

DOKTORANTŪROS STUDIJŲ DALYKO SANDAS

Dalyko pavadinimas	Mokslų kryptis (šaka) kodas	Fakultetas	Katedra
Dirbtiniai neuroniniai tinklai	09 P	MIF	Informatikos
Studijų būdas	Kreditų skaičius	Studijų būdas	Kreditų skaičius
paskaitos	4	konsultacijos	1
individualus		pratybos	2

Dalyko anotacija. Supažindinama su pagrindiniais dirbtinių neuroninių tinklų tipais, jų sudarymo principais ir jų mokymo, parinkimo teoriniais pagrindais.

1. Neuronų matematinis modelis. Vienasluoksnis perceptronas, jo mokymas, nuostolių funkcija ir gradientinis mokymo algoritmas. Problemos, atsirandančios mokant dviejų ir daugelio klasių atvejais.
2. Skirtumai tarp VSP-ų, naudojamų regresijos lygties ir klasifikavimo lygčių gavimui.
3. Reguliarizuota ir robastrinė regresija ir klasifikatoriai. Optimalaus regularizavimo parametro radimas. VSP panaudojimas įvairioms regresijoms gauti.
4. Klasifikavimo uždavinio statistinis formulavimas. I-os ir II-ros klasifikavimo klaidos ir jų tikimybės, apriorinės klasių tikimybės. Asimptotinė ir bajesinė klasifikavimo klaidos. Neteisingo klasifikavimo kainos ir jų vertinimas sudarant klasifikavimo taisykles.
5. Euklidinio atstumo, Fišerio klasifikatoriai. Regularizuota diskriminantinė analizė. Kvadratinis klasifikatorius.
6. Robastinis ir atraminių vektorių klasifikatoriai.
7. Klasifikavimo ir prognozavimo lygčių tikslumo rodikliai ir jų įvertinimas .
8. Kokie klasifikatoriai gaunami mokant vienasluoksnį perceptroną.
9. Pradinių sąlygų įtaka. Optimalus VSP mokymo ilgis, optimalus sustojimas.
10. Klasifikavimo klaidos įvertinimo būdai. Klasifikavimo klaidos įvertinimo tikslumas
11. Daugiasluoksnis perceptronas klasifikavimo ir prognozavimo uždavinių sprendimui. Nuostolių funkcija ir jos minimizavimo problemos. Gradientinio mokymo algoritmo ypatumai (stochastinis ir totalinis gradientai, inicializacija, nuostolių funkcijos paviršius, svorių augimas mokymo metu, triukšmo pridėjimas mokymo metu).
12. Neparametrinės - lokales k -artimiausių kaimynų bei Parzeno lango klasifikavimo taisyklės.
13. Požymių išrinkimas. Perceptrono „genėjimas“ (nereikalingų paslėptų neuronų atmetimas).
14. Požymių išskyrimas. DSP panaudojimas požymių išskyrimui
15. Klaster analizės uždavinys. k -vidurkių algoritmas. Dendrogramos.
16. Radialinių bazinių funkcijų ir mokymo vektorių kvantavimo neuroniniai tinklai, jų ryšys su k - artimiausių kaimynų ir Parzeno lango klasifikavimo ir prognozavimo algoritmais.
17. Duomenų transformavimas VSP mokymui palengvinti.
18. Genetiniai algoritmai. Jų panaudojimas DSP architektūrai parinkti ir mokymo procesui tobulinti.
19. Sprendimo medžiai ir jų ryšys su daugiasluoksniais perceptronais.
20. Neuroninių tinklų kooperavimas.
21. Aklas signalų išskyrimas dirbtinių neuroninių tinklų pagalba.
22. Neuroninio tinklo architektūros parinkimo patikimumas.

Praktinis darbas naudojant dirbtinius neuroninius tinklus analizuojant empirinius duomenis, pageidautina, savo disertacinio darbo tematikos kryptimi.

Pagrindinė literatūra

1. Introduction to pattern recognition : a MATLAB® approach / Sergios Theodoridis
2. Pattern recognition, 4th edition, by S. Theodoridis and K. Koutroumbas, Academic Press, 2009.
3. Haykin S. S. Neural Networks: A Comprehensive Foundation. Prentice Hall. 1998.
4. Ben Krose and Patrick van der Smagt, An Introduction to Neural Networks, Eight edition, 1996;
5. S.Raudys. Statistical and Neural classifiers: An integrated approach to design. Springer, NY, 2001 (galima rasti MIF Informatikos katedros internetiniame puslapyje)
6. Š. Raudys, Žinių išgavimas iš duomenų. KU, Klaipėda, 2008 (galima rasti MIF Informatikos katedros internetiniame puslapyje)

Konsultuojančiųjų dėstytojų vardas, pavardė	mokslo laipsnis	pedag. vardas	Svarbiausieji darbai mokslo kryptyje (šakoje) paskelbti per pastaruosius 5 metus
Šarūnas Raudys	habil. dr.	prof.	<ol style="list-style-type: none"> 1. S. Raudys, A. Raudys. Pair-wise costs in multi-class perceptrons. <i>IEEE Transactions on Pattern Analysis and Machine Intelligence</i> (ISSN 0162-8828), vol. 32, pp. 1324-1328, 2010. 2. S. Raudys, R. Kybartas, E. K. Zavadskas. Complexity and sample-size issues in multi-category nets of single-layer perceptrons. <i>IEEE Trans. on Neural Networks</i> (ISSN 1045-9227), vol. 21, 784-795, 2010. 3,4. S. Raudys. Trainable fusion rules. II. Small sample size case. <i>Neural Networks</i> (ISSN 0893-6080), vol. 19, pp. 1517-1527, 2006. I. Large sample size case. <i>Neural Networks</i>, vol. 19, pp. 1506-1516, 2006. 5. Ш.Рудис (S. Raudis), В.Юстицкий (V. Yustitskis). Закон Йеркса—Додсона: связь между стимулированием и успешностью научения. <i>Вопросы психологии (Voprosy Psikhologii)</i>, ISSN 0042-8841), №3, стр. 119-128, 2008.

Patvirtinta Matematikos ir informatikos fakulteto taryboje 2012 m. kovo 6 d., protokolo Nr. 7

Fakulteto tarybos pirmininkas

prof. Gediminas Stepanauskas