

**MAPEAMENTO DE ÁREAS DA CULTURA CAFEIEIRA
INFECTADAS POR NEMATOIDES A PARTIR DE IMAGENS
OBTIDAS POR AERONAVES REMOTAMENTE PILOTADAS**

*Mapping of nematode-infected areas of coffee culture from images
obtained by remotely piloted aircraft*

Carlos Alberto Matias de Abreu Júnior

Universidade Federal de Uberlândia

Instituto de Geografia

km 1, LMG-746, Monte Carmelo - MG

carlosalberto0103@hotmail.com

Geovane Piveta Vinhal

Universidade Federal de Uberlândia

Instituto de Geografia

km 1, LMG-746, Monte Carmelo - MG

geovanepiveta@hotmail.com

George Deroco Martins

Universidade Federal de Uberlândia

Faculdade de Engenharia Civil

km 1, LMG-746, Monte Carmelo - MG

deroco@ufu.br

Laura Cristina Moura Xavier

Universidade Federal de Uberlândia

Instituto de Geografia

km 1, LMG-746, Monte Carmelo - MG

xavier.lauramoura@gmail.com

Rodrigo Bezerra de Araujo Gallis

Universidade Federal de Uberlândia

Instituto de Geografia

km 1, LMG-746, Monte Carmelo - MG

rodrigogallis@ufu.br

Ricardo Luís Barbosa

Universidade Federal de Uberlândia

Instituto de Geografia

km 1, LMG-746, Monte Carmelo - MG

rluisbarbosa@ufu.br

Resumo:

O sensoriamento remoto vem sendo aplicado cada vez mais na agricultura de precisão, devido a sua forte correlação com as variáveis agrícolas. A combinação espectral de bandas do visível vem se tornando uma alternativa em câmeras com ausência do infravermelho próximo, devido a uma relativa correlação com a vegetação e, conseqüentemente, com as variáveis agrícolas. Dessa forma é possível identificar as oscilações presentes em uma plantação, como a presença de pragas e parasitas, sendo assim detectável a presença de nematoides na cultura cafeeira. Nesse contexto, as aeronaves remotamente pilotadas (ARPs) de baixo custo possibilitam o monitoramento contínuo dessas culturas, sendo uma alternativa cada vez mais utilizada, para a geração de mapas de controle de pragas, que auxiliam no controle da produtividade das plantações, para que esta não seja afetada. Neste trabalho, foi utilizada a classificação pelo método de redes neurais artificiais para discriminação de áreas da cultura cafeeira infectada por nematoides. Para tanto, a classificação foi aplicada em uma combinação de bandas do visível com TGI (Triangular Greenness Index) e análise da acurácia do mapeamento foi validada a partir do índice Kappa. A Matriz de confusão apresentou 26,32% de erro de omissão (para nematoide), 37,50% de comissão (para solo exposto), sendo estes os maiores valores obtidos, além do índice Kappa de 0,70.

Palavras-chave: Cafeicultura; Nematoides; Agricultura de Precisão; Mapas de infecção.

Abstract:

Remote sensing has been increasingly applied in precision agriculture due to its strong correlation with agricultural variables. The spectral combination of visible bands has become an alternative in cameras with absence of near infrared, due to a relative correlation with the vegetation and, consequently, with the agricultural variables. In this way it is possible to identify the oscillations present in a plantation, such as the presence of pests and parasites, so that it is possible to detect the presence of nematodes in the coffee crop. In this context, low-cost remotely piloted aircraft (ARPs) allow the continuous monitoring of these crops, being an increasingly used alternative for the generation of pest control maps, which help to control the productivity of the plantations, so that this not be affected. In this work, the artificial neural network classification was used to discriminate areas of the coffee crop infected by nematodes. For this, the classification was applied in a combination of bands of the visible with TGI (Triangular Greenness Index) and analysis of the avidity of the mapping was validated from the Kappa index. The confusion matrix presented 26.32% of omission error (for nematode), 37.50% of commission (for exposed soil), being these the highest values obtained, besides the Kappa index of 0.70.

Keywords: Remote Sensing; Nematodes; Precision Agriculture, Infection maps.

