadas intensas acometeram o desempenho desta cultivar e também das cultivares URS Taura e URS Guria na semeadura de 15 de abril, afetando diretamente a produtividade. Ainda sobre a URS Corona, em 2020 as maiores médias de produtividade acontecem em 01 de maio e 15 de maio, seguidas das médias obtidas em 15 de abril e 01 de junho. Destaca-se que, de modo geral, a média absoluta considerando os anos agrícolas registra os valores mais elevados de produtividade para esta cultivar nas semeaduras de 01 de maio e 15 de maio.

Observando os resultados da cultivar URS Taura em 2018, as melhores médias foram obtidas nas semeaduras de 15 de abril até 01 de junho. Em 2019, os valores mais expressivos ocorreram nas semeaduras de 01 de maio a 01 de junho. Em 2020, a semeadura de 15 de maio apresentou média superior. E, por fim, em 2021, as maiores médias de produtividade ocorreram em semeaduras mais precoces, anteriores ao período de recomendação, em 15 de abril e 01 de maio. Na análise das médias absolutas, calculadas a partir dos resultados dos anos agrícolas, percebe-se os maiores valores nas semeaduras de 01 de maio e 15 de maio.

Na cultivar URS Guria, em 2018, as produtividades de grãos mais elevadas ocorreram nas semeaduras precoces de 15 de abril e 01 de maio, seguidos dos valores obtidos nas semeaduras de 15 de maio até 15 de junho. Em 2019, as maiores médias são observadas nas semeaduras de 01 de maio até 01 de junho. Em 2020, os valores mais elevados ocorrem nas semeaduras de 15 de abril até 01 de junho. E no ano de 2021, valores mais expressivos de produtividade são observados de 15 de abril a 15 de maio, seguidos da média obtida na semeadura de 01 de junho. Observando as médias absolutas em função dos anos agrícolas, também se destacam as semeaduras realizadas em 01 de maio e 15 de maio.

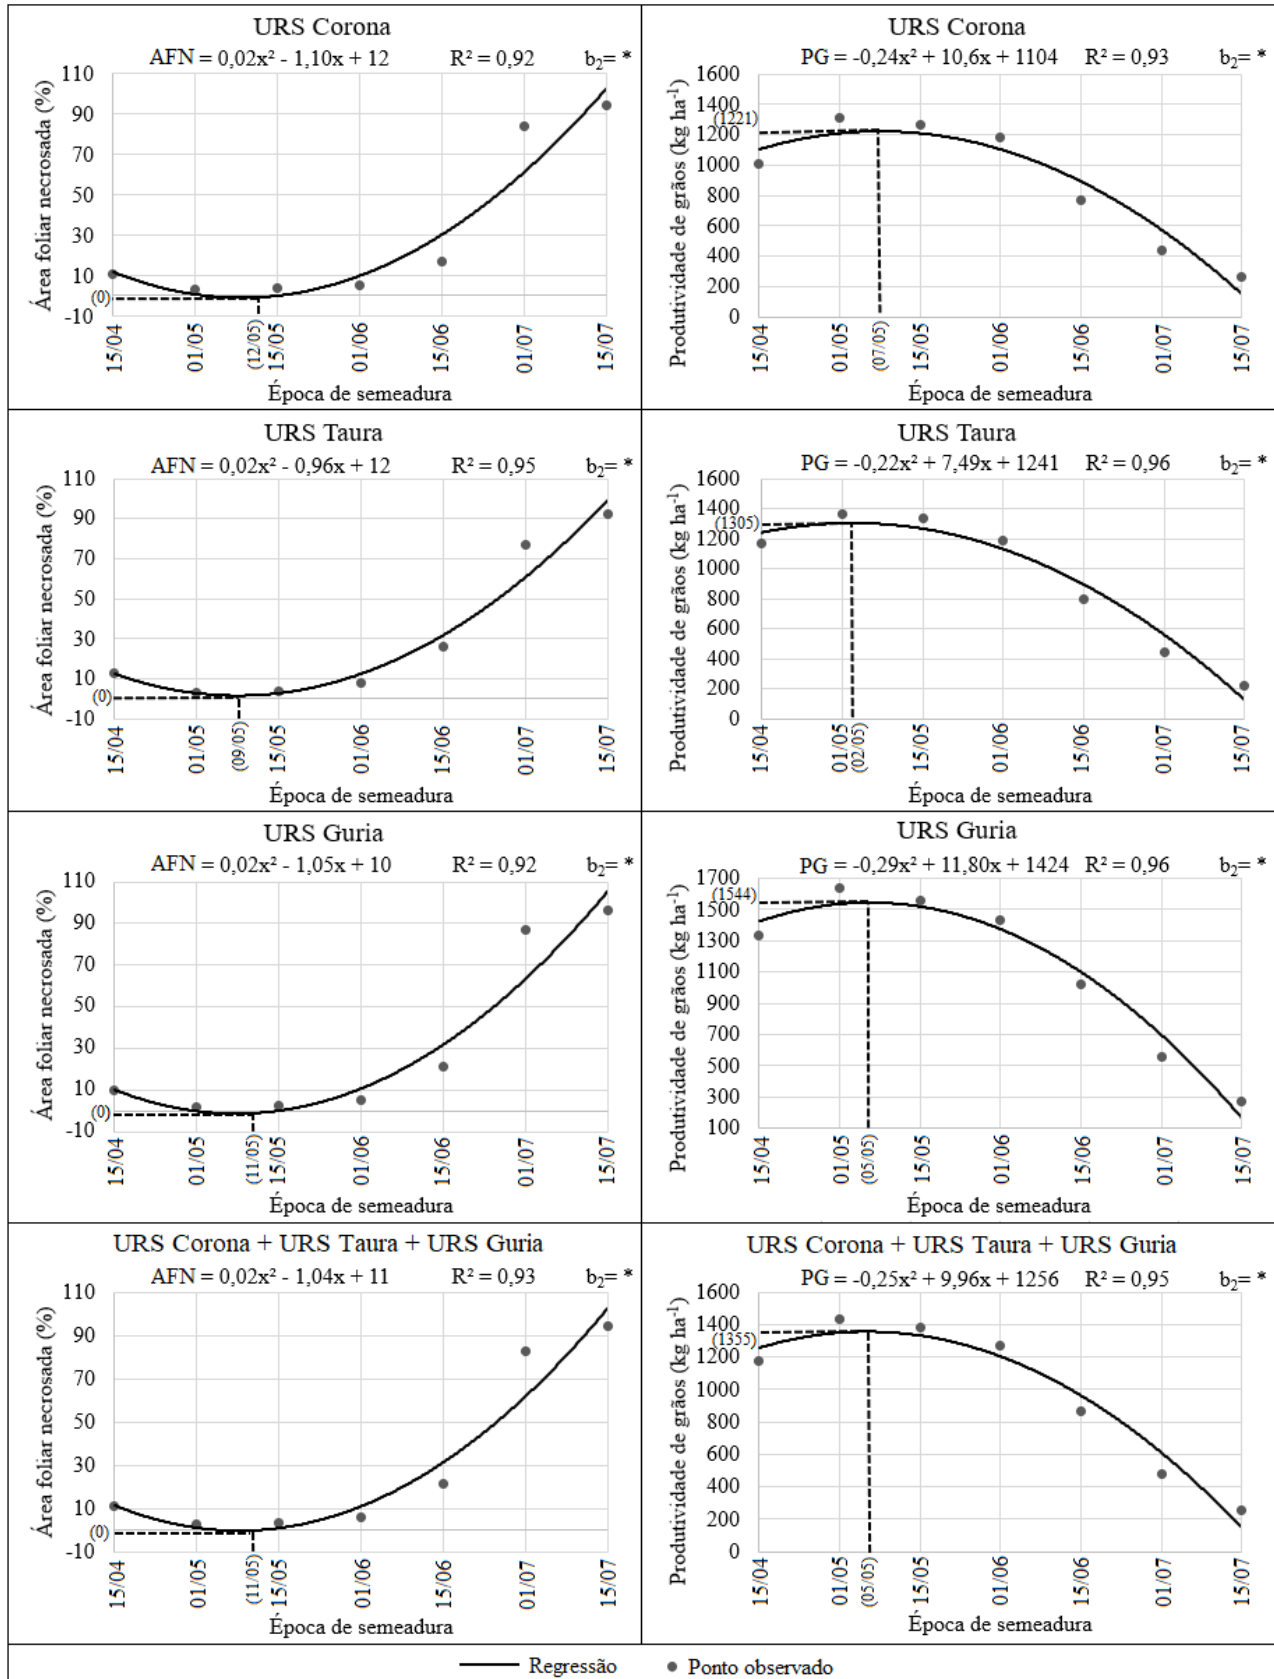
Ainda na Tabela 5, na análise independente de cultivar, observando as datas de semeadura, destaca-se a reduzida necrose foliar nas semeaduras precoces de 15 de abril e 01 de maio, anteriores ao período de recomendação de semeadura na região noroeste do RS, e nas semeaduras pertencentes à recomendação, nas datas de 15 de maio e 01 de junho. Em 2019, entretanto, houve elevado valor de necrose foliar na semeadura de 15 de abril, porém não em virtude de doenças foliares, mas da ocorrência de geada, conforme relatado no Capítulo 5. Os valores intermediários de necrose foliar

ocorreram, de modo geral, nas semeaduras realizadas na data de 15 de junho, sendo que o ano de 2021 demonstrou maior controle natural, com necrose ainda reduzida na semeadura nesta data. Os valores mais significativos de área foliar necrosada acontecem em semeaduras tardias, após o período de recomendação, em 01 de julho e 15 de julho.

Observando as médias de produtividade de grãos, em 2018 há destaque para as semeaduras de 15 de abril e 01 de maio. Em 2019, as maiores médias ocorrem nas semeaduras de 01 de maio até 01 de junho. Em 2020 houve destaque para a semeadura de 15 de maio e em 2021 nas semeaduras de 15 de abril e 01 de maio. Considerando os resultados médios absolutos de produtividade dos quatro anos agrícolas, em cada época de semeadura, percebe-se que semeaduras mais precoces evidenciam melhor desempenho, destacando 01 de maio e 15 de maio.

Este comportamento pode ser melhor observado quando analisados os gráficos na Figura 18, onde há o comportamento da área foliar necrosada aos 90 DAE e da produtividade de grãos em função da data de semeadura, por cultivar e independente das cultivares, considerando os efeitos dos quatro anos agrícolas do estudo concomitantemente.

Figura 18 - Comportamento da área foliar necrosada e da produtividade de grãos sem fungicida em função da época de semeadura, independente de ano de cultivo.



x: variável independente em dias, com x=0 em 15 de abril; AFN: área foliar necrosada aos 90 dias após a emergência; PG: produtividade de grãos; DAE: dias após a emergência; R²: coeficiente de determinação; b₂: coeficiente do termo de maior grau da regressão; *: significativo a 5% de probabilidade de erro.

Fonte: autoria própria.

Observando a Figura 18, percebe-se que em todos os cenários há significância do coeficiente do termo de maior grau da regressão (b_2) e valores satisfatórios de R^2 . Para a cultivar URS Corona, observando o comportamento da área foliar necrosada aos 90 DAE em função da época de semeadura, percebe-se que o menor valor de necrose aconteceria em uma semeadura realizada no dia 12 de maio. No entanto, analisando o gráfico percebe-se que a necrose ainda se mantém reduzida no período entre 01 de maio e 15 de maio. Para as cultivares URS Taura e URS Guria, os menores valores de área foliar necrosada ocorreriam em semeaduras realizadas em 09 de maio e 11 de maio, respectivamente, porém também evidenciam resultados satisfatórios com semeaduras no intervalo de 01 de maio a 15 de maio. Na análise da produtividade de grãos, resultados similares são obtidos. As cultivares URS Corona, URS Taura e URS Guria evidenciam os melhores resultados para a produtividade, respectivamente, nas datas de semeadura de 07 de maio, 02 de maio e 05 de maio, mas mantendo valores elevados em todo período de semeadura compreendido entre 01 de maio e 15 de maio.

Confirmando os resultados individuais obtidos nas três cultivares, na análise independente de cultivar também se observa valores reduzidos de necrose foliar aos 90 DAE no intervalo de semeadura de 01 de maio até 15 de maio, de modo que o menor valor de área foliar necrosada estimado pela regressão ocorre em semeadura no dia 11 de maio. Na análise da produtividade de grãos, valores mais satisfatórios também ocorrem no mesmo intervalo, sendo que o ponto máximo da produtividade é observado pela regressão na data de semeadura de 05 de maio. Destaca-se ainda que todos os pontos de mínimo observados para a área foliar necrosada aos 90 DAE observados na Figura 18, bem como, todos os valores de máximo obtidos para a produtividade de grãos, acontecem no intervalo de 01 de maio a 15 de maio, que compreendem um período anterior à recomendação de semeadura da aveia para a região noroeste do RS.

As regressões quadráticas possuem ampla empregabilidade em estudos agrícolas, na descrição do comportamento de variáveis e na otimização de manejos, nos mais diversos tipos de plantas, desde cereais até frutíferas. Morais et al. (2008) aplicaram modelos de regressão para avaliar a resposta de plantas de melancia cultivadas sob diferentes níveis de água e de nitrogênio, maximizando a produtividade com otimização do uso de nitrogênio e da lâmina de água. Na cultura do milho, Souza et al. (2018) utilizaram análise de regressão para investigar a resposta das plantas, em segunda safra, à adubação fosfatada, de modo que a maioria das variáveis estudadas apresentaram comportamento quadrático e foi possível otimizar a adubação com maximização da produtividade. Rosa et al. (2021b) otimizaram o aproveitamento de nitrogênio pela aveia à maior produtividade de grãos e de indústria por modelos de regressão quadrática que dimensionaram a máxima eficiência técnica e econômica do manejo. Além disso, estimaram parâmetros de estabilidade pelo modelo de Eberhart e Russel, na obtenção de resultados mais robustos.

Na Tabela 6, buscando efetividade na compreensão do desempenho das cultivares de aveia diante das distintas épocas de semeadura com ausência de uso de fungicida durante o cultivo, são apresentados os resultados do modelo de agrupamento de médias de Scott e Knott e do modelo de adaptabilidade e estabilidade de Eberhart e Russel. São avaliados os resultados de área foliar necrosada aos 90 DAE e de produtividade de grãos, considerando como índice ambiental o conjunto dos anos agrícolas.

Tabela 6 - Adaptabilidade e estabilidade das épocas de semeadura sobre a área foliar necrosada e a produtividade de grãos, sem fungicida, em cada cultivar e independente de cultivar.

Época Semeadura	Área foliar necrosada (%) (90 DAE)				Produtividade de grãos (kg ha ⁻¹)			
	b ₀	b ₁	σ ²	R ² (%)	b ₀	b ₁	σ ²	R ² (%)
URS Corona								
15/04	11c	2,99*	199,3*	83	1008b	1,65*	212470*	79
01/05	3d	0,23*	3,7	70	1311a	1,25	5370	94
15/05	3d	0,13*	-0,1	75	1262a	1,47*	1242	97
01/06	5d	0,31*	-0,1	77	1181a	0,68*	80193*	78
15/06	17c	1,67*	9,4*	90	773c	0,83	77469*	79
01/07	83b	0,53*	74,2*	72	439d	0,46*	5195	89
15/07	94a	1,13	55,9*	76	267e	0,66*	-5465	99
URS Taura								
15/04	13d	2,90*	510,2*	81	1172b	2,43*	447502*	74
01/05	3e	0,17*	0,3	73	1361a	0,77	166665*	73
15/05	4e	0,05*	6,8	70	1334a	1,42*	66850*	71
01/06	8e	0,12*	11,9	73	1188b	0,71	56034*	71
15/06	26c	2,45*	168,5*	89	800c	0,69	130500*	84
01/07	77b	0,94	99,4*	86	442d	0,49*	30589*	76
15/07	93a	0,37*	101,2*	75	223e	0,49*	-1571	89
URS Guria								
15/04	10d	2,60*	183,2*	84	1336b	2,81*	398447*	74
01/05	2e	-0,01*	-2,2	70	1638a	0,56	-8674	91
15/05	2e	0,01*	-2,2	71	1554a	0,92	31847*	75
01/06	5e	0,54*	6,5	89	1437b	0,47	64594*	75
15/06	21c	1,96*	31,8*	94	1022c	0,85	94705*	79
01/07	87b	1,49*	66,3*	81	553d	0,46	-1760	79
15/07	96a	0,40*	20,6*	75	276e	0,93	1931	91
URS Corona + URS Taura + URS Guria								
15/04	11d	2,97*	265,1*	88	1172c	2,13*	349988*	72
01/05	3e	0,13*	0,6	69	1437a	0,80	28733*	82
15/05	3e	0,07*	0,8	76	1383a	1,42*	13961*	90
01/06	6e	0,34*	5,1	70	1269b	0,67*	60429*	76
15/06	21c	1,92*	56,7*	72	865d	0,79	99217*	73
01/07	83b	0,96	76,5*	83	478e	0,47*	12771*	73
15/07	95a	0,61*	53,3*	71	255f	0,71	-625	93

Modelo de Eberhart e Russel, considerando os anos agrícolas no índice ambiental. Médias seguidas pela mesma letra na coluna são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott; DAE: dias após a emergência; b₀: média geral; b₁: coeficiente de regressão linear; σ²: desvios da regressão; R²: coeficiente de determinação; *: significativo a 5% de probabilidade de erro.

Na análise da cultivar URS Corona (Tabela 6), percebe-se as menores médias de área foliar necrosada nas semeaduras realizadas de 01 de maio até 01 de junho, com adaptabilidade a ambientes desfavoráveis e estabilidade. Estas datas de semeadura também demonstram os maiores valores de produtividades de grãos, de modo que a época de 01 de maio possui adaptabilidade ampla e estabilidade, a época de 15 de maio possui adaptabilidade a ambientes favoráveis e também é estável e a época de 01 de junho possui adaptabilidade a ambientes desfavoráveis, porém não é estável.

Observando os resultados para a cultivar URS Taura, novamente as semeaduras de 01 de maio até 01 de junho demonstram as menores médias de área foliar necrosada, com adaptabilidade a ambiente desfavorável e estabilidade. Na análise da produtividade de grãos, as maiores médias foram observadas pelas semeaduras em 01 de maio e 15 de maio, porém com instabilidade. A data de 01 de maio apresentou adaptabilidade ampla, enquanto 15 de maio demonstrou adaptabilidade a ambientes favoráveis.

De modo análogo às cultivares anteriores, na cultivar URS Guria, as semeaduras de 01 de maio até 01 de junho demonstraram os menores valores de área foliar necrosada, com adaptabilidade a ambientes desfavoráveis e estabilidade. Quanto à produtividade de grãos, as semeaduras de 01 de maio e 15 de maio evidenciaram as maiores médias, com adaptabilidade geral, de modo que a semeadura em 01 de maio foi estável, enquanto a época de 15 de maio não apresentou estabilidade.

Verifica-se que as semeaduras de 01 de maio e 15 de maio demonstram os resultados mais satisfatórios de produtividade de grãos e área foliar necrosada nas cultivares analisadas, de modo que a semeadura de 01 de maio apresenta adaptabilidade geral em todos os cenários quando avaliada a produtividade, com maior tendência de estabilidade. Ainda, na análise independente das cultivares, as menores médias de área foliar necrosada aconteceram nas semeaduras de 01 de maio até 01 de junho, com adaptabilidade a ambientes desfavoráveis e estabilidade. Analisando a produtividade de grãos, 01 de maio e 15 de maio evidenciaram os maiores valores, 01 de maio com adaptabilidade ampla e 15 de maio com adaptabilidade a ambiente favorável, porém ambas não apresentaram estabilidade.

Na agricultura, diversas pesquisas fazem uso de modelos de adaptabilidade e estabilidade no estudo de cultivares ou de manejos (CARGNIN, SOUZA, FOGAÇA, 2008; ROCHA et al., 2010; OLIVEIRA, FREITAS, JESUS, 2014; LIMA et al., 2017; SZARESKI et al., 2018). Krüger et al. (2016) identificaram o arranjo de plantas em híbridos de canola que possibilitava maior produtividade de grãos com adaptabilidade e estabilidade. Matias et al. (2017) analisaram a adaptabilidade e estabilidade de cultivares de pessegueiro e nectarineira sob condições de clima subtropical. Sowmya et al. (2018) empregaram o modelo de Eberhart e Russel na análise da estabilidade do rendimento de grãos de híbridos de milho em diferentes ambientes.

Os modelos de adaptabilidade e estabilidade também podem ser auxiliados por testes de agrupamento de médias, com possibilidade de serem empregados também no estudo de épocas de semeadura de culturas agrícolas variadas. Marques et al. (2011) empregaram modelos de adaptabilidade e estabilidade na avaliação de cultivares de soja em diferentes épocas de semeadura em Uberlândia-MG. Lima et al. (2017) analisaram a adaptabilidade e estabilidade de híbridos de canola, em função de diferentes épocas de semeadura, utilizando também o modelo de Scott e Knott na análise das médias. Santos et al. (2018) avaliaram a interação de genótipos de milho com o ambiente, observando o teor de óleo nos grãos, em função de doses de nitrogênio e de épocas de semeadura, identificando um genótipo ideal pelo modelo de Eberhart e Russel.

6.4. Conclusões

Observando o comportamento da área foliar necrosada, suas menores médias, bem como, as maiores médias de produtividade de grãos de aveia acontecem em semeaduras no intervalo de 01 de maio a 15 de maio, na ausência de fungicida. As semeaduras realizadas de 01 de maio até 01 de junho demonstram resultados vantajosos no cultivo de aveia, com minimização da atuação de doenças foliares, com estabilidade. Quanto à produtividade, há destaque para as semeaduras de 01 de maio e 15 de maio, que evidenciam as maiores produtividades de grãos, com resultados satisfatórios de adaptabilidade e estabilidade diante das condições de ano agrícola, dando subsídios para indicar que este período, anterior à atual recomendação, é a amplitude ótima de semeadura da aveia na região noroeste do RS.

7. AJUSTE DA ÉPOCA DE SEMEADURA DA AVEIA POR MODELOS DE ADAPTABILIDADE E ESTABILIDADE BASEADOS EM REGRESSÃO LINEAR E BISSEGMENTADA NA AUSÊNCIA E PRESENÇA DE FUNGICIDA

7.1. Introdução

A modelagem matemática, por meio de técnicas e modelos estatísticos e algébricos, caracteriza-se como um meio eficiente na descrição e interpretação de efeitos entre variáveis relacionadas ao cultivo de plantas. Os modelos de regressão são métodos estatísticos muito utilizados na análise de dados oriundos de pesquisas no contexto agrícola, visto que são capazes de descrever o comportamento de variáveis de interesse sobre condições independentes, que podem ou não ser controladas pelo pesquisador (ALVES, 2016; LOPES, CHAVARETTE, COSSI, 2017). A regressão linear permite a estimação da taxa de variação entre as variáveis analisadas, enquanto a regressão quadrática possibilita a otimização da variável independente em relação à minimização ou maximização da variável dependente. Os modelos de adaptabilidade e estabilidade, por sua vez, auxiliam na análise de manejos que promovem maior capacidade de adaptabilidade diante de condições favoráveis ou desfavoráveis, verificando também a estabilidade proporcionada pelos tratamentos. Estes modelos podem ser baseados em regressão linear e em regressão bissegmentada, com destaque para os modelos de Eberhart e Russel e de Cruz, Torres e Vencovsky, respectivamente (CARVALHO et al., 2014; MONTEIRO et al., 2015; BICALHO et al., 2018).

Na agricultura, a aveia é uma planta de estação fria que vem recebendo estudos relevantes, por possuir múltiplas opções de uso, destacando a utilização na alimentação humana, na forma de farinha, farelo e flocos, na alimentação animal, como ração, pastagem, feno e silagem, e na indústria farmacêutica, na produção de cosméticos (DOLINSKY et al., 2015; MOREIRA; MARTINS; WANNER, 2017; MALANCHEN et al., 2019). Um fator prejudicial ao desenvolvimento da aveia durante seu cultivo é a ocorrência de doenças foliares causadas por fungos, que acarretam em perdas significativas na produtividade e qualidade de grãos se não controladas. Um recurso comumente utilizado no controle destes patógenos é a aplicação de fungicidas. Entretanto, seu uso indiscriminado gera riscos à saúde humana, devido à contaminação do solo e lençóis de água, podendo afetar também os grãos (ALESSI et al., 2018b; PEREIRA et al., 2020).

Determinar estratégias que permitam a ausência ou a máxima redução no uso destes agrotóxicos é fundamental, garantindo os benefícios que a aveia pode promover, com segurança alimentar. O ajuste da época de semeadura da aveia pode estabelecer um zoneamento meteorológico que favoreça a diminuição da incidência de calor durante o ciclo, reduzindo a ocorrência de doenças fúngicas e conseqüentemente de fungicidas no seu controle. Modelos de regressão polinomiais e de adaptabilidade e estabilidade podem auxiliar na determinação de épocas de semeadura que promovam

redução da incidência de doenças foliares por zona de escape aos patógenos fúngicos, favorecendo manejos mais sustentáveis e elevando a produtividade e qualidade de grãos na cultura da aveia.

O objetivo deste capítulo é avaliar o efeito de distintas épocas de semeadura da aveia sobre o comportamento da área foliar necrosada, decorrente de doenças foliares, e da produtividade de grãos, sem e com o uso de fungicida. Determinar também a época de semeadura que possibilita elevar a produtividade de grãos e reduzir a área foliar necrosada, demonstrando adaptabilidade e estabilidade diante das condições dos anos agrícolas, na ausência e presença de uma aplicação de fungicida.

7.2. Materiais e métodos

No desenvolvimento deste capítulo, analisou-se a área foliar necrosada e a produtividade de grãos da aveia sob as condições de ausência e de presença de uma aplicação de fungicida no paniculamento. Inicialmente, foi apresentado o período compreendendo a quantidade de dias entre a emergência e o paniculamento, em cada época de semeadura, a fim de observar o momento da aplicação de fungicida.

Os dados referentes à área foliar necrosada e à produtividade de grãos foram organizados, sendo possível observar os valores de desvio-padrão da necrose foliar em cada ponto do ciclo, de 60 DAE até 120 DAE, a cada 15 dias. O momento de maior variabilidade da área foliar necrosada, definido com base na observação da maior magnitude do desvio-padrão, foi escolhido para análise desta variável. Após a observação da significância dos efeitos das épocas de semeadura sobre a área foliar necrosada e a produtividade de grãos pela ANOVA (não apresentado), os comportamentos dessas variáveis foram avaliados pela análise de regressão, em função da época de semeadura. A variável independente x foi considerada como o número de dias a partir de 15 de abril e as análises foram realizadas em ambos os cenários de aplicação de fungicida, por cultivar e também independente de cultivar, considerando os efeitos dos anos agrícolas simultaneamente.

A significância das épocas de semeadura, anos de cultivo e da interação entre os fatores foi realizada pela ANOVA (não apresentado). Na sequência, a adaptabilidade e estabilidade das épocas de semeadura sobre a área foliar necrosada e a produtividade de grãos foram avaliadas pelos modelos de Eberhart e Russel e de Cruz, Torres e Vencovsky. Além disso, foi empregado o modelo de agrupamento de médias de Scott e Knott na avaliação dos resultados. A análise foi realizada em cada condição de aplicação de fungicida e cultivar, considerando o efeito dos anos de cultivo como índice ambiental nos modelos de adaptabilidade e estabilidade.

As descrições detalhadas das variáveis estudadas neste capítulo podem ser observadas no Capítulo 3. Os modelos utilizados, por sua vez, estão descritos no Capítulo 4 e foram empregados

utilizando o software livre Genes. Em todas as análises estatísticas foi considerado nível de significância de 5%. Também foram empregados softwares do pacote Microsoft Office.

7.3. Resultados e discussão

Na Tabela 7 estão indicados os dias da emergência ao paniculamento (DEP), momento em que foi realizada a aplicação de fungicida.

Tabela 7 – Momento de aplicação de fungicida em dias após a emergência, coincidente ao paniculamento, em cada época de semeadura, cultivar e ano de cultivo.

Ano	Dias da emergência ao paniculamento/ Épocas de Semeadura						
	15/04	01/05	15/05	01/06	15/06	01/07	15/07
URS Corona							
2018	80	86	92	85	79	75	71
2019	77	90	91	86	80	78	75
2020	80	90	93	88	81	71	64
2021	79	88	91	81	78	71	68
Média	79	89	92	85	79	74	70
URS Taura							
2018	78	87	92	84	81	74	71
2019	75	90	92	88	80	79	76
2020	80	90	93	86	81	71	65
2021	79	88	91	81	79	72	68
Média	78	89	92	85	80	74	70
URS Guria							
2018	79	88	92	85	80	76	71
2019	76	90	92	88	80	80	75
2020	79	90	93	86	81	70	65
2021	79	88	93	81	78	73	67
Média	78	89	93	85	80	75	70

Observando os resultados médios dos DEP de cada época de semeadura em relação aos anos agrícolas (Tabela 7), percebe-se que as cultivares URS Corona, URS Taura e URS Guria demonstraram comportamento similar quanto a esta variável. A semeadura de 15 de abril evidenciou cerca de 78 DEP, de modo que há um aumento até 15 de maio, momento em que inicia o período de recomendação de semeadura da aveia na região noroeste do RS, com valores próximos a 92 dias. A partir deste período, há uma redução nos DEP, com cerca de 80 dias em 15 de junho, que marca o fim do período de recomendação, e 70 dias na semeadura tardia de 15 de julho. O período mais curto observado nos DEP em semeaduras mais tardias da aveia se deve à ocorrência de temperaturas do ar mais elevadas e de fotoperíodo mais longo, tendo em vista que a aveia sofre influência desses fatores durante seu cultivo devido a ser uma planta de dia longo (FÜHR, 2014; PIVETTA, 2019).

Na Tabela 8 são apresentados os resultados da cultivar URS Corona quanto à área foliar necrosada e à produtividade de grãos nos manejos com ausência e utilização de uma aplicação de fungicida, em cada época de semeadura e ano de cultivo, dos 60 dias após a emergência (DAE) aos 120 DAE.

Tabela 8 – Médias da área foliar necrosada e da produtividade de grãos da URS Corona em diferentes épocas de semeadura, anos de cultivo e condições de aplicação de fungicida.

