

TRAFFIC SIGN CLASSIFICATION USING DEEP LEARNING

Marek Sicha

Bachelor Degree Programme (3), FEEC BUT

E-mail: xsicha02@stud.feec.vutbr.cz

Supervised by: Tomáš Bravenec

E-mail: xbrave01@vutbr.cz

Abstract: The thesis focuses on the classification of traffic signs in images and video sequences. The goal is real-time processing and usage of software in the vehicle. Neural networks and the Python programming language were chosen to solve the problem. To solve the problem a machine learning method was chosen, more precisely a convolutional neural network. A neural network in the Python programming language was created for the classification of traffic signs, using the Keras and Tensorflow libraries. The neural network architecture is chosen for optimization for use on a single-board computer with limited performance.

Keywords: classification, neural networks, traffic signs

1 ÚVOD

Tato práce se zabývá rozpoznáváním dopravních značek v obraze. Detekce a rozpoznávání dopravních značek je jeden z hlavních předpokladů pro vytvoření autonomního řízení automobilů. Samozřejmě detekce a rozpoznávání dopravních značek není jenom čistě pro autonomní řízení aut. Může být použito i jako jeden z základních asistenčních prvků pro dopravní prostředky, ve kterých je stále ještě řidič člověk. Tento asistenční prvek by mohl upozornit řidiče např. na překročení maximální rychlosti nebo přehlednutí zákazové značky a včas zabránit dopravní nehodě.

Cílem této práce je navrhnout systém pro klasifikaci dopravních značek využívající konvolučních neuronových sítí se zaměřením na efektivitu výpočtu, pro možnost využití systému v automobilu.

Pro vytvoření softwaru byl zvolen programovací jazyk Python, který obsahuje nespočet knihoven pro úpravu vstupních datových sad. Datové sady jsou nedílnou součástí pro vytvoření neuronové sítě klasifikátoru. Vytvoření klasifikátoru bylo za pomoci neuronových sítí, které jsou v dnešní době stále populárnější a to díky stále rostoucímu výpočetnímu výkonu.

2 KLASIFIKACE DOPRAVNÍCH ZNAČEK

Klasifikátory slouží k rychlé identifikaci v předem vyznačené části obrázku. Pokud tedy chceme klasifikovat dopravní značky v reálném čase například z dopravní kamery, je nutné nejprve daný obrazový signál zpracovat vhodným detektorem, který nám určí oblast, ve které se dopravní značka nachází. Klasifikátory jsou tedy takový podpůrný prostředek pro detektory a z pravidla mají jednoduchou architekturu, ale vysokou pravděpodobnost klasifikace daného objektu, tedy dopravní značky.

2.1 METODY KLASIFIKACE DOPRAVNÍCH ZNAČEK

Způsoby jak klasifikovat dopravní značky můžeme rozdělit do dvou kategorií.

První kategorie jsou metody, které jsou založeny na klasifikaci podle tvaru nebo barev výhodou této metody je, že dopravní značky mají své specifické barvy a tvary, které se běžně v přírodě nevysky-

tují. Dalším způsobem je porovnání dopravní značky s již existující databází značek, nevýhoda této metody je její časová náročnost a problém s rozpoznáváním deformovaných dopravních značek. [6]


Jako další metody jsou metody strojového učení, neboli vytvoření neuronové sítě. Při vytváření neuronové sítě je potřeba dataset, podle kterého se síť naučí specifické prvky pro dané třídy. Neuronová síť dostane vstupní data, podle výstupních dat sítě a dat, které jsme očekávali, určí chybu a provede korekci. Nově nastaví hodnoty prahů a vah. Celý tento cyklus opakuje do chvíle, dokud nenajde takovou konfiguraci prahových hodnot a vah, která odpovídá naší stanovené chybě. [1, 5] Nevýhoda této metody je pokud chceme síť rozšířit na více tříd, je nutné provést celý proces učení znovu, zatímco při porovnávacích metodách se připíše jen pár podmínek.

3 KLASIFIKÁTOR DOPRAVNÍCH ZNAČEK

Pro vytvoření klasifikátoru byla zvolena metoda strojového učení, přesněji konvoluční neuronová síť. Model neuronové sítě klasifikátoru byl vytvořen pomocí knihovny Tensorflow, jejíž novější verze již obsahují knihovnu Keras v základním balíčku. Výhoda knihovny Tensorflow je její podpora pro jednodeskové počítače.

