

GERENCIAMENTO DE RISCO DECORRENTE DE DOENÇAS FUNGICAS EM CULTURA DA BANANA BASEADO EM AUTOMAÇÃO E APRENDIZADO DE MÁQUINAS

PAULO E. CRUVINEL¹

¹ Doutor, Embrapa Instrumentação, (16) 21072826, paulo.cruvinel@embrapa.br

Apresentado no
XLVIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2019
17 a 19 de setembro de 2019 - Campinas - SP, Brasil

RESUMO: Como uma planta herbácea vivaz acaule da família Musaceae (*Musa spp.*), originárias do sudeste da Ásia, a banana é cultivada em praticamente todas as regiões tropicais do planeta, principalmente no Brasil. Sua produção, entretanto, tem sido limitada devido à presença de doenças fúngicas, as quais têm provocado perdas aos produtores. Devido a este fato uma série de iniciativas tem sido requerida para o setor, principalmente no âmbito do monitoramento e controle de riscos causados por essas doenças. Este trabalho apresenta a evolução de um modelo para a gestão de riscos decorrentes do estágio dessas doenças em escala de propriedade utilizando conceitos da agricultura de precisão, do reconhecimento de padrões e classificação baseada em aprendizado de máquina.

PALAVRAS-CHAVE: Risco agrícola, Doenças fúngicas, Aprendizado de máquina.

RISK MANAGEMENT RELATED TO FUNGAL DISEASES IN BANANA CROP BASED ON THE PRECISION AGRICULTURE AND MACHINE LEARNING

ABSTRACT: As a lively herbaceous plant of the family Musaceae (*Musa spp.*), i.e., originating in Southeast Asia, banana is cultivated in practically all the tropical regions of the planet, mainly in Brazil. Its production, however, has been limited due to the presence of fungal diseases, which have caused losses to the producers. Due to this fact a series of initiatives have been required for the sector, mainly in the scope of the monitoring and control of risks. This work presents the evolution of a model for the management of risks arising from the stage of these diseases in property scale using concepts of precision agriculture, pattern recognition and classification based on machine learning.

KEYWORDS: Agricultural risk, Fungal diseases, Machine learning.

INTRODUÇÃO: Monitoramento e controle do risco é o processo que visa identificar e assegurar o controle do risco, monitorando-os e identificando-os, buscando assegurar a execução dos planos do risco e avaliando sua eficiência na redução dos mesmos. Bons sistemas de monitoramento e controle do risco devem fornecer informações que suportam decisões eficazes buscando elementos que possam definir o que fazer no avanço de ocorrências dos riscos.

Um processo de monitoramento de doenças de plantas, que considere aspectos relevantes do manejo baseado em informações qualificadas para a tomada de decisão, pode ser auxiliado considerando o incremento da produção e a rentabilidade agrícola, bem como a minimização dos impactos ambientais, o que é altamente desejável nas áreas produtivas.

Neste contexto, modelos de decisão acoplados a sistemas de informações se constituem em ferramentas que podem viabilizar o estabelecimento de programas territoriais de manejo de doenças, incluindo escala de propriedade, o que pode proporcionar efetividade e maior rapidez nos processos de tomada de decisão.

Segundo o Instituto Brasileiro de Frutas (IBRAF, 2008) entre as principais doenças que ocorrem em bananais, nos países tropicais, encontram-se as doenças fúngicas como a Sigatoka-amarela (BURT et al., 1997), o mal-do-Panamá (BORGES et al., 2007) e a Sigatoka-negra (HANADA et al., 2002).

Os reflexos dessas doenças são sentidos pela rápida destruição da área foliar, reduzindo-se a capacidade fotossintética da planta e, conseqüentemente, a sua capacidade produtiva.

Atualmente os sistemas de auxílio à decisão têm lançado mão de algoritmos estabelecidos com base no aprendizado de máquina. O aprendizado de máquina é compreendido como um método de análise de dados que automatiza a construção de modelos que podem auxiliar a tomada de decisão (YILDRIM & BIRANT, 2014). É tido como um ramo das ciências da computação que associa reconhecimento de padrões (BISHOP, 1995), classificadores (WANG et al., 2015) e inteligência artificial baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões não supervisionadas.

Neste trabalho é discutida a evolução de um modelo de gestão de riscos para o manejo de cultura de banana para o auxílio ao processo de tomada de decisão que visem à minimização de externalidades negativas provocadas por fungos. O método considera o manejo baseado em agricultura de precisão e conceitos do aprendizado de máquina para o processo de auxílio à tomada de decisão.

MATERIAL E MÉTODOS: A Figura 1 ilustra a concepção da estrutura do modelo para a gestão de riscos decorrentes de doenças fúngicas que podem ocorrer em bananais.

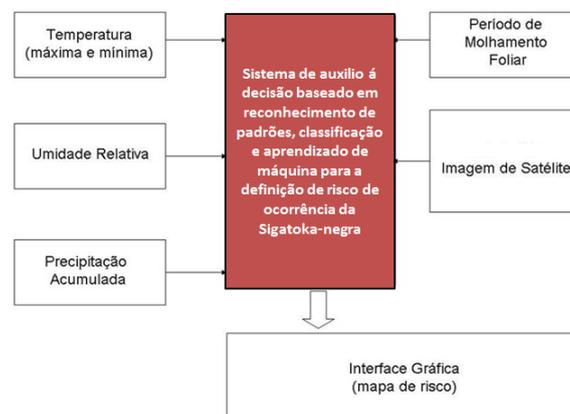


FIGURA 1. Concepção estrutural para estabelecimento do modelo para avaliar o risco de Sigatoka-negra em bananais, considerando o uso de funções polinomiais de ordem elevada e integração de variáveis para geração da figura de risco.

Com base no uso de aprendizado de máquina um conjunto de modalidades de funções utilizadas para ajustes de curvas ou funções viabiliza estabelecer modelos computacionais que utilizam dados obtidos a partir de medidas físicas de variáveis, os reconhece e classifica em tempo real. Dados climáticos sobre, temperatura e umidade relativa são obtidos de estações meteorológicas. Dados sobre a duração do período de molhamento foliar (DPM) são inferidos em função dos dados climáticos. Para obtenção dos dados relacionados à reflectância dos

comprimentos de onda na faixa do verde, são utilizadas imagens de satélites que podem ser obtidas com sensores apropriados.

No modelo a integração dos riscos é baseada nas metodologias propostas por Cruvinel e colaboradores (CRUVINEL *et al.*, 2011; BENDINI *et al.*, 2013), onde o risco integrado é fruto da concatenação das probabilidades sobre as faixas de valores de dados climáticos, período de molhamento foliar e informações de refletância que podem ser mais propícios à ocorrência de doenças fúngicas.

De forma a viabilizar a análise das variáveis, foram utilizados modelos de regressão não-linear, tomando por base que os dados observados de uma variável resposta podem ser descritos por uma função de uma ou mais variáveis explicativas que é não linear em relação aos seus parâmetros. Assim, foi possível identificar e estabelecer a relação entre variáveis explicativas e respostas. Desta forma, foi possível buscar relações físicas, biológicas, químicas e fisiológicas utilizando funções não lineares que apresentam coeficientes (parâmetros) identificados (estimados) a partir de dados observados ou experimentais.

RESULTADOS E DISCUSSÃO: Para validação do método foi utilizado um estudo de caso para gestão de risco de Sigatoka-negra. A escolha do cultivar de bananeira (*Musa spp.*) depende da preferência do mercado consumidor e do destino da produção (indústria ou consumo in natura). Assim, foram utilizadas bases de informações coletadas em área de 12 hectares de uma propriedade rural localizada no estado de São Paulo, área de bananal com a cultivar Grand Naine (Nanicão), com amostragem considerada em espaçamentos de 2,5m x 2,5m.

A Tabela 1 apresenta informações sobre as variáveis utilizadas, suas unidades, incluindo a amplitude e o passo para a organização das classes. Após a descrição do comportamento das variáveis, obtidas a partir do ajuste de funções spline cúbicas, foi incluído a análise da avaliação de risco integrado, utilizando um processo de análise multiparametral, onde se envolveu o estabelecimento de um polígono denominado Figura de Mérito de Risco (FMR), o qual é inscrito em um conjunto de círculos de raios unitários.

TABELA 1. Informações sobre as variáveis para descrição dos modelos

	T _{min} (°C)	T _{max} (°C)	R _g (mm)	UR (%)	DPM (t)
Máximo	22,67	35,94	200,90	91,9	127,0
Mínimo	7,57	19,13	0,00	79,3	23,0
Desvio Padrão	3,38	3,48	38,45	3,0	21,8
Média	17,23	28,34	32,46	85,9	83,2
Mediana	17,51	28,26	21,80	86,0	85,0
Moda	20,34	27,83	0,00	-	53,0
1° Quartil	15,00	25,39	1,60	84,4	65,0
2° Quartil	17,51	28,26	21,80	86,0	85,0
3° Quartil	20,14	30,89	47,80	88,0	97,0
Amplitude	15,10	16,81	200,90	12,6	104,0
Passo	1,51	1,68	20,09	1,3	10,4

A Figura 2 ilustra em (a) o uso dos círculos de raio unitário, onde se encontram distribuídas, como exemplos, resultados da composição das probabilidades de ocorrência de risco obtidas para cada pixel da imagem obtida para a área de cultura em análise; em (b) ilustra um exemplo de mapa de risco que é visualizado com o uso da interface gráfica e em função das informações das latitudes e das longitudes geodésicas em área de plantio.

A partir das figuras de mérito, cada qual georeferenciada com base nas coordenadas das imagens obtidas para a área de cultivo da banana é possível se obter a integração das variáveis de risco e o encontro das classes que podem ser conectadas, ou seja, aquelas que possuem vizinhos de valores iguais, ou com diferenças que estejam dentro limites pré-estabelecido. Uma vez encontradas, as mesmas são unidas, gerando novas classes de

primitivas que viabilizam a organização do mapa de risco em três níveis, a saber: alto (cor vermelha), médio (cor amarela) e baixo risco (cor verde). A partir do mapa de risco é possível estabelecer a prescrição da aplicação de fungicidas em taxa variada.

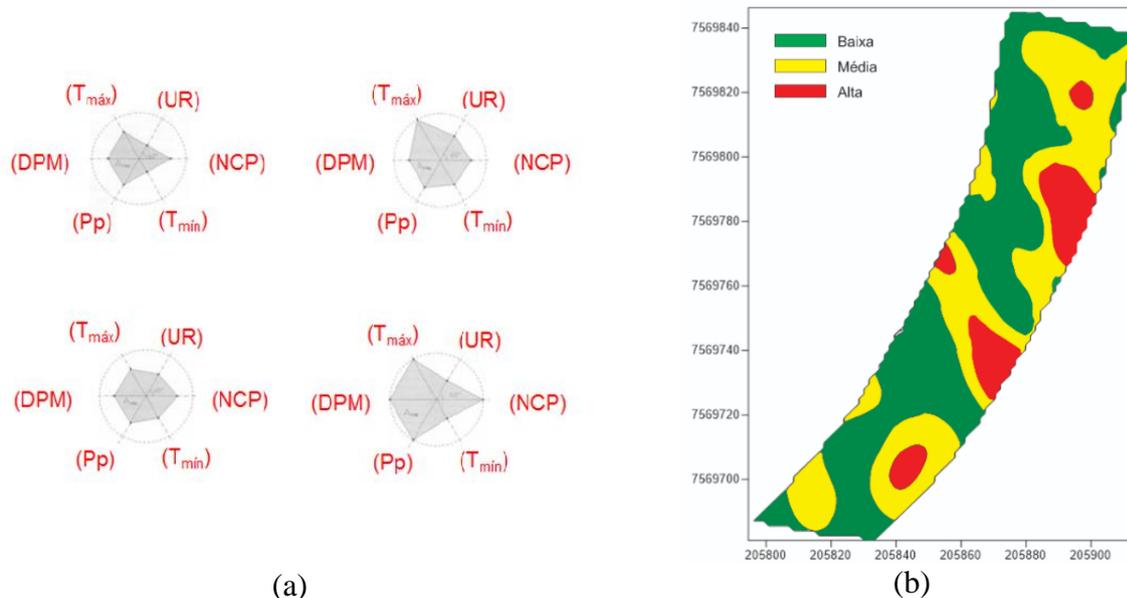


FIGURA 2. (a) Exemplo de círculos de raio unitário contendo a intersecção das probabilidades para os valores das variáveis para geração das Figuras de Riscos (FMR); (b) mapa de risco para a favorabilidade da ocorrência da Sigatoka-negra em área de cultivo em escala de propriedade.

CONCLUSÕES: Este trabalho apresentou um sistema para o auxílio á decisão sobre riscos da ocorrência de doenças fúngicas em áreas de cultivo de bananas, fundamentado nos paradigmas da agricultura de precisão e do aprendizado de máquina. A validação foi realizada considerando um caso real de Sigatoka-negra em escala de propriedade, com elementos que indicam caminhos para uma abordagem que pode ser estendida para outras doenças fúngicas que aparecem em áreas de produção.

AGRADECIMENTOS: Este trabalho recebeu apoio financeiro da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Processo 17/19350-2, via convênio IBM Brasil e da Empresa Brasileira de Pesquisa Agropecuária (Embrapa), Processo SEG 11.14.09.001.05.06.

REFERÊNCIAS

- BENDINI, H. N.; MORAES, W. da S.; SILVA, S.H.M.G.; TEZUKA, E. S.; CRUVINEL, P. E. Análise de risco da ocorrência de Sigatoka-negra baseada em modelos polinomiais: um estudo de caso. *Tropical Plant Pathology*, vol. 38, série1, pp. 35-43, 2013.
- BISHOP, C. *Neural Networks for Pattern Recognition*. Oxford University Press, 1995.
- BORGES, A.J.S.; TRINDADE, A. V.; MATOS, A. P.; SILVA PEIXOTO, M. F. Redução do mal-do-panamá em bananeira-maçã por inoculação de fungo *micorrízico arbuscular*. *Embrapa, Brasília*, vol.42, n.1, pp.35-41, 2007.
- BURT, P.J.A.; RUTTER, J.; GONZALES, H. Short-distance wind dispersal of the fungal pathogens causing Sigatoka diseases in banana and plantain. *Plant Pathology, Oxford*, vol.46, n.6, pp.451-458, 1997.
- CRUVINEL, P. E.; MORAES, W. da S.; BENDINI, H. N.; SILVA, S.H.M.G.; TEZUKA, E. S. Avaliação de modelos para estabelecimento de figura de risco de ocorrência da Sigatoka-negra em bananais, *Embrapa Instrumentação, Série Documentos*, ISSN: 1518-7179, 28pp., 2011.
- HANADA, R. E.; GASPAROTTO, L.; PEREIRA, J. C. R. Sobrevivência de conídios de *Mycosphaerella fijiensis* em diferentes materiais. *Fitopatologia Brasileira, Brasília*, vol.27, n.4, pp.408-411, 2002.
- INSTITUTO BRASILEIRO DE FRUTAS (IBRAF). *Perspectivas da Fruticultura Brasileira*. Disponível em: <http://www.ibraf.org.br/news_item.asp?NewsID=3345>. Acesso em 12 de maio de 2019.
- WANG S, JIANG L, LI C. Adapting naive Bayes tree for text classification. *Knowledge and Information Systems*, 44(1), pp.77-89, 2015.
- YILDRIM P, BIRANT D. Naïve Bayes classifier for continuous variables using novel method and distributions. *IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA)*.Alberobello, pp.110-115, 2014.