

## Extração e classificação de padrões em espécimes de gatos siameses

### *Extraction and Classification of Patterns in Specimens of Siamese Cats*

Lucas Augusto Cavenaghi<sup>1</sup>

Submetido em: 23/04/2019    Aceito em: 17/06/2019    Publicado em: 29/08/2019

**Resumo:** *Avanços recentes no campo da Inteligência Artificial, onde novas aplicações que usam conceitos de aprendizado de máquina aparecem frequentemente, estão fazendo com que nossa vida cotidiana mude. Assim, este artigo descreve o desenvolvimento de uma aplicação que utiliza técnicas de Inteligência Artificial, Processamento de Imagem e Visão Computacional, para reconhecer se existe ou não um espécime de gato siamês em uma determinada imagem. Neste sentido, este artigo mostra como podemos usar métodos para segmentação de imagens, extração de características e classificação para reconhecimento de gatos siameses.*

**Palavras-Chave:** *Aprendizado Supervisionado, Inteligência Artificial, ScyPy.*

**Abstract.** *Recent advances in the Artificial Intelligence field, where new applications using machine learning concepts are often appearing, are making our everyday life to change. Thus, this article describes the development of an application that uses Artificial Intelligence Techniques, Image Processing and Computer Vision, to recognize if there is or not a specimen of Siamese cat in a given image. In this vein, this paper shows how we can use methods for image segmentation, extraction of characteristics, and classification for Siamese cats recognition.*

**Keywords:** *Artificial Intelligence, Supervised Learning, ScyPy.*

## 1. Contextualização

A Inteligência Artificial (IA) é uma área da ciência muito estudada atualmente com focos teóricos e práticos, sendo utilizada para simular comportamento, aprendizado e adaptação de humanos em determinada situação, através do uso de máquinas.

Segundo Teixeira (2014), as técnicas de IA buscam o sucesso no tratamento de novas situações pelo ajuste apropriado do comportamento (inteligência por aprendizado), fazendo com que máquinas pareçam pensar.

Nessa mesma linha, este artigo vem demonstrar uma aplicação desenvolvida com o objetivo de definir binariamente, através de uma imagem de um espécime de gato (*felis catus*), se o mesmo pertence à espécie siamês.

---

<sup>1</sup> Escola de Engenharia de Piracicaba, Piracicaba (SP), Brasil. Email: [lucas.ag.cv@gmail.com](mailto:lucas.ag.cv@gmail.com)

## 2. Reconhecimento de imagens e padrões

Sistemas de reconhecimento de imagens devem transformar imagens em informação e utilizar seus valores, como cores, posição, textura, para caracterizar as informações da imagem. Além disso, essas aplicações devem não somente focar em valores, mas sim reconhecer qualquer tipo de padrão reconhecível.

Dessa forma, “padrão em reconhecimento de imagens digitais ou não é um termo genérico que se refere a qualquer elemento que possa ser definido quantitativamente mesmo que sujeito a variações” (CONCI, AZEVEDO e LETA, 2008).

Ainda segundo Conci, Azevedo e Leta (2008), um padrão no contexto de análise de imagens, computação gráfica e IA tem como significado qualquer aspecto que possa ser padronizado. No pós-processamento a parte final do algoritmo deve ponderar as saídas de diferentes classificadores e tomar uma decisão final.

O reconhecimento de padrões em imagens é algo realizado juntamente com o sistema ótico da raça humana, porém é algo complexo para ser reproduzido computacionalmente. Esse conceito se relaciona diretamente com diversos outros assuntos, como *Machine Learning*, *Data Mining*, linguagens formais e autômatos, redes neurais, entre outros.

## 3. Aprendizado de máquina supervisionado

Dentro da área de reconhecimento de padrões, existem duas técnicas de classificação, 1) não supervisionada e a 2) supervisionada, esta última utilizada no projeto. A classificação supervisionada utiliza um conjunto de objetos conhecidos pertencentes a diferentes classes, separando-as através de parâmetros desejados.

O processo de classificação se inicia com uma divisão da base de dados em duas: uma de treinamento e outra de testes. O conjunto de treinamento deve ter uma população bem representável, possibilitando um treino eficaz, não se misturando com a base de testes. A partir desse processo, deve-se escolher os parâmetros relevantes a serem utilizados obtidos pelas etapas de caracterização e descrição, sendo no caso do projeto, as características mais prevalentes em gatos persas.

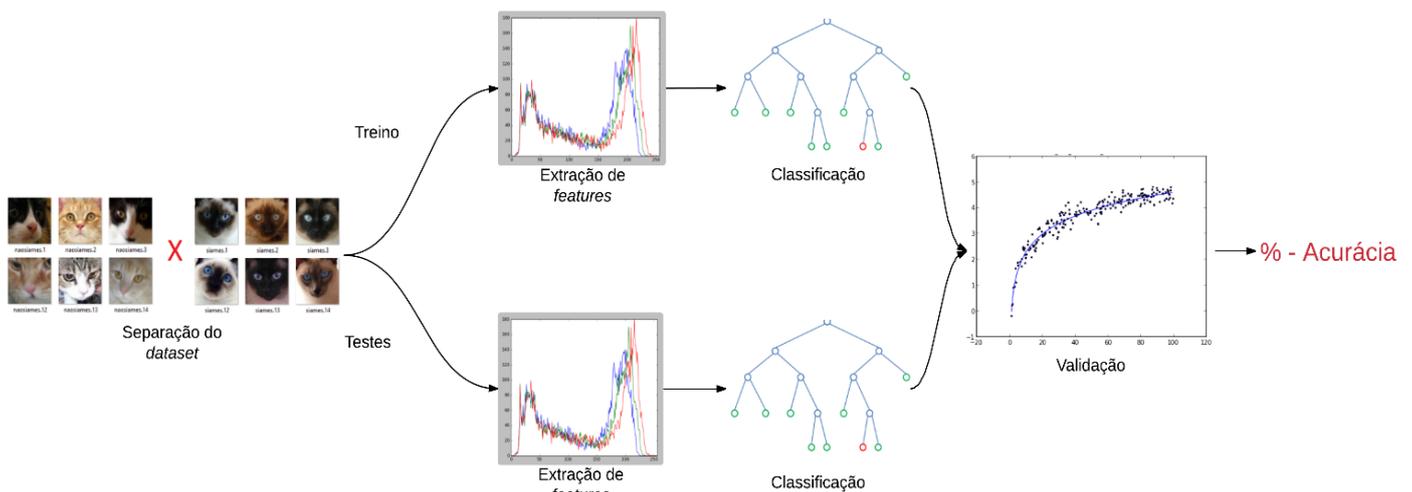
Com isso, é obtida uma função discriminante, que remove os parâmetros não relevantes. Nas etapas finais, são executados com a base de testes, atualizando os dados e realimentando o aprendizado, sendo que a aprendizagem do algoritmo se dá através da redução do erro do conjunto de treinamento.

Assim, o processo de reconhecimento de padrões é executado a partir dos processos descritos pelas subseções anteriores, aplicando uma decisão sobre o problema e resultando em um algoritmo completo.

#### 4. Reconhecendo gatos Siameses

A criação do algoritmo foi realizada em etapas, se iniciando com a criação de um *dataset* com imagens de gatos, separando-os em espécimes siameses e espécimes não siameses. Com o *dataset* de treino, foram realizadas extrações de características (*features*) e padrões que indicam se o espécime é ou não siamês. A partir dessas características, foi possível obter um modelo de classificação que pode ser utilizado para deduzir se na foto está presente ou não um gato siamês. A partir do classificador é possível realizar o processo com o *dataset* de treino, calculando a acurácia do classificador gerado pelo algoritmo. O processo como um todo fica claro observando o pipeline do algoritmo na Figura 1.

**Figura 1 – Pipeline da aplicação**



**Fonte:** Elaboração Própria.

Durante o desenvolvimento da aplicação, foram utilizadas diferentes técnicas. A primeira foi com a biblioteca *OpenCV (Open Source Computer Vision Library)*, através da aplicação direta de mecanismos de extração com características Haar e classificação via *traincascade*.

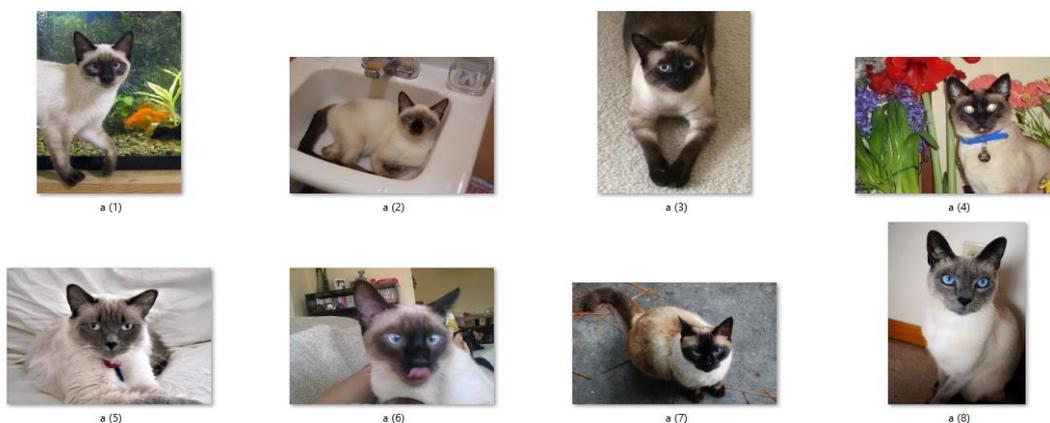
Em seguida, outras técnicas foram utilizadas para questões de comparação e acurácia, sendo desenvolvidos algoritmos utilizando outros métodos de classificação através da biblioteca *Scikit (SciPy Toolkit) Learn*. Para essa aplicação, foi utilizada a extração por meio de histogramas aplicada por meio de diferentes classificações, sendo a com melhor acurácia, *Random Forest*.

