

## I. IDENTIFIKAČNÍ ÚDAJE

<b>Název práce:</b>	Reprezentace problémů klasického plánování pro učení heuristické informace grafovými neuronovými sítěmi
<b>Jméno autora:</b>	Tomáš Grim
<b>Typ práce:</b>	diplomová
<b>Fakulta/ústav:</b>	Fakulta elektrotechnická (FEL)
<b>Katedra/ústav:</b>	Katedra Počítačů
<b>Oponent práce:</b>	RNDr. Ing. Otakar Trunda, Ph.D.
<b>Pracoviště oponenta práce:</b>	Katedra teoretické informatiky a matematické logiky, MFF, UK

## II. HODNOCENÍ JEDNOTLIVÝCH KRITÉRIÍ

<b>Zadání</b>	<b>náročnější</b>
<i>Hodnocení náročnosti zadání závěrečné práce.</i>	
Práce se věnuje problematice učení heuristické funkce pro řešení deterministických sekvenčních rozhodovacích problémů. Jedná se o mezioborové téma, které propojuje strojové učení a automatizované plánování. K úspěšnému zpracování je třeba, aby řešitel měl hlubší znalosti v obou těchto oblastech, proto téma hodnotím jako náročnější.	

<b>Splnění zadání</b>	<b>splněno s menšími výhradami</b>
<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>	
Práce splnila zadání v dostatečném rozsahu. Výhrady mám k bodu 2) „Vyberte vhodnou doménu/domény a jejich instance.“, kde výběr domén a instancí není dostatečně zdůvodněn a k bodu 5) „Experimentálně ověřte kvalitu naučené heuristiky a diskutujte výsledky.“. Konkrétní výhrady popisují v závěru.	

<b>Zvolený postup řešení</b>	<b>částečně vhodný</b>
<i>Posuďte, zda student zvolil správný postup nebo metody řešení.</i>	
<p>Řešitel navrhl 3 doménově nezávislé reprezentace stavů plánovacích problémů pomocí grafů a implementoval učení s využitím grafové neuronové sítě (GNN). Naučené heuristiky pak experimentálně srovnal s existujícími heuristikami na čtyřech plánovacích doménách: <i>Gripper</i>, <i>Blocksworld</i>, <i>Depot</i> a <i>VisitAll</i>. Autor experimentuje se dvěma ztrátovými funkcemi: <i>MSE</i> a <i>rank</i>.</p> <p>Zvolený postup řešení považuji v principu za správný, chybí ale hlubší analýza vlastností navrženého přístupu a odůvodnění učiněných rozhodnutí.</p> <p>Například: v učení heuristik (HL) rozlišujeme tzv. „<i>per-instance</i>“ variantu, kde je výsledný model aplikovatelný pouze na jednu instanci, čili na problémy se stejným cílovým stavem, a „<i>per-domain</i>“ variantu, kde lze model aplikovat na různé instance ([1]). Práce tyto varianty nezmiňuje, ale z popisu je zřejmé, že cílí na <i>per-domain</i> HL. Všechny 3 reprezentace jsou testovány na nových instancích, přestože <i>Minimální grafová reprezentace (MGR)</i> ani <i>Úplná grafová reprezentace (FGR)</i> neobsahují informaci o cílovém stavu a nemohou proto v principu vůbec fungovat na doménách, kde se cílové stavy jednotlivých instancí výrazně liší, jako jsou <i>Blocksworld</i> a <i>Depot</i>. Pro <i>per-instance</i> HL by však mohly být vhodné.</p> <p>Dále: jedním ze známých nedostatků GNN je pomalý přenos informace mezi vrcholy grafu. Pro přenos informace mezi vrcholy ve vzdálenosti <math>k</math> je třeba, aby síť měla aspoň <math>k</math> grafových vrstev. Tento problém lze za jistých okolností potlačit použitím úplného grafu ([2]). Autor tento problém zmiňuje jen okrajově. Není diskutováno, zda řešená úloha vyžaduje přenos informace na větší vzdálenost, případně na jakou (v závislosti na doméně), ani není zmíněn např. průměr grafu v použité reprezentaci. Obecně nejsou diskutované výhody a nevýhody <i>Úplné</i> reprezentace oproti <i>Minimální</i>.</p>	
[1] Ferber, P., Helmert, M., & Hoffmann, J. (2020). Neural network heuristics for classical planning: A study of hyperparameter space. In ECAI 2020 (pp. 2346-2353)	
[2] Alon, U. & Yahav, E. (2021). On the Bottleneck of Graph Neural Networks and its Practical Implications, In ICLR 2021	

## Odborná úroveň

C - dobře

Posuďte úroveň odbornosti závěrečné práce, využití znalostí získaných studiem a z odborné literatury, využití podkladů a dat získaných z praxe.

Řešitel prokázal znalost problematiky kombinatorické optimalizace i strojového učení, a to jak teoretickou (fungování použitých algoritmů), tak praktickou (jazyk PDDL, použití knihovny PyTorch, atd.). Obecně však k řešenému problému přistupuje spíše povrchně, kde jediným vodítkem je úspěšnost v experimentech. Chybí snaha o hlubší vhled do problematiky, analýza teoretických vlastností navržených technik a snaha důkladně pochopit a vysvětlit fenomény pozorované v experimentech. To se projevuje mimo jiné zavádějící interpretací některých výsledků. Konkrétní příklady uvádím dále.

## Formální a jazyková úroveň, rozsah práce

D - uspokojivě

Posuďte správnost používání formálních zápisů obsažených v práci. Posuďte typografickou a jazykovou stránku.

Text práce je vhodně strukturovaný, obsahuje úvod do problematiky, poté formuluje výzkumný problém včetně motivace a popisuje navržené řešení. Text je psaný odborným style obvyklým pro tento typ práce. Rozsah textu práce je standardní, rozsah zdrojových kódů spíše podprůměrný. Zdrojové kódy neobsahují žádné komentáře a není poskytnutá ani jiná forma dokumentace. V textu jsem objevil 64 pravopisných chyb a větší množství překlepů, špatně skloňovaných větných členů apod. Jde hlavně o nadbytečné a chybějící čárky. Kompletní seznam byl předán studentovi. I přes tyto nedostatky lze významu textu dobře porozumět.

## Výběr zdrojů, korektnost citací

B - velmi dobře

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. i citační etiky a zda jsou bibliografické citace úplné a v souladu s citačními zvyklostmi a normami.

Řešitel vhodným způsobem použil existující implementace infrastruktur pro plánování a strojové učení včetně nástroje pracujícího s GNN. Zdroje jsou řádně citované a vlastní přínos řešitele je dostatečně vymezený. Žádné porušení citační etiky ani zvyklostí jsem neshledal.

Použité prameny jsou relevantní a dostatečně pokrývají dané téma. Doporučil bych vzít v úvahu ještě práce Patrika Ferbera (<https://ai.dmi.unibas.ch/people/ferber/>), který se podobným tématem intenzivně zabývá.

Podoba některých citací je poměrně zvláštní. Zhruba polovinu citací (13 z 28) tvoří nerecenzované zdroje (arXiv / CoRR, technické zprávy atd.), přestože tyto články byly publikované i na běžných konferencích. Preferoval bych citaci ze sborníku.

## 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.

Pozitivní aspekty:

- Za hlavní pozitivní výsledek práce považuji fakt, že navržená technika výrazně překonala heuristiku *FastForward* na doméně *Visitall*. Výsledek je o to lepší, že učení probíhalo na mnohem menších instancích než následné testování a že použitá technika je doménově nezávislá, tedy nevyužívá žádné expertní znalosti.
- Autor správně pochopil a popsal úskalí *per-domain HL*, např. „*Na tomto jednoduchém řešení by však mohly fungovat pouze rekurentní sítě, jelikož velikost vstupního vektoru se mění podle velikosti stavu.*“, „*Tato reprezentace by umožňovala využití většího množství typů neuronových sítí, bohužel je však závislá na velikosti problému. To omezuje využití natrénovaných modelů pouze na problémy se stejnými objekty.*“ a vzal je v úvahu při návrhu grafové reprezentace.
- Dále oceňuji, že se řešitel pustil do náročného mezioborového tématu. HL kombinuje symbolické techniky se statistickými, navíc autor řeší doménově nezávislou *per-domain* variantu a naučená informace se přenáší z malých problémů na velké, tedy formou extrapolace. Jedná se tak o jednu z nejobtížnějších variant tohoto problému.

## Nedostatky:

- Volba domén pro experimenty není srozumitelně zdůvodněná. Autor píše „Složitost domény byla jedním z hlavních faktorů, který ovlivnil finální výběr.“, ale výpočetní složitost jednotlivých domén není nikde zmíněná. Ani další vlastnosti domén, které by mohly být relevantní vzhledem k použité technice, nejsou diskutované.
- Volba instancí pro experimenty: jak jsem psal výše, modely *MGR* ani *FGR* by neměly být testované na instancích s výrazně odlišným cílovým stavem. Diskuzi nad experimentálními výsledky těchto metod na doménách *Blocksworld* a *Depot* považuji za bezpředmětnou, protože naučená heuristika zde nijak nekoreluje se skutečnou vzdáleností do cíle. To by bylo možné ověřit, kdyby v experimentech byla zahrnutá i slepá heuristika.
- Ohodnocení *dead-end* stavů přičtením konstanty 100: pro účely experimentů to není třeba řešit, protože žádná z použitých domén *dead-end* stavy neobsahuje. Obecné řešení by pak mělo být navržené lépe.
- Prezentace výsledků učení:
  - o U rankovací funkce je chyba na validačních datech vždy menší než chyba na datech trénovacích, což by nemělo nastávat. Odhaduji, že je to způsobené odlišným normalizačním faktorem. Pak ale nedává smysl tyto hodnoty přímo porovnávat (např. v tabulce 4.1).
  - o Vývoj hodnoty chybové funkce v čase není až tak zajímavé kritérium. Tím spíše, že situace je na všech grafech téměř identická. Když už chceme všechny tyto grafy prezentovat, tak bych aspoň zvolil logaritmické měřítko, protože např. v grafech na obr. 4.4 lze velmi těžko pozorovat všech 6 časových řad.
  - o Zajímavější by bylo vidět korelační diagramy (scatter plot) hodnot  $\langle \text{SkutečnýVýstup}, \text{PožadovanýVýstup} \rangle$  přes všechny datové body, případně nějaký diagram chyby, např. histogram pro kolik % dat leží rozdíl  $(\text{SkutečnýVýstup} - \text{PožadovanýVýstup})$  v intervalu  $[0, 1)$ , pro kolik % dat leží rozdíl  $(\text{SkutečnýVýstup} - \text{PožadovanýVýstup})$  v intervalu  $[1, 2)$ , atd. Dále např. korelační digramy  $\langle \text{naučenáHeuristika}, h_{FF} \rangle$ ,  $\langle \text{naučenáHeuristika}, h_{max} \rangle$  na stavech nějakého většího problému použitého v experimentech. Dále také rozložení chyby vzhledem k požadovanému výstupu, tedy jestli síť dělá chyby spíše na stavech blízko k cíli nebo daleko od cíle. Stejně tak rozložení chyby vzhledem k velikosti problému. Obecně bych očekával mnohem hlubší analýzu výsledků. Bez těchto informací nelze kvalitu naučené heuristiky rozumně zhodnotit.
  - o Surová data z učení nejsou k práci přiložena. Čtenář tak nemůže zmíněné statistiky sám dopočítat ani výsledky prezentované v práci nijak snadno ověřit. To považuji za zásadní nedostatek předložené práce.
- Prezentace výsledků plánovacích experimentů:
  - o Tabulky porovnávající průměrné hodnoty kritérií *délka plánu*, *počet otevřených vrcholů* a *počet uzavřených vrcholů* neposkytují žádnou rozumnou informaci. Průměr je počítán přes problémy vyřešené danou metodou. Každá z metod však vyřešila jiný počet problémů, takže tyto hodnoty jsou navzájem neporovnatelné. Např. vyřešení jednoho těžkého problému navíc může zhoršit průměrnou délku plánu. Je nutné buď tato kritéria počítat pouze na problémech, které vyřešily všechny metody nebo použít jinou metriku, např. *IPC score*.
  - o Chybí detailnější informace o tom, jaké konkrétní problémy vyřešily jednotlivé metody. Např. pokud *metoda1* vyřeší v součtu menší počet problémů než *metoda2*, ale dokáže vyřešit jiné problémy než *metoda2*, je to zajímavý výsledek. Toto nelze z textu práce nijak zjistit.
  - o Kapitola *Diskuze nad výsledky* obsahuje 5 krátkých odstavců, které většinou jen konstatují výsledek experimentu. Podrobnější analýza chybí stejně jako případná reflexe výsledků formou úpravy návrhu.
  - o Surová data s výsledky jednotlivých běhů plánovače nejsou ani v tomto případě přiložena. Nelze ani dohledat, jaké přesně problémy byly v experimentech použité.

### III. CELKOVÉ HODNOCENÍ, OTÁZKY K OBHAJOBĚ, NÁVRH KLASIFIKACE

Shrňte aspekty závěrečné práce, které nejvíce ovlivnily Vaše celkové hodnocení. Uveďte případné otázky, které by měl student zodpovědět při obhajobě závěrečné práce před komisí.

Práce splnila náročné zadání a minimálně jedna z navržených reprezentací je použitelná pro doménově nezávislé učení heuristik pomocí modelů s fixní dimenzí vstupu. To představuje vědecký přínos problematice HL a lze na něj dále navazovat.

Hlavní nedostatky nacházím v povrchní analýze výsledků, v jejich nevhodné interpretaci a v absenci surových dat v přílohách práce.

Případné dotazy během obhajoby:

1. Jak vypadá strategie, kterou naučená heuristika s algoritmem GBFS reprezentuje na doméně *Visitall*? Lze ji nějak snadno popsat? Např. „Jdi na nejbližší nenavštívené políčko.“
2. Proč se nepodařilo dosáhnout rozumných výsledků na doméně *Gripper*?
3. Proč byl v experimentech použitý algoritmus GBFS namísto standardního  $A^*$  nebo  $IDA^*$ ?
4. Jak dlouho trvalo generování trénovacích dat? Bylo by možné postup urychlit použitím *backward search*?

Předloženou závěrečnou práci hodnotím klasifikačním stupněm **C - dobře**.

Datum: 17.6.2023

Podpis: