



Posudek oponenta na bakalářskou práci

Student: Michaela Mašková

Název práce: Variační autoencoder a jeho rozšíření

Předložená práce zkoumá základní vlastnosti generativního modelu typu variačního autoencoder, reprezentovaného neuronovou sítí. Hlavním přínosem práce je odvození modelu směsi variačních autoencoderů, srovnání se základním modelem a jeho známými rozšířeními a experimentální ověření na syntetických i reálných datech.

První kapitola spojuje dvě zdánlivě nesourodé oblasti a to základní teorii Bayesovského odhadování, demonstrovanou na příkladu lineární regrese, a stručný popis principů neuronových sítí. Principiálně lze tuto část chápat jako úvod k druhé, rozsáhlejší kapitole. V ní je popsáno několik témat. První je základ metody variačního Bayes s příkladem, na kterou poté navazuje samotná teoretická část věnující se variačnímu autoencoderu. Podrobně je odvozena spodní hranice věrohodnosti modelu, kterou lze přímo optimalizovat metodami, představenými v první kapitole. Dále jsou ukázána rozšíření základního variačního autoencoderu jako Wassersteinův autoencoder a VampPrior. Nakonec je odvozen hlavní výsledek celé práce, tj. model směsi variačních autoencoderů, který je uveden včetně EM algoritmu pro jeho optimalizaci. Je zde ukázána jeho přednost při reprezentaci multimodálních distribucí. V poslední kapitole jsou provedeny experimenty na reálných datech, srovnávající použití popsaných modelů pro účel detekce anomálií. Z uvedených výsledků nejlépe vychází původní variační autoencoder, jak po stránce přesnosti detekce, tak z pohledu výpočetní náročnosti.

Bakalářská práce je napsána srozumitelným, odborným jazykem. Poskytuje edukativní úvod k celé problematice variačního autoencoderu včetně některých jeho variant a rozšíření. Teoretická část je dostatečně pokrytá, plynule na ní navazují ilustrativní příklady a nakonec i relevantní aplikace na reálných datech. Jednoznačným přínosem je vlastní výsledek v podobě směsi variačních autoencoderů, jež zcela určitě stojí za další rozpracování.

V práci se vyskytuje několik nedostatků a nepřesností, které ale nejsou takového charakteru, aby to bránilo porozumění textu.

- Str. 11, 2. odstavec – metoda nejmenších čtverců není limitována na polynomy řádu M , lze použít pro libovolné bazické funkce.
- Na několika místech by místo druhé mocniny měla být použita vektorová norma – rovnice (2.33), (3.1), popis EMVAE modelu na str. 37.
- Str. 16, rovnice (1.33) – chybí, že $\eta > 0$.
- Str. 17 – u popisu metody Adam je použito pro optimalizační krok jiné značení než v předchozí části
- Str. 24, 2. odstavec – správně má být nižší místo vyšší hodnota parametru alfa.

- Str. 27, rovnice (2.33) – zde je vstup X srovnáván s výstupem z kodéru místo výstupu z dekodéru.
- Str. 31 - chybějící citace na Kantoroviche.
- Str. 32, rovnice (2.39) – pokud je tato veličina minimalizována, pak musí být u prvního členu mínus. Toto se opakuje na dalších místech.
- Str. 32, odstavec 3 – zde je poprvé zmíněn IMQ kernel, který je ale definován až později v textu.

I přes uvedené nedostatky text hodnotím jako přínosnou a originální práci a navrhuji známku **B** (velmi dobře).

Dotazy k obhajobě:

- Sekce 1.3.1 - popis stochastic gradient descentu je napsán pro update přes jednotlivé body, stejně tak I v rovnici (2.44) - bylo tomu tak i při vašich experimentech?
- Proč byla zvolena fixní hodnota variance generativního rozdělení dekodéru?
- Jaká je výhoda IMQ oproti Gaussovskému kernelu u WAE?
- Byl u modelu WAE použit směsový model pomocí Vamp apriorna?
- EMVAE model – rovnice (2.44) – je společné apriorno pro všechny autoencoder ve směsi?
- Experimentální část – bylo skutečně testováno na trénovacích datech? Pro věrohodnější ohodnocení by bylo lepší testovat na samostatné podmnožině dat. Přetrénování modelů proběhlo jen pro standartní VAE model?
- V části 3.3.3 zmiňujete, že optimální hodnota rozptylu modelu EMVAE byla poměrně vysoká. Dokážete to nějak vysvětlit?

V Praze dne 10.8.2020

Ing. Vít Škvára