

Computer Vision System to Identify Impurities amongst Coffee Beans: Fuzzy and Neural Approaches

Pedro Ivo de Castro Oyama¹; Evandro Luís Linhari Rodrigues²; Lúcio André de Castro Jorge³

- 1- Mestrando, Escola de Engenharia de São Carlos - USP, São Carlos – SP, pedro.oyama@gmail.com
- 2- Professor, Escola de Engenharia de São Carlos - USP, São Carlos – SP, evandro@sc.usp.br
- 3- Pesquisador, Embrapa Instrumentação, São Carlos – SP, lucio@cnpdia.embrapa.br

Abstract — Focusing on developing an automatic method to identify impurities in samples of coffee beans using digital images, two solutions were evaluated: one using an artificial neural network and another one using a fuzzy classifier. In both cases images of samples are preprocessed in order to extract the shape features from the beans to be used as input for the system. Different parameters and topologies were tested aiming to achieve the highest accuracy with a neural network. The input variables and linguistic rules of the fuzzy classifiers were initially set statistically analysing the distribution of the features throughout the samples set. Its accuracy was further improved by an algorithm that iteratively applies small changes in the input variables to obtain better results. The best classification was reached by the neural network, with 86.6% accuracy, which can be considered a good result.

Keywords — coffee beans, classification, neural network, fuzzy, pattern recognition.

I. Introdução

O café é um importante item da balança comercial brasileira e também tem significativa importância no mercado interno, de modo que a apresentação de um produto de alta qualidade é essencial para sua comercialização nos mercados tanto interno como externo, sendo a qualidade resultado dos cuidados despendidos desde o plantio até a torrefação e moagem. E como todo produto, seu preço é diretamente relacionado a sua qualidade.

Um dos passos da análise de qualidade se dá pela identificação de defeitos e impurezas em amostras de grãos de café não-torrados, sendo as impurezas as principais responsáveis pela depreciação da qualidade da bebida final. A metodologia empregada na identificação de impurezas é muito lenta, e muitas vezes não acompanha o ritmo de produção.

Assim, este trabalho apresenta um software desenvolvido para a identificação automática de impurezas (paus e pedras), grãos quebrados e grãos perfeitos em uma amostra de grãos de café através de características morfológicas extraídas de imagens digitais. Exemplos de cada uma das classes a serem identificadas são apresentadas nas figuras 1 a 4.

Sabe-se de vários trabalhos envolvendo classificação de sementes em imagens, dos quais pode-se citar [1] e

[2], mas dificilmente se encontra publicações acerca de grãos de café. No trabalho apresentado duas abordagens foram utilizadas na resolução do problema: uma que utiliza um sistema *fuzzy* e outra que utiliza redes neurais artificiais.




Fig. 1 - Exemplos de grãos perfeitos



Fig. 2 - Exemplos de grãos quebrados



Fig. 3 - Exemplos de pedras



Fig. 4 - Exemplos de paus

Na seção II serão apresentados sucintamente fundamentos relacionados a redes neurais *Perceptron* Multicamadas e a sistemas *fuzzy*. Na seção III serão mostrados os materiais utilizados e caracterizadas as amostras utilizadas no trabalho. Na seção **Error! Reference source not found.** será apresentada a metodologia adotada, especificando a etapa de pré-processamento e a modelagem dos sistemas de classificação. Na seção V são apresentados os resultados obtidos e discutidos suas implicações. Finalmente, na seção VI serão apresentadas as conclusões deste trabalho e as possibilidades para trabalhos futuros.

II. Fundamentação Teórica

A. Perceptron Multicamadas (PMC)

Redes neurais artificiais do tipo *Perceptron* Multicamadas (PMC) são modelos computacionais inspirados no modelo biológico de interligação entre neurônios, e visam promover o aprendizado de máquina.

Elas são largamente utilizadas na classificação de padrões, ou seja, indicar a que classe pertencem os dados de entrada. As PMCs são redes neurais cujo aprendizado é supervisionado, e, portanto, antes de realizar qualquer classificação é necessário um processo de treinamento, no qual vários exemplos de dados pré-classificados são apresentados.

As PMCs são constituídas de várias camadas de neurônios artificiais, os *Perceptrons*. Há uma camada de entrada, por onde dados são inseridos, uma de saída, por onde os resultados são fornecidos, e pelo menos uma camada escondida. As saídas de neurônios de uma camada são utilizadas como entrada para os neurônios da camada posterior, de forma sucessiva até o sinal chegar à camada de saída. O número de camadas escondidas e o número de neurônios em cada uma devem ser definidos de acordo com a aplicação, e influenciam na taxa de sucesso da classificação[3].

B. Sistemas Fuzzy

Sistemas que se baseiam não na lógica clássica, a qual define a pertinência de um elemento a um conjunto com valores binários (pertence ou não pertence), mas sim na lógica *fuzzy*, que permite que um elemento tenha um grau de pertinência a um conjunto ou mais conjuntos com um valor real (entre 0 e 1). A lógica fuzzy permite se trabalhar com variáveis com valores associados a conceitos subjetivos, como “pequeno” e “grande”, por exemplo. Dessa forma, tais sistemas conseguem tratar problemas envolvendo imprecisão e subjetividade, incorporados tanto nos dados de entrada como na modelagem do problemas, de forma mais efetiva e precisa.

Os sistemas *fuzzy* utilizam regras linguísticas que mapeiam valores de variáveis de entradas a valores de variáveis de saída, e necessitam de métodos para transformar valores numéricos em variáveis *fuzzy* de entrada (fuzzificação) e para transformar variáveis *fuzzy* de saída em valores numéricos (defuzzificação). Um dos campos onde sistema *fuzzy* são amplamente utilizados com sucesso são a classificação de padrões.

III. Material

Foram montadas duas bases de imagens com amostras de grãos e impurezas previamente classificadas por especialistas. A primeira das bases, denominada “conjunto de treinamento”, é composta por 468 grãos perfeitos, 460 grãos quebrados, 248 paus e 166 pedras e foi utilizada para treinamento e definição de parâmetros. A segunda base, denominada “conjunto de testes”, é formada por 99 grãos perfeitos, 99 grãos quebrados, 99 paus e 99 pedras. Essa base foi utilizada para se aplicar os

algoritmos de classificação desenvolvidos e se avaliar suas acurácias.

A captura de imagens das amostras foi realizada por uma câmera com resolução de 1024x768 pixels, em um ambiente de luz controlada e fundo de cor preta.

IV. Metodologia

A. Pré-Processamento

A segmentação é feita por um *Thresholding*, já que o fundo das imagens é muito mais escuro que os grãos. Na imagem já binarizada é aplicado o método dos componentes conexos [4] para a individualização e rotulação dos grãos. A partir da imagem binária, um algoritmo de detecção de bordas é executado para que os objetos sejam identificados junto com seus contornos.

B. Extração de características

Com a imagem binarizada de cada grão foram extraídas as seguintes características: as variâncias de todas as assinaturas do contorno, o perímetro do objeto, sua área, seu comprimento e a sua largura.

Assinaturas são elementos de uma função 1D calculada a partir dos pontos do contorno de uma forma. Existem várias abordagens para calculá-las, como a tangente do ângulo, a área, comprimento da corda e a distância do centroide [5]. Esta última foi a utilizada neste trabalho.

Dadas as coordenadas (\bar{x}, \bar{y}) do centróide de uma figura, a i -ésima assinatura $z(i)$ é calculada pela equação (1), sendo $(x(i), y(i))$ as coordenadas do i -ésimo ponto da borda do objeto, com $i = 1, \dots, N$ e N sendo o número de pontos presentes na borda.

$$z(i) = \sqrt{(x(i) - \bar{x})^2 + (y(i) - \bar{y})^2} \quad (1)$$

Como as variâncias de assinaturas apresentam valores muito pequenos, da ordem de 10^{-2} , elas são multiplicadas por 10.000 para uma melhor visualização dos dados.

C. Classificador baseado em redes neurais

Foram testadas oito topologias de redes neurais *Perceptron* Multicamadas, variando-se o número de camadas escondidas e o número de neurônios em cada uma, segundo a TABELA I, que apresenta para cada topologia (T1-T8) o número de neurônios na primeira camada escondida (C1), o número de neurônios na segunda camada escondida (C2) e o número de neurônios na terceira camada escondida (C3). Cada uma das topologias utilizou como entrada as cinco características de um grão

ou impureza, citados na seção B, e como saída a classe do objeto (grão perfeito, grão quebrado, pau ou pedra). Todas as topologias adotaram a taxa de aprendizagem de 0,1, momento de 0,7 e 10.000 épocas como critério de parada.

TABELA I - As diferentes topologias de PMC testadas (T1 – T8), sendo C1 a primeira camada escondida; C2, a segunda; e C3, a terceira.

	T1	T2	T3	T4	T5	T6	T7	T8
C1	4	4	10	4	7	7	7	7
C2	0	2	0	3	0	2	4	4
C3	0	0	0	0	0	0	0	2

Para cada topologia foram realizados cinco treinamentos com inicializações diferentes dos pesos sinápticos. Os treinamentos foram realizados com o conjunto de amostras de treinamento, e a determinação das acúrias conseguidas por cada uma feita pela execução da classificação no conjunto de amostras de teste.

Após a determinação da melhor topologia, foram variados os seus parâmetros de treinamento na tentativa de se melhorar ainda mais a solução. As combinações de parâmetros avaliadas se encontram na TABELA II.

TABELA II - Combinações de parâmetros (P1-P5) utilizadas no treinamento das redes neurais

	P1	P2	P3	P4	P5
Taxa de aprendizado	0.001	0.1	0.01	0.001	0.01
Momento	0.7	0.7	0.7	0.9	0.7
Número de épocas (x1000)	100	50	50	100	100

D. Classificador baseado em lógica fuzzy

Dois tipos de sistema fuzzy foram adotados para efeitos de comparação: um utilizando o operador de implicação Mamdani, e outro paramétrico, utilizando o modelo Takagi-Sugeno.

O primeiro sistema utiliza o operador de composição Max-Min, operador de agregação ‘Máximo’, e o operador ‘Mínimo’ como conectivo ‘E’. Três métodos de defuzzificação foram simultaneamente adotados, para que o melhor entre eles pudesse ser eleito. Os métodos são: média da área, média dos máximos e primeiro máximo.

O sistema de Takagi-Sugeno também adota o operador ‘Mínimo’ como conectivo ‘E’, e como operação de ponderação o método da média ponderada.

Características Utilizadas:

Por questão de simplicidade e para não contar com um conjunto de regras muito extenso, decidiu-se que o sistema contaria com apenas três variáveis, com três termos cada uma. Assim sendo, descartou-se o perímetro,

pois avaliou-se que este apresenta uma correlação muito alta com a área. Foi decidido também utilizar o comprimento e a largura dos grãos como um só descritor, uma vez que para a análise que se deseja fazer, é mais interessante saber quão alongado é o objeto, ao invés de suas medidas de comprimento e largura. Para tanto, uma boa medida é utilizar a razão largura/comprimento, parâmetro este denominado aspecto.

Análise Estatística e Definição dos Parâmetros Iniciais:

Para se definir as configurações iniciais dos termos das variáveis fuzzy e quais regras lingüísticas seriam adotadas, foi analisado como os descritores de forma supracitados estão distribuídos em seu domínio, de acordo com as classes dos objetos. Foram calculados os três quartis e os valores máximos e mínimos de cada um dos descritores, para o conjunto de treinamento. O resultado é mostrado na TABELA III.

TABELA III - Divisão do conjunto de treinamento em quartis.

Atributo	Min	25%	50%	75%	Max
Variância de Assinaturas	9,65	51,09	101,71	222,58	774,81
Área	7,65	36,30	51,85	65,69	127,16
Aspecto	16,47	59,40	74,48	83,74	98,97

As variáveis de entrada do sistema fuzzy são compostas de três termos cada uma, os quais indicam os conceitos ‘pequeno’, ‘médio’ e ‘grande’. Todos os termos são representados por funções trapezoidais definidas pelos parâmetros **a**, **m**, **n** e **b**, como mostrado na Fig. 5. Estes parâmetros foram denominados neste trabalho, como vértices.




Fig. 5 - Função trapezoidal

Os vértices de cada um dos termos das variáveis foram inicialmente definidos de acordo com os valores de quartis calculados para todo o conjunto de treinamento (TABELA III). Para os termos ‘pequeno’ **a** = **m** = 0 (valor mínimo do universo de discurso), **n** = 1º quartil e **b** = 2º quartil. Para os termos ‘médio’ **a** = 1º quartil, **m** = **n** = 2º quartil e **b** = 3º quartil. Para os termos ‘grande’ **a** = 2º quartil, **m** = 3º quartil e **n** = **b** = valor máximo do universo de discurso. A Fig. 6 apresenta a configuração da variável área.




Fig. 6 - Configuração inicial da variável área

Os três quartis e os valores máximos e mínimos de cada um dos descritores, foram agora calculados sobre as amostras do conjunto de treinamento pertencentes a uma classe específica: pau, pedra, perfeito e quebrado. Comparando-se as variáveis de entrada definidas com os respectivos valores dos quartis de cada uma das classes, atribuiu-se os valores lingüísticos ‘pequeno’ (P), ‘médio’ (M) e ‘grande’(G) para se definir qualitativamente os valores dos descritores de cada uma das classes. A TABELA IV mostra o resultado desse procedimento para a classe pau.

TABELA IV - Divisão dos descritores em quartis, para ‘pau’.

Descritor	Min	25%	50%	75%	Max	Termos
Assinaturas	67,21	339,35	486,55	578,96	774,81	G
Área	18,17	41,77	52,10	62,30	127,16	P,M,G
Aspecto	16,47	31,01	39,28	49,10	85,02	P

As regras lingüísticas foram formuladas a partir da análise dos valores qualitativos associados a cada classe. Da TABELA IV, por exemplo, puderam ser extraídas as regras da TABELA V.

TABELA V - Conjunto de regras lingüísticas

Regra	Antecedentes (conectados por ‘E’)			Conseqüentes
	Assinatura	Área	Aspecto	Classe
R1	G	P	P	Pau
R2	G	M	P	Pau
R3	G	G	P	Pau

Para a variável de saída os termos foram definidos de modo que a relação entre o valor de saída e as classes fosse dada pela TABELA VI.

TABELA VI - Associação do valor de saída às possíveis classes.

	Pau	Pedra	Perfeito	Quebrado
Saída(y)	$0 \leq y < 0.25$	$0.25 \leq y < 0.50$	$0.50 \leq y < 0.75$	$0.75 \leq y \leq 1.00$

Essa configuração inicial foi utilizada para classificar o conjunto de amostras em alguns ensaios. Em cada ensaio as variáveis foram discretizadas por diferentes números de pontos. Percebeu-se que a partir de 100 pontos não havia nenhuma alteração na taxa de acerto. Portanto esse foi o número adotado.

Aperfeiçoamento do Sistema por um Processo Iterativo:

A classificação do conjunto de testes por essa primeira configuração do sistema fuzzy gerou resultados abaixo do desejado, os quais são mostrados na TABELA VII. Nela são mostradas as taxas de acerto do modelo fuzzy não-paramétrico para os métodos de defuzzificação média da área(MdA), média dos máximos(MdM) e primeiro máximo (PM). Também é mostrado o resultado para o modelo Takagi-Sugeno(TS).

TABELA VII - Taxas de acerto da configuração inicial.

	Mda	MdM	PM	TS
Taxa de acerto(%)	64,7	66,7	66,8	38,4

Para aumentar as taxas de acerto foi desenvolvido um algoritmo que iterativamente altera as posições dos vértices das funções trapézoidais dos termos das variáveis de entrada em busca de uma melhor solução. Um esboço do algoritmo para modificar um vértice para uma melhor solução é apresentado no Algoritmo 1. Em linhas gerais, ele procura soluções melhores variando a posição do vértice para a esquerda e para direita, até um certo limite determinado e retorna a melhor solução obtida.

Algoritmo 1 - ModificaVértice

Parâmetros:
 posiçãoMAX, % Valor máximo de posição que o vértice deve atingir
 posiçãoMIM, % Valor mínimo de posição que o vértice deve atingir
 taxaAcertoInicial, % Atual taxa de acerto
 posiçãoInicial, % Atual posição do vértice
 passo, % O passo com que a posição do vértice é variada

INICIO

% Procurando melhor solução à direita
 posiçãoAtual ← posiçãoInicial;
 melhorTaxaAcertoDireita ← taxaAcertoInicial;

ENQUANTO posiçãoAtual < posiçãoMAX
 posiçãoAtual ← posiçãoAtual + passo;
 taxaAcertoRetornada ← classificaAmostras(posiçãoAtual);
 SE taxaAcertoRetornada > melhorTaxaAcertoDireita
 melhorTaxaAcertoDireita ← taxaAcertoRetornada;
 melhorPosiçãoDireita ← posiçãoAtual;
 FIM-SE
 FIM-ENQUANTO

% Procurando melhor solução à esquerda
 melhorTaxaAcertoEsquerda ← taxaAcertoInicial;
 posiçãoAtual ← posiçãoInicial;

ENQUANTO posiçãoAtual > posiçãoMIN
 posiçãoAtual ← posiçãoAtual - passo;
 taxaAcertoRetornada ← classificaAmostras(posiçãoAtual);
 SE taxaAcertoRetornada > melhorTaxaAcertoEsquerda
 melhorTaxaAcertoEsquerda ← taxaAcertoRetornada;
 melhorPosiçãoEsquerda ← posiçãoAtual;
 FIM-SE
 FIM-ENQUANTO

```

% Determina a melhor posição entre a da esquerda e a da direita
SE melhorTaxaAcertoEsquerda > melhorTaxaAcertoDireita
  melhorTaxaAcerto ← melhorTaxaAcertoEsquerda;
  melhorPosição ← melhorPosiçãoEsquerda;
SENÃO
  melhorTaxaAcerto ← melhorTaxaAcertoDireita;
  melhorPosição ← melhorPosiçãoDireita;
FIM-SE

% Determina e retorna a melhor posição entre a inicial e a encontrada
pelo algoritmo
SE melhorTaxaAcerto > taxaAcertoInicial
  RETORNA [melhorTaxaAcerto, melhorPosição]
SENÃO
  RETORNA [taxaAcertoInicial, posiçãoInicial]
FIM-SE
FIM-ALGORITMO

```

```

posiçãoMIN ← Definir mínimo valor de posição que X
deve atingir
[posiçãoRetornada, taxaAcertoRetornada] ←
  ModificaVértice(posiçãoMAX, posiçãoMIN,
    melhorTaxaAcerto, posiçãoInicial,
    passo);
SE taxaAcertoRetornada > melhorTaxaAcerto
  melhorTaxaAcerto ← taxaAcertoRetornada;
  posição de X ← posiçãoRetornada;
  Reinicia todos os laços PARA;
FIM-SE

FIM-PARA
FIM-PARA
FIM-PARA
FIM-ALGORITMO

```

As posições de cada um dos vértices das funções trapezoidais devem respeitar certas restrições, para certificar que o cálculo dos graus de pertinência seja realizado corretamente, e que não haja intervalos do universo de discurso que não pertençam a nenhum termo.

Sendo $a(v, t)$, $m(v, t)$, $n(v, t)$ e $b(v, t)$ os parâmetros da função trapezoidal do termo t da variável v , de acordo com a Fig. 5 e com $t = 1$ para o termo ‘pequeno’, $t = 2$ para o termo ‘médio’ e $t = 3$ para o termo ‘grande’, tem-se que:

$$A(v) \leq a(v, t) \leq m(v, t) \leq n(v, t) \leq b(v, t) \leq B(v), \forall v, t \quad (2)$$

Considerando que o universo de discurso de $v = [A(v), B(v)]$. Tem-se também que:

$$a(v, t) < b(v, t - 1), t > 1 \text{ e } \forall v \quad (3)$$

e

$$b(v, t) > a(v, t + 1), t < 3 \text{ e } \forall v \quad (4)$$

As equações acima definem as posições máxima e mínima que cada um dos vértices pode ter. Os passos para se melhorar as posições de cada um dos vértices e iterativamente melhorar a taxa de acerto do sistema são mostrados no Algoritmo 2.

Algoritmo 2 - Aperfeiçoar Variáveis

```

Parâmetros:
melhorTaxaAcerto, % Atual taxa de acerto
passo, % O passo com que a posição de um vértice é variada

INICIO

PARA cada uma das variáveis V
  PARA cada um dos termos T da variável V
    PARA cada um dos vértices X do termo T da variável V

      posiçãoInicial ← posição de X;
      posiçãoMAX ← Definir máximo valor de posição que X
      deve atingir

```

V. Resultados e Discussão

As taxas de acerto obtidas pelo melhor treinamento em cada uma das topologias de rede neural testadas são apresentadas na TABELA VIII.

TABELA VIII - Taxas de acerto (T.A.) das diferentes topologias de rede neural

	T1	T2	T3	T4	T5	T6	T7	T8
T.A. (%)	83,8	84,3	83,6	82,8	84,6	86,6	86,1	85,1

Os resultados das classificações geradas pelas diferentes combinações de parâmetros de treinamento constam na TABELA IX, mostrando que os parâmetros inicialmente definidos (taxa de aprendizagem de 0,1, momento de 0,7 e 10.000 épocas) são os mais adequados para a aplicação, os quais proporcionaram a melhor taxa de acerto – 86,6% – na abordagem com rede neural.

TABELA IX – Taxa de acerto (T.A.) para diferentes parâmetros de treinamento

	P1	P2	P3	P4	P5
T.A. (%)	86,1	85,4	85,1	85,6	84,6

A matriz de confusão obtida pela melhor configuração é mostrada na TABELA X.

TABELA X - Matriz de confusão da melhor solução com rede neural

	Pau	Pedra	Perfeito	Quebrado
Pau	88	0	0	11
Pedra	0	70	2	27
Perfeito	0	0	99	0
Quebrado	4	5	4	86

Ao fim da execução do algoritmo de aperfeiçoamento para o sistema *fuzzy*, obtiveram-se as variáveis de entrada formadas pelos parâmetros da TABELA XI. Submetendo o conjunto de testes ao processo de classificação do sistema fuzzy em sua configuração final, obtiveram-se os resultados da TABELA XII. Nela são apresentadas as taxas de acerto para cada método de defuzzificação do modelo não-paramétrico e do modelo Takagi-Sugeno.

VI. Conclusões e Trabalhos Futuros

TABELA XI - Configuração final das funções trapezoidais das variáveis de entrada.

Variável	Termo	a	m	n	b
Variância das assinaturas	P	0,00	0,00	25,55	34,06
	M	34,06	101,71	101,71	222,58
	G	123,15	350,00	900,00	900,00
Área	P	0,00	0,00	2,24	50,42
	M	32,32	34,57	34,57	65,69
	G	45,12	65,69	150,00	150,00
Aspecto	P	0,00	0,00	35,25	65,00
	M	45,00	65,00	83,74	83,74
	G	83,74	97,56	100,00	100,00

TABELA XII - Taxas de acerto da configuração final.

	Mda	MdM	PM	TS
Taxa de acerto (%)	63,1	82,0	49,8	54,3

O melhor resultado – 82,0% de taxa de acerto – foi obtido pelo modelo não-paramétrico utilizando o método de defuzzificação Média dos Máximos, o qual proporcionou o melhor resultado em todas as configurações anteriores à final. A matriz de confusão da melhor classificação obtida é apresentada na TABELA XIII. Observa-se também que o modelo Takagi-Sugeno apresenta desempenho muito inferior ao modelo não-paramétrico, o que indica que as regressões lineares não são capazes de separar as classes do problema abordado de forma eficiente. Com o algoritmo de aperfeiçoamento da classificação, conseguiu-se melhorar a taxa de acerto de 66,7% para 82,0%, o que representa um ganho satisfatório, comprovando a eficácia do algoritmo.

TABELA XIII - Matriz de confusão da melhor solução fuzzy

	Pau	Pedra	Perfeito	Quebrado
Pau	88	0	3	8
Pedra	1	71	11	16
Perfeito	0	0	97	2
Quebrado	4	13	13	69

Portanto, constata-se que as duas abordagens apresentam resultados semelhantes, com desempenho ligeiramente melhor por parte da rede neural. Nota-se, inclusive, uma semelhança muito grande nas matrizes de confusão, o que leva a crer que o principal fator limitante para um resultado melhor, tanto pelo sistema *fuzzy*, como pela rede neural, são os descritores de forma adotados, que, apesar de não terem sido exatamente os mesmos nos dois sistemas, basicamente representam as mesmas características.

Notou-se também que para este problema as variações na construção da rede neural pouco influenciaram no resultado final, enquanto o sistema *fuzzy* mostrou-se mais sensível à definição de seus parâmetros, podendo ter sua taxa de classificação aprimorada com testes mais aprofundados, por exemplo, modificando-se a configuração da variável de saída.

Este estudo utilizou duas abordagens para identificar impurezas em amostras de grãos de café: uma com redes neurais e outra com um sistema *fuzzy*. Utilizando um algoritmo iterativo para melhorar a configuração das variáveis de entrada do sistema *fuzzy*, obteve-se 82,0% como melhor taxa de acerto de classificação, que foi ligeiramente superada por uma rede neural, a qual apresentou 86,6% de acurácia com melhor arranjo de parâmetros dentre os vários avaliados.

Configurações diferentes de topologia e dos parâmetros de treinamento mostraram influenciar muito pouco na classificação gerada pela rede neural. Em contrapartida, a saída do sistema *fuzzy* foi mais suscetível a variações de seus parâmetros, sugerindo que sua classificação possa superar a da rede neural com um ajuste mais minucioso.

Como as matrizes de confusão apresentaram valores muito semelhantes em ambas abordagens, acredita-se que os descritores utilizados sejam uma possível limitação para se obter resultados melhores.

Os resultados da classificação podem ser considerados de bom nível, reforçados pela presença de poucos falsos positivos e falsos negativos para a classe de grãos perfeitos, indicando êxito na separação de grãos de objetos que depreciam a bebida.

Este problema já está sendo submetido a um estudo mais aprofundado, buscando-se identificar todas as classes de defeitos comumente encontradas em uma amostra de café, através da análise de descritores de várias naturezas: forma, cor e textura.

VII. Agradecimentos

Agradecemos ao apoio financeiro da Cooxupé, Guaxupé, MG.

REFERÊNCIAS

- [1] A. Arefi, A. M. Motlagh, R. F. Teimourlou. Wheat class identification using computer vision system and artificial neural networks. *International Agrophysics*, v. 25, p. 319-325, 2011.
- [2] X. Chen, Y. Xun, W. Li, J. Zhang. Combining discriminant analysis and neural networks for corn variety identification. *Computers and Electronics in Agriculture*, v. 71, p. 48-53, 2010.
- [3] I. Silva, D. Spatti, R. A. Flauzino. Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. São Paulo: Artibler, 2010. 91-169 p.
- [4] L. Costa, R. C. Jr. Shape analysis and classification: theory and practice. [S.l.]: CRC Press, 2002.
- [5] D. Zhang, G. Lu. Review of shape representation and description techniques. *Pattern Recognition*, 37:1-19, 2004.