Época Semeadura	Ano Cultivo	Sem fungicida					PG (kg ha ⁻¹)	Com fungicida					PG (kg ha ⁻¹)
		AFN (%)/ DAE						AFN (%)/ DAE					
		60	75	90	105	120		60	75	90	105	120	
15/04	2018	0	0	0	22	59	917	0	0	0	8	28	1432
	2019	2	8	39	50	77	202	1	7	27	34	74	264
	2020	0	0	2	7	45	1516	0	0	1	6	38	1629
	2021	0	0	1	6	22	1394	0	0	0	4	21	1806
	Média	0	2	11	21	51	1008	0	2	7	13	40	1282
01/05	2018	0	0	0	9	65	907	0	0	0	8	40	1418
	2019	1	3	6	40	85	1170	1	2	6	33	63	1401
	2020	1	1	2	7	45	1741	1	1	2	6	29	1858
	2021	1	2	3	6	24	1427	1	1	3	5	22	1694
	Média	1	1	3	15	55	1311	1	1	3	13	39	1593
15/05	2018	0	0	2	11	89	878	0	0	1	10	69	1655
	2019	2	3	5	47	96	969	2	3	5	43	79	1227
	2020	1	1	3	8	76	1755	1	1	2	6	49	1987
	2021	1	2	3	7	32	1447	1	1	3	6	29	1523
	Média	1	2	3	18	73	1262	1	2	3	16	57	1598
01/06	2018	1	2	5	70	99	775	1	2	4	51	86	1200
	2019	3	5	8	64	99	1376	2	4	7	56	90	1533
	2020	2	2	3	44	97	1449	1	2	3	34	95	1515
	2021	2	2	4	7	77	1124	2	2	3	7	52	1512
	Média	2	3	5	46	93	1181	2	3	4	37	81	1440
15/06	2018	3	4	22	97	-	531	3	4	17	84	-	1080
	2019	3	5	25	78	-	842	3	5	21	66	-	1201
	2020	2	3	16	94	-	1211	2	3	12	88	-	1246
	2021	3	4	5	54	-	508	3	4	4	45	-	667
	Média	3	4	17	81	-	773	3	4	14	71	-	1048
01/07	2018	3	9	91	-	-	434	3	9	84	-	-	533
	2019	4	8	80	-	-	254	4	8	73	-	-	528
	2020	2	14	88	-	-	631	2	14	83	-	-	880
	2021	3	13	74	-	-	438	3	12	68	-	-	647
	Média	3	11	83	-	-	439	3	11	77	-	-	647
15/07	2018	4	51	100	-	-	130	4	50	100	-	-	166
	2019	6	60	96	-	-	128	6	60	89	-	-	223
	2020	3	53	100	-	-	514	3	46	100	-	-	807
	2021	4	45	82	-	-	297	4	42	78	-	-	323
	Média	4	52	94	-	-	267	4	49	92	-	-	380
Desvio-padrão		2	18	39	32	27		2	17	37	28	26	

-: ausência de dados devido ao término do ciclo de cultivo; AFN: área foliar necrosada; DAE: dias após a emergência; PG: produtividade de grãos.

De maneira geral, na ausência de fungicida, a cultivar URS Corona evidencia valores reduzidos de área foliar necrosada em sementeiras mais precoces de 15 de abril até 15 de maio até cerca de 105 DAE, período posterior à fase de paniculamento, que por meio da atuação da zona de escape daria subsídios para o enchimento de grãos com proteção natural por meio de temperaturas reduzidas (BASSO et al., 2022). No entanto, em 2019, a sementeira de 15 de abril demonstra relevante progressão de necrose, em decorrência de geadas intensas ocorridas no emborrachamento (Capítulo 5). Na sementeira de 01 de junho, apesar de haver forte atuação das doenças foliares aos 105 DAE, ainda é constatada necrose reduzida até 90 DAE. Na sementeira de 15 de junho, a zona de escape mostra efetividade de controle apenas até 75 DAE, o mesmo acontece para a sementeira posterior ao período de recomendação em 01 de julho. Em um cenário mais drástico, com sementeira em 15 de julho, já há forte atuação das doenças foliares aos 75 DAE.

Quando analisado o efeito de uma aplicação de fungicida na fase de paniculamento na cultivar URS Corona, aliado à contribuição da zona de escape, percebe-se que há uma pequena redução da necrose foliar aos 105 DAE, nas sementeiras de 15 de abril até 01 de junho, novamente com impacto da geada na época de 15 de abril em 2019. A sementeira de 15 de junho e as sementeiras mais tardias, de 01 de julho e 15 de julho, também mostraram médias similares de área foliar necrosada quando realizada uma aplicação de fungicida em relação à ausência de uso, com pequena redução da necrose aos 90 DAE. Nesse sentido, evidencia-se que não é eficiente uma aplicação de fungicida no paniculamento, embora seja um período que evidencie maior ação da doença durante o ciclo de cultivo da aveia (PEREIRA et al., 2020).

Observando os resultados médios de produtividade de grãos obtidos para a URS Corona, nos cenários com ausência e presença de uma aplicação de fungicida, percebe-se que as sementeiras de 01 de maio e 15 de maio propiciaram os melhores resultados. Estas épocas de sementeira demonstraram ser possível obter produtividades próximas a 1300 kg ha^{-1} na ausência de fungicida, ou seja, apenas com a proteção pela zona de escape. As sementeiras de 15 de abril e 01 de junho também evidenciaram bons resultados, entretanto, é importante destacar que a época de 15 de abril oferece riscos ao cultivo devido à possibilidade de ocorrência de geadas. Nessa sementeira, as plantas de aveia ainda não possuem percepção celular sobre o frio, ficando mais vulneráveis a drásticas reduções de temperatura. Nesse sentido, ressalta-se o bom desempenho de sementeiras em 01 de maio e 15 de maio, que mesmo sendo acometidas por geadas, ainda mantêm resultados satisfatórios de produtividade, caracterizando-se também como os momentos mais oportunos para aproveitamento da máxima ação da zona de escape aos patógenos fúngicos por controle pela temperatura do ar.

Analisando ainda a Tabela 8, percebe-se que não é expressivo o aumento da produtividade de grãos na URS Corona quando realizada uma aplicação de fungicida na fase de paniculamento, em relação ao cenário de ausência de aplicação. A aplicação de fungicida implica em custos relacionados

ao combustível para entrada de trator na lavoura, mão de obra do operador e custos relacionados aos agrotóxicos fungicidas. Além disso, destaca-se os impactos ocasionados pelo uso de agrotóxicos à saúde humana, tanto pelo contato direto com o operador, como indiretamente à população em geral pela contaminação de diferentes compartimentos ambientais, o que não pode ser mensurado em curto prazo, mas que ao longo dos anos certamente acarretará em malefícios à saúde pública (JOBIM et al., 2010; SILVA et al., 2015). Com base nos fatores mencionados, percebe-se que não é vantajosa a aplicação de fungicida no cenário analisado, ou seja, no paniculamento.

Na Tabela 9, há a análise da evolução das doenças durante o ciclo e a produtividade de grãos nos cenários de ausência e presença de uma aplicação de fungicida na cultivar URS Taura.

Tabela 9 – Médias da área foliar necrosada e da produtividade de grãos da URS Taura em diferentes épocas de semeadura, anos de cultivo e condições de aplicação de fungicida.

Época Semeadura	Ano Cultivo	Sem fungicida					Com fungicida						
		AFN (%)/ DAE					PG (kg ha ⁻¹)	AFN (%)/ DAE					PG (kg ha ⁻¹)
		60	75	90	105	120		60	75	90	105	120	
15/04	2018	0	0	1	17	58	1128	0	0	1	14	24	1593
	2019	3	9	49	72	96	200	3	9	38	55	91	397
	2020	0	1	2	4	51	1178	0	1	1	3	48	1270
	2021	0	0	0	6	37	2180	0	0	0	5	35	2351
	Média	1	3	13	25	60	1172	1	3	10	19	49	1403
01/05	2018	0	0	2	6	53	991	0	0	2	5	50	1931
	2019	2	3	6	39	82	1302	1	3	6	32	68	1525
	2020	0	1	2	8	51	1242	0	1	2	7	40	1296
	2021	1	1	3	6	39	1908	0	1	2	5	36	2061
	Média	1	1	3	15	56	1361	0	1	3	12	48	1703
15/05	2018	0	1	2	11	78	984	0	1	2	10	54	1272
	2019	3	3	8	45	97	1100	2	3	8	37	79	1411
	2020	2	2	3	8	55	1912	2	2	3	4	47	2160
	2021	1	2	5	8	42	1339	1	2	5	6	37	1729
	Média	1	2	4	18	68	1334	1	2	4	14	54	1643
01/06	2018	1	1	5	55	99	965	1	1	5	49	92	1841
	2019	3	4	12	59	91	1126	3	4	11	52	89	1371
	2020	2	2	5	25	97	1578	2	2	5	21	95	1753
	2021	1	2	9	28	88	1085	1	2	8	16	65	1467
	Média	2	3	8	42	94	1188	2	2	7	34	85	1608
15/06	2018	2	3	49	97	-	640	2	3	42	93	-	944
	2019	3	5	26	75	-	716	3	5	23	71	-	1041
	2020	2	3	19	99	-	1307	2	3	16	94	-	1446
	2021	4	5	10	63	-	535	4	4	9	55	-	733
	Média	3	4	26	83	-	800	3	4	23	78	-	1041
01/07	2018	2	17	91	-	-	579	2	17	84	-	-	648
	2019	4	7	72	-	-	157	4	7	65	-	-	587
	2020	3	13	77	-	-	580	3	13	73	-	-	893
	2021	5	12	69	-	-	453	4	12	60	-	-	643
	Média	3	12	77	-	-	442	3	12	71	-	-	693
15/07	2018	14	57	100	-	-	155	14	57	100	-	-	190
	2019	4	59	86	-	-	101	4	58	79	-	-	209
	2020	5	64	100	-	-	411	4	57	100	-	-	587
	2021	5	55	84	-	-	226	5	52	75	-	-	344
	Média	7	59	93	-	-	223	7	56	88	-	-	333
Desvio-padrão		3	20	37	32	23		3	19	35	30	24	

-: ausência de dados devido ao término do ciclo de cultivo; AFN: área foliar necrosada; DAE: dias após a emergência; PG: produtividade de grãos.

Observando os resultados para a cultivar URS Taura, verifica-se um controle das doenças foliares pela zona de escape nas semeaduras mais antecipadas de 15 de abril até 15 de maio, até 105 DAE, evidenciando necrose mais elevada apenas aos 120 DAE, momento próximo da maturação fisiológica. Em 2019, porém, esta cultivar também sofreu danos devido à geada na semeadura de 15 de abril. Na semeadura de 01 de junho, o controle ocorreu apenas até 90 DAE, de modo que quanto

mais se adia a semeadura, mais há incidência das doenças foliares. Assim, nas semeaduras de 15 de junho e 01 de julho já há forte expressão de necrose aos 90 DAE e em 15 de julho ainda mais cedo, aos 75 DAE. Analisando os efeitos do uso de fungicida, percebe-se que uma aplicação no paniculamento apresenta progressões semelhantes de área foliar necrosada em relação à ausência de aplicação. Deste modo, a zona de escape por si só é suficiente para o controle de doenças foliares nas épocas de semeadura analisadas, similar à realização de uma aplicação de fungicida no paniculamento, mesmo que neste momento do ciclo já se perceba a ação das doenças.

Na análise dos melhores cenários de controle de doenças e de obtenção de produtividade de grãos, se evidenciam semeaduras de 15 de abril até 01 de junho, na ausência e presença de fungicida. Entretanto, cabe pontuar a possibilidade da ocorrência de geadas na semeadura de 15 de abril, ocasionando na formação de cristais de gelo no interior celular e a movimentação de água do simplasto para o apoplasto, de modo que este processo pode provocar morte celular, impactando diretamente na produtividade (NERBASS JUNIOR et al., 2010; KOVALESKI, 2021). Há destaque para as semeaduras de 01 de maio e 15 de maio, que obtiveram as maiores produtividades de grãos e mesmo sendo semeaduras precoces, também acometidas pela ocorrência de geadas, não sofreram danos nos anos agrícolas do estudo. Ambas épocas de semeadura evidenciaram produtividades de mais de 1300 kg ha⁻¹, sem uso de fungicida, ou seja, apenas pela proteção da zona de escape. Novamente se destaca a vantagem de manter o cultivo livre de agrotóxicos, tendo em vista os custos relacionados à aplicação e os riscos à saúde a longo prazo (JOBIM et al., 2010; PEREIRA et al., 2020).

Na Tabela 10, há a progressão da área foliar necrosada durante o ciclo e a produtividade de grãos obtidas nos diferentes cenários de semeadura e de aplicação de fungicida para a cultivar URS Guria.

Tabela 10 – Médias da área foliar necrosada e da produtividade de grãos da URS Guria em diferentes épocas de semeadura, anos de cultivo e condições de aplicação de fungicida.

Época Semeadura	Ano Cultivo	Sem fungicida					Com fungicida						
		AFN (%)/ DAE					PG (kg ha ⁻¹)	AFN (%)/ DAE					PG (kg ha ⁻¹)
		60	75	90	105	120		60	75	90	105	120	
15/04	2018	0	0	0	6	83	1539	0	0	0	2	17	1651
	2019	2	6	38	60	96	210	2	6	33	48	66	552
	2020	0	1	1	14	87	1651	0	1	1	12	70	1808
	2021	0	0	1	7	29	1946	0	0	0	5	29	2306
	Média	1	2	10	22	74	1336	0	2	9	17	46	1579
01/05	2018	0	0	0	4	50	1578	0	0	0	3	43	2210
	2019	1	1	2	35	77	1500	1	1	2	28	70	1833
	2020	1	1	3	8	61	1754	1	1	3	8	53	1863
	2021	0	0	2	8	34	1720	0	0	2	7	32	1827
	Média	1	1	2	14	55	1638	1	1	2	11	50	1933
15/05	2018	0	0	1	10	85	1244	0	0	1	9	69	1624
	2019	1	2	3	44	99	1510	1	2	2	32	91	1712
	2020	1	2	3	14	73	1849	1	2	3	6	66	2077
	2021	1	1	2	11	38	1612	1	1	2	9	35	1780
	Média	1	1	2	20	74	1554	1	1	2	14	65	1798
01/06	2018	0	1	2	55	100	1125	0	1	1	54	100	1365
	2019	2	2	11	64	98	1562	2	2	11	55	96	1807
	2020	2	3	4	24	98	1683	2	3	4	32	93	1731
	2021	1	2	3	14	76	1376	1	2	3	10	72	1689
	Média	1	2	5	39	93	1437	1	2	5	38	91	1648
15/06	2018	1	2	30	97	-	1034	1	2	23	96	-	1224
	2019	3	4	31	88	-	947	2	4	28	79	-	1246
	2020	3	4	18	94	-	1435	2	4	15	93	-	1518
	2021	1	2	5	62	-	674	1	2	4	58	-	1006
	Média	2	3	21	85	-	1022	2	3	17	81	-	1249
01/07	2018	1	12	96	-	-	622	1	12	89	-	-	829
	2019	4	13	91	-	-	376	4	13	85	-	-	630
	2020	3	14	90	-	-	639	3	14	85	-	-	904
	2021	3	12	71	-	-	576	2	12	69	-	-	718
	Média	3	13	87	-	-	553	3	13	82	-	-	771
15/07	2018	6	73	100	-	-	108	6	70	100	-	-	247
	2019	14	70	96	-	-	162	14	70	92	-	-	210
	2020	3	49	100	-	-	575	3	42	100	-	-	680
	2021	4	45	90	-	-	257	4	41	86	-	-	420
	Média	7	59	96	-	-	276	7	56	95	-	-	389
Desvio-padrão		3	21	40	32	24		3	20	39	31	26	

-: ausência de dados devido ao término do ciclo de cultivo; AFN: área foliar necrosada; DAE: dias após a emergência; PG: produtividade de grãos.

De modo semelhante às cultivares anteriores, a URS Guria demonstra as menores progressões de doenças nas semeaduras de 15 de abril até 15 de maio até 105 DAE, tanto na ausência como na presença de uma aplicação de fungicida. Valores mais expressivos de necrose são observados nestas semeaduras aos 120 DAE, entretanto, este ponto é próximo à maturação fisiológica, sendo possível confundir a senescência natural da planta com a necrose causada por patógenos fúngicos. Estas

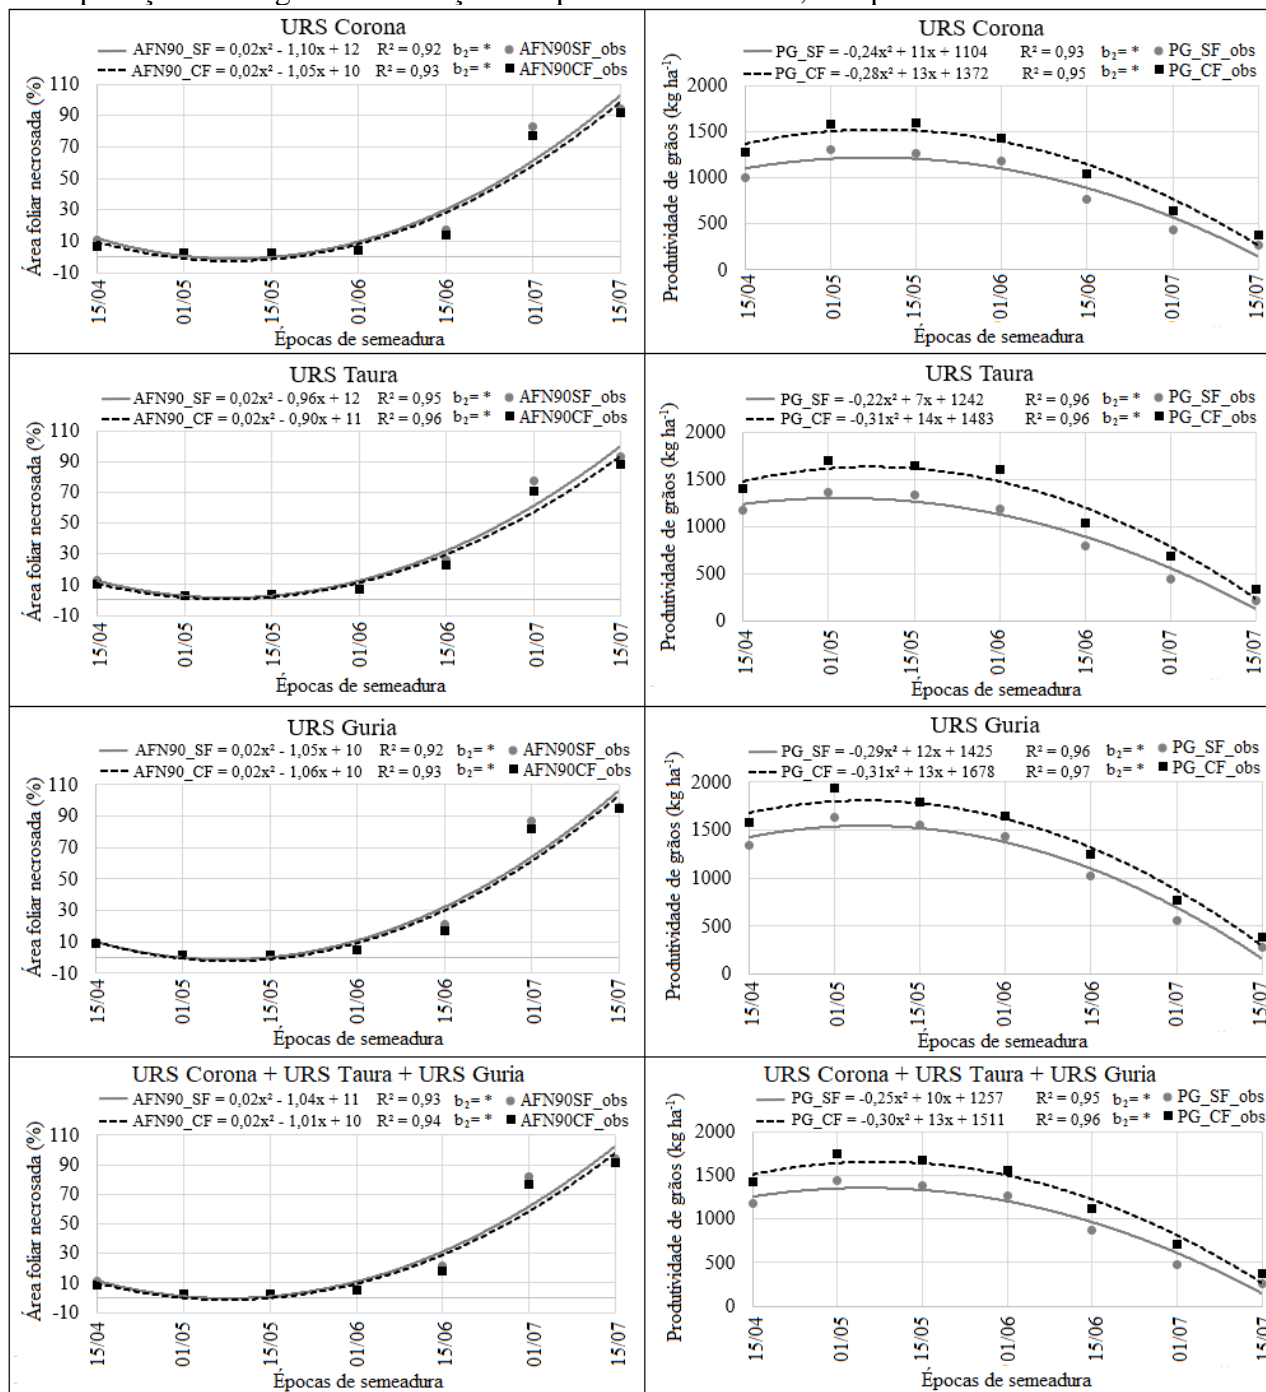
semeaduras também apresentam as maiores médias de produtividade de grãos, com destaque para 01 de maio e 15 de maio, que são semeaduras precoces, mas que já iniciam o ciclo de cultivo com temperaturas mais amenas, permitindo a aclimação das plantas ao frio e propiciando maior resistência a drásticas reduções da temperatura. Já a semeadura de 15 de abril, em um dos anos de cultivo, obteve relevante progressão da necrose foliar, além de sofrer perdas significativas de produtividade, em razão de condições de estresse por frio, visto que inicia seu ciclo em temperaturas muito elevadas, não fornecendo às plantas condições suficientes para serem resistentes a reduções expressivas na temperatura (Capítulo 5).

A semeadura de 01 de junho, por sua vez, apresentou controle adequado das doenças até 90 DAE, com comportamento semelhante nos cenários de ausência e presença de fungicida e bons resultados de produtividade de grãos, superiores aos obtidos na semeadura de 15 de abril, porém menores que os obtidos nas semeaduras de 01 de maio e 15 de maio. Por fim, semeaduras mais tardias de 15 de junho e 01 de julho já mostram progressão relevante das doenças aos 90 DAE, enquanto a semeadura de 15 de julho mostra efetivo aumento da doença ainda antes, aos 75 DAE. Estas semeaduras também evidenciam as menores médias de produtividade de grãos.

Na URS Guria, o incremento da produtividade de grãos também não é de grande magnitude com uma aplicação de fungicida no paniculamento, tendo em vista os custos relacionados à aplicação e as vantagens de um cultivo livre de agrotóxicos (JARDIM, ANDRADE, 2009; FRANÇA et al., 2016). Além disso, as semeaduras de 01 de maio e 15 de maio permitiram a obtenção de médias de produtividade superiores a 1500 kg ha⁻¹ apenas com a proteção pela zona de escape com base na temperatura do ar. Nerbass Junior et al. (2010) afirmam que a aplicação de fungicidas no cultivo da aveia sem critério técnico e econômico provoca aumento no custo de produção e contaminação do agroecossistema.

Observando as Tabelas 8, 9 e 10, com as progressões de área foliar necrosada para as três cultivares dos 60 aos 120 DAE, percebe-se que os maiores valores de desvio-padrão acontecem sempre no ponto de 90 DAE, tanto no cenário de ausência como no cenário de presença de fungicida. Nesse sentido, há maior variabilidade neste momento de desenvolvimento em relação às épocas de semeadura, indicando este ponto como mais oportuno para análise da necrose foliar. Assim, na Figura 19 há o comportamento da área foliar necrosada aos 90 DAE e da produtividade de grãos em função da época de semeadura em cada cultivar e independente de cultivar, sem e com o uso de fungicida, considerando os efeitos dos quatro anos de cultivo do estudo.

Figura 19 – Comportamento da área foliar necrosada e da produtividade de grãos sem e com aplicação de fungicida em função da época de semeadura, independente de ano de cultivo.



x: variável independente em dias, com $x=0$ em 15 de abril; DAE: dias após a emergência; AFN90_SF: regressão da área foliar necrosada aos 90 DAE sem fungicida; AFN90_CF: regressão da área foliar necrosada aos 90 DAE com fungicida; AFN90SF_obs: área foliar necrosada observada aos 90 DAE sem fungicida; AFN90CF_obs: área foliar necrosada observada aos 90 DAE com fungicida; PG_SF: regressão da produtividade de grãos sem fungicida; PG_CF: regressão da produtividade de grãos com fungicida; PG_SF_obs: produtividade de grãos observada sem fungicida; PG_CF_obs: produtividade de grãos observada com fungicida; R²: coeficiente de determinação. b₂: coeficiente do termo de maior grau da regressão; *: significativo a 5% de probabilidade de erro.

Fonte: autoria própria.

Na Figura 19, observa-se que as três cultivares URS Corona, URS Taura e URS Guria possuem comportamento similar em relação à área foliar necrosada e à produtividade de grãos, além de todas as regressões apresentarem coeficientes significativos nos termos de maior grau (b₂), com

coeficientes de determinação adequados. A partir da semeadura de 15 de abril, há um decréscimo da necrose foliar, que apresenta estabilidade da semeadura de 01 de maio até 15 de maio, momento a partir do qual inicia o crescimento desta variável. Analisando a produtividade de grãos, há incremento a partir da semeadura de 15 de abril com os maiores valores entre 01 de maio e 15 de maio e tendência de decréscimo a partir da semeadura em 15 de maio. Este comportamento é evidenciado nos cenários de ausência e presença de fungicida, bem como, na análise independente das cultivares. Portanto, o período de semeadura de 01 de maio a 15 de maio revela-se como o mais promissor para ocorrer reduzida área foliar necrosada e elevada produtividade de grãos, com efetividade na zona de escape, caracterizando-se também como um cenário meteorológico ajustado ao desenvolvimento biológico das plantas de aveia.

As regressões quadráticas são empregadas em diferentes contextos agrícolas, auxiliando na análise de resultados de diversos tipos de plantas sob influência de distintos manejos agrícolas (BAZZO et al., 2020). Medeiros et al. (2018) empregaram regressões para analisar os efeitos de distintas doses de nitrogênio no crescimento e alocação de fitomassa de quiabeiros, percebendo relação quadrática entre o nitrogênio e a área foliar, o que possibilitou a otimização da adubação. Sousa et al. (2017) ao avaliar o efeito de diferentes lâminas de irrigação e cobertura do solo no crescimento da cultura do sorgo, perceberam que o comprimento da panícula e a altura de planta aumentaram linearmente com o incremento das lâminas, porém os valores de diâmetro da panícula e diâmetro do caule apresentaram comportamento quadrático em função da lâmina de irrigação, com possibilidade de otimização.

A fim de aprofundar o estudo dos efeitos das épocas de semeadura sobre a área foliar necrosada, na Tabela 11 estão os resultados do modelo de agrupamento de médias de Scott e Knott e dos modelos de adaptabilidade e estabilidade de Eberhart e Russel e de Cruz, Torres e Vencovsky, considerando a necrose aos 90 DAE nas diferentes épocas de semeadura, com ausência e presença de fungicida. O índice ambiental dos modelos de adaptabilidade e estabilidade foi composto pelo conjunto de anos agrícolas.

Tabela 11 – Adaptabilidade e estabilidade das épocas de semeadura sobre a área foliar necrosada aos 90 dias após a emergência nas condições de uso de fungicida por cultivar de aveia.

Condição	Épocas Semeadura	b ₀ (%)	AFN (Eberhart e Russel)			AFN (Cruz, Torres e Vencovsky)			
			b ₁	σ ²	R ² (%)	β ₁	β ₁ +β ₂	σ ²	R ² (%)
URS Corona									
Sem fungicida	15/04	11c	2,99*	199*	83	2,02*	7,32*	243*	92
	01/05	3d	0,23*	4	77	0,05*	1,02	2	95
	15/05	3d	0,13*	-0,1	75	0,02*	0,58	0,2	98
	01/06	5d	0,31*	-0,1	87	0,27*	0,48	9	71
	15/06	17c	1,67*	9*	90	1,92*	0,53	1	99
	01/07	83b	0,53*	74*	72	1,13	-2,12*	93*	82
	15/07	94a	1,13	56*	76	1,57*	-0,82*	150*	76
Com fungicida	15/04	7d	2,08*	140*	72	1,19	8,35*	33*	97
	01/05	3d	0,18*	2	71	0,01*	1,40	5	86
	15/05	3d	0,12*	-1	74	0,02*	0,84	3	81
	01/06	4d	0,37*	-0,7	85	0,24*	1,25	0,1	99
	15/06	14c	1,70*	1	93	1,62*	2,28	22	95
	01/07	77b	0,88	63*	72	1,49	-3,42*	9	98
	15/07	92a	1,64*	98*	79	2,40*	-3,71*	3	99
URS Taura									
Sem fungicida	15/04	13d	2,90*	510*	71	2,56*	38,63*	125*	97
	01/05	3e	0,17*	0,3	73	0,13*	3,22	1	96
	15/05	4e	0,05*	7	71	0,004*	4,66	12	80
	01/06	8e	0,12*	12	73	0,06*	5,32*	29	78
	15/06	26c	2,45*	168*	79	2,65*	-18,62*	2	99
	01/07	77b	0,94	99*	76	1,09	-15,04*	25	96
	15/07	93a	0,37*	101*	75	0,47*	-11,18*	318*	71
Com fungicida	15/04	10d	1,75*	391*	72	1,94*	-49,21*	196*	93
	01/05	3e	0,12*	-2	71	0,14*	-5,19	2	91
	15/05	4e	-0,05*	3	70	-0,02*	-7,70	10	82
	01/06	7d	0,01*	8	80	0,03*	-8,97*	26	72
	15/06	23c	2,38*	83*	90	2,30*	25,68*	86*	95
	01/07	71b	1,46	79*	78	1,37	24,62*	63	93
	15/07	88a	1,31	199*	73	1,21	27,77*	646*	70
URS Guria									
Sem fungicida	15/04	10d	2,60*	183*	74	1,75*	6,10*	235*	92
	01/05	2e	-0,01*	-2	70	-0,07*	0,27	2	79
	15/05	2e	0,01*	-2	71	-0,05*	0,29	3	73
	01/06	5e	0,54*	6	79	0,32*	1,45	0,7	99
	15/06	21c	1,96*	32*	84	2,36*	0,28	8	99
	01/07	87b	1,49*	66*	71	2,02*	-0,73*	62*	94
	15/07	96a	0,40*	21*	75	0,66	-0,67*	61*	78
Com fungicida	15/04	9d	2,55*	147*	82	1,71*	5,96*	230*	90
	01/05	2d	-0,004*	-2	70	-0,07*	0,28	2	74
	15/05	2d	0,02*	-1	71	-0,04*	0,31	3	76
	01/06	5d	0,63*	8	77	0,36*	1,72	0,6	99
	15/06	17c	1,95*	11*	90	2,21*	0,88	24	97
	01/07	82b	1,29	45*	77	1,80*	-0,81*	39	94
	15/07	95a	0,54*	52*	77	1,02	-1,37*	120*	70

Modelos considerando os anos de cultivo no índice ambiental. Médias seguidas pela mesma letra na coluna são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott; AFN: área foliar necrosada aos 90 DAE; DAE: dias após a emergência; b₀: média geral; b₁: coeficiente de regressão linear; σ²: desvios da regressão; R²: coeficiente de determinação; β₁: coeficiente de regressão linear para ambientes desfavoráveis; β₁ + β₂: coeficiente de regressão linear para ambientes favoráveis; *: significativo a 5% de probabilidade de erro.

Analisando a cultivar URS Corona na ausência de fungicida, as menores médias de área foliar necrosada foram observadas nas semeaduras de 01 de maio até 01 de junho, com adaptabilidade específica a ambiente desfavorável e estabilidade destas épocas por ambos os modelos. Na presença de fungicida, esta cultivar obteve os menores valores de necrose da semeadura de 15 de abril até 01 de junho, de modo que 15 de abril apresentou adaptabilidade específica a ambiente favorável e instabilidade por ambos os modelos, enquanto as semeaduras de 01 de maio a 01 de junho demonstraram o mesmo comportamento observado na ausência de fungicida.

Observando a cultivar URS Taura, na ausência de fungicida, as menores médias de necrose foram observadas de 01 de maio a 01 de junho, com adaptabilidade específica a ambiente desfavorável e estabilidade por ambos modelos. No entanto, a semeadura de 01 de junho também apresenta adaptabilidade a ambiente favorável pelo modelo de Cruz, Torres e Vencovsky. Quando há aplicação de fungicida, as menores médias ocorrem nas semeaduras de 01 de maio e 15 de maio, adaptáveis a ambientes desfavoráveis e estáveis por ambos os modelos.

Na cultivar URS Guria na ausência de aplicação de fungicida as semeaduras de 01 de maio a 01 de junho demonstram as menores médias de necrose, com adaptabilidade específica a ambiente desfavorável e estabilidade por ambos modelos. Quando realizada aplicação de fungicida, há destaque para as semeaduras de 15 de abril a 01 de junho, com as menores médias. A semeadura de 15 de abril apresentou adaptabilidade a ambiente favorável e instabilidade pelos modelos analisados, enquanto as semeaduras de 01 de maio a 01 de junho são adaptáveis a ambientes desfavoráveis e estáveis por ambos os modelos.

As análises de médias e de adaptabilidade e estabilidade também foram realizadas para a produtividade de grãos, a fim de observar o desempenho das épocas de semeadura nas cultivares estudadas em cada condição de aplicação de fungicida, com o índice ambiental vinculado aos anos agrícolas (Tabela 12).

Tabela 12 - Adaptabilidade e estabilidade das épocas de semeadura sobre a produtividade de grãos nas condições de uso de fungicida por cultivar de aveia.

Condição	Épocas Semeadura	b ₀ (kg ha ⁻¹)	PG (Eberhart e Russel)			PG (Cruz, Torres e Vencovsky)			
			b ₁	σ ²	R ² (%)	β ₁	β ₁ +β ₂	σ ²	R ² (%)
URS Corona									
Sem fungicida	15/04	1008b	1,65*	212470*	79	1,99*	0,39	1015338*	78
	01/05	1311a	1,25	5370	94	1,31	1,00	56504	95
	15/05	1262a	1,47*	1242	97	1,59*	0,98	76	99
	01/06	1181a	0,68*	80193*	78	0,58*	1,04	491913*	70
	15/06	773c	0,83	77469*	79	0,45*	2,25*	124791*	87
	01/07	439d	0,46*	5195	79	0,41*	0,61	61699	71
	15/07	267e	0,66*	-5465	99	0,64	0,69	2027	99
Com fungicida	15/04	1282b	2,46*	298883*	76	3,41*	-0,70*	668930*	84
	01/05	1593a	0,98	-8246	88	1,07	0,65	40097	90
	15/05	1598a	1,38	2788	86	1,23	1,85	91727	89
	01/06	1440a	0,13*	20292*	73	0,17*	0,01	222209*	74
	15/06	1048c	0,05*	86923*	70	-0,62*	2,31	751	99
	01/07	647d	0,73	-13320	90	0,68	0,93	17891	92
	15/07	380e	1,24	6520	81	1,03	1,93	82905	89
URS Taura									
Sem fungicida	15/04	1172b	2,43*	447502*	74	2,65*	-14,49*	649211*	88
	01/05	1361a	0,77	166665*	73	0,91	-9,64*	256458*	81
	15/05	1334a	1,42*	66850*	81	1,33	8,29*	102158*	93
	01/06	1188b	0,71	56034*	71	0,62	7,13*	79762	87
	15/06	800c	0,69	130500*	74	0,54*	11,17*	27984	97
	01/07	442d	0,49*	30589*	76	0,47*	1,84	214585*	70
	15/07	223e	0,49*	-1571	89	0,46*	2,68	45	99
Com fungicida	15/04	1403b	3,44*	324137*	75	3,50*	-98,70*	147329	97
	01/05	1703a	0,33	169174*	73	0,37	-69,87*	208297*	81
	15/05	1643a	1,34	121390*	72	1,32	39,38*	548755*	70
	01/06	1608a	0,60	42381*	76	0,59	26,11	218046*	72
	15/06	1041c	0,15*	119220*	71	0,11*	65,06*	37587	95
	01/07	693d	0,45	2830	71	0,44	22,82	7808	95
	15/07	333e	0,64	13896	75	0,63	22,18	80750	73
URS Guria									
Sem fungicida	15/04	1336b	2,81*	398447*	74	3,68*	-1,45*	1094119*	79
	01/05	1638a	0,56	-8674	91	0,64	0,16	263	99
	15/05	1554a	0,92	31847*	75	0,87	1,16	250610*	75
	01/06	1437b	0,47	64594*	75	0,25*	1,50	370506*	70
	15/06	1022c	0,85	94705*	79	0,25*	3,74*	4408	99
	01/07	553d	0,46	-1760	79	0,49	0,30	51746	70
	15/07	276e	0,93	1931	81	0,80	1,56	45941	88
Com fungicida	15/04	1579b	3,83*	268444*	75	4,70*	-4,17*	193712	96
	01/05	1933a	-0,09*	34040*	71	-0,13*	0,29	302872*	71
	15/05	1798a	0,95	7527	77	0,79	2,49	91889	73
	01/06	1648b	-0,07*	39554*	70	-0,12*	0,35	335117*	71
	15/06	1249c	0,48	40603*	72	0,06	4,29*	2057	99
	01/07	771d	0,63	-9833	76	0,53	1,55	23183	82
	15/07	389e	1,26	-6027	94	1,16	2,17	46373	88

Modelos considerando os anos de cultivo no índice ambiental. Médias seguidas pela mesma letra na coluna são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott; PG: produtividade de grãos; b₀: média geral; b₁: coeficiente de regressão linear; σ²: desvios da regressão; R²: coeficiente de determinação; β₁: coeficiente de regressão linear para ambientes desfavoráveis; β₁ + β₂: coeficiente de regressão linear para ambientes favoráveis; *: significativo a 5% de probabilidade de erro.

Na Tabela 12, observando a cultivar URS Corona na ausência de fungicida, as semeaduras de 01 de maio até 01 de junho evidenciaram as maiores médias de produtividade. A semeadura de 01 de maio com adaptabilidade geral pelo modelo de Eberhart e Russel e estabilidade por ambos modelos. A data de 15 de maio com adaptabilidade específica a ambiente favorável também pelo modelo de Eberhart e Russel e estabilidade por ambos os modelos e a semeadura de 01 de junho com adaptabilidade específica a ambientes desfavoráveis, porém com instabilidade, evidenciadas pelos dois modelos. No cenário de uma aplicação de fungicida, as mesmas épocas de semeadura se destacaram. As datas de 01 de maio e 15 de maio demonstraram estabilidade por ambos os modelos e adaptabilidade geral por Eberhart e Russel. Enquanto 01 de junho demonstrou o mesmo comportamento do cenário sem uso de fungicida.

Na cultivar URS Taura na ausência de fungicida, 01 de maio e 15 de maio obtiveram as maiores médias de produtividade, porém com instabilidade por ambos modelos, sendo que 01 de maio obteve adaptabilidade geral por Eberhart e Russel e 15 de maio demonstrou ser adaptável a ambiente favorável pelos dois modelos. Na presença de uma aplicação de fungicida, houve destaque para semeaduras de 01 de maio a 01 de junho, também com instabilidade por ambos modelos. No entanto, as três épocas de semeadura apresentaram adaptabilidade geral por Eberhart e Russel e 15 de maio evidenciou adaptabilidade específica a ambiente favorável por Cruz, Torres e Vencovsky.

Analisando a cultivar URS Guria, na ausência de fungicida as semeaduras de 01 de maio e 15 de maio demonstraram os maiores valores de produtividade, ambas com adaptabilidade geral pelo modelo de Eberhart e Russel, de modo que 01 de maio apresentou estabilidade por ambos os modelos, enquanto 15 de maio foi instável. Na presença de fungicida, as mesmas datas de semeadura se destacaram. A época de 01 de maio apresentou adaptabilidade específica a ambientes desfavoráveis e instabilidade por ambos os modelos e 15 de maio apresentou adaptabilidade geral por Eberhart e Russel e estabilidade pelos dois modelos.

Na cultura da aveia, modelos de adaptabilidade e estabilidade, juntamente à análise de médias, podem auxiliar na otimização de épocas de semeadura que promovam cultivos estáveis e com adequada adaptabilidade, garantindo elevada produtividade de grãos e baixa incidência de doenças foliares. Em outras culturas, estudos também são desenvolvidos, buscando uma adequada utilização de manejos. Queiroz et al. (2014) estimaram a adaptabilidade e estabilidade de cultivares de alface tipo crespa em diferentes épocas de semeadura em condições de alta temperatura. Carvalho et al. (2014) realizaram uma análise de adaptabilidade e estabilidade do desempenho de cultivares de cenoura, em diversos ambientes do Brasil. Barili et al. (2015) estudaram os parâmetros de adaptabilidade e estabilidade fenotípica e avaliaram o incremento na produtividade de grãos em genótipos de feijão preto, desenvolvidos pelos programas brasileiros de melhoramento genético em cinco décadas. Além disso, submeteram as médias de produtividade de grãos das cultivares ao teste

de Scott e Knott, em cada um dos ambientes, na verificação dos diferentes agrupamentos entre os genótipos. Azizah (2016) utilizou modelos de adaptabilidade e estabilidade e o modelo de agrupamento de médias de Scott e Knott no estudo da interação de genótipos de soja e diferentes ambientes. Monteiro et al. (2017) empregaram modelos de adaptabilidade e estabilidade, na avaliação de cultivares de soja para produtividade de óleo nos grãos.

Em relação ao uso de modelos de adaptabilidade e estabilidade em conjunto, Oliveira et al. (2017) analisaram diferentes modelos, com base em dados de produtividade de diversas cultivares de milho híbrido, em diferentes ambientes localizados na região Nordeste do Brasil. Os autores concluíram que o uso combinado dos métodos de Eberhart e Russel e de Cruz, Torres e Vencovsky proporcionou os melhores resultados de seleção de genótipos, pois esses métodos associaram dados de produtividade com a estabilidade e adaptabilidade das cultivares.

7.4. Conclusões

Os comportamentos da área foliar necrosada e da produtividade de grãos evidenciam os valores mais satisfatórios destas variáveis no intervalo de semeadura entre 01 de maio e 15 de maio, tanto na ausência como na presença de fungicida. As épocas de semeadura de 01 de maio até 01 de junho demonstram as melhores médias de produtividade de grãos e de necrose foliar, de modo geral, com desempenhos satisfatórios quanto à adaptabilidade e à estabilidade às condições dos anos agrícolas, nos cenários sem e com o uso de fungicida.

8. REGRESSÃO LINEAR E CONTRIBUIÇÃO RELATIVA DOS EFEITOS DA ÉPOCA DE SEMEADURA DA AVEIA SOBRE INDICADORES DE PRODUTIVIDADE E DE QUALIDADE DE GRÃOS NA AUSÊNCIA E PRESENÇA DE FUNGICIDA

8.1. Introdução

Modelos e métodos matemáticos estatísticos permitem a análise das relações entre variáveis, com aplicação nas ciências agrárias (OLIVEIRA, FREITAS, JESUS, 2014; SILVA, M. P. et al., 2018; PANSEIRA et al., 2022). Os modelos de regressão são capazes de descrever a influência de uma variável sobre outra, favorecendo a análise das relações (ROSA et al., 2021a). O modelo estatístico de Singh permite verificar a contribuição relativa de variáveis para a diversidade genética em função de um tratamento, ou seja, evidencia as variáveis que sofrem maior influência pela aplicação de um manejo (ALESSI et al., 2021b).

Na área agrícola, a aveia é um cereal de estação fria e vem recebendo notoriedade em estudos, devido principalmente a suas múltiplas possibilidades de uso e benefícios à saúde humana, por ser rica em nutrientes (MA et al., 2017; LIU et al., 2018). No cultivo da aveia, entretanto, quando ocorre elevação da temperatura do ar, aliada à umidade, há o risco de incidência de doenças foliares ocasionadas por fungos. Estas doenças afetam significativamente a produtividade de grãos alterando as características industriais e químicas dos grãos (HENNING et al., 2009). Um manejo comum no controle destes patógenos é a aplicação de fungicidas. Entretanto seu uso demasiado pode trazer prejuízos ambientais e à saúde pública (PEREIRA et al., 2020).

O reposicionamento da época de semeadura da aveia, na busca de condições meteorológicas que dificultem o ataque destes patógenos pode ser uma opção eficiente na prevenção das doenças e redução da aplicação de fungicidas. Os modelos de regressão linear e de Singh podem indicar a influência da época de semeadura na produtividade de grãos e em variáveis ligadas à qualidade industrial e química.

O objetivo deste capítulo é avaliar o comportamento de variáveis relacionadas à produtividade e à qualidade industrial e química de grãos, em função de diferentes épocas de semeadura da aveia, analisando também a contribuição relativa das épocas sobre estas variáveis, na ausência e presença de fungicida.

8.2. Materiais e métodos

Para o desenvolvimento deste capítulo, foi considerada a produtividade de grãos, os caracteres de qualidade industrial, como a massa de mil grãos, a massa do hectolitro, o índice de descasque, o número de grãos maiores que 2 milímetros e a produtividade industrial, e os caracteres de qualidade

química, como a proteína total, o amido e a fibra total. Após o emprego da ANOVA (não apresentado) na observação dos efeitos da época de semeadura sobre as variáveis, o modelo de Scott e Knott foi utilizado na análise das médias, em cada condição de uso de fungicida, independente de ano agrícola.

Na análise da taxa de variação dos caracteres relacionados à produtividade de grãos e à qualidade industrial e química, empregou-se regressões lineares em função da época de semeadura. As contribuições relativas percentuais destas variáveis, que demonstram as que sofrem mais influência do efeito das épocas de semeadura, foram obtidas pelo modelo de Singh. Ambas análises foram observadas em cada condição de aplicação de fungicida, por cultivar e independente de cultivar, considerando de modo concomitante os anos agrícolas.

As descrições detalhadas das variáveis estudadas neste capítulo podem ser observadas no Capítulo 3. Os modelos utilizados, por sua vez, estão descritos no Capítulo 4 e foram empregados utilizando o software livre Genes. Em todas as análises estatísticas foi considerado nível de significância de 5%. Também foram empregados softwares do pacote Microsoft Office.

8.3. Resultados e discussão

Na Tabela 13, há os resultados da produtividade de grãos para cada cultivar e condição de aplicação de fungicida nas épocas de semeadura, de modo que foi realizada análise de agrupamento de médias por Scott e Knott nos resultados médios dos anos agrícolas em cada cenário.

Tabela 13 – Médias da produtividade de grãos em cada época de semeadura, condição de aplicação de fungicida, cultivar e ano de cultivo.

Ano Cultivo	Época de semeadura - Sem fungicida							Época de semeadura - Com fungicida						
	15/4	01/5	15/5	01/6	15/6	01/7	15/7	15/4	01/5	15/5	01/6	15/6	01/7	15/7
Produtividade de grãos (kg ha ⁻¹)														
URS Corona														
2018	917	907	878	775	531	434	130	1432	1418	1655	1200	1080	533	166
2019	202	1170	969	1376	842	254	128	264	1401	1227	1533	1201	528	223
2020	1516	1741	1755	1449	1211	631	514	1629	1858	1987	1515	1246	880	807
2021	1394	1427	1447	1124	508	438	297	1806	1694	1523	1512	667	647	323
Média	1008B	1311A	1262A	1181A	773C	439D	267E	1282B	1593A	1598A	1440A	1048C	647D	380E
URS Taura														
2018	1128	991	984	965	640	579	155	1593	1931	1272	1841	944	648	190
2019	200	1302	1100	1126	716	157	101	397	1525	1411	1371	1041	587	209
2020	1178	1242	1912	1578	1307	580	411	1270	1296	2160	1753	1446	893	587
2021	2180	1908	1339	1085	535	453	226	2351	2061	1729	1467	733	643	344
Média	1172B	1361A	1334A	1188B	800C	442D	223E	1403B	1703A	1643A	1608A	1041C	693D	333E
URS Guria														
2018	1539	1578	1244	1125	1034	622	108	1651	2210	1624	1365	1224	829	247
2019	210	1500	1510	1562	947	376	162	552	1833	1712	1807	1246	630	210
2020	1651	1754	1849	1683	1435	639	575	1808	1863	2077	1731	1518	904	680
2021	1946	1720	1612	1376	674	576	257	2306	1827	1780	1689	1006	718	420
Média	1336B	1638A	1554A	1437B	1022C	553D	276E	1579B	1933A	1798A	1648B	1249C	771D	389E

Médias seguidas pela mesma letra na linha são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott, em cada cenário de uso de fungicida.

Na cultivar URS Corona, nos cenários de ausência e de presença de aplicação de fungicida, se destacaram as semeaduras de 01 de maio, 15 de maio e 01 de junho. Na cultivar URS Taura, as mesmas épocas evidenciaram os melhores resultados com uma aplicação de fungicida, já no cenário de ausência de aplicação, apenas 01 de maio e 15 de maio obtiveram os maiores valores de produtividade. Na cultivar URS Guria, as semeaduras de 01 de maio e 15 de maio apresentaram os resultados mais satisfatórios em ambos os cenários de aplicação de fungicida.

Destaca-se que o melhor desempenho das cultivares, de modo geral, ocorre em um período mais precoce em relação à recomendação de semeadura da cultura da aveia, que atualmente é de 15 de maio a 15 de julho (LÂNGARO; CARVALHO, 2014). Semeaduras mais tardias, que possuem incidência de temperaturas do ar mais elevadas, tiveram sua produtividade impactada por favorecerem o desenvolvimento de doenças foliares (PEREIRA et al., 2020). Além do fato de dias longos influenciarem nos componentes de produtividade (FÜHR, 2014). Por outro lado, a semeadura precoce de 15 de abril não demonstrou as maiores produtividades, tendo em vista que pode oferecer riscos ao cultivo com a ocorrência de geadas no início do ciclo e durante o emborrachamento. Quando as plantas não possuem adequada aclimação ao frio, iniciando o cultivo em temperaturas mais elevadas, podem sofrer danos com quedas bruscas na temperatura. Destaca-se, inclusive, que a aveia é uma das principais culturas agrícolas a ser afetada por geadas (DEMARCHI, PIROLI, 2015).

Na Tabela 14, há os resultados da massa de mil grãos e da massa do hectolitro para cada cultivar e condição de aplicação de fungicida nas épocas de semeadura, com análise de agrupamento de médias por Scott e Knott nos resultados médios dos anos agrícolas em cada cenário.

Tabela 14 – Médias de caracteres de produtividade por época de semeadura, condição de aplicação de fungicida, cultivar e ano de cultivo.

Ano Cultivo	Época de semeadura - Sem fungicida							Época de semeadura - Com fungicida						
	15/4	01/5	15/5	01/6	15/6	01/7	15/7	15/4	01/5	15/5	01/6	15/6	01/7	15/7
Massa de mil grãos (g)														
URS Corona														
2018	26	24	24	19	17	17	17	28	29	27	20	20	19	23
2019	24	28	28	26	23	22	23	31	32	29	27	22	21	21
2020	31	35	35	33	30	30	31	30	36	37	34	31	31	33
2021	38	39	39	34	29	28	30	39	38	35	33	28	28	30
Média	30A	32A	31A	28A	25B	24B	25B	32A	34A	32A	29A	25B	25B	27B
URS Taura														
2018	23	20	20	18	17	17	19	23	26	23	22	19	18	21
2019	24	25	24	24	20	21	22	23	26	26	25	23	19	21
2020	29	32	32	32	30	29	31	30	31	32	31	31	32	33
2021	33	38	33	32	28	29	33	34	37	33	32	29	30	32
Média	27A	29A	27A	26A	24A	24A	26A	28A	30A	28A	28A	26A	25A	27A
URS Guria														
2018	27	25	23	20	20	16	20	25	29	25	23	17	18	19
2019	26	27	27	28	23	20	23	30	29	29	28	25	23	23
2020	34	37	36	31	31	31	29	35	35	36	36	32	29	33
2021	36	35	31	30	27	27	28	35	38	33	29	29	29	31
Média	31A	31A	29A	27A	25B	24B	25B	31A	33A	31A	29A	26B	25B	27B
Massa do hectolitro (kg hl ⁻¹)														
URS Corona														
2018	39	40	39	39	39	39	39	41	40	40	39	39	39	39
2019	39	39	39	39	39	39	39	42	42	41	40	39	39	40
2020	40	41	45	43	39	39	39	40	44	48	44	43	42	42
2021	49	44	42	39	39	38	39	45	45	41	40	39	40	41
Média	42A	41A	42A	40A	39B	39B	39B	42A	43A	43A	41A	40A	40A	41A
URS Taura														
2018	40	39	39	39	39	39	39	41	40	39	39	39	39	39
2019	39	39	39	39	39	39	39	40	40	40	40	39	39	40
2020	42	46	43	43	39	39	39	43	45	45	44	41	40	40
2021	48	53	44	40	40	39	40	50	51	42	41	40	41	42
Média	42A	45A	42A	40B	39B	39B	39B	43A	44A	42A	41A	40A	40A	40A
URS Guria														
2018	40	39	39	39	39	39	39	41	41	41	40	39	39	39
2019	40	40	41	40	39	39	39	39	39	41	40	40	39	40
2020	43	47	48	46	40	39	39	43	49	47	46	42	42	43
2021	50	51	41	40	39	40	40	49	50	44	42	41	41	42
Média	43A	44A	42A	41A	39B	39B	40B	43A	45A	43A	42A	40A	40A	41A

Médias seguidas pela mesma letra na linha são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott, em cada cenário de uso de fungicida.

Observando os resultados da massa de mil grãos, as cultivares URS Corona e URS Guria demonstraram similaridade, com valores mais expressivos nas semeaduras de 15 de abril até 01 de junho e mais reduzidos no período de 15 de junho até 15 de julho, tanto na ausência como na presença de fungicida. Destaca-se que a semeadura de 15 de junho ainda pertence ao período de recomendação de semeadura da aveia, porém não evidencia uma adequada expressão desta variável. Na análise da

cultivar URS Taura, há uma estabilidade que mostra ausência de variação, nas duas condições de aplicação de fungicida. Observando a massa do hectolitro, na ausência de fungicida, as cultivares URS Corona e URS Guria também demonstram os melhores resultados em semeaduras de 15 de abril até 01 de junho, com redução a partir de 15 de junho. No entanto, na URS Taura, já há redução da expressão desta variável a partir da semeadura de 01 de junho. No cenário de uma aplicação de fungicida no paniculamento, observa-se estabilidade nas cultivares, não havendo variação da massa do hectolitro ao longo das épocas de semeadura.

A massa de mil grãos e a massa do hectolitro se caracterizam como variáveis relevantes no estudo do desempenho de cultivares de aveia. Guerreiro e Oliveira (2012) avaliaram a influência de doses de regulador de crescimento em aveia, observando, dentre outros parâmetros, a massa de mil grãos e a massa do hectolitro. Passos et al. (2018) analisaram o desempenho agrônômico e a qualidade industrial de cultivares de aveia branca, sem e com aplicação de fungicida, verificando os valores de produtividade, da massa de mil grãos, do índice de descasque e os percentuais de acamamento. Lovatto et al. (2021) caracterizaram a resistência de genótipos de aveia à ferrugem da folha e avaliaram o impacto produtivo e econômico causado pela doença, em ambientes com e sem fungicida, estimando as perdas através da análise da produtividade, da massa de mil grãos e da massa do hectolitro.

Na Tabela 15, há os resultados dos caracteres de interesse à indústria em cada cenário, juntamente à análise de agrupamento de médias por Scott e Knott.

Tabela 15 – Médias de caracteres de qualidade industrial por época de semeadura, condição de aplicação de fungicida, cultivar e ano de cultivo.

Ano Cultivo	Época de semeadura - Sem fungicida							Época de semeadura - Com fungicida						
	15/4	01/5	15/5	01/6	15/6	01/7	15/7	15/4	01/5	15/5	01/6	15/6	01/7	15/7
Índice de descasque (g g ⁻¹)														
URS Corona														
2018	0,67	0,66	0,62	0,61	0,65	0,57	0,57	0,69	0,69	0,69	0,68	0,68	0,65	0,67
2019	0,73	0,74	0,77	0,77	0,68	0,64	0,64	0,74	0,71	0,79	0,81	0,74	0,74	0,74
2020	0,72	0,74	0,75	0,74	0,70	0,73	0,71	0,73	0,74	0,79	0,78	0,78	0,77	0,76
2021	0,82	0,74	0,73	0,67	0,64	0,67	0,78	0,77	0,71	0,70	0,67	0,64	0,61	0,70
Média	0,73A	0,72A	0,72A	0,70A	0,67B	0,65B	0,68B	0,73A	0,71A	0,74A	0,74A	0,71A	0,69A	0,72A
URS Taura														
2018	0,68	0,65	0,63	0,61	0,60	0,60	0,63	0,70	0,79	0,79	0,78	0,72	0,68	0,70
2019	0,67	0,67	0,72	0,65	0,65	0,65	0,67	0,78	0,79	0,76	0,67	0,59	0,58	0,59
2020	0,75	0,76	0,78	0,78	0,79	0,75	0,73	0,83	0,84	0,89	0,71	0,67	0,76	0,80
2021	0,78	0,77	0,75	0,74	0,74	0,77	0,79	0,79	0,79	0,72	0,71	0,68	0,68	0,69
Média	0,72A	0,71A	0,72A	0,70B	0,69B	0,69B	0,70B	0,78A	0,80A	0,79A	0,72B	0,66B	0,68B	0,70B
URS Guria														
2018	0,69	0,69	0,69	0,67	0,67	0,61	0,62	0,69	0,71	0,66	0,62	0,59	0,66	0,70
2019	0,75	0,78	0,78	0,70	0,68	0,60	0,66	0,77	0,76	0,76	0,73	0,67	0,65	0,68
2020	0,72	0,73	0,79	0,76	0,75	0,75	0,67	0,66	0,74	0,74	0,76	0,78	0,74	0,72
2021	0,75	0,79	0,71	0,65	0,59	0,57	0,62	0,70	0,71	0,63	0,62	0,55	0,64	0,67
Média	0,73A	0,75A	0,74A	0,70A	0,67B	0,63B	0,64B	0,70A	0,73A	0,70A	0,68B	0,65B	0,67B	0,69B
Número de grãos maiores que 2 milímetros (%)														
URS Corona														
2018	61	59	59	58	58	58	55	67	70	65	58	57	66	67
2019	54	73	66	62	55	50	50	71	73	61	59	51	51	53
2020	66	70	71	64	55	55	60	68	74	74	66	62	62	66
2021	73	81	80	70	65	64	69	74	72	70	69	66	66	70
Média	63B	71A	69A	63B	58C	57C	59C	70A	72A	67A	63B	59B	61B	64B
URS Taura														
2018	60	60	59	59	58	58	62	61	61	53	53	63	64	68
2019	62	57	57	56	50	51	51	58	57	57	54	52	56	70
2020	55	65	54	54	60	67	72	57	64	61	56	67	67	73
2021	71	68	64	64	63	65	68	80	75	72	71	65	66	70
Média	62A	63A	58A	58A	58A	61A	63A	64B	64B	61B	59B	62B	63B	70A
URS Guria														
2018	68	62	57	57	56	56	62	72	74	60	52	50	53	55
2019	76	61	54	54	48	63	74	69	66	66	65	60	62	72
2020	65	71	70	61	49	59	62	67	79	74	69	62	62	58
2021	76	72	69	68	67	68	72	62	73	67	60	59	60	67
Média	71A	66A	63B	60B	55C	62B	67A	67A	73A	67A	62B	58B	59B	63B
Produtividade industrial (kg ha ⁻¹)														
URS Corona														
2018	373	354	326	278	206	145	42	672	674	744	472	417	227	72
2019	78	626	495	673	306	80	42	137	732	577	742	450	206	86
2020	711	913	916	683	467	254	229	795	992	1168	785	586	414	410
2021	827	867	856	527	212	183	163	1021	863	748	694	289	253	158
Média	497B	690A	648A	540B	297C	165D	119D	656B	815A	809A	673B	436C	275D	181E
URS Taura														
2018	462	378	364	344	235	200	59	680	933	534	732	436	280	87
2019	84	493	454	405	231	53	35	173	678	611	490	320	190	88
2020	475	611	802	661	612	288	216	603	694	1146	695	635	442	341
2021	1209	1006	640	521	250	226	123	1466	1228	910	754	318	285	172
Média	557B	622A	565A	483C	332C	192D	108D	731B	883A	800A	668B	427C	299D	172E
URS Guria														
2018	722	671	491	426	387	213	41	816	1146	636	457	373	290	95
2019	122	706	625	589	305	145	79	289	926	869	842	502	245	103
2020	779	925	1026	781	515	280	235	794	1086	1131	909	734	411	281
2021	1089	968	793	591	269	227	113	986	941	750	630	332	273	196
Média	678B	817A	734A	597B	369C	216D	117D	721B	1025A	846A	709B	485C	305C	169D

Médias seguidas pela mesma letra na linha são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott, em cada cenário de uso de fungicida.

Na ausência de fungicida, as cultivares URS Corona e URS Guria demonstram redução do índice de descasque a partir de 15 de junho, enquanto a URS Taura já demonstra redução a partir de 01 de junho. Na presença de fungicida, a URS Corona evidencia estabilidade nos resultados, enquanto as cultivares URS Taura e URS Guria sofrem redução desta variável em sementeiras a partir de 01 de junho. Observando o número de grãos maiores que 2 milímetros, na ausência de fungicida, a cultivar URS Corona demonstra aumento a partir de 15 de abril, com os maiores valores nas sementeiras de 01 de maio e 15 de maio e diminuição dos valores a partir de 01 de junho. Na cultivar URS Taura há estabilidade desta variável e na URS Guria os valores mais expressivos ocorrem nas sementeiras de 15 de abril e 01 de maio, com decréscimo nas épocas seguintes e aumento nas sementeiras mais tardias. No cenário de uma aplicação de fungicida, as cultivares URS Corona e URS Guria evidenciam similaridade com valores mais expressivos nas sementeiras de 15 de abril até 15 de maio. Na URS Taura, há estabilidade de 15 de abril até 01 de julho, com leve aumento em 15 de julho.

O índice de descasque e o número de grãos com espessura maior que 2 milímetros, aliados à produtividade de grãos, determinam a produtividade industrial dos grãos de aveia (PANSERA et al., 2021). Dada a importância dessas variáveis, Crestani et al. (2010), ao caracterizarem cultivares de aveia-branca quanto ao conteúdo de betaglucana nos grãos, determinaram o conteúdo de betaglucana em amostras de grãos maiores que 2 mm, verificando suas relações com a produtividade industrial e de grãos. Hawerth et al. (2014) evidenciam que além da massa de hectolitro, a classificação da largura de grãos e o índice de descasque representam caracteres importantes na definição da qualidade industrial de um genótipo de aveia branca.

Na análise da produtividade industrial, em todos os cenários observados, ou seja, nas três cultivares, com ausência ou presença de fungicida, os valores mais satisfatórios foram observados nas sementeiras de 01 de maio e 15 de maio. Hawerth et al. (2014) ressaltam que a produtividade industrial representa a porção de cariopse obtida após a seleção e o descasque dos grãos colhidos, evidenciando que, para o agricultor, o desempenho da cultivar em relação à produtividade industrial é importante na escolha de uma produção de grãos voltada à comercialização com as indústrias de alimentos, pois caracteriza o produto final que será remunerado. Ziomkowski, Bruch e Volpato (2022) destacam os esforços de programas de melhoramento genético de aveia em garantir a qualidade industrial, adaptando as cultivares para que revertam na maior quantidade de produtos processados pela indústria.

Na Tabela 16, há os resultados para a qualidade química dos grãos de aveia, nos diferentes cenários, também com análise de médias por Scott e Knott.

Tabela 16 – Médias de caracteres de qualidade química por época de semeadura, condição de aplicação de fungicida, cultivar e ano de cultivo.

Ano Cultivo	Época de semeadura - Sem fungicida							Época de semeadura - Com fungicida						
	15/4	01/5	15/5	01/6	15/6	01/7	15/7	15/4	01/5	15/5	01/6	15/6	01/7	15/7
Proteína total (g kg ⁻¹)														
URS Corona														
2018	102	93	104	106	116	130	108	101	107	112	115	124	127	119
2019	114	110	106	106	112	119	149	123	114	109	105	115	116	143
2020	101	96	88	88	89	111	107	97	97	95	94	98	112	114
2021	117	121	102	98	97	118	121	117	116	103	103	104	118	126
Média	108B	105B	100B	100B	104B	120A	121A	109B	108B	105B	104B	110B	118A	126A
URS Taura														
2018	98	97	110	113	125	123	119	106	107	113	114	127	127	126
2019	133	124	110	108	112	130	152	133	121	107	114	120	132	149
2020	92	90	88	89	92	97	110	104	109	101	90	94	102	111
2021	99	113	105	104	107	114	127	106	111	109	108	101	120	129
Média	105B	106B	103B	103B	109B	116A	127A	112B	112B	108B	107B	110B	120A	129A
URS Guria														
2018	94	90	100	103	108	109	98	101	101	103	105	108	117	117
2019	119	114	106	105	104	120	152	128	119	114	105	111	114	149
2020	97	95	87	91	92	103	106	91	94	94	94	96	114	108
2021	104	111	102	104	105	112	115	114	112	107	104	107	115	125
Média	104B	103B	99B	101B	102B	111A	118A	108B	107B	104B	102B	105B	115A	125A
Amido (g kg ⁻¹)														
URS Corona														
2018	443	436	432	434	451	464	450	413	424	426	433	453	464	464
2019	447	444	441	437	435	453	461	442	434	431	423	442	463	464
2020	439	441	454	456	462	471	465	437	452	461	471	457	467	470
2021	428	435	436	439	446	461	459	429	431	446	445	437	465	466
Média	439B	439B	441B	442B	449B	462A	459A	430B	435B	441B	443B	447B	465A	466A
URS Taura														
2018	439	439	441	443	456	465	457	440	443	445	449	461	467	467
2019	459	453	449	440	438	463	477	457	447	442	444	443	469	469
2020	449	452	461	459	434	446	450	452	455	464	462	446	445	435
2021	443	453	457	457	457	456	462	456	449	445	461	462	460	457
Média	448B	449B	452B	450B	446B	457A	462A	451B	448B	449B	454B	453B	460A	457A
URS Guria														
2018	436	435	426	428	454	453	447	421	423	424	439	456	460	460
2019	445	440	431	430	437	467	478	443	439	434	429	440	467	481
2020	441	454	456	466	450	460	461	441	450	451	456	453	460	466
2021	445	443	435	443	454	459	462	453	448	443	443	452	462	469
Média	442B	443B	437B	442B	449B	460A	462A	440B	440B	438B	442B	450B	462A	469A
Fibra total (g kg ⁻¹)														
URS Corona														
2018	131	137	138	142	140	128	140	132	133	134	136	126	128	135
2019	132	133	135	137	137	139	134	129	132	134	136	130	138	138
2020	128	119	118	117	119	120	121	130	116	113	115	122	118	118
2021	129	130	144	144	144	130	130	130	131	141	138	134	128	130
Média	130A	130A	134A	135A	135A	129A	131A	130A	128A	131A	131A	128A	128A	130A
URS Taura														
2018	128	142	142	138	137	128	136	125	134	136	132	130	126	131
2019	127	131	136	137	138	137	134	127	129	131	133	130	138	138
2020	118	119	122	122	133	126	125	122	120	119	116	129	124	124
2021	129	123	140	141	143	131	131	124	125	143	138	138	129	131
Média	125A	129A	135A	135A	138A	131A	132A	124A	127A	132A	130A	132A	129A	131A
URS Guria														
2018	131	139	142	140	135	138	147	130	135	136	137	140	130	136
2019	134	136	137	135	134	142	143	136	133	132	132	129	141	142
2020	125	120	119	115	120	121	122	123	120	117	118	120	121	123
2021	124	124	146	146	143	132	137	123	125	145	140	138	131	134
Média	129A	130A	136A	134A	133A	133A	137A	128A	128A	133A	132A	132A	131A	134A

Médias seguidas pela mesma letra na linha são agrupadas a 5% de probabilidade de erro pelo teste de Scott e Knott, em cada cenário de uso de fungicida.

Analisando a Tabela 16, percebe-se que as três cultivares, URS Corona, URS Taura e URS Guria, obtiveram os maiores resultados para a proteína total e para o amido em semeaduras mais tardias, de 01 de julho e 15 de julho, tanto na ausência como na presença de fungicida. Observando a fibra total, também é possível perceber comportamento similar entre as cultivares, demonstrando estabilidade desta variável em ambos os cenários de aplicação de fungicida.

A aveia se destaca em relação aos outros cereais, devido à sua concentração de proteínas e fibras, mesmo apresentando também amido em sua composição (WEBER, GUTKOSKI, ELIAS, 2002). Zute et al. (2015) e Alessi et al. (2021a) afirmam que componentes como a proteína, o amido e a fibra, além de poderem ser alterados diante de distintos manejos, como a dosagem de nitrogênio e a cultivar, também podem ser influenciados pelas condições meteorológicas. Zute et al. (2015) ainda ressaltam que, se o crescimento da planta for limitado, o teor de proteína nos grãos é maior, o que vai ao encontro dos resultados obtidos, com os valores mais expressivos desse indicador em épocas mais tardias, que possuem encurtamento de seu ciclo (Capítulo 6). No entanto, como visto anteriormente, semeaduras mais tardias têm seu potencial de produtividade industrial e de grãos bastante reduzido nestes cenários, situação que não é compensada pelo ganho nos teores de proteína.

Considerando os caracteres de produtividade de grãos e de qualidade industrial e química, na Tabela 17 são apresentados os modelos de regressão linear destas variáveis. Os comportamentos estão em função da data de semeadura, em cada condição de aplicação de fungicida, cultivar e independente de cultivar, considerando os anos de cultivo concomitantemente. Destaca-se ainda que na variável independente há o número de dias a partir de 15 de abril. Além disso, é apresentada a análise de contribuição relativa das variáveis pelo modelo de Singh, considerando o efeito do dia de semeadura.

Tabela 17 – Regressões e contribuição relativa de caracteres de produtividade de grãos, industrial e química, pelo efeito do dia de semeadura.

Variável	Sem fungicida			Com fungicida		
	b_0+b_1x	R^2 (%)	CR (%)	b_0+b_1x	R^2 (%)	CR (%)
(2018+2019+2020+2021)						
URS Corona						
PG (kg ha ⁻¹)	1369-10,6*x	79	48,6	1693-12,3*x	70	44,2
MMG (g)	31-0,08*x	83	12,8	33-0,10*x	77	15,3
MH (kg hl ⁻¹)	42-0,03x	83	0,1	43-0,03x	71	0,9
ID (g g ⁻¹)	0,73-0,001x	92	4,2	0,73-0,0003x	77	0,9
NG>2mm (%)	69-0,13x	71	5,9	70-0,11x	70	2,0
PI (kg ha ⁻¹)	694-6,04*x	73	0,0	858-6,85*x	76	0,0
PT (g kg ⁻¹)	100+0,17*x	70	11,9	104+0,18*x	74	11,9
AM (g kg ⁻¹)	435+0,27*x	81	14,3	428+0,41*x	93	23,6
FT (g kg ⁻¹)	132+0,007x	71	2,2	130-0,006x	72	1,2
URS Taura						
PG (kg ha ⁻¹)	1490-12,4*x	89	70,7	1828-13,9*x	72	74,9
MMG (g)	28-0,04x	76	3,5	29-0,04x	75	2,3
MH (kg hl ⁻¹)	43-0,05x	72	6,7	44-0,05x	76	5,3
ID (g g ⁻¹)	0,72-0,0003x	71	1,2	0,80-0,001x	70	9,8
NG>2mm (%)	60-0,0002x	70	0,0	61+0,04x	74	0,0
PI (kg ha ⁻¹)	670-5,81*x	88	0,0	913-7,66*x	84	0,0
PT (g kg ⁻¹)	100+0,22*x	75	8,0	107+0,17*x	76	6,2
AM (g kg ⁻¹)	446+0,13x	73	0,0	448+0,11x	78	0,0
FT (g kg ⁻¹)	129+0,06x	71	9,9	127+0,05x	70	1,5
URS Guria						
PG (kg ha ⁻¹)	1747-14,0*x	75	63,4	2029-15,3*x	76	8,7
MMG (g)	31-0,09*x	90	2,9	32-0,08*x	79	8,4
MH (kg hl ⁻¹)	44-0,06x	84	7,8	44-0,04x	70	8,7
ID (g g ⁻¹)	0,75-0,001x	85	8,0	0,71-0,0005x	79	0,7
NG>2mm (%)	67-0,07x	78	5,6	69-0,12x	82	0,9
PI (kg ha ⁻¹)	852-7,74*x	86	0,0	979-8,23*x	77	44,3
PT (g kg ⁻¹)	98+0,15*x	72	1,9	102+0,16*x	73	1,7
AM (g kg ⁻¹)	436+0,25*x	72	10,4	433+0,34*x	82	26,6
FT (g kg ⁻¹)	130+0,07x	70	0,0	129+0,05x	70	0,0
URS Corona + URS Taura + URS Guria						
PG (kg ha ⁻¹)	1535-12,3*x	75	68,1	1850-13,8*x	73	58,4
MMG (g)	30-0,07*x	77	6,8	32-0,07*x	74	9,5
MH (kg hl ⁻¹)	43-0,05x	85	3,8	43-0,04x	73	5,1
ID (g g ⁻¹)	0,74-0,001x	85	4,2	0,75-0,001x	74	4,9
NG>2mm (%)	65-0,07x	79	3,6	67-0,06x	70	1,9
PI (kg ha ⁻¹)	739-6,53*x	83	0,0	917-7,58*x	80	0,0
PT (g kg ⁻¹)	100+0,18*x	73	6,7	104+0,17*x	78	10,5
AM (g kg ⁻¹)	439+0,22*x	78	3,6	437+0,29*x	89	8,9
FT (g kg ⁻¹)	130+0,05x	77	3,2	128+0,03x	79	0,8

x: variável independente em dias com x=0 em 15/04; PG: produtividade de grãos; MMG: massa de mil grãos; MH: massa do hectolitro; ID: índice de descasque; NG>2: número de grãos maiores que 2 milímetros; PI: produtividade industrial; PT: proteína total; AM: amido; FT: fibra total; b_0 : coeficiente linear; b_1 : coeficiente angular da regressão linear; R^2 : coeficiente de determinação; CR: contribuição relativa pelo método de Singh; *: significativo a 5% de probabilidade de erro pelo teste t.

Observando a Tabela 17, pela análise de regressão, percebe-se comportamentos similares nos cenários de ausência e presença de fungicida. As cultivares URS Corona e URS Guria também demonstraram resultados semelhantes, com redução significativa da produtividade de grãos, da massa de mil grãos e da produtividade industrial e aumento da proteína total e do amido, à medida que se adia a data de semeadura. A cultivar URS Taura, por sua vez, evidenciou redução da produtividade de grãos e da produtividade industrial e aumento da proteína total. Analisando os coeficientes angulares das regressões, os mais expressivos em relação à produtividade de grãos ocorreram na cultivar URS Guria, com redução de 14 kg ha^{-1} e $15,3 \text{ kg ha}^{-1}$, a cada dia de atraso na semeadura de aveia, na ausência e presença de uma aplicação de fungicida, respectivamente.

Na análise da contribuição relativa na URS Corona, a produtividade de grãos demonstrou maior alteração diante da variação no dia de semeadura, seguida das variáveis de amido, massa de mil grãos e proteína total, na ausência e presença de fungicida. Na cultivar URS Taura, a produtividade de grãos evidenciou maior possibilidade de alteração pelo dia de semeadura, nos cenários sem e com uso de fungicida. Analisando a cultivar URS Guria, na ausência de fungicida, a produtividade de grãos evidenciou a maior alteração pelo dia de semeadura, seguida pela expressão do amido. Na condição de uma aplicação de fungicida, a produtividade industrial, seguida pelo amido, foram os caracteres que evidenciaram maior alteração pela data de semeadura, mas cabe destacar que a produtividade industrial é influenciada também pela produtividade de grãos. Deste modo, evidencia-se a relevância do ajuste da época de semeadura da aveia, visto que impacta fortemente na produtividade de grãos, variável de elevado interesse aos agricultores, considerando também que a época de semeadura influencia sobre caracteres de qualidade industrial e química, de interesse da indústria.

Na análise independente das cultivares, observando os resultados das regressões na ausência e presença de fungicida, percebe-se que há redução significativa da produtividade de grãos, da massa de mil grãos e da produtividade industrial e aumento da proteína total e do amido. No entanto, embora as variáveis de composição química possam incrementar a qualidade dos grãos, a tendência de redução dos caracteres de produtividade impacta diretamente no valor econômico do produto. Destaca-se que outras variáveis importantes, como a massa do hectolitro, o índice de descasque, o número de grãos maiores que 2 milímetros e a fibra total, não mostram alteração em função do dia de semeadura, possibilitando que variações na época de semeadura não modifiquem componentes importantes ligados ao interesse da indústria. Quando analisados os resultados da contribuição relativa na análise independente das cultivares, percebe-se efeito relevante do dia de semeadura na produtividade de grãos, nos cenários de ausência e presença de fungicida. Estes resultados ressaltam a importância do estudo da época de semeadura. O estresse térmico provocado por altas temperaturas, decorrentes de alterações na época de semeadura, pode acarretar em mudanças nos caracteres de

plantas, causando redução da altura de planta, peso médio do grão e produtividade de grãos em cereais (CARGNIN et al., 2006).

As regressões lineares são muito utilizadas em estudos envolvendo plantas de estação fria. O'Donovan et al. (2005), através de regressões, estimaram perdas de rendimento de culturas de inverno devido a ervas daninhas. Rosa et al. (2009), utilizando regressões lineares, determinaram o filocrono de cultivares de trigo, sob distintos métodos de soma térmica, analisando também os efeitos de diferentes épocas de semeadura. Rosa et al. (2021a) definiram por regressão linear a eficiência agrônômica de aproveitamento do nitrogênio pela relação da dose fornecida e produtividade obtida na cultura da aveia.

O método de contribuição relativa de Singh caracteriza-se como uma ferramenta relevante no estudo da divergência de genótipos em diferentes culturas agrícolas, indicando as variáveis com maior potencial na expressão de dissimilaridade. Lucena e Dantas (2015) analisaram a divergência genética de linhagens e híbridos de mamoeiro, identificando as variáveis que evidenciavam maior capacidade de distinção pelo método de Singh. Sobral et al. (2018) aplicaram o método de Singh na identificação de caracteres relevantes para a caracterização de tipos de coqueiro-alto. Grigolo et al. (2018) estimaram pelo método de Singh a importância relativa de caracteres de acessos de feijão comum, na análise da dissimilaridade entre eles. Alessi et al. (2021b) realizaram, pelo método de Singh, a análise da contribuição do fornecimento de nitrogênio simples e dividido em componentes da espiga de trigo em diferentes doses de nutrientes, o que indica que, através deste método, é possível estudar o efeito de manejos sobre o cultivo de plantas, com identificação das variáveis mais afetadas.

8.4. Conclusões

A produtividade de grãos, a massa de mil grãos e a produtividade industrial mostram tendência de redução à medida que se adia a data de semeadura, enquanto a proteína total e o amido evidenciam crescimento, porém não compensando as perdas na produtividade. A massa do hectolitro, o índice de descasque, o número de grãos maiores que 2 milímetros e a fibra total não demonstram alteração linear à medida que se adia a data de semeadura. A produtividade de grãos é a variável mais afetada quando há modificação na data de semeadura da aveia.

Na ausência e presença de fungicida no cultivo da aveia, as épocas de semeadura de 01 de maio até 01 de junho são as mais satisfatórias, com destaque para as semeaduras de 01 de maio e 15 de maio, mais precoces quando comparadas à atual recomendação de semeadura para a região noroeste do RS.

9. INTELIGÊNCIA ARTIFICIAL POR REDES NEURAIS ARTIFICIAIS E ALGORITMO GENÉTICO NA DEFINIÇÃO DA ÉPOCA MAIS AJUSTADA DE SEMEADURA DA AVEIA NA AUSÊNCIA E PRESENÇA DE FUNGICIDA

9.1. Introdução

A modelagem matemática permite descrever processos reais, auxiliando na tomada de decisões em diferentes áreas de estudo (BATISTA et al., 2018; BAZZO et al., 2020). Sistemas agrícolas sofrem forte influência de práticas de manejo e de condições meteorológicas e a obtenção de modelos robustos, que considerem estes fatores na simulação e otimização dos processos, é importante na análise dos sistemas (MILOSAVLJEVIC, ESSER, CROWDER, 2016). Nesse sentido, a modelagem matemática pode ser potencializada com o emprego de abordagens estatísticas e computacionais, que contemplem os diversos fatores envolvidos.

Uma técnica estatística que permite a inclusão de diferentes variáveis é o modelo de regressão linear múltipla, capaz de relacionar uma variável dependente a duas ou mais independentes. Destaca-se também a possibilidade de identificar os caracteres potenciais para a modelagem através do método de Stepwise (LOPES, CHAVARETTE, COSSI, 2017). Além disso, grupos de variáveis predefinidos podem ser analisados a partir de resultados de regressões múltiplas.

Modelos de inteligência artificial, por sua vez, são modelos computacionais que se baseiam muitas vezes em processos naturais, visando reproduzir mecanismos biológicos através de estruturas computacionais e matemáticas com o propósito de obter a resolução de problemas (NASTOS et al., 2014; FERNANDES et al., 2018). As redes neurais artificiais (RNAs) e os algoritmos genéticos são bastante empregados na simulação e otimização de fenômenos biológicos (MARTINS et al., 2017; DORNELLES et al., 2018). As RNAs baseiam-se no processo de aprendizado de redes neurais biológicas, organizando neurônios artificiais em rede, através de estruturas algébricas (SAMBORSKA et al., 2014; VENDRUSCOLO et al., 2017). As RNAs são capazes de realizar o aprendizado por experiência, a partir de dados experimentais, ajustando parâmetros conhecidos como pesos sinápticos, que recebem esta denominação devido ao fato de simularem as sinapses no processo biológico (SÁNCHEZ et al., 2015). O ajuste dos pesos acontece através do treinamento da RNA, que possibilita a generalização e a identificação de padrões, permitindo, assim, a simulação de processos complexos, como os presentes na agricultura (SOARES et al., 2015).

O algoritmo genético é um método do campo da inteligência artificial que pertence à classe de algoritmos evolucionários e baseia-se no modo de evolução e seleção biológicas, como os conceitos darwinianos de evolução (NASCIMENTO et al., 2015; SIMÕES, EBECKEN, 2016; MOREIRA, MARTINS, WANNER, 2017). Considera-se uma população inicial de indivíduos (soluções) criados de modo randômico, que recebem seleção natural por aptidão e se reproduzem, de

modo que este processo vai se repetindo por gerações. Considera-se também que os indivíduos podem sofrer mutações durante o processo, garantindo a diversidade e reduzindo a chance de a solução tender a um mínimo local. Por fim, sobrevivem os melhores indivíduos, otimizando a solução, que maximiza ou minimiza uma variável de interesse (GOMES et al., 2017; SILVA et al., 2017).

Na agricultura, a aveia é uma cultura que recebe destaque, devido a seus múltiplos propósitos de uso, como na alimentação humana e animal, rotação e sucessão de culturas e indústria farmacêutica. Na alimentação humana, pode ser consumida na forma *in natura*, trazendo benefícios à saúde (KRAISIG et al., 2018). Entretanto, o cultivo deste cereal pode ser acometido por doenças foliares causadas por patógenos fúngicos. Estas doenças podem comprometer significativamente a qualidade e produtividades de grãos e normalmente são controladas com fungicidas (ALESSI et al., 2018b; BASSO et al., 2022). Cada vez mais busca-se a redução de aplicação de agrotóxicos no cultivo de plantas e a adequação da época de semeadura da aveia pode contribuir para a diminuição da incidência de doenças e, conseqüentemente, do uso de fungicidas.

O modelo estatístico de Stepwise caracteriza-se como uma alternativa eficiente na determinação de variáveis relevantes para modelagem. Além disso, os modelos de regressão linear múltipla podem auxiliar na verificação do desempenho de conjuntos predeterminados de variáveis, por meio da análise do erro de simulação. O reconhecimento de padrões pelo uso de redes neurais artificiais pode ser eficaz na simulação do progresso de doenças foliares em função de distintas épocas de semeadura, dos dias após a emergência e demais variáveis meteorológicas relevantes. Além disso, as redes podem simular a produtividade de grãos em função da época de semeadura, da ação de doenças foliares, da soma térmica e da precipitação. E o método de algoritmos genéticos pode ser empregado para otimizar a época de semeadura, minimizando a incidência de patógenos fúngicos e maximizando a produtividade de grãos.

O objetivo deste capítulo é selecionar as variáveis meteorológicas que mais influenciam na progressão da área foliar necrosada, simular a necrose foliar e otimizar a época de semeadura, com minimização da incidência de doenças fúngicas na aveia, sem e com o uso de fungicida. Além disso, simular a produtividade de grãos e otimizar a época de semeadura, com maximização da produtividade, também em cenários de ausência e de presença de fungicida, indicando o período de semeadura ideal da aveia.

9.2. Materiais e métodos

No desenvolvimento deste capítulo, as variáveis meteorológicas temperatura mínima média, temperatura máxima média, temperatura média, temperatura mínima, temperatura máxima, umidade mínima média, umidade máxima média, umidade média, umidade mínima e umidade máxima foram

organizadas em períodos quinzenais acumulativos, considerando 15 dias anteriores a cada ponto, de 60, 75, 90, 105 e 120 dias após a emergência (DAE). Para as variáveis soma térmica e precipitação, por sua vez, foram considerados os valores acumulados desde o início do ciclo até os pontos de 60, 75, 90, 105 e 120 DAE. Os dados referentes à área foliar necrosada foram organizados considerando seus valores aos 60, 75, 90, 105 e 120 DAE, juntamente à produtividade de grãos correspondente em cada condição de uso de fungicida, ano de cultivo e época de semeadura, independente de cultivar.

Na sequência, foram obtidos seis modelos via regressão linear múltipla, cinco com conjuntos de caracteres predefinidos e um com os selecionados por Stepwise, a fim de definir quais variáveis de entrada seriam escolhidas para a construção de uma rede neural artificial (RNA) com foco na simulação da área foliar necrosada. Em todos os modelos os dias após a emergência e as épocas de semeadura foram considerados como variáveis de entrada, com alterações nos caracteres meteorológicos entre um modelo e outro, conforme descrito na sequência. O primeiro modelo incluiu todas as variáveis meteorológicas. O segundo considerou as variáveis selecionadas pelo modelo de Stepwise. O terceiro utilizou a temperatura mínima, a temperatura máxima, a umidade mínima e a umidade máxima. O quarto empregou os valores médios da temperatura mínima, da temperatura máxima, da umidade mínima e da umidade máxima. O quinto considerou a temperatura média e a umidade média. E o sexto incluiu os valores médios da temperatura mínima, da temperatura máxima, da temperatura média, da umidade mínima, da umidade máxima e da umidade média. Os resultados dos modelos foram avaliados em cada condição de aplicação de fungicida, verificando a regressão mais adequada aos dados pela análise do erro médio absoluto e do coeficiente de regressão.

Na obtenção das RNAs para simular a área foliar necrosada, uma em cada condição de aplicação de fungicida, utilizou-se o aplicativo Neural Network Start do software Matlab. A arquitetura de RNA utilizada foi Perceptron de múltiplas camadas, do tipo *feedforward* com uma camada de entrada, uma camada neural oculta e uma camada neural de saída. O número de entradas foi igual à quantidade de variáveis de entrada selecionadas e o neurônio de saída foi caracterizado pela variável dependente, relativa à área foliar necrosada. Foram testadas quantidades de neurônios ocultos equivalentes ao tamanho do conjunto de entrada até o seu dobro, sendo escolhida a estrutura de RNA com os menores erros quadráticos médios (EQM) de treino e de validação, seguidos por valores satisfatórios de EQM de teste e de coeficientes de determinação do treino, da validação e do teste.

O algoritmo de aprendizado utilizado foi o Levenberg-Marquardt *backpropagation* e a função de ativação empregada foi a tangente hiperbólica. Foram utilizadas 1080 amostras em cada RNA, considerando 4 anos de cultivo, 3 cultivares, 3 repetições e 4 épocas de semeadura em 5 momentos do ciclo (15 de abril a 01 de junho, até 120 DAE), 1 época em 4 momentos do ciclo (15 de junho, até 105 DAE) e 2 épocas em 3 momentos do ciclo (01 de julho e 15 de julho, até 90 DAE). Para a

realização do treinamento, validação e teste das RNAs, os dados foram separados randomicamente na proporção de 70%, 15% e 15%, respectivamente. A fim de adequar as variáveis de entrada e de saída no intervalo considerado pela função de ativação, de -1 a 1, os dados foram normalizados através da equação

$$N = \frac{2 \cdot (R - R_{\min})}{(R_{\max} - R_{\min})} - 1 \quad (120)$$

em que N é o valor normalizado, R é o valor real a ser normalizado, e R_{\min} e R_{\max} são os valores mínimo e máximo do conjunto de dados reais, respectivamente.

Com a escolha da RNA em cada condição de aplicação de fungicida, ambas foram validadas comparando os valores simulados para a área foliar necrosada com os resultados observados via bioexperimentação, aos 60, 75, 90, 105 e 120 DAE, em cada época de semeadura e ano de cultivo. A validação ocorreu pela análise dos erros absolutos, calculados através do valor absoluto da diferença entre o dado simulado e o observado em cada cenário.

Na criação das RNAs para simulação da produtividade de grãos em cada condição de uso de fungicida, foi seguida uma metodologia semelhante à da RNA para a necrose foliar, com poucas distinções. Houve diferença quanto ao número de variáveis de entrada, que foi definido pela época de semeadura, área foliar necrosada (simulada pela RNA), soma térmica e precipitação, obtidas aos 90 DAE. Essas variáveis de entrada foram determinadas tendo em vista a influência relevante que exercem sobre a produtividade de grãos. Quanto ao número de neurônios ocultos, foram testados de 4 a 8 (considerando o número de variáveis de entrada até seu dobro) e quanto ao neurônio de saída foi utilizado 1, correspondente à produtividade. Em relação à quantidade de amostras, foram consideradas 252 em cada RNA, correspondentes aos 4 anos de cultivo, 7 épocas de semeadura, 3 cultivares e 3 repetições.

Na validação das RNAs para a produtividade de grãos em cada condição de aplicação de fungicida, foram obtidos os erros absolutos entre as médias observadas na bioexperimentação e os valores simulados em cada época de semeadura e ano de cultivo. A fim de avaliar a magnitude dos erros absolutos, foram obtidos também seus valores médios.

Para otimização da época de semeadura, na minimização da área foliar necrosada, foi empregado algoritmo genético, a partir de um código desenvolvido no Matlab, considerando uma população inicial e as subsequentes com 400 indivíduos, seleção de 100 indivíduos (genitores) e 100 gerações. Cada indivíduo da população inicial foi formado por um vetor (genótipo) de 5 posições (genes), de modo que cada gene foi preenchido com um algarismo de 0 a 9, determinado randomicamente. Para o cálculo do fenótipo, valor correspondente à época de semeadura,

inicialmente o indivíduo foi transformado em um número, de 0 a 99999, em que cada gene correspondeu a uma ordem do número, o primeiro à dezena de milhar, o segundo à unidade de milhar, o terceiro à centena e assim por diante. Posteriormente, esse número foi transformado para o intervalo de -1 a 1, adequando-o ao intervalo de dados normalizados e possibilitando a substituição na RNA para o cálculo da aptidão.

A aptidão foi determinada pelo oposto do resultado normalizado da área foliar necrosada aos 90 DAE, observado como o melhor momento para a análise das épocas de semeadura em função da necrose foliar (Capítulos 6 e 7). As demais variáveis meteorológicas também foram as correspondentes ao ponto de 90 DAE. Deste modo, quanto maior a necrose, menor a aptidão do indivíduo.

A seleção de indivíduos, para serem os genitores da próxima geração, foi realizada pelo método do torneio, com 10 indivíduos em cada, de modo que foram sorteados 10 indivíduos da população e selecionado o que apresentou melhor aptidão, repetindo este processo 100 vezes, a fim de preencher a matriz de genitores. Na geração da próxima população, para a obtenção de cada um dos 400 indivíduos, eram sorteados 2 dos 100 genitores, obtendo o novo indivíduo a partir dos três primeiros genes provindos de um genitor e dos dois últimos do outro. Assim, no cruzamento foi utilizado crossover em ponto único. A taxa de mutação para a alteração randômica de um dos genes de cada indivíduo foi de 10%. Por fim, a solução considerada foi a com a melhor aptidão, dentre os indivíduos da última geração.

Após o processo de otimização ser realizado em cada ano agrícola, a codificação da época de semeadura, de 1 a 7, sendo o número 1 correspondente a 15 de abril e o 7 a 15 de julho, foi convertida na data real, com sua respectiva simulação da área foliar necrosada, em cada condição de aplicação de fungicida. A análise geral, independente de ano agrícola, pôde ser observada pelo resultado médio dos anos e também pela otimização direta por meio do algoritmo genético.

Na otimização da época de semeadura, com maximização da produtividade de grãos, utilizou-se uma metodologia muito semelhante. Houve diferença apenas no cálculo da aptidão, que foi determinada pela produtividade de grãos normalizada, de modo que quanto maior a produtividade, melhor a aptidão da solução. As variáveis área foliar necrosada, soma térmica e precipitação foram consideradas aos 90 DAE.

As descrições detalhadas das variáveis estudadas neste capítulo podem ser observadas no Capítulo 3. Os modelos utilizados, por sua vez, estão descritos no Capítulo 4 e foram empregados utilizando os softwares Genes e Matlab. Em todas as análises estatísticas foi considerado nível de significância de 5%. Também foram empregados softwares do pacote Microsoft Office.

9.3. Resultados e discussão

Para obtenção de modelos eficientes por redes neurais artificiais (RNAs), primeiramente se organizou as variáveis meteorológicas envolvidas no processo de cultivo, para posterior seleção das mais relevantes no processo de modelagem. Na Tabela 18 são apresentadas as médias das temperaturas mínimas, máximas e médias do ar, obtidas em períodos quinzenais precedentes a cada ponto indicado, de 60 a 120 DAE.

Tabela 18 – Médias da temperatura mínima, máxima e média, em períodos quinzenais durante o ciclo, em cada época de semeadura e ano agrícola.

Época Semeadura	Variável	DAE (2018)					DAE (2019)				
		60	75	90	105	120	60	75	90	105	120
15/04	\bar{T}_{min}	6	11	9	6	6	13	5	9	8	7
	\bar{T}_{max}	20	20	22	18	19	26	18	22	20	20
	\bar{T}_{med}	13	16	15	12	13	20	12	16	14	14
01/05	\bar{T}_{min}	11	9	6	6	8	6	8	9	8	8
	\bar{T}_{max}	20	22	18	19	23	19	22	19	21	23
	\bar{T}_{med}	16	15	12	13	16	12	15	14	14	16
15/05	\bar{T}_{min}	9	6	6	8	14	9	8	7	9	14
	\bar{T}_{max}	22	18	19	23	26	22	20	20	23	24
	\bar{T}_{med}	15	12	13	16	20	16	14	14	16	19
01/06	\bar{T}_{min}	4	5	11	14	16	8	7	11	11	14
	\bar{T}_{max}	18	21	24	25	24	21	21	25	24	28
	\bar{T}_{med}	11	13	18	20	20	15	14	18	17	21
15/06	\bar{T}_{min}	6	10	14	16	-	6	11	12	13	-
	\bar{T}_{max}	20	24	25	24	-	21	24	23	27	-
	\bar{T}_{med}	13	17	20	20	-	14	18	17	20	-
01/07	\bar{T}_{min}	10	14	16	-	-	12	10	14	-	-
	\bar{T}_{max}	24	25	24	-	-	24	24	28	-	-
	\bar{T}_{med}	17	20	20	-	-	18	17	21	-	-
15/07	\bar{T}_{min}	14	16	16	-	-	12	13	15	-	-
	\bar{T}_{max}	26	24	27	-	-	24	27	27	-	-
	\bar{T}_{med}	20	20	21	-	-	18	20	21	-	-
Época Semeadura	Variável	DAE (2020)					DAE (2021)				
		60	75	90	105	120	60	75	90	105	120
15/04	\bar{T}_{min}	15	6	10	7	7	8	5	7	5	12
	\bar{T}_{max}	25	15	22	22	19	18	20	21	20	25
	\bar{T}_{med}	20	11	16	15	13	13	13	14	13	18
01/05	\bar{T}_{min}	8	10	8	8	10	5	7	5	12	11
	\bar{T}_{max}	18	20	22	20	23	19	22	20	25	24
	\bar{T}_{med}	13	15	15	14	17	12	15	13	18	17
15/05	\bar{T}_{min}	10	7	7	12	12	6	5	11	12	12
	\bar{T}_{max}	22	22	19	24	23	21	21	25	25	24
	\bar{T}_{med}	16	14	13	18	18	14	13	18	18	18
01/06	\bar{T}_{min}	8	7	13	11	14	5	11	12	12	12
	\bar{T}_{max}	23	18	24	24	29	21	24	24	23	25
	\bar{T}_{med}	15	13	18	18	22	13	18	18	17	19
15/06	\bar{T}_{min}	7	13	11	14	-	11	12	12	12	-
	\bar{T}_{max}	19	24	25	29	-	25	24	24	25	-
	\bar{T}_{med}	13	18	18	22	-	18	18	18	18	-
01/07	\bar{T}_{min}	13	11	14	-	-	12	12	12	-	-
	\bar{T}_{max}	23	25	28	-	-	24	23	25	-	-
	\bar{T}_{med}	18	18	21	-	-	18	17	19	-	-
15/07	\bar{T}_{min}	12	14	12	-	-	11	12	13	-	-
	\bar{T}_{max}	24	29	31	-	-	24	25	26	-	-
	\bar{T}_{med}	18	22	22	-	-	18	18	19	-	-

-.: dados não apresentados devido ao término do ciclo de cultivo; DAE: dias após a emergência; \bar{T}_{min} : temperatura mínima média (°C); \bar{T}_{max} : temperatura máxima média (°C); \bar{T}_{med} : temperatura média (°C).

De modo geral, percebe-se que, à medida que se adia a semeadura, ocorre o aumento das variáveis ligadas à temperatura no fim do ciclo de desenvolvimento da aveia, fator que pode favorecer a ocorrência de doenças foliares. Além disso, Castro, Costa e Ferrari Neto (2012), ao abordar a Ecofisiologia da aveia, evidenciam que a temperatura tem efeito direto nas fases de desenvolvimento da espécie, desde a germinação até a maturação fisiológica, além de influenciar na realização de fotossíntese. Estudos também comprovam que há relação da temperatura na ocorrência e desenvolvimento de doenças foliares em cereais. Amado e Gheller (2018) avaliaram o efeito de fungicidas sobre a produtividade de trigo e outros parâmetros produtivos, ressaltando a influência da temperatura e da umidade na ocorrência de patógenos fúngicos na cultura. Strapasson et al. (2019) evidenciam o surgimento de doenças fúngicas em triticales na ocorrência de temperaturas mais elevadas aliadas à umidade. Corroborando com estes estudos, Pereira et al. (2020) realizaram uma revisão integrativa da literatura sobre a utilização de fungicida na cultura da aveia, evidenciando que a aveia é um cereal vulnerável, de modo que o aumento da temperatura e a presença de umidade favorecem a desenvolvimento de doenças fúngicas.

Assim, na Tabela 19 são apresentadas as temperaturas mínimas e máximas do ar pontuais ocorridas em períodos quinzenais anteriores aos pontos compreendidos entre 60 e 120 DAE, bem como a soma térmica acumulada do início do ciclo até cada um dos pontos estabelecidos.

Tabela 19 – Temperaturas mínima e máxima em períodos quinzenais e soma térmica acumulativa no decorrer do ciclo, em cada época de semeadura e ano agrícola.

Época Semeadura	Variável	DAE (2018)					DAE (2019)				
		60	75	90	105	120	60	75	90	105	120
15/04	<i>T_{min}</i>	-2	4	2	1	0	4	-4	1	-1	-1
	<i>T_{max}</i>	28	27	29	24	27	29	29	27	28	28
	<i>ST</i>	766	939	1110	1229	1359	872	990	1167	1318	1465
01/05	<i>T_{min}</i>	4	2	1	0	-2	-4	0	-1	-1	2
	<i>T_{max}</i>	27	29	24	27	29	29	27	28	28	33
	<i>ST</i>	648	818	937	1068	1241	747	916	1065	1219	1394
15/05	<i>T_{min}</i>	2	1	0	-2	10	1	-1	-1	2	7
	<i>T_{max}</i>	29	24	27	29	32	27	28	28	33	34
	<i>ST</i>	646	765	895	1069	1304	706	857	1005	1184	1410
01/06	<i>T_{min}</i>	0	-2	5	10	12	-1	-1	2	4	8
	<i>T_{max}</i>	27	27	29	32	32	28	28	34	33	36
	<i>ST</i>	583	716	923	1158	1402	663	810	1019	1217	1467
15/06	<i>T_{min}</i>	-2	-1	10	12	-	-1	2	4	7	-
	<i>T_{max}</i>	27	29	32	32	-	28	34	33	36	-
	<i>ST</i>	584	774	1007	1250	-	594	800	1002	1246	-
01/07	<i>T_{min}</i>	-1	10	12	-	-	2	4	10	-	-
	<i>T_{max}</i>	29	32	32	-	-	34	33	36	-	-
	<i>ST</i>	610	843	1085	-	-	681	878	1135	-	-
15/07	<i>T_{min}</i>	10	12	11	-	-	4	7	10	-	-
	<i>T_{max}</i>	32	32	31	-	-	34	36	36	-	-
	<i>ST</i>	658	892	1151	-	-	702	943	1199	-	-
Época Semeadura	Variável	DAE (2020)					DAE (2021)				
		60	75	90	105	120	60	75	90	105	120
15/04	<i>T_{min}</i>	3	-2	-1	-1	-2	3	-1	-2	-4	2
	<i>T_{max}</i>	29	23	28	28	28	23	27	29	29	34
	<i>ST</i>	773	873	1056	1218	1348	637	766	914	1046	1262
01/05	<i>T_{min}</i>	-2	-1	-1	2	-2	-1	-2	-4	2	5
	<i>T_{max}</i>	28	28	28	28	33	27	29	29	34	29
	<i>ST</i>	684	843	1004	1161	1352	581	740	869	1082	1284
15/05	<i>T_{min}</i>	-1	-1	-2	4	3	-2	-4	2	5	5
	<i>T_{max}</i>	28	28	28	33	33	28	29	34	32	33
	<i>ST</i>	666	823	958	1168	1376	562	696	903	1120	1328
01/06	<i>T_{min}</i>	-1	-2	4	3	8	-4	2	5	5	6
	<i>T_{max}</i>	28	28	33	33	38	29	34	29	33	33
	<i>ST</i>	682	812	1024	1232	1498	541	751	958	1160	1378
15/06	<i>T_{min}</i>	-2	4	3	8	-	2	5	5	6	-
	<i>T_{max}</i>	29	33	33	38	-	34	29	33	33	-
	<i>ST</i>	592	805	1012	1275	-	613	822	1030	1245	-
01/07	<i>T_{min}</i>	4	3	7	-	-	5	5	6	-	-
	<i>T_{max}</i>	33	33	38	-	-	29	33	33	-	-
	<i>ST</i>	705	913	1170	-	-	709	911	1129	-	-
15/07	<i>T_{min}</i>	3	8	7	-	-	5	6	10	-	-
	<i>T_{max}</i>	33	38	36	-	-	33	33	30	-	-
	<i>ST</i>	711	977	1242	-	-	759	976	1205	-	-

-.: dados não apresentados devido ao término do ciclo de cultivo; DAE: dias após a emergência; *T_{min}*: temperatura mínima (°C); *T_{max}*: temperatura máxima (°C); *ST*: soma térmica (°C dia⁻¹).

A observação de variáveis ligadas à temperatura se mostra importante devido às diferentes interferências que estes caracteres podem possuir sobre o cultivo de aveia. Nerbass Junior et al. (2010) apresentaram em seu trabalho a possibilidade de morte de plântulas de aveia por ocorrência de geadas. Além disso, os autores destacam o surgimento e maior severidade de doenças foliares fúngicas na aveia em razão do aumento da temperatura. A soma térmica, por sua vez, também se constitui como uma importante variável no cultivo da aveia, com influência sobre o desenvolvimento vegetal das plantas, podendo ser uma variável relevante em processos de modelagem (MAROLLI et al., 2018; DELATORRE et al., 2022). Borella et al. (2020) afirmam que as plantas acumulam diariamente uma quantidade de energia que pode ser dada pela soma térmica acumulada, caracterizando a energia disponível para a realização de seus processos metabólicos.

As doenças foliares, além de se desenvolverem em função da temperatura, também possuem relação com a umidade. Deste modo, na Tabela 20 são apresentadas as médias da umidade mínima, máxima e média relativas, em períodos quinzenais que antecedem cada ponto indicado, dos 60 aos 120 DAE.

Tabela 20 – Médias da umidade mínima, máxima e média, em períodos quinzenais durante o ciclo, em cada época de semeadura e ano agrícola.

Época Semeadura	Variável	DAE (2018)					DAE (2019)				
		60	75	90	105	120	60	75	90	105	120
15/04	\bar{U}_{min}	62	78	59	66	63	45	49	49	60	52
	\bar{U}_{max}	95	97	93	97	95	89	94	91	94	92
	\bar{U}_{med}	79	87	76	81	79	67	72	70	77	72
01/05	\bar{U}_{min}	78	59	66	63	50	50	45	62	51	47
	\bar{U}_{max}	97	93	97	95	90	94	91	94	92	92
	\bar{U}_{med}	87	76	81	79	70	72	68	78	72	69
15/05	\bar{U}_{min}	59	66	63	50	56	49	60	52	47	58
	\bar{U}_{max}	93	97	95	90	94	91	94	92	92	92
	\bar{U}_{med}	76	81	79	70	75	70	77	72	69	75
01/06	\bar{U}_{min}	61	56	56	60	56	55	48	47	53	46
	\bar{U}_{max}	96	92	93	95	93	93	93	90	94	92
	\bar{U}_{med}	78	74	74	78	75	74	70	68	73	69
15/06	\bar{U}_{min}	58	53	59	57	-	47	47	53	47	-
	\bar{U}_{max}	94	91	94	95	-	93	90	93	92	-
	\bar{U}_{med}	76	72	77	76	-	70	69	73	70	-
01/07	\bar{U}_{min}	53	59	57	-	-	48	50	46	-	-
	\bar{U}_{max}	91	94	95	-	-	89	94	91	-	-
	\bar{U}_{med}	72	77	76	-	-	69	72	68	-	-
15/07	\bar{U}_{min}	56	60	45	-	-	53	47	46	-	-
	\bar{U}_{max}	94	95	92	-	-	93	92	89	-	-
	\bar{U}_{med}	75	77	69	-	-	73	69	68	-	-
Época Semeadura	Variável	DAE (2020)					DAE (2021)				
		60	75	90	105	120	60	75	90	105	120
15/04	\bar{U}_{min}	67	77	64	61	59	76	61	56	54	62
	\bar{U}_{max}	92	96	94	95	95	96	96	93	94	92
	\bar{U}_{med}	79	86	79	78	77	86	78	74	74	77
01/05	\bar{U}_{min}	71	67	63	62	58	63	56	53	61	66
	\bar{U}_{max}	94	95	95	95	91	96	93	94	92	95
	\bar{U}_{med}	82	81	79	79	74	80	74	74	76	80
15/05	\bar{U}_{min}	63	63	60	64	67	57	51	58	63	72
	\bar{U}_{max}	94	95	95	91	96	96	92	92	93	96
	\bar{U}_{med}	78	79	78	77	81	76	71	75	78	84
01/06	\bar{U}_{min}	60	59	68	62	49	51	60	67	71	67
	\bar{U}_{max}	95	94	92	95	91	94	92	95	96	97
	\bar{U}_{med}	78	77	80	79	70	73	76	81	83	82
15/06	\bar{U}_{min}	59	70	60	49	-	57	66	72	67	-
	\bar{U}_{max}	94	93	95	91	-	92	94	96	96	-
	\bar{U}_{med}	76	81	78	70	-	75	80	84	81	-
01/07	\bar{U}_{min}	71	59	48	-	-	67	71	67	-	-
	\bar{U}_{max}	94	95	92	-	-	95	96	97	-	-
	\bar{U}_{med}	82	77	70	-	-	81	83	82	-	-
15/07	\bar{U}_{min}	64	47	34	-	-	70	67	62	-	-
	\bar{U}_{max}	95	91	90	-	-	96	97	96	-	-
	\bar{U}_{med}	80	69	62	-	-	83	82	79	-	-

-: dados não apresentados devido ao término do ciclo de cultivo; DAE: dias após a emergência; \bar{U}_{min} : umidade mínima média (%); \bar{U}_{max} : umidade máxima média (%); \bar{U}_{med} : umidade média (%).

Segundo Castro, Costa e Ferrari Neto (2012), a ocorrência de uma umidade adequada do ar é um fator importante para um cultivo satisfatório da aveia, pois a umidade elevada pode prejudicar o crescimento das plantas. Além disso, períodos de elevada umidade, aliados a temperaturas superiores a 18°C, favorecem o início e desenvolvimento de doenças foliares (CASTRO, COSTA, FERRARI NETO, 2012). Estudos desenvolvidos com cereais corroboram com estas informações. Oliveira et al. (2015) destacam o aumento do potencial de inóculo de patógenos fúngicos em função do aumento da umidade na cultura do trigo. Estudos publicados pela Embrapa Trigo afirmam que a umidade relativa, a precipitação e a temperatura podem interferir na taxa de progresso de epidemias a cada safra, ocasionando variações nos danos à cultura (LAU et al., 2020).

Na Tabela 21 há as umidades mínimas e máximas relativas pontuais obtidas em períodos quinzenais anteriores aos pontos compreendidos entre 60 e 120 DAE. Além disso, são apresentadas as precipitações acumuladas do início do ciclo até cada um dos pontos apresentados.

Tabela 21 – Umidade relativa mínima e máxima em períodos quinzenais e precipitação acumulativa no decorrer do ciclo, em cada época de semeadura e ano agrícola.

Época Semeadura	Variável	DAE (2018)					DAE (2019)				
		60	75	90	105	120	60	75	90	105	120
15/04	<i>Umin</i>	37	63	41	38	43	28	26	33	31	39
	<i>Umax</i>	99	98	99	100	98	97	99	98	98	98
	<i>PP</i>	134	182	245	249	293	254	299	366	397	415
01/05	<i>Umin</i>	63	41	38	43	26	32	26	31	39	31
	<i>Umax</i>	98	99	100	98	98	99	98	98	98	98
	<i>PP</i>	170	233	237	282	386	215	232	313	331	369
15/05	<i>Umin</i>	41	38	43	26	34	33	31	39	31	27
	<i>Umax</i>	99	100	98	98	98	98	98	98	98	99
	<i>PP</i>	189	193	238	342	406	164	194	213	253	350
01/06	<i>Umin</i>	38	26	31	34	24	31	39	31	20	26
	<i>Umax</i>	100	97	98	98	98	98	98	98	99	98
	<i>PP</i>	143	187	291	401	483	174	174	242	312	379
15/06	<i>Umin</i>	26	26	34	24	-	39	31	20	27	-
	<i>Umax</i>	98	98	98	98	-	98	98	99	98	-
	<i>PP</i>	159	264	373	440	-	154	222	291	358	-
01/07	<i>Umin</i>	26	34	24	-	-	31	20	23	-	-
	<i>Umax</i>	98	98	98	-	-	98	99	98	-	-
	<i>PP</i>	216	325	393	-	-	187	253	320	-	-
15/07	<i>Umin</i>	34	24	22	-	-	20	27	23	-	-
	<i>Umax</i>	98	98	97	-	-	99	98	98	-	-
	<i>PP</i>	217	327	410	-	-	183	250	305	-	-
Época Semeadura	Variável	DAE (2020)					DAE (2021)				
		60	75	90	105	120	60	75	90	105	120
15/04	<i>Umin</i>	51	57	41	52	33	54	48	39	42	33
	<i>Umax</i>	98	98	98	97	99	98	98	98	97	98
	<i>PP</i>	269	658	766	802	955	347	347	359	364	484
01/05	<i>Umin</i>	51	41	54	45	33	48	39	42	33	33
	<i>Umax</i>	98	98	97	99	97	98	98	97	98	98
	<i>PP</i>	466	696	732	885	888	273	285	290	390	467
15/05	<i>Umin</i>	41	52	33	42	35	45	39	33	33	54
	<i>Umax</i>	98	97	99	97	98	98	97	98	98	98
	<i>PP</i>	596	632	785	803	834	232	235	240	365	519
01/06	<i>Umin</i>	50	33	42	35	28	42	33	33	54	41
	<i>Umax</i>	97	99	97	98	97	97	98	98	98	98
	<i>PP</i>	574	727	750	776	779	116	140	297	421	446
15/06	<i>Umin</i>	33	42	35	28	-	33	33	54	41	-
	<i>Umax</i>	99	97	98	97	-	98	98	98	98	-
	<i>PP</i>	661	683	710	712	-	75	223	375	397	-
01/07	<i>Umin</i>	42	35	24	-	-	33	54	41	-	-
	<i>Umax</i>	97	98	97	-	-	98	98	98	-	-
	<i>PP</i>	277	304	306	-	-	193	317	342	-	-
15/07	<i>Umin</i>	35	28	23	-	-	54	41	35	-	-
	<i>Umax</i>	98	97	95	-	-	98	98	99	-	-
	<i>PP</i>	238	239	240	-	-	307	329	423	-	-

-: dados não apresentados devido ao término do ciclo de cultivo; DAE: dias após a emergência; *Umin*: umidade mínima (%); *Umax*: umidade máxima (%); *PP*: precipitação (mm).

A umidade do ar é um fator importante no desenvolvimento das plantas de aveia e valores elevados podem favorecer o surgimento e a progressão de patógenos fúngicos na cultura (PEREIRA et al., 2020). Outra variável relacionada e também importante no cultivo da aveia é a precipitação pluviométrica, de modo que a aveia necessita de umidade no solo para um bom desempenho, entretanto não requer grandes quantitativos durante o ciclo, sendo que chuvas em excesso podem prejudicar seu cultivo (CASTRO, COSTA, FERRARI NETO, 2012).

Na Tabela 22 são apresentadas as médias de área foliar necrosada obtidas a partir de 60 DAE em cada época de semeadura e ano agrícola, na ausência e presença de fungicida, juntamente às produtividades de grãos correspondentes, em uma análise concomitante das cultivares.

Tabela 22 – Médias de área foliar necrosada ao longo do ciclo e de produtividade de grãos, sem e com aplicação de fungicida, em cada época de semeadura e ano agrícola, independente de cultivar.

Época Semeadura	AFN (%) (SF)					PG (SF) (kg ha ⁻¹)	AFN (%) (CF)					PG (CF) (kg ha ⁻¹)
	60	75	90	105	120		60	75	90	105	120	
(URS Corona + URS Taura + URS Guria)												
2018												
15/04	0	0	1	15	66	1195	0	0	0	8	23	1559
01/05	0	0	1	6	56	1159	0	0	1	5	44	1853
15/05	0	0	1	11	84	1036	0	0	1	10	64	1517
01/06	1	1	4	60	99	955	1	1	3	51	93	1469
15/06	2	3	34	97	-	735	2	3	27	91	-	1083
01/07	2	13	93	-	-	545	2	13	86	-	-	670
15/07	8	60	100	-	-	131	8	58	100	-	-	201
2019												
15/04	2	8	42	61	89	204	2	7	33	46	77	404
01/05	1	2	5	38	81	1324	1	2	4	31	67	1586
15/05	2	3	5	45	97	1193	2	3	5	37	83	1450
01/06	3	4	10	62	96	1355	2	4	10	54	92	1570
15/06	3	5	28	80	-	835	3	5	24	72	-	1163
01/07	4	9	81	-	-	262	4	9	74	-	-	582
15/07	8	63	93	-	-	130	8	63	87	-	-	214
2020												
15/04	0	1	2	9	61	1448	0	1	1	7	52	1569
01/05	1	1	2	8	53	1579	1	1	2	7	41	1672
15/05	1	2	3	10	68	1839	1	2	3	5	54	2075
01/06	2	2	4	31	97	1570	2	2	4	29	95	1667
15/06	2	3	18	96	-	1318	2	3	14	92	-	1403
01/07	3	14	85	-	-	616	3	13	80	-	-	892
15/07	4	55	100	-	-	500	4	48	100	-	-	692
2021												
15/04	0	0	1	6	30	1840	0	0	0	5	28	2154
01/05	1	1	2	7	32	1685	0	1	2	6	30	1860
15/05	1	2	3	8	37	1466	1	1	3	7	34	1677
01/06	2	2	5	17	81	1195	1	2	4	11	63	1556
15/06	3	4	7	59	-	572	3	3	6	53	-	802
01/07	3	12	71	-	-	489	3	12	66	-	-	669
15/07	5	48	86	-	-	260	5	45	80	-	-	363

-: ausência de dados devido ao término do ciclo de cultivo; AFN: área foliar necrosada; PG: produtividade de grãos; SF: sem fungicida; CF: com fungicida.

De modo geral, os cenários de ausência e presença de fungicida apresentam resultados similares na indicação das épocas de semeadura que demonstram valores satisfatórios de área foliar necrosada e de produtividade de grãos nos anos agrícolas do estudo. Em 2018, as semeaduras de 15 de abril até 01 de junho evidenciam controle da necrose foliar até 90 DAE. No entanto, o período de proteção aumenta, chegando a 105 DAE, se observadas apenas as semeaduras de 15 de abril até 15 de maio, período em que se observam também as maiores produtividades de grãos.

Em 2019, as semeaduras de 01 de maio até 01 de junho apresentaram maior proteção natural às doenças foliares pela atuação da zona de escape, com valores reduzidos de necrose até 90 DAE. As médias mais elevadas de produtividade também foram obtidas nas épocas mencionadas. Destaca-se que os elevados valores de necrose observados na semeadura de 15 de abril, juntamente a reduzidas produtividades, se devem à ocorrência de geadas ocorridas no cultivo (Capítulo 5). Os anos de 2020 e 2021 apresentaram comportamentos similares, com controle satisfatório da doença até 105 DAE nas semeaduras de 15 de abril até 01 de junho, registrando também as maiores produtividades de grãos nestas semeaduras.

Considerando as variáveis meteorológicas relacionadas à temperatura, à umidade, à soma térmica e à precipitação, foram analisados modelos de regressão linear múltipla com conjuntos definidos de variáveis e também com variáveis selecionadas por Stepwise, para posterior definição dos caracteres relevantes a serem utilizados na modelagem da progressão de doenças foliares e otimização da época de semeadura, por inteligência artificial. Na Tabela 23, são apresentadas as seis configurações de modelo analisadas e seus resultados.

Tabela 23 – Coeficientes, erros médios e coeficientes de determinação dos modelos de regressão linear múltipla, independente de ano e de cultivar, nas condições sem e com fungicida.

Variável	Coeficientes dos modelos de regressão linear múltipla					
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
(URS Corona + URS Taura + URS Guria + 2018 + 2019 + 2020 + 2021)						
Sem fungicida						
Constante	482,64	470,29	448,23	-546,56	-39,93	-529
Época	2,43	2,40*	1,52	2,16	4,68	2,24
DAE	-0,50	-0,48*	0,86	0,9	1,05	0,91
\bar{T}_{min}	172,37	ns	-	6,15	-	194,03
\bar{T}_{max}	169,50	-3,33*	-	-1,84	-	186,08
\bar{T}_{med}	-345,35	ns	-	-	2,7	-375,84
Tmin	3,21	3,17*	3,15	-	-	-
Tmax	0,79	0,78*	-0,15	-	-	-
ST	0,12	0,12*	-	-	-	-
\bar{U}_{min}	-32,35	-1,25*	-	-2,39	-	100,87
\bar{U}_{max}	-28,84	2,58*	-	6,48	-	109,46
\bar{U}_{med}	62,44	ns	-	-	-1,12	-206,42
Umin	-0,32	-0,27*	-0,75	-	-	-
Umax	-6,59	-6,59*	-4,87	-	-	-
PP	-0,001	ns	-	-	-	-
E_{med} (AFN, %)	10,2	9,9	12,6	11,5	14,1	11,6
R ² (%)	80	80	68	72	64	72
Com fungicida						
Constante	449,72	469,84	484,52	-521,94	-29,19	-506,62
Época	2,05	2,07*	1,36	1,99	4,43	2,06
DAE	-0,53	-0,53*	0,68	0,72	0,86	0,73
\bar{T}_{min}	144,82	ns	-	5,89	-	163,96
\bar{T}_{max}	142,21	-2,89*	-	-1,44	-	156,67
\bar{T}_{med}	-289,94	ns	-	-	2,85	-316,23
Tmin	3,15	3,07*	3,06	-	-	-
Tmax	0,83	0,87*	0,02	-	-	-
ST	0,11	0,11*	-	-	-	-
\bar{U}_{min}	-22,91	-1,23*	-	-2,3	-	92,36
\bar{U}_{max}	-19,19	2,65*	-	6,23	-	100,65
\bar{U}_{med}	43,42	ns	-	-	-1,12	-189,24
Umin	-0,31	-0,28*	-0,74	-	-	-
Umax	-6,33	-6,64*	-5,17	-	-	-
PP	0,003	ns	-	-	-	-
E_{med} (AFN, %)	8,3	8,3	11,2	10,1	12,6	10,2
R ² (%)	81	81	68	72	63	73

-: coeficiente não calculado; Época: época de semeadura; DAE: dias após a emergência; E_{med} : média dos erros absolutos entre os valores simulados e observados de área foliar necrosada; AFN: área foliar necrosada; \bar{T}_{min} : temperatura mínima média do ar (°C); \bar{T}_{max} : temperatura máxima média do ar (°C); \bar{T}_{med} : temperatura média do ar (°C); Tmin: temperatura mínima do ar (°C); Tmax: temperatura máxima do ar (°C); ST: soma térmica (°C dia⁻¹); \bar{U}_{min} : umidade relativa mínima média (%); \bar{U}_{max} : umidade relativa máxima média (%); \bar{U}_{med} : umidade relativa média (%); Umin: umidade relativa mínima (%); Umax: umidade relativa máxima (%); PP: precipitação (mm); *: significativo a 5% de probabilidade de erro pelo teste t; R²: coeficiente de determinação; ns: não significativo; Modelo 1: regressão linear múltipla com a época de semeadura, dias após a emergência e todas as variáveis meteorológicas; Modelo 2: regressão linear múltipla com variáveis selecionadas pelo método Stepwise; Modelo 3: regressão linear múltipla com a época de semeadura, dias após a emergência, e as temperaturas e umidades mínimas e máximas pontuais; Modelo 4: regressão linear múltipla com a época de semeadura, dias após a emergência e os valores médios das temperaturas e umidades mínimas e máximas. Modelo 5: regressão linear múltipla com a época de semeadura, dias após a emergência, e a temperatura e umidade médias; Modelo 6: regressão linear múltipla com a época de semeadura, dias após a emergência e os valores médios das temperaturas e umidades mínimas, máximas e médias.

Observando a Tabela 23, percebe-se resultados similares nos cenários de ausência e presença de uso de fungicida. Os ajustes mais satisfatórios aos dados foram obtidos nos modelos 1 e 2, com coeficientes de determinação adequados e os menores erros médios quando comparados os valores observados e simulados de área foliar necrosada, independente de ano agrícola e de cultivar. Com base nos resultados obtidos, foram consideradas as variáveis selecionadas por Stepwise, do modelo 2, ou seja, a época de semeadura, os dias após a emergência, a temperatura máxima média, as temperaturas mínimas e máximas pontuais, a soma térmica, as umidades mínimas e máximas médias e as umidades mínimas e máximas pontuais, na composição dos modelos por redes neurais artificiais. Destaca-se que além de estes caracteres se mostrarem eficientes, com menor erro na simulação com ausência de fungicida, também evidenciam capacidade de simulação em menor número, em relação ao conjunto completo de variáveis presentes no modelo 1.

Na composição de modelos de simulação é importante a seleção de variáveis relevantes no processo, evitando o uso de caracteres redundantes. Autores vêm utilizando o modelo de Stepwise e a análise de regressão múltipla no estudo e decisão sobre variáveis relevantes em processos agrícolas. Milosavljevic, Esser e Crowder (2016) aplicaram a técnica de Stepwise na seleção de variáveis no estudo dos efeitos de fatores ambientais e agronômicos em pragas que habitam o solo em plantações de cereais. Mansouri et al. (2018) utilizaram a técnica de Stepwise para verificar os caracteres agronômicos com maior influência na variação total observada na produtividade de grãos de trigo sob distintas condições de crescimento. Alessi et al. (2021a) definiram por Stepwise as variáveis potenciais para construção de modelos de regressão linear múltipla na simulação de variáveis ligadas à qualidade nutricional de grãos de aveia em função de doses de nitrogênio e de elementos meteorológicos. Lopes et al. (2021) avaliaram o desempenho da predição da altura total de árvores de eucalipto por meio do uso de regressão linear múltipla via Stepwise e de redes neurais artificiais, o que evidencia também a relevância do uso de inteligência artificial na simulação de variados processos agrícolas.

Na obtenção da rede neural artificial mais adequada para a simulação da área foliar necrosada, após a normalização dos dados de entrada e de saída, foram testadas estruturas com 10 entradas, considerando de 10 a 20 neurônios na camada oculta e 1 neurônio na camada de saída, nos cenários de ausência e de presença de fungicida. Na Tabela 24, são apresentados os erros quadráticos médios e os coeficientes de determinação, do treino, da validação e do teste, obtidos em cada estrutura de RNA.

Tabela 24 – Erros quadráticos médios e coeficientes de regressão do treino, validação e teste de arquiteturas de rede neural artificial, com variável dependente relativa à área foliar necrosada.

Arquitetura	Erro quadrático médio*			R ² (%)		
	Treino	Validação	Teste	Treino	Validação	Teste
(URS Corona + URS Taura + URS Guria + 2018 + 2019 + 2020 + 2021)						
Sem fungicida						
10-10-1	0,0125	0,0152	0,0129	99	98	98
10-11-1	0,0102	0,0101	0,0167	99	99	98
10-12-1	0,0131	0,0161	0,0147	99	98	98
10-13-1	0,0106	0,0166	0,0138	99	98	99
10-14-1	0,0111	0,0124	0,0124	99	98	99
10-15-1	0,0109	0,0136	0,0118	99	98	99
10-16-1	0,0110	0,0151	0,0112	99	98	99
10-17-1	0,0117	0,0130	0,0215	99	99	98
10-18-1	0,0110	0,0111	0,0145	99	99	99
10-19-1	0,0108	0,0106	0,0124	99	99	98
10-20-1	0,0114	0,0136	0,0116	99	98	99
Com fungicida						
10-10-1	0,0106	0,0120	0,0150	99	98	98
10-11-1	0,0088	0,0108	0,0170	99	98	98
10-12-1	0,0108	0,0142	0,0147	99	98	98
10-13-1	0,0091	0,0142	0,0121	99	98	99
10-14-1	0,0088	0,0135	0,0138	99	98	98
10-15-1	0,0097	0,0166	0,0097	99	98	99
10-16-1	0,0098	0,0109	0,0121	99	98	99
10-17-1	0,0096	0,0144	0,0146	99	98	98
10-18-1	0,0096	0,0136	0,0095	99	98	98
10-19-1	0,0102	0,0128	0,0080	99	98	99
10-20-1	0,0106	0,0109	0,0148	99	98	98

R²: coeficiente de determinação; *: erros adimensionais atrelados aos dados normalizados.

Observando os resultados da Tabela 24, percebe-se erros quadráticos médios reduzidos e coeficientes de determinação elevados nas diferentes estruturas de RNA, em ambos cenários de uso de fungicida. Os menores erros quadráticos médios de treino e de validação, juntamente a um valor de erro satisfatório no teste, foram obtidos nas estruturas com 11 neurônios na camada oculta, tanto na ausência como na presença de fungicida, sendo escolhidas as redes neurais artificiais com esta estrutura para modelagem da área foliar necrosada em ambos contextos de aplicação de fungicida.

Assim, na Tabela 25 podem ser observados os valores de área foliar necrosada simulados pela RNA na ausência de fungicida, os valores médios de necrose obtidos pela bioexperimentação e os erros absolutos da simulação, em cada época de semeadura e ano agrícola, dos 60 DAE aos 120 DAE.

Tabela 25 – Validação da rede neural artificial de arquitetura 10-11-1 na simulação da área foliar necrosada em cada época de semeadura e ano agrícola sem aplicação de fungicida.

Época Semeadura	DAE	2018			2019			2020			2021		
		AFNo	AFNs	EA	AFNo	AFNs	EA	AFNo	AFNs	EA	AFNo	AFNs	EA
(URS Corona + URS Taura + URS Guria)													
15/04	60	0	1	1	2	2	0	0	0	0	0	0	0
	75	0	0	0	8	8	0	1	1	0	0	1	1
	90	1	1	0	42	43	1	2	2	0	1	0	1
	105	15	13	2	61	61	0	9	8	1	6	6	0
	120	66	65	1	89	90	1	61	62	1	30	27	3
01/05	60	0	0	0	1	1	0	1	1	0	1	1	0
	75	0	0	0	2	2	0	1	2	1	1	1	0
	90	1	1	0	5	6	1	2	3	1	2	2	0
	105	6	5	1	38	37	1	8	8	0	7	6	1
	120	56	56	0	81	79	2	53	51	2	32	31	1
15/05	60	0	1	1	2	1	1	1	0	1	1	0	1
	75	0	0	0	3	1	2	2	2	0	2	2	0
	90	1	3	2	5	5	0	3	4	1	3	3	0
	105	11	11	0	45	46	1	10	11	1	8	9	1
	120	84	84	0	97	97	0	68	61	7	37	34	3
01/06	60	1	0	1	3	4	1	2	2	0	2	1	1
	75	1	2	1	4	3	1	2	3	1	2	2	0
	90	4	4	0	10	9	1	4	4	0	5	4	1
	105	60	61	1	62	62	0	31	35	4	17	17	0
	120	99	99	0	96	97	1	97	98	1	81	80	1
15/06	60	2	1	1	3	3	0	2	2	0	3	4	1
	75	3	4	1	5	5	0	3	4	1	4	5	1
	90	34	35	1	28	27	1	18	16	2	7	7	0
	105	97	97	0	80	81	1	96	97	1	59	60	1
	120	-	-	-	-	-	-	-	-	-	-	-	-
01/07	60	2	2	0	4	4	0	3	2	1	3	4	1
	75	13	14	1	9	11	2	14	13	1	12	12	0
	90	93	94	1	81	82	1	85	85	0	71	71	0
	105	-	-	-	-	-	-	-	-	-	-	-	-
	120	-	-	-	-	-	-	-	-	-	-	-	-
15/07	60	8	8	0	8	8	0	4	5	1	5	5	0
	75	60	60	0	63	60	3	55	60	5	48	50	2
	90	100	100	0	93	92	1	100	100	0	86	86	0
	105	-	-	-	-	-	-	-	-	-	-	-	-
	120	-	-	-	-	-	-	-	-	-	-	-	-

-: ausência de dados devido ao término do ciclo de cultivo; DAE: dias após a emergência; AFNo: área foliar necrosada observada (%); AFNs: área foliar necrosada simulada (%); EA: erro absoluto (%).

Observando os cenários apresentados na Tabela 25, percebe-se erros absolutos bastante reduzidos, indicando uma elevada capacidade de reconhecimento de padrões e generalização de informações pela rede neural artificial desenvolvida com arquitetura 10-11-1.

Na análise dos resultados da simulação com a presença de uma aplicação de fungicida, na Tabela 26 são apresentadas as médias de área foliar necrosada obtidas experimentalmente, os valores

simulados pela RNA e os respectivos erros absolutos, para cada época de semeadura em cada ano agrícola do estudo, dos 60 DAE até os 120 DAE.

Tabela 26 – Validação da rede neural artificial de arquitetura 10-11-1 na simulação da área foliar necrosada em cada época de semeadura e ano agrícola com uma aplicação de fungicida.

Época Semeadura	DAE	2018			2019			2020			2021		
		AFNo	AFNs	EA	AFNo	AFNs	EA	AFNo	AFNs	EA	AFNo	AFNs	EA
(URS Corona + URS Taura + URS Guria)													
15/04	60	0	0	0	2	2	0	0	0	0	0	0	0
	75	0	0	0	7	9	2	1	1	0	0	1	1
	90	0	0	0	33	33	0	1	2	1	0	2	2
	105	8	9	1	46	46	0	7	7	0	5	4	1
	120	23	26	3	77	76	1	52	50	2	28	27	1
01/05	60	0	0	0	1	1	0	1	0	1	0	0	0
	75	0	0	0	2	2	0	1	2	1	1	0	1
	90	1	1	0	4	4	0	2	2	0	2	2	0
	105	5	4	1	31	30	1	7	7	0	6	6	0
	120	44	48	4	67	67	0	41	43	2	30	28	2
15/05	60	0	1	1	2	2	0	1	0	1	1	1	0
	75	0	1	1	3	2	1	2	2	0	1	2	1
	90	1	1	0	5	5	0	3	3	0	3	3	0
	105	10	9	1	37	38	1	5	4	1	7	7	0
	120	64	60	4	83	86	3	54	55	1	34	36	2
01/06	60	1	1	0	2	3	1	2	2	0	1	1	0
	75	1	1	0	4	3	1	2	2	0	2	3	1
	90	3	4	1	10	10	0	4	4	0	4	5	1
	105	51	52	1	54	55	1	29	30	1	11	11	0
	120	93	93	0	92	92	0	95	93	2	63	56	7
15/06	60	2	2	0	3	3	0	2	2	0	3	3	0
	75	3	2	1	5	4	1	3	4	1	3	4	1
	90	27	31	4	24	25	1	14	14	0	6	6	0
	105	91	91	0	72	71	1	92	91	1	53	53	0
	120	-	-	-	-	-	-	-	-	-	-	-	-
01/07	60	2	3	1	4	3	1	3	3	0	3	4	1
	75	13	14	1	9	10	1	13	13	0	12	13	1
	90	86	85	1	74	72	2	80	80	0	66	64	2
	105	-	-	-	-	-	-	-	-	-	-	-	-
	120	-	-	-	-	-	-	-	-	-	-	-	-
15/07	60	8	8	0	8	9	1	4	3	1	5	5	0
	75	58	55	3	63	56	7	48	49	1	45	41	4
	90	100	99	1	87	87	0	100	100	0	80	78	2
	105	-	-	-	-	-	-	-	-	-	-	-	-
	120	-	-	-	-	-	-	-	-	-	-	-	-

-: ausência de dados devido ao término do ciclo de cultivo; DAE: dias após a emergência; AFNo: área foliar necrosada observada (%); AFNs: área foliar necrosada simulada (%); EA: erro absoluto (%).

No cenário de uma aplicação de fungicida também se observam resultados satisfatórios, com erros absolutos bastante reduzidos, apontando para a capacidade da rede neural artificial desenvolvida em realizar simulações confiáveis para a área foliar necrosada.

Com as RNAs definidas, otimizou-se a época de semeadura com o emprego de algoritmo genético, minimizando a área foliar necrosada aos 90 DAE, ponto mais oportuno de análise da necrose foliar, conforme relatado nos Capítulos 6 e 7. Na Tabela 27 pode ser observada a época ótima em cada ano agrícola, a média dos resultados e a otimização da época de semeadura independente de ano agrícola, assim como a área foliar necrosada simulada em cada caso.

Tabela 27 – Otimização da época de semeadura por algoritmo genético, com minimização da área foliar necrosada aos 90 dias após a emergência.

Ano	Época codificada otimizada	Época real otimizada	Área foliar necrosada simulada (%)
(URS Corona + URS Taura + URS Guria)			
Sem fungicida			
2018	1,6	25/04	0
2019	3,6	25/05	3
2020	3,6	25/05	1
2021	1,0	15/04	0
Média	2,4	05/05	1
Geral (AG)	1,6	25/04	2
Ano	Época codificada otimizada	Época real otimizada	Área foliar necrosada simulada (%)
(URS Corona + URS Taura + URS Guria)			
Com fungicida			
2018	1,0	15/04	0
2019	2,4	05/05	2
2020	2,4	05/05	1
2021	1,6	25/04	0
Média	1,9	30/04	1
Geral (AG)	2,0	01/05	0

AG: algoritmo genético.

Na ausência de fungicida, observando os anos agrícolas, percebe-se que a melhor época de semeadura está entre 15 de abril e 25 de maio, com média em 05 de maio e indicação de 25 de abril na análise geral. No cenário de uma aplicação de fungicida, ao observar os anos de cultivo, há semeaduras indicadas de 15 de abril até 05 de maio, com data média em 30 de abril e a otimização independente de ano indica para realização de semeadura em 01 de maio.

O algoritmo genético indica datas de semeadura pontuais na otimização, no entanto, com base nos capítulos anteriores é possível ampliar o período de semeadura recomendado, de modo que no cenário de ausência de fungicida há uma indicação preliminar de que a semeadura da aveia pode ser realizada de 25 de abril a 01 de junho, com intervalo ideal de 25 de abril a 15 de maio. Com uma

aplicação de fungicida, este intervalo pode ser determinado de 30 de abril a 01 de junho, evidenciando como período mais oportuno 30 de abril a 15 de maio.

A inteligência artificial possui aplicabilidade na análise de variados processos agrícolas e ambientais. Soares et al. (2015) empregaram redes neurais artificiais para realizar a predição da produtividade de milho, com base em variáveis morfológicas da cultura. Safa et al. (2016) utilizaram redes neurais artificiais e modelos de regressão linear para a previsão de emissões de CO₂ de insumos agrícolas na produção de trigo. Melo Junior, Farias e Kato (2016) aplicaram redes neurais artificiais na classificação de agroecossistemas na região amazônica. Singh e Misra (2017) utilizaram algoritmos genéticos para a identificação de doenças foliares em plantas através da segmentação de imagens.

Na obtenção das RNAs à simulação da produtividade de grãos, após a normalização dos dados, foram testadas estruturas com 4 entradas, 1 neurônio de saída e de 4 a 8 neurônios na camada oculta. Na Tabela 28 é possível observar os erros quadráticos médios e os coeficientes de determinação do treino, da validação e do teste, em cada condição de aplicação de fungicida.

Tabela 28 - Erros quadráticos médios e coeficientes de regressão do treino, validação e teste de arquiteturas de rede neural artificial, com variável dependente relativa à produtividade de grãos.

Arquitetura	Erro quadrático médio*			R ² (%)		
	Treino	Validação	Teste	Treino	Validação	Teste
(URS Corona + URS Taura + URS Guria + 2018 + 2019 + 2020 + 2021)						
Sem fungicida						
4-4-1	0,0763	0,0475	0,1042	85	90	79
4-5-1	0,0371	0,0382	0,0285	91	93	94
4-6-1	0,0337	0,0377	0,0333	92	92	93
4-7-1	0,0439	0,0381	0,0374	91	89	91
4-8-1	0,0295	0,0372	0,0393	93	90	93
Com fungicida						
4-4-1	0,0378	0,0408	0,0341	91	89	89
4-5-1	0,0482	0,0462	0,0291	88	89	92
4-6-1	0,0327	0,0482	0,0345	92	88	91
4-7-1	0,0322	0,0517	0,0533	92	87	89
4-8-1	0,0319	0,0373	0,0502	92	90	91

R²: coeficiente de determinação; *: erros adimensionais atrelados aos dados normalizados.

Observando a tabela, de modo geral se percebe reduzidos erros quadráticos médios e elevados coeficientes de determinação. Os menores erros quadráticos médios de treino e de validação ocorrem nas estruturas com 8 neurônios ocultos, sem e com o uso de fungicida. Nessas estruturas de rede, também é possível observar erros quadráticos médios de teste e coeficientes de determinação satisfatórios. Desse modo, na Tabela 29 são validadas as RNAs com estruturas 4-8-1.

Tabela 29 – Validação das redes neurais artificiais de arquitetura 4-8-1 na simulação da produtividade de grãos em cada época de semeadura e ano agrícola, sem e com uso de fungicida.

Época Semeadura	2018			2019			2020			2021		
	PGo	PGs	EA	PGo	PGs	EA	PGo	PGs	EA	PGo	PGs	EA
(URS Corona + URS Taura + URS Guria)												
Sem fungicida												
15/04	1195	1126	69	204	209	5	1448	1410	38	1840	1889	49
01/05	1159	1210	51	1324	1288	36	1579	1598	19	1685	1777	92
15/05	1036	1207	171	1193	1180	13	1839	1827	12	1466	1270	196
01/06	955	975	20	1355	1310	45	1570	1552	18	1195	1215	20
15/06	735	708	27	835	730	105	1318	1345	27	572	579	7
01/07	545	568	23	262	253	9	616	586	30	489	490	1
15/07	131	142	11	130	131	1	500	509	9	260	281	21
EA _{med}	53			31			22			55		
Com fungicida												
15/04	1559	1661	102	404	365	39	1569	1511	58	2154	2166	12
01/05	1853	1675	178	1586	1579	7	1672	1690	18	1860	1816	44
15/05	1517	1604	87	1450	1481	31	2075	2118	43	1677	1590	87
01/06	1469	1545	76	1570	1314	256	1667	1709	42	1556	1530	26
15/06	1083	1147	64	1163	1149	14	1403	1392	11	802	755	47
01/07	670	683	13	582	563	19	892	869	23	669	698	29
15/07	201	225	24	214	189	25	692	695	3	363	361	2
EA _{med}	78			56			28			35		

PGo: produtividade de grãos observada (kg ha⁻¹); PGs: produtividade de grãos simulada (kg ha⁻¹); EA: erro absoluto (kg ha⁻¹); EA_{med}: erro absoluto médio (kg ha⁻¹).

Ao observar os erros absolutos de simulação, em cada época de semeadura e ano de cultivo, percebe-se valores reduzidos. Na ausência de aplicação de fungicida, os erros médios por ano agrícola são menores que 60 kg ha⁻¹ e na presença de uso de fungicida são menores que 80 kg ha⁻¹. Esses resultados dão base em afirmar que as RNAs desenvolvidas são eficientes na simulação da produtividade de grãos. Assim, procedeu-se à otimização da época de semeadura, com maximização dessa variável (Tabela 30).

Tabela 30 – Otimização da época de semeadura por algoritmo genético, com maximização da produtividade de grãos.

Ano	Época codificada otimizada	Época real otimizada	Produtividade de grãos simulada (kg ha ⁻¹)
(URS Corona + URS Taura + URS Guria)			
Sem fungicida			
2018	3,5	23/05	1462
2019	3,5	23/05	1453
2020	2,4	05/05	1879
2021	1,5	23/04	2078
Média	2,7	10/05	1718
Geral (AG)	2,4	05/05	2037
(URS Corona + URS Taura + URS Guria)			
Com fungicida			
2018	1,6	25/04	1759
2019	1,6	25/04	1851
2020	2,4	05/05	2315
2021	1,0	15/04	2166
Média	1,6	25/04	2023
Geral (AG)	1,6	25/04	2060

AG: algoritmo genético.

Na ausência de fungicida, ao otimizar a época de semeadura com maximização da produtividade de grãos, observando os resultados em cada ano, há datas de semeadura compreendidas de 23 de abril a 23 de maio, obtendo-se, na média dos anos, a data de 10 de maio. Na otimização geral, independente de ano agrícola, a data de 05 de maio foi determinada. Na presença de uma aplicação de fungicida, os anos de cultivo evidenciam as melhores semeaduras no período de 15 de abril a 05 de maio, com data média em 25 de abril, que coincide com a otimização independente de ano agrícola.

Dessa forma, considerando a otimização da época de semeadura com maximização da produtividade de grãos e também com a minimização da área foliar necrosada pelo ataque de doenças, além dos resultados de capítulos anteriores, é possível afirmar que o intervalo de semeadura ideal ocorre de 25 de abril a 10 de maio, podendo ser estendido até 01 de junho, na ausência de fungicida. No uso de fungicida, o intervalo ideal ocorre de 25 de abril a 15 de maio, também podendo ser estendido até 01 de junho.

Diversos estudos empregam inteligência artificial na análise de processos envolvendo cereais. Zheng et al. (2017) aplicaram redes neurais artificiais e algoritmos genéticos para otimizar a condição de fermentação do germe de trigo. Etminan et al. (2018) empregaram redes neurais artificiais para identificar os melhores índices de tolerância à seca, considerando experimentações com trigo. Dornelles et al. (2018) utilizaram inteligência artificial via redes neurais artificiais e algoritmos genéticos na simulação da produtividade de grãos de aveia e otimização da densidade de semeadura,

nos principais sistemas de sucessão do sul do Brasil. Em estudo semelhante ao realizado neste trabalho, Gümüşçü, Tenekeci e Bilgili (2020) estimaram a data de semeadura do trigo utilizando algoritmos de aprendizado artificial com base em dados climáticos.

9.4. Conclusões

As variáveis meteorológicas mais relevantes na composição de modelos voltados à simulação da área foliar necrosada são a temperatura máxima média, as temperaturas mínimas e máximas pontuais, as umidades mínimas e máximas médias e as umidades mínimas e máximas pontuais, obtidas em períodos quinzenais durante o ciclo, e a soma térmica acumulativa durante o cultivo, aliadas à época de semeadura e aos dias após a emergência. As redes neurais artificiais simulam com eficiência a necrose foliar a partir dos caracteres indicados, sem e com o uso de fungicida.

Há resultados satisfatórios de simulação da produtividade de grãos em ambos cenários de uso de fungicida, considerando os efeitos da época de semeadura, da área foliar necrosada, da soma térmica e da precipitação. Com a otimização da época de semeadura, na ausência de fungicida, minimizando a área foliar necrosada e maximizando a produtividade de grãos, indica-se que o período ideal de semeadura da aveia ocorre de 25 de abril a 10 de maio, com possível extensibilidade até 01 de junho. Com o uso de fungicida, o período ideal fica entre 25 de abril e 15 de maio, também podendo ser estendido de modo análogo à ausência de fungicida. Destaca-se que, em ambos casos de uso de fungicida, o período ideal antecede a atual recomendação de semeadura para a região noroeste do Rio Grande do Sul.

10. CONSIDERAÇÕES FINAIS

As semeaduras de 01 de maio e 15 de maio recebem destaque, pois evidenciam maior controle da necrose foliar pelo ataque de doenças até 105 DAE. Em semeaduras mais tardias, principalmente após o período de recomendação, além de ocorrer maior pressão de inóculo fúngico, a condição estabelecida de atraso já acarreta em problemas relacionados aos componentes de produtividade devido ao encurtamento do ciclo. Além disso, na semeadura de 15 de abril, as plantas podem ser suscetíveis à ocorrência de geadas, reduzindo drasticamente a produtividade de grãos.

Dentre os momentos analisados, o ponto de 90 dias após a emergência (DAE) é o mais adequado para análise da necrose foliar decorrente do ataque de doenças, na avaliação das épocas de semeadura da aveia. Os menores valores de área foliar necrosada aos 90 DAE, bem como, as maiores médias de produtividade de grãos de aveia acontecem em semeaduras no intervalo de 01 de maio a 15 de maio. Quando avaliados os resultados de adaptabilidade e estabilidade e analisados os caracteres de produtividade e de qualidade industrial e química, é possível estender este intervalo, com destaque para as semeaduras de 01 de maio, 15 de maio e 01 de junho. Com a otimização da época de semeadura, minimizando a área foliar necrosada e maximizando a produtividade de grãos, indica-se que o período ideal de semeadura da aveia ocorre de 25 de abril a 10 de maio, anterior à atual recomendação de semeadura para a região noroeste do RS, com possível extensibilidade até 01 de junho.

11. REFERÊNCIAS

AFFÉRRI, F. S.; DOTTO, M. A.; CARVALHO, E. V. de; PELUZIO, J. M.; FARIA, L. A. de. Avaliação de genótipos de milho: adaptabilidade, estabilidade e estratificação ambiental. **Revista Sítio Novo**, Palmas, v. 4, n. 2, p. 81-92, 2020.

AGOSTINETTO, L.; CASA, R. T.; BOGO, A.; SACHS, C.; SOUZA, C. A.; REIS, E. M.; CUNHA, I. C. da. Barley spot blotch intensity, damage, and control response to foliar fungicide application in southern Brazil. **Crop Protection**, v. 67, p. 7-12, 2015. DOI: 10.1016/j.cropro.2014.09.012

ALESSI, O.; DE MAMANN, A. T. W.; DORNELLES, E. F.; HENRICHSEN, L.; ROSSI, D. S.; SILVA, J. A. G. da. Regressões lineares na estimativa da taxa de produtividade e área foliar necrosada em cultivares de aveia para redução no uso de fungicida. **VIII Seminário de Inovação e Tecnologia**, 2018a.

ALESSI, O.; DORNELLES, E. F.; DE MAMANN, A. T. W.; KRAISIG, A. R.; HENRICHSEN, L.; MAROLLI, A.; PANSERA, V.; SILVA, J. A. G. da. Aplicação de Modelos de Regressão e de Adaptabilidade e Estabilidade na Identificação de Cultivares de Aveia Branca com Maior Resistência Genética a Doenças Foliaves. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 6, n. 2, 2018b.

ALESSI, O.; MANTAI, R. D.; SILVA, J. A. G. da; BÁRTA, R. L.; PANSERA, V.; KRAISIG, A. R.; BERLEZI, J. D.; MATTER, E. M. Regressão linear múltipla envolvendo variáveis biológicas e ambientais na simulação de indicadores da composição química de grãos de aveia. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 8, n. 1, 2021a. DOI: 10.5540/03.2021.008.01.0469

ALESSI, O.; SILVA, J. A. G. da; PANSERA, V.; ROSA, J. A. da; CARVALHO, I. R.; LAUTENCHLEGER, F.; JUNG, M. S.; COLET, C. de F.; TEIXEIRA, C. A. M. B.; BASSO, N. C. F.; TISOTT, J. V.; BABESKI, C. M. Simulation of wheat yield by nitrogen and ear components in harvest prediction analysis. **Genetics and Molecular Research**, v. 20, n. 4, p. 1-13, 2021b. DOI: 10.4238/gmr18943

ALMEIDA, F. C. de; NAKAO, S. H. Redes neurais. In: CORRAR, L. J.; PAULO, E.; DIAS FILHO, J. M. (Coord.). **Análise multivariada**. São Paulo: Atlas, 2014.

ALVES, E. D. L. Influência das variáveis naturais e antrópicas nos padrões da temperatura de superfície: análise por meio de regressão linear múltipla. **R. Ra'e Ga**, Curitiba, v. 38, p. 345-364, 2016.

ALVES, M. F.; LOTUFO, N. D. P.; LOPES, M. L. M. Seleção de variáveis Stepwise aplicadas em redes neurais artificiais para previsão de demanda de cargas elétricas. **Proceeding Series of the Brazilian Society of Applied and Computational Mathematics**, v. 1, n. 1, 2013. DOI: 10.5540/03.2013.001.01.0144

AMADO, J. G.; GHELLER, J. A. Controle de Doenças foliares em trigo com fungicidas. **Revista Cultivando o saber**, p. 55-62, 2018.

AMADOR, V. C.; RODRIGUES, R. L.; OLIVEIRA, F. F.; TRINDADE, R. M. Simulação e avaliação de ancoramento do herbicida glifosato a proteína glutatona s-transferase phi 3 em *Oryza sativa* japônica. **Revista Saúde & Ciência Online**, v. 7, n. 2, p. 252-262, 2018.

AMARAL, R. T. do; NASCIMENTO, M.; NASCIMENTO, A. C. C.; BARROSO, L. A. Análise de correspondência múltipla na avaliação da associação entre respostas de métodos de adaptabilidade e estabilidade em alfafa. *Revista da Estatística UFOP*, v. 3, 2014.

AZIZAH, E. Stabilitas Hasil Galur Harapan Kedelai Hitam Di Lokasi Jawa Barat Berdasarkan Metode Eberhart-Russel dan Metode AMMI Biplot. **Jurnal Agrotek Indonesia** (Indonesian Journal of Agrotech), v. 1, n. 1, 2016. DOI: 10.33661/jai.v1i1.251

BARBOSA, J. C. Modelagem e modelos matemáticos na educação científica. **Alexandria Revista de Educação em Ciência e Tecnologia**, v. 2, n. 2, p. 69-85, 2009.

BARILI, L. D.; VALE, N. M. do; AMARAL, R. de C.; CARNEIRO, J. E. de S.; SILVA, F. F. e; CARNEIRO, P. C. S. Adaptabilidade e estabilidade e a produtividade de grãos em cultivares de feijão preto recomendadas no Brasil nas últimas cinco décadas. **Ciência Rural**, v. 45, n. 11, 2015. DOI: 10.1590/0103-8478cr20141383

BASSO, N. C. F.; BABESKI, C. M.; HEUSER, L. B.; ZARDIN, N. G.; BANDEIRA, W. J. A.; CARVALHO, I. R.; COLET, C. de F.; SILVA, J. A. G. da. The production without pesticides in the

control of oat foliar diseases: resistance inducer by silicon and potassium and escape zone. **Research, Society and Development**, v. 11, n. 8, p. e47611831191, 2022. DOI: 10.33448/rsd-v11i8.31191.

BATISTA, L. O.; SILVA, G. A. de; ARAÚJO, V. S.; ARAÚJO, V. J. S.; REZENDE, T. S.; GUIMARÃES, A. J.; SOUZA, P. V. de C. Utilização de Redes Neurais Nebulosas para criação de um Sistema Especialista em Invasões Cibernéticas. **ICOFCS**, 2018. DOI: 10.5769/C2018002

BAZZO, J. H. B.; GARCIA, E. B.; CARDOSO, C. P.; ZUCARELI, C. Qualidade fisiológica de sementes de trigo em resposta a diferentes doses de nitrogênio via solo e foliar. **Revista Terra & Cultura: Cadernos de Ensino e Pesquisa**, Londrina, v. 36, n. 70, 2020.

BHARDWAJ, N. R.; BANYAL, D. K.; ROY, A. K. Prediction model for assessing powdery mildew disease in common Oat (*Avena sativa* L.). **Crop Protection**, v. 146, 2021. DOI: <https://doi.org/10.1016/j.cropro.2021.105677>

BICALHO, T. F.; OLIVEIRA, A. M. E. de; ALBUQUERQUE, C. J. B.; FREITAS, R. S. de. Adaptabilidade e estabilidade de linhagens de sorgo granífero em Uberaba - MG, Patos de Minas - MG e Votuporanga – SP. **Caderno De Ciências Agrárias**, v. 10, n. 3, p. 1-8, 2018.

BICUDO, M. A. V. Meta-análise: seu significado para a pesquisa qualitativa. **REVEMAT**, Florianópolis, v. 9, p. 7-20, 2014. DOI: 10.5007/1981-1322.2014v9nespp7

BORELLA, D. R.; SOUZA, A. P. de; SILVA, A. C. da; FELIPE, R. T. A.; SILVA, K. N. C.; SOUZA, J. H. G. de. Exigências térmicas e filocrono de *Dipteryx alatas* sob níveis de sombreamento na transição Cerrado-Amazônia. **Scientia Plena**, v. 16, n. 5, 2020. DOI: 10.14808/sci.plena.2020.051702

BORÉM, A.; MIRANDA, G. V. **Melhoramento de plantas**. Viçosa: UFV, 2005.

BORGES, F. M. O.; FERREIRA, W. M.; SALIBA; E. O. S. Espectroscopia de reflectância no infravermelho próximo NIRS (“near infrared reflectance spectroscopy”) princípios e aplicações na nutrição e alimentação animal. *Revista CFMV*, v. 24, p. 43-58, 2001.

BORGES, K. S.; ZAIDEN, L. C.; CRUZ, N. A. C. Oficinas de Uso de Plantas Medicinais: cultivando a saúde integral e o saber feminino. **Cadernos de Agroecologia**, v. 10, n. 3, 2015.

BORNHOFEN, E.; BENIN, G.; STORCK, L.; WOYANN, L. G.; DUARTE, T.; STOCO, M. G.; MARCHIORO, S. V. Métodos estatísticos para estudo de adaptabilidade e estabilidade em trigo. **Bragantia**, Campinas, v. 76, n. 1, p. 1-10, 2017. DOI: 10.1590/1678-4499.557

BRAGA, A. D. P.; CARVALHO, A.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. [S.l.]: Livros Técnicos e Científicos, 2000.

CAMPOS, B. P. F.; SILVA, G. F. da; BINOTI, D. H. B.; MENDONÇA, A. R. de; LEITE, H. G. Descrição do perfil do tronco de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**, Colombo, v. 37, n. 90, p. 99-107, 2017.

CARDOSO, L. S.; VARONE, F.; JUNGES, A. H.; TAZZO, I. F. Condições meteorológicas ocorridas em julho de 2021 e situação das principais culturas agrícolas no estado do Rio Grande do Sul. **Comunicado Agrometeorológico**, Porto Alegre, n. 28, p. 6-23, jul. 2021.

CARGNELUTTI FILHO, A.; STORCK, L.; RIBOLDI, J.; GUADAGNIN, J. P. Associação entre métodos de adaptabilidade e estabilidade em milho. **Ciência Rural**, Santa Maria, v. 39, n. 2, p. 340-347, 2009. DOI: 10.1590/S0103-84782008005000080

CARGNIN, A.; SOUZA, M. A. de; FOGAÇA, C. M. Comparação de métodos de análise de adaptabilidade e estabilidade em trigo. **Ceres**, v. 55, n. 4, p. 243-250, 2008.

CARGNIN, A.; SOUZA, M. A. de; ROCHA, V. S.; MACHADO, J. C.; PICCINI, E. Tolerância ao estresse térmico em genótipos de trigo. **Pesq. agropec. bras.**, v. 41, n. 8, p. 1269-1276, 2006.

CARVALHO, A. D. F. de; SILVA, G. O. da; PEREIRA, R. B.; PINHERO, J. B. Análise de fatores e regressão bissegmentada no estudo da adaptabilidade e estabilidade de cenoura. **Revista Ceres**, Viçosa, v. 61, n. 6, p. 932-940, 2014. DOI: 10.1590/0034-737X201461060007

CASTILHO, C. L. de; VOLPIANO, C. G.; AMBROSINI, A.; ZULPO, L.; PASSAGLIA, L.; BENEDUZI, A.; SÁ, E. L. S. de. Growth-promoting effects of Bradyrhizobium soybean symbionts in black oats, white oats, and ryegrass. **Brazilian Journal of Microbiology**, v. 52, n. 3, p. 1451–1460, 2021. DOI: <https://doi.org/10.1007/s42770-021-00523-1>

CASTRO, G. S.A.; COSTA, C. H. M.; FERRARI NETO, J. Ecofisiologia da aveia branca. **Scientia Agraria Paranaensis**, v. 11, n. 3, p. 1-15, 2012.

CÉSAR, A. da S.; GOMES, J. C.; STALIANO, C. D.; FANNI, M. L.; BORGES, M. C. Elaboração de pão sem glúten. **Revista Ceres**, v. 53, n. 306, p. 150-155, 2006.

COELHO, A. P.; FARIA, R. T. de; DALRI, A. B.; PALARETTI, L. F.; ZANINI, J. R. Clorofilômetro portátil como forma de manejo da irrigação e adubação nitrogenada em aveia-branca. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v. 12, n. 2, p. 2542-2553, 2018. DOI: 10.7127/rbai.v12n200803

CORREA, S. M. B. B. **Probabilidade e estatística**. 2. ed. Belo Horizonte: PUC Minas Virtual, 2003.

COSTA NETO, P. L. de O. **Estatística**. São Paulo: Blucher, 2002.

CRESTANI, M.; CARVALHO, F. I. F. de; OLIVEIRA, A. C. de; SILVA, J. A. G da; GUTKOSKI, L. C.; SARTORI, J. F.; BARBIERI, R. L.; BARETTA, D. Conteúdo de β -glucana em cultivares de aveia-branca cultivadas em diferentes ambientes. **Pesquisa agropecuária brasileira**, v. 45, n. 3, 2010. DOI: 10.1590/S0100-204X2010000300005

CRUZ, C. D.; REGAZZI, A. J. **Modelos biométricos aplicados ao melhoramento genético**. 2. ed. Viçosa: UFV, 2001.

CRUZ, C. D. **Programa Genes**: versão Windows – Aplicativo computacional em genética e estatística. Viçosa: UFV, 2001.

CRUZ, C. D. **Programa GENES**: biometria. Viçosa: UFV, 2006a.

CRUZ, C. D. **Programa GENES**: estatística experimental e matrizes. Viçosa: UFV, 2006b.

CRUZ, C. D. **Programa GENES**: análise multivariada e simulação. Viçosa: UFV, 2006c.

CRUZ, C. D.; TORRES, R. A. A.; VENCOVSKY, R. An alternative approach to the stability analysis proposed by Silva and Barreto. **Revista Brasileira de Genética**, v. 12, p. 567-580, 1989.

CUNHA, B. A. da; NEGREIROS, M. M. de; ALVES, K. A.; TORRES, J. P. Influência da época de semeadura na severidade de doenças foliares e na produtividade do milho safrinha. **Summa Phytopathol.**, v. 45, n. 4, 2019. DOI: 10.1590/0100-5405/188038

DELATORRE, C. A.; DUARTE, V. de F.; WAIRICH, A.; FRAGA, G. P.; RIBEIRO, M. P.; LAZZARI, H. E. Desenvolvimento de aveia em resposta à temperatura. **Ciência Rural**, v. 52, n. 1, 2022. DOI: <https://doi.org/10.1590/0103-8478cr20210198>

DEMARCHI, J. C.; PIROLI, E. L. Análise dos efeitos de geadas na cobertura vegetal do município de Cândido Mota – SP, Brasil, por meio de índices de vegetação. **Boletim Goiano de Geografia**, Goiânia, v. 35, n. 3, p. 554-573, 2015.

DOLINSKY, M.; OLIVEIRA, R. M. da S. C. de; ROCHA, G. de S.; BARROSO, S. G.; DORES, S. M. C. das; AZEREDO, V. B. Efeitos do consumo de alimentos funcionais no perfil lipídico e estado nutricional de idosos. **Internacional Journal of Cardiovascular Sciences**, v. 28, n. 5, p. 400-408, 2015. DOI: 10.5935/2359-4802.20150059

DORNELLES, E. F. **Modelagem matemática da elaboração de grãos de aveia mais saudáveis à alimentação pela redução de uso de fungicida e maior intervalo entre a colheita e última aplicação**. 2018. 139 p. Dissertação (Mestrado em Modelagem Matemática) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, 2018.

DORNELLES, E. F.; KRAISIG, A. R.; SILVA, J. A. G. da; SAWICKI, S.; ROOS-FRANTZ, F.; CARBONERA, R. Artificial intelligence in seeding density optimization and yield simulation for oat. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 22, n. 3, p. 183-188, 2018. DOI:10.1590/1807-1929/agriambi.v22n3p183-188

DORNELLES, E. F.; SILVA, J. A. G. da; COLET, C. de F.; FRAGA, D. da R.; PANSERA, V.; ALESSI, O.; CARVALHO, I. R.; LAUTENCHLEGER, F.; ROSA, J. A. da; WARMBIER, E.; JUNG, M. S.; POLANCZYK, A. K. The efficiency of Brazilian oat cultivars in reducing fungicide use for greater environmental quality and food safety. **Australian Journal of Crop Science**, v. 15, n. 7, p. 1058-1065, 2021. DOI: 10.21475/ajcs.21.15.07.p3175

DVOŘÁČEK, V.; JÁGR, M.; KOTRBOVÁ KOZAK, A.; CAPOUCHOVÁ, I.; KONVALINA, P.; FAMĚRA, O.; HLÁSNÁ CEPKOVÁ, P. Avenanthramides: Unique Bioactive Substances of Oat

Grain in the Context of Cultivar, Cropping System, Weather Conditions and Other Grain Parameters.

Plants, v. 10, n. 11, 2485, 2021. DOI: <https://doi.org/10.3390/plants10112485>

EBERHART, A. S.; RUSSEL, W. A. Stability parameters for comparing varieties. **Crop Sci.**, v. 6, p. 36-40, 1966.

EIGENTLER, L.; SHERRATT, J. A. Analysis of a model for banded vegetation patterns in semi-arid environments with nonlocal dispersal. **Journal of Mathematical Biology**, v. 77, p.739-763, 2018.

DOI: 10.1007/s00285-018-1233-y

ELITH, J.; LEATHWICK, J. R. Species Distribution Models: Ecological Explanation and Prediction Across Space and Time. **Annual Review of Ecology, Evolution and Systematics**, v. 40, p. 677-697, 2009. DOI: 10.1146/annurev.ecolsys.110308.120159

ETMINAN, A.; POUR-ABOUGHADAREH, A.; MOHAMMADI, R.; SHOOSHTARI, L.; YOUSEFIAZARKHANIAN, M.; MORADKHANI, H. Determining the best drought tolerance indices using Artificial Neural Network (ANN): Insight into application of intelligent agriculture in agronomy and plant breeding. **Cereal Research Communications**, v. 17, 2018. DOI: 10.1556/0806.46.2018.057

FÁVERO, L. P.; BELFIORE, P. **Manual de Análise de Dados: Estatística e Modelagem Multivariada com Excel, SPSS E Stata**. 1. ed. Rio de Janeiro: Elsevier, 2017.

FAVERO, L. P. et al. **Análise de dados: modelagem multivariada para tomada de decisões**. Rio de Janeiro: Elsevier, 2009.

FERNANDES, A. M. da R. **Inteligência artificial: noções gerais**. Florianópolis: VisualBooks, 2005.

FERNANDES, J. G. L.; SILVA, N. A. M. da; BROCK, T. R.; QUEIROGA, A. P. G. de; RODRIGUES, L. C. Inteligência artificial: uma visão geral. **Revista Eletrônica Engenharia Estudos e Debates**, v. 1, 2018.

FERREIRA, A. C. de B.; BORIN, A. L. D. C.; BRITO, G. G. de; SILVA FILHO, J. L. da; BOGIANI, J. C. Épocas de semeadura, cultivares e densidades de plantas para algodão adensado em segunda safra. **Pesqui. Agropecu. Trop.**, v. 45, n. 4, 2015. DOI: 10.1590/1983-40632015v4536869

FERREIRA NETO, J. A.; MOREIRA, M. C. de O.; SANTOS JUNIOR, E. C. dos; PALEO, U. F.; LANI, J. L. Aptidão agrícola e algoritmos genéticos na organização espacial em projetos de reforma agrária. **Revista Brasileira de Ciência de Solo**, v. 35, n. 1, p. 255-261, 2011.

FERREIRA, P. H. B.; MATOS, L. M. A.; ASSIS, A. L. de; CABACINHA, C. D.; ARAÚJO JÚNIOR, C. A. Influência dos parâmetros da metaheurística simulated annealing em um problema de planejamento da produção florestal. **Caderno de Ciências Agrárias**, v. 10, n. 1, p. 59–67, 2018.

FOLLMANN, D. N.; CARGNELUTTI FILHO, A.; LÚCIO, A. D.; SOUZA, V. Q. de; CARAFFA, M.; WARTHA, C. A. Genetic progress in oat associated with fungicide use in Rio Grande do Sul, Brazil. **Genetics and molecular research**, v. 15, n. 4, p. 1-12, 2016. DOI: 10.4238/gmr15049390.

FONSECA, J. E. da; ALCÂNTARA, R.; BARBOSA, J. E. do C.; CAMPOS, P. K. de. Poluição da água e solo por agrotóxicos. **Revista científica e-locução**, 15, 2019. ISSN: 2238-1899.

FORTE, C. T.; GALON, L.; BEUTLER, A. N.; PERIN, G. F.; PAULETTI, E. S. S.; BASSO, F. J. M.; HOLZ, C. M.; SANTIN, C. O. Coberturas vegetais do solo e manejo de cultivo e suas contribuições para as culturas agrícolas. **Revista Brasileira de Ciências Agrárias**, Recife, v. 13, n. 1, 2018. DOI: 10.5039/agraria.v13i1a5504

FREITAS, T. F. S. de.; SILVA, P. R. F. da; MARIOT, C. H. P.; MENEZES, V. G.; ANGHINONI, I.; BREDEMEIER, C.; VIEIRA, V. M. Produtividade de arroz irrigado e eficiência da adubação nitrogenada influenciadas pela época da semeadura. **Revista Brasileira de Ciência de Solo**, v. 32, p. 2397-2405, 2008.

FRANÇA, L. C. de J.; SILVA, J. B. L. da; LISBOA, G. dos S.; LIMA, T. P.; FERRAZ, F. T. Elaboração de Carta de Risco de Contaminação por Agrotóxicos para a Bacia do Riacho da Estiva, Brasil. **Floresta e Ambiente**, v. 23, n. 4, p. 463-474, 2016. DOI: 10.1590/2179-8087.141415

FÜHR, M. J. **Análise da expressão fenotípica do caráter florescimento em aveia hexaplóide**. Salão UFRGS 2014: SIC - XXVI Salão de Iniciação Científica da UFRGS. Porto Alegre, 2014.

GAUCH, H. G.; ZOBEL, R. W. Predictive and postdictive success of statistical analyses of yield trials. **Theoretical and Applied Genetics**, v. 76, p. 1-10, 1988.

GHASEMIAN, A., HOSSEINMARDI, H., CLAUSET, A.: Evaluating overfit and underfit in models of network community structure. **Cornell University Library**, v. 2, p. 1-17, 2018.

GHINI, R.; HAMADA, E.; BETTIOL, W. Climate change and plant diseases. **Sci. Agric.**, Piracicaba, v. 65, p. 98-107, 2008.

GOLDBARG, M. C. (Org). **Otimização combinatória e programação linear: modelos e algoritmos**. 2. ed. Rio de Janeiro: Elsevier, 2005.

GOLDBERG, D. E. **Genetic Algorithm in Search, Optimization and Machine Learning**. Massachusetts: Addison-Wesley, 1989.

GOMES, F. M.; PEREIRA, F. M.; MARINS, F. A. S.; SILVA, M. B. Estudo comparativo entre os métodos gradiente reduzido generalizado e algoritmo genético em otimização com múltiplas respostas. **Revista Produção Online**. Florianópolis, v. 17, n. 2, p. 592-619, 2017.

GONTIJO, M. D. Simulação e otimização em circuito de flotação. **Revista Petra**, v. 4, n. 1, p. 61-75, 2018.

GORASH, A.; ARMONIENE, R.; FETCH, M.; LIATUKAS, Z.; DANYTE, V. Aspects in oat breeding: nutrition quality, nakedness and disease resistance, challenges and perspectives. **Annals of Applied Biology**, v. 171, p. 281-302, 2017. DOI: 10.1111/aab.12375

GRIGOLO, S.; FIOREZE, A. C. da C. L.; DENARDI, S.; VACARI, J. Implicações da análise univariada e multivariada na dissimilaridade de acessos de feijão comum. **Revista de Ciências Agroveterinárias**, Lages, v. 17, n. 3, p. 351-360, 2018. DOI: 10.5965/223811711732018351.

GUERREIRO, R. M.; OLIVEIRA, N. C. de. Produtividade de grãos de aveia branca submetida a doses de trinexapac-ethyl. Campo Digital: **Rev. Ciências Exatas e da Terra e Ciências Agrárias**, v. 7, n. 1, p. 27-36, 2012.

GÜMÜŞÇÜ, A.; TENKECI, M. E.; BILGILI, A. V. Estimation of wheat planting date using machine learning algorithms based on available climate data. **Sustainable Computing: Informatics and Systems**, v. 28, 100308, 2020. DOI: 10.1016/j.suscom.2019.01.010

GUZATTI, G.C.; DUCHINI, P.G.; SBRISSIA, A.F.; RIBEIRO FILHO, H.M.N. Aspectos qualitativos e produção de biomassa em pastos de aveia e azevém cultivados puros ou consorciados e submetidos a pastejo leniente. **Arq. Bras. Med. Vet. Zootec.**, v. 67, n. 5, p. 1399-1407, 2015. DOI: 10.1590/1678-4162-8103

HAIR JR., J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman, 2009.

HAWERROTH, M. C.; BARBIERI, R. L.; SILVA, J. A. G. da; CARVALHO, F. I. F. de; OLIVEIRA, A. C. de. **Importância e dinâmica de caracteres na aveia produtora de grãos**. Pelotas: Embrapa Clima Temperado, 2014.

HENNING, F. A.; MERTZ, L. M.; ZIMMER, P. D.; TEPLIZKY, M. D. F. Qualidade fisiológica, sanitária e análise de isoenzimas de sementes de aveia-preta tratadas com diferentes fungicidas. **Revista brasileira de sementes**, v. 31, n. 3, 2009. DOI: <https://doi.org/10.1590/S0101-31222009000300007>

JARDIM, I. C. S. F.; ANDRADE, J. de A. Resíduos de agrotóxicos em alimentos: uma preocupação ambiental global – um enfoque às maçãs, **Química Nova**, v. 32, n. 4, p. 996-1012, 2009. DOI: 10.1590/S0100-40422009000400031.

JOBIM, P. F. C.; NUNES, L. N.; GIUGLIANI, R.; CRUZ, I. B. M. da. Existe uma associação entre mortalidade por câncer e uso de agrotóxicos? Uma contribuição ao debate. **Ciência & Saúde Coletiva**, v. 15, n. 1, p. 277-288, 2010. DOI: 10.1590/S1413-81232010000100033

KIMATI, H.; AMORIM, L.; REZENDE, J. A. M.; BERGAMIN FILHO, A.; CAMARGO, L. E. A. **Manual de fitopatologia**. 4. ed. São Paulo: Agronômica Ceres, 2005.

KOVALESKI, S. **Caracterização, quantificação e modelagem de danos provocados pela geada no período reprodutivo da canola**. 2021. 214 p. Tese (Doutorado em Agronomia) - Universidade Federal de Santa Maria, Santa Maria, 2021.

KOZA, J. Genetic Programming as a Means for Programming Computers by Natural Selection. **Statistics and Computing**, v. 4, n. 2, p. 87-112, 1994.

KRAISIG, A. R.; SCREMIN, O. B.; MANTAI, R. D.; MAROLLI, A.; DE MAMANN, A. T. W.; BREZOLIN, A. P.; SCREMIN, A. H.; SILVA, J. A. G. da. Análise da Superfície de Resposta sobre o Uso do Biopolímero Hidrogel no Sistema Soja/Aveia. **Proceeding Series of the Brazilian Society of Applied and Computational Mathematics**, v. 6, n. 1, 2018. DOI: 10.5540/03.2018.006.01.0316

KRÜGER, C. A. M. B.; MEDEIROS, S. L. P.; SILVA, J. A. G. da; DALMAGO, G. A.; VALENTINI, A. P. F.; WAGNER, J. F. Rapeseed population arrangement defined by adaptability and stability parameters. **Revista brasileira de engenharia agrícola e ambiental**, Campina Grande, v. 20, n. 1, p. 36-41, 2016. DOI: 10.1590/1807-1929/agriambi.v20n1p36-41

KUINCHTNER, A.; BURIOL, G. A. Clima do estado do Rio Grande do Sul segundo a classificação climática de Köppen e Thornthwaite. **Disciplinarum Scientia**, v. 2, n. 1, p. 171-182, 2001.

LÂNGARO, N. C.; CARVALHO, I. Q. de. (Org.). **Indicações técnicas para a cultura da aveia: XXXIV Reunião da Comissão Brasileira de Pesquisa de Aveia** Fundação ABC. Passo Fundo: Ed. Universidade de Passo Fundo, 2014.

LAU, D.; SANTANA, F. M.; MACIEL, J. L. N.; FERNANDES, J. M. C.; COSTAMILAN, L. M.; CHAVES, M. S.; LIMA, M. I. P. M. Doenças de trigo no Brasil. In: PIRES, J. L. F.; VARGAS, L.; CUNHA, G. R. da (Ed.). **Trigo no Brasil: bases para produção competitiva e sustentável**. Passo Fundo: Embrapa Trigo, 2011. Cap. 12, p. 283-324.

LAU, D.; SBALCHEIRO, C. C.; MARTINS, F. C.; SANTANA, F. M.; MACIEL, J. L. N.; FERNANDES, J. M. C.; COSTAMILAN, L. M.; LIMA, M. I. P. M.; KUHNEM, P.; CASA, R. T. **Principais doenças do trigo no sul do Brasil: diagnóstico e manejo**. Passo Fundo, RS: Embrapa Trigo, 2020.

LIMA, L. H. da S.; BRACCINI, A. L.; SCAPIM, C. A.; PICCININ, G. G.; PONCE, R. M. Adaptability and stability of canola hybrids in different sowing dates. **Revista Ciência Agronômica**, Fortaleza, v. 48, n. 2, p. 374-380, 2017. DOI: 10.5935/1806-6690.20170043

LINDEN, R. **Algoritmos Genéticos**. 3. ed. Rio de Janeiro: Editora Ciência Moderna Ltda., 2012.

LIU, N.; NGUYEN, H.; WISMER, W.; TEMELLI, F. Development of an orange-flavoured functional beverage formulated with beta-glucan and coenzyme Q10-impregnated beta-glucan. **Journal of Functional Foods**, v. 47, p. 397-404, 2018. DOI: 10.1016/j.jff.2018.05.037

LOPES, I. L. E.; ARAÚJO, L. A.; MIRANDA, E. N.; ABREU, V. de S.; GOMES, V. de S.; ALMEIDA, B. C.; GONÇALVES, A. F. A.; BARBOSA, L. O.; GOMIDE, L. R. Aplicação de técnicas de regressão linear e aprendizagem de máquinas na predição da altura total de árvores de *Eucalyptus spp.* In: OLIVEIRA, R. J. de (Org.). **Silvicultura e manejo florestal: técnicas de utilização e conservação da natureza**, v. 1, 2021. DOI: 10.37885/201102132

LOPES, M. L. M.; CHAVARETTE, F. R.; COSSI, A. M. Avaliação do modelo de regressão linear múltipla e redes neurais artificiais na previsão do ganho de massa em animais. **Brazilian Journal of Biosystems Engineering**, v. 11, n. 1, p. 1-17, 2017. DOI: 10.18011/bioeng2017v11n1p01-17

LORENCETTI, C.; CARVALHO, F. I. F. de; MARCHIORO, V. S.; BENIN, G.; OLIVEIRA, A. C. de; FOSS, E. L. Implicações da aplicação de fungicida na adaptabilidade e estabilidade de rendimento de grãos em aveia branca. **Ciência Rural**, Santa Maria, v. 34, n. 3, p. 693-700, 2004. DOI: 10.1590/S0103-84782004000300007

LOVATTO, M.; SILVA, G. B. P. da; COELHO, F. K.; MARTINELLI, J. A.; PACHECO, M. T.; FEDERIZZI, L. C.; DELATORRE, C. A. Crown rust on oat genotypes with different levels of resistance: damages and losses. **Ciência Rural**, Santa Maria, v. 51, n. 3, 2021. DOI: 10.1590/0103-8478cr20200298

LUCENA, R. S.; DANTAS, J. L. L. Divergência genética por meio de caracteres morfoagronômicos e de qualidade de frutos de linhagens e híbridos de mamoeiro. **Magistra**, Cruz das Almas, v. 27, n. 1, p. 101-109, 2015.

LUDWIG, M. P.; DUTRA, L. M. C.; LUCCA FILHO, O. A.; ZABOT, L.; UHRY, D.; LISBOA, J. I.; JAUER, A. Características morfológicas de cultivares de soja convencionais e Roundup Ready™ em função da época e densidade de semeadura. **Ciência Rural**, v. 40, n. 4, 2010. DOI: 10.1590/S0103-84782010000400003

MA, B. L.; ZHENG, Z.; PAGEAU, D.; VERA, C.; FREGEAU-REID, J.; XUE, A.; YAN, W. Nitrogen and phosphorus uptake, yield and agronomic traits of oat cultivars as affected by fertilizer

N rates under diverse environments. **Nutrient Cycling in Agroecosystems**, v. 108, p. 245-265, 2017. DOI: 10.1007/s10705-017-9848-8

MAGALHÃES, M. N.; LIMA, A. C. P. de. **Noções de probabilidade e estatística**, 7. ed. São Paulo: Editora da Universidade de São Paulo, 2013.

MAGNABOSCO, M. E. B.; AMARAL, D. R. Incidência de brusone em diferentes épocas de semeadura e genótipos de trigo. **Scientia Agraria Paranaensis**, v. 17, n. 3, p. 311–316, 2018.

MALANCHEN, B. E.; B. E.; SILVA, F. A. DA; GOTTARDI, T.; TERRA, D. A.; BERNARDI, D. M. Composição e propriedades fisiológicas e funcionais da aveia. **FAJ Journal of Health**, v. 1, n. 2, p. 185-200, 2019. ISSN 2674-550X. DOI: <https://doi.org/10.35984/fjh.v1i2.86>

MANSOURI, A.; OUDJEHIH, B.; BENBELKACEM, A.; FELLAHI, Z. E. A.; BOUZERZOUR, H. Variation and Relationships among Agronomic Traits in Durum Wheat [*Triticum turgidum* (L.) Thell. ssp. *turgidum* conv. *durum* (Desf.) MacKey] under South Mediterranean Growth Conditions: Stepwise and Path Analyses. **International Journal of Agronomy**, Article ID 8191749, p. 1-11, 2018. DOI: <https://doi.org/10.1155/2018/8191749>

MANTAI, R. D.; SILVA, J. A. G. da; SAUSEN, A. T. Z. R.; COSTA, J. S. P.; FERNANDES, S. B. V.; UBESSI, C. A eficiência na produção de biomassa e grãos de aveia pelo uso do nitrogênio. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 19, n. 4, p. 343-349, 2015. DOI: 10.1590/1807-1929/agriambi.v19n4p343-349

MAROLLI, A.; MANTAI, R. D.; SCREMIN, O. B.; MAMMANN, A. T. W. de; SCREMIN, A. H.; BREZOLIN, A. P.; SILVA, J. A. G. da. Modelagem matemática da produtividade de grãos e acamamento da aveia com uso de regulador de crescimento. **Proceeding Series of the Brazilian Society of Applied and Computational Mathematics**, v. 5, n. 1, p. 1-7, 2017. DOI: 10.5540/03.2017.005.01.0397

MAROLLI, A.; SILVA, J. A. G. da; SAWICKI, S.; BINELO, M. O.; SCREMIN, A. H.; REGINATTO, D. C.; DORNELLES, E. F.; LAMBRECHT, D. M. A simulação da biomassa de aveia por elementos climáticos, nitrogênio e regulador de crescimento. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 70, n. 02, 2018. DOI: <https://doi.org/10.1590/1678-4162-9504>

MARQUES, M. C.; HAMAWAKI, O. T.; SEDIYAMA, T.; BUENO, M. R.; REIS, M. S.; CRUZ, C. D.; NOGUEIRA, A. P. O. Adaptabilidade e estabilidade de genótipos de soja em diferentes épocas de semeadura. **Biosci. j. (Online)**, v. 27, n. 1, p. 59-69, 2011.

MARTINS, A. P. M.; DEBASTIANI, A. B.; PELISSARI, A. L.; MACHADO, S. do A.; SANQUETTA, C. R. Estimativa do Afilamento do Fuste de Araucária Utilizando Técnicas de Inteligência Artificial. **Floresta e Ambiente**, v. 24, p. 1-10, 2017. DOI: 10.1590/2179-8087.023416

MATIAS, R. G. P.; BRUCKNER, C. H.; SILVA, D. F. P. da; CARNEIRO, P. C. S.; OLIVEIRA, J. A. A. de. Adaptability and stability of peach and nectarine cultivars in subtropical climate. **Revista Ceres**, Viçosa, v. 64, n. 5, p. 516-522, 2017. DOI: 10.1590/0034-737X201764050009

McCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v.52, p.115-133, 1943.

MEDEIROS, C. A. B.; BUENO, Y. M.; SA, T. D. de A.; VIDAL, M. C.; ESPINDOLA, J. A. A. **Fome zero e agricultura sustentável**: contribuições da Embrapa. Brasília, DF: Embrapa, 2018.

MELO, P de C.; ANTUNES, A. M.; ALVES, P. H. R. D.; ALVES, J. A. A.; DEVILLA, I. A. Modelagem matemática das curvas de secagem de grãos de feijão carioca. **Agrária**, Recife, v. 11, n. 3, p. 247-252, 2016. DOI: 10.5039/agraria.v11i3a5377

MELO, P. G. S.; ALVARES, R. C.; PEREIRA, H. S.; BRAZ, A. J. B. P.; FARIA, L. C.; MELO, L. C. Adaptability and stability of common bean genotypes in family farming systems. **Pesquisa Agropecuária Brasileira**, Brasília, v. 53, n. 2, p. 189-196, 2018. DOI: 10.1590/S0100-204X2018000200007

MELO JUNIOR, J. G. D.; FARIAS, F. S.; KATO, O. R. Assessment of the Sustainability of Agroecosystems in the Amazon Region Using Neural Artificial Networks. **IEEE Latin America Transactions**, v. 14, n. 8, p. 3804-3810, 2016. DOI: 10.1109/TLA.2016.7786367

MEDEIROS, A. de S.; ALVES, F. I. dos S.; FERRAZ, R. L. de S.; CAMPOS, A. C.; QUEIROZ, M. M. F. de; MAGALHÃES, I. D. Crescimento e alocação de fitomassa do quiabeiro submetido à doses de nitrogênio e irrigação com água residuária. **Revista Brasileira de Agricultura Irrigada**, v. 12, n. 3, p. 2621-2631, 2018. DOI: 10.7127/rbai.v12n300775

MILOSAVLJEVIC, I.; ESSER, A. D.; CROWDER, D. W. Effects of environmental and agronomic factors on soil-dwelling pest communities in cereal crops. **Agriculture, Ecosystems and Environment**, v. 225, p. 192-198, 2016.

DOI: 10.1016/j.agee.2016.04.006

MONTEIRO, A. S. **Regressão linear múltipla**. 2016. Disponível em: <<https://pt.scribd.com/document/320082531/Cap12-Regressao-Linear-Multipla-4>>. Acesso em: abr. 2019.

MONTEIRO, F. J. F.; PELUZIO, J. M.; AFFÉRI, F. S.; CARVALHO, E. V. de; SANTOS, W. F. dos. Adaptabilidade e estabilidade de cultivares de soja para produtividade de óleo nos grãos. **Revista Agrarian**, Dourados, v. 10, n. 35, p. 18-21, 2017. DOI: 10.30612/agrarian.v10i35.3836

MONTEIRO, F. J. F.; PELUZIO, J. M.; AFFÉRI, F. S.; CARVALLO, E. V. de; SANTOS, W. F. dos. Correlação entre parâmetros de quatro metodologias de adaptabilidade e estabilidade em cultivares de soja em ambientes distintos. **Revista de la Facultad de Agronomía**, La Plata, v. 114, n. 2, p. 143-147, 2015.

MORAIS, N. B. de; BEZERRA, F. M. L.; MEDEIROS, J. F. de; CHAVES, S. W. P. Resposta de plantas de melancia cultivadas sob diferentes níveis de água e de nitrogênio. **Revista Ciência Agronômica**, Fortaleza, v. 39, n. 3, p.369-377, 2008.

MOREIRA, G. L. P.; MOREIRA, E. de S.; PRATES, C. J. N.; CARDOSO JÚNIOR, N. dos S.; VIANA, A. E. S.; LOPES, S. C. Produtividade de biomassa e composição bromatológica de genótipos de aveia forrageira em Vitória da Conquista, BA. **Scientia Plena**, v. 13, n. 3, 2017.

DOI: 10.14808/sci.plena.2017.030201

MOREIRA, R. P. C.; MARTINS, F. V. C.; WANNER, E. F. CardNutri: Um software de planejamento de cardápios nutricionais semanais para alimentação escolar aplicando inteligência artificial. **Revista Eletrônica de Comunicação, Informação & Inovação em Saúde**, Rio de Janeiro, v. 11, n. 4, p. 1-11, 2017.

MORETTIN, P. A.; BUSSAB, W. O. **Estatística Básica**, 8. ed. São Paulo: Saraiva, 2013.

MORIN, P. V.; STUMM, E. M. F. Transtornos mentais comuns em agricultores, relação com agrotóxicos, sintomas físicos e doenças preexistentes. **Psico**, v. 49, n. 2, p. 196-205, 2018. DOI: 10.15448/1980-8623.2018.2.26814

MOUSAVI-AVVAL, S. H.; RAFIEE, S.; SHARIFI, M.; HOSSEINPOUR, S.; NOTARNICOLA, B.; TASSIELLI, G.; RENZULLI, P. A. Application of multi-objective genetic algorithms for optimization of energy, economics and environmental life cycle assessment in oilseed production. **Journal of Cleaner Production**, v. 140, p. 804-815, 2017. DOI: 10.1016/j.jclepro.2016.03.075

NANCARROW, N.; CONSTABLE, F. E.; FINLAY, K. J.; FREEMAN, A. J.; RODONI, B. C.; TREBICKI, P.; VASSILIADIS, S.; YEN, A. L.; LUCK, J. E. The effect of elevated temperature on Barley yellow dwarf virus-PAV in wheat. **Virus Research**, v. 186, p. 97–103, 2014.

NASCIMENTO, L. B. P.; PINTO, V. P.; AMORA, M. A. B.; SOUZA, D. A. Busca Harmônica com ajuste adaptativo de parâmetro por meio de Algoritmo Genético aplicada na otimização do projeto LQR. In: **Congresso Brasileiro de Inteligência Computacional**, n. 12, 2015. DOI: 10.21528/CBIC2015-150

NASTOS, P. T.; PALIATSOS, A. G.; KOUKOULETSOS, K. V.; LARISSI, I. K.; MOUSTRIS, K. P. Artificial neural networks modeling for forecasting the maximum daily total precipitation at Athens, Greece. **Atmospheric Research**, v. 144, p. 141-150, 2014. DOI: 10.1016/j.atmosres.2013.11.013

NAZARENO, E. S.; LI, F.; SMITH, M.; PARK, R. F.; KIANIAN, S. F.; FIGUEROA, M. Puccinia coronata f. sp. avenae: a threat to global oat production. **Molecular Plant Pathology**, v. 19, n. 5, p. 1047-1060, 2018. DOI: 10.1111/mpp.12608

NERBASS JUNIOR, J. M.; CASA, R. T.; KUHNEM JÚNIOR, P. R.; GAVA, F.; BOGO, A. Modelos de pontos críticos para relacionar o rendimento de grãos de aveia branca com a intensidade de doença no patossistema múltiplo ferrugem da folha – helmintosporiose. **Ciência Rural**, Santa Maria, v. 40, n. 1, p. 1-6, 2010. DOI: 10.1590/S0103-84782009005000228

NOGUEIRA, A. P. O.; SEDIYAMA, T.; SOUSA, L. B. de; HAMAWAKI, O. T.; CRUZ, C. D.; PEREIRA, D. G.; MATSUO. Análise de trilha e correlações entre caracteres em soja cultivada em duas épocas de semeadura. **Bioscience Journal**, Uberlândia, v. 28, n. 6, p. 877-888, 2012.

O'DONOVAN, J. T.; BLACKSHAW, R. E.; HARKER, K. N.; CLAYTON, G. W.; MAURICE, D. C. Field evaluation of regression equations to estimate crop yield losses due to weeds. **Canadian Journal of Plant Science**, v. 85, n. 4, p. 955-962, 2005. DOI: <https://doi.org/10.4141/P05-041>

OLIVEIRA, A. C. L. de; PASQUAL, M.; PIO, L. A. S.; LACERDA, W. S.; SILVA, S. de O. e. Utilização da modelagem matemática (redes neurais artificiais) na classificação de autotetraploides de bananeira (*Musa acuminata* COLLA). **Bioscience Journal**, Uberlândia, v. 29, n. 3, p. 617-622, 2013.

OLIVEIRA, E. J. de; FREITAS, J. P. X. de; JESUS, O. N. de. AMMI analysis of the adaptability and yield stability of yellow passion fruit varieties. **Scientia Agricola**, v. 71, n. 2, p. 139-145, 2014. DOI: 10.1590/S0103-90162014000200008

OLIVEIRA, G. M. de O. ; PEREIRA, D. D.; CAMARGO, L. C. M.; BALAN, M. G.; CANTERI, M. G.; Igarashi, S.; SAAB, O. J. G. A. Dose e taxa de aplicação de fungicida no controle da ferrugem da folha (*Puccinia triticina*) e da mancha amarela (*Pyrenophora tritici repentis*) do trigo. **Semina: Ciências Agrárias**, v. 36, n. 1, p. 17-30, 2015. DOI: 10.5433/1679-0359.2015v36n1p17

OLIVEIRA, T. R. A. de; CARVALHO, H. W. L. de; COSTA, E. F. N.; CARVALHO FILHO, J. L. S. de. Correlation among adaptability and stability assessment models in maize cultivars. **Australian Journal of Crop Science**, v. 11, n. 5, p. 516-521, 2017.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS (ONU), **Objetivos de Desenvolvimento Sustentável**. 2015. Disponível em: <https://brasil.un.org/pt-br/sdgs>. Acesso em: 03 set. 2022.

PANSERA, V.; MANTAI, R. D.; SILVA, J. A. G. da; CARBONERA, R.; KRAISIG, A. R.; ALESSI, O.; PORAZZI, F. U.; BABESKI, C. M. Modelos de regressão polinomiais na otimização de manejos para a máxima produtividade industrial com qualidade química em grãos de aveia. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 8, n. 1, 2021. DOI: 10.5540/03.2021.008.01.0447

PANSERA, V.; SILVA, J. A. G. da; ALESSI, O.; BASSO, N. C. F.; LUCCHESI, O. A.; PETER, C. L.; JUNG, M. S.; CARVALHO, I. R.; BABESKI, C. M.; ZARDIN, N. G.; HEUSNER, L. B. Dose and form of nitrogen supply in the relationship dynamics of wheat ear components with yield in

cropping systems. **Genetics and Molecular Research**, v. 21, n. 1, p. 1-14, 2022. DOI: <http://dx.doi.org/10.4238/gmr19008>

PASSOS, V.; ZILIO, M.; MANTOVANI, A.; PIVA, C. A. G.; DIAS, K. M.; CARRER, L. (2018). **Ensaio brasileiro de linhagens de aveia branca em Campos Novos, 2017**. Seminário De Iniciação Científica E Seminário Integrado De Ensino, Pesquisa E Extensão, 2018.

PEREIRA, L. M.; STUMM, E. M. F.; BURATTI, J. B. L.; SILVA, J. A. G. da; COLET, C. F.; PRETTO, C. R. A utilização de fungicida no cultivo de aveia: uma revisão integrativa da literatura. **Research, Society and Development**, v. 9, n. 8, 2020. ISSN 2525-3409. DOI: <http://dx.doi.org/10.33448/rsd-v9i8.6181>

PERES, F.; MOREIRA, J. C. Saúde e ambiente em sua relação com o consumo de agrotóxicos em um pólo agrícola do Estado do Rio de Janeiro, Brasil. **Caderno de Saúde Pública**, Rio de Janeiro, 23 Sup 4, p. S612-S621, 2007.

PIVETTA, R. P. **Filocrono de genótipos de aveia branca e preta submetidos a vernalização**. 2019. 24 f. Trabalho de Conclusão de Curso (Bacharelado em Agronomia) - Universidade Federal do Pampa, Itaqui, 2019.

PONTES, E. A. S.; PONTES, E. G. S.; MIRANDA, J. R. de; SANTOS, J. F. dos; GUARINO, A. L. O estudo do comportamento da sucessão de Fibonacci através de diversas linhas de tendência associadas as suas respectivas equações matemáticas de regressão. **Diversitas Journal**, v. 3, n. 3, p. 771-779, 2018. DOI: [10.17648/diversitas-journal-v3i3.622](https://doi.org/10.17648/diversitas-journal-v3i3.622)

POSSATTO JUNIOR, O.; FARIA, M. V.; MENDES, M. C.; OLIBONI, R.; BARCELLOS, A. L.; GUERRA, E. P. Adaptability and stability of wheat genotypes on ten environments in the states of Paraná and São Paulo, Brazil. **Agrária - Revista Brasileira de Ciências Agrárias**, Recife, v. 12, n. 2, p. 113-121, 2017. DOI: [10.5039/agraria.v12i2a5426](https://doi.org/10.5039/agraria.v12i2a5426)

QUEIROZ, J. P. da S.; COSTA, A. J. M. da; NEVES, L. G.; SEABRA JUNIOR, S.; BARELLI, M. A. A. Estabilidade fenotípica de alfices em diferentes épocas e ambientes de cultivo. **Revista Ciência Agronômica**, v. 45, n. 2, p. 276-283, 2014.

ROBERTI, D. R.; AVILA, D. C. de; FAGUNDES, L. A.; ZIMMERMANN, H. R. Comportamento do fluxo de energia em eventos de geada. **Ciência e Natura**, p. 193-195, 2013. DOI: 10.5902/2179-460X11599

ROCHA, V. P. C.; MODA-CIRINO, V.; DESTRO, D.; FONSECA JÚNIOR, N. da S.; PRETE, C. E. C. Adaptabilidade e estabilidade da característica produtividade de grãos dos grupos comerciais carioca e preto de feijão. **Semina: Ciências Agrárias**, Londrina, v. 31, n. 1, p. 39-54, 2010.

ROSA, H. T.; WALTER, L. C.; STRECK, N. A.; ALBERTO, C. M. Métodos de soma térmica e datas de semeadura na determinação de filocrono de cultivares de trigo. **Pesquisa Agropecuária Brasileira**, v. 44, n. 11, p. 1374-1382, 2009. DOI: 10.1590/S0100-204X2009001100002

ROSA, J. A. da R.; MANTAI, R. D.; KRAISIG, A. R.; SILVA, J. A. G. da; CARVALHO, I. R.; JUNG, M. S.; PANSERA, V.; ALESSI, O. Funções polinomiais na estimativa da eficiência técnica e agrônômica de uso do nitrogênio sobre a produtividade de grãos de aveia. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 8, n. 1, 2021a.

ROSA, J. A. da R.; MANTAI, R. D.; KRAISIG, A. R.; SILVA, J. A. G. da; CARVALHO, I. R.; PEREIRA, L. M.; PANSERA, V.; ALESSI, O. Modelos para estimativa da eficiência econômica e de estabilidade de uso de nitrogênio na produtividade da aveia. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 8, n. 1, 2021b.

ROSA, W. B.; DUARTE JÚNIOR, J. B.; TOMM, G. O.; PEREGO, I.; QUEIROZ, S. B.; RINALDI, L. C.; COSTA, B. P.; COSTA, A. C. T. da. Influência de épocas de semeadura nos subperíodos e desempenho agrônômico de híbridos de canola. **Brazilian Journal of Development**, v. 6, n. 9, 2020. DOI: 10.34117/bjdv6n9-126

SABAGHNIA, N.; SABAGHPOUR, S. H.; DEGHANI, H. The use of an AMMI model and its parameters to analyse yield stability in multi-environment trials. **Journal of Agricultural Science**, n. 146, p. 571-581, 2008. DOI: 10.1017/S0021859608007831

SADEGHI, S. M.; SAMIZADEH, H.; AMIRI, E.; ASHOURI, M. Additive main effects and multiplicative interactions (AMMI) analysis of dry leaf yield in tobacco hybrids across environments. **African Journal of Biotechnology**, v. 10, n. 21, p. 4358-4364, 2011. DOI: 10.5897/AJB09.1291

SAFA, M.; NEJAT, M.; NUTHALL, P.; GREIG, B. Predicting CO₂ Emissions from Farm Inputs in Wheat Production using Artificial Neural Networks and Linear Regression Models. (**IJACSA**) **International Journal of Advanced Computer Science and Applications**, v. 7, n. 9, p. 268-274, 2016.

SAMBORSKA, I. A.; ALEXANDROV, V.; SIECZKO, L.; KORNIATOWSKA, B.; GOLTSEV, V.; CETNER, M. D.; KALAJI, H. M. Artificial neural networks and their application in biological and agricultural research. **Signpost Open Access J. NanoPhotoBioSciences**, v. 2, p. 14-30, 2014.

SÁNCHEZ-MARTÍN, J.; RISPAIL, N.; FLORES, F.; EMERAN, A. A.; SILLERO, J. C.; RUBIALES, D.; PRATS, E. Higher rust resistance and similar yield of oat landraces versus cultivars under high temperature and drought. **Agronomy for Sustainable Development**, v. 37, n.1, 2017. DOI:10.1007/s13593-016-0407-5

SÁNCHEZ, S. E. T.; RODRÍGUEZ, M. O.; JIMÉNEZ, A. E.; SOBERANES, H. J. P. Implementación de algoritmos de inteligencia artificial para el entrenamiento de redes neuronales de segunda generación. **Jóvenes en la Ciencia**, v. 1, n. 3, p. 6-10, 2015.

SANTOS, D. C. dos; PEREIRA, C. H.; NUNES, J. A. R.; LEPRE, A. L. Adaptability and stability of maize hybrids in unreplicated multienvironment trials. **Revista Ciência Agronômica**, Fortaleza, v. 50, n. 1, p. 83-89, 2019. DOI: 10.5935/1806-6690.20190010

SANTOS, W. F. dos; AFFÉRI, F. S.; PELÚZIO, J. M.; SILVA, R. M. da; FARIA, L. A.; SODRÉ, L. F. Interação genótipo x ambiente para teor de óleo de milho em diferentes adubação e época. **Journal of Bioenergy and Food Science**, v. 5, n. 1, p. 22-31, 2018. DOI: 10.18067/jbfs.v5i1.176

SCHEER, M. R. **Fungicidas em cultivares de aveia branca: produtividade, qualidade fisiológica e sanitária de sementes e resíduos de agrotóxicos**. 2021. 98 p. Dissertação (Mestrado em Sistemas Ambientais e Sustentabilidade) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, 2021.

SCHÖNEBERG, T.; KIBLER, K.; WETTSTEIN, F. E.; BUCHELI, T. D.; FORRER, H. R.; MUSA, T.; MASCHER, F.; BERTOSSA, M.; KELLER, B.; VOGELGSANG, S. Influence of temperature, humidity duration and growth stage on the infection and mycotoxin production of *Fusarium langsethiae* and *Fusarium poae* in oats. **Plant Pathology**, 2018. DOI: 10.1111/ppa.12922

SILVA, E. R.; OLIVEIRA, J. N.; RUBIO, C. P.; LYRA, G. A.; STEINER, F. Épocas de semeadura do trigo para a região centro-sul mato-grossense. **Revista de Agricultura Neotropical**, Cassilândia-MS, v. 5, n. 1, p. 23-27, 2018. ISSN 2358-6303.

SILVA, F. F.; REGO, C. H. Q.; GOMES JUNIOR, F. G.; MORAES, M. H. D. de; MEDEIROS, A. D. de; SILVA, C. B. da. Detection of *Drechslera avenae* (Eidam) Sharif [*Helminthosporium avenae* (Eidam)] in Black Oat Seeds (*Avena strigosa* Schreb) Using Multispectral Imaging. **Sensors**, v. 20, 2020. DOI: 10.3390/s20123343

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas** - curso prático. São Paulo: Artliber, 2010.

SILVA, J. P.; RODRIGUES, B. A.; CASADO, J. C. S.; ROSA, S. S. R. F. Infusion Pump: Bond Graph Mathematical Modeling for Blood Pressure Control. **IEEE Latin America Transactions**, v. 16, n. 6, p. 1569-1573, 2018. DOI: 10.1109/TLA.2018.8444151

SILVA, J. A. G. da; WOHLLENBERG, M. D.; ARENHARDT, E. G.; OLIVEIRA, A. C. de; MAZURKIEVICZ, G.; MÜLLER, M.; ARENHARDT, L. G.; BINELO, M. O.; ARNOLD, G.; PRETTO, R. Adaptability and Stability of Yield and Industrial Grain Quality with and without Fungicide in Brazilian Oat Cultivars. **American Journal of Plant Sciences**, v. 6, n. 9, p. 1560-1569, 2015. DOI: 10.4236/ajps.2015.69155

SILVA, M. P. da; ABRANTES, F. L.; ARF, O.; SÁ, M. E. de; SOUZA, L. C. D. de. Doses de nitrogênio, espaçamentos entrelinhas em duas cultivares de feijoeiro irrigado no sistema plantio direto. **Cultura Agrônômica**, Ilha Solteira, v. 27, n. 2, p. 190-204, 2018.

SILVA, R. B. M. M.; SOARES, A. S.; SILVA, E. C.; GUSMÃO, L. A. P.; BARBOSA, C. R. H. Algoritmos genéticos aplicados à otimização multiparamétrica da resposta de gradiômetros GMI. **Metrologia**, Fortaleza, 2017.

SIMÕES, G. J.; EBECKEN, N. F. F. Algoritmo genético e enxame de partículas para a otimização de suportes laterais de fornos. **Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería**, v. 32, n. 1, p. 7-12, 2016.

DOI: 10.1016/j.rimni.2014.07.001

SINGH, D. The relative importance of characters affecting genetic divergence. **Indian Journal of Genetics and Plant Breeding**, v. 41, p. 237-245, 1981.

SINGH, V.; MISRA, A. K. Detection of plant leaf diseases using image segmentation and soft computing techniques. **Information Processing in Agriculture**, v. 4, p. 41-49, 2017. DOI: 10.1016/j.inpa.2016.10.005

SOARES, F. C.; ROBAINA, A. D.; PEITER, M. X.; RUSSI, J. L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, Santa Maria, v. 45, n. 11, p. 1987-1993, 2015. DOI: 10.1590/0103-8478cr20141524

SOBRAL, K. M. B.; QUEIROZ, M. A. de; LEDO, C. A. da S.; LOIOLA, C. M.; ANDRADE, J. B.; RAMOS, S. R. R. Genetic diversity assessment among tall coconut palm. **Revista Caatinga**, Mossoró, v. 31, n. 1, p. 28-39, 2018.

SOUSA, P. G. R. de; VIANA, T. V. de A.; CARVALHO, C. M. de; SOUSA, A. M. de; COSTA, C. P. de M.; AZEVEDO, B. M. de. Efeito de diferentes lâminas de irrigação e cobertura do solo no crescimento da cultura do sorgo. **Revista Brasileira de Agricultura Irrigada**, v. 11, n. 4, p. 1528 - 1537, 2017. DOI: 10.7127/rbai.v11n400592

SOUZA, D. R. de; VILAR, C. C.; USHIWATA, S. Y.; REIS, R. de G. E.; RIBEIRO, K. C. Resposta da cultura do milho, em segunda safra, à adubação fosfatada em Latossolo Amarelo no cerrado. **Revista de Ciências Agroambientais**, v.16, n.1, p. 14-24, 2018. DOI: 10.5327/Z1677-606220181307

SOWMYA, H. H.; KAMATAR, M. Y.; SHANTHAKUMAR, G.; BRUNDA, S. M.; SHADAKSHARI, T. V.; BABU, B. M. S.; RAJPUT, S. S. Stability Analysis of Maize Hybrids using Eberhart and Russel Model. **International Journal of Current Microbiology and Applied Sciences**, v. 7, n. 2, p. 3336-3343, 2018. DOI: 10.20546/ijcmas.2018.702.399

SPIEGEL, M. R.; STEPHENS, L. J. **Estatística**. 4. ed. Porto Alegre: Bookman, 2009.

STORCK, L. **Experimentação vegetal**. Santa Maria: Ed. UFSM, 2006.

STRAPASSON, M.; WALENDORFF, R. de A.; SPIRONELLO, A. N.; NASCIMENTO JUNIOR, A. do. Avaliação de ferrugem das folhas (*Puccinia triticina* Erikss) em genótipos de triticale. In: **Reunião da Comissão Brasileira de Pesquisa de Trigo e Triticale**, 13, 2019, Passo Fundo. Ata e Resumos. Passo Fundo: Ed. Universidade de Passo Fundo, 2019. p. 370-373.

SZARESKI, V. J.; CARVALHO, I. R.; KEHL, K.; LEVIEN, A. M.; NARDINO, M.; DELLAGOSTIN, S. M.; DEMARI, G. H.; LAUTENCHLEGER, F.; VILLELA, F. A.; PEDÓ, T.; SOUZA, V. Q. de; AUMONDE, T. Z. Adaptability and stability of wheat genotypes according to the phenotypic index of seed vigor. **Pesquisa agropecuária brasileira**, Brasília, v. 53, n. 6, p.727-735, 2018. DOI: 10.1590/S0100-204X2018000600009

TEIXEIRA, A. M. **Desenvolvimento de método analítico para determinação de resíduos de agrotóxicos em farinha de aveia**. Dissertação (mestrado) - Universidade Federal de Viçosa. – Viçosa, MG, 2019.

TEIXEIRA, T. M. Saúde e direito à informação: o problema dos agrotóxicos nos alimentos. **Revista de Direito Sanitário**, São Paulo, v. 17, n. 3, p. 134-159, 2017. DOI: 10.11606/issn.2316-9044.v17i3p134-159

TOLLER, M.; PELUZIO, J. M.; REINA, E.; LIMA, M. D. DE; HACKENHAAR, C.; HACKENHAAR, N. Adubação potássica e época de semeadura em soja para a produção de etanol. **Revista Agrogeoambiental**, v. 10, n. 2, 2018. DOI: 10.18406/2316-1817v10n220181114

TONIAL, I. B.; SILVA, M. R. da; SANCHES, S.; TORQUATO, A. S. Resíduos de agroquímicos organoclorados em águas e sedimentos no Rio Chopim no Município de Palmas-PR, **Revista UNINGÁ**, v. 9, n. 1, p. 31-42, 2006.

TRIOLA, M. F. **Introdução à estatística**. 7. ed. Rio de Janeiro: LTC, 1999.

VAZ, A. P. A.; SANTOS, H. P. dos; ZAIDAN, L. B. P. Floração. In: KERBAUY, G. B. **Fisiologia vegetal**. 2. ed. Rio de Janeiro: Guanabara Koogan, 2008.

VENDRUSCOLO, D. G. S.; CHAVES, A. G. S.; MEDEIROS, R. A.; SILVA, R. S. da; SOUZA, H. S.; DRESCHER, R.; LEITE, H. G. Estimativa da altura de árvores de *Tectona grandis* L.f. utilizando

regressão e redes neurais artificiais. **Nativa, Sinop**, v. 5, n. 1, p. 52-58, 2017. DOI: 10.5935/2318-7670.v05n01a09

VIEIRA, S. **Estatística Experimental**. São Paulo, Atlas, 1999.

WEBER, F. H.; GUTKOSKI, L. C.; ELIAS, M. C. CARACTERIZAÇÃO QUÍMICA DE CARIOPSES DE AVEIA (*Avena sativa* L) DA CULTIVAR UPF 18. **Ciênc. Tecnol. Aliment.**, Campinas, v. 22, n. 1, p. 39-44, 2002. DOI: 10.1590/S0101-20612002000100007

ZHENG, Z. Y., GUO, X. N.; ZHU, K. X.; PENG, W.; ZHOU, H. M. Artificial neural network – Genetic algorithm to optimize wheat germ fermentation condition: Application to the production of two anti-tumor benzoquinones. **Food Chemistry**, v. 227, p. 264-270, 2017. DOI: 10.1016/j.foodchem.2017.01.077

ZIOMKOWSKI, P.; BRUCH, K. L.; VOLPATO, G. Propriedade Intelectual, Registro e Transferência de Tecnologia: Estudo de Caso de cultivares de aveia da Universidade Federal do Rio Grande do Sul (UFRGS). **Cadernos de Prospecção**, Salvador, v. 15, n. 1, 2022, p. 18-35.

ZUTE, S.; BRUNAVA, L.; JANSONE, I.; TAMM, Y. Influence of farming system, nitrogen rates and meteorological conditions on naked oat in Latvia. **Agriculture & Forestry**, v. 61, p. 15-25, 2015. DOI: 10.17707/AgricultForest.61.1.02