

Posudek oponenta na diplomovou práci

## **Bc. Matěj Zorek: Generativní modely pro detekci L-H přechodu v plazmatu na tokamaku COMPASS**

Ještě nedávno velké fyzikální experimenty ať už v oblastech fyziky vysokých energií, astrofyzice, nebo právě fyzice plazmatu upřednostňovaly pro analýzu naměřených dat svoje postupy a řešení. V poslední dekádě se tento přístup změnil jak pod tlakem velkých objemů dat, tak především v dostupnosti a kvalitě algoritmů vycházejících z neuronových sítí. Tyto algoritmy pomáhají generovat umělé vzorky dat, popisovat dráhy jednotlivých částic, nebo klasifikovat měřené události. Rozdíl v přesnosti a úspěšnosti těchto nástrojů vyváží i to, že se často jedná o černé skřínky. Tato práce se mimo jiné snaží přinést trochu světla do těchto černých skříněk a pomocí autoencoderů navázat na předchozí práce studenta, které využívali pro klasifikaci stavů, v kterém se plazma v tokamaku COMPASS nachází, analyticky spočtené příznaky a modely založené na SVM a rozhodovacích stromech.

Práce je rozdělena do čtyř kapitol, přičemž první z nich je věnována motivaci, popisu fyzikálního experimentu a tokamaku COMPASS, ze kterého pocházejí zkoumaná reálná data. Další dvě kapitoly jsou nejobsáhlejší a seznamují čtenáře se základy teorie neuronových sítí (NN) včetně jejich pokročilých speciálních typů a jejich trénování, teorií a způsobu použití autoencoderů, variačních autoencoderů (VAE) a jejich propojení s teorií NN. Poslední kapitola je již věnována použití představené teorie na reálných datech a prezentuje jednak výsledky rekonstrukčních vlastností jednotlivých autoencoderů, tak samotnou klasifikaci založenou na analyticky spočtených příznacích, příznacích získaných z latentních prostorů autoencoderů, nebo pomocí semi-supervised VAE.

Celkově je práce velmi kompaktní a nijak rozsáhlá, což naopak přispívá k její čitelnosti a srozumitelnosti. Zejména bych vyzdvihl pěknou rešeršní část v kapitolách dvě a tři, kdy je z mého pohledu řečeno vše podstatné, nezabíhá se do přílišných detailů a přitom není vynecháno nic z toho co je poté zmiňováno v následující experimentální části. Množství překlepů je minimální a až na nějakou záměnu  $n$  za  $N$ , označování rovnic apod. jsem si závažnějších chyb nevšiml. Práce se zdroji je dostačující (vytknul bych ale řazení bibliografie, množství preprintů na ArXivu a chybějící čas přístupu u online zdrojů), množství grafů a obrázků pomáhajících vysvětlit danou problematiku je značné a chybějící citace u spousty z nich předpokládám značí vlastní práci studenta. Poslední kapitola, kde je shrnut a popsán hlavní přínos práce je z mého pohledu naopak příliš stručná a prezentace výsledků neodpoví na všechny dotazy, které si čtenář pokládá. Vybrané otázky, které mně při čtení napadaly, shrnuji níže. Jelikož klasifikace do více tříd umožňuje různé způsoby hodnocení kvality, je škoda, že student v práci nepopsal jak počítá F1 score, přesnost klasifikace, případně nedoplnil jiná kritéria. Stejně tak problematika přetrénování a validace výsledků je zejména u neuronových sítí kruciólní a v práci bych ocenil lepší popis provedené validace a například i vykreslení průběhu ztrátové funkce pro trénovací a testovací data set.

V průběhu obhajoby doporučuji zodpovědět následující otázky.

- Jaký je poměr výskytu jednotlivých stavů (L mod, H mod, ELM start, ELM end) v datech a byl tento poměr dodržen i při rozdělení datasetu? Bylo toto dělení zvoleno jednou a pevně (64% test, 16% train, 20% validační) a proč právě takto?
- Jak jste počítal F1 score a přesnost klasifikace a je pro vás z fyzikálního pohledu kvalita klasifikace každé třídy stejně důležitá?
- Jak je pro praktické použití prezentovaných modelů důležitý čas trénování a jak čas samotné klasifikace nových dat? Jakou roli v tom hraje decimování a jaký je jeho vliv na kvalitu klasifikace oproti času zpracování?
- V práci je například zmíněno, že při použití vlastních hlubších sítí začala kvalita modelů degradovat, ale model encoderu vycházející z architektury ResNet byl opuštěn ne kvůli své kvalitě ale výpočetnímu času. Na základě čeho tedy byly vybrány výsledné architektury prezentované jako "nejlepší"?
- Jaké jsou možnosti použití výsledků práce přímo kolaborací COMPASS (případně jiných kolaborací na jiných tokamacích) a bude mít práce přínos i pro plánovaný upgrade COMASS-U?

Závěrem mi zbývá už jen konstatovat, že zadání bylo zcela splněno a práce navíc dosáhla na poli klasifikace reálných fyzikálních dat neobvykle dobrých výsledků. Škoda, že student závěrečné výsledky neprezentoval v širší míře a že okolnosti neumožnily srovnání s jinými výsledky v této oblasti. I přes zmíněné nedostatky doporučuji práci k obhajobě a navrhuji udělit známku **B (velmi dobře)** a při zodpovězení uvedených otázek je možno ji i zlepšit.

V Praze dne 16. července 2020

.....

Ing. Jiří Franc, Ph.D.