

I. IDENTIFIKAČNÍ ÚDAJE

Název práce:	Anomaly Detection Methods for Log Files
Jméno autora:	Martin Koryťák
Typ práce:	diplomová
Fakulta/ústav:	Fakulta elektrotechnická (FEL)
Katedra/ústav:	Katedra počítačů
Vedoucí práce:	Ing. Jan Drchal, PhD.
Pracoviště vedoucího práce:	Katedra počítačů

II. HODNOCENÍ JEDNOTLIVÝCH KRITÉRIÍ

Zadání	náročnější
<i>Hodnocení náročnosti zadání závěrečné práce.</i>	
Práce se soustředí na aplikace neuronových autoenkodérů pro detekci anomálií nad sekvenčními daty logů. V návaznosti na předchozí práce a v souladu se současným odklonem od tradičních rekurentních architektur, jsme se rozhodli zaměřit na architektury založené na konvolučních vrstvách a self-attention přístupu. To od studenta vyžadovalo nastudování a dobré pochopení nových a netriviálních metod strojového učení.	

Splnění zadání	splněno
<i>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.</i>	
Zadání bylo bez výhrad splněno. Rozsah práce je nadstandardní.	

Aktivita a samostatnost při zpracování práce	A - výborně
<i>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.</i>	
Student byl po celou dobu mimořádně aktivní, na konzultace byl vždy perfektně připraven. Rád bych ocenil jeho samostatnost při vyhledávání relevantních zdrojů i samotném řešení problémů (zejména návrhů různých architektur neuronových sítí). Student si rovněž dobře plánoval jednotlivé kroky a tak byla diplomová práce ve finálním stavu se značným předstihem, před cílovým datem odevzdání.	

Odborná úroveň	A - výborně
<i>Posuďte úroveň odbornosti závěrečné práce, využití znalostí získaných studiem a z odborné literatury, využití podkladů a dat získaných z praxe.</i>	
Práce je z odborného hlediska na vysoké úrovni. Velmi oceňuji velké množství architektur a přístupů, které student zvládl navrhnout a experimentálně ověřit. Všechny kroky návrhu i analýzy experimentů jsou vždy pečlivě motivovány. Velmi oceňuji přístup, který student uplatnil pro ladění meta-parametrů – v případě neuronových přístupů se, jak bývá zvykem, neomezil pouze na ladění parametrů optimalizační metody, ale hledal i detailně parametrizovanou optimální architekturu sítí.	
Jako nedostatečné se mohou jevit experimenty na jediné datové sadě HDFS. Faktem však je, že se jedná o jedinou vhodnou dostupnou sadu – ostatní datasety buď postrádají anotace, které jsou potřeba pro evaluaci metod, případně jsou pouze triviálně anotovány na úrovni jednotlivých řádek souborů.	

Formální a jazyková úroveň, rozsah práce	A - výborně
<i>Posuďte správnost používání formálních zápisů obsažených v práci. Posuďte typografickou a jazykovou stránku.</i>	
Práce je psána výbornou angličtinou. Text je dobře strukturovaný, čtivý a dobře srozumitelný. Velmi pěkná teoretická část podrobně popisuje moderní metody pro zpracování sekvencí, temporální autoenkodéry, související typy vrstev neuronových sítí a metody detekce anomálií se zaměřením na detekci anomálií nad logy. Práce dále obsahuje návrhovou a implementační část a nosnou experimentální kapitolu, zakončenou podrobnou diskusí a shrnutím všech dosažených	

výsledků. Text práce je z typografického hlediska na vysoké úrovni, navíc je doplněn řadou přehledných, originálních ilustrací.

Výběr zdrojů, korektnost citací

A - výborně

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.

Zdroje jsou citovány správně. Rozsah citací je nadprůměrný.

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.

Výsledky dosažené studentem považuji za mimořádně přínosné a plánujeme na nich založit následnou publikaci.

Nejlepší metoda založená na číselných reprezentacích (embeddings) se kvalitativně vyrovná starším typům metod, pracujících s daty předzpracovanými parserem, přináší však velikou výhodu v možnostech zpracování logů, které se nevykytly v trénovacích datech. Není také nutné pracně ladit parametry parseru.

Po domluvě se mnou, se student zaměřil na specifický typ semi-supervizovaného přístupu, kdy je příslušný autoenkodér trénován nad většími daty normálního provozu (s anomáliemi odfiltrovanými s použitím dostupných anotací) a práh rozhodovací funkce pro detekci anomálií následně kalibrován na menší, plně anotované části datové sady (v textu označena jako validační množina). Postup trénování těchto metod bývá v praxi, vzhledem k typicky nízkému zastoupení anomálií, relaxován: anomálie nejsou z dat normálního provozu odstraňovány, což signifikantně snižuje nároky na anotace. Experimenty s tímto přístupem plánujeme navázat v rámci dalšího výzkumu.

III. CELKOVÉ HODNOCENÍ A NÁVRH KLASIFIKACE

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

Předloženou závěrečnou práci považuji za nadstandardní a hodnotím ji klasifikačním stupněm **A - výborně**.

Datum: 3.6.2021

Podpis: