

Oponentský posudok na PhD dizertačnú prácu

Learning with Regularisation Networks

Autor práce: **Petra Kudová**, Matematicko-fyzikálna fakulta, Karlova univerzita, Praha

Školiteľ: **Mgr. Roman Neruda, CSc.**, Ústav informatiky AV ČR, Praha

Predložená práca je z oblasti neurónových sietí (NS) a vychádza z teoretických poznatkov získaných predovšetkým pri štúdiu teórie regularizácie neurónových sietí. Aplikácie regularizačných neurónových sietí (RNS) si vyžadujú dôsledné znalosti o regularizačnom parametri a kernel funkciach. Základný učiaci algoritmus pre tieto siete je teoreticky podložený, dáva presné výsledky, ale jeho použiteľnosť napríklad pri veľkých dátach je nevhodná, preto je tu potrebné hľadať nové algoritmy. Práca je venovaná skúmaniu vyššie spomínaných dôležitých problémov a tiež návrhu inovovaných modelov RNS, ktoré sú tiež skúmané experimentálne.

Práca je napísaná v anglickom jazyku prehľadne a čitateľne s dobrou a peknou grafickou úpravou. Spolu s úvodom a záverom obsahuje sedem kapitol spracovaného textu. Zoznam preštudovanej literatúry obsahuje 76 položiek, zoznam publikácií autorky práce má 23 položiek, medzi ktorými je 13 uvedených ako samostatné práce. Priložené CD obsahuje text PhD práce, dátá, na ktorých boli vykonané experimenty, a doplňujúce informácie nutné k podaniu práce.

Teoretické základy k RNS sú spracované v druhej kapitole práce a vychádzajú zo známych výsledkov T. Poggia a S. Smalea (ale aj ďalších). V niektorých prípadoch autorka dosiahla známe výsledky pomocou modifikovaných odvodení. V druhej kapitole sú popísané novo navrhnuté modely RNS, a sice *Product Kernel Regularisation Networks* a *Sum Kernel Regularisation Networks*, ktoré autorka vytvorila a študovala spolu s T. Šámalovou. Pre nové modely sú analyzované aj vhodné možnosti pre ich použitie. Štvrtá kapitola je venovaná analýze regularizačných parametrov a metódam krízového vyhodnotenia získaných výsledkov. Piata kapitola prináša tri algoritmy pre trénovanie Radial Basis Neurónových Sietí (RBNS), z ktorých minimálne tretí využívajúci genetické algoritmy, je v tejto oblasti nový. Tiež sú tu spomenuté hybridné metódy kombinujúce iné známe metódy.

Experimentálne výsledky a ich príprava je obsahom rozsiahlej šiestej kapitoly. Experimenty na otestovanie algoritmov boli urobené na benchmarkových dátach PROBEN1, ale tiež na reálnych dátach nameraných pri skúmaní toku rieky Ploučnice. Dosiahnuté výsledky sú uvedené v tabuľkách a farebných grafoch a z nich vyplýva, že výsledky nových modelov a algoritmov sú celkom vyhovujúce. Podstatná časť kapitoly je venovaná experimentom s RBF sieťami, pre ktoré boli navrhnuté učiace algoritmy v predchádzajúcej piatej kapitole. Do diskusie ponúkam dve otázky na vyhodnocovanie algoritmov v nasledujúcom tvare:

- Mám e – presnosť, d – dôveryhodnosť. Algoritmus mi dá výsledky, ktoré sú predstavované funkciou L, skutočnosť je funkcia T. Chcela by som vedieť, či som dosiahla danú presnosť odchýlky (na všetkých tréningových údajoch platí $|F(x)-T(x)| \leq e$ pre všetky tréningové hodnoty x) a nakoľko percent tomu môžem veriť, čo by som porovnala s d. Dalo by sa uvažovať o vyhodnocovaní uvedených učiacich algoritmov

v tomto zmysle? Je nutné využiť všetky pripravené tréningové príklady? Moja otázka smeruje k možnostiam použitia PAC učenia v tejto oblasti.

- Práca obsahuje rozsiahlu šiestu kapitolu, v ktorej sú popísané výsledky experimentov. Experimentálne bolo preskúmaných viacero modelov, výsledky poskytujú obraz na použiteľnosť sietí na dátach podobného typu, ako sú benchmarkové dátá. Kapitola svedčí o tom, že pri získavaní týchto výsledkov bolo strávených veľa hodín. Dalo by sa pre skúmané modely povedať, že na trénovanie na týchto dátach daný model sa spotrebuje toľko času bez merania pomocou stopiek?

Prechodom cez zoznam stanovených cieľov dizertačnej práce a porovnaním s výsledkami uvedenými v práci konštatujem, že stanovené ciele boli splnené. Tým nemyslím, že všetko v danej oblasti je vyriešené a v jednotlivých bodoch nemožno pokračovať a urobiť viac. O niektorých možnostiach autorka hovorí v závere práce. Vytýčené zámerы do budúcnosti vyplynuli z výsledkov práce, sú priateľné a poukazujú na to, že autorka skúmanú problematiku ovláda.

Prínos práce je predovšetkým v nasledujúcim:

- v teoretickej časti je to návrh nových modelov regularizačných neurónových sietí a návrh nových aj modifikovaných algoritmov na ich učenie,
- v praktickej časti jednak autorka popísala výsledky z praktickej aplikácie RNS pri predikcii vodného toku rieky Ploučnice, jednak spracovala množstvo výsledkov získaných pomocou študovaných modelov RNS a algoritmov na ich učenie, čím poskytla náhľad do práce funkčných aplikácií RNS.

Autorka práce dosiahnutými výsledkami preukázala schopnosť samostatnej tvorivej vedeckej práce.

Záver:

Práca splňuje všetky požiadavky kladené na PhD dizertačnú prácu, preto ju odporúčam k obhajobe a po jej úspešnom obhájení odporúčam Petre Kudovej udeliť titul PhD.

Košice 14. novembra 2006