1. INTRODUÇÃO

A produção de café impulsiona fortemente as atividades de indústria e comércio do Brasil, assim como gera uma gama de empregos nas regiões onde ocorre sua produção. Essa variedade de regiões produtoras e a extensão dessas áreas fazem com que o Brasil seja o maior produtor mundial de café e o segundo maior mercado consumidor (ARRUDA, 2017). A projeção realizada pelo Conselho dos Exportadores de Café do Brasil – Cecafé, aponta que até 2030 o consumo mundial deve aumentar por volta de 30% e atingir 204,65 milhões de sacas. Assim, para que o Brasil conserve sua parcela de mercado é necessário que a produção nacional aumente por volta de 16,17 milhões de sacas até 2030 (EMBRAPA, 2018).

Com o aumento da produtividade aliado à tecnologia, existem diversos fatores que podem causar a redução da produtividade e conseqüente redução da área plantada de café. Entre eles, os aspectos relacionados à ocorrência de pragas e doenças durante o ciclo da cultura estão entre os mais significativos. Dentre os diversos fatores que causam sérios prejuízos e, principalmente perdas na produtividade na cultura do café estão os fitonematoides, onde os pertencentes ao gênero *Meloidogyne*, conhecidos como nematoides de galhas têm maior destaque (ITO, 2012).

Uma parcela substancial das espécies de nematoides do solo alimenta-se diretamente nas raízes das plantas, às vezes causando doença ou não (SBN, 2016). No Brasil, *M. incognita*, *M. paranaensis* e *M. exigua* constituem as principais espécies por consequência dos danos que causam e pela ampla distribuição nas áreas produtoras de café (CAMPOS e VILLAIN, 2005). Os nematoides danificam drasticamente a integridade das raízes, causando escamações em sua superfície, com aspecto de cortiça, com descascamento, rachaduras e pontos de lesões necróticas. Na parte aérea das plantas, os sintomas são clorose, desfolhamento, redução no crescimento e as vezes morte da planta (FERRAZ, 2012).

Quando se objetiva o aumento de produtividade e busca de qualidade é imprescindível que haja inicialmente a diminuição das perdas causadas por fitoparasitas, pragas, e etc., sendo a agricultura de precisão uma das soluções para tais desafios. Nos últimos anos, o sensoriamento remoto, que possibilita obtenção de informações sobre alvos na superfície terrestre, sem contato com os estes, tornou-se uma importante ferramenta no âmbito da agricultura de precisão e monitoramento agrícola, tendo o objetivo de manejo diferenciado de áreas agrícolas, por meio da aplicação diferenciada de práticas agrônômicas a partir de uma definição prévia da distribuição espacial das condições da cultura (MARTINS E GALO, 2015).

Contudo, um dos fatores que tem impulsionado o sensoriamento remoto fortemente na agricultura de precisão são as Aeronaves Remotamente Pilotadas (ARPs), que possibilitam o monitoramento contínuo das plantações agrícolas, auxiliando nos processos de tomada de decisão nos principais meios agrônômicos. A velocidade de disseminação desta tecnologia tem a tornado uma das tecnologias mais importantes na agricultura de precisão atualmente (DAMIAN et. al, 2015).

Nas atividades agrícolas, o sensoriamento remoto tem-se destacado devido à forte correlação de imagens com as variáveis agrícolas para auxílio em práticas de planejamento de plantio e monitoramento. Como é descrito no estudo de Oliveira (2015), em que foi estimada a produtividade de cana-de-açúcar em função de índices de vegetação a partir de dados multiespectrais, assim como na detecção de áreas agrícolas infestadas por parasitas, tais como os nematoides, reportada em estudos de Martins e Galo (2015) e (2014) que detectaram nematoides na cultura de cana-de-açúcar. No primeiro trabalho, os autores utilizaram a espectrorradiometria no visível e infravermelho próximo para a detecção, e no segundo geraram mapas de variabilidade do potencial de produtividade obtidos por plataformas orbitais. Como também, Beck et al. (2015) verificaram o potencial de sensores instalados em plataformas orbitais na detecção de nematoides na cultura de pinheiros.

Dessa forma, esta pesquisa tem por objetivo utilizar as ARPs para detecção de nematoides na cultura cafeeira, através da classificação supervisionada pelo método de redes neurais artificiais. Neste contexto, é possível determinar a interferência do GSD (*Ground Sample Distance*) na detecção de doenças, uma vez que em imagens com uma resolução espacial melhor é possível discriminar os alvos de forma mais acurada, favorecendo o processo de treinamento do algoritmo de classificação aqui utilizado. Para subsidiar os resultados encontrados nesta pesquisa foi calculada a matriz de confusão, assim como o índice Kappa, criado por Cohen (1960).

2. MATERIAL E MÉTODOS

2.1. Área de estudo e materiais utilizados

Os materiais utilizados nesta pesquisa foram imagens, capturadas através de uma câmera RGB com sensor CMOS e focal de 20mm e 20 megapixels, acoplada a um Drone Phantom 4 Advanced. Coordenadas mensuradas com um receptor GNSS Garmin Ca com precisão de 3,5m, contendo pontos amostrais referentes a cada uma das variáveis de estudo. Para o processamento dos dados foram utilizados os softwares ENVI 5.0 *Classic*, *Arcgis* 10.0 e *Quantum GIS* 2.18.

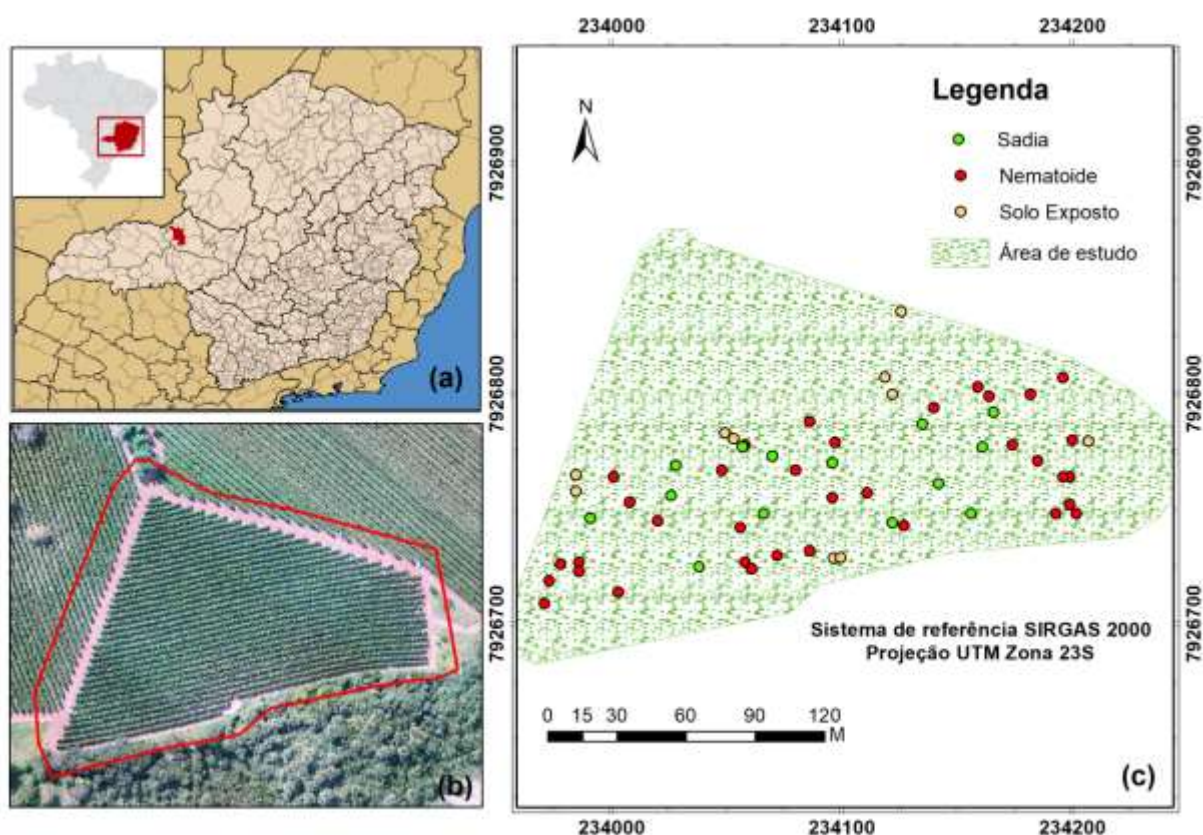


Figura 1 – Mapa de Localização: (a) Município de Monte Carmelo em destaque no mapa de Minas Gerais e Brasil. (b) Talhão de café destacando a área de estudo em uma composição cor natural RGB de uma imagem aerofotogramétrica, limitada no vermelho. (c) Mapa da área de estudo, contendo a distribuição espacial georreferenciada dos pontos mensurados *in situ* dos três alvos espectrais estudados na pesquisa.

Fonte: Os autores

2.3. Classificação e validação dos dados

A priori foram investigadas *in situ* três classes de informação: solo exposto, café sadio e café infectado por nematoides. Com um receptor de navegação foram georreferenciados locais de apoio para a classificação e para análise da acurácia a partir de pontos de verificação. A

incidência do nematoide se dá por meio das reboleiras (aproximadamente 10m²) logo, a precisão por GNSS não precisa ser pontual, uma vez que a coordenada mensurada situa-se no centro da área infectada.

Foram feitos três arquivos *shapefile* com parte das coordenadas mensuradas em campo, discriminadas em relação as classes de informação, sendo elas, café sadio, infectado e solo exposto. Estes arquivos foram utilizados como amostras para as regiões de interesse, as quais foram necessárias para o treinamento do algoritmo, na fase de definição das classes, para a classificação da imagem pelo método de redes neurais artificiais. O restante das coordenadas foi utilizado para gerar novas amostras que seriam aplicadas para validação da classificação, através da matriz de confusão e calculo do índice Kappa. Ao todo foram utilizados 15 pontos amostrais escolhidos aleatoriamente para o treinamento do algoritmo e classificação, e 45 pontos para a validação através da matriz de confusão, calculo do índice Kappa e precisão global. Para auxiliar a classificação foi feito uma combinação entre as bandas RGB e TGI, uma vez que a imagem obtida pelo Drone já é obtida em composição RGB. As imagens utilizadas apresentam um GSD de 5cm, obtido através de uma altura de voo de 150m.

A classificação supervisionada por redes neurais artificiais consiste no treinamento do algoritmo para classificação de determinada classe, por um processo repetitivo de iterações, no qual a entrada para um neurônio de qualquer camada é sempre a soma ponderada da saída da camada anterior. Dessa forma, o erro requerido para afeição dos pesos por meio dos neurônios da camada de saída, para os nós das camadas previas, é propagado regressivamente pelo método iterativo, que é o componente principal para o funcionamento do algoritmo (GALO e NOVO, 2002). A Figura 2 mostra o funcionamento de um neurônio artificial, pelo qual ocorre o processo de classificação por redes neurais artificiais.

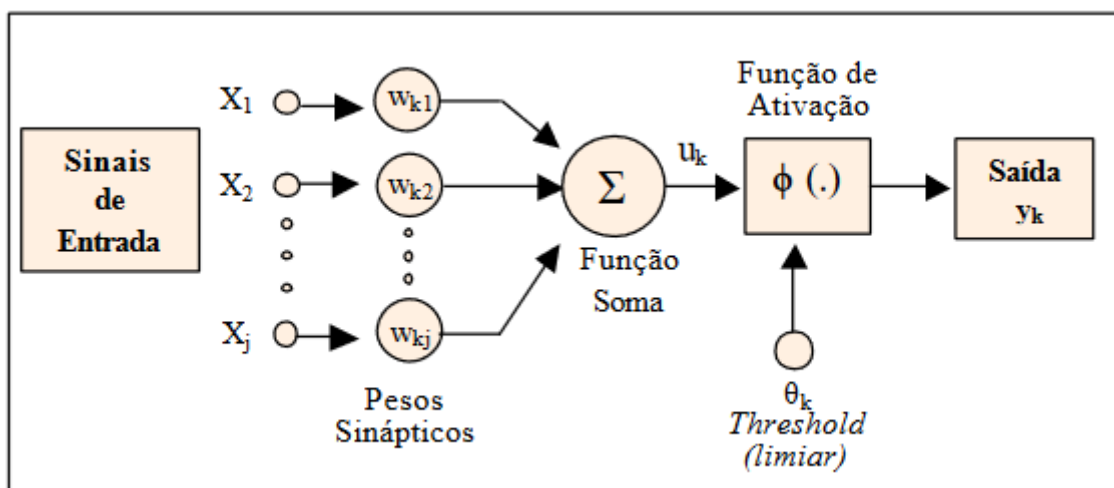


Figura 2 – Modelo de neurônio artificial

Fonte: Brondino, 1999

As classes utilizadas foram relacionadas às respectivas cores, planta sadia ao verde, planta infectada por nematoide ao vermelho, e o solo exposto ao mango. Para confeccionar o mapa da

figura foram adotadas como sistema de referência SIRGAS 2000, e como projeção cartográfica UTM Zona 23S.

Diante do exposto, antes de executar a classificação foi calculado o TGI, a fim de auxiliar o treinamento do algoritmo durante a classificação. Segundo McKinnon e Hoff (2017) analisando o sensor de uma câmera CMOS, e considerando os seus comprimentos de ondas, normalizados pelo sinal do verde, podemos descrever a equação do TGI como:

$$TGI = G - 0,39 * R - 0,61 * B \quad (1)$$

Onde G são os valores espectrais do canal verde, R os valores espectrais do canal vermelho e B os valores espectrais do canal azul.




Figura 3 – O TGI é definido como a área do triângulo, no qual seus vértices são determinados pelos sinais de reflectância do vermelho, verde, e azul

Fonte: Hunt Jr. Et al. 2011

Apos a classificação pelo método de redes neurais artificiais foi calculado o índice Kappa, sugerido por Cohen (1960), que serve para validar a classificação. O índice foi calculado através da matriz de confusão, que retorna também o valor da acurácia geral da classificação. O índice Kappa foi determinado pela seguinte expressão:

$$\bar{K} = \frac{\hat{p}_o - \hat{p}_e}{1 - \hat{p}_e} \quad (2)$$

Onde

$$\hat{p}_o = \sum_{i=1}^r \frac{n_{ii}}{n} \quad (3)$$

$$\hat{p}_e = \sum_{i=1}^r \frac{n_i * n_i}{n^2} \quad (4)$$

O resultado do coeficiente Kappa retorna um valor que indica a qualidade da classificação. Este resultado foi analisado segundo a Tabela 1, proposta por Landis e Koch (1977), que associa um grau de qualidade para parametrizar o índice Kappa. Os intervalos das classes variam de valores inferiores a zero, e menores ou igual a um.

Tabela 1. Valores do coeficiente Kappa para análise da classificação

Kappa	Qualidade da classificação
<0,00	Pobre
0,00 – 0,20	Fraca
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito Boa
0,80 – 1,00	Excelente

Fonte: Adaptada de Landis e Koch (1977, p.165)

2.4 Parâmetros de entrada para a classificação

A classificação supervisionada por redes neurais foi realizada no *software ENVI classic 5,0*. Foram utilizados os valores de entrada padrão imputados pelo sistema, sendo cada um deles respectivos aos seguintes campos:

- *Training Threshold Contribution*: Recebe valores de 0 a 1. Determina o tamanho da contribuição de um peso específico com seu respectivo nó de ativação. É usado para ajustar as mudanças de um peso interno para o nó. Neste processamento foi utilizado o valor de 0,9.
- *Training Rate*: Recebe valores de 0 a 1. Serve para determinar a magnitude dos pesos no ajustamento. Para este processamento foi escolhido como valor de entrada 0,2.
- *Training Momentum*: Recebe valores de 0 a 1. Quando inserido um valor superior a zero permite um maior valor de treinamento médio com menos oscilações. Foi escolhido o valor de 0,9 para este processamento.
- *Training RMS Exit Criteria*: Recebe o valor de RMS ideal para o treinamento, de tal forma que quando atingido o sistema pare o treinamento do algoritmo. É importante destacar que mesmo que o número de iterações não tenha sido concluído a fase de treinamento se encerrará após atingir esse valor. O valor de entrada para o processamento foi de 0,1.

- *Number of Hidden Layers*: Para uma classificação linear é utilizado o valor 0. Classificações não lineares são executadas por um valor de entrada igual a 1 ou maior. Neste processamento foi utilizado o valor de entrada igual a 1.
- *Number of Training Iterations*: Número de iterações para qual o sistema repete, neste processamento o valor de entrada foi 1000.
- *Min Output Activation Threshold*: Se o valor de ativação para classificação do pixel for menor que o threshold, então o pixel não será classificado. Neste contexto, o valor inserido foi nulo, para que todos os pixels fossem classificados.

3. RESULTADOS E DISCUSSÕES

A Figura 3 mostra o resultado obtido pela classificação supervisionada pelo método de redes neurais artificiais.




Figura 3 – Identificação dos patógenos através da classificação por RNA

Fonte: Os autores.

Entre os resultados a serem evidenciados nesse trabalho, pode-se destacar o processo de classificação pelo método de redes neurais artificiais, assim como a geração da matriz de confusão e cálculo do índice Kappa. A classificação por RNA gerou resultados satisfatórios, uma vez que o algoritmo foi capaz de identificar corretamente a presença de nematoides na plantação,

em todos os seus talhões, como pode ser observado na Figura 3. Também é possível observar as delimitações de solo exposto corretamente classificadas.

A partir do mapa gerado pela classificação supervisionada podemos observar que as áreas infectadas por nematoides concentram-se principalmente nas extremidades e no centro da área de estudo. Ao passo que é possível a identificação visual de forma mais homogênea tanto da área infectada como da planta sadia.

Podemos observar na Tabela 2 as colunas referentes a cada uma das classes, assim como uma coluna correspondente ao valor total de pontos analisados em cada linha e a taxa de comissão. As linhas foram divididas de acordo com as classes, para que fosse feita a correspondência das informações, seguidas por uma linha de total, expondo o total de pontos analisados em cada coluna, e uma linha como a taxa de omissão de cada classe.

Tabela 2. Matriz de Confusão

Classe	Sadia	Nematoide	Solo Exposto	Total	Comissão(%)
Sadia	12	0	0	12	0
Nematoide	3	14	0	20	17,65
Solo Exposto	1	5	10	13	37,50
Total	16	19	10	45	
Omissão (%)	25,00	26,32	0,00		

Fonte: Os autores

Através dos valores da matriz de confusão (Tabela 2) é possível analisar os erros de comissão e omissão dos objetos de estudo. O solo exposto foi a classe com menor valor de omissão, representado por 0,00%, o que transcreve que todos os pixels dessa classe foram devidamente classificados, ao passo que seu valor de comissão equivaleu a 37,50%. Entre as plantas sadias e as infectadas por nematoide os valores calculados pela matriz de confusão mostraram que a divisão entre os dois objetos de estudo foi separada de forma satisfatória, uma vez que nas plantas sadias o valor de omissão foi de 25,00% e nas plantas infectadas por nematoides de 26,32%.

O índice Kappa calculado foi de 0,70, e o valor de precisão geral de 80,00%. A diferença entre os dois valores se dá principalmente pelo fato de a precisão geral não considerar os valores de pixels incorretamente classificados, sendo que o índice Kappa considera todos os valores de pixels. Entretanto, o resultado do índice Kappa mostra que a qualidade da classificação é “Muito boa”, uma vez que este resultado está entre o intervalo de 0,6 e 0,8, segundo a Tabela 1.

Dessa forma, pode ser observado o potencial de métodos de classificação supervisionada para discriminação de patógenos da cultura cafeeira, em função do seu comprimento de onda, uma vez que esta metodologia tem se mostrado eficiente com sensores orbitais, tais como Landsat 8 (MARTINS et. al, 2015).

4. CONCLUSÕES

A aplicação de ARPs na detecção de patógenos vem crescendo cada vez mais, uma vez que esta tecnologia tem-se mostrado eficiente em pesquisas agrícolas que as utilizam. Através do mosaico das imagens aerofotogramétricas, é possível identificar com exatidão aspectos físicos ligados a plantação, já que é possível obter o GSD que melhor atenda as análises de cada cultura.

Dessa forma, a classificação pelo método de redes neurais artificiais mostrou-se muito eficiente na detecção de nematoides, alcançando os resultados esperados. No que tange a aplicabilidade do método, sua eficiência foi comprovada pelo índice Kappa, que retornou um valor próximo a um, sendo este um resultado “muito bom”, segundo as referências utilizadas nessa pesquisa. O índice de precisão geral retornou um valor mais otimista (80,00%), visto as referências que são adotadas para o seu cálculo. Todavia, a metodologia ainda pode ser aperfeiçoada em pesquisas posteriores, para que o resultado seja mais acurado, assim como a comparação entre outros métodos de classificação, para estimar o mais preciso, ou determinar um valor limiar mais próximo do ideal.

Referências Bibliográficas

ARRUDA, Rosalina Oliveira. **A produção de café arábica e sua relação com o crédito rural nos principais estados produtores do Brasil**. 2017. 21 f. TCC (Graduação) - Curso de Ciências Contábeis, Universidade Federal de Uberlândia, Uberlândia, 2017.

BECK, P. S. A et al., The feasibility of detecting trees affected by Pine Wood Nematode using remote sensing. **Europe Comission. Joint Research Centre**. Institute of Environment and Sustainability, Italy. 2015. 34p.

BRONDINO, N.C.M. **Estudo da Influência da Acessibilidade no Valor de Lotes Urbanos Através do Uso de Redes Neurais**, 1999, 97 f. Tese (Doutorado em Engenharia Civil – Transportes) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

Campos VP, Villain L (2005). **Nematode parasites of coffee, cocoa and tea**. In: Luc M, Sikora RA, Bridge J (Eds.) Plant parasitic nematodes in subtropical and tropical agriculture. Wallingford UK. CAB International. pp. 529-579.

Cohen, J. (1960). **A coefficient of agreement for nominal scales**. *Educational and Psychological Measurement*, 20, 37-46.

EMBRAPA. **Estudos socioeconômicos e ambientais - Produtividade média da cafeicultura brasileira em 2018**. 2018. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/31412007/produktividade-media-da-cafeicultura-brasileira-em-2018-devera-ser-a-maior-ja-registrada-com-2947-sacas-por-hectare>>.

FERRAZ, G. A. S.; SILVA, F. M.; COSTA, P. A. N. da; SILVA, A. C.; CARVALHO, F.M.. **Agricultura de precisão no estudo de atributos químicos do solo e da produtividade de lavoura cafeeira**. *Coffee Science*, v. 7, p. 59-67, 2012.

GALO, M. L. B. T.; NOVO, E. M. L. M. Aspectos relacionados com o fenômeno de mistura espectral e ambiguidade na classificação usando redes neurais artificiais. In: Simposio Brasileiro de Geomática, 1., 2002. Presidente Prudente - SP. *Anais...* Presidente Prudente – SP: 2002, p. 150-161.

HUNT, E. Raymond et al. Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. **Agronomy Journal**, [s.l.], v. 103, n. 4, p.1090-1099, maio 2011. American Society of Agronomy. <http://dx.doi.org/10.2134/agronj2010.0395>.

ITO, D.S.; MACHADO, A.C.Z.; SILVA, S.A.. **Distribuição de espécies de nematoides do gênero meloidogyne em regiões cafeeiras do paran .** Ci ncia Florestal, Londrina, v. 1, n. 22, p.113-124, jan. 2012.

MARTINS, George Deroco; GALO, Maria de Lourdes Bueno Trindade. **Detec o de  reas infestadas por nematoides e Migdolus fryanus em cultura canavieira a partir de imagens multiespectrais Rapideye.** Revista Brasileira de Cartografia, Bras lia, v. 2, n. 66, p.285-301, 01 jun. 2014.

MARTINS, George Deroco; GALO, Maria de Lourdes Bueno Trindade. **Caracteriza o hiperespectral in situ do cafeeiro infectado por nematoides.** Anais XVII Simp sio Brasileiro de Sensoriamento Remoto - SBSR, Jo o Pessoa-PB, Brasil, 25 a 29 de abril de 2015.

MARTINS, George Deroco; GALO, Maria de Lourdes Bueno Trindade; VIEIRA, Bruno Sergio. Detecting and Mapping Root-Knot Nematode Infection in Coffee Crop Using Remote Sensing Measurements. **Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing**, [s.l.], v. 10, n. 12, p.5395-5403, dez. 2017. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/jstars.2017.2737618>

OLIVEIRA, Gildriano Soares de. **Produtividade de biomassa de cana-de-a car em fun o dos  ndices de vegeta o utilizando t cnicas de sensoriamento remoto.** Tese: Mestrado. Reposit rio UNESP, 2015.

SOCIEDADE BRASILEIRA DE NEMATOLOGIA. **Nematoides de Galha.** Dispon vel em: <<http://nematologia.com.br/category/aceso-mini-aulas/meloidogyne-spp/>>.