

# Posudek oponenta na bakalářskou práci

**Student:** Petr Šebek

**Název práce:** Weakly Supervised Data Augmentation for LiDAR Based 3D Object Detection

**Autor posudku:** Ing. David Hurych Ph.D.

## Formální a jazyková úroveň práce

Práce je dobře čitelná, obsahuje dostatečné množství podpůrných obrázků a schémat napomáhajících pochopení problému. Autor se vyhýbá formálnějšímu popisu pomocí vzorců a algoritmů. Velmi by to pomohlo čtenáři v rozluštění mnohoznačnosti slovního popisu postupů.

## Struktura a členění práce

Práce je dobře členěna a používá standardní strukturu technicky psaných článků.

## Přehled dostupné literatury a relevantních zdrojů

Práce cituje několik základních metod augmentace point cloudu (rotace, translace, šum, ...). Nicméně chybí diskuze pokročilejších metod, například použití generativních neuronových sítí [1, 2].

[1] Chun-Liang Li, Manzil Zaheer, Yang Zhang, Barnabás Póczos, Ruslan Salakhutdinov: *Point Cloud GAN*, ICLR 2019

<https://chunliangli.github.io/docs/19iclrPCGAN.pdf>

[2] Ahmad El Sallab, Ibrahim Sobh, Mohamed Zahran, Nader Essam: *LiDAR Sensor modeling and Data augmentation with GANs for Autonomous driving*, CoRR 2019

<https://arxiv.org/pdf/1905.07290.pdf>

## Způsob řešení a tvůrčí zpracování

Nově navržené metody augmentace datasetu považuji za zajímavé a relevantní ke studované tématice a povaze dat.

Při informované augmentaci např. pomocí vložení vozidla do scény tuto scénu nenahradíte, ale zkopírujete a do kopie vložíte nový vzorek. Původní scéna a její původní statické i dynamické objekty jsou zkopírovány (kromě překryvů způsobených vloženými objekty).

Při simulaci pohybu jsou odmazány pohybující se objekty a opět přidány zpět v jiné pozici ve scéně. Původní scéna je tedy v datech zdvojená, dynamické objekty jsou překresleny, nicméně statické objekty jsou také zdvojeny. Pokud tomu rozumím správně, tak vždy augmentujete všechny scény a zdvojíte tak téměř všechny

objekty a tedy nedojde k výrazné změně distribuce ostatních tříd (jiných než augmentovaných). Jak vysvětlíte například výsledky v tabulkách 4.11 (baseline), kde je výsledek pro třídu pedestrian bez augmentace Recall 0.365 Precision 0.295 a IoU 0.194 a tabulkou 4.12 ukazující výsledky po augmentaci vložení pouze **vozidel** do scény a to paradoxně výrazně zlepšilo výsledky na třídě pedestrian na Recall 0.378 Precision 0.424 a IoU 0.249? Jak je vidět v confusion table v tabulce 4.12, tak mis-labeling pedestrianu zlepšen vůči všem ostatním třídám a ne jen vůči třídě vehicle a nerozumím příčině.

Chválím srovnání výsledků práce se state of the art v tab 4.21 a 4.22. Autor také správně uvádí průměr výsledků z více běhů a různých inicializací což zvyšuje důvěryhodnost výsledků.

## Rozsah realizace

Bylo provedeno velké množství srovnávacích experimentů soustředících se na augmentaci datasetu. Až na drobné nejasnosti ve výsledcích (viz výše) si myslím, že práce přináší pěkné srovnání několika velmi základních metod augmentace datasetu se dvěma nově navrženými přístupy a zasazuje své výsledky do kontextu dalších prací.

## Splnění zadání (splnil, splnil na rámeček, nesplnil)

Zadání považuji za splněné.

## Dotazy k obhajobě

1. Při simulaci pohybu ve scéně by mělo dojít i ke změně pokrytí objektu laserovými měřeními a to jak kvůli relativní změně natočení objektu vůči senzoru, tak i vzhledem k různé vzdálenosti objektu od senzoru. Tyto dva fenomény nebyly simulovány. Vzhledem k minimálnímu pohybu při augmentaci translací objektů to lze pochopit. Při vložení objektu do různých hloubek by to přece jen mělo hrát roli. Prosím o vysvětlení, jak jste to řešil a jaký je potenciální vliv na výsledky.
2. Prosím o vysvětlení zlepšení výsledků na třídě pedestrian při augmentaci datasetu vložení objektů třídy automobil (viz komentář výše).
3. Visibilitu řešíte matematickou morfologií operací "uzavření" - to může vymazat objekty. Proč nepoužíváte např metodu convex hull? Nebo snakes (active contour)?
4. Nevíme, jestli je počet iterací = 150 správným kritériem pro zastavení učení všech modelů. Typicky je potřeba sledovat validační chybu a vybrat vhodný model k testování podle validační chyby a ne po počtu uběhnutých iterací. Je počet vzorků ve small datasetu dostatečný k natrénování modelu? Jak je zajištěno, že nedošlo k přefitování modelu?

**Návrh klasifikace:** Práci hodnotím stupněm A - výborně

V Praze dne 1.6.2021

Podpis: