

Posudek bakalářské práce

Matematicko-fyzikální fakulta Univerzity Karlovy

Autor práce	Václav Volhejn	
Název práce	Smoothness of Functions Learned by Neural Networks	
Rok odevzdání	2020	
Studijní program	Informatika	
Studijní obor	Obecná informatika	
Autor posudku	Mgr. Tomáš Musil	Vedoucí
Pracoviště	Ústav formální a aplikované lingvistiky	

K celé práci

lepší OK horší nevyhovuje

	lepší	OK	horší	nevyhovuje
Obtížnost zadání	X	X		
Splnění zadání		X		
Rozsah práce <i>... textová i implementační část, zohlednění náročnosti</i>		X		
<p>Neuronové sítě používané dnes v tzv. hlubokém strojovém učení mají zajímavou schopnost generalizovat: i poté, co dosáhnou úplné úspěšnosti na trénovacích datech, stále dobře generalizují na testovacích datech. Předložená práce se zabývá hypotézou, že je tomu tak proto, že tyto modely preferují jednodušší, „hladší“ funkce.</p> <p>Vzhledem k tomu, že chování neuronových sítí ve vztahu ke generalizaci je otevřený vědecký problém, o který se vědecká komunita začala zajímat teprve nedávno, považuji zadání za spíše náročnější.</p>				

Textová část práce

lepší OK horší nevyhovuje

	lepší	OK	horší	nevyhovuje
Formální úprava <i>... jazyková úroveň, typografická úroveň, citace</i>		X		
Struktura textu <i>... kontext, cíle, analýza, návrh, vyhodnocení, úroveň detailu</i>		X		
Analýza	X	X		
Vývojová dokumentace		X		
Uživatelská dokumentace		X		

První část práce přehledně popisuje základní pojmy a algoritmy, se kterými se v dalším textu setkáme. Následuje přehled souvisejících prací.

V teoretické části práce jsou navrženy čtyři možnosti měření „hladkosti“ funkcí. Ty jsou rozděleny na míry prvního řádu (*gradient norm*, *function path length*) a druhého řádu (*weights product*, *gradient path length*).

Jádro práce tvoří kapitola popisující experimenty. První skupina experimentů spočívá v postupném zvětšování trénovacích dat. Protože větší trénovací data vyžadují složitější model, měla by míra hladkosti naučených funkcí s rostoucím množstvím dat klesat.

Druhá skupina experimentů spočívá v explicitní regularizaci míry hladkosti. Pokud s pomocí explicitní regularizace najdeme model s nižší mírou hladkosti, který klasifikuje testovací data stejně dobře jako původní model, znamená to, že tato míra nebyla v původním modelu regularizovaná implicitně.

Autor práce po vyhodnocení experimentů dochází k závěru, že míry hladkosti prvního stupně nejsou při trénování neuronových sítí implicitně regularizovány.

Přínos práce (kromě samotných výsledků) spočívá také v možnosti navázat podrobnějším výzkumem měř hladkosti druhého řádu, pro které nebyla hypotéza o implicitní regularizaci experimenty vyvrácena.

Práce je psána dobrou angličtinou a je kvalitně vysázená. Použité zdroje jsou korektně citovány.

Implementační část práce

lepší OK horší nevyhovuje

Kvalita návrhu ... <i>architektura, struktury a algoritmy, použité technologie</i>		X		
Kvalita zpracování ... <i>jmenné konvence, formátování, komentáře, testování</i>		X		
Stabilita implementace		X		

Použité technologie (Python, TensorFlow) jsou standardně používány v této výzkumné oblasti. Zdrojové kódy pro provedené experimenty jsou přehledně organizované a doplněné dostatečným množstvím komentářů. Oceňuji snadnou reprodukovatelnost experimentů.

Celkové hodnocení Výborně
Práci navrhuji na zvláštní ocenění Ne

Datum

Podpis