

DESENVOLVIMENTO DE UM PROTÓTIPO PARA IDENTIFICAÇÃO DO FUNGO ASPERGILLUS NIGER

WAGNER IGARASHI¹, FLÁVIA SHIZUE KOHIYAMA²

RESUMO:

O desenvolvimento do protótipo de sistema SeAn tem como objetivo automatizar o processo de identificação do fungo *Aspergillus niger* a partir de uma imagem digital. O protótipo se baseia na utilização de técnicas de processamento de imagens digitais e de Redes Neurais Artificiais (RNA), bem como na definição de um processo de treinamento e outro de utilização. As atividades iniciais nos dois processos são as mesmas, ou seja, as atividades de pré-processamento da imagem e de extração das características, que no processo de treinamento servem para que a rede neural aprenda; no processo de utilização servem para que a RNA treinada receba as características de novas imagens e identifique a presença do fungo *Aspergillus niger*. O treinamento da rede foi realizado pelo método *backpropagation*, utilizando 35 imagens do fungo. Na utilização da rede treinada foram utilizadas outras 35 fotos do fungo e 3 aleatórias. A validação da RNA treinada demonstrou que o protótipo aplicado pode ser utilizado para a identificação do fungo *Aspergillus niger*.

Palavras chave: SeAn, Processamento de imagens digitais, Redes neurais artificiais, *Aspergillus niger*.

PROTOTYPE DEVELOPMENT FOR ASPERGILLUS NIGER IDENTIFICATION

ABSTRACT

The development of SeAn prototype had as objective to automate the *Aspergillus niger* identification process starting from a digital image. The prototype is based on digital images processing techniques and Artificial Neural Networks(ANN), in addition it was defined a training and use process. The initial steps in the two processes are the same, witch are activities of image pre-processing and of characteristics extraction, that in training process are used for ANN learning and in the use process are used for trained ANN to classified as *Aspergillus niger* fungus. The ANN learning was accomplished by *backpropagation* method, using 35 fungus digital images. With the ANN trained was tested other 35 fungus digital

¹ Professor Adjunto do curso de Ciência da Computação, UNIOESTE, Av. Tarquinio Joslin do Santos, 1300, Foz do Iguaçu, CEP 85870-900, wigarash@gmail.com.

² Acadêmica do curso de Ciência da Computação, UNIOESTE, Av. Tarquinio Joslin do Santos, 1300, Foz do Iguaçu, CEP 85870-900, flavinha.shi@gmail.com

images and 3 aleatory digital images. The validation of ANN trained demonstrated that applied prototype can be used for *Aspergillus niger* identification.

Key-words: SeAn, Digital Image Processing, Artificial Neural Networks, *Aspergillus niger*.

1 INTRODUÇÃO

O objetivo do estudo é o desenvolvimento de um protótipo de sistema, aqui denominado SeAn, que possa automatizar o processo de identificação do fungo *Aspergillus niger* a partir de imagens digitais. O desenvolvimento deste estudo se justifica uma vez que há aproximadamente 300 espécies de *Aspergillus*, os quais são responsáveis por doenças graves que podem se instalar em pulmões, na pele por infecções cutâneas, no globo ocular e nas válvulas cardíacas (SIDRIM, ROCHA, GADELHA, 2004).

Uma infecção no pulmão, causada por *Aspergillus*, pode se agravar de tal modo que os antibióticos podem não conseguir combatê-la, levando a pessoa infectada à morte. Neste sentido, pode-se citar as mortes ocorridas pela exposição ao fungo *Aspergillus niger* na abertura da tumba do faraó Tutancâmon (ISIDRO, 2006).

Atualmente, a partir de alguns estudos e experimentos realizados pelo Laboratório Ambiental da Itaipu em animais silvestres, identificou-se a morte por infecções possivelmente causadas pelo fungo *Aspergillus niger*. A partir destes experimentos foi possível realizar o estudo da morfologia macroscópica e microscópica da colônia *Aspergillus niger*, bem como permitiu a captura de imagens digitais do fungo, as quais serviram de base para o presente estudo e desenvolvimento de um protótipo.

Como metodologia para o desenvolvimento do protótipo SeAn têm-se: o uso de imagens do fungo *Aspergillus niger* digitalizadas e disponibilizadas pelo Laboratório Ambiental da Itaipu; avaliação e uso de técnicas de processamento de imagens digitais com o propósito de melhoramento, segmentação e retirada de características; aplicação da rede neural artificial *Multilayer Perceptron*, com o objetivo de aprender as características visuais do fungo *Aspergillus niger* e com isto facilitar sua identificação em novas imagens.

2. PROCESSAMENTO DE IMAGENS DIGITAIS

Com o avanço computacional as imagens digitais podem ser facilmente manuseadas para modificação de suas cores e atributos (JÄHNE, 2002). Estas modificações permitem que certas informações sejam destacadas ou mesmo corrigidas de modo a permitir ou facilitar a visualização humana, ou ainda permitir seu reconhecimento automático.

De modo geral, o processamento de imagens digitais é definido como um processo que é composto por 5 fases: (1) aquisição de imagem digital por uma câmera ou outro dispositivo de captura; (2) pré-processamento: permite corrigir alguns tipos de defeitos e imperfeições da imagem; (3) segmentação: consiste em dividir uma imagem em suas partes constitutivas, como objetos e fundo; (4) representação e descrição: cria uma nova estrutura de dados que agrupa os resultados das etapas precedentes e armazena os padrões da imagem e outras informações que a caracterizem; (5) reconhecimento e interpretação: permite realizar a identificação e a descrição de imagens similares a partir do conhecimento *a priori* do caso e do conhecimento adquirido durante as fases precedentes (GONZALEZ; WOODS, 2002).

Além disso, o processamento de imagens digitais tem como base a estrutura de armazenamento de tais imagens, a qual se baseia em um modelo matricial. Neste modelo, uma matriz de dados ($N \times M$) é utilizada para armazenar a informação de cor referente a cada ponto da imagem, também denominado pixel (menor unidade de uma imagem que preserva suas características). (JÄHNE, 2002).

No modelo matricial há outra informação atrelada, a qual se refere ao brilho da imagem, em que os valores de $f(x,y)$ representam a intensidade de luz para cada pixel “f”, em uma dada coordenada espacial (x,y) (ACHARYA; RAY, 2008). As imagens monocromáticas, cujos valores de “f” devem ser maiores que 0 e finitas, podem ser caracterizadas ou pela intensidade da luz que incide sobre o pixel da imagem ou pela quantidade de luz que reflete.

Esses componentes são chamados de iluminância e refletância e são representados por $i(x, y)$ e $r(x, y)$. A partir da combinação destas duas funções obtém-se o produto $f(x, y)$: $f(x,y) = i(x,y) * r(x,y)$; onde $0 < i(x,y) < \infty$; e $0 < r(x,y) < 1$. (GONZALEZ; WOODS, 2002).

A inequação $0 < r(x,y) < 1$ mostra que a refletância é limitada por 0 e 1, onde 1 representa a refletância total. Os valores de $i(x, y)$ são determinados pela fonte luminosa e os de $r(x, y)$ são determinados pela refletância de luz pelos objetos presentes na cena (GONZALEZ; WOODS, 2002). Para uma imagem monocromática, a intensidade da luz em uma coordenada qualquer (x_0, y_0) será chamada de nível de cinza (ℓ) da imagem naquele ponto (GONZALEZ; WOODS, 2002); e a escala de cinza de uma imagem será o intervalo $[L_{\min}; L_{\max}]$. Este intervalo é deslocado para o intervalo $[0; L - 1]$, onde $\ell = 0$ representa a cor preta e $\ell = L - 1$ representa a cor branca. Os valores intermediários representam os diversos tons de cinza utilizados para representar uma imagem monocromática (GONZALEZ; WOODS, 2002).

Além dos elementos descritos, o histograma é uma representação gráfica que pode auxiliar os usuários na identificação de características gerais de uma imagem, como brilho e

contraste, de modo a direcionar possíveis melhorias (CONCI; LETA; AZEVEDO, 2008). O histograma de uma imagem monocromática representa a distribuição dos níveis de cinza, que podem ser representados na forma de um gráfico de barras, onde o número de pixels é representado pelo eixo Y, e cada nível de cinza é representado pelo eixo X. Assim, $f(x,y)$ é uma imagem representada por uma matriz bidimensional, com dimensões $(M \times N)$ pixels e contendo “L” níveis de cinza no intervalo $[0; L_{max}]$ (PEDRINI; SCHWARTZ, 2008).

O histograma pode ser expresso como $p_k(f) = \frac{n_k}{n} = \frac{H(k)}{MN}$ em que $H(k)$ representa o número de ocorrências do nível de cinza “k” e MN corresponde ao número total de pixels na imagem “f” (PEDRINI; SCHWARTZ, 2008). A partir do histograma de uma imagem é possível verificar se há necessidade, ou não, da aplicação de algum tipo de filtro (alteração do brilho, contraste, nitidez, etc) para melhorar a visualização dos elementos na imagem. O filtro é uma técnica de transformação aplicada pixel a pixel, levando em conta os níveis de cinza de cada pixel e também dos pixels vizinhos (CONCI; LETA; AZEVEDO, 2008).

Outra técnica relevante em relação ao processamento de imagem se refere à detecção de bordas. A borda é representada pelo limite ou pela fronteira entre duas regiões de uma imagem com propriedades relativamente distintas de níveis de cinza (PEDRINI; SCHWARTZ, 2008), ou seja, permite delinear os limites de um elemento ou objeto presente em uma imagem. De modo geral, o conceito de borda mais próximo da técnica de detecção de bordas é o cálculo de operador local diferencial (PEDRINI; SCHWARTZ, 2008); (BOAVENTURA; GONZAGA, 2007).

A borda pode ser detectada pela derivada de primeira ordem, a qual se baseia em dois métodos fundamentais. No primeiro, é aplicada a geração de gradientes no sentido horizontal e vertical, ou mesmo em dois sentidos ortogonais da imagem. O segundo envolve um conjunto de derivadas direcionais (ACHARYA; RAY, 2008).

