



Reconhecimento de Sinais de Trânsito Utilizando Deep Learning

Marcos Vinícius Oliveira Sobrinho e Matheus Chaves Menezes

Universidade Federal do Maranhão – mv.olsob@gmail.com, matheuschavesmenezes@gmail.com

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.

Materiais e métodos

Para o desenvolvimento do classificador de sinais de trânsito, utilizamos técnicas de processamento de imagem para criação da base sintética e técnicas de aprendizagem de máquina para treinar o classificador.

Criação da base sintética

Para este trabalho, foram usadas 19 imagens-classes. A Figura 01 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 trânsito. A figura 02 mostra uma comparação da base de dados gerada sinteticamente e imagens manualmente capturadas para teste.



Figura 01. Placas usadas para a Classificação




Figura 02. Em cima: reais. Em baixo: imagens sintéticas

Técnicas de Aprendizado de Máquina e Classificação

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

Resultados

Para validar o trabalho, nós o testamos o modelo com 21 imagens manualmente adquiridas e classificadas. A Figura 03

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.

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.