#### 4.1. Dataset

Para o desenvolvimento da aplicação foram coletadas diversas imagens de gatos da raça siamesa, sendo que o banco de imagens foi dividido em duas partes, uma para o treinamento e outra para os testes.

As imagens do *dataset* foram adquiridas em diversos locais, através do Google Imagens, Instagram, Pinterest como também pelo banco de imagens de treinamento do concurso *Cats versus Dogs* do Kaggle. Assim, foram totalizadas quinhentas imagens para o processo de treino e cem para os testes, conforme a Figura 2.

**Figura 2** - Dataset de imagens positivas

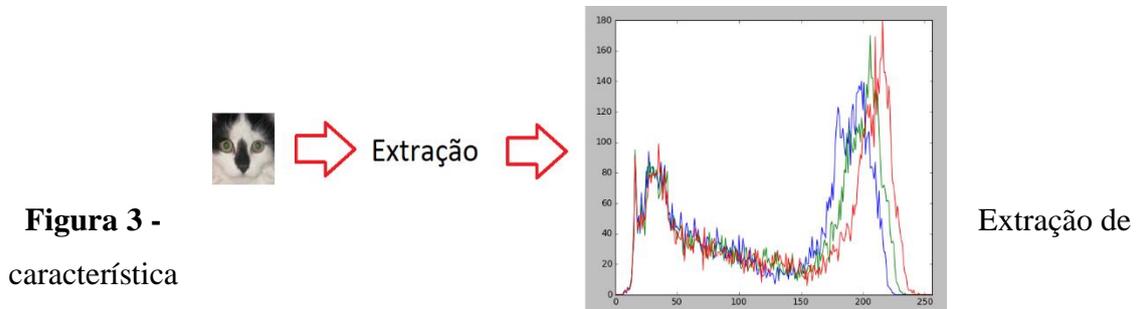


**Fonte:** Elaboração Própria.

#### 4.2. Extração de características

No OpenCV, foram extraídas as *features* (características) das imagens através do processo *haar-like features*, que conforme Lima referem à Wavelet de Haar, uma transformada matemática discreta usada no processamento e análise de sinais, sendo ela uma função matemática capaz de decompor e descrever ou representar outra função. Assim, a transformada de Haar processa dados em diferentes escalas e resoluções, independentemente de qual é o ponto de interesse a ser descrito na imagem, entregando uma representação detalhada.

Já no caso do *Scikit-Learn* a extração de *features* das imagens do *dataset* utilizou da extração por histogramas, ocorrendo a extração de tonalidades dos pixels das imagens. Nesta, cada imagem é subdividida em três, cada uma possuindo as tonalidades de vermelho, verde e azul, respectivamente. Após essa subdivisão, as imagens passam por uma função de cálculo de histograma, gerando um *array* de *features*. No caso da aplicação deste projeto, cada um dos histogramas é subdividido em dez faixas de valores, gerando trinta *features*, conforme a Figura 3.



**Fonte:** Elaboração Própria.

### 4.3 Treinamento

No *OpenCV* já com as imagens processadas e as *features* extraídas, foi realizado treinamento via *traincascade*, método que concatena diversas características, utilizando o nível de importância de uma característica em conjunto com a próxima característica e assim por diante.

Porém o método de classificação que gerou melhores resultados utilizando os *features* extraídos através do método de histogramas no *Scikit-Learn* foi o *Random Forest*. O algoritmo de *Random Forest* é um tipo de *ensemble learning*, tipo de classificação que gera muitos classificadores e combina o seu resultado gerando um classificador mais forte.

Assim, este método gera diferentes árvores de decisão, cada uma com suas particularidades e caminhos, combinando o resultado da classificação de todas elas. Com isso, essa combinação de modelos faz com que o método *Random Forest* seja muito mais eficaz do que uma única árvore de decisão.

### 4.4 Resultados

Após a execução de ambas as aplicações, diversos resultados foram obtidos. Para a realização dos testes, duzentas fotos foram utilizadas, tanto na primeira aplicação quanto na segunda.

Dentre essas fotos, cem eram positivas, contendo fotos de gatos siameses, e cem negativas, contendo fotos de outras espécies de gatos. A acurácia do treinamento pode ser demonstrada a partir da porcentagem de acerto do classificador. No caso do algoritmo, o classificador é binário, sendo que os casos do modelo são apenas dois, o siamês e o não siamês.

