

## Posudek diplomové práce Bc. Lukáše Kuličky

**Název práce:** Estimating Sparse Parameterization of Neural Networks

**Oponent:**

prof. Mgr. Pavel Rajmic, Ph.D.

FEKT VUT v Brně

Technická 12, 616 00 Brno

[pavel.rajmic@vut.cz](mailto:pavel.rajmic@vut.cz)

Student ve své práci uvádí několik přístupů k odhadu řídkých regresních koeficientů, a to jak v klasických lineárních modelech, tak v případě aproximace dat neuronovými sítěmi. Podle vlastních slov jeden z úspěšných přístupů vyvinul sám.

Co se týká zadání, student nekomentuje, zda dosáhl interpretovatelných pravděpodobnostních modelů, což zadání požadovalo. Podle mého názoru sice není lehké definovat, co se interpretovatelným modelem myslí, ale i tak student tuto část zadání pomínl. Podobně zadání mluví o srovnávání s tzv. variačním dropoutem, na což jsem v práci také nenarazil.

Nicméně celkově oceňuji tři skutečnosti. Jednak je téma dosti náročné. Bylo třeba nastudovat spoustu teorie, ačkoliv experimenty vůči tomu působí kontrastně svou relativní jednoduchostí. Oceňuji splnění jednoho z hlavních cílů práce, a to získání rozptylu odhadů parametrů. Druhým pozitivem je angličtina, která co se týká slovníku a použitých obrátů na dobré úrovni, i když prostor ke zlepšení stále zůstává. Nakonec si cením, že student dal k dispozici počítačové kódy s testovanými modely.

K jazyku mám několik výhrad: občas chybějící slovo, chybějící členy, překlapy, czenglish (např. nadužívání slova so), občas familierní fráze, které nepatří do odborného textu; nejednotnost časů (např. v Introduction).

V práci jsem našel několik typů typografických nedostatků: občas nekonzistence značení ((1.2) a za ní), diferenciál italikou, naddimenzované mezery za Eq. Na str. 40 zůstal volný prostor.

Z hlediska organizace materiálu, plynulosti četby a návaznosti částí mi práce příliš nevyhovovala. Vysvětlení jsou strohá (nebo žádná), je uvedena spousta přípravného materiálu (v prvních kapitolách), aniž by pisatel čtenáře dostatečně motivoval k čemu budou nástroje později potřeba a pak jej také udržoval v pozornosti. Cítil jsem se zavalen výčtem nástrojů bez vysvětlení proč.

Součástí vyzrálé práce bývá také studentovo vysvětlení, proč se na důležitých křižovatkách rozhodl právě tak jak se rozhodl. Bc. Kulička ale žádné vysvětlení na několika takových místech nedává (např. není zdůvodněna volba KL v části 1.5.2, nebo obdobně 1.7.1 nevysvětluje volbu dle (1.44)).

Naopak některé pojmy jako jsou batch size, overfitting, trénovací epocha, jsou suverénně používány, jako by šlo o samozřejmosti. Podobně třeba důvod pro rozdělení dat na trénovací a testovací část nebo možná dokonce podmíněná a marginální pravděpodobnost. Myslím, že alespoň několik vět těmto pojmům mělo být věnováno.

Největší můj problém je metodologický a týká se základního experimentu, kdy se dělá regrese (s náhodně vygenerovanou datovou maticí X). Datová matice má více řádků než sloupců (a jelikož je náhodná, předpokládám má plnou hodnost, což ale student nezmiňuje). V takovém případě je zřejmé, že řešení s nejmenšími čtverci je unikátní, a pokud bychom generovali nová a nová pozorování šumu, budou se veškeré odhady blížit k „true“ datům. Student navíc používá slovo „konvergovat“ nevhodně – graficky to sice vypadá, že odhad trefil správné řešení, ale numericky to vlivem šumu nemůže být přesně. Na druhou stranu chápu experiment jako prvotní ověření, zda metoda vůbec funguje. Mluvit o nalezení řídkého řešení, když existuje jenom jedno řešení, mi ale připadne přestřelené.

Se závěry práce souhlasím, až na příliš silné tvrzení že variační metody detekují irelevantní parametry neuronových sítí. Myslím si, že takovýto závěr je příliš obecný a není možné jej učinit na základě několika experimentů.

Student splnil většinu bodů zadání a i přes uvedené nedostatky se jedná o práci, která je na dobré úrovni a na které lze stavět dále. Navrhuji hodnotit tuto diplomovou práci známkou C a doporučuji ji k obhajobě inženýrského titulu.

### **Otázky k obhajobě:**

Jaký je vztah problému (1.45) s klasickou Tichonovovou regularizací?

L1 norma je známa svým biasem/výchylkou (tendence odhadovat koeficienty menší než je optimální). Trpí podobným neduhem i některé ostatní metody navržené v diplomové práci?

Vychýlené L1 odhady se někdy přefitují metodou nejmenších čtverců, kdy malé koeficienty jsou z tohoto odhadu vyloučeny (tzv. debiasing). Pokud je to realistické, mohl byste tuto post-proceduru provést na svých datech a zjistit, zda se odhady zpřesnily? Totéž lze samozřejmě provést u neuronové sítě, která se znovu přefituje, ale koeficienty původně určené jako nevýznamné se z učení musí vypustit.

V Brně, 19. května 2022

Pavel Rajmic