



**THIAGO ANDRADE**

**DESENVOLVIMENTO DE SISTEMAS INTELIGENTES PARA  
A PREDIÇÃO DE PRAGAS E DOENÇAS NO CAFEIEIRO**

**LAVRAS – MG**

**2021**

**THIAGO ANDRADE**

**DESENVOLVIMENTO DE SISTEMAS INTELIGENTES PARA A PREDIÇÃO DE  
PRAGAS E DOENÇAS NO CAFEIEIRO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

Prof. DSc. Danton Diego Ferreira  
Orientador

DSc. Rogério Antônio Silva  
Coorientador

**LAVRAS – MG  
2021**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Andrade, Thiago.

Desenvolvimento de sistemas inteligentes para a predição de pragas e doenças no cafeeiro / Thiago Andrade. - 2021.

75 p.

Orientador(a): Danton Diego Ferreira.

Coorientador(a): Rogério Antônio Silva.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2021.

Bibliografia.

1. Sistemas inteligentes. 2. Pragas e doenças. 3. Previsão. I. Ferreira, Danton Diego. II. Silva, Rogério Antônio. III. Título.

**THIAGO ANDRADE**

**DESENVOLVIMENTO DE SISTEMAS INTELIGENTES PARA A PREDIÇÃO DE  
PRAGAS E DOENÇAS NO CAFEIEIRO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

APROVADA em 09 de Abril de 2021.

Prof. DSc. Danton Diego Ferreira	UFLA
DSc. Rogério Antônio Silva	EPAMIG
DSc. Luiz de Gonzaga Ferreira Júnior	CEFET
DSc. Margarete Marin Lordelo Volpato	EPAMIG

Prof. DSc. Danton Diego Ferreira  
Orientador

DSc. Rogério Antônio Silva  
Co-Orientador

**LAVRAS – MG  
2021**

*Dedico este trabalho aos meus pais e familiares que sem eles isso seria impossível.*

## AGRADECIMENTOS

Primeiramente agradeço aos meus pais, Bento e Vilma, por terem estado ao meu lado todos os instantes e me apoiarem em toda a minha trajetória até esse momento e também toda a estrutura necessária para construir quem hoje sou.

Ao meu orientador, professor Danton, por apresentar paciência, dedicação e confiança. Ao coorientador Rogério pela parceria e contribuição neste trabalho. Agradeço também pela amizade e o bom relacionamento construído ao longo desta jornada.

À minha família pelo apoio e incentivo.

À Patrícia, pelo amor, carinho e atenção.

Aos professores do DAT-UFLA que, diretamente ou indiretamente, deram contribuições positivas para o desenvolvimento do trabalho.

Aos outros professores da UFLA que também contribuíram na minha formação.

Aos técnicos administrativos do DAT-UFLA pela assistência prestada ao longo de todo o curso.

Agradeço também todos da EPAMIG que estiveram envolvidos neste trabalho diretamente ou indiretamente.

Por fim, gostaria de agradecer a Deus por me guiar em todos os momentos da minha vida dando força e sabedoria.

*Sem a educação das sensibilidades, todas as habilidades são tolas e sem sentido. Os conhecimentos nos dão meios para viver. A sabedoria nos dá razões para viver.*  
*(Rubem Alves)*

## RESUMO

As pragas e doenças no cafeeiro, ocasionadas por bicho-mineiro-do-cafeeiro, broca-do-café, ferrugem-do-cafeeiro e cercosporiose, chegam a atingir até 50% de uma lavoura cafeeira, podendo causar grandes prejuízos aos cafeicultores. Sendo assim, os sistemas inteligentes são de suma importância para prever esses danos ao cafeeiro e também auxiliar os cafeicultores na tomada de decisão. Este trabalho propõe o uso de redes neurais artificiais do tipo *Multilayer Perceptron* (MLP) e árvores de decisão para o desenvolvimento de sistemas inteligentes para prever a taxa de ocorrência de pragas e incidência de doenças no cafeeiro. Utilizou-se um método de regressão linear no intuito de compará-lo com os modelos de sistemas inteligentes por meio de métricas estatísticas. Foram utilizados dados meteorológicos, tais como: temperaturas mínima e máxima, precipitação pluviométrica, umidade relativa do ar, incidência de raios solares e a quantidade de dias sem chuva na região como variáveis de entrada dos modelos. O valor dos dados referentes às pragas e doenças foram coletados no Campo Experimental da EPAMIG de São Sebastião do Paraíso, no sul de Minas Gerais. Foram empregadas as métricas estatísticas *Root Mean Square Error* (RMSE) e o Coeficiente de Determinação ( $R^2$ ) para verificar o quão os modelos propostos estão predizendo as manifestações de pragas e doenças adequadamente. As redes neurais MLP apresentaram os melhores resultados para os modelos de doenças e pragas com um RMSE na faixa de 0,0220 a 0,1569 e um  $R^2$  que variou entre 0,7552 a 0,9803. Os valores para os modelos de árvores de decisão ficou em um intervalo para RMSE e  $R^2$  entre 0,0477 a 0,2900 e 0,2059 a 0,8752, respectivamente. Os resultados dos modelos aplicando regressão linear múltipla variou entre 0,0633 a 0,3154 e 0,1045 a 0,4822 para as métricas RMSE e  $R^2$ , respectivamente. Uma das vantagens de se utilizarem redes neurais artificiais do tipo MLP é a alta capacidade de aprender e generalizar após o treinamento do algoritmo, isto ficou evidente neste trabalho. Por fim, desenvolveu-se um aplicativo para *smartphones* embarcado com um modelo de sistema inteligente com o objetivo de prever e informar o cafeicultor em tomadas de decisões no que refere-se a doenças e pragas.

**Palavras-chave:** Predição. Sistemas Inteligentes. Doenças e Pragas. Cafeeiro.



## ABSTRACT

The pests and diseases in the coffee tree, caused by the coffee miner bug, coffee borer, coffee rust and cercosporiosis, reach up to 50% of a coffee crop, which can cause great damage to coffee growers. Thus, intelligent systems are of paramount importance to predict these damages to the coffee tree and also assist coffee farmers in decision making. This work proposes the use of artificial neural networks of the type Multi-layer Perceptron (MLP) and decision trees for the development of intelligent systems to predict the rate of occurrence of pests and incidence of diseases in the crop. A linear regression method was used in order to compare it with models of intelligent systems by means of statistical metrics. Meteorological data were used, such as: minimum and maximum temperatures, rainfall, relative air humidity, incidence of sunlight and the number of days without rain in the region as input variables for the models. The value of data relating to pests and diseases were collected at the EPAMIG Experimental Camp in São Sebastião do Paraíso, in the south of Minas Gerais. Statistical metrics Root Mean Square Error (RMSE) and the Termination Coefficient ( $R^2$ ) were used to verify how the proposed models are adequately predicting pest and disease manifestations. The MLP neural networks showed the best results for disease and pest models with an RMSE in the range of 0.0220 to 0.1569 and an  $R^2$  that varied between 0.7552 to 0.9803. The values for the decision tree models were a range for RMSE and  $R^2$  between 0.0477 to 0.2900 and 0.2059 to 0.8752, respectively. The results of the models applying multiple linear regression varied between 0.0633 to 0.3154 and 0.1045 to 0.4822 for the metrics RMSE and  $R^2$ , respectively. One of the advantages of using artificial neural networks of the MLP type is the high capacity to learn and generalize after training the algorithm, this was evident in this work. Finally, an application was developed for textit smartphones embedded with an intelligent system model with the aim of predicting and informing the coffeegrower in decision making regarding diseases and pests.

**Keywords:** Prediction. Intelligent Systems. Diseases and Pests. Coffee.

## LISTA DE FIGURAS

Figura 2.1 – Folhas lesionadas provocados pelo bicho-mineiro. . . . .	17
Figura 2.2 – Fêmea adulta da broca no fruto do café. . . . .	18
Figura 2.3 – Folhas do café com o fungo <i>Hemileia Vastatrix</i> (ferrugem). . . . .	20
Figura 2.4 – Folhas do café com cercosporiose. . . . .	21
Figura 2.5 – Representação simplificada de um neurônio. . . . .	25
Figura 2.6 – Modelo matemático não-linear dos neurônios utilizados na RNA. . . . .	26
Figura 2.7 – Modelo de um neurônio proposto por Rosenblatt. . . . .	28
Figura 2.8 – Representação gráfica de uma rede MLP com duas camadas intermediárias e uma saída. . . . .	30
Figura 2.9 – Exemplo simplificado de um classificador utilizando árvore de decisão. . .	32
Figura 2.10 – Exemplo de um possível caminho para classificação. . . . .	33
Figura 2.11 – Exemplo de distribuição de dados gerados. . . . .	36
Figura 4.1 – Disposição dos dados de treinamento para os modelos de pragas e doenças.	44
Figura 4.2 – Previsão da taxa de ocorrência da praga bicho-mineiro-do-cafeeiro utilizando dados de validação. . . . .	45
Figura 4.3 – Previsão da taxa de ocorrência da praga bicho-mineiro-do-cafeeiro utilizando dados de teste. . . . .	45
Figura 4.4 – Previsão da taxa de ocorrência da praga broca-do-café utilizando dados de validação. . . . .	46
Figura 4.5 – Previsão da taxa de ocorrência da praga broca-do-café utilizando dados de teste. . . . .	46
Figura 4.6 – Previsão da taxa de incidência da doença cercosporiose utilizando dados de validação. . . . .	47
Figura 4.7 – Previsão da taxa de incidência da doença cercosporiose utilizando dados de teste. . . . .	47
Figura 4.8 – Previsão da taxa de incidência da doença ferrugem-do-cafeeiro utilizando dados de validação. . . . .	48
Figura 4.9 – Previsão da taxa de incidência da doença ferrugem-do-cafeeiro utilizando dados de teste. . . . .	48
Figura 4.10 – Previsão da taxa de ocorrência da praga bicho-mineiro-do-cafeeiro utilizando dados de validação. . . . .	51

Figura 4.11 – Previsão da taxa de ocorrência da praga bicho-mineiro-do-cafeeiro utilizando dados de teste. . . . .	51
Figura 4.12 – Previsão da taxa de ocorrência da praga broca-do-café utilizando dados de validação. . . . .	52
Figura 4.13 – Previsão da taxa de ocorrência da praga broca-do-café utilizando dados de teste. . . . .	52
Figura 4.14 – Previsão da taxa de incidência da doença cercosporiose utilizando dados de validação. . . . .	53
Figura 4.15 – Previsão da taxa de incidência da doença cercosporiose utilizando dados de teste. . . . .	53
Figura 4.16 – Previsão da taxa de incidência da doença ferrugem-do-cafeeiro utilizando dados de validação. . . . .	54
Figura 4.17 – Previsão da taxa de incidência da doença ferrugem-do-cafeeiro utilizando dados de teste. . . . .	54
Figura 4.18 – Fluxograma sequencial das etapas de utilização do aplicativo. . . . .	62
Figura 4.19 – Tela inicial do aplicativo. . . . .	63
Figura 4.20 – Tela para selecionar doenças ou pragas. . . . .	63
Figura 4.21 – Tela referente à praga bicho-mineiro-do-cafeeiro para predição. . . . .	64
Figura 4.22 – Campo informativo sobre o dano econômico causado pela praga . . . . .	64
Figura 4.23 – Tela referente à praga broca-do-café para predição. . . . .	65
Figura 4.24 – Tela referente à doença cercosporiose para predição. . . . .	65
Figura 4.25 – Tela referente à doença ferrugem-do-cafeeiro para predição. . . . .	66

## LISTA DE GRÁFICOS

Gráfico 4.1 – Média do RMSE para os modelos de sistemas inteligentes e regressão linear múltipla utilizando dados de validação. . . . .	56
Gráfico 4.2 – Média do $R^2$ para os modelos de sistemas inteligentes e regressão linear múltipla utilizando dados de validação. . . . .	56
Gráfico 4.3 – Média do RMSE para os modelos de sistemas inteligentes e regressão linear múltipla utilizando dados de teste. . . . .	57
Gráfico 4.4 – Média do $R^2$ para os modelos de sistemas inteligentes e regressão linear múltipla utilizando dados de teste. . . . .	57

## LISTA DE TABELAS

Tabela 3.1 – Informações sobre amostras coletadas, quantidade de dados e variáveis meteorológicas. . . . .	37
Tabela 3.2 – Dados de pragas e doenças utilizados nos treinamentos e testes dos modelos. . . . .	38
Tabela 4.1 – Média e desvio padrão do RMSE de um teste preliminar para a seleção da função de treinamento a ser utilizada nos modelos de predição. . . . .	41
Tabela 4.2 – Resultados dos RMSE, $R^2$ e a média com o desvio padrão dos <i>folds</i> para o modelo de predição da praga bicho-mineiro-do-cafeeiro. . . . .	42
Tabela 4.3 – Resultados dos RMSE, $R^2$ e a média com o desvio padrão dos <i>folds</i> para o modelo de predição da praga broca-do-café. . . . .	42
Tabela 4.4 – Resultados dos RMSE, $R^2$ e a média com o desvio padrão dos <i>folds</i> para o modelo de predição da doença cercosporiose. . . . .	43
Tabela 4.5 – Resultados dos RMSE, $R^2$ e a média com o desvio padrão dos <i>folds</i> para o modelo de predição da doença ferrugem-do-cafeeiro. . . . .	43
Tabela 4.6 – Resultados dos RMSE, $R^2$ e a média com o desvio padrão dos <i>folds</i> para o modelo de predição da praga bicho-mineiro-do-cafeeiro. . . . .	49
Tabela 4.7 – Resultados dos RMSE, $R^2$ e a média com o desvio padrão dos <i>folds</i> para o modelo de predição da praga broca-do-café. . . . .	49
Tabela 4.8 – Resultados dos RMSE, $R^2$ e a média com o desvio padrão dos <i>folds</i> para o modelo de predição da doença cercosporiose. . . . .	50
Tabela 4.9 – Resultados dos RMSE, $R^2$ e a média com o desvio padrão dos <i>folds</i> para o modelo de predição da doença ferrugem-do-cafeeiro. . . . .	50
Tabela 4.10 – Média e desvio padrão do RMSE e $R^2$ dos <i>folds</i> para os modelos de regressão linear múltipla de doenças e pragas utilizando dados de validação e teste. . . . .	55
Tabela 4.11 – Teste t de <i>Student</i> (valor <i>p</i> ) entre os modelos de redes neurais MLP e árvores de decisão para dados de teste. . . . .	58
Tabela 4.12 – Teste t de <i>Student</i> (valor <i>p</i> ) entre os modelos de redes neurais MLP e regressão linear múltipla para dados de teste. . . . .	58
Tabela 4.13 – Método teste t de <i>Student</i> (valor <i>p</i> ) entre os modelos de árvores de decisão e regressão linear múltipla. . . . .	59

Tabela 4.14 – Tempo de processamento dos algoritmos de redes neurais artificiais MLP, árvores de decisão e regressão linear múltipla. . . . .	60
--	----

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	14
1.1	Objetivos	16
1.2	Organização do trabalho	16
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	17
2.1	Classificação de Pragas no Cafeeiro	17
2.1.1	Bicho-mineiro-do-cafeeiro	17
2.1.2	Broca-do-café	18
2.2	Classificação de Doenças no Cafeeiro	19
2.2.1	Ferrugem-do-cafeeiro	19
2.2.2	Cercosporiose	20
2.3	Manejo Integrado de Pragas	22
2.4	Fatores impactantes no agroecossistema cafeeiro	22
2.5	Sistemas Inteligentes	24
2.5.1	Redes Neurais Artificiais	24
2.5.1.1	O <i>Perceptron</i>	28
2.5.1.2	Redes de Múltiplas Camadas	29
2.5.2	Árvores de Decisão	31
2.6	Validação Cruzada	33
2.6.1	<i>K-Fold</i>	34
2.7	Métricas Estatísticas para Validação	34
2.7.1	Coefficiente de Determinação	34
2.7.2	RMSE ( <i>Root Mean Square Error</i> )	35
2.8	SMOTE - <i>Synthetic Minority Oversampling Technique</i>	35
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	37
3.1	Base de Dados	37
3.2	Modelos Utilizados	39
3.3	Métricas de Validação	40
3.4	Desenvolvimento de Aplicativo	40
<b>4</b>	<b>RESULTADOS e DISCUSSÕES</b>	41
4.1	Redes Neurais MLP	41
4.1.1	Teste preliminar	41

4.1.2	Resultados dos Modelos de Predição . . . . .	41
4.2	Resultados - Árvores de Decisão . . . . .	44
4.3	Comparação entre os Método Propostos e Regressão Linear Múltipla . . .	55
4.3.1	Complexidade Computacional . . . . .	60
4.4	Aplicativo para <i>Smartphone</i> . . . . .	60
5	CONCLUSÃO . . . . .	67
6	TRABALHOS FUTUROS . . . . .	68
	REFERÊNCIAS . . . . .	69
	APÊNDICE A - Publicação em Congresso . . . . .	73



## 1 INTRODUÇÃO

A cafeicultura é uma das atividades mais representativas do agronegócio brasileiro, com grande relevância do ponto de vista social e econômico. O café está entre os maiores produtos nacionais comercializados no mercado internacional, uma vez que o país é o maior produtor de café arábica do mundo. O estado brasileiro que possui um maior destaque na produção de café é Minas Gerais, com aproximadamente 50% da produção nacional, no qual abastece tanto o mercado interno quanto externo. Sendo assim, o café é responsável por uma parcela significativa na balança comercial do Estado, além de gerar muitos empregos diretamente e indiretamente.

Entretanto, distúrbios de naturezas diversas podem iniciar uma ação agressiva nos cafeeiros, ocasionando anormalidades que resultam na redução da produção, e também na regressão do desenvolvimento fisiológico da planta. Dependendo da gravidade destes distúrbios a exploração econômica da lavoura se torna inviável, uma vez que alguns fenômenos ocorrem em cafeeiros ainda em formação, ou seja, logo no início da plantação e outros na fase produtiva. Tais distúrbios, como fatores bióticos e abióticos, são citados e estudados como pragas, doenças aliadas às condições climáticas, todos estes presentes no agroecossistema cafeeiro.

O controle de pragas e doenças está entre as práticas mais realizadas nas lavouras de café durante o período agrícola além de ser uma atividade com custo financeiro elevado. Logo, é de suma importância que o produtor quantifique os danos ocasionados e conheça os métodos de controle da forma mais sustentável possível, para assim, minimizar as perdas nas lavouras de café.

Para tanto, o estudo epidemiológico das interações patógenos, pragas, hospedeiro e ambiental é fundamental para o manejo das doenças e pragas nas plantações de café. Portanto, o conhecimento dos fatores que influenciam o desenvolvimento tanto de pragas como de doenças no cafeeiro é de substancial importância para um melhor desempenho na produção do café, pois tais estudos podem beneficiar agricultores da área cafeeira na forma de manejar suas plantações, por exemplo, evitando a utilização excessiva de pesticidas no cafeeiro.

Devido aos elevados custos de produção da cafeicultura, e um mercado cada vez mais competitivo com o passar dos tempos, é primordial a necessidade de evitar quaisquer forma de perda. Sendo assim, para a correta adoção de métodos de controle, é necessário conhecer a dinâmica das manifestações de pragas e doenças nesses sistemas de cultivos.

As principais pragas e doenças mais conhecidas são: bicho-mineiro-do-cafeeiro (*Leucoptera coffeella*), broca-do-café (*Hypothenemus hampei*), ferrugem-do-cafeeiro (*Hemileia vastatrix*) e cercosporiose (*Cercospora coffeicola*), onde os dois primeiros são pragas e os dois últimos doenças. Sabe-se que as causas mais comuns destas manifestações estão diretamente relacionada com fenômenos meteorológicos, tais como: temperaturas mínimas e máximas, precipitação pluviométricas, umidade relativa do ar, dentre outros.

Diante dos problemas supracitados, ferramentas como modelos de predição ou alerta podem ser utilizadas visando antecipar a ocorrência de pragas e a incidência de doenças no cafeeiro. Dessa forma, com a predição por meio de tais modelos, quando realizada corretamente, pode-se evitar danos a produção e qualidade do café bem como a aplicações incorretas de defensivos agrícolas e, assim, gerar uma economia financeira para o agricultor.

Com base nestes aspectos, estas ferramentas que possibilitam desenvolver modelos de predição são inseridas e classificadas como Sistemas Inteligentes. No entanto, estes podem ser descritos como um conjunto de modelos matemáticos que buscam incorporar aspectos habitualmente associados ao comportamento inteligente humano, tais como percepção, raciocínio, aprendizagem, adaptação, entre outras características.

Sistemas inteligentes vêm sendo utilizados para predizer com uma maior probabilidade de acerto a ocorrência de pragas e incidência de doenças no cafeeiro (MEIRA; RODRIGUES; MORAES, 2009). Tais sistemas levam em consideração fatores que estão diretamente ligados com esses fenômenos, como faixa de temperatura ao longo dos dias ou as ocorrências de grandes períodos chuvosos ou até mesmo a umidade relativa do ar, todos estes, presentes nos agroecossistemas cafeeiro.

Destacam-se vários sistemas inteligentes com vastas aplicações na agricultura em especial na cafeicultura. Redes Neurais Artificiais, Árvores de Decisão, Máquina de Vetores de Suporte e Lógica Fuzzy são alguns dos sistemas inteligentes presentes na literatura e que são destaques para predizer fenômenos em diversas áreas de estudo.

No presente trabalho propõe-se pesquisar e desenvolver modelos matemáticos que têm como função prever a incidência de doenças e ocorrências de pragas no cafeeiro. Foram desenvolvidos e testados modelos de redes neurais artificiais (*Multilayer Perceptron* - MLP), árvores de decisão e regressão linear múltipla. Por fim, desenvolveu-se um aplicativo com os modelos matemáticos de doenças e pragas embarcados no mesmo.

## 1.1 Objetivos

O objetivo geral deste trabalho é desenvolver e validar modelos de Sistemas Inteligentes para a predição de pragas e doenças no cafeeiro. A validação destes modelos foram por métricas estatísticas que são: *Root Mean Square Error* e o Coeficiente de Determinação. Os outros objetivos específicos são:

- Desenvolver modelos matemáticos utilizando algoritmos de redes neurais artificiais e árvores de decisão.
- Testar os modelos matemáticos e verificar qual possui uma acurácia satisfatória para previsão de doenças e pragas no cafeeiro e apresentar os resultados.
- Comparar os modelos de sistemas inteligentes com o método de regressão linear múltipla.
- Desenvolver um aplicativo para dispositivo móvel com o modelo matemático que apresentou melhor acurácia.

## 1.2 Organização do trabalho

Após o capítulo de Introdução, no Capítulo 2 apresenta-se o referencial teórico, que inicia a Seção 2.1 descrevendo a classificação de pragas e doenças no cafeeiro, tais como: Bicho-mineiro do cafeeiro – subseção 2.1.1; Broca-do-café – subseção 2.1.2; Ferrugem do cafeeiro – subseção 2.2.1; Cercosporiose – subseção 2.2.2. A Seção 2.3 aborda o Manejo Integrado de pragas, assim como os fatores impactantes no agroecossistema cafeeiro na Seção 2.4. No transcorrer da Seção 2.5 é apresentado alguns métodos que originaram os sistemas inteligentes, que são eles: Redes Neurais Artificiais – subseção 2.5.1; *Perceptron* – subseção 2.5.1.1; Redes de Múltiplas Camadas – subseção 2.5.1.2; Árvores de decisão – subseção 2.5.2; o método de Validação Cruzada – Seção 2.6; As métricas estatísticas que foram empregados neste trabalho – seção 2.7; Técnica SMOTE para gerar dados artificiais – Seção 2.8; No Capítulo 3 descreve-se os materiais e métodos utilizado nesta pesquisa. Os resultados obtidos para cada modelo de predição e o aplicativo para *smartphones* estão no Capítulo 4. O Capítulo 5 refere-se as conclusões da presente pesquisa. E por fim, o Capítulo 6 descreve alguns trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

### 2.1 Classificação de Pragas no Cafeeiro

#### 2.1.1 Bicho-mineiro-do-cafeeiro

O Bicho-Mineiro-do-Cafeeiro - BMC, (*Leucoptera coffeella* Guérin-Méneville) (Lepidoptera : Lyonetiidae) é considerado a praga de maior importância na cultura do cafeeiro no Brasil. As lagartas desse lepidóptero se alimentam exclusivamente do parênquima paliçádico causando lesões e provocando, em altas infestações, queda acentuada das folhas reduzindo substancialmente a capacidade fotossintética e, por consequência, a produção de frutos nas plantas (CONCEIÇÃO; GUERREIRO-FILHO; GONÇALVES, 2005).

Figura 2.1 – Folhas lesionadas provocados pelo bicho-mineiro.



Fonte: <http://www.epamig.br/download/cartilha-bicho-mineiro-docafeeiro/>

Entretanto, a intensidade do ataque de *L. coffeella* é influenciada pelo clima, presença de predadores e parasitóides, densidade de plantio e tratos culturais, entre outros fatores. O estado fisiológico e características de crescimento do cafeeiro, em função de sua nutrição, também podem estar relacionados com o ataque do bicho-mineiro (CAIXETA et al., 2004).

Os danos originados por meio da praga variam em função das práticas culturais adotadas, da época do ano e, sobretudo da região de cultivo, podendo comprometer mais de 37% da produtividade das lavouras. Fatores climáticos, como longos períodos de estiagem associados a temperaturas elevadas e o desequilíbrio ecológico provocado pela utilização inadequada de pro-

duto químicos são as principais causas das grandes infestações (CONCEIÇÃO; GUERREIRO-FILHO; GONÇALVES, 2005).

Sabe-se que o cafeeiro é exigente em nutrientes, principalmente nitrogênio (N) e potássio (K), e a época de adubação da cultura coincide com a fase crítica de ataque do bicho-mineiro. Deste modo, conforme verificado em outras culturas e com outras pragas, as quantidades de N e K fornecidas ao cafeeiro podem conferir maior tolerância ou susceptibilidade ao inseto (CAIXETA et al., 2004).

### 2.1.2 Broca-do-café

A broca-do-café (*Hypothenemus hampei* - *Coleoptera: Scolytidae*) tem se dispersado pelas regiões produtoras de café arábica (*Coffea arabica* L.) e conilon (*C. canephora* Pierre ex A. Froehner) no mundo, e comprometido a produtividade e a qualidade das bebidas. Ela pode infestar frutos verdes, maduros ou secos e causar sérios danos, como redução no peso e na qualidade dos frutos e mesmo da bebida (FERNANDES et al., 2014).

Figura 2.2 – Fêmea adulta da broca no fruto do café.



Fonte: <http://www.epamig.br/download/broca-do-cafe/>

Historicamente, a presença da broca-do-café no Brasil relaciona-se com introdução de sementes oriundas da África e de Java entre os anos de 1913 a 1924, atingido na sua disseminação por todas as zonas produtoras de café no país. No entanto, essa praga, originária do continente africano, é um pequeno coleóptero de cor preta, considerada em algumas regiões, a praga mais severa do café devido aos resultados negativos de sua ação sobre a produção cafeeira em termos quantitativo e qualitativo. Os danos são causados pelas larvas, que vivem no interior

do fruto de café e atacam as sementes para sua alimentação, podendo destruir os frutos parcial ou totalmente (SOUZA et al., 2014).

Sabe-se que os machos da broca-do-café em nenhum momento deixam os frutos onde se originam, por não serem capazes de alcançar voos, enquanto as fêmeas apresentam alta capacidade de voo. Essa característica bioecológica faz dessa praga um alvo difícil de ser atingido, além disso, são poucos os métodos de controle eficientes. Entre os mais usados, estão o controle cultural e o químico. O cultural consiste em realizar adequadamente a colheita com repasse. Por outro lado, o controle químico é feito com inseticidas (FERNANDES et al., 2014).

Por outro lado, alimentando-se e reproduzindo-se exclusivamente em frutos do cafeeiro, *H. hampei* é condicionada em seu potencial biótico pela disponibilidade desses frutos durante o ano. Sendo assim, os fatores que afetam a fenologia da planta afetam também, indiretamente, a fenologia desse inseto. Nas condições do Sul de Minas Gerais, os fatores mais importantes para a fenologia do cafeeiro são o fotoperíodo, que regula a indução floral da planta, e os fatores climáticos como a precipitação e a temperatura (FERREIRA et al., 2000).

## **2.2 Classificação de Doenças no Cafeeiro**

### **2.2.1 Ferrugem-do-cafeeiro**

Dentre as principais doenças do café, a ferrugem-do-cafeeiro cujo agente etiológico é *Hemileia vastatrix* Berk. & Br., é a principal doença do cafeeiro (*C. arábica* L.) em todo o mundo. Entretanto, no Brasil, ela atinge a produção do cafeeiro cerca de 35% nas regiões onde as condições climáticas são favoráveis à doença (THAMADA; RODRIGUES; MEIRA, 2015).

No entanto, esta doença, a ferrugem, foi observada pela primeira vez no mundo em 1861, em cafeeiros silvestres, próximo ao Lago Victória, no Quênia, África Oriental. O fungo *Hemileia vastatrix* Berk. & Br. foi estudado pela primeira vez por Berkeley. Em 1867, teve sua presença confirmada no Ceilão, atualmente Sri-Lanka, dois anos depois, em 1869, a doença demonstrava gravidade. A devastação foi tamanha que o país abandonou o cultivo do cafeeiro e passou a cultivar o chá (ALFONSI et al., 2019).

A ferrugem-do-cafeeiro causa uma desfolha precoce nas plantas, principalmente pela produção de etileno na folhas lesionadas, com isso podendo diminuir substancialmente a produção de café. Os danos causados por ela, por meio da queda precoce das folhas, resultam em menor vingamento da florada, dos chumbinhos e também a desidratação dos ramos pla-

Figura 2.3 – Folhas do café com o fungo *Hemileia Vastatrix* (ferrugem).



Fonte: <http://www.epamig.br/download/cartilha-ferrugem-do-cafeeiro/>

giotrópicos, isso pode levar a comprometer em até 50% da produção do cafeeiro (COSTA; ZAMBOLIM; RODRIGUES, 2007).

Conhecer os fatores que determinam a maior taxa de progresso da ferrugem no cafeeiro é de grande importância, uma vez que eles influenciam diretamente o desenvolvimento da doença, a sua incidência e severidade. O estudo das relações entre o patógeno, o hospedeiro e o ambiente pode auxiliar na compreensão da ocorrência de epidemias e, assim ter como consequência, permitir a aplicação de medidas de controle mais otimizadas (MEIRA; RODRIGUES; MORAES, 2008).

No que diz respeito ao ambiente, a temperatura, umidade do ar e pluviosidade afetam diretamente tanto a incidência quanto a severidade da doença no cafeeiro. No entanto, as condições e manejo, como a utilização de árvores consorciadas aos cafeeiros afetam a intensidade das doenças devido à alteração do microclima (SALGADO et al., 2007). Variações na temperatura e alterações no regime de chuva podem alterar a curva de progresso da ferrugem, levando o atraso do seu início ou até mantendo altos níveis da doença ao fim de seu ciclo, na qual ocorre em agosto (THAMADA; RODRIGUES; MEIRA, 2015).

### 2.2.2 Cercosporiose

No Brasil a cercosporiose ou "mancha-de-olho-pardo", causada por *Cercospora coffeicola* Berk. & Cooke, constitui uma das principais doenças da fase de viveiro da cultura do café (*C. arabica* L.). As plantas doentes apresentam desfolha, redução no desenvolvimento e

raquitismo, tornando-se impróprias ao plantio. O principal método de controle da cercosporiose são produtos químicos (POZZA et al., 2004). A intensidade da doença pode agravar-se em decorrência da deficiência hídrica prolongada e da adubação insuficiente e desequilibrada (BOTELHO et al., 2005).

Figura 2.4 – Folhas do café com cercosporiose.



Fonte: <http://www.epamig.br/download/cartilha-cercosporiose/>

Sabe-se que o progresso dessa doença é favorecido por vários fatores relacionados ao patógeno, hospedeiro e ambiente. Assim, período de molhamento foliar de 6 a 12 horas resulta em máxima severidade da cercosporiose e o período de incubação médio de *C. coffeicola* é de 16 dias (SANTOS et al., 2008).

De modo geral, os conídios podem sobreviver por mais de sete semanas em folhas destacadas e permanecerem viáveis por quase nove meses na superfície foliar aguardando condições favoráveis para germinarem, como temperatura ótima em torno de 24 °C. O estresse hídrico e o desequilíbrio nutricional propiciam maior severidade e, da mesma forma, o desequilíbrio entre o cálcio e o potássio tende a aumentar a suscetibilidade do cafeeiro à cercosporiose. Entretanto, esse desequilíbrio pode ser originado por grande produção, ausência de chuvas ou excesso de adubação em cobertura sem a devida calagem (SANTOS et al., 2008).



### 2.3 Manejo Integrado de Pragas

De acordo com (BUSOLI et al., 2014), o Manejo Integrado de Pragas (MIP) constitui-se no planejamento e na utilização de táticas e estratégias voltadas para o controle de artrópodes-praga, objetivando à sua manutenção em níveis que não acarretam danos econômicos à produtividade das culturas, assim como a qualidade de seus produtos.

Entretanto, um programa adequado de MIP é composto por três princípios básicos, que são: princípio econômico, ecológico e toxicológico (BUSOLI et al., 2014). O primeiro refere-se que toda tecnologia adotada deve ter custo com os benefícios, ou seja, produtividade maior e custo menor. Para o segundo princípio, as medidas ou estratégias devem proporcionar um incremento das interações tritróficas que ocorrem no agroecossistema, com destaque para o controle biológico natural de pragas. E finalmente, o princípio toxicológico que visa optar pela utilização de defensivos seletivos, propiciando menor toxicidade ao ser humano e ao meio ambiente e baixo impacto sobre inimigos naturais.

Diante disso, o agroecossistema cafeeiro apresenta excelentes condições para a implantação do manejo integrado de pragas, pois a perenidade das plantas favorecem o aumento de predadores e parasitóides, visto que podem alcançar níveis capazes de reduzir as populações de artrópodes-praga. Entretanto, a utilização indiscriminada de agrotóxicos nesta cultura tem reduzido as populações de insetos benéficos de forma drástica (SILVA et al., 2012).

### 2.4 Fatores impactantes no agroecossistema cafeeiro

No agroecossistema cafeeiro surgem algumas pragas secundárias, por exemplo, a espécie de ácaros fitófagos destacando-se o ácaro-vermelho *Oligonychus ilicis* (McGregor, 1917) (Acari: Tetranychidae), o ácaro da mancha-anular *Brevipalpus phoenicis* (Geijskes, 1939) (Acari: Tenuipalpidae) e o ácaro branco *Polyphogotarsonemus latus* (Banks, 1904) (Acari: Tarsonemidae), todos estes considerados pragas-chave do cafeeiro. Está espécie de ácaro estão entre os problemas fitossanitários e são responsáveis por uma parte dos danos econômicos na cafeicultura (ABREU, 2013).

Os insetos pertencentes à família Chrysopidae possui uma importância atuação no equilíbrio da densidade populacional de muitos artrópodes-praga e dentre os crisópides a espécie *Chrysoperla externa* (Neuroptera: Chrysopidae), ocorrendo em culturas cafeeiras. Sendo assim, ela é considerada um agente potencial de controle biológico de diversas pragas de impor-

tância agrícola. Além disso, a fase de pupa dos crisópides é considerada tolerante a muitos produtos fitossanitários (SILVA et al., 2006).

Por outro lado, a precipitação pluvial pode diminuir as populações de pragas em diversas culturas, por meio da ação mecânica. As chuvas provocam um impacto mecânico de suas gotas sobre os insetos e ácaros, influenciando na densidade populacional desses organismos. Um dos principais causadores de mortalidade de insetos são as chuvas, uma vez que são arrastados pelas mesmas. Porém, umidade elevada beneficia o desenvolvimento de fungos que são inimigos naturais das pragas (PICANÇO, 2010).

Contudo, a umidade relativa do ar, temperatura e insolação despertam problemas com ácaros e outras pragas em lavouras, influenciando diretamente nas atividades de oviposição, alimentação, crescimento, desenvolvimento e reprodução, ou de forma indireta, por intermédio da ação de inimigos naturais, mudanças fisiológicas e bioquímicas na planta hospedeira (LAW; PEDIGO; HINZ, 2001; HOPKINS; MEMMOTT, 2003).

Alguns métodos disponíveis no manejo integrado da praga broca-do-café é o controle biológico. Todavia, quatro espécies parasitoides são reproduzidas em laboratório (BUSOLI et al., 2014). A família Bethylidae possuem três: a vespa da Costa do Marfim *Cephalonomia stephanoderis* (Betrem, 1961); *C. hyalinipennis* (Ashmead, 1893) (Hymenoptera: Bethylidae); e a vespa de Uganda *Prorops nasuta* (Waterson, 1923) e por último a espécie da família Eulophidae: *Phymastichus coffea* (LaSalle, 1990).

São conhecidos diversos métodos para o controle da praga bicho-mineiro-do-cafeeiro, como o controle biológico por ação de predadores e parasitoides e o controle químico. No entanto, esse último apresenta uma eficiência satisfatória, por isso é o método mais empregado por produtores de café. Os inseticidas mais recomendados são dos grupos organofosforado, piretroides e carbamatos, que em sua maioria, apresentam largo espectro de ação. Porém, eles são responsáveis por desequilíbrios biológicos, além do surgimento de resistência a produtos fitossanitários (MENDONÇA et al., 2006).

A recomendação de um determinado produto fitossanitário para o controle de pragas deverá ser fundamentada em alguns fatores, tais como: a seletividade em favor dos inimigos naturais; o custo e a sua eficiência no controle. Em relação à seletividade, ela pode ser inerente ao agrotóxico, estando relacionada à maior tolerância de um certo organismo, possibilitando que ele entre em contato com a praga e não com seus inimigos naturais (MENDONÇA et al., 2006).

## 2.5 Sistemas Inteligentes

### 2.5.1 Redes Neurais Artificiais


As redes neurais artificiais (RNA) são definidas como processadores paralelos na qual simulam o cérebro humano na intenção de coletar evidências empíricas e também à medida que preservam e permitem o uso do conhecimento experimental. Em seu funcionamento, existem sinapses ou ligações inter-neurais que são utilizadas para fins de aprendizagem e armazenamento do conhecimento (SILVEIRA-MARTINS et al., 2016).

As RNAs têm por objetivo representar o modo como o cérebro humano processa dados sensoriais de entrada. No entanto, uma rede neural é um processador distribuído de forma paralela, composta por unidades de processamento simples, com a propensão natural a armazenar conhecimento experimental e, além de tudo, torná-lo disponível ao uso. Na literatura são referidas como neurocomputadores, redes conexionistas, processadores paralelamente distribuídos, entre outros termos. Além disso, as RNAs se assemelham ao cérebro humano na medida em que, por meio do processo de aprendizagem, adquirem conhecimento a partir do ambiente e, por possuir pesos sinápticos ou forças de conexão entre os neurônios que a compõem que lhe permitem armazenar este conhecimento, desenvolvem esta capacidade (SILVEIRA-MARTINS et al., 2016).

Sabe-se que o cérebro humano é composto de bilhões de neurônios. Um neurônio é uma célula formada por três seções com funções específicas e complementares: corpo, dendritos e axônio. Os dendritos captam os estímulos recebidos em um determinado período de tempo e os transmitem ao corpo do neurônio, onde são processados. Quando tais estímulos atingirem determinado limite, o corpo da célula envia novo impulso que se propaga pelo axônio e é transmitido às células vizinhas por meio de sinapses. Este processo pode se repetir em várias camadas de neurônios. Como resultado, a informação de entrada é processada, podendo levar o cérebro a comandar reações físicas. A figura 2.5 ilustra de forma simplificada as partes de um neurônio (FERNEDA, 2006).

Todavia, a busca por um modelo computacional que simule o funcionamento das células do cérebro data dos anos 1940, com o trabalho de Warren S. McCulloch e Walter Pitts em 1943. No entanto, a pesquisa neste campo cresceu durante os anos 1950 e 1960. Nesse período, Frank Rosenblatt em 1958 propôs um método inovador de aprendizagem para as redes neurais artificiais denominado *perceptron*. Até 1969, muitos trabalhos foram realizados utilizando o

Figura 2.5 – Representação simplificada de um neurônio.



Fonte: (FERNEDA, 2006).

*perceptron* como modelo. No final dos anos 1960, Marvin Minsky e Seymour Papert em 1969 publicam um livro no qual apresentam limitações do *perceptron*. As dificuldades metodológicas e tecnológicas, juntamente com os ataques pessimistas de Seymour Papert e Marvin Minsky, fizeram com que as pesquisas arrefecessem nos anos seguintes. Durante os anos 1970, a pesquisa contava apenas com um número ínfimo de cientistas (FERNEDA, 2006).

Porém, durante os anos 1980 com o trabalho de John Hopfield, o entusiasmo ressurgiu graças a avanços metodológicos importantes e ao aumento dos recursos computacionais disponíveis. Mais precisamente em 1982, surgia um modelo de RNA desenvolvido por Hopfield. Tal modelo era baseado em rede com conexões recorrentes e com um comportamento baseado na competição entre os neurônios, na qual o aprendizado era não supervisionado (HOPFIELD, 1982).

Ademais, o último modelo de destaque é o ART (Adaptive Resonance Theory) desenvolvido por Gail Carpenter e Stephen Grossberg em 1993. Tal modelo, possui aprendizado do tipo não supervisionado, criando protótipos dos padrões aprendidos. O modelo ART possui diversas versões, em destaque para a versão do tipo semi-supervisionado e com uso de conceitos de lógica fuzzy.

As Redes Neurais Artificiais são frequentemente utilizadas na resolução de problemas complexos, onde o comportamento das variáveis não é rigorosamente conhecido. Uma de suas principais características das RNAs é a capacidade de aprender por meio de exemplos e de generalizar a informação aprendida, gerando um modelo não linear, tornando sua aplicação na análise espacial bastante eficiente (TAVARES et al., 2016).

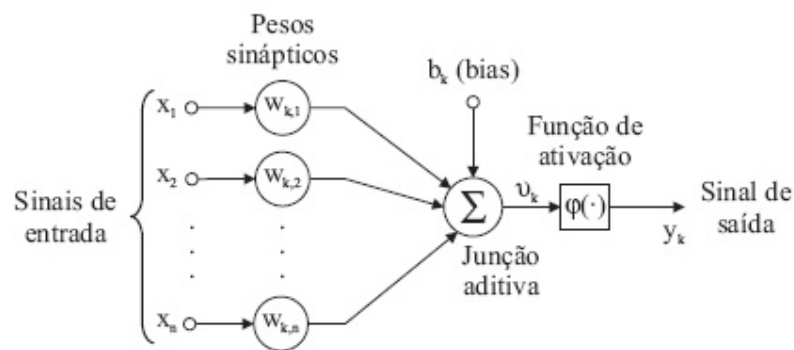
As RNAs têm apresentado elevado desempenho devido a fatores como: estrutura robusta e camadas paralelamente distribuídas; eficiência no aprendizado e generalização, que as tornam

capazes de resolver dos mais variados problemas complexos; são tolerantes a dados discrepantes ou "outliers"; podem modelar distintas variáveis e suas relações não lineares; e possibilitam a modelagem com variáveis categóricas, além das numéricas (LEAL et al., 2015).

Entretanto, em termos de topologia, para implementar uma RNA deve-se definir diferentes variáveis, dentre as quais destacam - se: o número de nós na camada de entrada (tal variável corresponde ao número de variáveis que serão utilizadas para alimentar a rede neural, sendo normalmente as variáveis de maior importância para o problema em estudo); o número de camadas escondidas e o número de neurônios a serem inseridos nessas camadas; e o número de neurônios na camada de saída (TAVARES et al., 2016).

O modelo de uma rede neural artificial da figura 2.6 é uma simplificação do modelo apresentado por (ZANETTI et al., 2008).

Figura 2.6 – Modelo matemático não-linear dos neurônios utilizados na RNA.



Fonte: (ZANETTI et al., 2008).

Os pesos sinápticos ( $W_{k,j}$ ) o índice  $k$  se refere ao neurônio em questão, enquanto o índice  $j$  diz respeito ao sinal de entrada da sinapse com a qual o peso tem relação. A junção aditiva possui como propósito somar todos os sinais de entrada ( $x_j$ ) ponderados pelos pesos sinápticos de cada neurônio. O bias ( $b_k$ ) funciona aumentando ou diminuindo a influência do valor da entrada para a ativação do neurônio; por outro lado, a função de ativação funciona restringindo a amplitude de saída de determinado neurônio e adicionando não-linearidade ao modelo; o neurônio apresentado na Figura 2.2 pode ser descrito pelas seguintes equações matemáticas:

$$u_k = \sum_{j=1}^n W_{kj} \cdot X_j \quad (2.1)$$

$$v_k = u_k + b_k \quad (2.2)$$

$$y_k = \varphi(v_k) \quad (2.3)$$

sendo:  $u_k$  é a saída do combinador linear (junção aditiva);  $W_{(k,1)}, W_{(k,2)}, \dots, W_{(k,n)}$  são os pesos sinápticos;  $x_1, x_2, \dots, x_n$  são os sinais de entrada;  $v_k$  é o potencial de ativação;  $(b_k)$  é o bias;  $y_k$  é o sinal de saída do neurônio  $k$  e  $\varphi(\cdot)$  é a função de ativação.

As redes neurais artificiais se diferenciam pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado. A RNA possui a propriedade de aprender por intermédio de exemplos e realizar inferências sobre o que aprendeu, assim melhorando gradativamente o seu desempenho. As redes neurais utilizam um algoritmo de aprendizagem cuja tarefa é ajustar os pesos de suas conexões.

Entretanto, as RNA's possuem duas formas básicas de aprendizado: aprendizado supervisionado e aprendizado não supervisionado. No aprendizado supervisionado, um agente externo apresenta à rede neural alguns conjuntos de padrões de entrada e seus correspondentes padrões de saída, assim é necessário ter um conhecimento prévio do comportamento que se deseja ou se espera da rede. Para cada entrada, esse agente externo, indica explicitamente se a resposta calculada é aceitável ou não. A resposta fornecida pela rede neural é comparada à resposta esperada. O erro verificado é informado à rede para que sejam feitos ajustes a fim de melhorar suas futuras respostas desejadas (FERNEDA, 2006).

Por outro lado, na aprendizagem não supervisionada ou aprendizado auto-supervisionado, não existe um agente externo para acompanhar o processo de aprendizado. Neste tipo de aprendizagem, somente os padrões de entrada estão disponíveis para a rede neural. A rede processa as entradas e, detectando suas regularidades, tenta progressivamente estabelecer representações internas para codificar características e classificá-las automaticamente. Este tipo de aprendizado só é possível quando existe redundância nos dados de entrada, para que se consiga encontrar padrões em tais dados (FERNEDA, 2006).

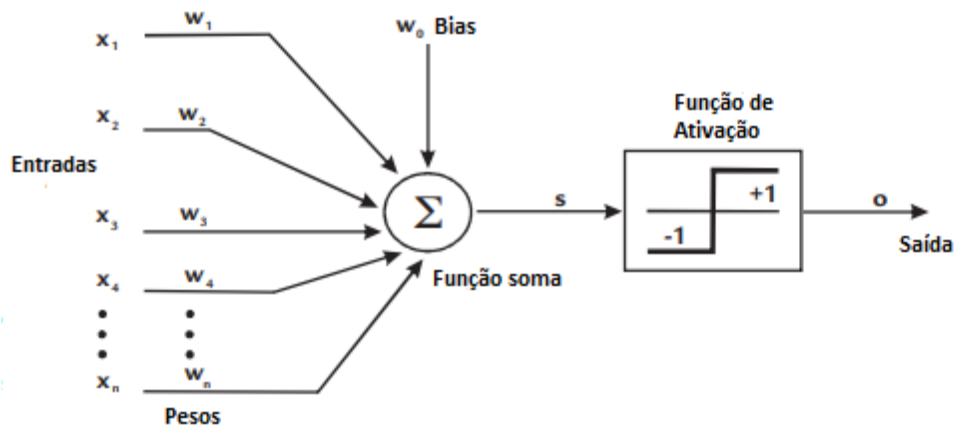
Com tudo, uma rede neural extrai seu potencial computacional máximo por meio de sua estrutura e sua habilidade de aprender e generalizar. As RNAs produzem saídas ajustadas e adequadas mesmo recebendo entradas que não estavam no processo de treinamento, portanto podendo interpretar leituras errôneas sem modificar os resultados.

### 2.5.1.1 O Perceptron

Nas décadas de 1950 e 1960 Frank Rosenblatt pesquisou e desenvolveu um modelo de neurônio denominado *perceptron*, como é observado na figura 2.7.

Por meio das entradas  $x_i$ , são apresentados os valores que se desejam processar. Os pesos das sinapses  $w_i$ , na qual representam o aprendizado da rede, assumirão valores que, aplicados aos valores de entrada, resultarão em uma saída intermediária  $s$ . Por outro lado, a variável  $w_0$ , denominada *bias*, não multiplica nenhuma entrada, uma vez que possui valor fixo, sendo assim, funcionando como ajuste fino da rede (MEDEIROS, 2006).

Figura 2.7 – Modelo de um neurônio proposto por Rosenblatt.



Fonte: (MEDEIROS, 2006).

Com a intenção de obter o valor da saída intermediária  $s$ , realiza-se o somatório da multiplicação entre as entradas e seus respectivos pesos em um função, como pode-se ser observado em (2.4).

$$s = \sum(x_j w_{ij}) + w_0 \quad (2.4)$$

Dando sequência, a função de ativação ou de transferência modula a amplitude do intervalo do sinal de saída do neurônio para algum valor finito, normalmente no intervalo  $[-1,1]$  ou  $[0,1]$ , observa-se na função (2.5). A respeito das funções de ativação utilizáveis, a de uso mais comum é a sigmoideal, por apresentar algumas características interessantes, tais como: continuidade, monotonicidade, não linearidade e diferenciabilidade em qualquer ponto (MEDEIROS, 2006).

$$y_i = \frac{1}{1 + e^{(-\lambda s_i + \rho)}} \quad (2.5)$$

Onde  $\rho$  é a constante de translação da curva  $y_i$  e  $\lambda$  é a constante de inclinação da curva  $Y_i$ .

### 2.5.1.2 Redes de Múltiplas Camadas

As redes de múltiplas camadas distinguem-se das redes de camada simples pelo número de camadas intermediárias, aquelas entre a camada de entrada e a de saída. No entanto, dentre as redes de múltiplas camadas, uma que possui destaque é a do tipo *Perceptrons* de Múltiplas Camadas (*Multilayer Perceptron* - MLP), que apresentam uma ou mais camadas de neurônios intermediários ou ocultas, sendo considerada uma aproximadora universal. Sendo assim, De acordo com o teorema da aproximação universal, qualquer função contínua pode ser uniformemente aproximada por uma rede com pelo menos uma camada de neurônios ocultos, e com uma função de ativação sigmoide (SILVA; LEAL; LIMA, 2019).

Considere seja  $\varphi(\cdot)$  uma função contínua, limitada e monotonamente crescente e  $I_{m_0}$  um hipercubo unitário  $[0, 1]^{m_0}$  de dimensão  $m_0$ . O espaço das funções contínuas em  $I_{m_0}$  é representado por  $C(I_{m_0})$ . Logo, concedida qualquer função  $f \in C(I_{m_0})$  e  $\varepsilon > 0$ , existe um inteiro  $M$  e conjuntos de constantes reais  $\alpha_i$ ,  $b_i$  e  $w_{ij}$ , onde  $i = 1, \dots, m_1$  e  $j = 1, \dots, m_0$  tal que pode-se definir:

$$F(x_1, \dots, x_{m_0}) = \sum_{i=1}^{m_1} \alpha_i \varphi\left(\sum_{j=1}^{m_0} w_{ij} x_j + b_i\right) \quad (2.6)$$

Como (2.4) é uma realização aproximada da função  $f(\cdot)$ , isto é:

$$|F(x_1, \dots, x_{m_0}) - f(x_1, \dots, x_{m_0})| < \varepsilon \quad (2.7)$$

para todo  $x_1, x_2, \dots, x_{m_0}$  que se encontre no espaço de entrada.


Portanto, o teorema rema da aproximação universal é diretamente aplicável aos *perceptrons* de múltiplas camadas (SILVA; LEAL; LIMA, 2019).

A Figura 2.8 representa uma rede MLP com três entradas, duas camadas intermediárias com quatro neurônios e uma camada de saída com um neurônio produzindo uma única informação de saída.

Contudo, as redes MLP têm sido aplicadas com êxito para resolver uma gama de problemas, por meio do treinamento de forma supervisionada com a utilização do algoritmo de retropropagação do erro (*backpropagation*), o qual apresenta duas fases distintas. Na primeira fase, ocorre a propagação do sinal funcional (*feedforward*) mantendo-se os pesos fixos para ge-



Figura 2.8 – Representação gráfica de uma rede MLP com duas camadas intermediárias e uma saída.



Fonte: (SILVA; LEAL; LIMA, 2019) adaptado.

rar um valor de saída a partir das entradas fornecidas à rede. Na segunda fase, as saídas são comparadas com os valores desejados, gerando um sinal de erro, que se propaga da saída para a entrada, ajustando-se os pesos de forma a minimizar o erro. Sendo assim, a forma de calcular o erro depende da camada em que se encontra o neurônio, na qual é observado na (2.8) (SILVA; LEAL; LIMA, 2019).

$$\delta_l = \begin{cases} f'_a e_l, & \text{se } n_l \in C_{sai} \\ f'_a \sum w_{lk} \delta_k, & \text{se } n_l \in C_{int} \end{cases} \quad (2.8)$$

Onde  $n_l$  é o  $l$ -ésimo neurônio,  $C_{sai}$  representa a camada de saída,  $C_{int}$  representa uma camada intermediária,  $f'_a$  é a derivada parcial da função de ativação do neurônio e  $e_l$  é o erro quadrático cometido pelo neurônio de saída quando sua resposta é comparada à desejada, que é definido pela equação (2.9).

$$e = \frac{1}{2} \sum_{q=1}^k (y_q - \hat{y}_q)^2 \quad (2.9)$$

Onde  $\hat{y}_q$  é a saída produzida pelo neurônio e  $y_q$  é a saída desejada.

Nota-se que a derivada parcial define o ajuste dos pesos, utilizando o gradiente descendente da função de ativação, entretanto, ela avalia a contribuição de cada peso no erro da rede para a classificação de um dado objeto. Na hipótese da derivada para um dado peso for positiva, o peso está facultando um aumento da diferença entre a saída e a entrada desejada da rede. Por

outro lado, se a derivada para um dado peso permanecer negativa, o peso estará contribuindo no sentido que a saída da rede esteja mais próxima da desejada.

### 2.5.2 Árvores de Decisão

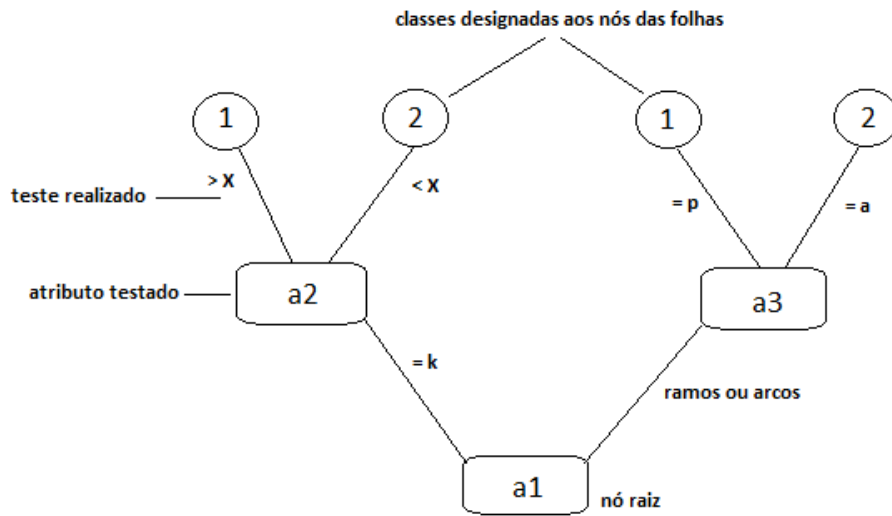
Um outro Sistema Inteligente utilizado para predição são árvores de decisão. Na qual são modelos de classificação cuja a estrutura consiste em um determinado número de nós e ramos. No topo da estrutura, o nó raiz é o primeiro nó da árvore. Por outro lado, os nós internos, incluindo o nó raiz, são nós de decisão. Conseqüentemente, cada um contém um teste sobre uma variável independente e os resultados desse teste formam os ramos da árvore. Entretanto, os nós folhas, nas extremidades das árvores, representam valores de predição para a variável dependente ou distribuições de probabilidade desses valores (MEIRA; RODRIGUES; MORAES, 2008).

As árvores de decisão são conhecidas também como árvores de classificação ou regressão, onde a variável dependente seja categórica ou numérica, respectivamente. Dado isto, o propósito básico da inclusão de uma árvore de decisão é produzir um modelo de predição acurado ou localizar a estrutura preditiva do problema. Neste último caso, a intenção é compreender quais variáveis e interações das mesmas conduzem o fenômeno pesquisado. Portanto, as árvores de decisão possuem representação simbólica e interpretável, facilitando compreender quais as variáveis e suas interações que conduzem ao fenômeno estudado (MEIRA; RODRIGUES; MORAES, 2008; NETO; RODRIGUES; MEIRA, 2014).

Para construir uma árvore de decisão, o mais comum é a utilização do algoritmo dividir para conquistar, ou seja, ele trabalha dividindo o conjunto de dados de treinamento em subconjuntos. Este algoritmo inicia selecionando a árvore de decisão de forma mais geral, incluindo o nó inicial na qual é conhecido como nó raiz. Com base nisto, o algoritmo é aplicado recursivamente em todo nó da árvore refinando esta para que cada subconjunto pertença a uma exclusiva classe. Com isso, os resultados de subconjuntos obtidos na construção de uma árvore de decisão possuem dados organizados de forma compactada (QUINLAN, 1993).

Na figura 2.9, os nós são representados pelos atributos  $a_1$ ,  $a_2$  e  $a_3$ , organizados na árvore de acordo com seu nível informativo. No ramos ou arcos são testados os respectivos valores do atributo designado ao nó a que pertencem. Por outro lado, os testes são realizados levando em consideração os valores dos atributos que, quando categóricos, são representados por uma igualdade ( $= k$ ), como é observado na figura 2.9, onde  $k$  é um valor do atributo. No entanto,

Figura 2.9 – Exemplo simplificado de um classificador utilizando árvore de decisão.



Fonte: Fonte: Do autor (2021).

quando os atributos possuem valores quantitativos, estes são representados por um intervalo de valor, por exemplo,  $> X$ , na qual este valor é obtido por meio de cálculo. E por fim, cada círculo no final dos arcos da árvore está associada aos nós folhas, no caso da 2.9, 1 relaciona uma classe positiva e 2 um outra classe negativa (QUINLAN, 1986; GARCIA, 2003).

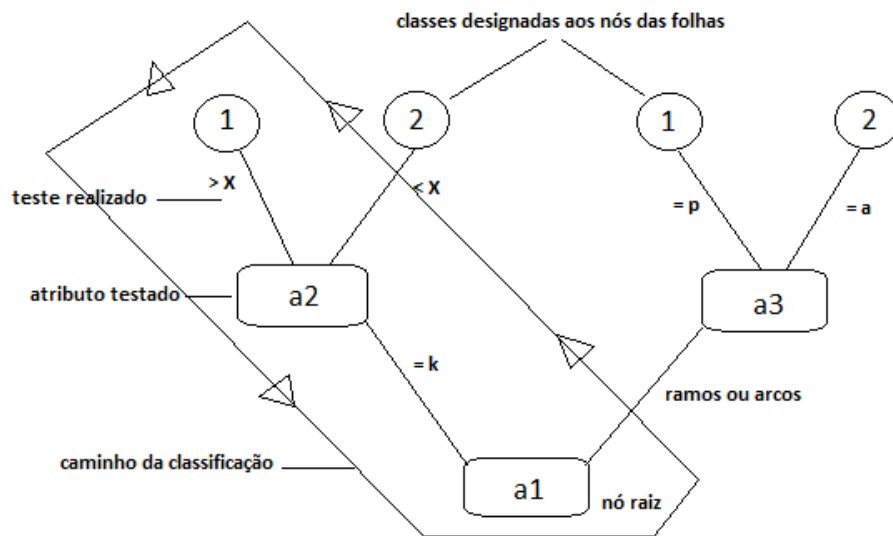
A classificação na árvore (figura 2.9), como qualquer outra, ocorre ao se percorrer o caminho que se inicia no nó raiz (a1) na qual se estende ate as folhas. O cenário pode ser observado na figura 2.10. O caminho tracejado na figura 2.10 indica uma classificação onde o atributo a1 valor igual a k e o atributo a2 valor maior que um determinado X.

Sendo assim, por meio dos caminhos descritos por uma árvore de decisão é possível derivar regras. As árvores e as regras são utilizadas em conjunto devido ao fato delas tenderem a crescer bastante de acordo com algumas aplicações, por isso elas são substituídas, na maioria dos casos, pelas regras. Isto ocorre em virtude de as regras poderem ser simplesmente modularizadas.

Em virtude disso, a regra extraída do caminho de classificação demarcado na figura 2.10 é dado por:

"Se  $a1 = k$  e se  $a2 > X$  então 1"

Figura 2.10 – Exemplo de um possível caminho para classificação.



Fonte: Fonte: Do autor (2021).

## 2.6 Validação Cruzada

O princípio básico da validação cruzada é avaliar a capacidade de generalização de um modelo com base em um conjunto de dados. Esta técnica é implementada em problemas que envolvem ou tem como objetivo a predição de um determinado modelo em estudo. Sendo assim, busca-se estimar o quão é exato este modelo na prática, isto é, a sua performance para um novo conjunto de dados (KOHAVI, 1995).

Validar um modelo é um estágio fundamental para obter uma avaliação da capacidade de predição do mesmo. No entanto, o conceito das técnicas de validação cruzada é o particionamento de subconjuntos de dados mutuamente exclusivos, onde parte são utilizados como subconjuntos de dados para treinamento e o restante do subconjuntos empregados na validação ou teste do modelo (KOHAVI, 1995).

Dando continuidade, para esta técnica de validação cruzada, um subconjunto de treino é constituído utilizando  $n - 1$  partições, e o restante dessa partição constitui o subconjunto de teste, na qual este último é empregado para estimar o erro de classificação gerado. Sendo assim, estas partições realizadas que são determinados subconjuntos de dados, ocorrem  $n$  permutações distintas, onde são construídos classificadores parciais.

### 2.6.1 K-Fold

Uma técnica de validação cruzadas utilizada em modelos de predição é o método *K-fold*. Nesta técnica, a amostra de dados  $d$  é particionada em  $K$  partes, ou seja, em  $d_1, d_2, d_3, \dots, d_k$ , onde cada uma possui tamanhos similares, em que  $\sum_{k=1}^K m_k = n$ . Este método terá  $K$  iterações na qual a amostra de validação será dada por  $d_k$ , em cada iteração, com  $k = 1, 2, \dots, K$ . Por outro lado, a amostra de treino para o desenvolvimento do preditor será o conjunto das outras amostras  $K - 1$  partes, ou seja,  $d_{(-k)} = (d_1, d_2, d_3, \dots, d_{k-1}, d_{k+1}, \dots, d_k)$ . Portanto, ao final de todos os  $K$  passos, teríamos utilizados na sua totalidade os dados para treino e na parte de validação ou teste (BURMAN, 1989). O método *K-fold* é dado por:

$$kfK = \frac{1}{K} \sum_{k=1}^K \frac{1}{m_k} \sum_{i=1}^{m_k} L(y_{ik}, \hat{f}_{(-k)}(X_{(ik)})) \quad (2.10)$$

Na qual o preditor  $\hat{f}_{(-k)}(X)$  é originado com a amostra de treino  $d_{(-k)}$  e esse preditor é mensurado nas observações das amostras de teste  $d_k$  para  $k = 1, 2, 3, \dots, K$ .

## 2.7 Métricas Estatísticas para Validação

Modelos de regressão linear é um método utilizado para a obtenção de uma função de predição para predizer os valores de uma variável resposta  $Y$  utilizando uma ou mais variáveis preditoras  $X_1, X_2, \dots, X_k$ . No entanto, este modelo de regressão é linear se as derivadas parciais de primeira ordem da variável dependente, não serem funções dos próprios parâmetros (SCHABENBERGER; PIERCE, 2002). Dessa forma, o modelo linear é dado por:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_m X_{im} + e_i \quad (2.11)$$

Onde  $Y_i$  é a  $i$ -ésima observação da variável resposta;  $X_{ik}$  é a  $i$ -ésima análise da  $k$ -ésima variável;  $\beta_k$  são os parâmetros do modelo;  $e_i$  é o erro experimental associado à  $i$ -ésima observação.

### 2.7.1 Coeficiente de Determinação

O coeficiente de determinação, conhecido como  $R^2$ , é uma grandeza de ajuste de um modelo linear generalizado, como a regressão linear, ou seja, representa a qualidade do ajuste linear. O  $R^2$  contempla um intervalo que varia entre 0 e 1, ocasionalmente é expressado em

termos de percentuais. Quando mais próximo desse coeficiente estiver de 1, melhor será o ajuste ao conjunto de pontos. O coeficiente de determinação é dado por:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.12)$$

Onde  $y_i$  é o valor observado;  $\hat{y}_i$  é a previsão de  $y_i$ ;  $\bar{y}$  é a média das observações.

### 2.7.2 RMSE (*Root Mean Square Error*)

Uma medida constantemente utilizada na verificação da acurácia de modelos numéricos é o Erro Quadrático Médio (MSE na sigla em Inglês). MSE é sempre positivo. MSE igual a zero indica simulação perfeita (WILKS, 2006). MSE é definido por:

$$MSE = \frac{1}{n} \sum_{i=1}^n (E_i - O_i)^2 \quad (2.13)$$

sendo:  $E_i$  valores estimados;  $O_i$  os valores observados; e  $n$  é o número de observações.

No entanto, em acréscimo ao MSE, a raiz quadrada de MSE, ou Raiz do Erro Quadrático Médio (RMSE em Inglês), é normalmente utilizada para expressar a acurácia dos resultados numéricos com a vantagem de que RMSE apresenta valores do erro nas mesmas dimensões da variável analisada (HALLAK; FILHO, 2011). O RMSE é definido por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (E_i - O_i)^2} \quad (2.14)$$

## 2.8 SMOTE - *Synthetic Minority Oversampling Technique*

Métodos de sobreamostragem conhecido como *oversampling* inserem exemplos na classe minoritária com o objetivo de balanceamento. Deste modo, essas técnicas podem replicar representantes da classe minoritária, ou seja, sobreamostragem com repetição, de forma aleatória ou informativa, ou gerar estes dados artificialmente.


A técnica SMOTE proposta por (CHAWLA et al., 2006) gera dados artificiais por meio de interpolação. Para isto, ela utiliza o algoritmo *K-Nearest Neighbors* (KNN) (AHA; KIBLER; ALBERT, 1991) para produzir representantes entre exemplos e seus  $k$  vizinhos. Para tanto, um exemplo da classe minoritária é selecionado e o vetor obtido pela diferença entre o elemento em consideração e seu vizinho é multiplicado por um número aleatório no intervalo entre 0 e 1. Este novo vetor é aplicado sobre o elemento em consideração, onde é selecionado um ponto

no espaço, na qual fica na reta entre o elemento e seu vizinho. Portanto, o novo ponto que representa a classe minoritária é gerado. Este processo é representado pela equação 2.1.

$$x_{novo} = x_i + (\hat{x}_i - x_i)\gamma \quad (2.15)$$

Onde  $x_i$  é o exemplo selecionado;  $\hat{x}_i$  é o seu vizinho mais próximo;  $\gamma$  é o número aleatório entre 0 e 1.

Figura 2.11 – Exemplo de distribuição de dados gerados.



Fonte: Do autor (2021).

Como um exemplo para ilustrar, considere a figura 2.11 com um conjunto de dados em um espaço de dois atributos, onde os 'X' pertence a classe majoritária e os círculos em vermelho a classe minoritária.

### 3 MATERIAIS E MÉTODOS

#### 3.1 Base de Dados

Para o desenvolvimento dos modelos propostos neste trabalho, foram utilizados dados meteorológicos fornecidos e extraídos na plataforma Nasa Power - *Prediction Of Worldwide Energy Resources* (LaRC, 2020). Adicionalmente, a EPAMIG forneceu dados de amostras coletadas de pragas e doenças em um campo experimental na cidade de São Sebastião do Paraíso - MG; Latitude: 20° 55' 2" Sul, Longitude: 46° 59' 29" Oeste. Estas amostras coletadas correspondem ao período de janeiro de 2015 a dezembro de 2019.

Para cada dado fornecido pela EPAMIG, uma amostragem foi feita no cafeeiro. Para a ferrugem-do-cafeeiro e a cercosporiose, os percentuais de incidência foram levantados a partir de 100 amostras de folhas de café, verificando-se quantitativamente a manifestação de cada uma destas doenças (vide Tabela 3.1). Para as pragas bicho-mineiro-do-cafeeiro e broca-do-café, os dados de ocorrência foram levantados a partir de 200 amostras de folhas de café e 1000 amostras do fruto do café, respectivamente. Estas amostras foram coletadas uma vez por mês e no início de cada mês.

Tabela 3.1 – Informações sobre amostras coletadas, quantidade de dados e variáveis meteorológicas.

Pragas/Doenças	Exemplares	Dados reais	Variáveis
Bicho-mineiro	200	60	6
Broca	1000	25	6
Ferrugem	100	60	6
Cercosporiose	100	60	6

Fonte: Do autor (2021).

A coluna Exemplares na Tabela 3.1 refere-se ao número de amostras de folha e/ou fruto utilizado na computação do percentual de infestações/infecções (pragas ou doenças), enquanto que o número de amostras disponíveis para o desenvolvimento do trabalho está relacionado na coluna Dados reais, para cada caso. Finalmente, a coluna Variáveis refere-se ao número de variáveis de entrada (disponíveis para cada dado de praga e doença) aplicadas nos modelos de sistemas inteligentes propostos.

As variáveis de entrada são os dados meteorológicos referentes ao mês anterior da coleta das amostras de pragas e doenças e consistem em: temperaturas mínima e máxima (em graus Celsius), índice pluviométrico (em milímetros), umidade relativa do ar (em valor absoluto), insolação total (em horas) e a quantidade de dias sem precipitação de água. Para cada um destes



dados, exceto para a última variável mencionada, foram calculadas as médias para o mês, uma vez que os valores são diários.

As coletas das amostras de folhas e frutos do café foram realizadas pela equipe da EPA-MIG da seguinte forma: o técnico, especialista na área de café, percorre as duas "ruas" do campo experimental a fim de coletar metade das amostras em cada uma dessas "ruas". Por exemplo, para a cercosporiose (vide Tabela 3.1), 50 amostras foram coletadas na primeira "rua" e as 50 restantes na segunda "rua", totalizando 100 amostras coletadas. Após essa etapa, ele inspeciona cada folha e fruto no intuito de localizar e registrar a incidência e ocorrência de doenças e pragas, respectivamente.

Devido ao baixo desempenho dos algoritmos após os primeiros treinamentos devido à base de dados pequena, foi necessário o uso da técnica SMOTE (vide Seção 2.8) para gerar novas amostras artificiais de pragas e doenças no cafeeiro. Já que o SMOTE usa amostras reais para gerar as artificiais, tomou-se o cuidado de separar 20% dos dados originais (reais), antes da geração dos dados artificiais. Posteriormente, realizou-se o teste final com estes dados nos modelos de sistemas inteligentes propostos neste trabalho e averiguou-se a acurácia dos mesmos a fim de se obter uma validação final.

A coluna Dados de Treinamento na Tabela 3.2 refere-se aos dados reais (conforme Tabela 3.1) coletados mais os dados artificiais gerados pela técnica SMOTE (Seção 2.8) para o treinamento dos modelos propostos. Os valores correspondente à coluna Dados de Validação são para cada *fold* (Subseção 2.6.1) utilizados na validação após os treinamentos dos sistemas inteligentes. Foram utilizados 8 *folds* para Bicho-Mineiro-do-Cafeeiro e para Cercosporiose, 5 para Broca-do-Café e 6 para Ferrugem-do-Cafeeiro. E por fim, a coluna Dados de Teste dessa tabela representa 20% dos dados reais retirados antes de aplicar a técnica SMOTE para a realização do teste final dos modelos.

Tabela 3.2 – Dados de pragas e doenças utilizados nos treinamentos e testes dos modelos.

Pragas/Doenças	Dados de Treinamento	Dados de Validação	Dados de Teste
Bicho-mineiro	144	18	12
Broca	100	20	5
Ferrugem	96	16	12
Cercosporiose	192	24	12

Fonte: Do autor (2021).

### 3.2 Modelos Utilizados

Para a construção dos sistemas inteligentes foram implementados modelos de aprendizado de máquina fundamentados em Redes Neurais Artificiais do tipo MLP e Árvores de Decisão.

O projeto das redes neurais artificiais e árvores de decisão foi realizado via *software* MATLAB no Laboratório de Processamento de Dados do Programa de Pós-Graduação em Engenharia de Sistemas e Automação da Universidade Federal de Lavras, localizado no Departamento de Automática. Os algoritmos auxiliares, tais como: tratamento dos dados, cálculo de médias e outros também foram realizados no MATLAB.

A rede neural MLP proposta possui duas camadas intermediárias, em que variaram-se experimentalmente a quantidade de neurônios destas camadas e percebeu-se a melhor combinação dos mesmos. Em seguida, fixou-se esta combinação de neurônios nas camadas da rede neural em 7 neurônios na primeira camada e 7 na segunda nos modelos de predição de ferrugem-do-cafeeiro, broca-do-café, bicho-mineiro-do-cafeeiro e cercosporiose.

Além disso, foram utilizadas quatro tipos de funções de treinamento no modelo de rede neural MLP, que são: *Bayesian Regulation backpropagation* (trainbr) (MACKAY, 1992), *Levenberg-Marquardt backpropagation* (trainlm) (HAGAN; MENHAJ, 1994; HAGAN; DEMUTH; BEALE, 1996), *Resilient backpropagation* (trainrp) (RIEDMILLER; BRAUN, 1993) e *Scaled conjugate gradient backpropagation* (trainscg) (MOLLER, 1993). Diante destas quatro funções, avaliou-se qual delas, por meio de um treinamento prévio dos modelos, demonstrou um desempenho que qualificasse a fixação de uma função para ser utilizada nos modelos de predição de pragas e doenças.

O modelo de árvores de decisão apresenta quatro nós-folhas. Para este modelo variaram-se experimentalmente a quantidade de nós e identificou-se este valor como sendo o mais favorável ao sistema em questão. Na sequência, esta combinação de nós-folhas foram utilizados nos modelos de predição do bicho-mineiro-do-cafeeiro, broca-do-café, ferrugem-do-cafeeiro e cercosporiose.

Ainda neste trabalho foi realizada uma comparação dos sistemas inteligentes com um método de regressão linear básico descrito como *multiple linear regression* (CHATTERJEE; HADI, 1986). Todos os modelos de regressão desenvolvidos contêm sete coeficientes. Este método de regressão apresenta 95% de confiança na estimativa destes coeficientes.

A metodologia de validação cruzada via *k-fold* descrita na Subseção 2.6.1 foi aplicada a todos os modelos implementados. O desempenho dos modelos foi medido por meio de métricas estatísticas conforme descrito na próxima seção.

A complexidade computacional foi avaliada nos modelos propostos por meio do tempo de execução que cada algoritmo leva para ser processado no intuito de identificar qual possui maior vantagem operacional. O cálculo do tempo de execução de cada modelo foi realizado pelo *software* MATLAB. A configuração de *hardware* da máquina que realizou estes processamentos possui processador de 2,4 GHz, memória RAM de 8 GB (Giga Bytes), capacidade de armazenamento de 500 GB (Giga Bytes) e sistema operacional de 64 bits. Neste processo foram desativadas todas as atividades paralelas da máquina para o cálculo do tempo de processamento.

### 3.3 Métricas de Validação

Para validar os modelos implementados foram utilizados dois tipos de métricas estatísticas, que são: RMSE (*Root Mean Square Error*) ou raiz do erro quadrático médio, descrita na Subseção 2.7.2, e o coeficiente de determinação conhecido como  $R^2$ , detalhado na Subseção 2.7.1, além de cálculos de médias e desvio padrão.

Foi utilizado um método estatístico denominado teste t de *Student* (GOSSET, 1908) para identificar a diferença estatística das médias com nível de significância de 95% nos dados de teste dos modelos de predições propostos.

A aplicação da técnica de validação cruzada *k-fold* (Subseção 2.6.1) decorreu nos sistemas inteligentes da seguinte forma: os modelos de predição bicho-mineiro-do-cafeeiro e cercosporiose possuem oito *folds* cada. Por outro lado, a ferrugem-do-cafeeiro e a broca-do-café possuem seis e cinco *folds*, respectivamente.

### 3.4 Desenvolvimento de Aplicativo

Para promover uma interação com o usuário final e a predição de doenças e pragas no cafeeiro de forma dinâmica e simples, foi projetado e desenvolvido um aplicativo para *smartphones* na plataforma *App Inventor*, a qual é uma ferramenta *open source* (MIT App Inventor, 2020). Após os desenvolvimentos e realizações de testes dos sistemas inteligentes propostos neste trabalho, inseriu-se no aplicativo o modelo matemático de predição que apresentou uma performance satisfatória.

## 4 RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados obtidos com os sistemas inteligentes propostos e com o método convencional (regressão linear) para cada uma das bases de dados. O produto final que consistiu no desenvolvimento de um aplicativo para *smartphones* é também demonstrado neste Capítulo. Os resultados referentes aos sistemas inteligentes foram organizados por técnica de *machine learning* utilizada.

### 4.1 Redes Neurais MLP

#### 4.1.1 Teste preliminar

Os valores da Tabela 4.1 são referentes à média dos *folds* considerados utilizando a base de dados da doença ferrugem-do-cafeeiro, cercosporiose, bicho-mineiro-do-cafeeiro e broca-do-café, para o treinamento da rede neural MLP. Nota-se nesta tabela que o algoritmo de treinamento *trainlm* (*Levenberg-Marquardt*) apresentou um valor menor de RMSE perante as outras. Sendo assim, utilizou-se este algoritmo nos treinamentos posteriores para encontrar os modelos finais de predição de doenças e pragas.

Tabela 4.1 – Média e desvio padrão do RMSE de um teste preliminar para a seleção da função de treinamento a ser utilizada nos modelos de predição.

Função	Ferrugem	Cercosporiose	Bicho-mineiro	Broca-do-café
<i>trainlm</i>	0,3292 ± 0,0248	0,2703 ± 0,0361	0,2924 ± 0,0351	0,3311 ± 0,0119
<i>trainbr</i>	0,4177 ± 0,0442	0,2818 ± 0,0127	0,2995 ± 0,0274	0,3410 ± 0,0301
<i>trainscg</i>	0,4290 ± 0,0371	0,3460 ± 0,0320	0,3521 ± 0,0388	0,3467 ± 0,0294
<i>trainrp</i>	0,5239 ± 0,0296	0,3319 ± 0,0287	0,3578 ± 0,0229	0,3616 ± 0,0193

Fonte: Do autor (2021).

#### 4.1.2 Resultados dos Modelos de Predição

As Tabelas 4.2, 4.3, 4.4 e 4.5 referem-se aos resultados de RMSE e  $R^2$  obtidos para cada *fold* em que utilizou-se o algoritmo de treinamento *trainlm* (*Levenberg-Marquardt*) nos modelos de predição de doenças e pragas. As colunas dois e três de cada uma destas Tabelas apresentam os resultados utilizando dados de validação no modelo proposto, enquanto que as colunas quatro e cinco são os resultados para dados de teste.

É importante ressaltar que a base de dados é fixa e segue a descrição da Tabela 3.2, ou seja, para cada *fold* da validação cruzada, o correspondente modelo foi aplicado à base de dados de doença ou praga correspondente.

Tabela 4.2 – Resultados dos RMSE,  $R^2$  e a média com o desvio padrão dos *fold*s para o modelo de predição da praga bicho-mineiro-do-cafeeiro.

<i>Fold</i>	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
<i>fold</i> 1	0,0182	0,9502	0,0323	0,8487
<i>fold</i> 2	0,0203	0,9345	0,0539	0,8106
<i>fold</i> 3	0,0246	0,9590	0,0593	0,7799
<i>fold</i> 4	0,0190	0,9068	0,0902	0,8913
<i>fold</i> 5	0,0226	0,9165	0,0404	0,8084
<i>fold</i> 6	0,0265	0,9478	0,0702	0,7943
<i>fold</i> 7	0,0310	0,9307	0,0676	0,7613
<i>fold</i> 8	0,0136	0,9503	0,0444	0,8052
<b>média</b>	<b>0,0220 ±0,0051</b>	<b>0,9370 ±0,0171</b>	<b>0,0573 ±0,0175</b>	<b>0,8125 ±0,0381</b>

Fonte: Do autor (2021).

Tabela 4.3 – Resultados dos RMSE,  $R^2$  e a média com o desvio padrão dos *fold*s para o modelo de predição da praga broca-do-café.

<i>Fold</i>	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
<i>fold</i> 1	0,0244	0,9809	0,0377	0,9058
<i>fold</i> 2	0,0162	0,9724	0,0981	0,7811
<i>fold</i> 3	0,0195	0,9623	0,0198	0,9479
<i>fold</i> 4	0,0208	0,9885	0,0418	0,8191
<i>fold</i> 5	0,0322	0,9974	0,0246	0,9037
<b>média</b>	<b>0,0226 ±0,0055</b>	<b>0,9803 ±0,0122</b>	<b>0,0444 ±0,0280</b>	<b>0,8715 ±0,0616</b>

Fonte: Do autor (2021).

Apesar dos resultados utilizando somente dados de teste ficarem inferiores quando comparados com os dados de validação para todas as bases de dados, eles obtiveram uma significativa média de RMSE e  $R^2$  que variou entre 0,0444 a 0,1569 e 0,7552 a 0,8715, respectivamente (vide Tabelas 4.2 a 4.5). Isso mostra a capacidade de generalização dos modelos, visto que os dados de teste são referentes a dados reais que não foram apresentados ao modelo durante o projeto.

O modelo de predição da ferrugem-do-cafeeiro apresentou desempenhos inferiores de RMSE e  $R^2$  quando comparados com os outros modelos de pragas e doenças. Isto se deve pelo fato de que a sua base de dados utilizada para o treinamento da rede neural artificial é menor do que as outras bases de dados (vide Tabela 3.2). Um outro aspecto que pode ter contribuído

Tabela 4.4 – Resultados dos RMSE,  $R^2$  e a média com o desvio padrão dos *fold*s para o modelo de predição da doença cercosporiose.

<i>Fold</i>	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
<i>fold 1</i>	0,0238	0,9066	0,0757	0,7035
<i>fold 2</i>	0,0143	0,9217	0,1375	0,7748
<i>fold 3</i>	0,0175	0,9358	0,0704	0,7559
<i>fold 4</i>	0,0199	0,8201	0,0869	0,8562
<i>fold 5</i>	0,0216	0,9171	0,0812	0,7186
<i>fold 6</i>	0,0187	0,9593	0,0727	0,7232
<i>fold 7</i>	0,0252	0,9100	0,1046	0,7295
<i>fold 8</i>	0,0216	0,8481	0,0624	0,7802
<b>média</b>	<b>0,0203 ±0,0033</b>	<b>0,9023 ±0,0429</b>	<b>0,0864 ±0,0226</b>	<b>0,7552 ±0,0460</b>

Fonte: Do autor (2021).

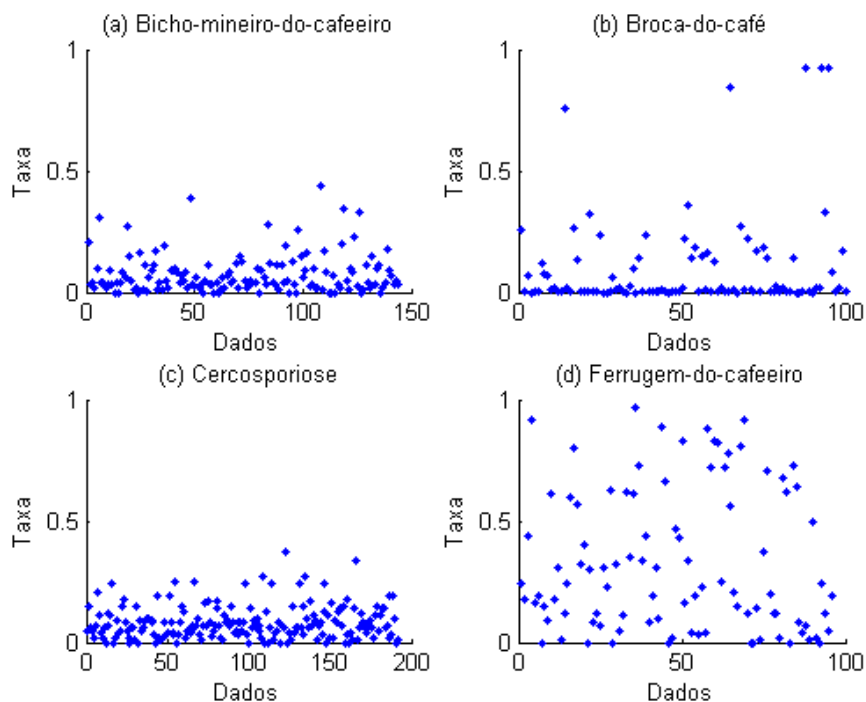
Tabela 4.5 – Resultados dos RMSE,  $R^2$  e a média com o desvio padrão dos *fold*s para o modelo de predição da doença ferrugem-do-cafeeiro.

<i>Fold</i>	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
<i>fold 1</i>	0,0721	0,9281	0,1450	0,8746
<i>fold 2</i>	0,0817	0,9051	0,1421	0,8622
<i>fold 3</i>	0,1142	0,8560	0,1327	0,8667
<i>fold 4</i>	0,1042	0,9106	0,1629	0,8330
<i>fold 5</i>	0,0729	0,9479	0,1658	0,8112
<i>fold 6</i>	0,1104	0,8416	0,1932	0,8134
<b>média</b>	<b>0,0926 ±0,0175</b>	<b>0,8982 ±0,0377</b>	<b>0,1569 ±0,0199</b>	<b>0,8435 ±0,0255</b>

Fonte: Do autor (2021).

para este menor desempenho é que a base de dados da ferrugem-do-cafeeiro apresenta maior variabilidade entre as amostras, conforme mostra a Figura 4.1.

Figura 4.1 – Disposição dos dados de treinamento para os modelos de pragas e doenças.



Fonte: Do autor (2021).


As Figuras 4.2 a 4.9 mostram os valores reais e previstos das taxas de incidências de doenças e ocorrências de pragas para todos os modelos de predição utilizando o algoritmo de treinamento *Levenberg-Marquardt* (*trainlm*), evidenciando a eficiência dos modelos propostos. Estas figuras representam os melhores *folds* das Tabelas 4.2 a 4.5 para cada modelo de predição.

Analisando o desempenho das redes neurais MLP por meio das métricas empregadas neste trabalho, quando foram utilizados um conjunto de dados que contempla dados reais mais artificiais em um primeiro teste do modelo e um conjunto de dados somente reais para um teste final dos modelos, os resultados deste teste final demonstraram um desempenho bastante satisfatório.

## 4.2 Resultados - Árvores de Decisão


As Tabelas 4.6 a 4.9 referem-se aos resultados de RMSE e  $R^2$  obtidos para cada *fold* utilizando um algoritmo de treinamento árvores de decisão nos modelos de predição de doenças e pragas. As colunas dois e três de cada uma destas Tabelas são valores atingidos com o conjunto

Figura 4.2 – Previsão da taxa de ocorrência da praga bicho-mineiro-do-cafeeiro utilizando dados de validação.



Fonte: Do autor (2021).


Figura 4.3 – Previsão da taxa de ocorrência da praga bicho-mineiro-do-cafeeiro utilizando dados de teste.



Fonte: Do autor (2021).




Figura 4.4 – Previsão da taxa de ocorrência da praga broca-do-café utilizando dados de validação.




Fonte: Do autor (2021).

Figura 4.5 – Previsão da taxa de ocorrência da praga broca-do-café utilizando dados de teste.




Fonte: Do autor (2021).

Figura 4.6 – Previsão da taxa de incidência da doença cercosporiose utilizando dados de validação.




Fonte: Do autor (2021).

Figura 4.7 – Previsão da taxa de incidência da doença cercosporiose utilizando dados de teste.




Fonte: Do autor (2021).

Figura 4.8 – Previsão da taxa de incidência da doença ferrugem-do-cafeeiro utilizando dados de validação.



Fonte: Do autor (2021).

Figura 4.9 – Previsão da taxa de incidência da doença ferrugem-do-cafeeiro utilizando dados de teste.



Fonte: Do autor (2021).

de dados de validação em um primeiro teste dos modelos, e as últimas duas colunas apresentam os resultados obtidos para o conjunto de dados reais (dados de teste), em que os modelos de cada *fold* são aplicados aos dados de teste.

Tabela 4.6 – Resultados dos RMSE,  $R^2$  e a média com o desvio padrão dos *folds* para o modelo de predição da praga bicho-mineiro-do-cafeeiro.

<i>Fold</i>	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
<i>fold 1</i>	0,0476	0,6778	0,0680	0,2001
<i>fold 2</i>	0,0728	0,4040	0,1090	0,4898
<i>fold 3</i>	0,0424	0,7740	0,1770	0,5272
<i>fold 4</i>	0,0252	0,6982	0,1670	0,1257
<i>fold 5</i>	0,0606	0,1956	0,0530	0,2820
<i>fold 6</i>	0,0515	0,7852	0,1910	0,5818
<i>fold 7</i>	0,0549	0,7464	0,0440	0,2431
<i>fold 8</i>	0,0513	0,6769	0,0310	0,4921
<b>média</b>	<b>0,0508 ±0,0129</b>	<b>0,6198 ±0,1957</b>	<b>0,1050 ±0,0610</b>	<b>0,3677 ±0,1625</b>

Fonte: Do autor (2021).

Tabela 4.7 – Resultados dos RMSE,  $R^2$  e a média com o desvio padrão dos *folds* para o modelo de predição da praga broca-do-café.

<i>Fold</i>	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
<i>fold 1</i>	0,1232	0,5862	0,3338	0,1889
<i>fold 2</i>	0,0309	0,9124	0,3238	0,1812
<i>fold 3</i>	0,0256	0,9409	0,3202	0,2943
<i>fold 4</i>	0,0425	0,9527	0,3382	0,1825
<i>fold 5</i>	0,0726	0,9836	0,1338	0,1826
<b>média</b>	<b>0,0590 ±0,0360</b>	<b>0,8752 ±0,1463</b>	<b>0,2900 ±0,0784</b>	<b>0,2059 ±0,0443</b>

Fonte: Do autor (2021).

Nas Tabelas 4.6 a 4.9 são observados quando os testes foram realizados somente com os dados reais, o método apresentou um desempenho inferior de RMSE e  $R^2$ , em geral, quando comparado com os resultados com dados de validação, que consideram dados reais e sintéticos.

Observa-se, portanto, que os modelos de predições de doenças e pragas utilizando árvores de decisão não alcançaram bons resultados de generalização para dados reais (colunas 4 e 5 das Tabelas 4.6 a 4.9). A quantidade de dados de treinamento utilizada neste algoritmo pode ter sido pouco representativa para este modelo a ponto que ele pudesse ser capaz de generalizar.

As Figuras 4.10 a 4.17 revelam os valores reais e previstos das taxas de incidências de doenças e ocorrências de pragas para todos os modelos de predição utilizando o algoritmo de treinamento árvores de decisão. Estas figuras representam os melhores *folds* das Tabelas 4.6 a

Tabela 4.8 – Resultados dos RMSE,  $R^2$  e a média com o desvio padrão dos *fold*s para o modelo de predição da doença cercosporiose.

<i>Fold</i>	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
<i>fold 1</i>	0,0464	0,5402	0,1700	0,1628
<i>fold 2</i>	0,0363	0,6386	0,2170	0,0489
<i>fold 3</i>	0,0566	0,3344	0,1550	0,3086
<i>fold 4</i>	0,0310	0,6136	0,2930	0,1020
<i>fold 5</i>	0,0370	0,7650	0,0020	0,0192
<i>fold 6</i>	0,0597	0,5393	0,0276	0,0249
<i>fold 7</i>	0,0782	0,3145	0,0067	0,0513
<i>fold 8</i>	0,0360	0,6076	0,0164	0,0417
<b>média</b>	<b>0,0477 ±0,0151</b>	<b>0,5442 ±0,1429</b>	<b>0,1110 ±0,1051</b>	<b>0,0949 ±0,0921</b>


Fonte: Do autor (2021).

Tabela 4.9 – Resultados dos RMSE,  $R^2$  e a média com o desvio padrão dos *fold*s para o modelo de predição da doença ferrugem-do-cafeeiro.

<i>Fold</i>	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
<i>fold 1</i>	0,1041	0,8330	0,0733	0,7549
<i>fold 2</i>	0,2033	0,4315	0,2190	0,4520
<i>fold 3</i>	0,2802	0,3564	0,1767	0,4610
<i>fold 4</i>	0,2622	0,4866	0,1823	0,2858
<i>fold 5</i>	0,1511	0,7657	0,0242	0,7415
<i>fold 6</i>	0,2063	0,4800	0,3220	0,4444
<b>média</b>	<b>0,2012 ±0,0605</b>	<b>0,5589 ±0,1763</b>	<b>0,1663 ±0,0968</b>	<b>0,5233 ±0,1697</b>


Fonte: Do autor (2021).

Figura 4.10 – Previsão da taxa de ocorrência da praga bicho-mineiro-do-cafeeiro utilizando dados de validação.




Fonte: Do autor (2021).

Figura 4.11 – Previsão da taxa de ocorrência da praga bicho-mineiro-do-cafeeiro utilizando dados de teste.




Fonte: Do autor (2021).

Figura 4.12 – Previsão da taxa de ocorrência da praga broca-do-café utilizando dados de validação.




Fonte: Do autor (2021).

Figura 4.13 – Previsão da taxa de ocorrência da praga broca-do-café utilizando dados de teste.




Fonte: Do autor (2021).

Figura 4.14 – Previsão da taxa de incidência da doença cercosporiose utilizando dados de validação.



Fonte: Do autor (2021).


Figura 4.15 – Previsão da taxa de incidência da doença cercosporiose utilizando dados de teste.



Fonte: Do autor (2021).




Figura 4.16 – Previsão da taxa de incidência da doença ferrugem-do-cafeeiro utilizando dados de validação.



Fonte: Do autor (2021).

Figura 4.17 – Previsão da taxa de incidência da doença ferrugem-do-cafeeiro utilizando dados de teste.



Fonte: Do autor (2021).

4.9 para cada modelo de predição. Um destaque maior para as predições dos modelos broca-do-café, Figura 4.12, e Bicho-mineiro-do-cafeeiro, Figura 4.10 usando os dados de validação em uma primeira avaliação do modelo. Por outro lado, as predições dos modelos com dados de teste, apresentaram desempenhos inferiores (vide Figuras 4.11, 4.13, 4.15 e 4.17).

Examinando o desempenho das árvores de decisão neste trabalho por meio das Tabelas 4.6 a 4.9, percebe-se que os valores quando utilizados dados reais no teste final dos modelos de predições apresentaram desempenho inferiores se comparados com os resultados do conjunto de dados reais mais artificiais (dados de validação). Sendo assim, os modelos não conseguiram apresentar uma generalização para as bases de dados após o treinamento e testes realizados com o algoritmo árvores de decisão.

### 4.3 Comparação entre os Método Propostos e Regressão Linear Múltipla

Os resultados das Tabelas 4.10 são referentes ao método de regressão linear múltipla para os conjuntos de dados reais mais artificiais (dados de validação) e somente com dados reais (dados de teste) para as bases de dados propostas. A média e desvio padrão apresentados são dos *folds* de cada modelo de praga e doença. Foi empregada a mesma metodologia de validação cruzada proposta para os modelos MLP e árvores de decisão para fins de comparação.

Os coeficientes dos modelos de regressão linear múltipla bicho-mineiro-do-cafeeiro, broca-do-café, cercosporiose e ferrugem-do-cafeeiro possuem faixas de valores entre -0,3716 a 0,2148, -0,2089 a 0,3283, -0,2890 a 0,2598 e -0,1928 a 0,3429, respectivamente. Todos os modelos possuem sete coeficientes e nenhum com valor zero, dessa forma o modelos de regressão não identificou redundância entre as variáveis preditoras.


Tabela 4.10 – Média e desvio padrão do RMSE e  $R^2$  dos *folds* para os modelos de regressão linear múltipla de doenças e pragas utilizando dados de validação e teste.

Pragas/Doenças	RMSE (validação)	$R^2$ (validação)	RMSE (teste)	$R^2$ (teste)
Bicho-mineiro	0,0633 $\pm$ 0,0221	0,4100 $\pm$ 0,1958	0,1577 $\pm$ 0,0012	0,3455 $\pm$ 0,0251
Broca	0,1577 $\pm$ 0,0431	0,3248 $\pm$ 0,2241	0,3154 $\pm$ 0,0347	0,0260 $\pm$ 0,0275
Cercosporiose	0,0643 $\pm$ 0,0165	0,1045 $\pm$ 0,0976	0,1018 $\pm$ 0,0015	0,0519 $\pm$ 0,0578
Ferrugem	0,1881 $\pm$ 0,0242	0,5753 $\pm$ 0,1292	0,2124 $\pm$ 0,0097	0,4822 $\pm$ 0,0311

Fonte: Do autor (2021).

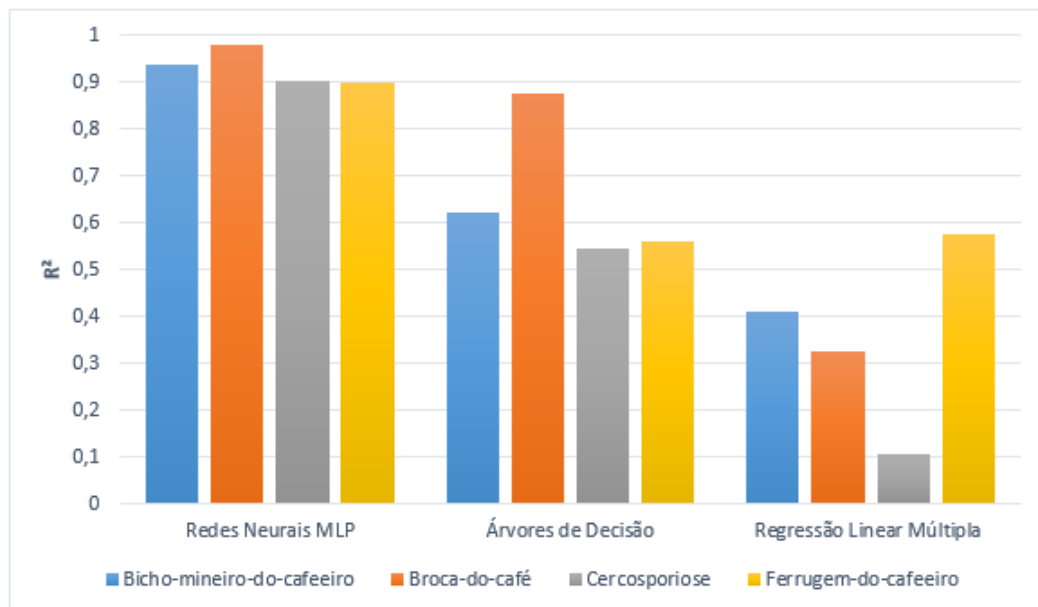
Os Gráficos 4.1 e 4.2 resumem os valores médios das métricas estatísticas RMSE e  $R^2$  para o conjunto de dados de validação obtidos pelos algoritmos MLP, árvores de decisão e regressão linear. Observe que o modelo MLP superou os demais modelos em ambas as métricas.

Gráfico 4.1 – Média do RMSE para os modelos de sistemas inteligentes e regressão linear múltipla utilizando dados de validação.



Fonte: Do autor (2021).

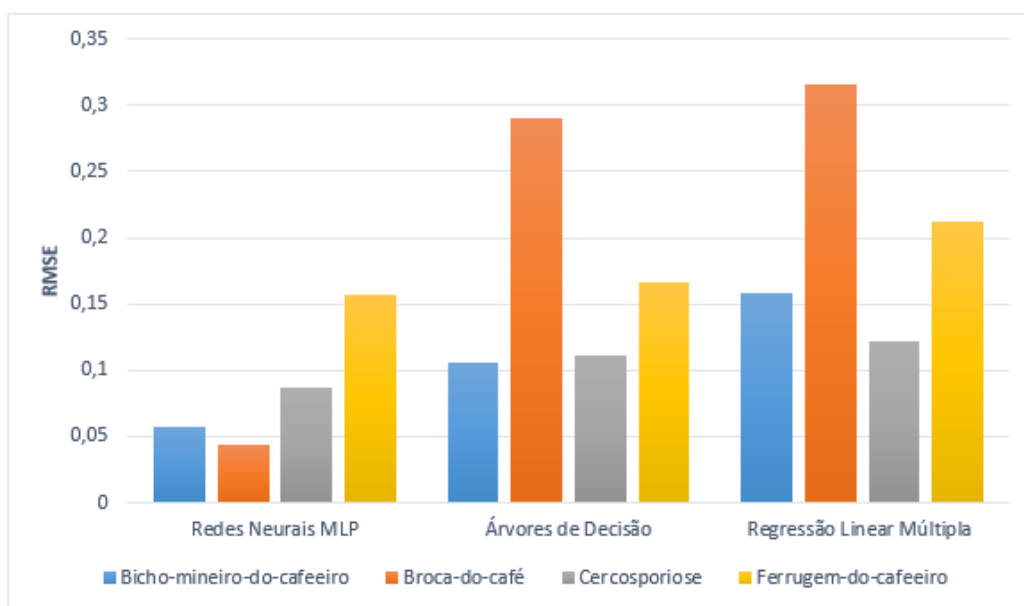
Gráfico 4.2 – Média do  $R^2$  para os modelos de sistemas inteligentes e regressão linear múltipla utilizando dados de validação.



Fonte: Do autor (2021).


Os Gráficos 4.3 e 4.4 resumem os valores médios das métricas estatísticas RMSE e  $R^2$  para o conjunto de dados de teste obtidos pelos algoritmos MLP, árvores de decisão e regressão

Gráfico 4.3 – Média do RMSE para os modelos de sistemas inteligentes e regressão linear múltipla utilizando dados de teste.



Fonte: Do autor (2021).

Gráfico 4.4 – Média do  $R^2$  para os modelos de sistemas inteligentes e regressão linear múltipla utilizando dados de teste.



Fonte: Do autor (2021).

linear. Observe que as redes neurais MLP novamente superaram os demais modelos em ambas as métricas.

A comparação entre redes neurais artificiais MLP e árvores de decisão foi realizada aplicando o teste t de *Student* (nível de significância de 5%) nos dados de teste (vide Tabela 4.11). Foi encontrada diferença estatística significativa entre as médias das acurácias dos modelos de predições para bicho-mineiro-do-cafeeiro, broca-do-café e cercosporiose para as métricas RMSE e  $R^2$ . Isso reforça que os modelos de predições de redes neurais artificiais do tipo MLP superaram os algoritmos de predições de árvores de decisão. Para o modelo de predição ferrugem-do-cafeeiro houve diferença estatística significativa entre as médias para  $R^2$ , o que não ocorreu para a métrica RMSE neste caso.

Tabela 4.11 – Teste t de *Student* (valor  $p$ ) entre os modelos de redes neurais MLP e árvores de decisão para dados de teste.

Pragas/Doenças	RMSE	$R^2$
Bicho-mineiro	$1,0713 \times 10^{-4}$	$1,2352 \times 10^{-4}$
Broca	0,002	$3,2635 \times 10^{-7}$
Cercosporiose	0,0395	$7,389 \times 10^{-9}$
Ferrugem	0,841	0,0079

Fonte: Do autor (2021).

Para fins de comparação também foi realizada uma comparação entre o método de regressão linear múltipla com o de redes neurais artificiais do tipo MLP utilizando o teste t de *Student* para dados de teste, que pode ser vista na Tabela 4.12. Neste caso encontrou-se diferença estatística significativa entre as médias para todos os modelos de previsões de pragas e doenças nas métricas RMSE e  $R^2$ . Diante disso e dos resultados das métricas das médias com seus respectivos desvios padrões (Tabelas 4.2 a 4.10), os modelos de predições utilizando redes neurais artificiais MLP foram superiores ao método de regressão linear múltipla.

Tabela 4.12 – Teste t de *Student* (valor  $p$ ) entre os modelos de redes neurais MLP e regressão linear múltipla para dados de teste.

Pragas/Doenças	RMSE	$R^2$
Bicho-mineiro	$2,053 \times 10^{-4}$	$5,7531 \times 10^{-11}$
Broca	$7,3716 \times 10^{-5}$	$1,2221 \times 10^{-5}$
Cercosporiose	0,0044	$9,5135 \times 10^{-11}$
Ferrugem	$7,2505 \times 10^{-4}$	$5,5196 \times 10^{-6}$

Fonte: Do autor (2021).

Os resultados do teste t de *Student* entre os modelos de árvores de decisão e regressão linear múltipla para dados de teste são mostrados na Tabela 4.13. Foi encontrada diferença estatística significativa entre as médias para o modelo bicho-mineiro-do-cafeeiro apenas para

a métrica RMSE. Para a métrica  $R^2$ , os modelos para broca-do-café e cercosporiose obtiveram diferença estatística entre as médias. Por outro lado, os modelos para ferrugem-do-cafeeiro não obtiveram diferença estatística entre as médias. Neste caso, não se pode afirmar qual modelo é melhor que o outro entre árvores de decisão e regressão linear múltipla, apesar de que as médias dos *folds* dos modelos de árvores de decisão apresentarem desempenhos superiores aos modelos de regressão linear múltipla (vide Tabelas 4.6 a 4.10).

Tabela 4.13 – Método teste t de *Student* (valor p) entre os modelos de árvores de decisão e regressão linear múltipla.

Pragas/Doenças	RMSE (teste)	$R^2$ (teste)
Bicho-mineiro	$7,5753 \times 10^{-8}$	0,2491
Broca	0,5765	$2,8431 \times 10^{-4}$
Cercosporiose	0,7934	0,0025
Ferrugem	0,3361	0,0909

Fonte: Do autor (2021).

Em geral, os modelos de árvores de decisão para previsão de pragas e doenças não demonstraram bons resultados para os dados de teste quando comparados com os modelos baseados em redes neurais MLP, que alcançaram resultados superiores. Um fator que pode ter contribuído para o baixo desempenho é a limitação de dados usados nos treinamentos dos modelos de árvores de decisão.

Entre todos os modelos de predições de pragas e doenças, os que apresentaram piores modelagens foram os de regressão linear múltipla, como demonstraram os resultados obtidos. Isto se deve pelo fato que o método de regressão linear múltipla não consegue aprender (modelar) as relações não lineares presentes nas bases de dados utilizados neste trabalho, que consistem em dados climáticos e taxas de incidência de doenças e ocorrência de pragas.

Diante dos resultados obtidos (vide Tabelas, 4.11, 4.12, 4.13 e Gráficos 4.1 a 4.4) é de se notar que os modelos de predição envolvendo redes neurais artificiais do tipo MLP apresentaram desempenhos superiores aos de árvores de decisão e do método de regressão linear implementado neste trabalho. Isto foi possível pelo fato de, após o desenvolvimento do algoritmo e por meio de testes experimentais, identificou-se uma configuração ideal para os parâmetros que fazem parte da arquitetura de uma rede neural artificial do tipo MLP, sendo assim este modelo evidenciou uma generalização significativa para as bases de dados aplicadas nesta pesquisa. Esta generalização é umas das principais vantagens quando utilizam-se redes neurais artificiais, isto é realizado durante o processo de treinamento e aprendizagem do algoritmo.

### 4.3.1 Complexidade Computacional

A Tabela 4.14 mostra o tempo gasto de processamento dos algoritmos propostos neste trabalho para processar uma amostra. O teste foi realizado com o modelo de cada abordagem (MLP, árvores de decisão e regressão linear) que apresentou melhor desempenho para o conjunto de teste. Para os algoritmos de árvores de decisão e regressão linear múltipla foram utilizados os modelos de ferrugem-do-cafeeiro, o de redes neurais MLP foi o modelo brocado-café. O algoritmo que apresentou menor tempo de processamento foi o de regressão linear múltipla. No entanto, apesar deste algoritmo apresentar menor complexidade computacional ele não apresenta vantagem operacional perante os outros algoritmos propostos, uma vez que apresentou resultados insatisfatórios para o problema abordado neste trabalho. O algoritmo árvores de decisão mostrou maior complexidade computacional quando comparado com o de redes neurais MLP, e isso representa uma desvantagem operacional para ele, pois as bases de dados utilizadas neste trabalho são relativamente pequenas, sendo assim o algoritmo de redes neurais MLP o mais vantajoso no que refere-se ao custo-benefício envolvendo tempo de processamento e acurácia.

Tabela 4.14 – Tempo de processamento dos algoritmos de redes neurais artificiais MLP, árvores de decisão e regressão linear múltipla.

Algoritmos	Tempo de processamento (segundos)
Redes neurais MLP	1,450729
Árvores decisão	2,234567
Regressão linear	0,039599

Fonte: Do autor (2021).

## 4.4 Aplicativo para *Smartphone*

Durante o desenvolvimento do aplicativo optou-se pela elaboração de um layout em que o usuário se sentisse familiarizado e com telas de fácil acesso e de simples inserção dos valores para que a predição de doenças e pragas seja realizada e apresentada na tela do *smartphone*.

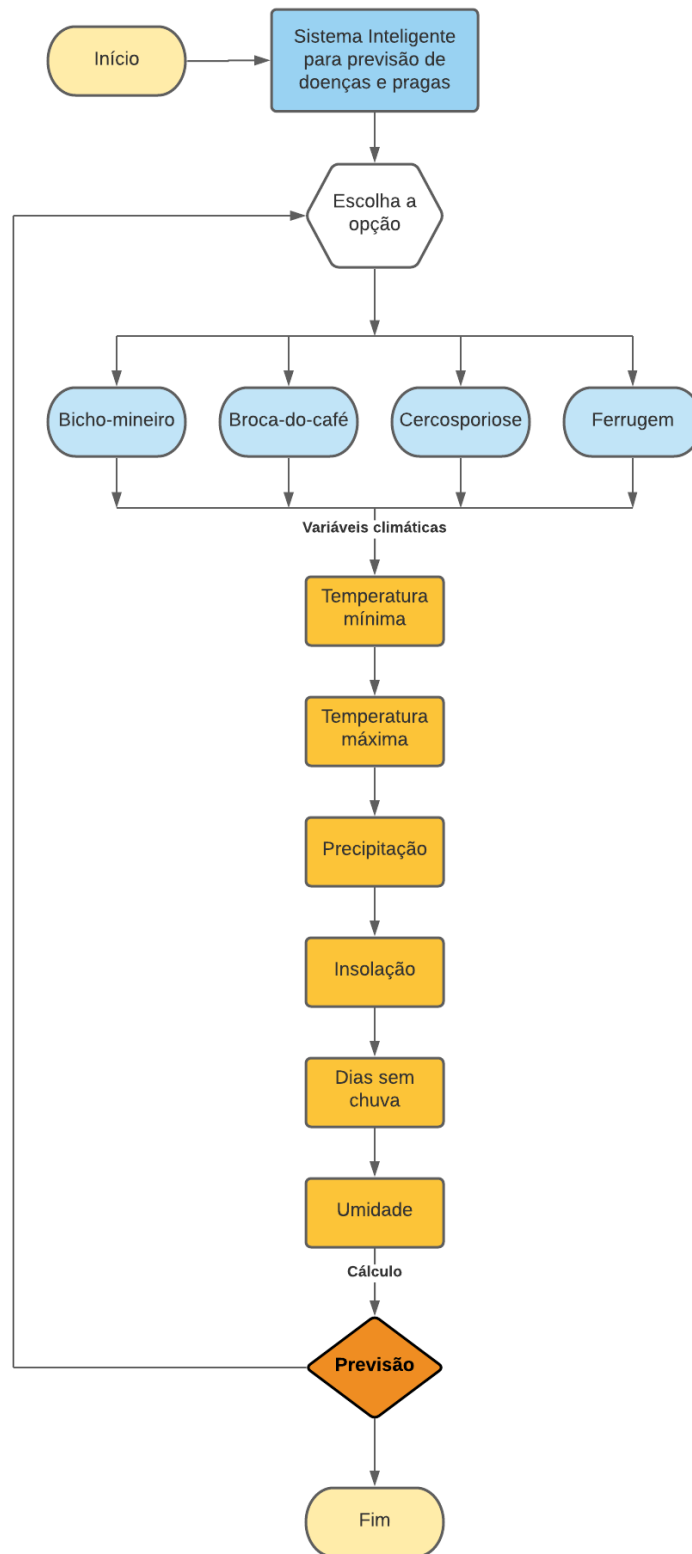
O aplicativo dispõe de telas onde o usuário escolhe qual doença ou praga que deseja verificar a predição destes fenômenos no cafeeiro. As Figuras de 4.19 a 4.25 demonstram o resultado final após o desenvolvimento do aplicativo. O aplicativo também apresenta um campo informando (vide Figura 4.22) o dano econômico causada pelas manifestações de pragas e doenças na produção de café quando este valor é atingido. Diante desses resultados em mãos

o cafeicultor poderá ter alguma tomada de decisão no sentido de amenizar o dano econômico que as pragas e doenças no cafeeiro podem causar se não forem previstas em um tempo hábil.

Para exemplificar de como manusear o aplicativo foi utilizada as Figuras 4.18 e 4.21 como exemplo. O usuário inseri nos seus respectivos campos as médias mensais das variáveis meteorológicas temperaturas mínima e máxima em graus Celsius, índice pluviométrico em milímetros, insolação total em horas, quantidade de dias sem precipitação de água e umidade relativa do ar ambas em valores absolutos e na sequência pressiona o botão calcular para que seja apresentada na tela a previsão da ocorrência pragas bicho-mineiro-do-cafeeiro em porcentagem.



Figura 4.18 – Fluxograma sequencial das etapas de utilização do aplicativo.



Fonte: Do autor (2021).

Figura 4.19 – Tela inicial do aplicativo.



Fonte: Do autor (2021).

Figura 4.20 – Tela para selecionar doenças ou pragas.



Fonte: Do autor (2021).

Figura 4.21 – Tela referente à praga bicho-mineiro-do-cafeeiro para predição.

Bicho-Mineiro-do-Cafeeiro

info

Temperatura mínima Temperatura máxima

Insira o valor Insira o valor

Precipitação Insolação

Insira o valor Insira o valor

Dias sem chuva Umidade

Insira o valor Insira o valor

Calcular Limpar

Predição em %

Fonte: Do autor (2021).

Figura 4.22 – Campo informativo sobre o dano econômico causado pela praga .

Bicho-Mineiro-do-Cafeeiro

info

Temperatura mínima Temperatura máxima

Insira o valor Insira o valor

Precipitação Insolação

Insira o valor Insira o valor

**INFORMAÇÃO**

O dano econômico no cafeeiro causado pelo bicho-mineiro inicia-se com 30% de ocorrência dessa praga, ou seja, a partir desse valor começa a dar prejuízo financeiro ao cafeicultor, assim tornando-se inviável a continuidade da plantação se não for tratada esta praga de forma correta.

OK

Fonte: Do autor (2021).

Figura 4.23 – Tela referente à praga broca-do-café para predição.

Broca-do-Café

info

Temperatura mínima Temperatura máxima

Insira o valor Insira o valor

Precipitação Insolação

Insira o valor Insira o valor

Dias sem chuva Umidade

Insira o valor Insira o valor

Calcular Limpar

Predição em %

Fonte: Do autor (2021).

Figura 4.24 – Tela referente à doença cercosporiose para predição.

Cercosporiose

info

Temperatura mínima Temperatura máxima

Insira o valor Insira o valor

Precipitação Insolação

Insira o valor Insira o valor

Dias sem chuva Umidade

Insira o valor Insira o valor

Calcular Limpar

Predição em %

Fonte: Do autor (2021).

Figura 4.25 – Tela referente à doença ferrugem-do-cafeeiro para predição.

Ferrugem-do-Cafeeiro

info

Temperatura mínima Temperatura máxima

Insira o valor Insira o valor

Precipitação Insolação

Insira o valor Insira o valor

Dias sem chuva Umidade

Insira o valor Insira o valor

Calcular Limpar

Predição em %

Fonte: Do autor (2021).

## 5 CONCLUSÃO

A utilização de redes neurais artificiais do tipo MLP mostraram-se uma tecnologia bastante promissora para as previsões abordadas quando se comparada com árvores de decisão e regressão linear múltipla. Os modelos de redes neurais que utilizaram o algoritmo de treinamento *Levenberg-Marquardt backpropagation* apresentaram os melhores resultados para as métricas RMSE e  $R^2$  para todas as pragas e doenças abordadas neste trabalho. Os resultados também mostraram que as redes neurais artificiais alcançaram uma maior generalização perante as bases de dados impostas na presente pesquisa.

A pesquisa utilizou uma técnica que gera dados artificiais, conhecida por SMOTE, para aumentar a base de dados original para o treinamento e o teste dos sistemas inteligentes. Para validar os modelos desenvolvidos, um grupo de dados reais foi utilizado. Os bons resultados obtidos para dados reais, mostraram, além da capacidade de generalização dos modelos, que os dados sintéticos gerados foram representativos o suficiente para que os modelos pudessem aprender o problema a ponto de generalizar para novos dados reais.

Dessa forma, evidencia-se que o sistema inteligente do tipo redes neurais artificiais MLP, além de promissor, pode ser uma poderosa e arrojada tecnologia para a predição de doenças e pragas em cafeeiros, auxiliando os cafeicultores nas tomadas de decisões por meio de aplicativos para *smartphones*, uma vez que estes apresentam mobilidade, fácil acessibilidade e são de uso bastante simples.

## 6 TRABALHOS FUTUROS

Apesar das redes neurais artificiais MLP combinado com a técnica SMOTE se destacarem com os resultados obtidos, outras abordagens de geração de dados artificiais podem serem investigadas em trabalhos futuros, como por exemplo as *Generative Adversarial Networks* (MAHDIZADEHAGHDAM; PANAHI; KRIM, 2019).

Sugere-se também que o trabalho possa ser avançado no sentido de realizar mais estudos comparativos ou até mesmo desenvolver outros modelos de sistemas inteligentes, por exemplo, redes neuro-fuzzy ANFIS (JANG, 1993) ou máquina de vetores suporte (SVM, do inglês, *Support Vector Machine*) (GUNN, 1998).

Um outro trabalho futuro que pode ser realizado é no sentido de transformar o problema de regressão em classificação. Nesse sentido, poderia trabalhar com faixas de valores das taxas de incidência de doenças e ocorrência das pragas na forma de classes. Essa abordagem poderia auxiliar o cafeicultor na tomada de decisão quando o método classificador gerasse um resultado que estaria dentro de uma faixa de valores preditos.

Um ponto que pode também ser explorado nessa pesquisa, seria aplicar a rede neural MLP para a predição de pragas e doenças utilizando a técnica dois passos e/ou três passos a frente e analisar o comportamento dessa rede neural por meio das mesmas métricas estatísticas propostas neste trabalho. No contexto deste trabalho, dois passos e três passos a frente significariam dois meses e três meses a frente, respectivamente.

Um outro avanço que este trabalho pode ter é identificar quais variáveis de entrada influenciam nos resultados dos sistemas inteligentes propostos utilizando, por exemplo, a ferramenta LIME (*Local Interpretable Model-agnostic Explanations*) (PELTOLA, 2018).

## REFERÊNCIAS

- ABREU, F. A. **Manejo de plantas adventícias em cafezal e seu efeito sobre ácaros fitófagos e predadores**. 74 p. Dissertação (Mestrado), 2013.
- AHA, W.; KIBLER, D.; ALBERT, M. K. Instance-Based Learning Algorithms. **Machine Learning**, v. 6, p. 37–66, 1991.
- ALFONSI, W. M. V. et al. Período de incubação da ferrugem do cafeeiro. **Summa Phytopathologica**, v. 45, n. 2, p. 134–140, 2019. ISSN 0100-5405.
- BOTELHO, D. M. S. et al. Intensidade da cercosporiose em mudas de cafeeiro em função de fontes e doses de silício. **Fitopatologia Brasileira**, v. 30, n. 6, p. 582–588, 2005. ISSN 0100-4158.
- BURMAN, P. A Comparative Study of Ordinary Cross-Validation, V-Fold Cross-Validation and the Learning-Testing Methods. **Biometrika**, p. 503–514, 1989.
- BUSOLI, A. C. et al. Manejo Integrado de Pragas : Pesquisas , avanços e desafios. **Tópicos em Entomologia Agrícola VII**, n. July, p. 392, 2014.
- CAIXETA, S. L. et al. Nutrição e vigor de mudas de cafeeiro e infestação por bicho mineiro. **Ciência Rural**, v. 34, n. 5, p. 1429–1435, 2004. ISSN 0103-8478.
- CHATTERJEE, S.; HADI, A. S. Influential observations, high leverage points, and outliers in linear regression. **Statistical Science**, v. 1, p. 379–416, 1986.
- CHAWLA, N. V. et al. SMOTE: Synthetic Minority Over-sampling Technique. **Journal of Artificial Intelligence Research**, v. 2009, n. Sept. 28, p. 321–357, 2006. ISSN 10769757.
- CONCEIÇÃO, C. H. C.; GUERREIRO-FILHO, O.; GONÇALVES, W. Flutuação populacional do bicho-mineiro em cultivares de café arábica resistentes á ferrugem. **Bragantia**, v. 64, n. 4, p. 625–631, 2005. ISSN 00068705.
- COSTA, M. J.; ZAMBOLIM, L.; RODRIGUES, F. A. Avaliação de produtos alternativos no controle da ferrugem do cafeeiro. **Fitopatologia Brasileira**, v. 32, n. 2, p. 150–155, 2007. ISSN 01004158.
- FERNANDES, F. L. et al. Controle massal da broca-do-café com armadilhas de garrafa Pet vermelha em cafeeiro. **Pesquisa Agropecuaria Brasileira**, v. 49, n. 8, p. 587–594, 2014. ISSN 16783921.
- FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, v. 35, n. 1, p. 25–30, 2006. ISSN 01001965.
- FERREIRA, A. J. et al. Dinâmica Populacional da Broca-do-Café *Hypothenemus hampei* ( Ferr .) ( Coleoptera : Scolytidae ) em Lavras , MG. **An. Soc. Entomol. Brasil** **29(2)**, v. 29, n. 2, p. 237–244, 2000.
- GARCIA, S. C. O Uso de Árvores de Decisão na Descoberta de Conhecimento na Área da Saúde. **Dissertação Submetida - Universidade Federal do Rio Grande de Sul**, p. 34–35, 2003. Disponível em: <<https://www.lume.ufrgs.br/bitstream/handle/10183/4703/000503532.pdf?sequence=1>>.



- GOSSET, W. S. The Probable Error of a Mean. **Biometrika**, v. 6, n. 1, p. 1–25, 1908.
- GUNN, S. Support vector machines for classification and regression. In: . [S.l.: s.n.], 1998.
- HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H. **Neural Network Design**. 1996. 12–19 p.
- HAGAN, M. T.; MENHAJ, M. Training feed-forward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, p. 989–993, 1994.
- HALLAK, R.; FILHO, A. J. P. Metodologia para análise de desempenho de simulações de sistemas convectivos na região metropolitana de São Paulo com o modelo ARPS: sensibilidade a variações com os esquemas de advecção e assimilação de dados. **Revista Brasileira de Meteorologia**, v. 26, n. 4, p. 591–608, 2011. ISSN 0102-7786.
- HOPFIELD, J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences of the United States of America**, v. 79, p. 2554–8, 05 1982.
- HOPKINS, G. W.; MEMMOTT, J. Seasonality of a tropical-leaf-mining moth: leaf availability versus enemy-free space. **Ecology Entomology**, v. 28, p. 687–693, 2003.
- JANG, J. . R. Anfis: adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 23, n. 3, p. 665–685, 1993.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. **International joint Conference on artificial intelligence**, v. 14, p. 1137–1145, 1995.
- LaRC. **Centro de Pesquisa Langley da NASA (LaRC)**. 2020. Disponível em: <<https://power.larc.nasa.gov/>>.
- LAW, W. K. F.; PEDIGO, L. P.; HINZ, P. N. Population dynamics of bean leaf beetles (Coleoptera: Chrysomelidae) in Central Iowa. **Environmental Entomology**, v. 6, p. 562–567, 2001.
- LEAL, A. J. F. et al. Artificial neural networks for corn yield prediction and definition of site-specific crop management through soil properties. **Bragantia**, v. 74, n. 4, p. 436–444, 2015. ISSN 00068705.
- MACKAY, D. J. C. Bayesian interpolation. **Neural Computation**, v. 4, p. 415–447, 1992.
- MAHDIZADEHAGHDAM, S.; PANAHI, A.; KRIM, H. Sparse generative adversarial network. **Proceedings - 2019 International Conference on Computer Vision Workshop, ICCVW 2019**, p. 3063–3071, 2019.
- MEDEIROS, L. F. de. Redes Neurais em Delphi. **Visual Books**, v. 2 .Ed., p. 209–210, 2006. ISSN 9788575021941.
- MEIRA, C. A.; RODRIGUES, L. H.; MORAES, S. A. Analysis of coffee leaf rust epidemics with decision tree. **Tropical Plant Pathology**, v. 33, n. 2, p. 114–124, 2008. ISSN 1983-2052.
- MEIRA, C. A. A.; RODRIGUES, L. H. A.; MORAES, S. A. de. Modelos de alerta para o controle da ferrugem-do-cafeeiro em lavouras com alta carga pendente. **Pesquisa Agropecuária Brasileira**, v. 44, n. 3, p. 233–242, 2009. ISSN 0100204X.

- MENDONÇA, J. M. A. de et al. Produtos naturais e sintéticos no controle de *Leucoptera coffeella* (Guérin-Mèneville & Perrotet, 1842) (Lepdoptera: Lyonetiidae) e seus efeitos sobre a predação por vespas. **Ciência e Agrotecnologia**, v. 30, n. 5, p. 892–899, 2006. ISSN 1413-7054.
- MIT App Inventor. **Massachusetts Institute of Technology**. 2020. Disponível em: <<https://appinventor.mit.edu/>>.
- MOLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural Networks**, v. 6, p. 525–533, 1993.
- NETO, C. D. G.; RODRIGUES, L. H. A.; MEIRA, C. A. A. Modelos de predição da ferrugem do cafeeiro (*Hemileia vastatrix* Berkeley & Broome) por técnicas de mineração de dados. **Coffee Science**, v. 9, n. 3, p. 408–418, 2014. ISSN 19843909.
- PELTOLA, T. Local Interpretable Model-agnostic Explanations of Bayesian Predictive Models via Kullback–Leibler Projections. **arXiv**, 2018. ISSN 23318422.
- PICANÇO, M. C. **Manejo Integrado de Pragas**. Viçosa, MG: UFV: [s.n.], 2010. 146 p.
- POZZA, A. A. A. et al. Efeito do silício no controle da cercosporiose em três variedades de cafeeiro. **Fitopatologia Brasileira**, v. 29, n. 2, p. 185–188, 2004. ISSN 0100-4158.
- QUINLAN, J. R. Induction of Decision Trees. **Machine Learning, Dordrecht**, v. 1, p. 81–106, 1986.
- QUINLAN, J. R. Programs for Machine Learning. **Morgan Kaufmann Publishers**, n. 235-240, p. 302, 1993. Disponível em: <<https://doi.org/10.1007/BF00993309>>.
- RIEDMILLER, M.; BRAUN, H. **A direct adaptive method for faster backpropagation learning: The RPROP algorithm**. 1993.
- SALGADO, B. G. et al. PROGRESSO DA FERRUGEM E DA CERCOSPORIOSE DO CAFEIEIRO CONSORCIADO COM GREVÍLEA, COM INGAZEIRO E A PLENO SOL EM LAVRAS - MG. **Congresso Brasileiro De Agroinformática**, p. 1067–1074, 2007.
- SANTOS, F. D. S. et al. Progresso da cercosporiose (*Cercospora coffeicola* Berkeley & Cooke) em cafeeiros sob cultivos orgânico e convencional. **Summa Phytopathologica**, v. 34, n. 1, p. 48–54, 2008. ISSN 01005405.
- SCHABENBERGER, O.; PIERCE, F. J. Contemporary statistical models for the plant and soil sciences. **Boca Raton: CRC**, p. 753, 2002.
- SILVA, R. A. et al. Ação de produtos fitossanitários utilizados em cafeeiros sobre pupas e adultos de *Chrysoperla externa* (Hagen, 1861) (Neuroptera: Chrysopidae). **Ciencia Rural**, v. 36, n. 1, p. 8–14, 2006. ISSN 01038478.
- SILVA, R. A. et al. Effects of pesticides on eggs of *chrysoperla externa* (neuroptera: Chrysopidae) and consequences on subsequent Development. **Revista Colombiana de Entomologia**, v. 38, n. 1, p. 58–63, 2012. ISSN 0120-0488.

SILVA, R. M.; LEAL, M. R. R.; LIMA, F. M. Predição do Câncer de Mama com Aplicação de Modelos de Inteligência Computacional. **TEMA - Tendências em Matemática Aplicada e Computacional - Sociedade Brasileira de Matemática Aplicada e Computacional**, v. 2, n. 229-240, 2019.

SILVEIRA-MARTINS, E. et al. Aplicação de redes neurais no Brasil: um estudo bibliométrico. **Biblionline**, v. 12, n. 2, p. 101–116, 2016. ISSN 1809-4775.

SOUZA, M. S. de et al. Parasitismo na população da broca-do-café *Hypothenemus hampei* (Ferrari) (Coleoptera: Scolytidae), pelo parasitoide *Cephalonomia stephanoderis* Betrem (Hymenoptera: Bethyilidae). **EntomoBrasilis**, v. 7, n. 3, p. 178–182, 2014. ISSN 1983-0572.

TAVARES, M. H. F. et al. Redes Neurais Artificiais: Princípios Básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47–57, 2016. ISSN 2175-1846.

THAMADA, T. T.; RODRIGUES, L. H. A.; MEIRA, C. A. A. Predição Da Taxa De Progresso Da Ferrugem Do Cafeeiro Por Meio De Ensembles. **IX Simpósio de Pesquisa Dos Cafés do Brasil**, p. 0–4, 2015.

WILKS, D. S. Statistical Methods in the Atmospheric Sciences. In: **International Geophysics Series**. 2a. ed. Estados Unidos da América: Academic Press, 2006. v. 91, p. 627.

ZANETTI, S. S. et al. Reference evapotranspiration estimate in Rio de Janeiro State using artificial neural networks. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 2, p. 174–180, 2008. ISSN 18071929.

### APÊNDICE A - Publicação em Congresso

Nesta seção é apresentada uma breve descrição de um trabalho publicado no Congresso Brasileiro de Automática 2020 utilizando redes neurais MLP para a predição de doenças e pragas no cafeeiro.

1. ANDRADE, T., SILVA, R. A., MATOS, C. S. M., VOLPATO, M. M. L., PEREIRA, A. B., FERREIRA, D. D., "Predição de pragas e doenças no cafeeiro utilizando Redes Neurais Artificiais", *XXIII Congresso Brasileiro de Automática - CBA*, novembro 2020. DOI: <https://doi.org/10.48011/asba.v2i1.1286>

As pragas e doenças no cafeeiro, ocasionadas por bicho-mineiro-do-cafeeiro, broca-do-café, ferrugem-do-cafeeiro e cercosporiose, chegam a atingir até 50% de uma lavoura cafeeira, podendo causar grandes prejuízos aos cafeicultores. Sendo assim, os sistemas inteligentes são de suma importância para predizer esses danos ao cafeeiro. As redes neurais artificiais do tipo perceptron multicamadas, foram os sistemas inteligentes utilizados neste trabalho para prever a porcentagem de ocorrência de pragas e incidência de doenças no cafeeiro. Foram utilizados dados meteorológicos como variáveis de entrada do modelo. Os valores das métricas estatísticas RMSE resultou em uma faixa de 0,0212 a 0,1801 e um  $R^2$  variando entre 0,4854 a 0,9459 para cada modelo de predição de doenças e pragas.