

# DIAGNOFOMIL: FERRAMENTA PARA DIAGNÓSTICO DE DOENÇAS FÚNGICAS EM FOLHAS DE MILHO POR MEIO DE VISÃO COMPUTACIONAL E REDES NEURAIIS

Eduardo Stahnke<sup>1</sup>, Fernando dos Santos<sup>1</sup>

<sup>1</sup>Universidade do Estado de Santa Catarina (UDESC)

Centro de Educação Superior do Alto Vale do Itajaí (CEAVI)

stahnke.eduardo@gmail.com, fernando.santos@udesc.br

## Resumo

Este trabalho apresenta o desenvolvimento de uma ferramenta para diagnóstico de doenças fúngicas em folhas de milho. A ferramenta utiliza técnicas de processamento de imagens e visão computacional para a extração das características das imagens. Para isto é utilizada a imagem referente ao plano H do modelo de cor HSV, da qual é feita a segmentação utilizando a limiarização. A partir destes segmentos são encontrados os contornos e com bases nestes contornos são calculados os momentos de Hu. Para efetuar o diagnóstico é utilizada rede neural de múltiplas camadas, e para o treinamento da rede foi adotado o método Back Propagation. A ferramenta alcançou um nível de acerto aceitável ao diagnosticar de forma correta 100% dos testes realizados com amostras da Mancha Branca, 80% da Mancha de Cercóspora e 80% de acerto no diagnóstico da Antracnose.

**Palavras-chave:** Doenças do Milho. Visão Computacional. Redes Neurais.

## Abstract

This paper presents the development of a tool for diagnosis of fungal diseases in corn leaves. The tool uses techniques of image processing and computer vision to extract the characteristics from images. These characteristics are extracted using threshold segmentation over the H plane of the image in the HSV color model, highlighting the disease spot. Given the disease spots, their Hu moments are calculated and used as inputs to a neural network. To make the diagnosis a multilayer perceptron neural network is used. Backpropagation is used for the network training. The system achieved an acceptable level of accuracy, diagnosing correctly 100% of the White Spot disease samples, 80% of the Cercospora samples and 80% of the Anthracnose samples.

**Keywords:** Corn Diseases. Computer Vision. Neural Networks.

## 1. Introdução

O milho destaca-se das demais culturas no Brasil por ser produzido em todo o território brasileiro e ocupar a maior área cultivada do país. A importância econômica deste cereal é caracterizada pelos diferentes setores onde ele é utilizado, indo desde a alimentação de animais, sendo esta a maior aplicação, até indústrias altamente tecnológicas (BORTOLINI, GHELLER; 2011).

Com esta expansão da área cultivada, a extensão da época de plantio e também o uso de cultivares precoces, tem aumentado a ocorrência de doenças foliares na cultura do milho (BORTOLINI, GHELLER; 2011). Outros fatores que podem contribuir para o aumento da incidência destas doenças são o manuseio incorreto da água e o plantio consecutivo de milho na mesma lavoura (PINTO, 2004).

Tendo em vista a grande produção deste cereal e também por ser uma cultura propícia à contaminação por doenças fúngicas, observou-se a oportunidade do desenvolvimento de uma ferramenta que auxilie no diagnóstico destas doenças. Além disto, depois de diagnosticada a doença, a ferramenta exibirá ao produtor qual o fungicida adequado para combater a doença e assim auxiliar no desenvolvimento sadio deste cereal.

A ferramenta desenvolvida faz uso de processamento digital de imagens, a fim de extrair as informações relevantes da imagem da folha. Também utiliza redes neurais, uma técnica de inteligência artificial, para fazer a classificação das folhas em um determinado grupo de doenças a partir das informações extraídas da imagem.

O trabalho se justifica pelo fato de colaborar com os produtores de milho, fornecendo a eles uma ferramenta automatizada capaz de informar qual doença afeta a plantação e apontar qual o fungicida adequado para o combate de tal doença. Esta ferramenta dará condições também aos pequenos produtores produzirem cereal de boa qualidade, evitando gastos com especialistas agrônomos e aumentando assim a lucratividade destes agricultores.

O artigo está organizado da seguinte forma. Primeiramente é apresentado o embasamento teórico referente às doenças que contaminam as plantações, estabelecendo um melhor entendimento dos sintomas e características de cada doença. Feito isto, conceitos técnicos são apresentados, esclarecendo quais métodos e técnicas serão utilizadas para o desenvolvimento do sistema. Logo após é mostrado o processo de desenvolvimento da ferramenta e por fim os trabalhos que podem ser realizados com base neste trabalho.

## **2. Fundamentação Teórica**

### **2.1 Doenças Fúngicas que Afetam o Milho**

A partir da década de 90 a produção de milho tem sofrido uma redução em termos de qualidade, devido ao aumento na frequência de doenças foliares que afetam as plantações (PINTO, 2004). A seguir são apresentadas algumas das doenças que causam tais danos nas produções.

#### **2.1.1 Mancha Branca**

A mancha branca é atualmente uma das doenças que mais afetam as plantações de milho, e está presente em praticamente todas as regiões do Brasil, podendo causar perdas superiores a 60% (COSTA, CASELA, COTA; 2009).

Os principais sintomas da doença, segundo Costa, Casela e Cota (2009) são pequenas manchas circulares, aquosas e verdes claras. Mais tarde passam a ser da cor de palha, com formato circular a elíptico e medindo de 0,3 cm a 1 cm. Estas manchas iniciam se na ponta da folha e avançam para a base. Estes sintomas aparecem inicialmente nas folhas inferiores da planta, mas progridem rapidamente para as folhas superiores. A Figura 1 ilustra os sintomas descritos.



**Figura 1 – Folha contaminada com mancha branca (Costa, Casela e Cota; 2009, p. 4)**

Uma medida para o manejo da mancha branca é o plantio do milho em época adequada, optando por épocas de semeadura em que a fase de florescimento, onde a planta está mais suscetível, não coincida com as condições de tempo favoráveis a doença (COSTA, CASELA, COTA; 2009).

### 2.1.2 Mancha de Cercóspora

Segundo Costa, Casela e Cota (2009), os principais sintomas desta doença são manchas de coloração cinza de formas retangulares irregulares e lesões que se desenvolvem paralelas às nervuras, como pode ser visto na Figura 2.



Figura 2 - Folha contaminada com cercosporiose (Costa, Casela e Cota; 2009, p. 2)

Costa, Casela e Cota (2009) citam ainda que esta doença é transmitida por esporos e restos de cultura, por isto, um modo de evitar tal doença é evitar a plantação de milho em uma lavoura onde já havia milho, sendo indicada a rotação de culturas.

### 2.1.3 Antracnose

A antracnose (*Colletotrichum graminicola*), segundo Costa, Casela e Cota (2009) é uma doença foliar do milho muito difundida nas regiões produtoras do milho, que ocorre de forma grave, resultando na diminuição elevada da produção em virtude do desconhecimento dos sintomas da doença pelos técnicos.

Os sintomas desta doença são manchas elípticas e alongadas, onde sobre estas manchas formam-se inúmeros acérvulos, podendo ocasionar a queima das pontas das folhas (EMBRAPA). A figura 3 apresenta uma folha de milho contaminada por antracnose, onde a nervura central foi afetada.




Figura 3 - Folha de milho contaminada pela antracnose (Costa, Casela e Cota; 2009, p. 14)

Para o combate desta doença, a rotação de cultura é a principal medida que pode ser adotada pelos produtores, além de evitar plantios consecutivos (COSTA, CASELA, COTA; 2009).

Com estas características das doenças é possível fazer o processamento das imagens das folhas de milho, para extrair delas as informações necessárias, como o formato e dimensões para diagnosticar que doença afeta a planta.

## 2.2 Processamento de Imagem

Imagens digitais são representações de uma imagem bidimensional, limitada por um grupo de valores que representam todos os seus pontos. Segundo Conci, Azevedo e Leta (2008) a imagem digital pode ser binária, monocromática, multibanda ou colorida dependendo do teor de cada um dos pontos que a compõem e em relação a sua descrição pode ser vetorial ou matricial. Gonzales e Woods (2000) definem a imagem como sendo uma matriz onde cada célula da matriz identifica um ponto na imagem e o valor de cada célula representa o nível de cinza da imagem naquele ponto.

Segundo Marengoni e Stringhini (2009) técnicas de processamento de imagens muitas vezes precisam ser utilizadas em sistemas de visão computacional. A utilização se faz necessária para converter a imagem para um determinado formato ou ajustar seu tamanho ou mesmo para filtrar a imagem, retirando os ruídos resultantes do processo de aquisição. A Figura 4 mostra a diferença de uma imagem recém-capturada, ao lado esquerdo, e à direita, a imagem filtrada.



Figura 4 – Diferença entre as imagens antes e depois do filtro(Marengoni e Stringhini; 2009, p.4)

De acordo com Conci, Azevedo e Leta (2008), os algoritmos de processamento de imagens são eficazes em fases iniciais de aplicativos de análise de imagens. Tais algoritmos são utilizados para melhorar a imagem e ressaltar características necessárias para as próximas etapas do sistema.

## 2.3 Visão Computacional

A visão computacional é uma técnica da computação gráfica que tem por objetivo analisar e manipular uma imagem buscando extrair suas informações relevantes e classificar tais informações (CONCI, AZEVEDO, LETA; 2008).

Atualmente existem técnicas confiáveis para analisar imagens com um grau de acerto muito grande. Com os avanços nesta área é possível analisar uma imagem e acompanhar uma pessoa em movimento, mesmo havendo um fundo complexo nesta imagem. Outro fator a se destacar é a possibilidade de encontrar todas as pessoas presente em uma foto, analisando a combinação do rosto, roupas e reconhecimento do cabelo. Porém, mesmo com o progresso desta área, o anseio de ter um computador capaz de compreender uma imagem da mesma forma que uma pessoa ainda é algo distante (SZELISKI, 2010).

Em virtude do avanço da visão computacional e sua maior confiabilidade, ela está sendo utilizada em diversas aplicações. Dentre estas aplicações, segundo Szeliski (2010), pode-se citar o reconhecimento óptico de caracteres, análise de imagens médicas, segurança automobilística, sistemas de vigilância, reconhecimento biométrico, entre outras diversas aplicações.

As técnicas de visão computacional seguem tradicionalmente uma sequência de passos. A primeira etapa de um sistema de processamento de imagens é a aquisição da imagem, que

consiste na captura da imagem, sendo por scanner ou câmera digital, por exemplo. Feito isto, a restauração e o realce buscam corrigir pequenas falhas da imagem (como imagens borradas e falta de contraste) e destacar partes da imagem que são relevantes para o objetivo da análise. A próxima etapa, a segmentação, consiste em isolar áreas da imagem, e assim extrair as características necessárias. Após esta etapa, já é possível extrair os dados relevantes ao problema, como características dimensionais, as formas dos objetos segmentados na imagem e as cores. Com estas informações pode-se então classificá-las e tomar as decisões necessárias com base na saída do sistema (CONCI, AZEVEDO, LETA; 2008).

### 2.3.1 Modelo de Cor HSV

O modelo de cor HSV é caracterizado por matiz, saturação e brilho. Esta seção descreve cada um destes componentes que formam este sistema de representação de cores.

De acordo com Conci, Azevedo e Leta (2008, p.36), a matiz “determina a cor propriamente dita, definindo sua personalidade, sua identidade; está associado aos seus diferentes comprimentos de onda. É um atributo da cor que permite, por exemplo, distinguir o verde do azul ou o amarelo do vermelho”.

O outro componente deste modelo, a saturação, reflete a pureza da cor, ou seja, o quanto uma determinada cor é dissolvida na luz branca. Em virtude desta característica é possível é possível distinguir tonalidades mais escuras das mais fracas, como por exemplo, o vermelho do rosa (CONCI, AZEVEDO e LETA; 2008).

Por fim, o brilho, ou também chamado de intensidade define a proporção de luminosidade que uma superfície pode refletir ou então uma fonte luminosa de emitir. Conci, Azevedo e Leta (2008) citam que esta propriedade é fundamental para a criação de sensações espaciais por meio da cor, como distância e profundidade.

### 2.3.2 Momentos da Imagem

No campo de aplicações de visão computacional atualmente a técnica dos momentos é uma das técnicas mais utilizadas para a extração de características de uma imagem. De acordo com Chacon et al (2011) os momentos são calculados a partir de uma imagem previamente segmentada, caracterizados por valores numéricos com o objetivo de representar a distribuição dos pontos de um segmento e para isto é utilizada a fórmula:

Esta fórmula define os momentos regulares da imagem, onde  $M_{pq}$ , segundo Chacon et al (2011, p.6) “é o momento de ordem  $(p, q)$  da função intensidade  $I(x, y)$ , onde  $x$  e  $y$  representam respectivamente a largura e a altura da imagem. Uma imagem binária terá valores da função  $I(x, y)$  iguais a 0 ou 1”.

Calculados os momentos regulares da imagem, é possível extrair algumas informações relevantes para a identificação de padrões. Um exemplo disto são os momentos de ordem 0 e 1, que são utilizados para o cálculo do ponto de centro de massa do objeto utilizando a fórmula  $M_{10}/M_{00}$  para representar o ponto correspondente à coordenada X (altura) e a fórmula  $M_{01}/M_{00}$ , representando a coordenada Y (largura) (CHACON et al; 2011).

A partir dos momentos regulares, Hu, em 1962, sugeriu uma combinação destes momentos, criando os momentos de Hu. Estes momentos são definidos por sete equações e são invariantes à escala rotação e translação, resolvendo um dos principais problemas dos sistemas de reconhecimento de padrões, que a variação das características dos objetos no que diz respeito a estes atributos (CHACON et al; 2011). Uma demonstração da aplicação destes momentos invariantes pode ser vista na Figura 5.

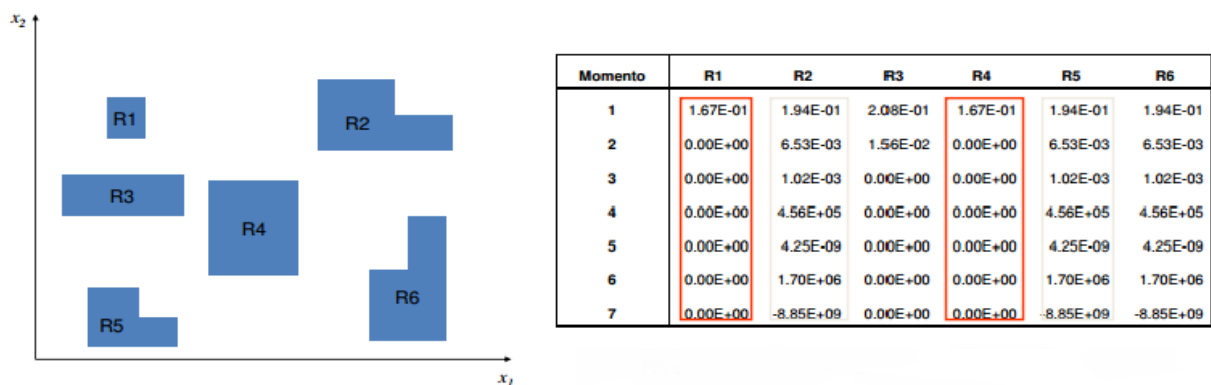


Figura 5: Demonstração dos Momentos Invariantes de Hu (CHACON et al; 2011)

Como pode ser visto na Figura 5, a imagem R1 e R4 são representações do mesmo objeto em diferentes escalas, já a imagem R6 é uma versão rotacionada de R2 e R5, e nestes casos os valores dos sete momentos de Hu são iguais entre eles.

## 2.4 Rede Neural Artificial

O cérebro humano é composto por milhões de neurônios, que são células com a função de coletar, processar e distribuir sinais elétricos. A grande capacidade de processamento do cérebro humano se dá ao conjunto destes neurônios, formando uma rede. Baseados no cérebro humano, o trabalho inicial da inteligência artificial teve como objetivo criar redes neurais artificiais, constituídas por neurônios artificiais (RUSSELL, NORVIG, 2004).

Os neurônios artificiais, também chamados de nós, são as unidades que compõem uma rede neural artificial. Estes neurônios recebem uma série de valores de entrada, juntamente com um peso, que determina a intensidade e o sinal da conexão. Cada neurônio possui uma função de ativação, que recebe a soma de todas as entradas multiplicadas pelos seus respectivos pesos, processa tais valores e gera uma saída para o neurônio.

As redes neurais são desenvolvidas semelhantemente ao cérebro humano, sendo composta por vários neurônios artificiais. Estas redes são simuladas através de programação em computadores ou com a utilização de componentes eletrônicos (HAYKIN, 2001). Podem se classificadas em três diferentes arquiteturas, porém este trabalho aborda apenas as redes de múltiplas camadas.

A arquitetura com múltiplas camadas se caracteriza pela existência de uma ou mais camadas ocultas, cuja função é interferir entre a camada de entrada e a camada de saída. Haykin (2001) cita que adicionando camadas ocultas em uma rede neural a tornamos mais capaz de obter informações relevantes. De acordo com Vahldick (2012) esta técnica da inteligência artificial se difere das outras técnicas devido a sua capacidade de aprender, onde através de algoritmos de treinamento a rede aprende a identificar e classificar os padrões.

Haykin (2001, p. 75) define a aprendizagem de redes neurais como “um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida”. O treinamento de uma rede ocorre por meio de um conjunto de normas bem definidas, o qual é chamado de algoritmo de treinamento. Existe uma série de algoritmos de treinamento, cada um oferecendo vantagens específicas e se diferenciam basicamente pela forma de como é feito o ajuste dos pesos sinápticos.

## 3. Especificação e Implementação da Ferramenta

Nesta seção serão apresentadas as técnicas utilizadas para a extração das características das imagens, o modelo de classes do sistema e quais as tecnologias, bem como as bibliotecas

utilizadas no desenvolvimento do sistema. Será apresentada também a arquitetura da rede neural juntamente com os ensaios realizados com o objetivo de obter a melhor configuração da rede.

### 3.1 Extração das Características da Imagem

Para extrair as características das imagens algumas técnicas foram utilizadas. Esta seção descreve as técnicas e quais os resultados parciais obtidos com cada técnica.

Inicialmente a imagem original é transformada de RGB para o modelo de cor HSV. Esta imagem em HSV é dividida em seus três planos de cores, separando a cor, saturação e brilho. Para este trabalho apenas foi utilizado o plano referente à cor (chamado neste trabalho de plano H), que é usado para realizar a segmentação das manchas. A Figura 6 mostra a imagem em HSV, à esquerda, e a direita a imagem representando o plano H, retirando a saturação e o brilho.




Figura 6 – Imagem em HSV (à esquerda) e a imagem no plano H (à direita) (Próprio Autor, 2013)

Continuando o processo de extração de características, a imagem referente ao plano H foi utilizada para segmentar a imagem, com objetivo de evidenciar as manchas. O resultado desta operação pode ser visto na Figura 7.



Figura 7 – Imagem segmentada (Próprio Autor, 2013)

A imagem segmentada é então utilizada para a extração dos contornos das manchas. A Figura 8 apresenta a imagem com os contornos dos segmentos encontrados.




Figura 8 – Imagem com os segmentos contornados (Próprio Autor, 2013)

Com os segmentos contornados é possível dar continuidade ao processo de extração das características. Esta imagem é utilizada para o cálculo dos momentos invariantes de Hu e também para a extração da cor no ponto central da mancha.

### 3.2 Diagrama de Classes

Para representar estruturalmente a ferramenta foi desenvolvido um diagrama de classes, separado em pacotes, onde cada pacote representa a funcionalidade das classes dentro do sistema. A Figura 9 apresenta o diagrama de classes da aplicação.

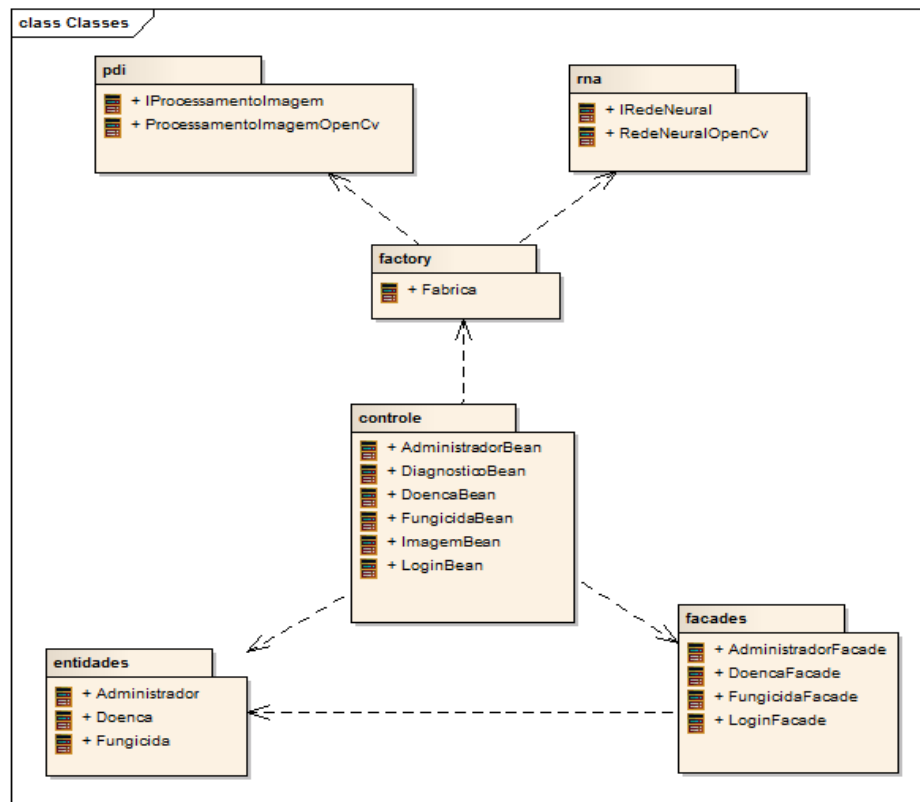


Figura 9 – Diagrama de classes (Próprio Autor, 2013)

Conforme pode ser visto no diagrama, buscou-se a independência do sistema em relação às classes de processamento de imagem e rede neural. Desta forma a aplicação se torna flexível neste ponto, e assim, caso seja alterada a tecnologia utilizada para executar estas tarefas, o funcionamento do sistema não será afetado.

### 3.3 OpenCv

Para as tarefas de processamento e análise de imagens, optou-se por usar neste trabalho a biblioteca OpenCV, que será apresentada nesta seção.

OpenCV (Open Computer Vision) é uma biblioteca liberada sob a licença BSD, sendo gratuita tanto para uso acadêmico como comercial. Tal biblioteca foi desenvolvida pela Intel, contendo mais de 500 funções, com a finalidade de tornar a visão computacional mais acessível para os usuários e desenvolvedores. De acordo com Marengoni e Stringhini (2009), esta biblioteca disponibiliza algoritmos para o reconhecimento de padrões, filtros, segmentação e manipulação de imagens além da implementação de rede neural de múltiplas camadas, incluindo as funções para seu treinamento.

A biblioteca é escrita utilizando as linguagens de programação C e C++, possuindo interfaces para programação em C, C++, Python e Java, suportando os ambientes Windows, Linux, Mac OS, iOS e Android (MARENGONI E STRINGHINI; 2009).



### 3.4 Arquitetura da Rede Neural

A camada de entrada de rede neural utilizada neste trabalho é formada por dez neurônios, onde sete correspondem aos momentos invariantes de Hu, representando a forma da mancha e os outros três à cor do ponto central da mancha. Estas estradas foram utilizadas em virtude das características das doenças, que podem ser diferenciadas pelo formato e pela cor da mancha.

Para definir a quantidade de camadas ocultas bem como a quantidade de neurônios em cada camada vários testes foram realizados, com o objetivo de obter a configuração que melhor se adaptasse ao problema de reconhecimento de doenças. Os primeiros testes foram realizados com uma camada oculta, porém não apresentaram bons resultados. Em seguida a rede foi testada com duas camadas ocultas, apresentando um desempenho aceitável, conforme pode ser visto na Tabela 1. Testes com três camadas também foram realizados e os resultados foram similares aos resultados obtidos com duas camadas, portanto não serão apresentados neste artigo.

Quantidade de Neurônios	Diagnóstico correto da Mancha Branca	Diagnóstico correto da Mancha de Cercóspora	Diagnóstico Correto da Antracnose
5,5	100%	60%	80%
5,15	100%	80%	80%
10,30	100%	60%	80%
15,50	100%	20%	100%
50,50	100%	60%	80%
10,5	100%	80%	80%
20,15	100%	80%	80%
25,20	100%	80%	80%
40,20	100%	80%	80%
40,40	100%	80%	80%

**Tabela 1 – Casos de testes e resultados com duas camadas intermediárias (Próprio Autor, 2013)**

Em alguns casos a rede neural apresentou resultados iguais com diferentes configurações. Para determinar qual a quantidade de neurônios adequada foi levada em consideração também a probabilidade da ocorrência de cada doença, apontada pela ferramenta. Desta forma, a configuração utilizada é de quarenta neurônios na primeira camada oculta e vinte na segunda camada.

Por fim a camada de saída é formada por três neurônios, onde cada um representa uma doença. O valor de cada neurônio é referente à probabilidade da planta estar contaminada com determinada doença, e assim, o maior valor indica qual a contaminação da folha.

### 4. Operacionalidade da Ferramenta

A utilização da ferramenta por parte do usuário resume-se a duas telas de maior importância. A primeira tela consiste na página de envio da imagem para o diagnóstico, onde a imagem é selecionada e então é possível recortar a imagem, com o objetivo de realizar uma pré-segmentação, excluindo partes irrelevantes da imagem. Desta forma reduz-se o tempo de processamento do sistema bem como aumenta a possibilidade de um diagnóstico correto, pois o sistema analisa apenas as áreas da imagem onde realmente existem manchas. A Figura 10 apresenta a tela do sistema para envio da imagem.

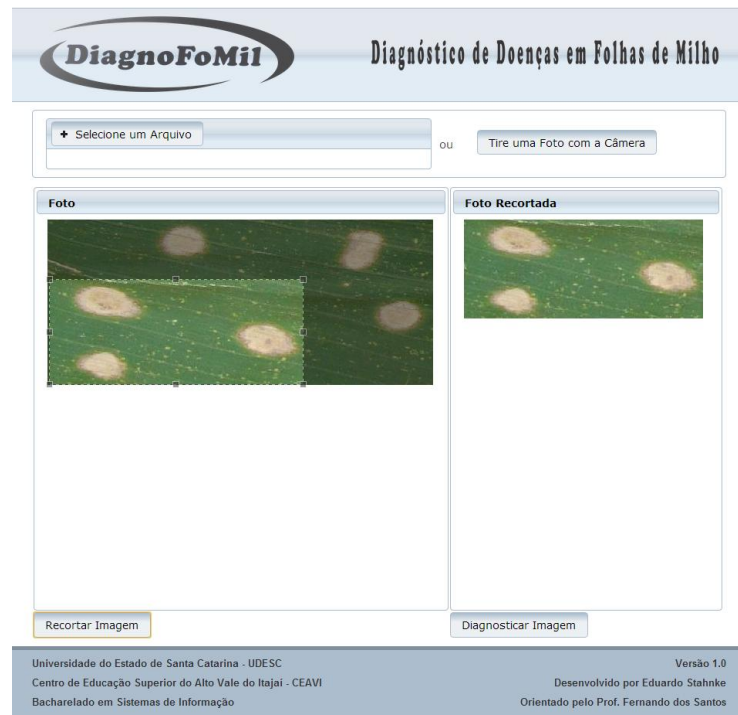


Figura 10 – Tela do sistema para envio da imagem (Próprio Autor, 2013)

Após selecionar a imagem e clicar no botão Diagnosticar Imagem, o sistema aponta qual a doença diagnosticada, apresentando informações como características da doença, algumas técnicas de manejo e lista os fungicidas que podem ser usado para seu combate. A Figura 11 mostra a tela do sistema com o diagnóstico apresentado ao usuário.



Figura 11 – Tela do sistema com o diagnóstico (Próprio Autor, 2013)

Esta tela apresenta ainda as outras possibilidades de doenças daquela planta, listadas em segundo plano. Para estas doenças o sistema mostra apenas seu nome e as características, com o objetivo de alertar o usuário para outras possíveis doenças em sua plantação.

## 5. Conclusões

Diante deste trabalho é possível notar a importância da cultura do milho atualmente para o Brasil, e é notável também a preocupação em relação às doenças fúngicas que afetam as plantações.

Dito isto, propôs-se o desenvolvimento de uma ferramenta para diagnosticar doenças fúngicas na plantação do milho. Para isto uma pesquisa foi realizada com o objetivo de levantar as características de cada doença e assim, a ferramenta, que por intermédio de visão computacional extrairá as características encontradas em uma imagem, e, com base nestas características fará uso de uma rede neural para diagnosticar a doença.

Inicialmente era previsto o diagnóstico efetivo de cinco doenças, porém com as dificuldades encontradas na extração das características, o sistema aponta o diagnóstico correto de apenas três. Isso se deve ao fato da complexidade das manchas de algumas doenças, onde inclusive a textura das manchas deveria ser analisada, fato que necessita o aprofundamento das técnicas de processamento de imagens e acarretaria na mudança da configuração de rede neural. Outro fator negativo a ser citado é a pouca quantidade de amostras levantadas das doenças, o que dificultou no treinamento da rede neural.

Mesmo com estes empecilhos, o treinamento da rede neural foi possível e a ferramenta apresenta-se confiável no diagnóstico das doenças para as quais a rede está treinada. Nos testes realizados os resultados alcançados pela ferramenta foram satisfatórios. O percentual de acerto do diagnóstico da Mancha Branca foi o maior atingido, com 100% das amostras reconhecidas. A Mancha de Cercóspora e a Antracnose foram as doenças com um percentual menor de acerto, com 80%, mas levando-se em consideração o reduzido número de amostras, é um bom resultado.

A partir desta ferramenta é possível o desenvolvimento de outros trabalhos que possam diminuir ainda mais os problemas do agronegócio. É possível aumentar o número de doenças diagnosticadas, e assim abranger uma gama maior de diagnósticos. Outro trabalho que pode ser desenvolvido considerando este como base é o desenvolvimento de uma ferramenta embarcada, a fim de possibilitar a utilização do sistema em campo, sem a necessidade de conexão com a Internet.

## Referências

BORTOLINI, Alexandre M. M. GHELLER, Jorge A. **Aplicação de Diferentes Fungicidas no Controle de Doenças Foliares na Cultura do Milho em relação à Produtividade**. 2011. Disponível em: <[http://www.fag.edu.br/novo/arquivos/revista/rbe/1-2011/Artigo\\_10\\_2011.pdf](http://www.fag.edu.br/novo/arquivos/revista/rbe/1-2011/Artigo_10_2011.pdf)>. Acesso em: 01 mar. 2012.

CHACON, Germano. ALBUQUERQUE, Marcelo de. ALBUQUERQUE, Marcio. GASTARDELLI, Elton. MORAES, Fernanda. OLIVEIRA, Gabriel. **Aplicação da Técnica de Momentos Invariantes no Reconhecimento de Padrões em Imagens Digitais**. 2011. Disponível em: <[http://cbpfindex.cbpf.br/publication\\_pdfs/nt00611.2011\\_11\\_01\\_09\\_51\\_20.pdf](http://cbpfindex.cbpf.br/publication_pdfs/nt00611.2011_11_01_09_51_20.pdf)>. Acesso em: 08 out. 2013.

CONCI, Aura. AZEVEDO, Eduardo. LETA, Fabiana R. **Computação Gráfica: Teoria e Prática**. Rio de Janeiro: Campus, 2008. 407 p. 2 v.

COPPIN, Bem. **Inteligência Artificial**. Rio de Janeiro: LTC, 2010. 636 p.

COSTA, Rodrigo V. da. CASELA, Carlos R. COTA, Luciano V. **Cultivo do Milho**. 5. ed. 2009. Disponível em: <[http://www.cnpms.embrapa.br/publicacoes/milho\\_5\\_ed/doencas.htm](http://www.cnpms.embrapa.br/publicacoes/milho_5_ed/doencas.htm)>. Acesso em: 09 abr. 2012.

GONZALES, Rafael C. WOODS, Richard E. **Processamento de Imagens**. Trad: Roberto Marcondes Cesar Junior. São Paulo: Editora Edgar Blücher LTDA. 2000. 591 p.

HAYKIN, Simon. **Redes Neurais: Princípios e Práticas**. 2. ed. Trad: Paulo Martins Engel. Porto Alegre: Bookman, 2001. 900 p.

MARENGONI, Maurício. STRINGHINI, Denise. **Tutorial: Introdução à Visão Computacional Usando OpenCv**. 2009. Disponível em: <[http://seer.ufrgs.br/rita/article/view/rita\\_v16\\_n1\\_p125](http://seer.ufrgs.br/rita/article/view/rita_v16_n1_p125)>. Acesso em: 26 jul. 2013.

PINTO, Nicésio F. J de A. **Controle Químico de Doenças Foliares em Milho**. 2004. Disponível em: <<http://rbms.cnpms.embrapa.br/index.php/ojs/article/view/96/97>>. Acesso em: 08 abr. 2012.

RUSSELL, Stuart. NORVIG, Peter. **Inteligência Artificial**. Trad: Publicare Consultoria. Rio de Janeiro: Elsevier, 2004. 1021 p.

SZELISKI, Richard. **Computer Vision: Algorithms and Applications**. Trad: Próprio Autor. 2010. Disponível em: <<http://szeliski.org/Book/>>. Acesso em: 26 jul. 2013.

VAHLDICK, Adilson. **Inteligência Artificial**. 2012. Notas de Aula.

