

Sistema de Visão Computacional Aplicado em Reconhecimento de Peças LEGO® para Auxílio na aprendizagem de Pessoas Cegas

Applied Computer Vision System for LEGO® Parts Recognition to Help Blind People Learning

Kaio C. B. Costa
Bacharelado em Sistemas de Informação
Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais
Campus Juiz de Fora - MG, Brasil
costakaiojf@gmail.com

Silvana T. Faceroli
Departamento de Educação e Tecnologia
Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais
Campus Juiz de Fora - MG, Brasil
silvana.faceroli@ifsudestemg.edu.br

Felipe S. Amaral
Programa de Pós-Graduação em Ciência da Computação
Departamento de Ciência da Computação – Universidade Federal de Juiz de Fora
Juiz de Fora - MG, Brasil
felipe.amaral@ice.ufjf.br

ABSTRACT

Com os novos paradigmas da inclusão social, a tecnologia assistiva vem ganhando espaço e importância, impulsionando o desenvolvimento de novos projetos na área. Para as pessoas cegas, ou com baixa visão, tais tecnologias são recursos fundamentais de acessibilidade, promovendo autonomia e independência. Desta forma, este trabalho tem como objetivo investigar técnicas de visão computacional e redes neurais artificiais para um sistema de identificação de peças LEGO® Education. Foi desenvolvido um protótipo de baixo custo para captação das imagens que, em seguida, foram pré-processadas. Devido às características das peças, foram utilizados descritores geométricos, de cores e transformada de Hough como entrada de uma rede neural artificial. A metodologia proposta apresentou um acerto de 100% das peças, mostrando ser bastante eficiente para esta aplicação.

ABSTRACT

With the new paradigms of social inclusion, assistive technology has been gaining space and importance, driving the development of new projects in the area. For blind people, or those with low vision, such technologies are fundamental accessibility features, promoting autonomy and independence. Thus, this work aims to investigate computer vision and artificial neural networks for a LEGO® Education parts identification system. A low-cost prototype was developed to capture the images, which were then preprocessed. Due

to the characteristics of the pieces, geometric and color descriptors and Hough transform were used as input to an artificial neural network. The proposed methodology presented a 100% accuracy of the pieces, showing to be very efficient for this application.

CCS Concepts

•Computing methodologies → *Computer graphics*; •Applied computing → *Education*;

Keywords

Tecnologia assistiva; visão computacional; LEGO; transformada de Hough
Assistive technology; computer vision; LEGO; Hough transform

1. INTRODUÇÃO

De acordo com Assis [8], em 2010 a população mundial cega era de 32,4 milhões de pessoas e mais 191 milhões tiveram um comprometimento visual moderado e grave. De acordo com dados do IBGE do mesmo ano, cerca de 3,5% da população brasileira se declara com deficiência visual.

A deficiência visual pode ser classificada em dois grupos distintos: cegueira e baixa visão ou visão subnormal. A pessoa que apresenta perda total de visão é considerada com cegueira, possuindo a necessidade de ferramentas para auxílio específicas, como bengala, cão-guia e material em braille, para manter sua independência e autonomia [1]. Já a pessoa que apresenta baixa visão ou visão subnormal, possui deficiência visual parcial sendo potencialmente capaz de usar a visão para planejamento e execução de tarefas.

A promoção da saúde, que é um instrumento que auxilia na qualidade da saúde e da vida da população [14], é de grande importância para as pessoas com deficiência visual, podendo proporcionar uma maior autonomia e independência. Neste ponto de vista, a utilização de tecnologias assis-

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

tivas pode ser bastante promissora e, atualmente, diversos trabalhos têm sido desenvolvidos [9] [4] [15].

O desenvolvimento deste trabalho surgiu de uma necessidade de alunos deficientes visuais do Instituto Benjamin Constant (IBC), que atende crianças e adolescentes cegos, surdo-cegos, com baixa visão e deficiência múltipla; é também um centro de referência, a nível nacional, para questões da deficiência visual, capacitando profissionais e assessorando instituições públicas e privadas nessa área, além de reabilitar pessoas que perderam ou estão em processo de perda da visão. Ao longo dos anos, o IBC tornou-se também um centro de pesquisas médicas no campo da oftalmologia, possuindo um dos programas de residência médica mais respeitados do país. Através desse programa, presta serviços de atendimento médico à população, realizando consultas, exames e cirurgias oftalmológicas. O Instituto é comprometido também com a produção e difusão da pesquisa acadêmica no campo da Educação Especial. Através da Imprensa Braille, edita e imprime livros e revistas em Braille, além de contar com um farto acervo eletrônico de publicações científicas.

O IBC, como instituição de ensino, oferece as duas primeiras etapas da Educação Básica – a Educação Infantil, para crianças de 0 a 5 anos de idade, e o Ensino Fundamental, para crianças de 6 a 14 anos. Desde 2016, vem oferecendo aulas de robótica com kits Lego Mindstorm® no intuito de fornecer, aos alunos, subsídios tecnológicos e psicopedagógicos para resolver problemas de forma independente ou em equipe.

Os exercícios com os kits da LEGO® possuem uma sequência de encaixe de peças e os alunos deficientes visuais apresentam dificuldades para distinguir essas peças apenas com o tato. Atualmente, os professores auxiliam na identificação das peças e vão indicando a sequência dos encaixes, o que compromete a autonomia dos alunos, pois dependem de outra pessoa para a realização das tarefas. Por outro lado, o professor também fica prejudicado pois o tempo da aula é tomado, em sua maioria, somente com a atividade de identificação de peças. A partir do exposto, verifica-se a necessidade de um sistema inteligente que possa fazer o reconhecimento das peças considerando que este kit ainda não está disponível com marcação em braile.

1.1 Trabalhos relacionados

A identificação de peças pode ser baseada em códigos explícitos, como código de barras ou códigos de matrizes de dados [17]. No entanto, a utilização de tais métodos por pessoas cegas é um pouco mais complexa pela necessidade de localização e posicionamento do código. Já a identificação automatizada tem se tornado cada vez mais importante devido à eficiência e à confiabilidade produzidas pelos algoritmos desenvolvidos.

Um avanço importante tem acontecido na área de identificação de peças utilizando *Machine Learning*. Em Russakovsky et al. [16], os autores trazem um estudo detalhado das principais técnicas de reconhecimento e classificação de imagens, fornecendo um resumo dos algoritmos mais bem-sucedidos na área.

No trabalho de Corona et al. [6], é desenvolvido um algoritmo com Redes Neurais Convolucionais para identificação de peças de vestuário por robôs. De acordo com os resultados apresentados, a técnica se mostrou promissora, mas verificou-se a necessidade de melhoria na captura das imagens.

Em Kruger et al. [13], é apresentado um estudo de caso de identificação de peças de turbinas utilizando algoritmos de aprendizagem de máquina. Os resultados alcançados foram bastante promissores, chegando a 99,8% de acerto. Já em Astanin et al. [3], um sistema de visão inteligente foi desenvolvido para reconhecer e localizar uma peça em metal reflexivo para ajustes automáticos nos robôs industriais. A solução proposta foi testada e qualificada em um ambiente realista e, de acordo com os autores, os resultados foram satisfatórios.

1.2 Objetivos

O objetivo desta pesquisa é investigar a eficiência de um sistema de reconhecimento de peças LEGO® por visão computacional baseado em extração de características geométricas e de cor, transformada de *Hough* e classificação por Redes Neurais Artificiais (RNA). Como objetivos específicos, podemos destacar:

- Averiguar a melhor forma de capturar imagens com brilho, inerentes às peças LEGO®;
- Investigar os melhores descritores para caracterizar as peças LEGO®;
- Analisar o desempenho das redes neurais artificiais utilizando os descritores propostos.

2. MATERIAIS E MÉTODOS

2.1 Coleta de Dados

Com o intuito de evitar interferências como brilho excessivo, reflexo nas peças e sobreamento, foi construído um mini estúdio fotográfico de baixo custo, mas muito eficiente para melhorar a qualidade das imagens. A estrutura foi feita em papelão com dimensões de 13x11 cm e com a frente aberta, para possibilitar o manuseio da peça a ser identificada pela câmera. Suas laterais foram cortadas e cobertas com TNT (Tecido não tecido) para passagem da iluminação. A parte interna foi preenchida com EVA (Espuma vinílica acetinada) em forma curva, conforme a Figura 1, para eliminar as sombras.



Figure 1: Mini estúdio para captura das imagens

A iluminação lateral foi feita com led's (diodo emissor de luz) de potência. Para a captura das imagens, utilizou-se uma câmera de smartphone, que foi posicionada na parte superior do mini estúdio. Apesar da simplicidade e baixo custo, a estrutura mostrou-se muito eficiente, melhorando consideravelmente a qualidade das imagens.

2.2 Repositório

Para a criação do repositório de imagens, foram selecionadas cinco peças LEGO® distintas, tendo tamanho e cores diferentes. De cada uma dessas peças, foram tiradas 20 (vinte) fotografias na resolução 4032x3024 pixels, em diversas posições, resultando em um banco de dados com 100 imagens. A Figura 2 mostra algumas imagens capturadas.



Figure 2: Imagens do Banco de Dados

2.3 Pré-processamento das Imagens

A etapa de pré-processamento é quando se dá o tratamento dos dados brutos para a calibração radiométrica da imagem, correção de distorções geométricas e remoção de ruído [2].

Todos os processamentos realizados neste trabalho foram executados no software MATLAB® em um computador com 8Gb de Memória de RAM, Processador Intel® Core i5 5500 (5ª Geração) com placa gráfica embutida.

As imagens do repositório foram captadas em RGB (*Red-Green-Blue*) e transformadas em tons de cinza. Com a imagem em níveis de cinza, é aplicado um Filtro de Mediana, que altera o valor de cada pixel-alvo pela mediana estatística dos valores dos pixels vizinhos, cuja função é eliminar os ruídos das imagens, suavizando-as.

O próximo passo é a aplicação de outros dois filtros visando melhorar a qualidade do objeto na imagem: (1) Filtro de Erosão e (2) Filtro de Dilatação. A operação de erosão é caracterizada pela corrosão das arestas do objeto de interesse, resultando em uma imagem encolhida do objeto e, também, sendo capaz de separar objetos e remover extrusões. Na dilatação, a área do objeto de interesse será dilatada, ou seja, o objeto do primeiro plano ficará maior do que era inicialmente, podendo também reparar quebras e intrusões. Essas operações não são inversas e, sim, duais.

O último passo do pré-processamento foi a binarização da imagem, que consiste em transformar uma imagem originalmente com 256 níveis de cinza, em apenas dois níveis: 0 (zero) e 1 (um), ou seja, preto e branco, segmentando assim a região de interesse, ou seja, separando a peça LEGO® do fundo da imagem.

2.4 Extração das Características das Imagens

Pelo motivo das peças LEGO® possuírem formas geométricas e cores bem definidas, como seu formato quadrado ou retangular e os encaixes em formato de círculo, optou-se pela extração de características geométricas e de cor.

As seguintes características geométricas foram calculadas: área, perímetro, comprimento do eixo maior e menor, ex-

centricidade, área convexa, diâmetro equivalente, extensão e área preenchida da imagem. Essas características foram escolhidas pois continham informações importantes da peça e as caracterizavam de forma eficiente.

Além desses descritores, a contagem dos encaixes de cada peça também traz uma informação importante. Muitas vezes, as peças são parecidas geometricamente, mas apresentam números diferentes de encaixe. Para a realização da contagem dos círculos, a técnica utilizada foi a transformada de *Hough*, que, segundo Backes and Sá [2], é um processo de mapeamento de cada pixel da imagem para o espaço de parâmetros. Esta técnica pode ser aplicada para detecção de formatos circulares com eficiência. O algoritmo desenvolvido detecta os círculos e faz a contagem, criando mais um descritor para caracterizar a peça. A Figura 3 mostra uma imagem do repositório com os círculos detectados em vermelho.

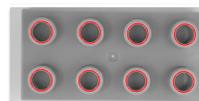


Figure 3: Imagem do banco de dados com os pontos de encaixe detectados

Outro parâmetro importante para diferenciar peças LEGO® em suas devidas aplicações são as cores. Nesta etapa, foi desenvolvido um algoritmo que, a partir da imagem em RGB, destaca uma pequena área do artefato e calcula os parâmetros de cor HSV (Hue-Saturation-Value) deste espaço [Backes and Sá 2019], conforme mostrado na Figura 4.

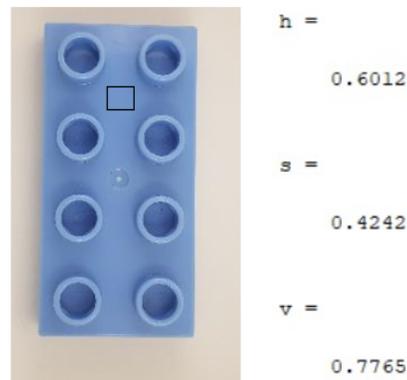


Figure 4: Cálculo de HSV das peças LEGO®

Esta técnica consiste em calcular a matiz, a saturação e o brilho, onde:

- Matiz (ou tonalidade): é o parâmetro que verifica o tipo de cor, indo do vermelho ao violeta, e tendo valores entre 0 e 360°, mas pode ser representado no intervalo entre 0 e 1;
- Saturação (ou pureza): representa a quantidade de cor branca no pixel e atinge valores entre 0 e 1;
- Brilho (ou luminância): representa a intensidade da cor e, também, é representada no intervalo entre 0 e 1.

	1	2	3	4	5	6	7	8	9	10	11	12	13
	Circulos	Area	Perimete	MajorAxisLength	MinorAxisLength	Eccentricity	ConvexArea	EquivDiameter	Extent	FilledArea	Hue	Saturation	Lightness
1	8	743.7670	12803	347.2836	178.2428	0.8582	33032	127.6765	0.3805	32647	0.6035	0.4583	0.5647
2	8	764.3720	21548	321.4942	172.8368	0.8432	34909	165.6375	0.3220	34402	0.6070	0.5278	0.7059
3	8	763.4410	21030	320.6403	170.4579	0.8470	34275	163.6344	0.3659	33626	0.6027	0.4649	0.7255
4	8	763.5640	20802	321.5305	169.6992	0.8494	34099	162.7450	0.3818	33419	0.6024	0.4826	0.6745
5	8	747.7780	14676	330.3415	172.2555	0.8533	33361	136.6970	0.4360	32958	0.5985	0.4293	0.8039
6	8	772.4030	20583	321.3370	169.8324	0.8489	34275	161.8860	0.4158	33529	0.6027	0.4410	0.7647
7	8	1.0752...	6112	344.5680	129.7589	0.9264	26450	88.2159	0.1756	6291	0.6012	0.4242	0.7765
8	8	762.2290	21807	324.9225	172.6543	0.8471	35225	166.6299	0.3398	34576	0.5974	0.4320	0.8078
9	9	2.0651...	21211	324.9391	173.1853	0.8461	35317	164.3371	0.2989	22894	0.5949	0.4851	0.5255
10	8	759.1190	21892	318.2623	173.1393	0.8391	34759	166.9544	0.3323	34346	0.6008	0.4332	0.7333

Figure 5: Características extraídas das peças LEGO®

A Figura 6 mostra a representação geométrica do espaço de cores HSV. Existem outros modelos de cores como CMY, CMYK e HSL. No entanto, por ser o mais usado, optou-se pela utilização do HSC nesta pesquisa.

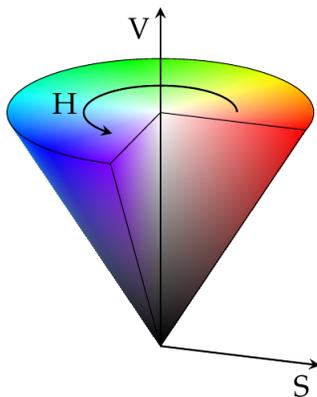


Figure 6: Representação geométrica do espaço de cores HSV

[10]

A partir dos descritores gerados de cada imagem, foi montado um novo banco de dados contendo apenas essas informações. A Figura 5 mostra, como exemplo, a matriz com os 13 (treze) descritores gerados para 10 (dez) imagens de uma mesma peça. Pode-se observar que ocorrem alguns erros em determinados parâmetros, mas, devido à variedade de descritores escolhidos, outros valores ajudam a manter as características da peça.

2.5 Classificação das imagens

A classificação de dados ocorre quando um objeto precisa ser designado como pertencendo a uma determinada classe baseando-se em seus atributos. Neste trabalho, optou-se por utilizar Redes Neurais Artificiais (RNA) pelas suas características, tais como acuidade, velocidade, robustez e interpretabilidade, necessárias na tarefa proposta. As RNAs são modelos matemáticos computacionais baseados na estrutura neural de organismos inteligentes que adquirem conhecimentos através da experiência [12].

No processo de classificação das imagens das peças LEGO®,

foram utilizadas redes do tipo *Perceptron* com Múltiplas Camadas (MLP). As redes MLP consistem em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, conforme a Figura 7. É do tipo *feedforward*, ou seja, a saída de um neurônio da camada i não pode ser usada como entrada em neurônios de camadas com índice igual ou menor que i .

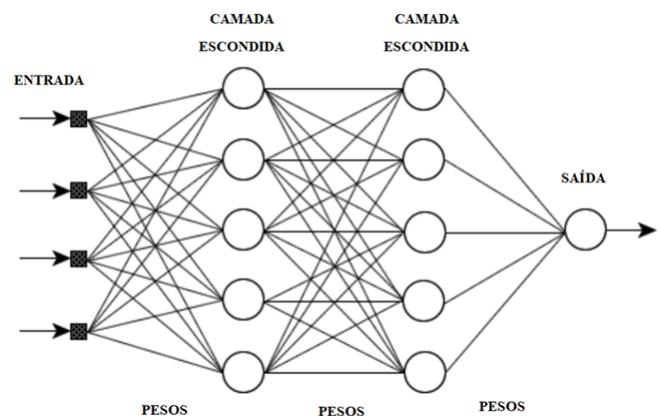


Figure 7: Arquitetura da rede MLP

Neste trabalho, foi utilizada uma rede MLP com 1 (uma) camada escondida, o que é suficiente para aproximar qualquer função contínua [7]. Foram 13 (treze) neurônios na camada de entrada, 10 (dez) neurônios na camada escondida e 5 (cinco) neurônios na camada de saída. O número de neurônios na camada de entrada se refere à quantidade de descritores de cada imagem. O número de neurônios na camada escondida foi testado e o valor apresentado foi o que demonstrou melhor desempenho da rede. Já o número de neurônios da camada de saída se deve ao fato de terem sido escolhidas 5 (cinco) peças para teste, ou seja, a quantidade de opções para classificação. A Figura 8 mostra a arquitetura da rede utilizada mostrada pelo MATLAB®.

Os dados foram separados em 70% para treinamento, 15% para validação e 15% para teste. Esses valores foram escolhidos por apresentarem o melhor desempenho da rede.

O algoritmo escolhido foi o *backpropagation*, que é um algoritmo com paradigma supervisionado e é um dos mais utilizados e o mais importante em redes neurais artificiais. Sua principal vantagem é que ele trabalha com múltiplas

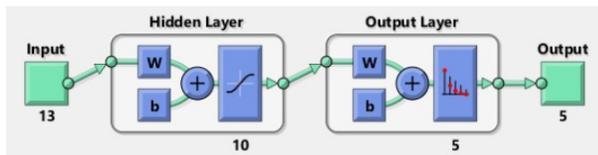


Figure 8: Arquitetura da rede MLP utilizada no software MATLAB®

camadas e resolve problemas não-linearmente separáveis. A função de ativação usada para treinamento da rede foi a Tangente Hiperbólica. Essa função logística tem variação de -1 a 1, centrada em zero, o que leva a uma melhor convergência da rede.

3. RESULTADOS E DISCUSSÕES

Para análise dos resultados são apresentadas a Matriz de Confusão e o Gráfico ROC.

Uma ferramenta útil e muito usada para a avaliação do desempenho do algoritmo de classificação de dados em aprendizagem de máquinas é a matriz de confusão, que analisa como um classificador pode reconhecer registros de diferentes classes. Uma matriz de confusão de m classes é uma tabela M de tamanho $m \times m$, onde uma entrada M_{ij} indica o número de registros da classe i que foi rotulado pelo classificador como classe j . Para um classificador ter um bom desempenho, a maioria dos registros deve ser representada ao longo da diagonal principal da matriz de confusão, com o resto das entradas sendo igual a zero.

Considerando todos os dados e processamentos apresentados no capítulo anterior, a Figura 9 mostra o resultado da classificação das peças LEGO® através da Matriz de Confusão. São apresentadas 4 (quatro) matrizes: de treinamento, de validação, de teste e do resultado final, respectivamente.

Como pode-se observar, em todas as fases do processo o classificador se mostrou muito eficiente acertando todas as amostras. Este resultado indica que a técnica proposta é promissora para classificação de peças onde a cor e o formato são relevantes.

Na próxima análise, foram utilizadas as curvas ROC (*Receiver Operating Characteristic*) que é uma das métricas mais utilizadas para a avaliação de um modelo de aprendizagem de máquina. Essa é uma ferramenta importante para análise de resultados de classificação e é baseada em 2 (duas) quantidades que contêm as informações: fração de *verdadeiros positivos* e fração de *falsos positivos* [5]. As frações de *falsos negativos* e *verdadeiros negativos* são os respectivos complementares. A Figura 10 mostra diversos gráficos ROC em situações distintas. A curva mais à esquerda representa a situação ideal, onde 100% do espaço é ocupado, ou seja, é capaz de distinguir os resultados negativos dos positivos. Quanto mais à direita está o gráfico, pior o processo de detecção de classe.

Na Figura 11, é possível ver os gráficos gerados a partir do processo de classificação de imagens de peças LEGO®, proposto neste trabalho. Como pode-se observar, em todos os estágios e para todas as peças, a curva ROC atingiu seu melhor resultado demonstrando a eficiência de classificação do algoritmo.

4. CONCLUSÕES

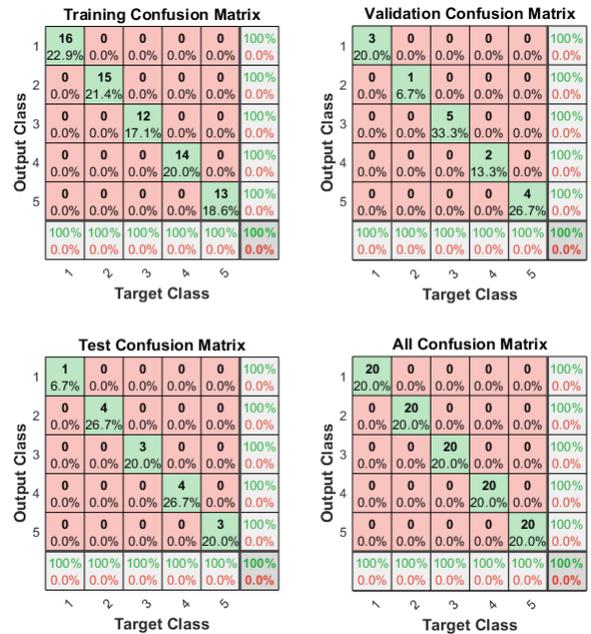


Figure 9: Matriz de confusão gerada pelo software MATLAB®

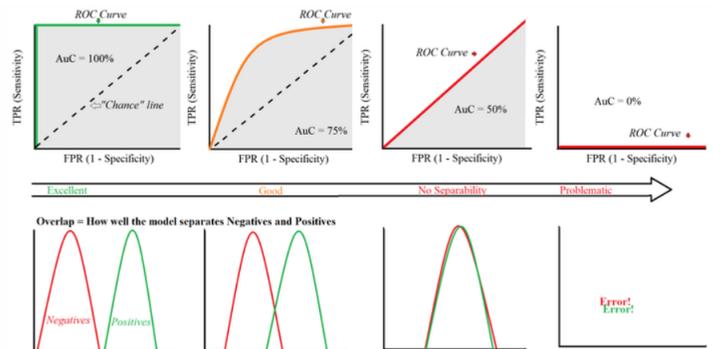


Figure 10: Gráficos de Curvas ROC [11]

O presente trabalho propôs um sistema de reconhecimento de peças LEGO® para o auxílio na aprendizagem de alunos cegos do Instituto Benjamin Constant. Este módulo de visão computacional faz parte de um sistema interativo, ainda em desenvolvimento, onde o aluno coloca a peça em uma base e tem como retorno um sistema sonoro, que indica o tipo de peça e de qual atividade ela pertence. A identificação das peças traz autonomia aos professores e proporciona novas oportunidades de aprendizagem aos alunos. Atualmente, a LEGO® lançou kits para montagem destinados a pessoas cegas, ou com baixa visão, utilizando a linguagem Braille. No entanto, nem todos os cegos dominam essa linguagem e as peças lançadas são para montagens simples, diferente dos kits LEGO® *Mindstorm Education*. Além disso, muitas instituições já possuem os conjuntos tradicionais. Por isso, um sistema de identificação de baixo custo e eficiente é muito

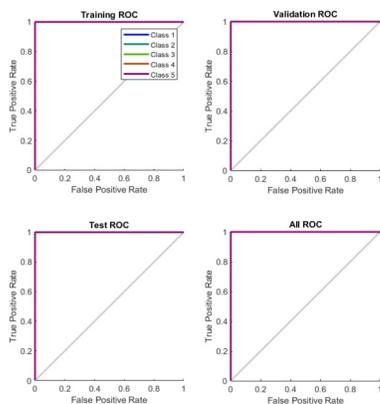


Figure 11: Gráficos de Curva ROC gerado pelo software MATLAB®

importante.

Os resultados dos testes mostraram que a utilização de descritores geométricos, de cor e transformada de *Hough* é eficiente para descrever peças com variação de formato, tamanho e cor. Além disso, o algoritmo de redes MLP proposto foi eficaz para a classificação, resultando em 100% de acerto. Conclui-se, então, que o conjunto de técnicas sugeridas neste trabalho são promissoras para a aplicação a que se destina.

Como trabalhos futuros, pretende-se finalizar o sistema interativo e produzir um protótipo para ser testado com os alunos do IBC.

5. REFERENCES

- [1] M. A. F. Adam Seth Moran, John Patrick Schwamb. Developing an information system for assistive technology apps. *Worcester Polytechnic Institute*, 2018.
- [2] J. J. d. M. S. J. André Ricardo Backes. *Introdução à Visão Computacional Usando MATLAB*. Alta Books Editora, first edition, 2016.
- [3] S. Astanin, D. Antonelli, P. Chiabert, and C. Alletto. Reflective workpiece detection and localization for flexible robotic cells. *Robotics and Computer-Integrated Manufacturing*, 44:190–198, 2017.
- [4] R. Babu and D. Heath. Mobile assistive technology and the job fit of blind workers. *Journal of Information, Communication and Ethics in Society*, 15(2):110–124, 2017.
- [5] A. Braga. *Curvas ROC: aspectos funcionais e aplicações*. PhD thesis, Universidade do Minho, 2001.
- [6] E. Corona, G. Alenya, A. Gabas, and C. Torras. Active garment recognition and target grasping point detection using deep learning. *Pattern Recognition*, 74:629–641, 2018.
- [7] G. Cybenko. Continuous valued neural networks with two hidden layers are sufficient, 1988. University of Illinois at Urbana -Champaign.
- [8] D. C. A. de Assis. O caminhar da pessoa cega: análise da exploração de elementos do espaço urbano por meio da bengala longa. Master's thesis, Universidade Federal de Alagoas, dec 2017.
- [9] B. E. Dicianno, J. Joseph, S. Eckstein, C. K. Zigler, E. J. Quinby, M. R. Schmeler, R. M. Schein, J. Pearlman, and R. A. Cooper. The future of the provision process for mobility assistive technology: a survey of providers. *Disability and Rehabilitation: Assistive Technology*, 14(4):338–345, Mar. 2018.
- [10] A. F. M. Duarte. Reconhecimento de objetos baseado em visão artificial. Master's thesis, Universidade do Porto, 2015.
- [11] S. Glen. Roc curve explained in one picture. In <https://www.datasciencecentral.com/profiles/blogs/roc-curve-explained-in-one-picture>, mar 2019.
- [12] S. Haykin and S. Haykin. *Neural Networks and Learning Machines*. Prentice Hall, 2009.
- [13] J. Krüger, J. Lehr, M. Schlüter, and N. Bischoff. Deep learning for part identification based on inherent features. *CIRP Annals*, 2019.
- [14] P. C. d. A. M. R. M. A. L. R. F. d. C. G. M. d. S. Paula Marciana Pinheiro de Oliveira, Lorita Marlina Freitag Pagliuca. Tecnologia assistiva sobre amamentação para pessoas com deficiência visual: comparação brasil e portugal. *Texto & Contexto-Enfermagem*, 27(3), 2018.
- [15] S. Pradhan and M. Samanta. Use of assistive technology in blind schools of west bengal: A comparative study. *Library Philosophy & Practice*, 2018.
- [16] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, et al. Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3):211–252, 2015.
- [17] M. Schlüter, C. Niebuhr, J. Lehr, and J. Krüger. Vision-based identification service for remanufacturing sorting. *Procedia Manufacturing*, 21:384–391, 2018.