3.1 ARCHITEKTURA KLASIFIKÁTORU DOPRAVNÍCH ZNAČEK

Zvolen byl sekvenční model, který umožňuje skládat vrstvy lineárně za sebe, každá vrstva je propojena jen s předchozí a následující vrstvou. Mimo to také obsahuje jen jeden vstup a výstup, což pro klasifikaci dopravních značek není žádné omezení. [2]



Obrázek 1: Architektura klasifikátoru.


Vstupní obrázek klasifikátoru je o rozměrech 32x32x1, obrázek je ve stupních šedi. Následuje série konvolučních a sdružovacích vrstev viz obrázek 1. V architektuře jsou použity dvě dropout vrstvy, které se uplatňují jenom při trénování sítě. Zabraňují přetrénování sítě, tím že náhodně nastaví vstup pro další vrstvu na 0. Poslední část architektury jsou plně propojené vrstvy, poslední vrstva obsahuje 43 uzlů, což odpovídá počtu tříd. Aktivační funkce poslední vrstvy je softmax, které se používá pro jedno třídovou identifikaci, určuje pravděpodobnost, že objekt spadá do určité třídy, součet všech pravděpodobností tříd je 1. [2] Až na poslední vrstvu, která má funkci softmax, jsou použity aktivační funkce ReLU, jejíž výhodou je její jednoduchost, oproti jiným funkcím neuvažuje záporné hodnoty.

Optimalizátor je algoritmus, který mění hodnoty neuronové sítě, jako jsou váhy a míra učení, aby ztráty byly co nejmenší. V této architektuře byl použit optimalizátor Adam, který používá metodu gradientního sestupu. Metoda spočívá ve výpočtu první derivace ze ztrátové funkce a podle toho předpovídá, jak by se měli váhy měnit, aby funkce mohla dosáhnout minima. [4] Metoda je výpočetně efektivní, má malý požadavek na paměť.

Ztrátová funkce vyjadřuje aktuální ztrátu sítě během trénování. Výstupem funkce jsou ztráty, které určují rozdíl mezi předpokládaným výstupem a daným výstupem neuronové sítě. Pro klasifikaci do více než dvou tříd se používá funkce Categorical Cross-entropy, kdy každé třídě odpovídá jeden výstupní neuron.

3.2 TRÉNOVÁNÍ KLASIFIKÁTORU

Trénování klasifikátoru bylo provedeno na Německém datasetu pro klasifikaci značek, který obsahuje kolem 30 tisíc obrázků značek ve 43 různých třídách. Dataset byl rozdělen na tři množiny, pro trénování bylo použito 20 tisíc obrázků, testovací množina obsahuje 3 tisíce snímků a ověřovací množina 5 tisíc obrázků. Trénování bylo provedeno pro 30 cyklů, kdy do každého cyklu vstupovaly všechny obrázky z množiny pro trénování. Trénování bylo provedeno, jak pro model ve stupních šedi, tak i pro model v RGB. Dále je použit model pracujících ve stupních šedi, a to z důvodu menšího počtu parametrů, a tedy menší náročnosti na výpočetní výkon. Snížením výpočetního výkonu jsme ale nesnížili přesnost klasifikace, protože oba modely dosahovali stejných výsledků. Pro model byly v průběhu trénování tvořeny grafy pro zobrazení jeho přesnosti a ztrát pro každý cyklus viz obrázek 2.



Obrázek 2: Přesnost a ztráty klasifikátoru v průběhu trénování.

Přesnost a ztráty byly zaznamenávány pro každý cyklus trénování, podívejme se nejdříve na přesnost, přesnost klasifikátoru trénovací sady je již po třech cyklech přes 90 %, pro ověřovací sadu je to již po prvním cyklu. Průběh odpovídá rostoucí logaritmické funkci, která dosahuje po 30 cyklech přesnosti až 99 %, jak pro testovací, tak i pro ověřovací sadu. Průběh ztrát má opačný charakter, průběh pro trénovací sadu je klesající logaritmická funkce, pro kterou jsou ztráty na konci trénování menší než 0,3 pro trénovací sadu, pro ověřovací sadu jsou ztráty pod 0,2.

3.3 TESTOVÁNÍ KLASIFIKÁTORU

Vstupní obrázek nejprve prochází úpravami, tak aby se shodoval s obrázky, které byly použity při testování. Nejprve je změněn jeho rozměr na 32x32, poté je převeden do stupňů šedi a je změněn jeho kontrast.



Class: Hlavní cesta (v obci)
Probability : 99.9%

Obrázek 3: Příklad správné klasifikace.

Na obrázku 3 je uveden příklad správné klasifikace. Dopravní značka pro klasifikaci je značně ovlivněna světelným vlivem v tomhle případě se jedná o sluneční svit a v jejím středu se nachází objekt, který není součástí tohoto typu dopravní značky, i tak ale klasifikátor určil správně typ značky s pravděpodobností blízkou se ke 100 %. Ve srovnání s přesnostmi ostatních systémů testovaných nad

Tabulka 1: Srovnání přesností navrženého systému klasifikace s ostatními řešeními

	Metoda	Úspěšnost klasifikace
Navržené řešení	Konvoluční Neuronová síť	99,54 %
IDSIA	Konvoluční Neuronová síť	99,46 %
sermanet	Konvoluční Neuronová síť	98,31 %
CAOR	Náhodný les	96,14 %

stejným datasetem vychází navržená neuronová síť nejlépe. Srovnání úspěšnosti klasifikace ostatních systémů je v Tabulce 1.

Nesprávná klasifikace se v testovacím setu vyskytovala u méně než 2 % případů. A ve většině případů se správný typ značky umístí oproti s druhou nejvyšší pravděpodobností, která se od nesprávného typu lišila jen o pár desítek procent.

Testování bylo prováděno na grafické kartě Nvidia GeForce GTX 1050 Ti, kde čas pro klasifikaci jednoho obrázku se pohyboval kolem 0,1 sekundy.

4 ZÁVĚR

Cílem práce bylo prostudovat možné způsoby ke zpracování obrazových signálů, se zaměřením na klasifikaci dopravních značek v obrazech a videosekvencích. Pro dosažení tohoto cíle byla použita neuronová síť a programovací jazyk Python. Pomocí konvoluční neuronové sítě byl vytvořen klasifikátor dopravních značek, pro model ve stupních šedi. Klasifikátor byl trénován i testován na německém datasetu, určený pro klasifikaci dopravních značek. Úspěšnost klasifikace modelu testovacího datasetu se pohybuje kolem 99,5% a čas pro klasifikaci jednoho snímku je kolem 0,1 sekundy.

Datová sada použita pro trénování klasifikátoru obsahovala ve 43 třídách přes 30 tisíc obrázků, za různých světelných podmínek a pro různé deformace značek. Množina datové sady byla rozdělena do tří sad: testovací, trénovací a validační.

REFERENCE

- [1] O'Shea, Keiron & Nash, Ryan. (2015). An Introduction to Convolutional Neural Networks. ArXiv e-prints.
- [2] Keras API reference. Keras [online]. [cit. 2020-12-05]. Dostupné z: <https://keras.io/api/>
- [3] J. Stallkamp, M. Schlipsing, J. Salmen, and C. Igel. The German Traffic Sign Recognition Benchmark: A multi-class classification competition. In Proceedings of the IEEE International Joint Conference on Neural Networks, pages 1453–1460. 2011.
- [4] Overview of various Optimizers in Neural Networks. Towardsdatascience [online]. June 9 [cit. 2020-12-05]. Dostupné z: <https://towardsdatascience.com/overview-of-various-optimizers-in-neural-networks-17c1be2df6d5>
- [5] Yamashita, R., Nishio, M., Do, R.K.G. et al. Convolutional neural networks: an overview and application in radiology. Insights Imaging 9, 611–629 (2018). <https://doi.org/10.1007/s13244-018-0639-9>
- [6] Saadna, Yassmina & Behloul, Ali. (2017). An overview of traffic sign detection and classification methods. International Journal of Multimedia Information Retrieval. 6. 1-18. 10.1007/s13735-017-0129-8.