

I. IDENTIFIKAČNÍ ÚDAJE

Název práce:	Rozpoznávání typů automobilů pomocí konvolučních neuronových sítí
Jméno autora:	Bc. Kryštof Filip
Typ práce:	diplomová práce
Fakulta:	Fakulta jaderná a fyzikálně inženýrská (FJFI)
Katedra:	Katedra softwarového inženýrství
Oponent práce:	Ing. Pavel Strachota, Ph.D.
Pracoviště oponenta práce:	Katedra matematiky FJFI ČVUT v Praze

II. HODNOCENÍ JEDNOTLIVÝCH KRITÉRIÍ

Zadání	průměrně náročné
<i>Hodnocení náročnosti zadání závěrečné práce.</i>	
Teoretická část práce je zaměřena na seznámení se s matematickými a algoritmickými principy neuronových sítí (NN), s důrazem na konvoluční NN (CNN). Praktická část pak spočívá ve využití hotových softwarových nástrojů k otestování výkonnosti známých architektur CNN a v návrhu vlastních alternativ. Vzhledem k tomu, že jde o diplomovou a nikoliv bakalářskou práci, nepovažuji toto zadání za zvláště náročné. Z mého pohledu se nejobtížnější částí úkolu stalo získávání vhodné datové sady, při němž musel student projevit značnou kreativitu a zdravý úsudek.	

Splnění zadání	splněno
<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>	
Všechny body zadání byly splněny. Oceňuji zejména praktickou část, která dokumentuje nápaditý postup při získávání dat a poté značné množství provedených experimentů a jejich pečlivé vyhodnocení.	

Zvolený postup řešení	vhodný
<i>Posuďte, zda student zvolil správný postup nebo metody řešení.</i>	
Student se seznámil s existujícími modely CNN, natrénoval je s využitím kvalitní datové sady, kterou sám vytvořil, a pomocí vhodných metrik srovnával jejich úspěšnost. Mrzí mě pouze, že v práci není podrobněji komentován implementační aspekt. MATLAB není oproti knihovnám PyTorch a Keras (TensorFlow) tak často používaným nástrojem pro implementaci modelů NN, a proto by se hodilo mít možnost nahlédnout do zdrojových kódů (alespoň formou úryvků v textu). Bylo by velmi přínosné (pro účely posudku i pro další zájemce), kdyby student vytvořené programy a zejména získanou datovou sadu ve vhodné formě zpřístupnil.	

Odborná úroveň	průměrná
<i>Posuďte úroveň odbornosti závěrečné práce, využití znalostí získaných studiem a z odborné literatury, využití podkladů a dat získaných z praxe.</i>	
Teoretická část textu se zaměřuje nejen na architekturu NN, ale i na matematickou a algoritmickou stránku jejich trénování, úskalí, která v praxi mohou nastat, a jejich možná řešení. Text je strukturován tak, že se čte velmi dobře a obsahuje řadu vhodných intuitivních vysvětlení a příkladů. Toto pozitivní hodnocení je však nutno konfrontovat se skutečností, že značné části kapitol 1--3 vznikly volným překladem a zkrácením pasáží ze zdroje [26], a to ne vždy zcela správným. V těchto kapitolách je výklad někdy nekonzistentní, neúplný nebo zmatený. Hned zpočátku se používají nedefinované pojmy (váhy, bias, perceptron), které jsou správně vysvětleny až dále. Chybí mi nadhled, který by student získal širší rešerší literatury. Z textu například vzniká dojem, že NN jsou určeny pouze pro klasifikační problémy, kde výstupy jsou ve formě „one-hot encoding“, přičemž takový problém není vůbec formálně definován. Regresní úlohy vůbec nejsou zmíněny. O ztrátové funkci křížové entropie se hovoří jako o lepší alternativě k MSE, přičemž studentovi uniká, že ji lze použít pouze právě	

v klasifikačních úlohách. V celém textu se rozlišují „biasy“ (vychýlení) a váhy, což není moc šikovné a dochází k zbytečnému opakování analogických vztahů. Stačilo by zavést (jak je to běžné v literatuře) na vstupu každého neuronu $x_0=1$ a váha w_0 je pak odpovídající vychýlení. Všechny tyto nedostatky vycházejí z přílišného spoléhání na zdroj [26], který je však spíše neformálním úvodem do NN než ucelenou učebnicí.

Další nedostatky:

- aktivační funkce je funkce 1 reálné proměnné, ne celého vstupu x , ale v textu se oba přístupy různě mísí
- str. 21: tvar y pro MNIST (one hot encoding) není vysvětlen, ani to, že vektor x je obrázek rozložený po řádcích
- str. 12: rozumí se derivace podle parametrů, ne podle výstupu
- označení θ na str. 17 není definováno
- str. 23: vágní a zavádějící formulace: „máme zaručeno, že delta-C je nekladné, pokud aproximace ze vztahu (2.5) je dostatečně přesná“ – Přesnost aproximace klesá s rychlostí učení a naopak pro dost velkou rychlost učení máme zaručeno, že už to fungovat nebude. Není diskutováno, jak tedy volit rychlost učení.
- k údajné optimalitě gradientního sestupu – Metoda je „optimální“ jen za daných předpokladů, jak je velmi opatrně vysvětleno v [26]. Student neuvádí žádné alternativy ke gradientnímu sestupu, jako jsou metody založené na 2. derivaci.

V kapitolách 5-7 popisujících vlastní výsledky je věcných nedostatků již podstatně méně.

Formální a jazyková úroveň

podprůměrná

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

Text bohužel působí dosti odbytým dojmem. Zdá se mi, že nejdříve student psal praktickou část, kde je řada tabulek, grafů a poctivě vytvořených barevných schematických nákrešů architektury NN. Výsledky jsou pečlivě popsány. Teoretická část je však psána „horkou jehlou“, s řadou překlepů a gramatických chyb i typografických prohřešků:

- nekvalitní převzaté obrázky (např. obr. 1.2, 6.6) s anglickými popisky, i když je lze snadno překreslit a popsat česky
- nekonzistentní velikost obrázků (obr. 1.3 vs 3.12 vs 3.14)
- titěrné nečitelné obrázky s průběhy trénování, které vznikly jako screenshoty GUI MATLABu (např. obr. 5.1).
- používání anglicko-českých zkomolenin (skenovat, parsovat, biasů, dataset, fittování). Na str. 23 je definována „rychlost učení“, ale dále je konzistentně používáno anglické „learning rate“.
- v úvodu i dále míchání přítomného a budoucího času ve výkladu
- přetékání přes okraj stránky (např. str 37)

Popis obrázků je příliš stručný, takže je někdy (hlavně u těch převzatých) potřeba si domýšlet jejich význam.

Výběr zdrojů, korektnost citací

průměrné

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

Citace v kap. 1 a 2 jsou sporadické, bylo by lepší odkazovat na jednotlivé kapitoly knih u jednotlivých podsekcí. V kapitole 3 výklad dlouho probíhá zcela bez citace. Naprostá většina citací je do r. 2016, což je z hlediska NN pravěk. Výklad algoritmu zpětného šíření (backpropagation) opět vychází ze zdroje [26], který je z r. 2015, a lze jej použít pouze na plně propojené dopředné síť řešící klasifikační úlohu. Dnes se v softwarových balíčcích pro NN (PyTorch, TensorFlow, ale i MATLAB) používá jeho zobecnění, tzv. zpětné automatické derivování (Reverse

mode automatic differentiation), které umí vypočítat gradient nejen z NN, ale z libovolné algoritmicky vyčíslené funkce, což umožňuje použít tyto nástroje např. pro hluboké zpětnovazební učení (deep reinforcement learning) i zcela mimo oblast strojového učení (v oboru matematické optimalizace a optimálního řízení).

Pro NN doporučuji knihu „Aggarwal – Neural Networks and Deep Learning, 2nd ed. , Springer, 2023.“.

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.

Viz celkové hodnocení níže.

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.

Student dokázal, že je schopen porozumět principu strojového učení pomocí CNN a využít prostředky MATLABU pro otestování existujících architektur CNN i implementaci vlastních. Rozsáhlou praktickou část pečlivě zpracoval, vyhodnotil výsledky a ve vhodné formě je prezentoval. Dobrý dojem z odvedené práce však snižuje řada formálních nedostatků a rovněž teoretická část, která se příliš spoléhá jen na malý počet zdrojů, které navíc již nejsou zcela aktuální. Je též škoda, že jsem neměl k dispozici k nahlédnutí zdrojové kódy a datovou sadu, kterou student s pomocí řady dobrých nápadů získal a vyčistil tak, aby se dala úspěšně použít k trénování CNN.

Rád bych, aby u obhajoby zazněly odpovědi na následující otázky:

1. Je epsilon v GD metodách a batch normalizacích opravdu šum, nebo jen konstantní parametr?
2. V části 5.8, resp. 5.9 hovoříte o manuálním vytvoření datasetu, resp. manuální kontrole několika tisíc snímků. Opravdu jste manuálně zpracovával takový počet snímků?
3. Proč jste se společně s Vaší vedoucí rozhodli použít MATLAB a ne PyTorch nebo Keras? (Tato volba je přímo součástí zadání práce.)

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

Chýně, 25.8.2023

Ing. Pavel Strachota, Ph.D.

