Počítání vozidel v statickém obraze

Autor: Ondřej Zemánek
Vedoucí: prof. Ing. Adam Herout, Ph.D.

#31

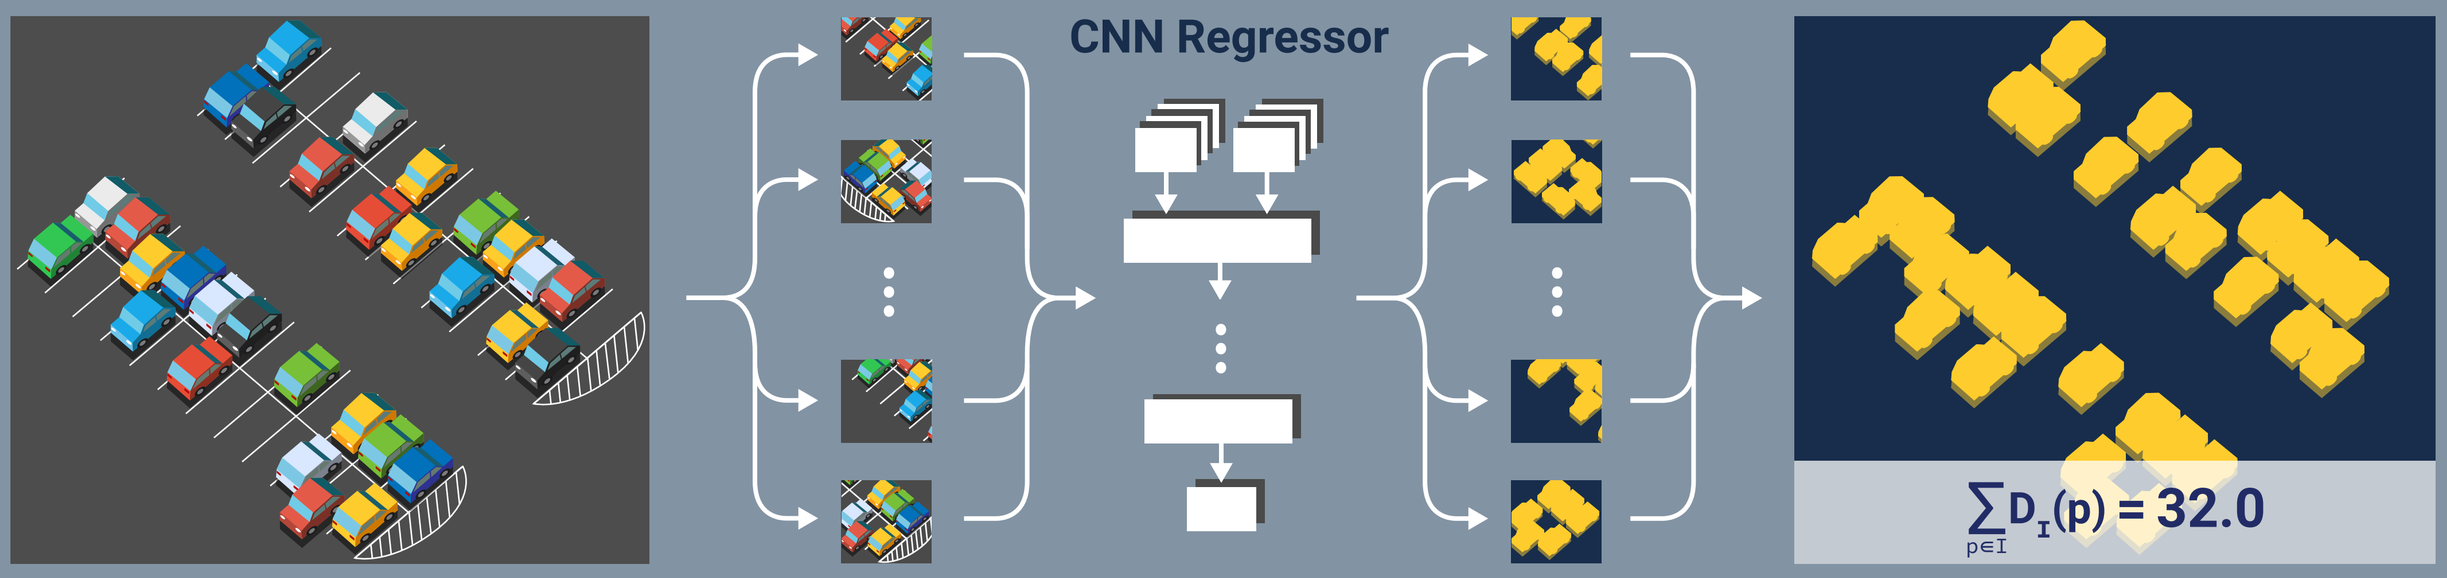

Motivace

Monitorování obsazenosti parkoviště, dlouhodobá analýza hustoty dopravy na silnicích, informovaní řidičů o počtu volných míst na odstavných parkovištích u dálnic, a další možné aplikace lze postavit na řešení počítání vozidel z obrazu.

