

# Reconhecimento de Sinais de Trânsito Utilizando Deep Learning

Marcos Vinicius Oliveira Sobrinho<sup>1</sup>, Matheus Chaves Menezes<sup>1</sup>

<sup>1</sup>Universidade Federal do Maranhão - UFMA  
São Luis – MA – Brasil

***Resumo.** Sinais de trânsito são de extrema importância para a harmonia no trânsito para quem vive em grandes cidades. É de extrema importante respeitá-los, pois um descuido pode levar a graves problemas como acidentes fatais. Este trabalho descreve a criação de um modelo para fazer classificação de sinais de trânsito em placas utilizando a técnica de Deep Learning. Foi criada uma base sintética dos sinais para o treino do modelo através de técnicas de processamento de imagem. Os testes iniciais mostraram um desempenho razoável para o classificador.*

## 1. Introdução

Para quem vive nos centros urbanos é perceptível o aumento do número de veículos, devido ao tempo gasto, cada vez maior, de horas diárias no trânsito. Assim como crescem os números de carros, crescem também o aumento de acidentes com vítimas no trânsito, sendo um dos principais motivos a imprudência no trânsito. Sistemas computacionais são utilizados diariamente como auxiliares por diversos profissionais. Este trabalho propõe a utilização de um modelo treinado de técnicas de aprendizado de máquina para o reconhecimento de sinais de trânsito. O objetivo é a apresentação da técnica deep learning, e a possibilidade de sua utilização no reconhecimento de sinais de trânsito.

## 2. Referencial Teórico

Aprendizado de máquina é uma área de Inteligência Artificial cujo objetivo é o desenvolvimento de técnicas computacionais sobre o aprendizado bem como a construção de sistemas capazes de adquirir conhecimento de forma automática. Através das experiências acumuladas, esse sistema de aprendizado consegue encontrar soluções mais eficientes a problemas [Bishop, 2004]. A área de aprendizado de máquina desenvolveu-se rapidamente através dos estudos de reconhecimento de padrões, e se transformando na base da análise preditiva.

Entre as diversas variações de Aprendizado de Máquina, uma das que mais ganhou destaque é o Deep Learning, que é o conjunto de múltiplas tarefas de aprendizado de máquina que lida com diferentes tipos de abstração, sendo que sua característica mais marcante é a resolução de problemas a partir de estruturas de representação dos dados de diferentes maneiras [Deng 2004]. O objetivo principal da utilização do Deep Learning é fazer com que o objetivo de Inteligência Artificial seja finalmente alcançado, através de uma simulação de neurônios de uma rede neural convolucional de diversas camadas [Dee ].

Redes neurais artificiais são inspiradas no modelo biológico de 1959 proposto por David H. Hubel e Torsten Wiesel, que encontrou dois tipos de células no córtex visual


primário: celular simples e complexas. Grande parte das redes neurais artificiais são vistas como modelos em cascata dos tipos de células inspirados por estas observações biológicas. Desde a descoberta do algoritmo de ‘back-propagation’, pesquisadores tentam treinar redes neurais artificiais profundas, este métodos supervisionados geraram o primeiro reconhecedor artificial de padrões a alcançar a performance humana-competitiva em certas tarefas.

### 3. Metodologia

Este trabalho foi conduzido em duas partes. A primeira foi a aquisição da base de dados dos sinais de trânsito e a segunda foi a geração de modelo treinado para classificação destes sinais. É comum em trabalhos de classificação e aprendizado de máquina que as bases de dados sejam adquiridas de forma manual e em grande quantidade para que não haja classificações errôneas no modelo, principalmente se este modelo necessitar de grande acurácia em seus resultados. Esse processo pode ser demorado e, para que se tenha um bom resultado, geralmente é necessária uma grande quantidade exemplos adquiridos, tornando o trabalho até inviável a curto prazo. A nossa solução para este problema foi a criação de uma base de dados sintética [Greenhalgh and Mirmehdi 2002].

#### 3.1. Geração da Base de Dados

As imagens que nós utilizamos para a criação da base foram obtidas da base de dados online do Departamento de Transporte do Maranhão [Det ]. Para este trabalho, nós usamos 19 imagens-classes. A Figura 2 exibe todas as classes que foram utilizadas para classificação. Para cada classe, foram geradas 1300 novas imagens sintéticas e cada uma sofreu distorções geométricas aleatórias para que se assemelhassem com exemplos manualmente adquiridos. Após a aplicação das distorções, cada imagem foi sobreposta a uma outra imagem de fundo. As imagens de fundo foram retiradas manualmente e um total de 32 imagens foram utilizadas. Depois de sobrepor as duas imagens, foram aplicados efeitos aleatórios de brilho, contraste, borrões e ruídos, afim de termos uma base robusta para classificação de sinais de trânsitos. Cada imagem foi salva em uma proporção de 28x28 pixels cada e em escala de cinza. A Figura 1 mostra uma comparação da base de dados gerada sinteticamente e imagens manualmente capturadas para teste.



**Figura 1. Em cima: imagens manualmente adquiridas. Em baixo: imagens criadas artificialmente**

#### 3.2. Classificação dos Sinais de Trânsito

Para a classificação dos sinais de trânsito, utilizamos o modelo LeNet-5 [LeCun 1998], este modelo de Rede Neural Convolutiva utiliza técnicas de Deep Learning para treinar e gerar nosso modelo de classificação utilizando como Solver o Stochastic gradient

descent (SGD) e uma base de aprendizado rácio de 0.01. O treinamento do modelo foi realizado utilizando o framework Digits [Dig ] com o Solver Stochastic gradient descent (SGD). Foram utilizadas 24.700 imagens para o treino da rede, com 25 % para validação cruzada.



Figura 2. Classes utilizadas para o treino da rede

#### 4. Resultados

Para validar o trabalho, nós o testamos o modelo com 21 imagens manualmente adquiridas e classificadas. A Figura 3 mostra a matriz confusão da classificação. A acurácia do modelo para as 21 imagens testadas foi de 81,82 %.

Confusion matrix

	12	13	14	15	16	18	19	20	21	22	23	24	25	26	27	28	29	5	9	Per-class accuracy
12	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100.0%
14	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100.0%
15	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100.0%
16	0	1	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	66.67%
18	0	1	0	0	1	2	0	0	0	0	0	0	0	0	0	0	0	0	1	40.0%
20	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	100.0%
24	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	100.0%
28	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	100.0%
29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	100.0%
9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	100.0%

Figura 3. Matriz confusão das imagens testadas

Inicialmente, a baixa quantidade de imagens para teste não reflete ainda o poder de abstração e classificação do modelo. Uma das próximas etapas para validar este modelo é obter mais imagens para testes de todas as classes. Nas imagens testadas, alguns exemplos não foram classificados corretamente devido ao alto ruído na imagem, mostrando que a base sintética não conseguiu abranger todas as situações de possíveis classificações do modelo. Outro exemplo de classificação errônea foi devido a alta angulação da placa.

#### 5. Conclusão

O trabalho aprendeu um modelo de classificação de sinais de trânsito brasileiro utilizando a técnica de Deep Learning. Preliminarmente, os resultados foram positivos devido

a acurácia obtida com o classificador, porém, devido a limitação que houve no teste do modelo, ainda não é possível afirmar que o classificador é robusto utilizando uma base de treino sintética. Como trabalhos futuros, mais imagens para testes serão obtidas para uma validação mais precisa. Técnicas de captura dessas placas já são possíveis de forma automática e isso é sugerido também como próximas etapas.

## Referências

Deep learning. <http://neuralnetworksanddeeplearning.com/chap6.html>. Accessed: 2016-04-19.

Departamento nacional de trânsito. <http://www.detran.ma.gov.br/>. Accessed: 2016-04-19.

Nvidia digits. <https://developer.nvidia.com/digits>. Accessed: 2016-04-19.

Deng, L. (2004). "deep learning: Methods and applications". In *BISHOP, C.M. Pattern Recognition and Machine Learning*. Amazon.com.

Greenhalgh, J. and Mirmehdi, M. (2002). Real-time detection and recognition of road traffic signs. In IEEE, editor, *IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS*. IEEE.

LeCun, Y. (1998). Gradient-based learning applied to document recognition. In IEEE, editor, *Proceedings of the IEEE*. IEEE.