

Aprendizado de máquina aplicado à identificação de deficiências nutricionais em bananeiras

Silvia H. M. G. Silva^{1†}, Liciana A. V. Silveira², Danilo E. Rozane³, Juliana D. Lima⁴, Eduardo N. Gomes⁵, Kassiane L. Lindner⁶

¹Universidade Estadual Paulista – Câmpus Experimental de Registro.

²Universidade Estadual Paulista – Instituto de Biociências, Dep. de Bioestatística. E-mail: liciana.silveira@unesp.br.

³Universidade Estadual Paulista – Câmpus Experimental de Registro. E-mail: danilo.rozane@unesp.br.

⁴Universidade Estadual Paulista – Câmpus Experimental de Registro. E-mail: juliana.d.lima@unesp.br.

⁵Universidade Estadual Paulista – Câmpus Experimental de Registro. E-mail: engomes@unesp.br.

⁶Universidade Estadual Paulista – Câmpus Experimental de Registro. E-mail: kassiane.lindner@unesp.br.

Resumo: A avaliação nutricional das plantas é feita por meio de análises químicas ou pela diagnose visual e é preciso conhecer os padrões característicos de deficiência nutricional de cada elemento. O processamento digital de imagens (PDI) é um exemplo do uso de tecnologia na agricultura. Neste trabalho aplica-se o PDI para identificação da sintomatologia de deficiência em imagens digitais de folhas de bananeiras, induzidas à deficiência dos nutrientes de N, P e K. Realizou-se o experimento em duas etapas: 1) em casa de vegetação, com mudas submetidas ao delineamento experimental em blocos casualizados em esquema fatorial 5x5, com três repetições. Os fatores foram variação nutricional (Solução completa, omissões individuais de N, P, K e um controle com o cultivo em solo), e época de amostragem aos 0, 30, 60, 90 e 120 dias após a aplicação dos tratamentos; 2) experimento com PDI, aplicado em quatro fases: coleta e digitalização das amostras, extração dos histogramas, seleção de atributos e classificação, executados com uma base de dados para cada época estudada (0, 30, 60, 90 e 120 dias). As maiores taxas de acurácias do experimento foram apresentadas pelos classificadores com redes neurais artificiais (RNA), iguais a 66,7%, 62%, 76,7%, 62,3%, 68,3%, nas épocas 0, 30, 60, 90 e 120, respectivamente. Evidencia-se um bom desempenho encontrado pelos classificadores com RNA, verificado pelas especificidade (90%, 98%, 97%, 97% e 98%) sensibilidade (93 %, 77%, 93%, 75% e 82%) nas épocas 0, 30,60,90 e 120, respectivamente, dos modelos.

Palavras-chave: classificação; processamento digital de imagens; diagnóstico visual de plantas; redes neurais artificiais.

Abstract: The nutritional evaluation of plants is done through chemical analysis or visual diagnosis and it is necessary to know the characteristic patterns of nutritional deficiency of each element. Digital image processing (PDI) is an example of the use of technology in agriculture. In this work the PDI is applied to identify the symptomatology of deficiency in digital images of banana leaves, induced to the deficiency of N, P and K nutrients. The experiment was carried out in two stages: 1) in a greenhouse, with seedlings submitted to a randomized complete block design in a 5x5 factorial scheme, with three replications. The factors were nutritional variation (complete solution, individual omissions of N, P, K and a control with soil cultivation), and sampling time at 0, 30, 60, 90 and 120 days after application of the treatments; 2) PDI experiment, applied in four phases: sample collection and digitization, extraction of histograms, selection of attributes and classification, performed with a database for each time studied (0, 30, 60, 90 and 120 days). The highest accuracy rates of the experiment were presented by classifiers with artificial neural networks (ANNs), equal to 66.7%, 62%, 76.7%, 62.3%, 68.3%, in the 0, 30, 60, 90 and 120, respectively. A good performance was found by the classifiers with RNA, verified by specificity (90%, 98%, 97%, 97% and 98%) sensitivity (93%, 77%, 93%, 75% and 82%) in the 0, 30,60,90 and 120, respectively, of the models.

Keywords: classification; digital image processing; visual diagnosis of plants; artificial neural networks.

†Autora correspondente: silvia.modenese@unesp.br.

Introdução

Na fruticultura mundial a banana tem se estabelecido como a segunda maior frutífera cultivada, em cultivo em mais de 125 países. O continente asiático lidera a produção com 58 % do volume produzido, seguido pelo americano com 26 % (América do Sul, com 17 % e a América Central com 8 %), e o africano com 14 % (FAO, 2014). No Brasil, o quarto maior produtor mundial desta frutífera, as produções anuais equivalem a 6,9% da produção mundial, superando sete milhões de toneladas, perdendo em volume apenas para a citricultura (FAO, 2016).

Mesmo enquadrando-se entre os maiores produtores mundiais, observando o período das safras agrícolas de 2009 a 2013, o Brasil apresentou o rendimento médio de 14,3 t ha⁻¹ (ou, 12,0 t ha⁻¹, segundo Agriannual, 2016), ou seja, inferior à média mundial que é de 19,3 t ha⁻¹. O maior rendimento médio por área colhida pertence à Nicarágua, que perfaz 55,6 t ha⁻¹ (FAO, 2014).

