

## **Sistema Embarcado de Identificação de Cores Utilizando Redes Neurais *Perceptron* Múltiplas Camadas**

**Jefferson John Do Rego Leite<sup>1</sup>, Pedro Thiago Valério De Souza<sup>1</sup>**

<sup>1</sup>Departamento de Engenharias e Tecnologia – Universidade Federal Rural do Semi-Árido (UFERSA)

Caixa Postal 15.064 – 59.900.970 – Pau dos Ferros – RN – Brasil

pedro.souza@ufersa.edu.br jefferson.john.rego@gmail.com

**Abstract.** *The identification of colors allows applications such as coffee cultivation, measurement of solar absorptivity and aid color blinds in the recognition of colors. This work aims to develop a MLP neural network, implemented in an ATmega 328p microcontroller, that is able to identify seven different colors. In order to verify the operation of the network, the confusion matrix is constructed and the percentage of correctness for each of the colors to be classified is calculated. The results obtained prove the efficiency of the system in the task of color classification, using few resources available in the microcontroller.*

**Resumo.** *A identificação de cores permite aplicações como o cultivo do café, medição da absorvância solar e auxiliar daltônicos no reconhecimento das cores. Este trabalho objetiva desenvolver uma rede neural PMC, implementado em um microcontrolador ATmega 328p, que seja capaz de identificar sete diferentes cores. A fim de verificar o funcionamento da rede, constrói-se a matriz de confusão e calcula-se a percentagem de acerto para cada uma das cores a serem classificadas. Os resultados obtidos comprovam a eficiência do sistema na tarefa de classificação de cores, utilizando poucos recursos disponíveis no microcontrolador.*

### **1. Introdução**

A identificação de cores apresenta variadas aplicações, tais como no cultivo de café [Carmo et al. 2016], medição da absorvância solar de superfícies opacas [Kelen and Kelen 2019] e auxiliar daltônicos no reconhecimento das cores [Mano 2011]. Em seu trabalho Carmo et al. (2016) analisa solos em que a cor da terra representa características especiais, como nível de salinidade. Desta forma, por reconhecimento de cores pode-se identificar áreas com diferentes potenciais para produção do café. Já Kelen e Kelen (2019) elenca que tintas de diferentes cores podem apresentar as mesmas absorvâncias no espectro visível, provocando sensações semelhantes de nível claro-escuro, o que pode enganar o olho humano quanto à sua absorvância solar. Por sua vez, Mano (2011) desenvolveu um sistema que facilitasse a identificação de cores para pessoas daltônicas, que não conseguem distinguir bem o vermelho do verde.

Um método bem simples para classificação de cores consiste em um banco de dados carregado de informações sobre as cores a serem classificadas. Através de

consultas pode-se identificar qual cor foi apresentada [SARTI 2019]. Entretanto, esse banco não seria sensível a mudanças do ambiente, no qual a luminosidade poderia efetuar um grande erro na identificação.

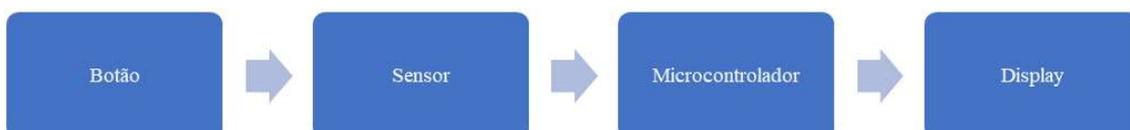
Uma forma possível para solucionar este problema consiste na utilização de uma Rede Neural Artificial (RNA) de forma a distinguir cores básicas [MORETTI 2016]. Alguns exemplos de RNA empregadas neste propósito são as redes *Perceptron*, rede de funções de base radial (RBF) e os mapas auto-organizáveis de Kohonen [SILVA et al. 2016].

Diante disso, neste trabalho, propõe-se a utilização de uma rede *Perceptron* Múltiplas Camadas (PMC), devido sua facilidade de implementação, como um classificador de cores. O sistema será implementado em um microcontrolador ATmega 328p, de forma a produzir um protótipo em *hardware* barato e que seja capaz de identificar as cores com alta precisão e baixo custo.

O processo de treinamento da rede é efetuado de forma *off-line*, utilizando o *software* Matrix Laboratory (MATLAB) [ERAQI 2016], a fim de obter a matriz de pesos. Em seguida, essa matriz de pesos é armazenada no microcontrolador, que executa tão somente a etapa de classificação.

## 2. Descrição do Sistema

O sistema é composto por 4 elementos básicos: Microcontrolador; Sensor RGB TCS230; um Botão e um Display LCD 16x2. A Figura 1 representa o fluxo de execução do sistema proposto.



**Figura 1. Fluxo de execução do sistema.**

O microcontrolador armazena a matriz de pesos da rede e a etapa de processamento da Rede Neural. Neste trabalho utilizou-se um microcontrolador ATmega 328p, escolhido devido a facilidade de programação, a disponibilidade no mercado e baixo preço, atendendo também as demandas desse trabalho.

O sistema aguarda que o botão seja pressionado, para então ativar o sensor de cores que irá, a partir de uma codificação própria, gerar um pulso quadrado conforme a cor apresentada. Neste trabalho utilizou-se o sensor TCS230. Este sensor apresenta um fotodiodo acionado pela luz refletida do objeto. O TCS230 é um oscilador que produz uma saída de onda quadrada cuja frequência é proporcional à intensidade da cor escolhida [TAOS 2003].

O microcontrolador lê os valores obtidos pelo sensor TCS230 e então aplica os valores medidos na rede, de forma a obter uma resposta a respeito da classificação da cor. Por fim o resultado, nome da cor, é impresso no *Display* LCD.

### 3. Materiais e Métodos

Inicialmente selecionou-se 7 cores, sendo elas: Laranja, Vermelho, Marrom, Preto, Azul, Verde e Branco, distribuídas de acordo com a Tabela 1. Em seguida submeteu-se cada cor ao sensor, e através do Microcontrolador, obteve-se os valores medidos para cada amostra de cor. Essas amostras foram utilizadas no processo de treinamento da Rede Neural.

**Tabela 1. Quantidade de amostras obtidas para cada cor.**

Cor	Quantidade de Amostras
Azul	27
Verde	28
Preto	29
Branco	17
Marrom	18
Vermelho	22
Laranja	29

Utilizando o software MATLAB foi criado um algoritmo de treinamento para a PMC, que possui 3 camadas, sendo uma camada de entrada, uma oculta e uma de saída, possuindo 3, 8 e 7 neurônios em cada camada, respectivamente. O algoritmo utilizado foi o *Backpropagation* com o critério de parada de  $10^{-3}$ . A função de ativação utilizada foi a *sigmoid*, produzindo apenas números positivos.

A camada de entrada recebe as informações do sensor RGB, possuindo assim um neurônio responsável pelo vermelho, outro pelo verde e o último pelo azul. A necessidade de 8 neurônios na camada oculta parte da proximidade com a quantidade de cores (classes) a ser separada. Já a camada de saída é composta por 7 neurônios referente a qual das cores foi reconhecida. A camada de entrada recebe os valores RGB do sensor, normalizados, ao passo que a camada de saída é um vetor de 7 posições, com codificação apresentada na Tabela 2.