Ressalta-se que existem vários filtros que são operadores de gradiente que podem ser utilizados, mas, no presente estudo foi selecionado o filtro *Prewitt*, por atenuar os efeitos negativos do ruído, mantendo o efeito de diferenciação e suavização da imagem (ACHARYA; RAY, 2008). O *Prewitt* calcula a gradiente da intensidade de luz em cada ponto da imagem, indicando a direção da maior variação de brilho e o nível desta variação. Como variações intensas de brilho correspondem às fronteiras bem definidas entre objetos, consegue-se fazer a detecção de contornos da imagem.

A partir do resultado de operadores de gradiente, como o *Prewitt*, em que há a melhoria da visualização dos objetos, pode-se então utilizar a técnica de limiarização

(*thresholding*), a qual consiste em separar duas ou mais regiões, por exemplo, o objeto e o fundo (CONCI; LETA; AZEVEDO, 2008). Uma forma simplificada de limiarização é o método global simples que consiste em bipartir o histograma da imagem, em que os pixels cujo tom de cinza é igual ou maior a certo valor limiar em branco e o restante em preto. A operação de limiarização pode ser definida por uma equação $g(x,y) = 1$ se $f(x,y) \geq T$; $= 0$ se $f(x,y) < T$ (PEDRINI; SCHWARTZ, 2008).

Em algumas situações é necessário realizar transformações como a rotação da imagem. Para realizar uma rotação é necessário que um ponto P, com um ângulo ϕ , em relação à origem, rotacione com um ângulo θ para um ponto P'. Assim, as coordenadas do ponto P, que antes eram definidas como $x = r * \cos(\phi)$ e $y = r * \sin(\phi)$, no ponto P' passam a ser descritas como (x', y') : $x' = r * \cos(\theta + \phi) = r * \cos\phi * \cos\theta - r * \sin\phi * \sin\theta$ e $y' = r * \sin(\theta + \phi) = r * \sin\phi * \cos\theta + r * \cos\phi * \sin\theta$.

Em relação aos elementos descritos, no presente estudo foram aplicadas as seguintes técnicas: as cores da imagem foram convertidas para tons de cinza, pois as cores originais não traziam características relevantes ao processo; o histograma foi utilizado como informação para balancear o brilho e o contraste da imagem, de modo a dar destaque aos elementos presentes na imagem; a técnica de detecção de borda (utilizando filtro *Prewitt*) e a técnica de *thresholding* serviram para segmentar os objetos presentes na imagem e extrair apenas a imagem referente ao fungo; e a rotação permitiu padronizar o posicionamento do fungo nas imagens.

Das técnicas descritas, podem-se destacar a técnicas de detecção de borda (utilizando filtro *Prewitt*) e a de *thresholding*, referentes à principal fase do processamento de imagens, que é a segmentação de regiões, a qual consiste na busca de uma determinada região ou partição de interesse. De modo geral as regiões de interesse são homogêneas e apresentam algumas características aproximadamente constantes (ANIL, 1993). Nesta etapa é possível separar os objetos e outras entidades, a partir dos quais serão extraídas as características a serem utilizadas na fase seguinte do processamento de imagens, a qual consiste em tarefas como: descrições, classificação, contagem e reconhecimento (ACHARYA; RAY, 2008).

3. MÉTODOS PARA EXTRAÇÃO DE CARACTERÍSTICAS

A extração de características se refere à extração de padrões, que possam ser utilizados de modo a reduzir a dimensionalidade das informações necessárias para o treinamento de um sistema classificador de imagens, aumentando a velocidade do

processamento e propiciando melhores taxas de aprendizado. De modo geral, as características podem ser baseadas em características visuais (forma, textura, cor, relacionamento entre objetos, etc).

Para estabelecer quais características a serem retiradas da imagem, é necessário delimitar quais são pertinentes para o reconhecimento do objeto e a exatidão com que se quer extraí-lo, estas ainda podem estar relacionadas com a localização, a existência de efeitos, se o objeto de interesse está sobreposto ou conectado, cores, dimensões e texturas da imagem (CONCI; LETA; AZEVEDO, 2008).

Como exemplo de técnica de extração de característica pode-se citar a extração de contorno, utilizando o código de cadeia de Freeman como uma forma de definir as bordas de um objeto (CONCI; LETA; AZEVEDO, 2008). Outro exemplo seria usar o sentido anti-horário e atribuir um segmento para cada par de pixels, tomando como base a vizinhança (PEDRINI; SCHWARTZ, 2008). Para a vizinhança são definidos números para as direções dependendo do método aplicado. Os números de direções servem para codificar as bordas de um objeto na imagem. Dentre as duas técnicas foi utilizado o código de cadeia de Freeman.

O uso do código de cadeia de Freeman, como pode ser observado em trabalhos como o de Pimenta (2009), permitiu extrair o contorno dos objetos presentes nas imagens e assim analisar suas características dimensionais: a área é obtida por uma contagem de todos os pixels do objeto; outras duas características poligonais que podem ser extraídas de um objeto são o diâmetro (maior distância entre dois pontos do objeto) e a excentricidade (a relação entre dois pontos a um eixo do objeto); uma quarta característica é o raio (mínimo ou máximo, e representam respectivamente a distância mínima e máxima do centro geométrico do objeto com um ponto no contorno); a última característica é o perímetro (consiste no número de pixels do contorno do objeto).

Com os elementos apresentados é possível explicitar, por exemplo, a característica de compacidade de um objeto em uma imagem, obtida pela relação entre os valores do perímetro

(P) ao quadrado e a área (A) da região: $C = \frac{P^2}{A}$ (CONCI; LETA; AZEVEDO, 2008). No caso

de uma forma circular, a compacidade é 4π , logo a característica descreve a proximidade da forma com uma circunferência. A compacidade é formada por um valor mínimo, onde o valor da compacidade mais irregular está o objeto, ou seja, menos compacto (CONCI; LETA; AZEVEDO, 2008). Esta técnica foi aplicada ao estudo, pois a cabeça do fungo é similar a uma circunferência.

As técnicas mencionadas permitiram a extração de uma série de características que

permitem definir se um determinado objeto está, ou não, presente em uma imagem. Ao se extrair as características de um conjunto de diferentes imagens de um mesmo tipo de objeto, neste caso, do fungo *Aspergillus niger*, foi possível realizar o treinamento de uma rede neural, a partir do qual se pôde realizar o aprendizado do padrão de características do fungo. Deste modo, na seção seguinte são descritos os elementos relativos à rede neural aplicada no estudo.

4. REDES NEURAIS ARTIFICIAIS

Redes neurais são modelos matemáticos baseados na simulação das funções básicas de um neurônio e suas ligações, no processo de resolução de uma determinada tarefa (NORVIG, 2004), por exemplo, o reconhecimento de padrões, como pode ser observado em trabalhos como o de Nunes (2002), Sales (2010) e Pettres (2011). Assim, as redes neurais podem ser utilizadas na solução de problemas de classificação de objetos. Neste caso, a aprendizagem da rede é utilizada para a classificação de pixels ou objetos em uma cena.

Uma rede neural pode ser formada por várias redes de neurônios interligados de modo que possam realizar a tarefa de aprendizagem (ACHARYA; RAY, 2008); (THEODORIDIS; KOUTROUMBAS; SMITH, 2003). A rede neural é composta de um conjunto de nós, chamados neurônios, ligados uns aos outros por meio de conexões (NORVIG, 2004). Cada conexão tem um peso numérico associado, o qual é o principal responsável pelo armazenamento de “longo prazo” e o aprendizado normalmente se dá pela atualização destes pesos. Alguns destes neurônios são conectados ao ambiente externo como unidades de entrada ou saída, a partir das quais a rede recebe estímulos de aprendizado para atualização dos pesos das conexões. (NORVIG, 2004).

As redes neurais podem ser caracterizadas pela sua orientação, estrutura e forma de aprendizagem. A orientação pode ser dividida em: rede sem ciclo, ou redes diretas, ou *feedforward* (NORVIG, 2004). O funcionamento destas redes consiste em neurônios, nos quais a saída parte para neurônios das camadas seguintes. Esse tipo de orientação é mais popular devido a sua simplicidade e difusão dos métodos utilizados na aprendizagem. As Redes com Ciclo, ou redes com realimentação, têm seu funcionamento constituído por neurônios de saída com ligações com neurônios de entrada.

Quanto à estrutura, as redes neurais podem ser classificadas em: (a) rede de camada única, se refere a uma estrutura em que existe uma camada intermediária entre as camadas de nós de saída e entrada; (b) rede de múltiplas camadas, a estrutura é formada por uma camada de nós de entrada, uma ou mais camadas de nós intermediários e uma camada de nós de saída; ou ainda (c) rede recorrente, a estrutura possui no mínimo um laço de alimentação e pelo

menos uma camada de nós (NORVIG, 2004).

A idéia por trás da aprendizagem das redes neurais é de que as percepções devem ser usadas não apenas para agir, mas, também para melhorar as habilidades do agente (NORVIG, 2004). A aprendizagem das redes neurais ocorre conforme a observação e a interação com o ambiente, sendo assim elas podem ser dependentes dos paradigmas de aprendizado supervisionado, aprendizado não-supervisionado e por reforço (NORVIG, 2004; CARBONELL, 1989).

No aprendizado supervisionado é fornecida a entrada e a saída correspondente. Deste modo, a rede deve ter a capacidade de monitorar o comportamento atual com os comportamentos fornecidos, e de corrigir os pesos para diminuir os erros, além de retornar o parâmetro desejado. No aprendizado não supervisionado são fornecidos os padrões de saída, porém sua base de decisão é definida pelos padrões de entrada. Devido à falta de auxílio externo, seu monitoramento é feito de maneira a definir os parâmetros por conta própria.

As redes neurais de aprendizado não supervisionado admitem variações, como, por exemplo, a existência de camadas de entrada e de saída, de conexões entre elas e conexões entre as camadas de saída. Por fim, no caso do reforço existe um avaliador crítico sobre a saída da rede, caso o avaliador verifique que o retorno foi correto, então os pesos relacionados à entrada serão reforçados, caso contrário, penalizados.

A partir da combinação das características citadas, surgiram diversos modelos de redes neurais visando a solução de problemas específicos. Sendo assim, foram pesquisados estudos similares ao presente, como os de Rumelhart, Hinton e Williams (1986), Gaspar (2006) e Poffo (2010), o que direcionou ao uso da rede *Multilayer Perceptron*, com aprendizado supervisionado empregando o algoritmo *Backpropagation*.

No caso específico do reconhecimento do fungo *Aspergillus niger*, a utilização de uma rede neural pode ser considerada válida, pelo fato da rede neural ter a capacidade intrínseca de aprender a partir de determinados padrões de entrada apresentados, sendo capaz de criar fronteiras de decisões não lineares no espaço das características. Além do que, redes neurais apresentam propriedades interessantes como: (a) várias aplicações que utilizam dados de imagens para treinamento e reconhecimento utilizam redes neurais, como verificado em trabalhos de pesquisadores como: Lucarini, Silva e Bianchi (2004), Papagianni (2006), Dobra, Cracan e Teodoru (2005), Michalopoulos e Hu (2002); (b) a capacidade de gerar regras de aprendizagem conforme o treinamento apresentado; (c) tolera um erro de resposta quando um elemento de processamento é defeituoso ou danificado, deste modo a rede distribuiu através dos pesos um resultado mais próximo do correto. Na seção seguinte será

delineado o processo de implementação do protótipo SEaN, baseado nas técnicas discutidas.

5. IMPLEMENTAÇÃO DO PROTÓTIPO SEAN

Nesta seção são apresentadas as técnicas e materiais selecionados para o desenvolvimento deste estudo, em termos da arquitetura e do funcionamento do protótipo de reconhecimento do fungo *Aspergillus niger* (SeAn), bem como a implementação da solução proposta.

5.1. ARQUITETURA PROPOSTA

A arquitetura proposta para o SeAn envolveu os seguintes elementos: (a) imagens digitais do fungo *Aspergillus niger*, disponibilizadas pelo Laboratório Ambiental da Itaipu, as quais foram obtidas por meio de um microscópio Olympus BX41 acoplado a uma câmera digital Olympus DP-12; computador, este dispositivo foi o meio utilizado para a implementação e uso do SeAn; (b) Software, este se refere à parte lógica do protótipo SeAn responsável por automatizar parte do processo; e (c) dois processos, um de treinamento e outro de utilização do SeAn.

O processo treinamento é realizado conforme as etapas de aquisição, pré-processamento, segmentação, extração de características e treinamento da rede neural. Já o processo de utilização visa identificar uma ou várias imagens (de fungos *Aspergillus niger* ou não) passando pelas etapas de aquisição, pré-processamento, segmentação, extração de características, apresentação destas à rede neural já treinada, a qual irá informar o reconhecimento positivo ou não da(s) imagem(s) como fungo *Aspergillus niger*.

Nos processos de treinamento e utilização as quatro primeiras etapas estabelecidas são as mesmas, sendo: (1) aquisição da imagem - realizada por um microscópio acoplado a uma câmera digital que irá capturar as imagens de fungos, que são armazenadas em um diretório base para a próxima etapa de processamento de imagem; (2) pré-processamento - são aplicadas as técnicas de processamento de imagem, descritas no referencial teórico, para eliminar ruídos e desníveis da imagem. Esta etapa tem como objetivo realçar as características do fungo na imagem; (3) segmentação da imagem - são extraídos apenas os segmentos da imagem referentes ao fungo, ignorando os demais elementos; (4) extração de características - nesta etapa são extraídas as características da imagem e armazenadas em um arquivo. Junto às características de cada imagem são armazenadas duas informações fornecidas pelo usuário, a cor macroscópica do fungo e uma previsão se a imagem é ou não pertencente ao fungo.

No processo de treinamento, após a extração de características, foi produzido um

arquivo em formato texto do tipo "ARFF", o qual foi carregado pelo simulador de rede neural Weka (WITTEN; FRANK, 2005). A rede foi treinada de modo a balancear os pesos das ligações dos neurônios, assim a rede pôde aprender as características do fungo, gerando um modelo de rede neural. O treinamento utilizou as configurações padrões do software Weka, como número de iterações para o aprendizado. No processo de utilização, o arquivo produzido pela etapa de extração de características é carregado e apresentado ao modelo de rede neural do Weka, gerado pelo processo de treinamento, o qual realiza a análise e retorna o valor um se a imagem foi reconhecida como fungo *Aspergillus niger*, e o valor zero caso seja outra imagem qualquer.

5.2. TÉCNICAS EMPREGADAS

Para a implementação dos processos descritos anteriormente, foram analisadas e aplicadas algumas das técnicas apresentadas nas seções anteriores, estas são apresentadas na sequência.

Para a captura das imagens foi necessária a ajuda de especialistas da área de bioquímica do Laboratório Ambiental da Itaipu para o manuseio das lâminas, de modo que estas fossem moldadas a fim de se obter um melhor posicionamento do fungo. Uma imagem considerada ideal é descrita por um fungo isolado, ou seja, sem que haja nenhuma sobreposição de outros elementos.

As lâminas com o fungo *Aspergillus niger* foram preparadas e disponibilizadas por um técnico do laboratório ambiental da Itaipu. Inicialmente as lâminas foram testadas aplicando-se várias colorações, a fim de descobrir qual daria maior destaque ao fungo nas imagens. A melhor apresentação foi obtida com a solução KOH. Ressalta-se que a imagem pode ser capturada de outras maneiras, desde que o fungo se encontre separadamente e que os ruídos do fundo da imagem não estejam conectados ao fungo.

Nos experimentos, as lentes do microscópio foram ajustadas para um aumento de 400 vezes em relação ao tamanho normal do fungo (Figura 1).



Figura 1: Imagem do fungo *Aspergillus niger* ampliado em 400 vezes.

A câmera digital acoplada ao microscópio foi ajustada para capturar as imagens a uma resolução de 2.048 x 1.536 pixels, no formato jpg, e depois redimensionadas para a resolução 400 x 300. Foram capturadas 70 imagens do fungo *Aspergillus niger*.

No pré-processamento foram aplicadas várias técnicas: (a) escala de cinza - deixa a imagem acinzentada (GONZALEZ; WOODS, 2002); (b) histograma - serve para revelar a distribuição de níveis de cinza, de modo a mostrar o limiar mais adequado para a imagem (CONCI; LETA; AZEVEDO, 2008); (c) *Prewitt* - tem como finalidade detectar as bordas utilizando o limiar do histograma (ACHARYA; RAY, 2008); (d) limiarização (*threshold*) - colore em preto e branco a imagem (CONCI; LETA; AZEVEDO, 2008); (e) média - serve para a retirada de ruídos da imagem (CONCI; LETA; AZEVEDO, 2008); (f) crescimento de regiões - é um método de segmentação de imagens em tons de cinza, que usa a variação da intensidade dos pixels e a proximidade geométrica entre eles para identificar diferentes regiões (ACHARYA; RAY, 2008), neste caso, o fungo *Aspergillus niger*.

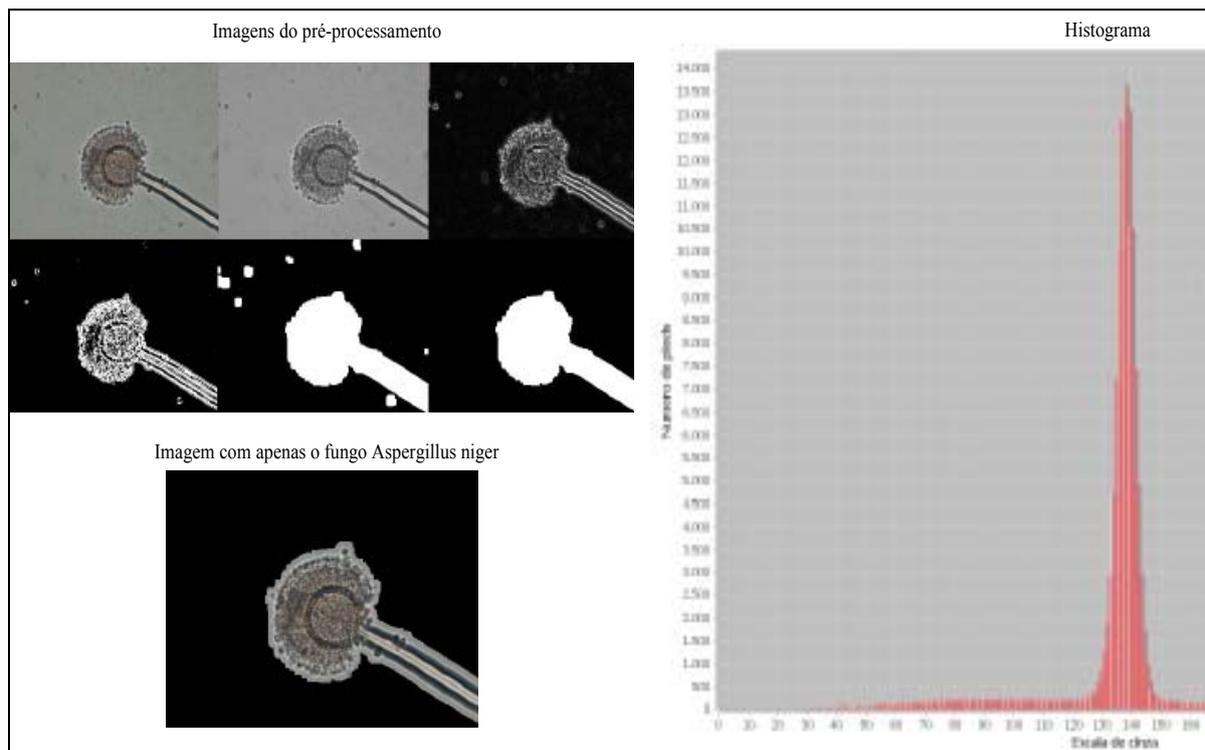


Figura 2: Processo de pré-processamento, histograma e segmentação

Na Figura 2, com a aplicação das técnicas, é possível encontrar a região de interesse na imagem. Obtida a imagem apenas com o fungo *Aspergillus niger* é possível verificar as distâncias da região central da cabeça do fungo até à extremidade direita, com a finalidade de encontrar a semicircunferência que o fungo apresenta (Figura 3).

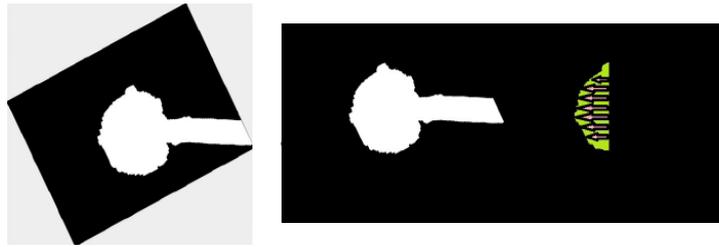


Figura 3: Dimensões do fungo

A imagem é rotacionada para a direita, de modo a posicionar a haste do fungo para o canto direito da imagem, deixando-o padronizado. Além disso, é feita uma soma em cima da imagem com um fundo preto, com a finalidade de preencher as partes que no momento da rotação ficaram vazias.

A Figura 3 apresenta a sequência dessas fases. Os motivos que levaram à mensuração destas distâncias é devido ao fungo apresentar um formato circular na região da cabeça, que varia de um fungo para outro. No caso da espécie *niger* é preciso levar em consideração a coloração da colônia, pois a espécie apresenta uma coloração escura que colônias de outras espécies não apresentam.

As distâncias obtidas da cabeça do fungo, a presença de coloração negra e a previsão se o fungo é ou não *Aspergillus niger* são armazenadas em um formato padrão de arquivo, com extensão "ARFF", necessário ao se utilizar o simulador de rede neural do Weka (WITTEN; FRANK, 2005). Gerado o arquivo, este foi passado para o software Weka, sendo selecionada a rede *Multilayer Perceptron*, utilizado o algoritmo *Backpropagation* no processo de treinamento supervisionado e as configurações padrões da rede no software Weka. A partir dos parâmetros descritos foi executado o treinamento a partir de 35 imagens do fungo, sendo possível obter um modelo de rede neural.

O modelo de rede neural resultante do Weka serve de base para o reconhecimento de imagens do fungo *Aspergillus niger*, dentro do processo de utilização do SeAn. O formato do arquivo de entrada para o processo de reconhecimento é o mesmo do arquivo para o processo de treinamento, com extensão "ARFF". Os resultados do reconhecimento são gerados na própria tela do Weka.

Para o processo de utilização do SeAn foram utilizadas outras 35 imagens do fungo *Aspergillus niger* e 3 imagens aleatórias que não são do fungo, a Figura 4 demonstra quatro tipos de imagens utilizadas: a) celular; b) pessoa; c) outro tipo de fungo; e d) fungo *Aspergillus niger* (35 imagens). As 38 imagens foram então testadas com o protótipo SeAn, o qual apresentou 100% de classificação correta.

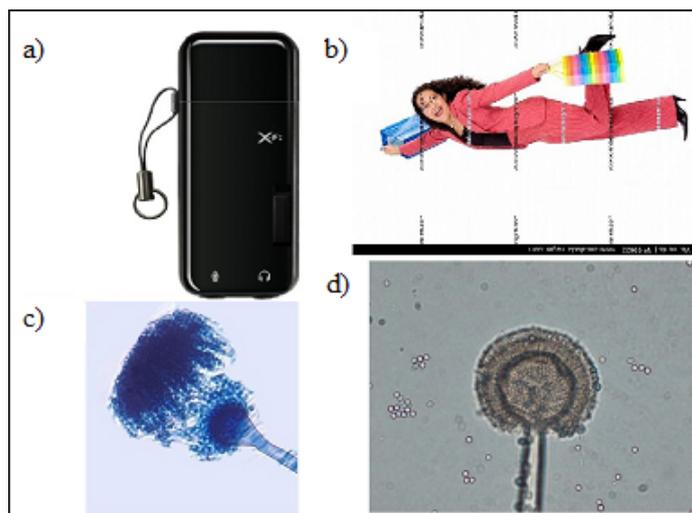


Figura 4: Imagens utilizadas para testes do SeAn

Destaca-se que estes resultados são preliminares e que há a necessidade de realização de outros experimentos. Uma vez que é necessário verificar a robustez do sistema com uma variedade maior de outros fungos que não sejam *Aspergillus niger*, bem como de experimentos na configuração de outros parâmetros da rede no processo de treinamento, como por exemplo, o número de iterações necessárias ao treinamento ou o número de camadas ocultas na rede.

6. CONSIDERAÇÕES FINAIS

O desenvolvimento do protótipo SeAn para o reconhecimento do fungo *Aspergillus niger*, abrangeu várias áreas de conhecimento distintas, como a micologia, o processamento de imagens e redes neurais, permitindo um trabalho interdisciplinar. Em relação ao processo de reconhecimento foram utilizadas as fases de aquisição das imagens, pré-processamento de imagens, representação das características, treinamento da rede neural e seu posterior uso para o reconhecimento do fungo.

Os resultados obtidos a partir da rede neural treinada foram satisfatórios, apesar de poucas características trabalhadas. Porém, ressalta-se que estes resultados são preliminares, devido à quantidade reduzida de imagens de entrada que foram utilizadas para o treinamento e para o teste da rede neural. O número reduzido de imagens foi ocasionado pelo risco de exposição ao se manusear as lâminas com exemplares do fungo, e do processo de geração de novos exemplares do fungo.

Como trabalhos futuros se propõem: a automação de alguns passos da abordagem apresentada, de modo a criar um sistema automatizado de identificação do fungo; a aplicação

de outras técnicas para extrair outras características que possam representar o fungo *Aspergillus niger*; a aplicação da abordagem apresentada aqui para o reconhecimento e classificação de outras espécies de *Aspergillus*.

REFERÊNCIAS

ACHARYA, T.; RAY, A. K. **Image Processing** - Principles and Applications. New Jersey, USA: John Willey and Sons, 2008.

ANIL, J.K. **Fundamentals of digital image processing**. New York, USA: Thomas Kailath, Series Editor, 1993.

BOAVENTURA, I. A. G.; GONZAGA, A. A border detection in digital image: An approach by fuzzy number In IEEE – **Seventh International Conference on Intelligent Systems Design and Applications**, pages 341–346, October 2007.

CARBONELL, J. G. **Introduction: Paradigms for Machine Learning**. [S.L. : s.n.], 1989. v. 40. p. 1 - 9.

CONCI, A.; LETA, F.; AZEVEDO, E. **Computação Gráfica** – Teoria e prática. Rio de Janeiro, Brasil: Campus, 2008.

DOBREA, D.M.; CRACAN, A.; TEODORU, C. Computer vision face tracking for use in a perceptual user interface. **European Medical and Biological Engineering Conference**, 2005.

GASPAR, T. L. **Reconhecimento de faces humanas usando redes neurais MLP**. Dissertação de Mestrado, USP, São Carlos, 2006.

GONZALEZ, R.C.; WOODS, R.E. **Digital Image Processing**. São Paulo: Addison-Wesley Publishing, 2002.

ISIDRO, A. Las momias: tipología, historia y patologia. Espanha, Logroño: **Revista espanhola de antropología física**, n. 26, p. 37-62, 2006. Disponível em: <http://dialnet.unirioja.es/servlet/revista?codigo=6875>. Acesso em: 14 de maio de 2009.

JÄHNE, B. **Digital Image Processing**. Alemanha, Berlin: Springer, Ed. 5, 2002.

LUCARINI, A.C.; SILVA, L.A.; BIANCHI, R.A.C. Um sistema para a contagem semi-automática de microorganismos. **Revista pesquisa e tecnologia** - FEI, São Bernardo do

Campo, v. 26, p. 36-40, 2004.

MICHALOPOULOS, D.; HU, C.H. An Error Back-Propagation Artificial Neural Networks Application in Automatic Car License Plate Recognition. **Developments in Applied Artificial Intelligence**, 2002.

NUNES, L. E. N. do P.; PRADO, P. P. L. do P. **Reconhecimento de objetos contidos em imagens através de redes neurais**. Revista de Ciências exatas, Taubaté, v. 5-8, p. 77-88, 1999-2002.

PAPAGIANNI, M. **Quantification of the fractal nature of mycelial aggregation** - In *Aspergillus niger* submerged cultures. BioMed Central Ltd., Grécia, 2006.

PEDRINI, H.; SCHWARTZ, W.R. **Análise de Imagens Digitais**. São Paulo: Thomson, 2008.

PETTRES, R. **Reconhecimento de padrões de defeitos em concreto a partir de imagens térmicas estacionárias e redes neurais artificiais**. Dissertação de mestrado - Programa de Pós-graduação em Métodos Numéricos em Engenharia, UFPR, Paraná, 2011.

PIMENTA, A. M. **Reconstrução digital de documentos mutilados usando programação dinâmica**. Dissertação de mestrado - Programa de pós-graduação em informática aplicada, PUC, Paraná, 2009.

POFFO, F. **Visual Autonomy** – protótipo para reconhecimento de placas de trânsito fernando. Trabalho de Conclusão de Curso, Universidade Regional de Blumenau, Santa Catarina, 2010.

RUMELHART, D.; HINTON, G.; WILLIAMS, R. Learning Internal Representations by Error Propagation, D. Rumelhart, J. McClelland,(Eds), **Parallel Distributed Processing: Exploration in the Micro-Structure of Cognition**, volume 1. Foundations MIT-Press, p. 318–362, 1986.

RUSSEL, S.; NORVIG, P. *Inteligência Artificial*, 2ª edição. Rio de Janeiro, Brasil: Campus, 2004.

SALES, R. B. **Localização e validação de regiões candidatas de placas a partir da análise de imagens digitais**. Dissertação de mestrado - Universidade Estadual do Ceará/Instituto Federal de Educação Ciência e Tecnologia do Ceará, Fortaleza – Ceará, 2010.

SIDRIM, J.J.C.; ROCHA, M.F.G.; GADELHA, M.F. **Micologia Médica À Luz de Autores Contemporâneos**. Rio de Janeiro: Editora Guanabara-Koogan, 2004.

THEODORIDIS, S.; KOUTROUMBAS, K; SMITH, R . **Pattern Recognition**. Elsevier, USA: Elsevier, 2003.

WITTEN, I.H.; FRANK, E. **Data Mining**: Practical Machine Learning Tools and Techniques. 2. ed. San Francisco: Morgan Kaufmann, 2005.