No Brasil, os melhores rendimentos na safra 2015 pertencem ao Rio Grande do Norte. Embora não tenha uma produção tão expressiva (158 mil toneladas – 10º posição no ranking nacional), atinge mais que o dobro da média nacional, com 30 t ha⁻¹. Praticamente empatados na segunda posição estão Paraná e Santa Catarina, com 24 t ha⁻¹, seguidos por São Paulo, com o quarto melhor desempenho, produzindo 21 t ha⁻¹, apesar de ser o maior estado produtor com 1,13 milhões de toneladas produzidas (AGRIANUAL, 2016).

A banana é a segunda fruta mais consumida no planeta, com 11,4 kg hab⁻¹ ano⁻¹, perdendo apenas para a laranja, com 12,2 kg hab⁻¹ ano⁻¹. O continente americano é o maior consumidor, com 15,2 kg hab⁻¹ ano⁻¹, destacando-se a América do Sul, com 20 kg hab⁻¹ ano⁻¹ e a América Central, com 13,9 kg hab⁻¹ ano⁻¹ (FAO, 2014). O mercado interno brasileiro consome praticamente a totalidade da produção de banana do país, em torno de 7,3 milhões de t ano⁻¹, com as regiões Sul e Sudeste respondendo por aproximadamente 45% das áreas de cultivo (IBGE, 2016; GONÇALVEZ; PEREZ, 2013; FAO, 2014).

No Estado de São Paulo, a produção de bananas predomina-se no Vale do Ribeira, litoral sul de São Paulo, onde está concentrada a maior área plantada e de produção no país (828.593 toneladas), e se caracteriza com produção por pequenos e médios agricultores (10 a 20 ha) (AGRIANUAL, 2016). De acordo com Gelmini (2004) a maioria dos bananicultores da região (80%) é constituída por micro e pequenos produtores que produzem até 50 mil pés de banana que utilizam mão-de-obra familiar, enquanto que o restante é constituído de médios e grandes produtores, destacando-se pela importância para a geração de emprego e renda, e presença do homem no campo.

Segunda Malavolta (2006), a bananeira e as plantas em geral necessitam, para o ciclo de vida, de dezenove nutrientes essenciais. Desses nutrientes três (C, H e O) são provenientes do ar e da água, e compõem aproximadamente 95% da matéria seca da planta. Por sua vez, os dezesseis restantes são divididos em macronutrientes (N, P, K, Ca, Mg e S) e micronutrientes (Fe, Mn, Zn, Cu, B, Cl, Mo, Ni, Co e Se).

Como os solos tropicais, via de regra, são caracterizados pela baixa fertilidade, a nutrição da planta deve ser realizada com a prática da adubação, quando necessária, com vistas à manutenção da produtividade ou redução de perdas no ciclo da cultura. A avaliação do estado nutricional das plantas, usualmente, é feita por meio de análises químicas ou pela diagnose visual da planta (MALAVOLTA, 2006).

A diagnose visual é uma ferramenta útil na identificação de distúrbios fisiológicos em plantas, onde deficiências nutricionais são geralmente os mais comuns. A identificação visual de deficiências nutricionais se dá pelo conhecimento do observador, entretanto, muitas vezes necessita de comprovação mediante a análise do tecido vegetal, que leva tempo e possui um custo. A identificação

Sigmae, Alfenas, v.8, n.2, p. 704-715, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).

18º Simpósio de Estatística Aplicada à Experimentação Agrônômica (SEAGRO).

precoce da necessidade de nutrientes agiliza a adubação, tornando-a mais eficiente (PESTANA et al., 2003).

No mundo globalizado, a agricultura intensiva depende, de forma crescente e irreversível, da utilização de insumos e tecnologias modernas, a fim de que os resultados tragam benefícios práticos. O uso de modelos matemáticos e técnicas computacionais para a resolução de problemas do campo têm se tornado mais comuns com o avanço das bases científicas mais confiáveis do ponto de vista técnico. Uma alternativa interessante e atraente para agilizar o diagnóstico nutricional é utilizar o processamento digital de imagens, PDI, (GONZALEZ; WOODS, 2002).

Técnicas de Aprendizado de Máquina, AM, por serem capazes de aprender por si próprias, são muito aplicadas dentro do PDI, sobretudo na fase de análise de imagens (DIETTERICH, 1997; MITCHELL, 1997). Várias pesquisas têm mostrado a aplicação de métodos de AM para a resolução de problemas na produção vegetal, sobretudo com o processamento digital de imagens (ABRAHÃO et al., 2013; LEE et al., 2010. CHAUDHARY et al., 2012; MODENESE-GORLA DA SILVA, 2008).

Escolher uma técnica de AM, que gere classificadores com bom desempenho tornará o uso do PDI na diagnose nutricional mais eficiente e confiável. Assim, neste trabalho, buscou-se comparar o desempenho de 4 técnicas de AM para problemas de classificação, Redes Neurais Artificiais (RNA), Random Forests (RF), Máquinas de Vetores Suporte (SVM) e Naive Bayes, aplicadas no PDI para identificação da deficiência de N, P e K em bananeiras.

Material e Métodos

Foi realizado um experimento em casa de vegetação, no período de janeiro a julho de 2014, na Unesp, Câmpus Experimental de Registro (CERe), com mudas de bananeiras cultivadas em hidroponia, cujo objetivo foi induzir deficiência nutricional. Foram utilizadas mudas micropropagadas e certificadas da cultivar Grande Naine, as quais foram submetidas a um delineamento experimental em blocos casualizados, em esquema fatorial 5x5, com três repetições. Os fatores foram variação nutricional (solução nutritiva completa, omissão de nitrogênio, omissão de fósforo, omissão de potássio e cultivo em solo) e época de amostragem (0, 30, 60, 90 e 120 dias após a aplicação das variações nutricionais).

Juntamente ao experimento químico, iniciou-se o experimento computacional para identificação dos sintomas de deficiências nutricionais a partir das folhas índices coletadas. Foi utilizado o PDI composto por quatro fases distintas de operacionalização (MODENESE-GORLA DA SILVA, 2008): (1) coleta e digitalização das amostras, (2) segmentação e extração dos histogramas das imagens, (3) seleção de atributos e, por último, (4) classificação.

Na fase 1, foram coletadas as folhas índices das plantas e levadas ao laboratório da Unesp – CERe. As folhas foram separadas e classificadas de acordo com sua variação nutricional (Fator 1) em cada umas das épocas (Fator 2): solução nutritiva completa (Comp), omissão de nitrogênio (-N), omissão de fósforo (-P), omissão de potássio (-K) e solo (Solo). Seguindo na Fase 1 e, logo após a coleta e a classificação manual das folhas, foram obtidas imagens digitais de cada uma das folhas, em scanner de mesa HP®, com resolução de 600 dpi. Às imagens foram atribuídas classes correspondentes aos níveis do Fator 1.

Na fase 2, de cada imagem, foram extraídas 20 subamostras, com o software GIMP®, com dimensões de 100 x 100 pixels, totalizando 300 subamostras para cada época (5 níveis (Fator1) x 3 repetições x 20 subamostras). As amostragens digitais foram coletadas na região de maior expressão do sintoma de deficiência e, quando não observados ou não existentes, foram coletadas nas regiões de maior incidência dos sintomas conforme as plantas deficientes.

Sigmae, Alfenas, v.8, n.2, p. 704-715, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).

18º Simpósio de Estatística Aplicada à Experimentação Agrônômica (SEAGRO).

Ainda na Fase 2, para cada subamostra foram extraídos os três componentes do sistema de cores RGB (*red green e blue*) com 256 tons de cinza. De cada componente, foram extraídos histogramas da distribuição de pixels na escala de cinza variando de 0 (preto puro) a 255 (branco puro), com o uso da ferramenta computacional desenvolvida por Modenese-Gorla da Silva (2008). Os histogramas gerados foram armazenados digitalmente em arquivos textos no formato (.txt), onde, posteriormente, foram agrupados formando uma base de dados para cada época de coleta (0,30, 60, 90 e 120 dias), também armazenadas em arquivos textos. Assim, foram testadas 5 bases de dados diferentes. Cada uma dessas bases de dados consistiu de 300 linhas, referentes ao número de subamostras, representadas por 769 variáveis (3bandas*256níveis de cinza + rótulo da classe).

A partir da Fase 3, a base de dados foi submetida ao software WEKA[®] (WITTEN; FRANK, 2005), onde a análise multivariada aplicada para a seleção de atributos, com a técnica de Análise de Componentes Principais, visou diminuir expressivamente o número de variáveis de entrada, substituindo-as por componentes principais selecionadas quanto ao grau de importância na classificação dos sintomas, sem prejuízo da informação biológica contida na variabilidade das respostas (JOHNSON; WICHEM, 2002).

Na classificação das imagens, a qual compreende a quarta e última etapa, foi realizado um estudo com técnicas de AM. As técnicas de AM testadas foram RNA, RF, SVM e NB, onde . compararam-se o desempenho. As RNA se baseiam em uma forma de computação não algorítmica, cujo funcionamento é inspirado no cérebro humano. A RNA testada foi a rede *Perceptron* multicamadas, treinadas com o algoritmo *backpropagation*, foram utilizados os valores de 0,2 e 0,3 para as taxas de aprendizado e termo *momentum* (HAYKIN, 1999), respectivamente. RF são combinações de classificadores de árvores de decisão, no experimento, utilizaram-se 10 árvores de decisão (BREIMAN, 2001). Já as SVM, são baseadas nos conceitos da Teoria do Aprendizado Estatístico (VAPNIK, 1995). Por sua vez, o NB se baseia no Teorema de Bayes para o cálculo das probabilidades necessárias para a classificação (MITCHELL, 1997; DUDA et al., 2002). Nesta etapa também foi utilizada a ferramenta computacional Weka[®].

A Weka[®] é uma ferramenta para AM desenvolvida na Universidade de Waikato, na Nova Zelândia, escrita em linguagem JAVA, com código aberto, que permite alterações nas funções a serem utilizadas, bem como a inserção de implementações não suportadas. A operacionalização deste programa é de domínio público disponível no endereço eletrônico: <http://www.cs.waikato.ac.nz/ml/weka>.

A execução da parte de experimentação computacional foi realizada em um microcomputador com multiprocessadores, com 16 Gbytes de memória RAM e 1 Tbytes de memória auxiliar.

Para verificar a validação (consistência) do experimento, foram utilizados alguns procedimentos e técnicas convencionais de confiabilidade. No caso de tarefas de classificação, uma medida comumente utilizada é a frequência (taxa) de erro do classificador, também conhecida como probabilidade (taxa) de classificação incorreta ou errônea ou acurácia. A probabilidade clássica do erro é obtida utilizando a expressão, a qual acumula as discordâncias entre a classe original de cada amostra com o rótulo atribuído pelo classificador induzido ponderada pelo total de amostras. Utilizando a função indicadora, tem-se que se a indicação de classificação for concordante, há uma classificação correta, ou seja, expressão lógica verdadeira e, neste caso, o contador indica o valor 1, caso contrário, expressão lógica falsa, e o valor indicado consiste de 0. O procedimento é obtido repetido para todas as amostras e o operador matemático vai acumulando o resultado até o número n de unidades amostrais. O complemento da probabilidade de erro é tomado como a precisão do classificador (BARANAUSKAS, 2000).

Para obter uma estimativa não viciada de erro do classificador, utilizou-se de técnicas de amostragem para manipulação dos conjuntos de treinamento e teste. Neste trabalho, foi considerada a metodologia r-partição *cross-validation* (EFRON; GONG, 1983; EFRON; TIBSHIRANI, 1993), que divide o conjunto de dados total, de tamanho n , em r partes mutuamente exclusivas (partições) de tamanhos iguais a n/r amostras. As amostras nos $(r - 1)$ partições são usadas para treinamento e a hipótese induzida é testada na partição remanescente. Este processo é repetido r vezes, cada vez considerando uma partição diferente para teste. O erro no *cross-validation* é a média dos erros calculados em cada uma das r partições de teste (BARANAUSKAS, 2000). A acurácia, por sua vez, representa a taxa de acerto do classificador, obtida de maneira análoga ao erro no *cross-validation*. Neste trabalho, a base de dados total foi dividida em 10 partições e o experimento foi repetido por 10 vezes.

Na comparação entre as técnicas aplicou-se o teste t pareado, para cada uma das técnicas testadas, verificando-se quais técnicas diferem entre si em relação à taxa de acurácia do classificador.

Após a comparação entre os classificadores, foram escolhidos os classificadores com melhor acurácia em cada base de dados, para ampliação da discussão da discriminação entre as classes.

Resultados e Discussão

Com a aplicação do critério de Kaiser, descartaram-se as combinações lineares das variáveis representadas nas componentes principais que possuíam pequena variância (autovalor < 1). Esses primeiros componentes principais explicam acumuladamente 95% da variação total.

Depois de selecionadas as componentes principais, a partir da matriz de correlação de dados, utilizaram-se essas componentes como vetores de entrada para a fase de classificação. De acordo com o critério descrito, foram selecionadas 31, 37, 46, 37 e 36 componentes principais para os experimentos das épocas de coleta 0, 30, 60, 90 e 120, respectivamente. Assim, os vetores foram compostos pelas variáveis de entrada (componentes principais) e uma variável de saída representando a classe de cada uma das amostras em cada base de dados.

Como ilustração do processo de treinamento, com as 36 componentes de principais de entrada, a Figura 1 exibe a arquitetura da RNA utilizada na classificação do experimento na época 120. Os traços gráficos em verde ilustram os neurônios da camada de entrada (componentes principais), os em vermelho, os neurônios da camada escondida e os amarelos, os neurônios da camada de saída, que são as 5 classes.

Os valores da média e desvio padrão da acurácia obtidos entre conjuntos de testes, para cada técnica de classificação nas 5 bases de dados estudadas estão apresentadas na Tabela 1. Os desvio-padrões estão indicados entre parênteses. Verifica-se que as maiores taxas de acurácia foram apresentadas pelos classificadores com RNA.

O resultado da aplicação do teste t entre as técnicas estudadas é ilustrado na Tabela 2. Verifica-se que a RNA foi a técnica que apresentou um maior número de diferenças significativas com superiores entre as comparações, com 7 asteriscos (*), apresentando, portanto, um melhor desempenho, seguida pelas técnicas RF, SVM e NB, respectivamente. Na linha da técnica NB encontram-se 14 asteriscos, mas com essa técnica sendo inferior em relação às outras na comparação.

O experimento computacional rodado na época 0 apresentou uma taxa de 33,3% de erro médio nos conjuntos de testes, o que correspondem a 100 imagens, e 66,7% de acerto, correspondendo a 200 imagens classificadas corretamente.

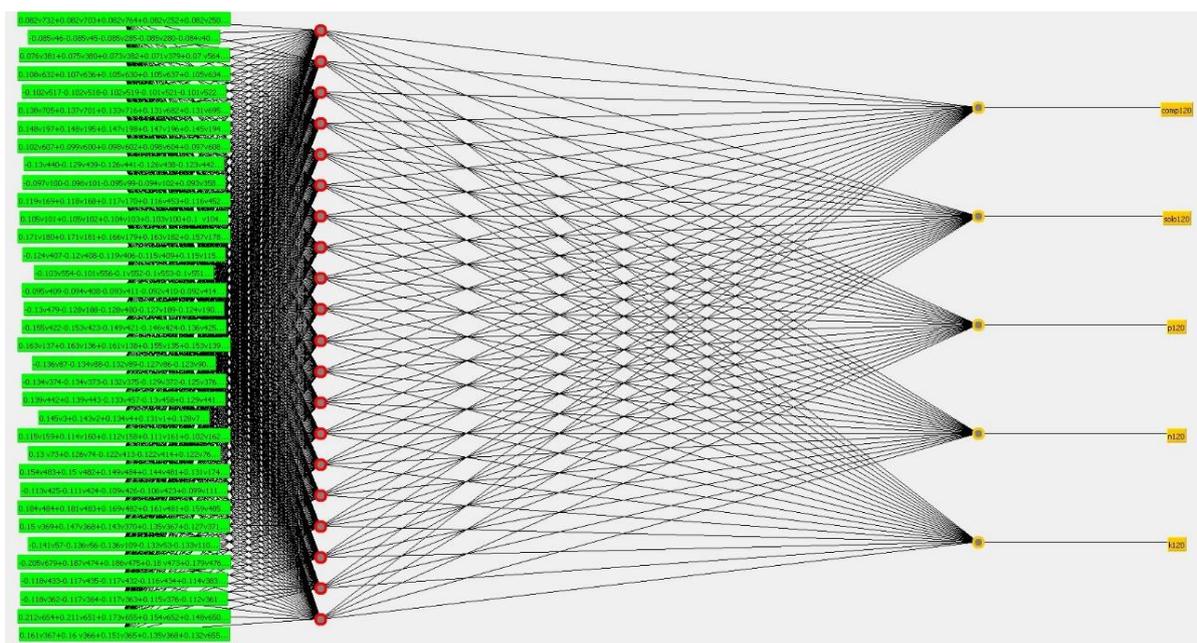


Figura 1: Rede Neural Multicamadas utilizada no treinamento dos padrões do experimento 120 dias.

Tabela 1. Acurácias médias e desvio-padrões dos conjuntos de testes das técnicas estudadas para as bases de dados das diferentes épocas de coleta das folhas.

Técnica	RNA	RF	SVM	NB
Base de dados				
0	66,70 (8,16)	65,57 (7,15)	61,5 (5,79)	55,83 (6,76)
30	62,00 (6,19)	61,43(6,34)	57,6 (6,03)	53,37 (5,62)
60	76,70 (5,08)	73,67(5,68)	75,07 (5,26)	68,10 (5,94)
90	62,30 (7,75)	59,50 (7,08)	56,3 (7,59)	50,77 (7,59)
120	68,30 (7,18)	67,67 (7,15)	63,93 (6,02)	60,37 (6,63)

Tabela 2: Resultados da aplicação do teste t, confrontando-se cada uma das técnicas contra as demais nas diferentes bases de dados - ns: não diferem estatisticamente entre si (p>0,05) - * diferem estatisticamente entre si (p<0,05).

	RNA					RF					SVM					NB					
	0	30	60	90	120	0	30	60	90	120	0	30	60	90	120	0	30	60	90	120	
RNA	-					ns ns ns ns ns						ns * ns ns *									
RF	ns ns ns ns ns					-						ns ns ns ns ns									
SVM	ns * ns ns *					ns ns ns ns						-									
NB	* * * * *					* * * * *						* * * * ns									

Os Quadros 1, 2, 3, 4 e 5 ilustram as matrizes de confusão dos resultados de classificação nas épocas 0, 30, 60, 90 e 120, respectivamente. A matriz de confusão quantifica quantos exemplos da base de dados utilizada foram classificados corretamente pelo modelo construído (representado na diagonal principal) e quantos foram classificados de maneira incorreta (fora da diagonal principal). Cada linha representa o resultado para cada uma das classes (MITCHELL, 1997). A soma dos valores

da diagonal principal é o acerto do modelo gerado e, por sua vez, a soma dos outros valores fora da diagonal principal é o erro.

No Quadro 1, pode-se observar pelos resultados da matriz de confusão que variação nutricional Comp confundiu 46,6,3% com a Solo, o que pode ser explicado pela semelhança na coloração das folhas entre esses tratamentos que estavam adequadamente nutridos, seja pelo fornecimento de nutrientes via solução nutritiva, seja pelo solo.

A variação nutricional Solo apresentou 100% de suas amostras classificadas corretamente, podendo ser explicado por ser o único tratamento cultivado nesta situação e, assim, distinguir-se dos demais, visto o exclusivo e único balanço de cargas iônicas que apresenta. A classe -N apresentou 78,3% de acerto, sugerindo-se sinais de deficiência nas folhas, confundindo com Solo, -P, -K. Essa alta porcentagem de acurácia em nitrogênio pode ser explicada pela alta demanda para o crescimento e desenvolvimento das mudas e, dessa maneira, a falta do nutriente em questão causam sintomas de deficiência bem expressivos. A classe -P apresentou 65% de acerto, confundindo com todos os outros tratamentos. Já a variação -K, apresentou o menor acerto dentro os tratamentos induzidos à deficiência, com apenas 56,6%, confundindo com os demais tratamentos.

Quadro 1: Matriz de confusão do resultado de classificação do experimento na época 0, para os conjuntos de teste.

Destino Origem	Comp	Solo	N	P	K	Total
Comp	20 (33,4%)	28 (46,6%)	1 (1,7%)	5 (8,3%)	6 (10%)	60
Solo	0	60 (100%)	0	0	0	60
-N	0	1 (1,7%)	47 (78,3%)	5 (8,3%)	7 (11,7%)	60
-P	4 (6,7%)	1 (1,7%)	3 (5%)	39 (65%)	13 (21,6%)	60
-K	3 (5%)	4 (6,7%)	6 (10%)	13 (21,7%)	34 (56,6%)	60
Total	17	104	57	62	60	300

Aos 30 dias de avaliação, verifica-se pelos resultados dos conjuntos de testes, ilustrados pelo Quadro 2, que a variação nutricional Comp também se confunde com o Solo em 78,3% das avaliações, distinguindo-se somente em 18,3% das situações. Evidencia-se, assim, uma adequada nutrição entre esses dois tratamentos.

A classe Solo obteve 100% de acerto (Quadro 2), de maneira semelhante ao que aconteceu no experimento do tempo 0.

A classe -N apresentou 90% de acerto, sugere-se que isso poderia ser explicado pela severa e nítida deficiência de nitrogênio em que as folhas das plantas de bananeiras apresentaram, já em 30 dias de aplicação dos tratamentos. Esta classe se confunde apenas, em pequenas proporções, com a -P (1,7%) e de potássio (8,3%), como demonstrado no Quadro 2. Por sua vez, a classe -P apresentou 71,7% de acerto em suas amostras, devido ao aparecimento de sintomas de deficiências desse nutriente, confundindo-se com o Solo (20,0%) e com a -K (8,3%).

Sigmae, Alfenas, v.8, n.2, p. 704-715, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).

18º Simpósio de Estatística Aplicada à Experimentação Agronômica (SEAGRO).

A classe - K não apresentou sintomas de deficiências característicos nas imagens, com uma acurácia de apenas 30% de acerto. No experimento rodado para a época 30, houve um erro de 38%, o que corresponde 114 imagens e o acerto foi de 62%, representada por 186 imagens.

Quadro 2: Matriz de confusão do resultado de classificação do experimento no tempo 30, para os conjuntos de teste.

Destino Origem	Comp	Solo	N	P	K	Total
Comp	11 (18,3%)	47 (78,3%)	1 (1,7%)	1 (1,7%)	1 (1,7%)	60
Solo	0	60 (100%)	0	0	0	60
-N	0	0	54 (78,3%)	1 (1,7%)	5 (8,3%)	60
-P	0	12 (20%)	0	43 (71,7%)	5 (8,3%)	60
-K	1 (1,7%)	28 (46,7%)	2 (3,3%)	11 (18,3%)	18 (30%)	60
Total	17	147	6	56	29	300

A classe Comp, no experimento rodado para o tempo 60, ainda se confunde com o tratamento Solo em 50%, como evidenciado nos resultados com as bases de dados das épocas 0 e 30 dias. Não encontra-se a mesma taxa de acerto na classe Solo, nesta época em relação às épocas anteriores, confundindo-se com as classes Comp, -P e -K. A classe -N apresentou 96,6% de acerto, mostrando-se ser nítido o aparecimento dessa deficiência nas folhas de bananeira nesta época. A classe -P também mostrou nitidamente a deficiência desse nutriente nas folhas, com 83,3% das imagens classificadas corretamente com a deficiência de fósforo. O tratamento omissão de potássio, aos 60 dias, começou a mostrar a deficiência, com 85% das imagens classificadas corretamente com a falta de potássio (Quadro 3).

Quadro 3: Matriz de confusão do resultado de classificação do experimento no tempo 60, para os conjuntos de teste.

Destino Origem	Comp	Solo	N	P	K	Total
Comp	28 (46,6%)	30 (50%)	0	1 (1,7%)	1 (1,7%)	60
Solo	15 (25%)	43 (71,6%)	0	1 (1,7%)	1 (1,7%)	60
N	0	1 (1,7%)	58 (96,6%)	1 (1,7%)	0	60
P	0	3 (5%)	1 (1,7%)	50 (83,3%)	6 (10%)	60
K	1 (1,7%)	7 (11,6%)	0	1 (1,7%)	51 (85%)	60
Total	44	44	59	54	59	300

Sigmae, Alfenas, v.8, n.2, p. 704-715, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).

18º Simpósio de Estatística Aplicada à Experimentação Agronômica (SEAGRO).

O erro nessa época foi de 23,3%, representado por 70 imagens, enquanto que o acerto foi de 76,7%, ou seja, 230 imagens foram classificadas corretamente. Verificam-se que os erros dos classificadores, no decorrer das épocas de coleta das folhas, foram diminuindo, justificado, talvez, pela evidência na indução das deficiências em cada tratamento, ocasionado pela diluição do conteúdo dos nutrientes na massa da matéria seca, em relação ao desenvolvimento das plantas, mesmo que não a contento, como ocorreram com as classes Comp e Solo (Quadro 3).

Para a base de dados da época 90 dias, a classe Comp apresentou 35% de acerto e também confundiu-se com a classe Solo (61,7%), de maneira semelhante com o que ocorreu nos tempos anteriores (Quadro 4). A classe Solo apresentou 76,6% de acertos, confundindo-se com a Completa, -P e -K. Já a classe -N, apresentou 95% de acerto, reconhecendo bem essa deficiência nas folhas. As classes -P e -K, nesta época 90 dias, confundiram-se com todos os demais tratamentos, não sendo mais bem característico os sintomas de deficiências destas classes, apresentando 56,7% e 48,3% de acerto, respectivamente (Quadro 4). O erro neste tempo foi superior, igual a 37,7%, representado por 113 imagens, enquanto que o acerto foi de 62,3%, resultando em 187 imagens. O aumento do erro pode ser explicado pela confusão dos sintomas de deficiência de potássio e fósforo, como pode ser visto no Quadro 4.

Quadro 4: Matriz de confusão do resultado de classificação do experimento no tempo 90, para os conjuntos de teste.

Destino Origem	Comp	Solo	-N	-P	-K	Total
Comp	21 (35%)	37 (61,7%)	0	2 (3,3%)	0	60
Solo	12 (20%)	46 (76,6%)	0	1 (1,7%)	1 (1,7%)	60
-N	0	0	57 (95%)	2 (3,3%)	1 (1,7%)	60
-P	2 (3,3%)	17 (28,4%)	2 (3,3%)	34 (56,7%)	5 (8,3%)	60
-K	3 (5%)	23 (38,3%)	1 (1,7%)	4 (6,7%)	29 (48,3%)	60
Total	38	123	60	43	36	300

Por último, para a base de dados 120 dias, a classe Comp apresentou 98,3% de acerto, confundindo-se com a Solo em apenas 1,7%, o que não ocorreu durante todas as outras. Isto deve-se, muito provavelmente, por destacar-se no acúmulo de massa de matéria seca nas folhas. Porém, a classe Solo que nas épocas 0 e 30 dias, apresentou uma taxa de 100% de acerto, aos 120 dias possui apenas 35% de acerto, confundindo-se com a completa em 61,7%. A classe -N continua com os sintomas de deficiência característicos, apresentando 95% de acerto. A classe -P apresentou 61,7% de acerto, confundindo-se com os demais tratamentos. O mesmo ocorreu com a -K, na qual acertou 51,7% (Quadro 5). O erro apresentado nessa época foi de 31,7%, representando 95 amostras e acertou 68,3%, que são 205.

O erro médio entre todos os tempos foi de 32,80%, e a acurácia média, ou seja a taxa de acerto médio nos conjuntos de teste entre todas as bases de dados foi de 66,53%.

Quadro 5: Matriz de confusão do resultado de classificação do experimento no tempo 120, para os conjuntos de teste.

Destino Origem	Comp	Solo	-N	-P	-K	Total
Comp	59 (98,3%)	1 (1,7%)	0	0	0	60
Solo	37 (61,7%)	21 (35%)	0	2 (3,3%)	0	60
-N	0	0	57 (95%)	2 (3,3%)	1 (1,7%)	60
-P	8 (13,3%)	3 (5%)	1 (1,7%)	37 (61,7%)	11 (18,3%)	60
-K	21 (35%)	0	0	8 (13,3%)	31 (51,7%)	60
Total	125	25	58	49	43	300

Considerando-se que Sensibilidade é a capacidade que o teste de diagnóstico apresenta de detectar os indivíduos verdadeiramente positivos, ou seja, de diagnosticar corretamente com deficiência; e Especificidade é a capacidade que o teste diagnóstico tem de detectar os verdadeiros negativos, isto é, de diagnosticar corretamente os indivíduos sem deficiência (FACELLI et al., 2011), foram aplicados os testes de diagnósticos para demonstrar as sensibilidades e as especificidades dos classificadores.

Para o teste de diagnóstico, as classes foram separadas em dois grupos, um com deficiência, que agrupou as classes -N, -P e -K e, outro grupo, sem deficiência composto pelas classes Comp e Solo.

A Tabela 3 apresenta os valores de sensibilidades e especificidades calculadas. Pode-se observar que, os valores de especificidades são maiores nas épocas 30, 60, 90 e 120 dias e, apenas na época 0, a sensibilidade apresenta-se maior valor. Esses valores foram comparados com a utilização do teste t, havendo diferença significativa entre eles ($p < 0,01$), demonstrando que os classificadores são mais específicos do que sensíveis, isto é, detecta mais corretamente os indivíduos sem deficiência. Mas, de qualquer maneira, tanto pelos valores de especificidades, quanto os de sensibilidade (Tabela 3), evidencia-se um bom desempenho encontrado nos modelos gerados.

Tabela 3: Sensibilidade e especificidade dos tratamentos durante as épocas do experimento.

Causas	0	30	60	90	120
Sensibilidade	93%	77%	93%	75%	82%
Especificidade	90%	98%	97%	97%	98%

Conclusões

Os classificadores com maiores taxas de acurácia foram gerados pela técnica de RNA, seguidos de RF, SVM e NB.

Os classificadores baseados em RNA apresentam uma baixa discriminação entre as classes Comp e Solo.

A classe -N apresentou alta taxa de acerto nos modelos de classificação, praticamente, para todas as épocas estudadas.

As classes -P e -K foram melhores discriminadas na época 60 dias.

Os modelos de classificação gerados mostraram-se mais específicos que sensíveis.

Sigmae, Alfenas, v.8, n.2, p. 704-715, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).

18º Simpósio de Estatística Aplicada à Experimentação Agrônoma (SEAGRO).

Evidencia-se um bom desempenho encontrado nos modelos de classificação, tanto pela especificidade, quanto pela sensibilidade.

Referências Bibliográficas

ABRAHÃO, S. A.; PINTO, F. A. C.; QUEIROZ, D. M.; SANTOS, N. T.; CARNEIROS, J. E. S. Determination of nitrogen and chlorophyll levels in bean-plant leaves by using spectral vegetation bands and indices. *Revista Ciência Agronômica*, Fortaleza, v.44, n.3, p.464-4173, 2013.

AGRIANUAL. *Anuário da Agricultura Brasileira*. Banana. São Paulo. FNP. p.161-168. 2016.

BARANAUSKAS, J.A. *Extração automática de conhecimento por múltiplos indutores*. Tese de Doutorado. Instituto de Ciências Matemáticas e de Computação, USP, 2000.

BREIMAN, L. Random Forests. *Machine Learning*, v.45, n.2, p.5-32, 2001.

CHAUDHARY, P.; CHAUDHARI, A. K.; CHEERAN, D. A. N.; GODARA, S. Color Transform Based Approach for Disease Spot Detection on Plant Leaf. *International Journal of Computer Science and Telecommunications*. Pune, Maharashtra, India: Accenture Services Pvt. Ltd., p 65-70. 2012.

DIETTERICH, T.G. *Machine Learning Research: Four current directions*, 1997. <ftp://ftp.cs.orst.edu/pub/tgd/papers>.

DUDA, R.; HART, P.; STORK, D. *Pattern Classification*. Willey Interscience, 2002.

EFRON, B.; GONG, G. A leisurely Look at the bootstrap, the jackknife, and crossvalidation. *The American Statistician*, Washington, DC, v.37, n.1, p.36-48. 1983.

EFRON, B.; TIBSHIRANI, R. J. *An Introduction to the Bootstrap*. New York: Chapman & Hall. 436p, 1993.

FACELI, K., LORENA, A. C., GAMA, J., AND CARVALHO, A. *Inteligência Artificial: Uma abordagem de aprendizado de máquina*, LTC, 2011.

FAO. Statistics Division. *Food and Agriculture commodities production* [internet]. Roma: Fao; 2014 [acesso em 06 de nov de 2016]. Disponível em: http://faostat3.fao.org/browse/rankings/countries_by_commodity/S.

FAO. Statistics Division. *Food and Agriculture commodities production* [internet]. Roma: Fao; 2016 [acesso em 12 de fev de 2016]. Disponível em: <http://faostat3.fao.org/browse/Q/QC/E>

GELMINI, G. A. *Controle da Sigatoka Negra na Cultura da Banana: Indicações Básicas*. Campinas: Coordenadoria de Defesa Agropecuária. (Manual, 2) 32p, 2004.

Sigmae, Alfenas, v.8, n.2, p. 704-715, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).
18º Simpósio de Estatística Aplicada à Experimentação Agronômica (SEAGRO).

GONÇALVEZ, J.S.; PEREZ, L.H. *Relevância econômica da Banana em São Paulo e no Brasil*. In: NOGUEIRA, E.M.C; ALMEIDA, I.M.G; FERRARI J.T; BERIAM, L.O.S. eds. *Banicultura: manejo fitossanitário e aspectos econômicos e sociais da cultura*. São Paulo: Instituto Biológico; 2013. p03-20.

GONZALEZ, R.C.; WOODS, R.E. *Digital image processing*. 2nded. New York: Prentice Hall, 2002. 793 p.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. New York, US: MacMillan, 1999.

IBGE. Base de dados agregados [internet]. Brasília: Instituto Brasileiro de Geografia e Estatística; 2016 [acesso em 06 fev de 2016]. Disponível em: <http://www.sidra.ibge.gov.br/bda/prevsaf/default.asp>.

JOHNSON, R.A.; WICHERN, D.W. *Applied Multivariate Statistical Analysis*, 5 ed., New Jersey: Prentice-Hall, 2002, 767p.

LEE, W.S.; ALCHANATIS, V.; YANG, C.; HIRAFUJI, M.; MOSHOU, D.; LI, C.. Sensing technologies for precision specialty crop production. *Computers and Electronics in Agriculture*. 32p. 2010.

MALAVOLTA, E. *Manual de nutrição mineral de plantas*. Piracicaba: Ceres, 2006. 631p.

MITCHELL, T. M. *Machine learning*. Boston: McGraw Hill Companies Inc. 414p., 1997.

MODENESE-GORLA DA SILVA, S. H. Processamento digital de imagens para identificação da sigatoka negra em bananais utilizando análise de componentes principais e redes neurais artificiais. *Tese de Doutorado: Energia na Agricultura*, FCA, 2008. 83p.

PESTANA, M.; VARENNE, A.; FARIA, E.A. Diagnosis and correction of iron chlorosis in fruit trees: a review. *Food Agric. Environ*, 1:46-51, 2003.

VAPNIK, V. N. *The nature of statistical learning theory*. New York: Springer-Verlag, 1995.

WITTEN, I.H.; FRANK, E. *Data Mining: Practical Machine Learning Tools and Techniques, Second Edition*. Morgan Kaufmann, 2005.