

**Detecção de Giberela em Trigo
Usando Processamento Digital de
Imagens na Banda do Infravermelho
Próximo**



*Empresa Brasileira de Pesquisa Agropecuária
Embrapa Informática Agropecuária
Ministério da Agricultura, Pecuária e Abastecimento*

Boletim de Pesquisa e Desenvolvimento 37

Detecção de Giberela em Trigo Usando Processamento Digital de Imagens na Banda do Infravermelho Próximo

*Jayme Garcia Arnal Barbedo
Casiane Salete Tibola
José Mauricio Cunha Fernandes*

Embrapa Informática Agropecuária
Campinas, SP
2014

Embrapa Informática Agropecuária
Avenida André Tosello, 209 - Barão Geraldo
C. Postal 6041 - 13083-886 - Campinas, SP
Telefone: (19) 3211-5700
www.embrapa.br/informatica-agropecuaria
sac: www.embrapa.br/fale-conosco/sac/

Comitê de Publicações

Presidente: *Silvia Maria Fonseca Silveira Massruhá*

Secretária: *Carla Cristiane Osawa*

Membros: *Adhemar Zerlotini Neto, Stanley Robson de Medeiros Oliveira, Thiago Teixeira Santos, Maria Goretti Gurgel Praxedes, Adriana Farah Gonzalez, Neide Makiko Furukawa, Carla Cristiane Osawa*

Membros suplentes: *Felipe Rodrigues da Silva, José Ruy Porto de Carvalho, Eduardo Delgado Assad, Fábio César da Silva*

Supervisor editorial: *Stanley Robson de Medeiros Oliveira, Neide Makiko Furukawa*

Revisor de texto: *Adriana Farah Gonzalez*

Normalização bibliográfica: *Maria Goretti Gurgel Praxedes*

Editoração eletrônica/Capa: *Neide Makiko Furukawa*

Imagem da capa: *disponível em <<http://www.freeimages.com/>>*

1ª edição

on-line 2014

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte, constitui violação dos direitos autorais (Lei nº 9.610).

Dados Internacionais de Catalogação na Publicação (CIP)

Embrapa Informática Agropecuária

Barbedo, Jayme Garcia Arnal.

Detecção de Giberela em Trigo usando processamento digital de imagens na banda do infravermelho próximo / Jayme Garcia Arnal Barbedo, Casiane Salete Tibola, José Mauricio Cunha Fernandes. - Campinas : Embrapa Informática Agropecuária, 2014.

23 p. : il. ; 14,8 cm x 21 cm. - (Boletim de Pesquisa e desenvolvimento / Embrapa Informática Agropecuária, ISSN 1677-9266; 37).

1. Giberela. 2. Grãos de trigo. 3. Imagens hiperespectrais. 4. Processamento digital de imagens. 5. Infravermelho próximo. I. Tibola, Casiane Salete. II. Fernandes, José Mauricio Cunha. III. Embrapa Informática Agropecuária. IV. Título. V. Série.

CDD 006.6 (21.ed.)

© Embrapa 2014

Sumário

Resumo	5
Abstract	7
Introdução	8
Material e métodos	9
Resultados e discussão	14
Conclusões	17
Agradecimentos	18
Referências	18
Anexo 1 - aplicativo	21

Detecção de Giberela em Trigo Usando Processamento Digital de Imagens na Banda do Infravermelho Próximo

Jayme Garcia Arnal Barbedo¹

Casiane Salete Tibola²

José Mauricio Cunha Fernandes³

Resumo

Dentre as principais doenças que atacam o trigo, a giberela é de particular interesse. Esta doença, além de causar perdas na produção, está associada também à presença da micotoxina chamada deoxinivalenol, a qual pode causar sérios problemas de saúde em pessoas e animais.

A identificação de grãos afetados pela giberela é normalmente realizada visualmente por especialistas humanos, os quais têm como responsabilidade fornecer uma nota para o grau de contaminação dos grãos. Esse processo manual é lento, cansativo e sujeito a subjetividades inerentes a todas as atividades envolvendo percepções humanas.

Embora existam algumas iniciativas voltadas ao desenvolvimento de métodos automáticos para detecção da giberela em trigo, estes ainda possuem

¹ Engenheiro-eletricista, doutor em Engenharia Elétrica, pesquisador da Embrapa Informática Agropecuária, Campinas, SP

² Engenheira-agrônoma, doutora em Agronomia, pesquisadora da Embrapa Trigo, Passo Fundo, RS

³ Engenheiro-agrônomo, doutor em Fitopatologia, pesquisador da Embrapa Trigo, Passo Fundo, RS

limitações, e aspectos importantes relacionados à robustez de tais métodos frente às condições encontradas na prática não foram ainda suficientemente estudados.

O presente trabalho propõe um novo método para detecção da giberela em grãos de trigo, tendo como base o processamento de imagens hiperespectrais na banda do infravermelho próximo. Além disso, são fornecidas novas informações sobre os ainda pouco estudados fatores que influenciam o processo de detecção da giberela, particularmente no que diz respeito à relação entre os níveis de micotoxinas e a severidade da doença.

