

Posudek bakalářské práce

předložené na Matematicko-fyzikální fakultě

Univerzity Karlovy

- posudek vedoucího posudek oponenta
 bakalářské práce diplomové práce

Autor: Jan Benda
Název práce: Machine learning for recognition of simple physical systems
Studijní program a obor: Matematické modelování (MMOP)
Rok odevzdání: 2024

Jméno a tituly vedoucího: doc. RNDr. Michal Pavelka, Ph.D.
Pracoviště: Matematický ústav, MFF UK
Kontaktní e-mail: pavelka@karlin.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 vedoucího:

Student v práci prozkoumal metodu strojového učení Direct Poisson Neural Networks (DPNNs) [2], které dokážou identifikovat hamiltonovský systém (jeho Poissonovu závorku a energii) z časové řady stavů daného systému.

Po úvodním shrnutí strojového učení založeném na neuronových sítích a shrnutí DPNNs student zkoumal robustnost dané metodiky. Konkrétně pozoroval chování metody při zanesení gaussovského šumu do dat a zjistil, že metoda je na šum poměrně citlivá. Poté navrhnul, jak citlivost na šum zmírnit (pomocí dropoutu).

Dále student zkoumal, jak dobře DPNNs extrapolují trajektorie daleko od oblasti, kde jsou sítě trénovány. Mimo trénovací oblast může být chyba extrapolace velká. Student pak ukázal, jak chybu extrapolace zmírnit (zvětšením trénovacího datasetu a přidáním dalších trénovaných veličin). Dále student prozkoumal, jak nahrazení numerického kroku ve ztrátové funkci (implicit midpont rule) metodou Runge-Kutta čtvrtého řádu zrychlí trénování sítí. Nakonec student rozšířil metodu DPNNs na disipativní systémy přidáním sítí pro relaxční čas v rámci Ehrenfestovy disipace [1].

V souhrnu student detailně prozkoumal možnosti metody DPNNs pro rozpoznávání hamiltonovských systémů mimo oblasti, které jsou pro danou metodu výhodné. Navrhnul zlepšení metody tak, aby v těchto oblastech fungovala robustněji, a rozšířil metodu na disipativní systémy. Práci jednoznačně doporučuji k obhajobě a navrhuji známku výborně.

Práci:

doporučuji

nedoporučuji

uznat jako bakalářskou.

Navrhuji hodnocení stupněm:

výborně velmi dobře dobře neprospěl

Místo, datum a podpis vedoucího:

Praha, 24. května 2024

Reference

- [1] M. Pavelka, V. Klika, and M. Grmela. Ehrenfest regularization of Hamiltonian systems. *Physica D: Nonlinear phenomena*, 399:193–210, 2019.
- [2] M. Šípka, M. Pavelka, O. Esen, and M. Grmela. Direct Poisson neural networks: learning non-symplectic mechanical systems. *Journal of Physics A: Mathematical and Theoretical*, 56(49), 2023. <https://github.com/enaipi/direct-Poisson-neural-networks>.