

Oponentský posudek doktorské disertační práce Mgr.
Petry Kudové: Learning with Regularization Networks

Obor: Teoretická informatika (OR I-1)

Univerzita Karlova v Praze, Matematicko-fyzikální fakulta

Recenzent: RNDr. Kateřina Hlaváčková-Schindler, CSc.

Commission for Scientific Visualization, Austrian Academy of Sciences

Techgate, Donaucitystr. 1, 1220 Vienna, Austria

Neuronové sítě typu RBF a stejně tak regularizační sítě jsou od svého vzniku často využívanými metodami pro problém klasifikace či funkcionální approximaci. Byť jsou studovány v literatuře již skoro 20 let, kvalitních prací studujících souvislosti mezi typem sítě, učícím algoritmem a typem datové množiny je v literatuře nedostatek. Z tohoto pohledu je téma práce Mgr. Petry Kudové velmi aktuální.

Práci lze rozdělit do dvou částí. První teoreticky seznámuje s pojmem regularizačních sítí, se součinem a součtem regularizačních sítí, z nichž poslední dva pojmy jsou originálním příspěvkem autorky. Je zde dokázána na první pohled poněkud modifikace věty od Poggio a Smale o tvaru minima funkcionálu vyjadřujícího chybu pro regularizační kernelové sítě (str. 16 a 17 disertace). Tato modifikace funkcionálu však zaručí, na rozdíl od jejich práce, kde je funkcionál normovaný, že získané řešení bude numericky přípustné. V této části se dále popisují alternativy učících algoritmů pro regularizační a RBF sítě. Druhá, rozsáhlější část práce, se věnuje experimentům.

Mé celkové hodnocení celé práce je velmi pozitivní, připomínky se týkají víceméně jen formální stránky práce (viz níže). Práce je přehledně napsána a je přímosem do oboru neuronových sítí. Co se týče navržených učících algoritmů, tří-fázové učení i genetické učení pro RBF i regularizační sítě jsou známy z literatury (např. [1], [2], [4]). Není mi však známa práce, která by tyto typy učení mezi sebou srovnávala. Tomuto srovnání se věnuje druhá část práce zabývající se rozsáhlými experimenty, jednak na approximačních a klasifikačních problémech se známými datovými množinami, tak na problému predikce toku tekky Plotěnice na reálných datech. Experimenty a jejich porovnání je dokumentováno přehlednými grafy, tabulkami a obrázky na dobré grafické úrovni. Závěrečné hodnocení jednotlivých učících metod v závislosti na typu a velikosti datové množiny, respektive, zda se jedná o approximační, klasifikační či prediktivní problém, je adekvátní rozsahu práce a výsledkům experimentů. Dovolila bych si poznámku k uvedeným námětům k budoucí práci. S uvedenými body výzkumu do budoucna lze jen souhlasit. Jako další bod bych připojila

problém závislosti velikosti sítě (regularizační i RBF) a její chyby aproximace. K této otázce se většinou v literatuře, včetně této disertace, přistupuje experimentálně, ale existují některé teoretické výsledky, např. [5], [3]. Teoretické znalosti autorky v první části této disertace opravňují předpokládat, že by je mohla autorka využít pro odhad velikosti architektury sítí, které využívá v experimentech.

Vzhledem k tomu, že práce splňuje všechny předpoklady kladené na doktorské disertace, doporučuji, aby byl Mgr. Petře Kudové udělen titul PhD.

Konkrétní poznámky k textu:

Str. 19

The choice of kernel is equivalent to the choice of prior assumption about the problem - spíš, že to určuje ty podmínky, slovo *equivalent* je zde zavádějící.

Str.23

Vzorec 3.11: chybí tam $i = 1, \dots, k$

Str.23

Vzorec 3.12: - chybí indexování přes i , tj. nahrad'te c_1, \dots, c_k pomocí c_1^i, \dots, c_k^i .

Str. 51-52 *Three step learning* - Je třeba říci, že nalezené řešení nemusí být globálním minimem, když se určují parametry postupně ve fázích.

References

- [1] Chaiyaratana, N, Zalzala, A.M.S.: Evolving hybrid RBF-MLP networks using combined genetic /unsupervised/supervised learning UKACC International Conference on Control (CONTROL '98), 1998.
- [2] Chen, S., Wu, Y. and Luk, B.L.: Combined genetic algorithm optimization and regularized orthogonal least squares learning for radial basis function networks, IEEE Transactions on Neural Networks, vol. 10, no. 5, September 1999.
- [3] Corradi, V., White, H.: Regularized neural networks: some convergence rate results, Neural Computation, 1995, vol. 7, no. 6, pp. 1225-1244.
- [4] Jin, Y., T. Okabe, T., Sendhoff, B.: Neural network regularization and ensembling using multi-objective evolutionary algorithms, Proceedings on Evolutionary Computation Conference, CEC2004, 2004.
- [5] Xu, L., Krzyzak, A. Yuille, A.: On radial basis function nets and kernel regression: Statistical consistency, convergence rates and receptive field size, Neural Networks, vol. 7, no. 4, pp. 609-628, 1994.