Termos para indexação: Giberela, grãos de trigo, imagens Hiperespectrais, processamento digital de imagens, infravermelho próximo.

Fusarium Head Blight Detection in Wheat Using Digital Image Processing in the Near-Infrared Band

Abstract

Among the main diseases that affect wheat, Fusarium Head Blight (FHB) is particularly important. This disease not only causes production losses, but is also associated to the presence of the deoxynivalenol (DON) mycotoxin, which can cause serious health problems in humans and animals.

The identification of FHB affected kernels is usually performed by human experts, which must grade the degree of contamination of the kernels. This manual process is slow, tiresome and affected by the subjectivities inherent to all activities involving human perceptions.

Although some initiatives towards the development of automatic methods for FHB detection in wheat, those are still limited, and important aspects related to the robustness of those methods under practical conditions need to be studied further.

This work proposes a new method for FHB detection in wheat kernels based on the processing of hyperspectral images in the near-infrared band. Additionally, new information about the factors that influence the FHB detection is presented, especially regarding the relationship between mycotoxin levels and the disease severity.

Index terms: Fusarium head blight, wheat kernels, hyperspectral images, digital image processing, Near-Infrared.

Introdução

O trigo é uma cultura que tem grande importância econômica e social ao redor do mundo. Como consequência, o monitoramento, a detecção e o controle de doenças são tópicos sempre presentes nas pesquisas relacionadas ao trigo. Quando a doença tem também impacto na saúde pública, como é o caso da giberela, a importância desses estudos se torna ainda maior. A giberela é causada pelo fungo patógeno *Fusarium graminearum* (*Gibberella zeae*), o qual produz uma micotoxina, chamada deoxinivalenol (DON), capaz de interromper o funcionamento normal das células pela inibição da síntese proteica (SCHMALE, 2003). Além dos potenciais danos à saúde, a giberela também causa perdas de produção: no Brasil, estudos indicaram perdas de 13,4% em 2001 (CASA et al., 2004), mas perdas de até 50% foram relatadas em países como China e Japão (LIMA; FERNANDES, 2000).

Dados os potenciais danos que podem ser causados pela giberela, grãos doentes devem ser identificados antes de serem processados e usados como alimento para pessoas e animais. Essa detecção normalmente é feita por especialistas humanos, em um processo demorado e cansativo. Além disso, a efetividade da detecção visual tende a ser prejudicada por fatores como fadiga, distrações externas e ilusões de ótica (BOCK et al., 2010).

Nesse contexto, é natural a busca por métodos automáticos capazes de fornecer uma detecção rápida e acurada. A maioria dos métodos propostos na literatura são baseados em processamento digital de imagens. Os tipos de imagens mais utilizados são a fluorescência da clorofila, a fotografia convencional na faixa visível e, principalmente, a hiperespectral na faixa do infravermelho próximo, *Near-Infrared* (NIR). Parte dos trabalhos utilizando NIR tentam fazer a detecção diretamente nas espigas do trigo (BAURIEGEL et al., 2010, 2011; DAMMER et al., 2011), enquanto outros têm os grãos como foco (DELWICHE; KIM, 2000; DELWICHE et al., 2011; MENESATTI et al., 2009; POLDER et al., 2005; SHAHIN; SYMONS, 2011; WEGULO; DOWELL, 2008).

Neste trabalho, o foco foi também a detecção da giberela em grãos de trigo individuais, usando imagens capturadas na faixa entre 528 e 1785 nm.

Apesar de os princípios usados no método proposto serem os mesmos de propostas predecessoras, este possui algumas vantagens, como: simplicidade de implementação, baixa complexidade computacional, ausência de ajustes manuais, capacidade de separação de sementes agrupadas, e disponibilidade da ferramenta no endereço⁴.

Material e métodos

Aquisição das Imagens

A aquisição das imagens hiperespectrais foi realizada na Embrapa Trigo, em Passo Fundo, RS. O espectrômetro usado no sistema (EV/NIR Hyperspec Model 1003B-10151, Headwall Photonics Inc., Fitchburg, MA, USA) emprega um sensor InGaAs com 320x256 pixels, e uma câmera XENICS (XEVA-1246 XC 134, Leuven, Bélgica). O equipamento mede a refletância das amostras na faixa de comprimentos de onda de 528-1785 nm (Visível/Infravermelho Próximo), com uma resolução espectral de 5-7 nm, resultando em 256 bandas. As imagens foram adquiridas em uma configuração linha-por-linha, sendo que 800 linhas foram escaneadas para cada amostra, com cerca de 500 dessas linhas delimitando a região de interesse onde os grãos estão localizados. O resultado final para cada amostra é uma matriz tridimensional de dimensões 320 x 800 x 256, ou seja, as imagens têm uma dimensão espacial de 320 x 800 ao longo de 256 bandas.

As sementes foram colocadas em um recipiente para evitar deslocamentos, e transportadas para uma esteira deslizante. A esteira foi controlada pelo software Hyperspec III. As imagens, capturadas à medida que as amostras se moviam pela esteira, foram pós-processadas para eliminar interferências externas e manter apenas a resposta do infravermelho próximo, usando imagens de referência brancas e escuras. Após o pós-

⁴ Disponível em: <<https://www.digipathos.cnptia.embrapa.br>>.

-processamento, os dados são representados em ponto flutuante, com precisão 32 bits.

A base de dados usada neste trabalho é composta de 27 imagens hiperespectrais (803 grãos no total). Todas as imagens contêm uma mistura das seguintes cultivares de trigo: BRS 194 (suscetível à giberela, grãos com formato arredondado); Quartzo (moderadamente suscetível à giberela, grãos com formato arredondado); BRS Parrudo e BRS 179 (ambas moderadamente resistentes à giberela, grãos com formato alongado). Apenas duas imagens foram usadas para calibrar o algoritmo, e todas as demais foram usadas nos testes cujos resultados são mostrados mais adiante.

Algoritmo

O primeiro passo do algoritmo é a determinação da região de interesse, region of interest (ROI) onde os grãos estão localizados. Foi determinado empiricamente que a reflectância na banda de 647 nm provê o melhor contraste entre a ROI e as regiões a serem descartadas. Porém, a imagem deve ser pré-processada antes de se aplicar o procedimento de limiarização. Primeiro, a fim de reduzir o impacto de pixels com valores de reflectância excessivos (devido a ruído ou reflexões especulares), todos os pixels na banda citada acima com valores acima de 2 são forçados a assumir o valor de 2 (considerando uma representação em ponto flutuante com precisão de 32 bits). A seguir, todos os valores dos pixels são divididos por 2, de tal modo que todos os valores de pixels se encontrem na faixa entre 0 e 1. Essa imagem normalizada é então limiarizada, de tal modo que todos os pixels com valores maiores que 0,25 são feitos brancos (valor 1), e todos os demais são tornados pretos (valor 0). A fim de eliminar elementos espúrios fora da ROI desejada, apenas a maior componente conectada (grupo de pixels brancos conectados) na imagem binária é mantida. Adicionalmente, a fim de remover elementos espúrios nas bordas da ROI, a imagem é morfologicamente aberta usando um disco de 5 pixels de diâmetro como elemento estruturador. A seguir, todos os buracos que porventura existam no interior da ROI são preenchidos. Por fim, a casca convexa (*convex hull*) (GRAHAM, 1972) do maior objeto é tomada como a região de interesse definitiva.

A próxima etapa do algoritmo é a segmentação da imagem em grãos e fundo. A aplicação de uma simples limiarização, em qualquer das bandas disponíveis, não é adequada porque a reflectância de cada grão pode variar significativamente devido a deformidades na superfície e reflexões especulares, e também devido ao ruído no fundo. Por esse motivo, quatro bandas foram selecionadas: 672 nm (A), 1361 nm (B), 1509 nm (C) e 1657 nm (D), com exemplos mostrados na Figura 1 (a-d). As representações na escala de cinza das reflectâncias nessas bandas foram normalizadas de acordo com o procedimento descrito anteriormente nesta seção. Então, as seguintes operações foram aplicadas:

$$dif_1 = \frac{|A - D|}{\max(|A - D|)} \quad (1)$$

$$dif_2 = \frac{|B - C|}{\max(|B - C|)} \quad (2)$$

$$ref = 0.5 \cdot (dif_1 + dif_2) \quad (3)$$

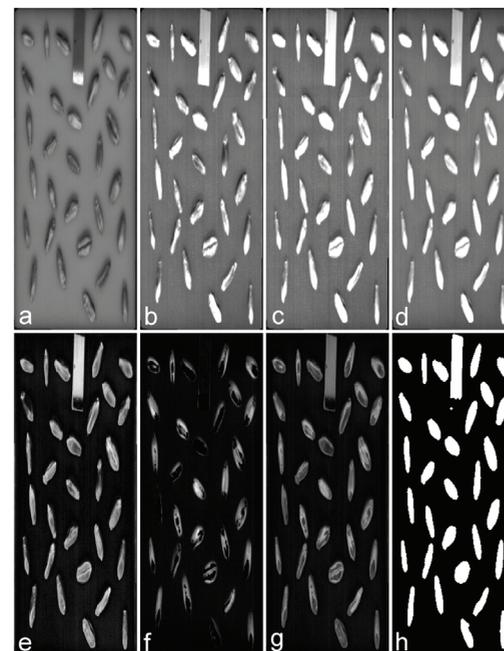


Figura 1. Separação entre grãos e fundo:

- a) Representação em escala de cinza da banda de 672 nm.
- b) Representação em escala de cinza da banda de 1361 nm.
- c) Representação em escala de cinza da banda de 1509 nm.
- d) Representação em escala de cinza da banda de 1657 nm.
- e) Diferença normalizada entre as bandas A e D.
- f) Diferença normalizada entre as bandas B e C.
- g) Combinação das diferenças normalizadas.
- h) Máscara definindo os grãos.

onde dif_1 é a diferença normalizada entre as bandas A e D (Figura 1e), dif_2 é a diferença normalizada entre as bandas B e C (Figura 1f), e ref é a combinação de ambas as diferenças normalizadas (Figura 1g). Pode ser visto que, apesar de dif_1 fornecer uma boa separação entre grãos e fundo, há algumas partes dos grãos que aparecem muito escuras, o que explica a necessidade de haver a combinação com dif_2 . Um limiar é então aplicado a ref , onde pixels com valor acima de 0,15 assumem valor 1 (branco), e todos os demais assumem valor zero (preto). A máscara dos grãos é mostrada na Figura 1h. Como se pode ver, alguns elementos espúrios ainda podem permanecer. No exemplo, dois elementos devem ser descartados: um pequeno objeto resultante de ruído na imagem, e uma escala de referência na parte superior central da ROI.

Para o descarte de objetos espúrios, duas regras são aplicadas:

- Se um objeto é menor que $0,0004 \cdot x_p \cdot y_p$ pixels, onde x_p e y_p são as dimensões espaciais da imagem em pixels, este é descartado.
- Se um objeto é maior que $0,006 \cdot x_p \cdot y_p$ pixels, e sua área dividida pela área de sua casca convexa é maior que 0,9, este é considerado um elemento espúrio (neste caso, uma escala), sendo então descartado.

Dependendo da posição dos grãos, alguns destes podem aparecer aglomerados na máscara binária (Figura 2a), o que fará com que estes sejam tratados pelo algoritmo como uma única entidade. A fim de evitar resultados incorretos, esses objetos devem ser separados. A estratégia normalmente utilizada é a aplicação de operações morfológicas como erosão, dilatação ou abertura, o que em geral causa, como efeito colateral, a de-

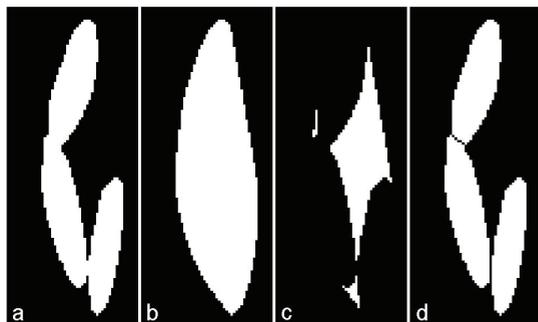


Figura 2. Passos na separação de grãos aglomerados:
a) Três grãos unidos.
b) Casca convexa para os três grãos.
c) Subtração entre a casca convexa e os três grãos unidos.
d) Três grãos separados.

formação dos objetos. Além disso, dependendo da maneira como os grãos estão dispostos, essas operações podem remover grãos inteiros antes de conseguir separá-los.

A fim de preservar as formas dos grãos, a seguinte estratégia de separação foi adotada. Quando grãos se tocam, eles normalmente geram regiões côncavas na máscara, contrastando com a convexidade quase perfeita de grãos isolados. Essas concavidades podem ser isoladas calculando a casca convexa para todos os objetos (Figura 2b), e então subtraindo o objeto original desta (Figura 2c). Apenas regiões côncavas com 10 pixels ou mais são consideradas, porque até mesmo grãos isolados podem gerar regiões côncavas devido a irregularidades e ruído. Na maioria dos casos, as linhas que conectam os pixels mais próximos de duas regiões côncavas é a que melhor separa dois grãos. A aplicação dessa ideia a aglomerados de dois grãos é simples, uma vez que apenas duas regiões côncavas serão geradas, então basta encontrar tal linha.

Quando três regiões côncavas estão presentes, como é o caso na Figura 2c, isto indica que há três grãos naquele aglomerado. A fim de determinar as linhas que melhor separam esses grãos, as distâncias mínimas entre todos os três possíveis pares de regiões são calculados. Então, as duas menores distâncias e respectivas linhas conectando pixels são usadas para separar os grãos (Figura 2d).

Quando quatro regiões côncavas estão presentes, este fato quase sempre indica a presença de três grãos (em alguns casos improváveis, quatro grãos podem estar presentes). Neste caso, a distância mínima entre todos os seis pares de regiões são calculadas. A menor dessas distâncias indica o primeiro par de regiões que será usado para separar os grãos, e as duas regiões remanescentes são usadas para gerar a outra linha de separação.

Se cinco ou mais regiões estão presentes, apenas as quatro maiores regiões são mantidas, e o procedimento descrito no item anterior é aplicado. Isto significa que o algoritmo somente será capaz de lidar corretamente com aglomerados de no máximo três grãos. É importante frisar que grandes aglomerados só existirão em situações com alta densidade de grãos, situação esta que deve ser evitada.

O uso da estratégia descrita normalmente leva a separações próximas do ideal. Porém, em alguns poucos casos, devido à posição dos grãos, pequenas porções do aglomerado podem ser atribuídas ao grão errado. Apesar de indesejável, este erro tem pouco impacto nos resultados, uma vez que este normalmente corresponde a menos de 10% da área do grão correspondente.

O último passo do algoritmo visa identificar grãos saudáveis e doentes. A banda de 1411 nm, normalizada de acordo com os procedimentos descritos anteriormente, foi a escolhida para esta tarefa. Para cada grão, a proporção de pixels com valores maiores que 0,58, chamada aqui de Índice giberela (IG), é calculada. Quanto maior essa proporção, mais provável é a infecção. A próxima seção apresenta uma discussão sobre como interpretar os resultados fornecidos pelo algoritmo.

Resultados e discussão

Todas as imagens foram manualmente anotadas e rotuladas antes do imageamento. Essa anotação, a qual é referência para todos os resultados apresentados nesta seção, está sujeita a erros provenientes de fatores como fadiga, distrações externas e ilusões de ótica, e inconsistências nas notas dadas pelos especialistas são comuns (Nutter, 1993). Portanto, essa referência não é absoluta, um fato que deve ser levado em consideração na análise dos resultados.

A Tabela 1 mostra a distribuição dos valores para grãos saudáveis e doentes. O limiar para o valor de IG é fixado em 0,5, isto é, se uma semente for considerada doente, sendo o IG correspondente maior que 0,5, o índice

Tabela 1. Resultados gerais.

	Faixa do Índice Giberela (IG) em % de ocorrências									
	0-0,1	0,1-0,2	0,2-0,3	0,3-0,4	0,4-0,5	0,5-0,6	0,6-0,7	0,7-0,8	0,8-0,9	0,9-1,0
Saudável	11	27,1	27,1	20,5	7,1	4,3	2,9	0	0	0
Doente	0	0,5	1	3,1	7,2	7,2	19,1	19,7	27,8	14,4

de acerto seria em torno de 91% em linha com outros métodos propostos na literatura. Porém, uma vez que a rotulagem de referência está também sujeita a erros, uma abordagem menos categórica e absoluta é uma melhor opção. Em outras palavras, a menos que o valor de IG seja muito próximo de zero ou um, não é possível ter 100% de certeza no diagnóstico, ou seja, na verdade o IG indica uma probabilidade, no sentido mais amplo da palavra. É importante ainda observar que as incertezas envolvidas na classificação de um único grão são maiores que na análise de conjuntos inteiros de sementes.

A Análise de Componentes Principais (Principal Component Analysis - PCA) é frequentemente utilizada para extrair informação relevante das muitas imagens presentes em uma captura hiperespectral. A fim de testar o impacto que esta técnica teria se incorporada à estratégia proposta, a banda em 1411 nm utilizada originalmente foi substituída pelos cinco principais componentes da PCA, ou seja, imagens foram geradas usando esses cinco componentes, e a média do índice giberela obtido para essas cinco imagens foi calculada. Como pode ser visto na Tabela 2, os resultados usando PCA foram quase idênticos àqueles usando a banda em 1411 nm, não havendo, portanto, ganhos com o uso de tal técnica.

Tabela 2. Resultados com a banda em 1411 nm substituída pelos primeiros cinco componentes da PCA .

	Faixa do Índice Giberela (IG) em % de ocorrências									
	0-0,1	0,1-0,2	0,2-0,3	0,3-0,4	0,4-0,5	0,5-0,6	0,6-0,7	0,7-0,8	0,8-0,9	0,9-1,0
Saudável	11,9	25,3	28,0	19,6	8,0	4,3	2,1	0,8	0	0
Doente	0	0	1,5	3,1	6,7	7,7	18,1	20,2	28,3	14,4

Dentre as principais conclusões que se pode tecer a partir dos resultados, tem-se:

- a) Valores baixos do IG para grãos doentes são mais comuns quando esses grãos são mais alongados, o que provavelmente se deve ao fato de as cultivares com grãos nesse formato serem as mais resistentes à giberela.

- b) Altos valores de IG para grãos saudáveis, por outro lado, são mais comuns em grãos com formato mais arredondado, o que é devido principalmente à maior superfície capaz de gerar reflexão especular, o que tende a inutilizar partes da imagem.
- c) Sombras geradas pelos grãos são às vezes tomadas como parte destes, ao invés de serem removidos junto com o restante do fundo, o que acaba por diminuir artificialmente o valor de GI; porém, como o procedimento de segmentação adotado aqui é robusto, apenas pequenas porções das sombras podem às vezes ser consideradas.
- d) Não houve diferença significativa nos resultados obtidos com as sementes aglomeradas sendo separadas automaticamente e manualmente, revelando que os poucos eventuais erros que ocorrem na separação adotada têm pouco impacto no desempenho do método.

Foi também investigado se o algoritmo é capaz de estimar a concentração de DON em grãos de trigo. Seis imagens foram utilizadas, cada qual contendo cerca de 50 grãos com aproximadamente os mesmos níveis de concentração da toxina, como mostrado na Tabela 3. Infelizmente, apenas a concentração média por imagem estava disponível, de modo que não foi possível realizar uma análise considerando cada grão individualmente. A Figura 3 ilustra os resultados, onde a linha indica uma relação perfeitamente linear hipotética entre concentrações de DON e IG (a linha aparece curva devido à escala logarítmica utilizada), os círculos indicam os valores de IG médios para cada uma das imagens, e as barras ligadas a cada círculo indicam os desvios padrões associados. Como se pode observar,

Tabela 3. Níveis de concentração de DON nas imagens utilizadas.

Nível de concentração	Concentração média de DON ($\mu\text{g}/\text{kg}$)
Level 1	<200
Level 2	499
Level 3	747
Level 4	1225
Level 5	2748
Level 6	5985

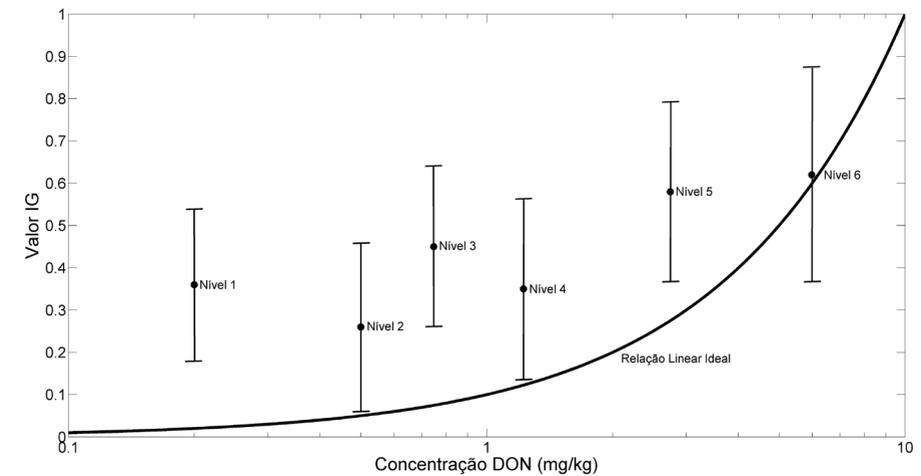


Figura 3. Correlação entre concentração de DON e valor IG.

a correlação é fraca para baixas concentrações de DON, porém aumenta consideravelmente à medida que essas concentrações aumentam. Isso ocorre porque, no caso baixas concentrações, os grãos muitas vezes ainda não apresentam sintomas visualmente detectáveis; à medida que essa concentração aumenta, os sintomas se tornam mais claros, e a correlação se estabelece. Como os casos de maior interesse que são aqueles em que as concentrações são suficientemente elevadas a ponto de causar danos à saúde, o método proposto tem potencial para estimar, ainda que de maneira aproximada, as concentrações prováveis em amostras de grãos de trigo.

Conclusões

Este trabalho apresentou um novo método para detecção da giberela em grãos de trigo, o qual tem como base a extração das informações contidas em imagens hiperespectrais capturadas na banda do infravermelho próximo. O algoritmo proposto é fácil de implementar e simples em termos computacionais, uma vez que é inteiramente baseado em operações de

morfologia matemática e regras baseadas em observação. Devido às incertezas envolvidas na própria geração das informações de referência usadas no desenvolvimento do método, o valor fornecido na saída do algoritmo, o qual foi chamado de IG, deve ser usado como um indicador da probabilidade de determinado grão estar doente, e não como uma resposta absoluta.

Testes demonstraram que o método proposto possui um desempenho comparável a outras técnicas similares, e aspectos pouco explorados na literatura foram estudados e sua influência relatada. Foi também determinado que o método é capaz de prover uma estimativa das concentrações da DON quando esta está presente em altas concentrações. Estudos futuros deverão se concentrar no aperfeiçoamento da estimação dos níveis de DON.

Agradecimentos

Os autores gostariam de agradecer o suporte financeiro fornecido pela Fapesp (Proc. 2013/06884-8) e Embrapa (SEG 03.13.00.062.00.00).

Referências

BAURIEGEL, E.; GIEBEL, A.; HERPPICH, W. B. Rapid Fusarium head blight detection on winter wheat ears using chlorophyll fluorescence imaging. **Journal of Applied Botany and Food Quality**, v. 83, n. 2, p. 196-203, 2010.

BAURIEGEL, E.; GIEBEL, A.; GEYER, M.; SCHMIDT, U.; HERPPICH, W. B. Early detection of Fusarium infection in wheat using hyper-spectral imaging. **Computer and Electronics in Agriculture**, v. 75, n. 2, p. 304-312, Feb. 2011.

BOCK, C. H.; POOLE, G. H.; PARKER, P. E.; GOTTWALD, T. R. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences**, v. 29, n. 2, p. 59-107, Mar. 2010.

CASA, R. T.; REIS, E. M.; BLUM, M. M. C.; BOGO, A.; SCHEER, O.; ZANATA, T. Danos causados pela infecção de *Gibberella zeae* em trigo. **Fitopatologia Brasileira**, v. 29, n. 3, p. 289-293, maio/jun. 2004.

DAMMER, K.-H.; MÖLLER, B.; RODEMANN, B.; HEPNER, D. Detection of head blight (*Fusarium* spp.) in winter wheat by color and multispectral image analyses. **Crop Protection**, v. 30, n. 4, p. 420-428, Apr. 2011. DOI: 10.1016/j.cropro.2010.12.015.

DELWICHE, S. R.; KIM, M. S. Hyperspectral imaging for detection of scab in wheat. In: DESHAZER, J. A.; MEYER, G. E. (Ed.). **Biological quality and precision agriculture II**. Bellingham: SPIE, 2000.p. 13-20. (SPIE proceedings series, v. 4203).

DELWICHE, S. R.; KIM, M. S.; DONG, Y. Fusarium damage assessment in wheat kernels by Vis/NIR hyperspectral imaging. **Sensing and Instrumentation for Food Quality and Safety**, v. 5, n. 2, p. 63-71, June 2011.

GRAHAM, R. L. An efficient algorithm for determining the convex hull of a finite planar set. **Information Processing Letters**, v. 1, p. 132-133, 1972.

LIMA, M. I. P. M.; FERNANDES, J. M. C. Giberela: um problema de todos. **Revista Cultivar**, v. 2, n. 20, p. 8-9, 2000.

MENESATTI, P.; ANTONUCCI, F.; COSTA, C.; SANTORI, A.; NICIARELLI, I.; INFANTINO, A. Application of morphometric image analysis system to evaluate the incidence of fusarium head blight wheat infected kernels. In: WORKSHOP COMPUTER-BILDANALYSE IN DER LANDWIRTSCHAFT, 15., 2009, Potsdam. **Image analysis for agricultural products and processes**: proceedings... Potsdam: Bornimer Agrartechnische Berichte, 2009. p. 157-161. Heft 69.

NUTTER, F. W.; GLEASON, M. L.; JENCO, J. H.; CHRISTIANS, N. C. Assessing the accuracy, intra-rater repeatability, and inter-rater reliability of disease assessment systems. **Phytopathology**, v. 83, p. 806-812, 1993.

POLDER, G.; HEIJDEN, G. W. A. M. van der; WAALWIJK, C.; YOUNG, I. T. Detection of Fusarium in single wheat kernels using spectral imaging. **Seed Science and Technology**, v. 33, n. 3, p. 655-668, Oct. 2005.

SCHMALE III, D. G.; BERGSTROM, G. C. Fusarium head blight in wheat. **The Plant Health Instructor**, 2003. DOI: 10.1094/PHI-I-2003-0612-01.

SHAHIN, M. A.; SYMONS, S. J. Detection of *Fusarium* damaged kernels in Canada Western Red Spring wheat using visible/near-infrared hyperspectral imaging and principal component analysis. **Computers and Electronics in Agriculture**, v. 75, n. 1, p. 107-112, Jan. 2011.

WEGULO, S. N.; DOWELL, F. E. Near-infrared versus visual sorting of Fusarium-damaged kernels in winter wheat. **Canadian Journal of Plant Science**, v. 88, n. 6, p. 1087-1089, Nov. 2008. DOI: 10.4141/CJPS08053.

Anexo 1 - aplicativo

Foi desenvolvido um aplicativo, com uma interface gráfica, para disponibilização na internet, no endereço⁵. Abaixo são apresentadas, de maneira breve, as principais instruções de uso.

Uma vez que o executável do programa é acionado, a primeira tela que surge para o usuário é mostrada na Figura 4.

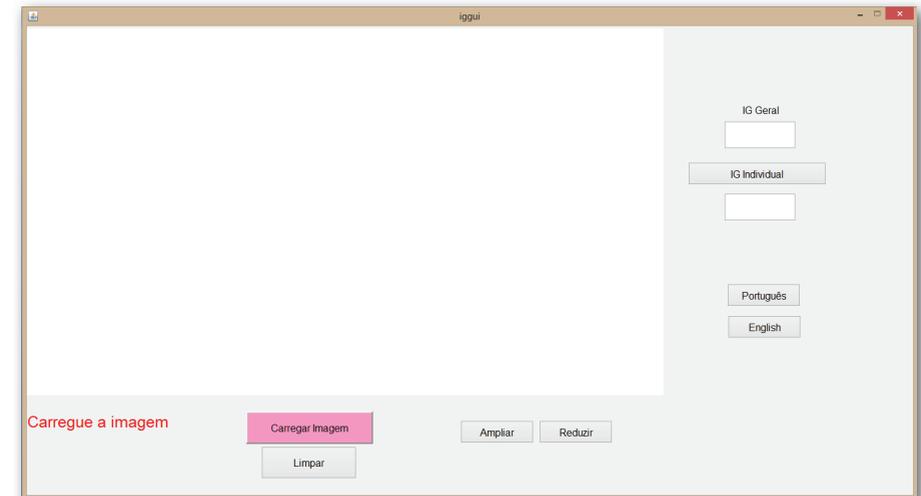


Figura 4. Tela inicial da interface.

Os botões e campos presentes na interface são os seguintes:

- Carregar imagem: abre uma interface para o usuário escolher o arquivo contendo as imagens hiperespectrais.
- Limpar: limpa todos os dados e coloca o programa em seu estado inicial.
- Ampliar: permite ao usuário ampliar partes da imagem.
- Reduzir: permite ao usuário reduzir o zoom da imagem.
- IG Geral: mostra o valor médio do “índice giberela” (IG); quanto mais próximo de 1 este valor, maior a probabilidade dos grãos estarem infectados

⁵ Disponível em: < <https://www.digipathos.cnptia.embrapa.br>>.

por giberela, e quanto mais próximo de zero, maiores as chances dos grãos estarem saudáveis.

- IG Individual: permite ao usuário visualizar os valores de IG para grãos individuais.
- Português e English: alteram a linguagem usada na interface.

A Figura 5 mostra a interface após o carregamento da imagem.

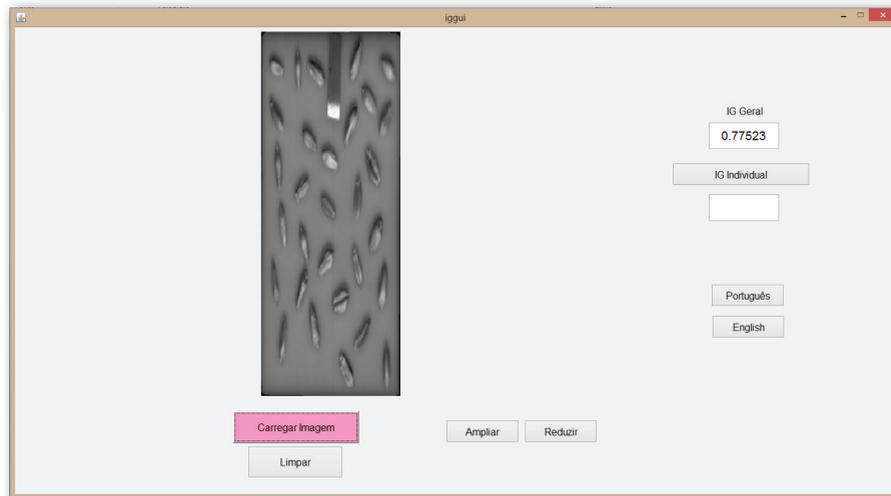


Figura 5. Tela após carregamento da imagem.

Como se pode ver, a representação em escala de cinza de uma das bandas é mostrada, e o valor IG Geral é mostrado no campo correspondente. Para visualizar o valor de IG para grãos individuais, basta clicar em IG Individual, o qual gera um cursor especial com o qual o usuário pode apontar o grão de interesse, cujo valor de IG é mostrado no campo correspondente, como mostrado na Figura 6.

O programa gera também um arquivo csv no mesmo diretório onde se encontra o executável, o qual armazena todos os valores de IG para cada um dos grãos individualmente.

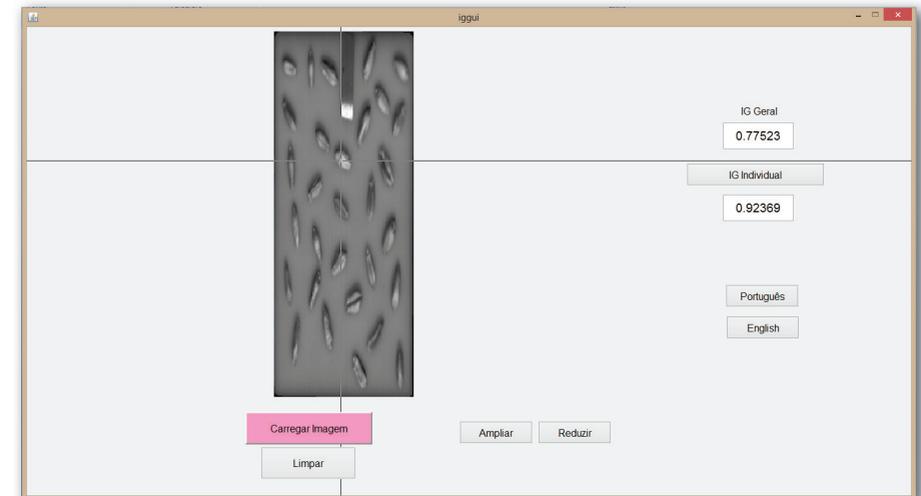


Figura 6. Visualização dos valores de IG para grãos individuais.



Informática Agropecuária

Ministério da
Agricultura, Pecuária
e Abastecimento



CGPE 11796