Com a aplicação utilizando *OpenCV*, *Haar* e *Traincascade*, os resultados obtidos foram bastante satisfatórios, obtendo uma acurácia de 76%. Assim, essa acurácia foi medida pela taxa de acertos dos casos negativos e dos positivos e está descrita de maneira simples na Tabela 1.

**Tabela 1** - Resultados da aplicação com *OpenCV*

	Siamês	Não Siamês
Siamês	80	20
Não Siamês	28	72

Fonte: Elaboração Própria.

Já na aplicação utilizando o *Scikit-Learn*, diversos classificadores foram testados a partir dos *features* extraídos pelo método de histogramas. O classificador que gerou a melhor acurácia foi o *Random Forest*, gerando uma acurácia de 87%. Os funcionamentos de outros métodos não foram explicados neste artigo, o qual focou no classificador com melhor resultado. Esses outros métodos testados, sendo medidas suas acurácias, foram:

1. *Gradient Boosting* – 86%
2. *Extra Trees* – 83%
3. Vizinheiro mais próximo (*KNeighbors*) – 79%

**Tabela 2.** Resultados da aplicação através do *Scikit-Learn*

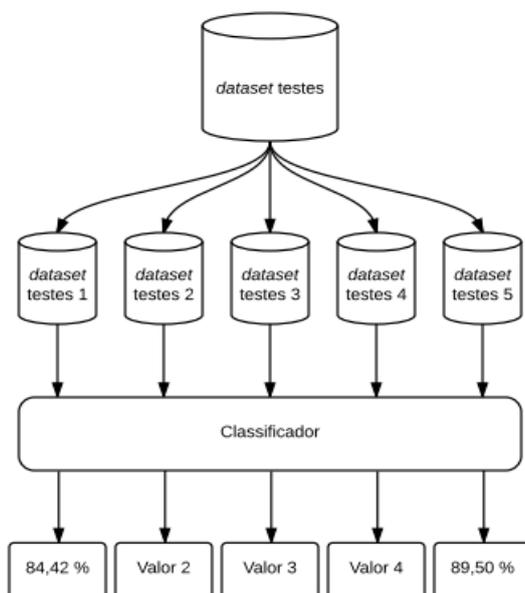
	Siamês	Não Siamês
Siamês	91	9
Não Siamês	17	83

Fonte: Elaboração Própria.

Outra ferramenta importante para avaliar a capacidade de um classificador foi a validação cruzada (*cross-validation*), uma técnica para avaliar a capacidade de generalização de um modelo. O objetivo da validação cruzada é definir um conjunto de

imagens para "testar" o modelo na fase de treinamento, generalizando o classificador para que tenha uma acurácia real em comparação a imagens de um conjunto real utilizado fora dos testes e treinamento, dividindo o *dataset* de treinos em cinco e realizando o cálculo de acurácia em cada um deles, conforme a Figura 4.

**Figura 4** - Exemplificação do processo de *cross-validation*.



**Fonte:** Elaboração Própria.

Portanto, os valores gerados a partir da validação cruzada foram uma média entre o menor valor, 84,42% e o maior valor, 89,50%, o que resultou em um valor médio de 86,58%.

## 5. Considerações finais

Considerando os resultados obtidos, fica evidente que ao utilizarmos a biblioteca *Scikit-Learn* é notável a facilidade proporcionada para realizar programas relacionados à área de visão computacional, criando aplicações diretas de métodos complexos em poucas linhas de código. Também se evidencia que os algoritmos apresentados obtiveram boas acurácias, através de diferentes métodos de extração de características, classificação e treinamento, aspectos da visão computacional e reconhecimento de imagem que acabam sendo cada vez mais atualizados e melhorados em um setor da tecnologia recente.

Com isso, para trabalhos futuros, surge a possibilidade de criação de outros algoritmos utilizando o mesmo *dataset* e visualizando melhores resultados, como

também a classificação em diferentes espécies de gatos, onde com uma foto seria possível designar qual a espécie do gato. Seria possível pensar também em outros animais, onde esses algoritmos seriam aplicados em fotos de cachorros e outros animais que se diferenciam por raças.

### **Referências Bibliográficas**

CONCI, A.; AZEVEDO, E.; LETA, F. Capítulo 6: Extração de Características e Reconhecimento de Padrões e Objetos. In: AZEVEDO, Eduardo; CONCI, Aura; LETA, Fabiana. Computação Gráfica - Vol. 2: Teoria e Prática. Rio de Janeiro: Elsevier, 2008. p. 195-267.

TEIXEIRA, J. F. Inteligência artificial. Pia Sociedade de São Paulo-Editora Paulus, 2014.