Zvolený přístup

Pro počítání vozidel byl zvolen přístup predikce mapy hustoty objektů ve vstupním obraze, kdy se provádí transformace vstupního snímku na mapu hustoty objektů. Oproti přístupu počítání s pomocí klasifikace jednotlivých objektů v obraze dosahují metody postavené na tomto přístupu lepších výsledků, co se týče generalizace predikce. Tento přístup je robustní vůči komplikovanějším scénám, které obsahují překrývající se objekty, částečně vyditelné objekty nebo mají jinou perspektivu než snímky trénovacího datasetu.

Použité metody

Counting CNN – sekvenční plně konvoluční neuronová síť se 6 konvolučními vrstvami

Hydra CNN – paralelní zpracování vstupního snímku z více měřítek. Architektura má několik tzv. hlav – inspirace mytologickou zrůdou Hydra

Stacked Hourglass – několikanásobný průchod od nízko-úrovňových po vysoko-úrovňové vlastnosti vstupního obrázku

Spatial Divide-and-Conquer Network – kombinace regresivního modelu VGG16 s klasifikačními moduly. Finální odhad počtu objektů ve vstupním snímku je dán fúzí predikcí na různých úrovních přiblížení.

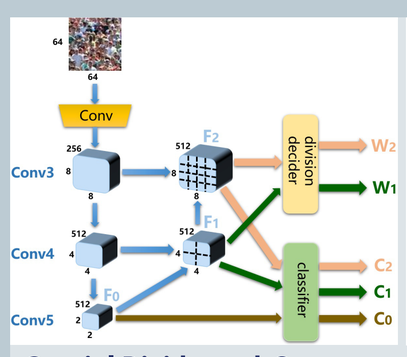

Spatial Divide-and-Conquer Network [3]

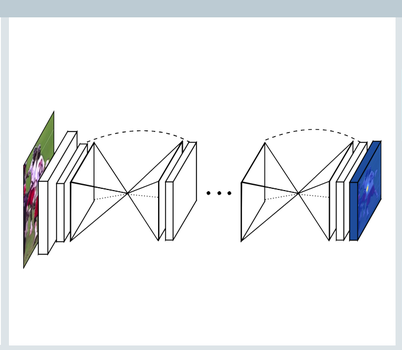

Stacked Hourglass network [1]

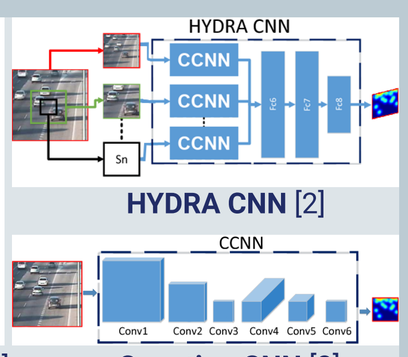

HYDRA CNN [2]

Counting CNN [2]

[1] Alejandro Newell. Stacked hourglass networks for human pose estimation.
[2] Daniel Onoro-Rubio. Towards perspective-free object counting with deep learning.
[3] Haipeng Xiong. From open set to closed set: Counting objects by spatial divide-366and-conquer.

Vlastní dataset

Existující datasety mají jen pár pohledů s podobnými parametry a pohledy. Vlastní dataset byl nafocen především k ověření schopnosti generalizace predikce napříč různými scénami s různými vlastnostmi.

Dataset obsahuje přes 19 000 nafocených snímků ze 7 různých scén a 12 různých pohledů celkem z toho více jak 3 000 snímků je anotováno.

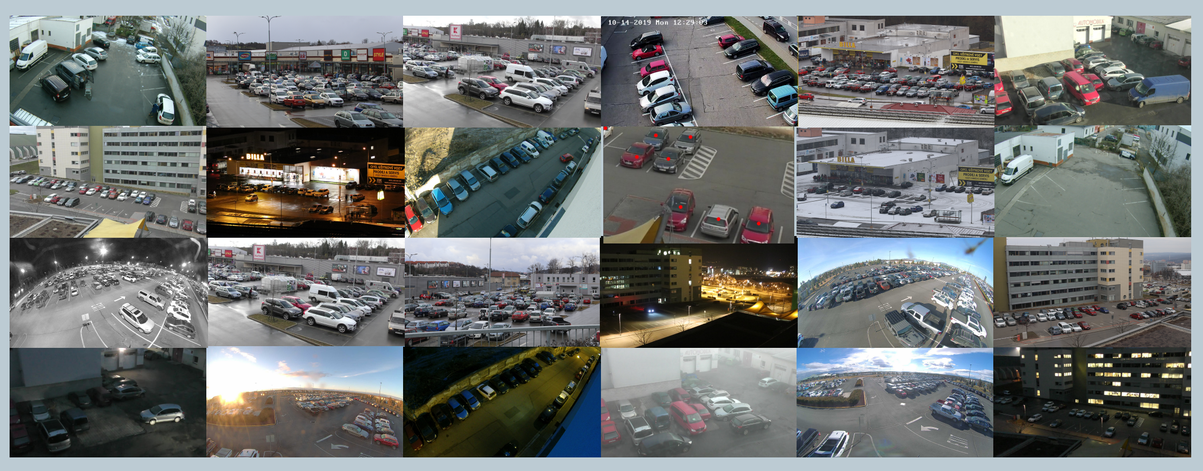

Experimenty a výsledky

Všechny použité metody byly uzpůsobeny pro počítání vozidel a následně byly natrénovány a vyhodnoceny na referenčním datasetu TRANCOS. Pro vyhodnocení byla použita metrika Grid Average Mean Error (GAME), vyjádřená následujícím vzorcem:

$$GAME(L) = \frac{1}{N}\sum_{n=1}^{N}\left(\sum_{l=1}^{4^L}|C^l_{pre} - C^l_{gt}|\right).$$

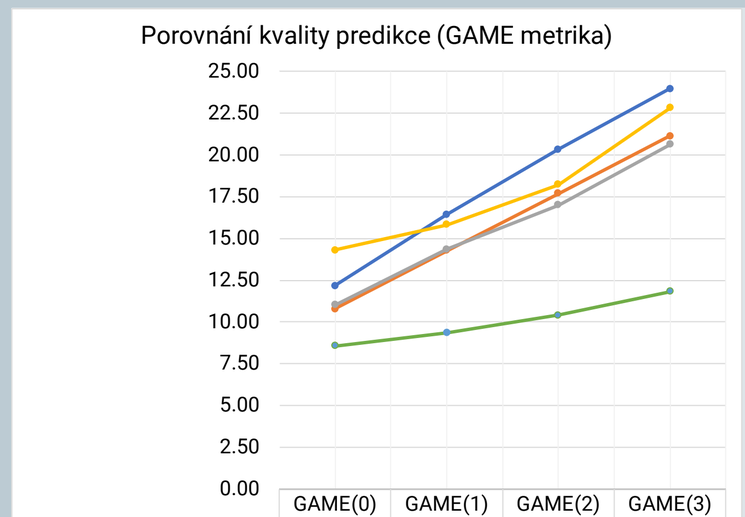

	GAME(0)	GAME(1)	GAME(2)	GAME(3)
CCNN	12.18	16.44	20.35	23.97
Hydra 2s	10.77	14.28	17.69	21.13
Hydra 3s	11.02	14.37	17.01	20.64
Stacked-Hourglass 2s	14.30	15.84	18.23	22.81
S-DCNet	8.57	9.36	10.40	11.83

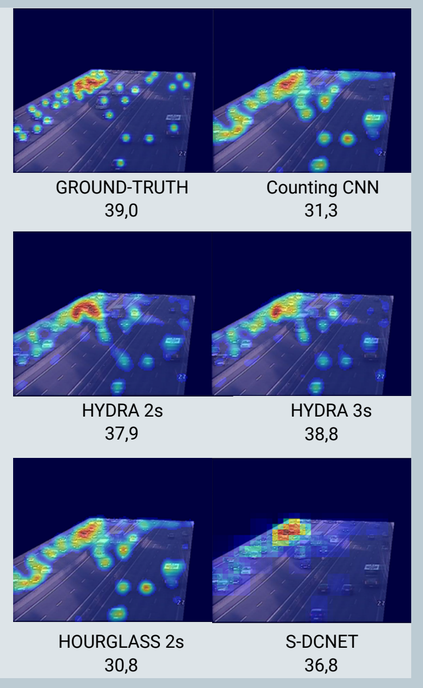

Excel@FIT

FIT