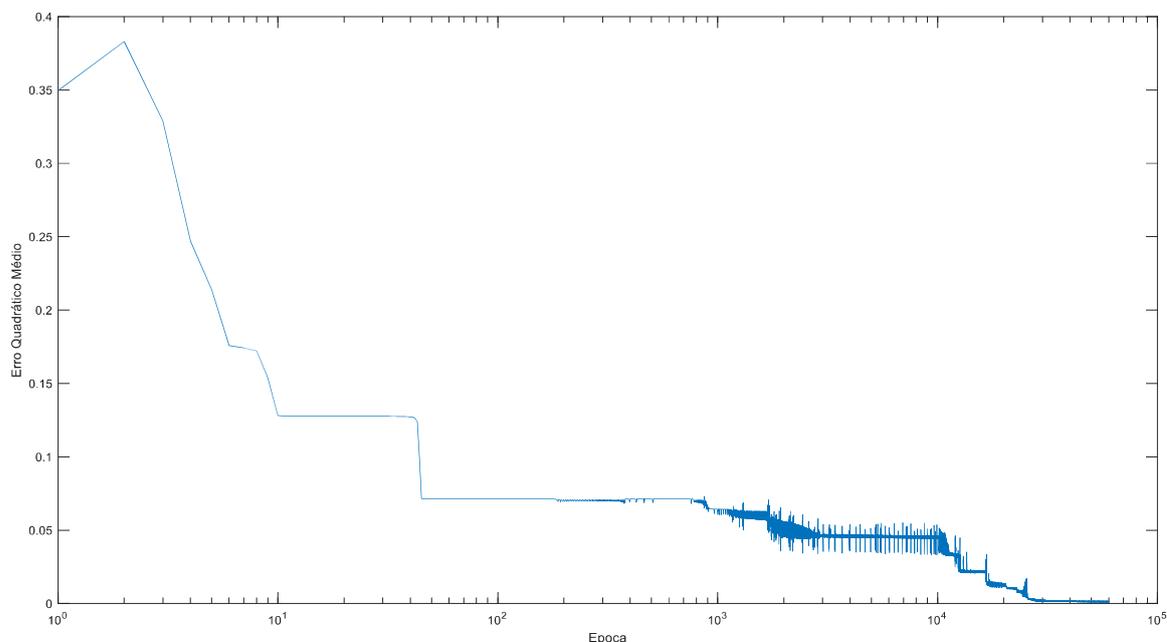
**Tabela 2. Código referente as cores.**

Cor	Saída
Azul	1000000
Laranja	0100000
Marrom	0010000
Verde	0001000
Vermelho	0000100
Preto	0000010
Branco	0000001

## 4. Resultados e Discursões

### 4.1. Análise do Erro Quadrático Médio

Na Figura 2 é apresentado o gráfico do Erro Quadrático Médio (EQM) em função da época de treinamento.



**Figura 2. Gráfico do EQM em função da época.**

Analisando a Figura 2, observa-se que no início do processo de treinamento até a décima época, observa-se uma grande queda do EQM, mostrando que a rede está aprendendo bastante. A partir da época 45, o EQM se manteve estável até a época 100. Quando então passa a oscilar um pouco se mantendo estável novamente só a partir da época 20000.

Finalizado o processo de treinamento obteve-se um EQM de  $9,659 \times 10^{-4}$ . Isso mostra que os valores fornecidos pela RNA se diferem dos valores desejados, em média, de  $9,659 \times 10^{-4}$ .

### 4.2. Matriz de Confusão na Classificação

A fim de analisar a capacidade de generalização da Rede Neural, apresenta-se na Tabela 3 a matriz de confusão para a classificação do sistema implementado em microcontrolador.

**Tabela 3. Matriz de Confusão para Classificação.**

	Classe Prevista							
	Azul	Laranja	Marrom	Verde	Vermelho	Preto	Branco	
Classe Real	Azul	15	0	0	0	0	0	0
	Laranja	0	14	0	0	1	0	0
	Marrom	0	0	15	0	0	0	0
	Verde	0	0	0	15	0	0	0
	Vermelho	0	0	0	0	15	0	0
	Preto	0	0	0	0	0	15	0
	Branco	0	0	0	0	0	0	15

Pela análise da Tabela 3 nota-se que apenas uma amostra da cor Laranja foi classificada incorretamente. Este erro não se caracteriza grave, já que as cores Laranja e Vermelho são similares. Desta forma, é notável que o sistema projetado apresentou um desempenho satisfatório para todas as cores analisadas.

A partir da Tabela 3, pode-se elaborar um percentual de acerto da rede para cada cor, apresentado na Tabela 4.

**Tabela 4 – Porcentagem de Acerto da Rede para cada Cor.**

Cor	Porcentagem de Acerto
Azul	100,00%
Laranja	93,33%
Marrom	100,00%
Verde	100,00%
Vermelho	100,00%
Preto	100,00%
Branco	100,00%
Média	99,04%

O tamanho do código e das variáveis presente no microcontrolador é visto na Tabela 5.

**Tabela 5 – Uso da memória do microcontrolador**

Objeto	Tamanho ocupado (bytes)	Porcentagem ocupada
Código	9210	28%
Variáveis	925	45%

Os resultados mostrados na Tabela 5 demonstram que redes mais complexas e com mais camadas ainda poderiam ser implementadas com este mesmo microcontrolador.

O tempo, em milissegundos, necessário para identificação de cada cor é apresentado na Tabela 6.

**Tabela 6 – Tempo para identificação das cores.**

Cor	Tempo (ms)
Vermelho	29
Preto	26
Marrom	27
Laranja	28
Verde	25
Branco	27
Azul	26
Média	26,85

Pode-se verificar que o tempo necessário para a identificação das cores é pequeno, mostrando que o sistema tem uma resposta rápida quando acionado. A cor que levou mais tempo para ser reconhecida foi a Vermelha, 29 milissegundos, sendo cerca de 90% mais rápido que uma piscada de olho humana, que leva cerca de 300 milissegundos [LITHERLAND 2016].

## 5. Conclusões

A partir das análises realizadas neste trabalho, verificou-se que o sistema foi projetado e implementado de forma a garantir uma quantidade ínfima de erro, identificando as 7 cores distintas, com boa precisão de classificação e rapidez no reconhecimento das diferentes cores.

Um dos aspectos que talvez interfira na execução do reconhecimento, é o fato do microcontrolador utilizado ter um limite de 7 casas decimais para suas variáveis de ponto flutuante, logo cores muito parecidas podem ser identificadas de forma errada.

Para trabalhos futuros deseja-se aumentar o número de cores a serem reconhecidas, de forma abranger o máximo de colorações dentro dos limites de memória e precisão do microcontrolador.

## Referências

- Carmo, Danilo Almeida Baldo do et al. (2016) “Cor do solo na identificação de áreas com diferentes potenciais produtivos e qualidade de café” In Pesquisa Agropecuária Brasileira, [s.l.], v. 51, n. 9, p.1261-127. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-204x2016000900026>.
- Eraqi, Hesham (2016). “MLP Neural Network with Backpropagation”. Disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/54076-mlp-neural-network-with-backpropagation>>. Acesso em: 04 abr. 2019.
- Kelen, Almeida & Dornelles, Kelen. (2019) “a ilusão das cores na identificação da absortância solar de superfícies opacas”.
- Leite, Tiago M. (2018) “Redes Neurais, Perceptron Multicamadas e o Algoritmo Backpropagation”. Disponível em: <<https://medium.com/ensina-ai/redes-neurais-backpropagation>>.

- perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8>. Acesso em: 04 abr. 2019.
- Litherland, Neal (2016) “Quão rápido é um piscar de olhos?”. Disponível em: <[https://www.ehow.com.br/quao-rapido-piscar-olhos-sobre\\_67301/](https://www.ehow.com.br/quao-rapido-piscar-olhos-sobre_67301/)>. Acesso em: 04 abr. 2019.
- MANO, Thiago (2011) “Coloradd: um sistema de identificação de cores para daltonicos.”. Disponível em: <<http://www.revistadesign.com.br/2/2011/10/14/coloradd-um-sistema-de-identificacao-de-cores-para-daltonicos/>>. Acesso em: 04 abr. 2019.
- Moretti, Caio Benatti. (2016) “Color sensor prototype using artificial neural networks”. Disponível em: <<http://www.moretticb.com/blog/color-sensor-prototype-using-neural-networks/>>. Acesso em: 03 abr. 2019.
- Texas. Taos (2003) “Datasheet TCS230. 2003”. Disponível em: <<http://www.w-r-e.de/robotik/data/opt/tcs230.pdf>>. Acesso em: 04 abr. 2019.
- Sarti, Erika (2019) “Tabela de Cores: hexadecimal e RGB”. Disponível em: <<http://erikasarti.com/html/tabela-cores/>>. Acesso em: 03 abr. 2019.
- Silva, Ivan Nunes; Spatti, Danilo Hernane; Flauzino, Rogério Andrade (2016) “Redes Neurais Artificiais: fundamentos teóricos e aspectos práticos”. 2. ed. São Paulo: Artliber.