

POSUDEK OPONENTA DIPLOMOVÉ PRÁCE

Studentka: Bc. Antonie Brožová

Název práce: Slepá dekonvoluce obrazu s prostorově proměnným konvolučním jádrem

Předložená práce se zabývá problematikou slepé dekonvoluce, ve které je cílem rekonstrukce ostrého obrazu bez znalosti tvaru konvolučního jádra – rozmařání. Jedná se o matematicky špatně podmíněnou úlohu, kterou je nutné řešit pomocí regularizace – apriorní znalosti. Práce porovnává etablovanou metodu variačního Bayese s optimalizací ELBO (evidence lower bound), která je relativně novým přístupem v této oblasti, a detailně rozebírá různé varianty těchto metod. Implementované metody aplikuje na velmi zajímavý problém nekompletního obrazu, který se například vyskytuje v rastrovací elektronové mikroskopii.

Práce je rozdělena do čtyř kapitol. V první kapitole je nadefinován problém slepé dekonvoluce a jsou ilustrovány nejčastěji používané apriorní modely obrazu a shrnutý základní přístupy řešení. Druhá kapitola detailně rozebírá bayesovský přístup ke slepé dekonvoluci včetně optimalizační metody VADAM, které je následně použita k nalezení ELBO. Ve třetí kapitole autorka práce srovnává popsané variační přístupy na synteticky rozmařaném obrazu pro tři druhy rozmařání a čtyři hladiny šumu. Vyhodnocení je provedeno jak vizuálně tak pomocí PSNR. Veškeré algoritmy jsou popsány pseudokódem. Poslední čtvrtá kapitola ukazuje nové použití metod k odhadu z nekompletního obrazu, které by umožňovalo navádět hrot rastrovacího mikroskopu do oblastí, kde je odhadován vysoký rozptyl derivací měřených dat.

Práce je napsaná věcně a někdy až možná příliš stručně. Myslím si, že čtenář, který není předem seznámen s teorií variačního Bayese, práci plně neporozumí. Naopak obeznámený čtenář je rád, že práce vede rychle k jádru problému, a hodnotí tuto stručnost kladně. Přínos studentky je v práci zřejmý a tkví v experimentálním ukázání, že ELBO přístup s VADAM optimalizací dosahuje stejných výsledků jako méně flexibilní variační Bayes s odhadem plné kovarianční matice. Práce navádí k dalšímu zkoumání nového přístupu a jeho aplikaci ve složitějších akvizičních modelech, kde standardní variační Bayes nelze použít.

Grafická úroveň práce je velmi dobrá. Velké množství tabulek s výsledky v kapitole 3 nepůsobí přehledně, ale naštěstí jsou v závěru grafy, které by však mohly být čitelnější. Je škoda že podobné grafy chybí v kapitole 4. Při čtení jsem si všiml několika překlepů, ale jejich frekvence je nízká.

Pokud bych měl hodnotit práci jako recenzent odborného článku v impaktovaném vědeckém časopise, tak bych hlavně vytknul následující: experimenty jsou provedeny na příliš malém vzorku syntetických obrazů, chybí srovnání s jinými metodami slepé dekonvoluce a nejsou ukázky na reálných datech. Některé další připomínky a otázky k zamýšlení uvádím na konci

posudku. Samotná skutečnost, že však k práci přistupuji tímto prizmatem jen potvrzuje výjimečně vysokou teoretickou a experimentální úroveň práce.

S potěšením tedy mohu konstatovat, že slečna Brožová se výborně zorientovala ve variační Bayesově teorii a souvisejících kapitolách a splnila zadání diplomové práce. Předloženou diplomovou práci tedy doporučuji k obhajobě a hodnotím ji známkou **A-výborně**.

Případné dotazy k obhajobě:

- Na str. 15 dole je uvedeno „Konvoluci lze pak zapsat v maticovém tvaru ...“. Myslím si, že diskrétní konvoluci lze vždy zapsat maticí, pokud uvažujeme konečný nosič obrazu a konvolučního jádra. Různé formy rozšiřování okraje obrazu pouze mění tvar matice a formu, jak jsou prvky do matice naskládány.
- V sekci 1.4 by mělo zaznít, že minimalizace kvadratické chyby (1.3) je ekvivalentní MAP přístupu, když se použijí odpovídající věrohodnostní a apriorní funkce.
- V kapitole 3 pro neslepou dekonvoluci byla použita metoda (3.1), která je ekvivalentní optimalizaci s jednoduchou L_2 normou obrazu. Tato metoda však rozmažává hrany a není tedy vhodná pro dekonvoluci obrazů s ostrými hranami, jako je příklad obrázku „Leny“. Výsledky neslepé dekonvoluce jsou tedy zbytečně podhodnoceny. Proč byla tato metoda použita a neuvažovala jste o metodách s TV regularizací? Navíc dekonvoluci s TV už stejně implementovanou máte, protože tvoří podmnožinu slepých dekonvolučních metod.
- Obr 3.5: Předpokládám, že se jedná o výsledky ELBO-full a ne ELBO-diag, jak je chybně uvedeno v popisku.
- V algoritmech je na konci každé iterace nelineární krok nulování záporných hodnot PSF. Zkoušela jste, jaký vliv tento krok má?
- V práci se uvádí, že algoritmus konverguje do cca 100 kroků. Nikde však není uvedeno, jaké konvergenční kritérium bylo použito.
- Můžete vysvětlit závěr v sekci 4.5 o míře poškození? Není mi hlavně jasná věta: „Minimální počet pixelů bude stanoven na 10%...“
- Několikrát je u výsledků uvedeno, že pixel v rohu se odhadl s vysokou intenzitou a obrázek působí tmavě. Z vlastní zkušenosti vím, že to můžou způsobovat špatně řešené okrajové podmínky. V každém případě, pro účely vizualizace je možné intenzity výsledku oříznout, aby tento jev nezpůsobil tmavost obrázku.
- Je trochu škoda, že se nepodařilo demonstrovat navrženou metodu na příkladu (i pouze umělém) s prostorově proměnným konvolučním jádrem.
- Výsledky ukazující odhad přesnosti (obr. 4.3) jsou velmi zajímavé. Je k dispozici víc výsledků, které by potvrdily, že odhadnutá přesnost uvnitř oblastí s detaily se opravdu chová jinak než v uniformních oblastech?

V Praze 23.1. 2021

Doc. Ing. Filip Šroubek, Ph.D.