

I. IDENTIFIKAČNÍ ÚDAJE

Název práce:	Weakly Supervised Data Augmentation for LiDAR Based 3D Object Detection
Jméno autora:	Petr Šebek
Typ práce:	bakalářská
Fakulta/ústav:	Fakulta elektrotechnická (FEL)
Katedra/ústav:	Katedra kybernetiky
Vedoucí práce:	Prof. Ing. Tomáš Svoboda, Ph.D.
Pracoviště vedoucího práce:	Katedra kybernetiky

II. HODNOCENÍ JEDNOTLIVÝCH KRITÉRIÍ

Zadání

náročnější

Hodnocení náročnosti zadání závěrečné práce.

Téma překračuje svojí náročností standardy pro bakalářskou práci. Student musel hodně témat nastudovat samostatně.

Splnění zadání

splněno

Posuďte, zda předložená závěrečná práce splňuje zadání. V komentáři případně uveďte body zadání, které nebyly zcela splněny, nebo zda je práce oproti zadání rozšířena. Nebylo-li zadání zcela splněno, pokuste se posoudit závažnost, dopady a případně i příčiny jednotlivých nedostatků.

Zadání práce bylo splněno. Pokročilejší metody, vkládaní a simulace pohybu, byly prozkoumány spíše povrchně, tam byl prostor určitě větší.

Aktivita a samostatnost při zpracování práce

B - velmi dobře

Posuďte, zda byl student během řešení aktivní, zda dodržoval dohodnuté termíny, jestli své řešení průběžně konzultoval a zda byl na konzultace dostatečně připraven. Posuďte schopnost studenta samostatně tvůrčí práce.

Student pracoval samostatně, na pravidelné týdenní (virtuální) schůzky přicházel připraven. Asi jedinou výtku bych měl, že hlavní kreativní úsilí přišlo relativně pozdě. Pokročilé metody, vkládání a simulace pohybu, navrhnul velmi samostatně. Přes pozdní začátek se povedlo pokročilé metody otestovat a do textu zapracovat.

Odborná úroveň

B - velmi dobře

Posuďte úroveň odbornosti závěrečné práce, využití znalostí získaných studiem a z odborné literatury, využití podkladů a dat získaných z praxe.

Student postupoval rozumně, algoritmická rozhodnutí jsou rozumně vyargumentovaná. Odborné články pochopil v dostatečné míře a vhodně na ně navázal vlastními návrhy nových metod.

Formální a jazyková úroveň, rozsah práce

B - velmi dobře

Posuďte správnost používání formálních zápisů obsažených v práci. Posuďte typografickou a jazykovou stránku.

Text práce je srozumitelný. Angličtina na úrovni, že neruší při čtení. Student se v průběhu iterací nad textem průběžně zlepšoval. Odhaduji, že další jím psaný text bude opět lepší.

Výběr zdrojů, korektnost citací

C - dobré

Vyjádřete se k aktivitě studenta při získávání a využívání studijních materiálů k řešení závěrečné práce. Charakterizujte výběr pramenů. Posuďte, zda student využil všechny relevantní zdroje. Ověřte, zda jsou všechny převzaté prvky řádně odlišeny od vlastních výsledků a úvah, zda nedošlo k porušení citační etiky a zda jsou bibliografické citace úplné a v souladu s citačními zvyklostmi a normami.

Nemám zásadních námitek, práce se citacemi je korektní. Rešerše dané oblasti určitě není kompletní, tady šlo udělat více.

Další komentáře a hodnocení

Vyjádřete se k úrovni dosažených hlavních výsledků závěrečné práce, např. k úrovni teoretických výsledků, nebo k úrovni a funkčnosti technického nebo programového vytvořeného řešení, publikačním výstupům, experimentální zručnosti apod.

Práce je přínosem, je zpracována formou, na kterou lze navázat. Git repozitář se zdrojovými kódůmi je doplněn návodem.

III. CELKOVÉ HODNOCENÍ A NÁVRH KLASIFIKACE

Shrňte aspekty závěrečné práce, které nejvíce ovlivnily Vaše celkové hodnocení.

Některé další možnosti pokročilejších metod prozkoumány bohužel nebyly. Rešeršní práce mohla být pečlivější. Student prokázal schopnost samostatně pracovat na obtížném tématu, pracoval systematicky a přicházel s vlastními návrhy řešení. Předloženou závěrečnou práci hodnotím klasifikačním stupněm **B - velmi dobré**.

Datum: 2.6.2021

Podpis:

Posudek oponenta na bakalářskou práci

Student: Petr Šebek

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

Autor posudku: Ing. David Hurých 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 považují za zajímavé a relevantní ke studované tématice a povaze dat.

Při informované augmentaci např. pomocí vložení vozidla do scény tuto scénu nenahradíte, ale zkopiujete a do kopie vložíte nový vzorek. Původní scéna a její původní statické i dynamické objekty jsou zkopirovány (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 vložením 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 pedestriana zlepšen vůči všem ostatním třídám a ne jen vůči třídě vehicle a nerozumím přičině.

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 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 rámec, 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 vložením objektů třídy automobil (viz komentář výše).
3. Visibilitu řešíte matematickou morfologii operací "uzavření" - to může vymazat objekty. Proč nepoužíváte napřímet 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: