

# Posudek práce

předložené na Matematicko-fyzikální fakultě  
Univerzity Karlovy

- posudek vedoucího     posudek oponenta  
 bakalářské práce     diplomové práce

Autor: Patrik Novotný  
Název práce: Exploring jet calibration with machine learning techniques  
Studijní program a obor: Fyzika, Obecná fyzika (FOF)  
Rok odevzdání: 2021

Jméno a tituly oponenta: Mgr. Radek Žlebčík, Ph.D.  
Pracoviště: Ústav částicové a jaderné fyziky, MFF UK  
Kontaktní e-mail: zlebcik@ipnp.mff.cuni.cz

## Odborná úroveň práce:

- vynikající     velmi dobrá     průměrná     podprůměrná     nevyhovující

## Věcné chyby:

- téměř žádné     vzhledem k rozsahu přiměřený počet     méně podstatné četné     závažné

## Výsledky:

- originální     původní i převzaté     netriviální kompilace     citované z literatury     opsané

## Rozsah práce:

- veliký     standardní     dostatečný     nedostatečný

## Grafická, jazyková a formální úroveň:

- vynikající     velmi dobrá     průměrná     podprůměrná     nevyhovující

## Tiskové chyby:

- téměř žádné     vzhledem k rozsahu a tématu přiměřený počet     četné

## Celková úroveň práce:

- vynikající     velmi dobrá     průměrná     podprůměrná     nevyhovující

## Slovní vyjádření, komentáře a připomínky oponenta:

Patrik se ve své bakalářské práci zabývá kalibrací energie jetů měřených v detektoru ATLAS na urychlovači LHC (CERN, Ženeva). Primárně je práce zaměřena na jety ve srážkách olovo-olovo, které jsou, mimo jiné, nástrojem ke zkoumání vlastností kvark-gluonového plazmatu – skupenství hmoty dominující v první sekundě života našeho vesmíru.

Kalibrace energie jetů je vysoce netriviální a na velkých experimentech jako je ATLAS na různých jejích aspektech pracují desítky lidí v několika pracovních skupinách. Hlavní úsilí se ovšem soustředí na jety v proton-protonových srážkách a kalibrace jetů ve srážkách těžkých iontů je daleko méně rozvinuta.

Patrik v práci studuje, jak mohou moderní metody strojového učení (deep-learning) vylepšit energetické rozlišení jetů. V práci je ukázáno, že odezva detektoru na jety inicializované kvarkem a gluonem je rozdílná, jelikož vlastnosti kvarkových a gluonových jetů jsou odlišné; gluonové jety jsou například méně kolimované a obsahují obecně více částic (tracků) než jety kvarkové. Tyto další jetové parametry jsou tedy společně s rekonstruovanou energií použity jako vstup do neuronové sítě, která je trénována tak, aby dokázala co nejlépe předpovědět skutečnou energii jetu.<sup>1</sup> Neuronová síť je trénována na jetech pocházejících ze srážek protonů a použita pro předpověď energie jetů ve srážkách olovo-olovo. Ukazuje se, že energie jetu korigovaná neuronovou sítí má asi o 10 procent lepší rozlišení v porovnání s energií korigovanou klasickou metodou. Dalším krokem jetové kalibrace by pak bylo určení korekce na případné rozdíly mezi Monte Carlo simulací a skutečným detektorem a ověření, že je toto zpřesnění rozlišení pozorováno i v datech.

Bakalářská práce obsahuje originální výsledky, které demonstrují studentovo hluboké porozumění tématu a v budoucnu mohou přispět k přesnějším měření jetů na experimentu ATLAS. Svým rozsahem práce přesahuje běžné bakalářské práce, je psaná kvalitní angličtinou a nemám k ní podstatnější výhrady.

Práci tedy hodnotím jako výbornou.

---

<sup>1</sup>Skutečná energie jetů je známa, protože jsou použity jety z Monte Carlo simulace.

### Případné otázky při obhajobě a náměty do diskuze:

- Co vás vedlo k vaší volbě topologie neuronové sítě, tedy sítě se dvěma skrytými vrstvami s 40 a 80 neurony? Zkoušel jste tyto "hyper-parametry" neuronové sítě optimalizovat?
- Jak jste testoval, že neuronová síť není při 20 epochách učení, které jste použil, přeučená nebo nedoučená? Testoval jste výkon sítě ve statisticky nezávislém testovacím  $pp$  datovém samplu?
- Z práce mi není zcela zřejmé jakou loss funkci jste pro trénování neuronové sítě použil. Jak hodnota loss funkce souvisí s veličinou kterou chcete minimalizovat, tedy relativní energetické rozlišení jetu?
- V práci ukazujete, že neuronová síť zlepší energetické rozlišení jetu, ale vychýlí střední hodnoty rekonstruované energie. Jak si vysvětlujete, že vámi použitá loss funkce má minimum pro tyto konfigurace? Kdyby jste dodatečně opravil výchyly středních hodnot (pomocí tzv. numerické inverze), byla by hodnota vámi použité loss funkce horší?
- Jaké jsou četnosti jetů vstupujících do trénování jako funkce příčné energie  $E_T$ ? Není vaše síť příliš trénována na malé hodnoty příčné energie? Vámi použité Monte Carlo je generováno separátně pro několik  $E_T$  intervalů, nemohou tyto diskontinuity ovlivnit trénování neuronové sítě?

### Práci:

doporučuji

nedoporučuji

uznat jako bakalářskou.

### Navrhuji hodnocení stupněm:

výborně  velmi dobře  dobře  neprospěl

Místo, datum a podpis oponenta:



Praha, 23. června 2021