

Vyhodnocení agentů hlubokého Q-učení pomocí testu algoritmické IQ

Autor: Ing. Michal Dvořák

Vedoucí práce: Ing. Ondřej Vadinský, Ph.D.

Škola a fakulta: Vysoká škola ekonomická v Praze, Fakulta informatiky a statistiky

S rozmachem umělých inteligencí v posledních dvou desetiletích vyvstává přirozeně otázka, jak jsou tyto nové technologie skutečně inteligentní. Tato otázka ale není zrovna nová. Zabýval se jí již Alan Turing v první polovině minulého století. Od té doby se metodika měření inteligence strojů a algoritmů značně posunula a moderní směr se snaží nahlížet na inteligenci v podobném pojetí, které se vztahuje i na inteligenci v podobě jakou jí vnímáme i u člověka.

Jedním z možných pohledů na testování inteligence přináší koncept zvaný Univerzální inteligence. Ten definuje inteligenci jako „schopnost dosahovat cílů v široké množině prostředí.“ Množinu prostředí lze přeložit jako skupinu všech možných problémů a situací, kde dosahovat cílů znamená vyřešit tyto problémy podle kritérií, které agentovi sdělíme.

Testování takového pojetí inteligence je bohužel prakticky neproveditelné, kvůli různým matematickým problémům, ale naštěstí existuje aproximace testu univerzální inteligence, který se nazývá Test algoritmického IQ. Ten jako množinu problémů používá množinu počítačových programů v nejjednodušší formě. Agent je poté zasazen do běžícího programu, a je mu umožněno tento program řešit, a následně je jeho výsledek ohodnocen. Pokud takovéto měření provedeme na dostatečně velkém množství programů, tak jsme schopni odhadnout skóre jeho Algoritmické IQ.

Tento test existuje v programové podobě v jazyce Python. Bohužel tento test v době začátku psaní této práce obsahoval pouze ty nejzákladnější agenty umělé inteligence, které se neopírali o moderní algoritmy, jejichž rozmach lze zaznamenat v posledních desetiletích.

Úkolem této práce tak bylo rozšířit tento test o nového agenta, který využívá algoritmus zvaný Hluboké Q-učení. Tento algoritmus využívá neuronové sítě

k rozhodování, jak se agent v danou chvíli zachová. Zároveň si ukládá všechny dříve zažité situace, ze kterých poté tvoří učící data pro neuronovou síť.

Agent využívající tento přístup se ale učí sám proti sám sebou vytvořenými daty. Tento proces se ukázal pro složitá prostředí, jako nedostačující, protože se agent často ztratil, a nebyl schopný se dál učit. Z tohoto důvodu autoři původního algoritmu rozšířili agenta, ještě o druhou síť, jejíž úkolem je generovat učící data, čímž se stabilizuje celý učící proces. Obě tyto verze agentů byly v rámci této práce přidány do AIQ testu.

Problémem implementovaných agentů bylo velké množství jejich nastavitelných parametrů. Z toho důvodu byl AIQ test rozšířen o mechanismus k hledání optimálních konfigurací agentů, který využívá konceptu Evolučních algoritmů. Ty využívají jakousi inteligentní heuristiku, a dokážou velice rychle najít dostatečně dobrou konfiguraci, a s dalším výpočetním časem se více a více blíží optimálnímu výsledku.

Pomocí evolučních algoritmů, byly nalezeny dvě dostatečně dobré konfigurace obou verzí agentů, které překonali výsledky konfigurací z původních článků. A ačkoliv se potvrdilo, že agenti hlubokého Q-učení mají podobné výsledky jako agenti prostého Q-učení, tak po provedení Studentova t-testu, bylo odhaleno, že agenti hlubokého Q-učení dosahují lepších, a v jednom případě stejných, výsledků na stejné konfiguraci AIQ testu oproti všem doposud implementovaných agentů. Výsledné měření agentů zároveň odhalilo možné nedostatky aktuální verze AIQ testu, které by se daly popsat jako, že AIQ test je příliš jednoduchý pro takto robustní algoritmy, mezi kterými již nedokáže odhalit rozdíly.