

Daugiamatių duomenų vizualizavimas išvertinant savireguliuojančių neuroninių tinklų mokymo eiga

Gintautas DZEMYDA, Olga KURASOVA (MII)

el. paštas: dzemyda@ktl.mii.lt, kurasova@ktl.mii.lt

1. Įvadas

Daugiamatių duomenų vizualizavimas – sudėtinga problema. Vienas iš daugiamatių duomenų vizualizavimo metodų – Sammono algoritmas [1]. Daugiamatę erdvę projektuojant į plokštumą neišvengiamos projekcijos paklaidos. Būtina kurti metodus, minimizuojančius šias paklaidas. Anksčiau atliliki tyrimai [2] parodė, kad savireguliuojančių neuroninių tinklų (SOM) kombinacija su Sammono algoritmu yra efektyvus projektavimo būdas. Čia po neuroninio tinklo apmokymo gauti vektoriai (neuronai-nugalėtojai) analizuojami ir vizualizuojami Sammono algoritmu. Šiame straipsnyje pasiūlyta nauja SOM ir Sammono algoritmo kombinacija, kai daugiamatiai duomenys projektuojami į plokštumą pagal Sammono algoritmą, išvertinant savireguliuojančių neuroninių tinklų mokymo eiga. Parodyta, kad naujuoju algoritmu gaunama mažesnė daugiamatių vektorių projektavimo į dvimatių plokštumą vidutinė paklaida.

2. Daugiamatių duomenų vizualizavimo būdai

Sammono algoritmas. Sammono projekcija [1] yra netiesinio daugelio kintamųjų objektų (vektorų) atvaizdavimo žemesnio matavimo erdvėje metodas. Nagrinėsime atveją, kai projektinės erdvės, į kurią atvaizduojame, dimensija yra 2, t. y. atvaizduojame į plokštumą.

Tarkime, turime daugiamatius vektorius x_1, x_2, \dots, x_m , priklausantius erdvėi R^n . Čia $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$, $i = \overline{1, m}$. Sprendžiamas uždavinys – šiuos n -mačius vektorius x_1, x_2, \dots, x_m atvaizduoti (gauti projekciją) plokštumoje R^2 . Juos atitiks dvimatių vektoriai $y_1, y_2, \dots, y_m \in R^2$. Čia $y_i = (y_{i1}, y_{i2})$, $i = \overline{1, m}$. Pažymėkime d_{ij}^* atstumą tarp daugiamatių vektorių x_i ir x_j , d_{ij} – atstumą tarp vektorių x_i ir x_j atitinkančių dvimatių vektorių y_i ir y_j ($i, j = \overline{1, m}$). Sammono algoritmas minimizuoją projekcijos iškraipymą (paklaidą):

$$E_s = \frac{1}{\sum_{\substack{i,j=1 \\ i < j}}^n d_{ij}^*} \sum_{i,j=1 \atop i < j}^n \frac{(d_{ij}^* - d_{ij})^2}{d_{ij}^*}. \quad (1)$$

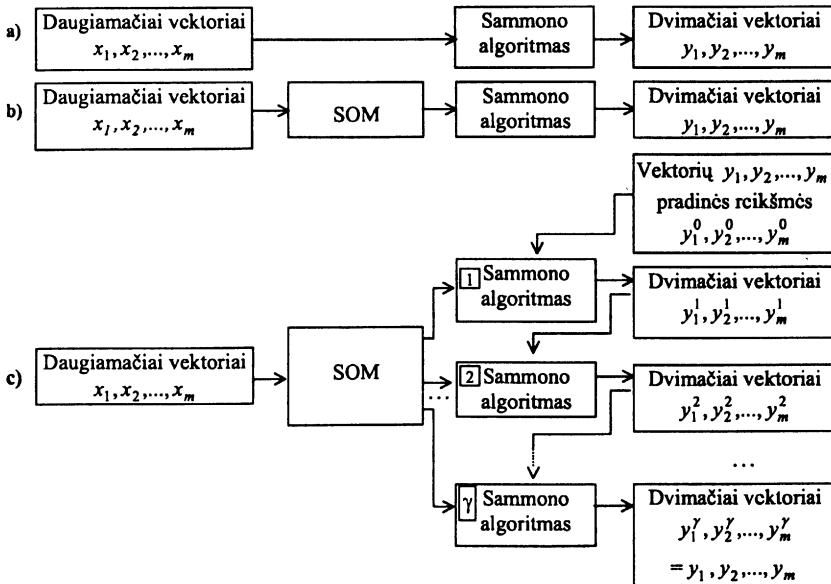
Dvimačių vektorių $y_i \in R^2$ komponentės y_{ik} , $i = \overline{1, m}$, $k = \overline{1, 2}$ randamos naudojantis iteracine formulė:

$$y_{ik}(m' + 1) = y_{ik}(m') - \alpha \frac{\frac{\partial E_s(m')}{\partial y_{ik}(m')}}{\left| \frac{\partial^2 E_s(m')}{\partial y_{ik}^2(m')} \right|}, \quad (2)$$

čia m' yra iteracijos numeris, o α vadinamas „magiškuoju faktoriumi“, kadangi nuo jo priklauso projekcijos paklaida.

Savireguliuojantys neuroniniai tinklai. Šiame darbe nagrinėsime savireguliuojančius neuroninius tinklus dar vadinamus Kohoneno neuroniniais tinklais. Kohoneno tinklas [3] yra neuronų masyvas, paprastai išdėstyti dvimačio tinklelio, dar vadinamo žemėlapiu arba lentele, mazguose. Kiekvieną žemėlapio elementą atitinka n -matis vektorius. Stačiakampis tinklelis (žemėlapis) yra sudarytas iš $q \times r$ elementų – n -mačių vektorių: q eilučių ir r stulpelių. Neuroninis tinklas apmokomas, jam daug kartų pateikiant v skirtingu objektų, nusakomų n -mačiais vektoriais. Apmokant tinklą apskaičiuojami žemėlapio vektoriai ir tuos vektorius atitinkančių objektų numeriai, t.y. objektai pasiskirsto tarp žemėlapio elementų. Netuščius lentelės langelius atitinkančius vektorius, t.y. neuronus-nugalėtojus, galima analizuoti Sammono algoritmu.

Sammono algoritmo kombinacijos su savireguliuojančiais neuroniniais tinklais. Atvaizduojant n -mačius vektorius x_1, x_2, \dots, x_m plokštumoje, naudojant SOM kombinaciją su Sammono algoritmu, galimi trys scenarijai pateikti 1 pav. 1a pav. pavaizduota daugiamacių vektorių vizualizavimo algoritmo struktūra, kai vektoriai x_1, x_2, \dots, x_m atvaizduojami plokštumoje naudojant Sammono algoritmu. Vektorius x_1, x_2, \dots, x_m



1 pav. Daugiamacių vektorių projekcijos plokštumoje scenarijai.

plokštumoje atitinka dvimatičiai vektoriai y_1, y_2, \dots, y_m . 1b pav. pavaizduoto algoritmo pradžioje n -mačiais vektoriais apmokamas neuroninis tinklas, vėliau netuščius lentelės langelius atitinkantys vektoriai (neuronai)-nugalėtojai analizuojami Sammono algoritmu. Vektorių-nugalėtojų skaičius paprastai būna mažesnis nei m , o tada tarp vektorių y_1, y_2, \dots, y_m būna ir sutampančių, t. y. kelis vektorius iš x_1, x_2, \dots, x_m atitiks vienas plokštumos taškas. 1a ir 1b atvejai detaliau aptarti darbe [2]. Kad būtų galima geriau palginti 1 pav. algoritmus, šiame darbe tyrimoje naudota 1b algoritmo modifikacija (toliau – 1b algoritmas). Trumpai aptarsime. Neuroninio tinklo mokymo rezultate kiekvieną netuščią lentelės langelį atitinka vieną ar keli vektoriai iš x_1, x_2, \dots, x_m ir vieną n -matis vektorius-nugalėtojas. Sammono algoritmu analizuojami ne vektoriai-nugalėtojai, bet m n -mačių vektorių z_1, z_2, \dots, z_m sistema, susidedanti iš vektorių-nugalėtojų, kiek vieną kurių yra pakartotas tiek kartą, kiek yra tą vektorių atitinkančių vektorių tarp x_1, x_2, \dots, x_m . Toliau bus išsamiau nagrinėjamas algoritmas, kurio struktūra pateikta 1c pav. Tai naujas savireguliuojančių neuroninių tinklų ir Sammono atvaizdavimo apjungimo algoritmas. Tyrimai parodė, kad būtent tokia SOM ir Sammono algoritmo kombinacijos struktūra tinkamiausia norint rasti tikslesnę daugiamatičių vektorių projekciją plokštumoje kriterijaus (1) prasme.

Algoritmo struktūra

- Neuroninį tinklą apmokykime n -mačiais vektoriais x_1, x_2, \dots, x_m naudodami e epochų. Epocha – tai mokymo proceso dalis, kai visus vektorius atsitiktine tvarka pateikiame tinklui po vieną kartą.
- Prieš neuroninio tinklo apmokymą pasirenkame į kelis blokus γ skaidysime mokymo eiga.
- Po p mokymo epochų ($p = e \bmod \gamma$) gautus vektorius-nugalėtojus analizuojame Sammono algoritmu. Pradinės dvimatičių vektorių $y_i^0 = (y_{i1}^0, y_{i2}^0)$, $i = \overline{1, m}$, koordinatės imamos tokios: $y_{i1}^0 = i + \frac{1}{3}$, $y_{i2}^0 = i + \frac{2}{3}$. Sammono algoritmu apskaičiuojame vektorių-nugalėtojų dvimates projekcijas, o tuo pačiu ir n -mačių vektorių x_1, x_2, \dots, x_m dvimates projekcijas $y_1^1, y_2^1, \dots, y_m^1$ ($y_i^1 = (y_{i1}^1, y_{i2}^1)$, $i = \overline{1, m}$).
- Neuroninio tinklo mokymas tęsiamas toliau. Po sekančių p epochų gautus vektorius-nugalėtojus vėl analizuojame Sammono algoritmu. Dabar pradinės dvimatičių vektorių $y_1^2, y_2^2, \dots, y_m^2$ koordinates imame lygias prieš tai buvusio atvaizdavimo dvimatičių vektorių $y_1^1, y_2^1, \dots, y_m^1$ koordinatėms.
- Po γ tokų žingsnių gauname dvimatičius vektorius $y_1^\gamma, y_2^\gamma, \dots, y_m^\gamma$, kurie atitinka n -mačių vektorių x_1, x_2, \dots, x_m dvimates projekcijas y_1, y_2, \dots, y_m .

Norint parodyti, kad, kokia bebūtų α reikšmė (2) formulėje, naujuoju algoritmu gaunama vidutiniškai mažesnė paklaida, negu algoritmu 1b, tyriame buvo analizuojami atvejai su įvairiomis α reikšmėmis. Minimali projekcijos paklaida E_s ieškoma gradientiniu metodu (2). Iteracijoms augant, paklaidos reikšmė mažėja, tačiau pasitaiko atvejų, kai kažkurios iteracijos metu paklaida staigiai išauga ir vėl sumažėja [4]. Tokia situacija gali būti ir paskutinės iteracijos metu. Norint neužfiksuoти tokios paklaidos reikšmės kaip galutinio rezultato, imama mažiausia paklaida, apskaičiuota visų iteracijų metu. Projekcijos paklaidos gali skirtis ir esant kitoms tinklo neuronų pradinėms reikšmėms, generuojamoms

atsitiktinai. Vadinasi, atsitiktinai gautis daug didesnė arba daug mažesnė paklaida ir naujuoju algoritmu, ir 1b algoritmu. Kad to išvengti, eksperimentai buvo vykdomi 25 kartus, gauti rezultatai suvidurkinti. 25 eksperimentų pilnai pakanka, kad vidurkiai pakliliūtų į savo pasikliautinuosius intervalus su pakankamai didele tikimybe. Atliekant eksperimentus pastebėta, kad vykdant 1b algoritmą pasitaikydavo atvejų, kad, iteraciniu būdu skaičiuojant projekcijos koordinates, projekcijos paklaidos E_s , antrosios eilės išvestinės tapdavo lygios nuliui. Toliau vykdyti skaičiavimų nebuvo galima, kadangi (2) formulėje antrosios eilės išvestinės yra vardiklyje. Tai atsitikdavo, kai neuroninis tinklas būdavo mažas (2×2), t. y. vieną neuroną-nugalėtoją atitikdavo keli apmokymo aibės vektoriai. Naujajame algoritme šią problemą pavyko nesunkiai išspręsti: jeigu analizuojant kažkuriuo mokymo bloko rezultatus antroji išvestinė lygi nuliui, tai tas tinklo mokymo blokas turi būti praleidžiamas, o analizuojant sekantį mokymo bloką, pradinės dvimačių vektorių koordinates reikia imti iš prieš tai buvusio „gero“ bloko.

3. Tyrimų rezultatai

Naujojo algoritmo (1c pav.) pranašumas prieš 1b algoritmą, parodytas analizuojant realius duomenis. Analizuoti ekologiniai duomenys, nusakantys Suomijos pajūrio kopas ir jų vegetaciją [5]. Kopas charakterizuojama šie parametrai: x_1 – atstumas nuo kranto; x_2 – aukštis virš jūros lygio; x_3 – dirvožemio PH; x_4, x_5, x_6, x_7 – kalcio (CA), fosforo (P), kalio (K), magnio (Mg) kiekis; x_8, x_9 – vidutinis smėlio skersmuo ir jo rūšis; x_{10} – šiaurumas pagal suomišką koordinacių sistemą; x_{11} – žemės kilimo greitis; x_{12} – jūros lygio svyravimas; x_{13} – dirvožemio drėgnumas; x_{14} – šlaito tangentas; x_{15} – smėlio paviršiaus dalis; x_{16} – medžiai apaugusi dalis. Darbe [5] yra pateikta šių 16 parametrų koreliacinė matrica. Naudojantis darbe [2] pasiūlytu metodu, gauti 16 objektų-vektorius ($v = 16$), atitinkančių parametrams $x_1 – x_{16}$, sudarytų iš 16 komponenčių ($n = 16$). Visi šie 16-mačiai vektoriai yra vienetinio ilgio.

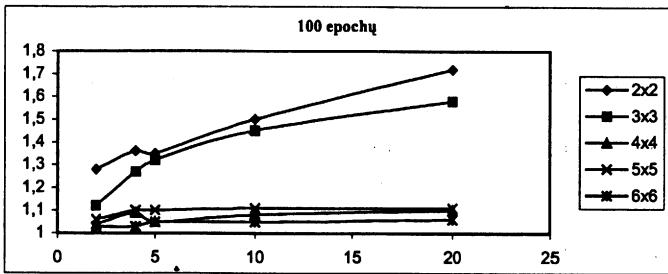
Analizuoti atvejai, esant įvairiam neuroninio tinklo dydžiui ($2 \times 2, 3 \times 3, 4 \times 4, 5 \times 5, 6 \times 6$), tinklo mokymo epochų skaičiui (100, 200, 300), Sammono algoritmo „magiškajam faktoriui“ α (0, 1; 0, 11; . . . ; 0, 89; 0, 9). Esant toms pačioms pradinėms sąlygomis, su visais minėtais parametrais apskaičiuotos projekcijos paklaidos ir 1b, ir naujuoju algoritmu. Kaip minėta anksciau, eksperimentai pakartoti 25 kartus, imant kitas atsitiktines pradines SOM neuronų-vektorų komponenčių reikšmes. Apskaičiuotas santykis tarp suvidurkintų projekcijos paklaidų, gautų 1b ir naujuoju algoritmais. Iš 1 lentelės ir 2 pav. matyti, kad šis santykis visada didesnis už vienetą. Vadinasi naujuoju algoritmu gautos vidutinės paklaidos yra mažesnės. Didinant neuroninio tinklo mokymo bloku γ skaičių (2 pav. abscisių ašis), šis santykis didėja. Tai ypač ryšku, kai analizuojamas mažas tinklas. Taip pat matyti, kad, didėjant tinklo dydžiui, santykis mažėja.

3 pav. parodyta, kad naujuoju algoritmu gauta vidutinė projekcijos paklaida mažiau priklauso nuo α reikšmės negu gautoji 1b algoritmu. Čia imtos suvidurkintos paklaidos, kai atlikti 25 eksperimentai. Pateiktame pavyzdyme neuroninio tinklo 2×2 apmokymui naudojama 200 epochų ir atsižvelgiama į 40 tarpinių mokymo rezultatų. Panašūs rezultatai gauti ir kitais atvejais.

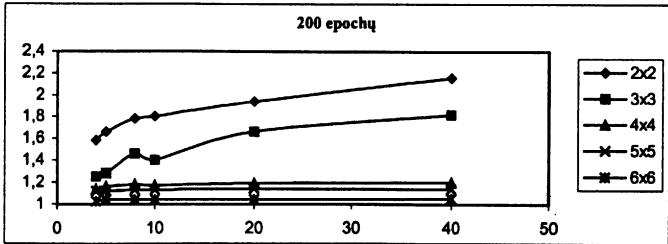
1 lentelė. Santykis tarp projekcijos paklaidos, gautos 1b ir naujuoju algoritmais

e	100					200					300					
p	50	25	20	10	5	50	40	25	20	10	5	60	50	30	25	15
γ	2	4	5	10	20	4	5	8	10	20	40	5	6	10	12	20
2×2	1,28	1,36	1,35	1,5	1,72	1,58	1,66	1,78	1,8	1,94	2,16	1,9	1,93	2,22	2,29	2,44
3×3	1,12	1,27	1,32	1,45	1,58	1,25	1,28	1,46	1,4	1,66	1,82	1,48	1,42	1,55	1,59	1,72
4×4	1,04	1,09	1,05	1,08	1,1	1,14	1,16	1,18	1,17	1,19	1,2	1,16	1,17	1,16	1,18	1,19
5×5	1,06	1,1	1,1	1,11	1,11	1,12	1,12	1,13	1,13	1,14	1,14	1,12	1,12	1,13	1,13	1,13
6×6	1,03	1,03	1,05	1,05	1,06	1,03	1,04	1,04	1,04	1,04	1,05	1,04	1,04	1,04	1,04	1,05

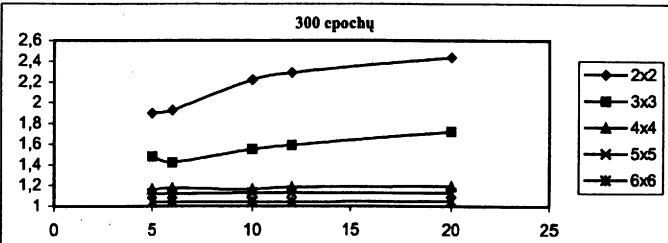
a)



b)



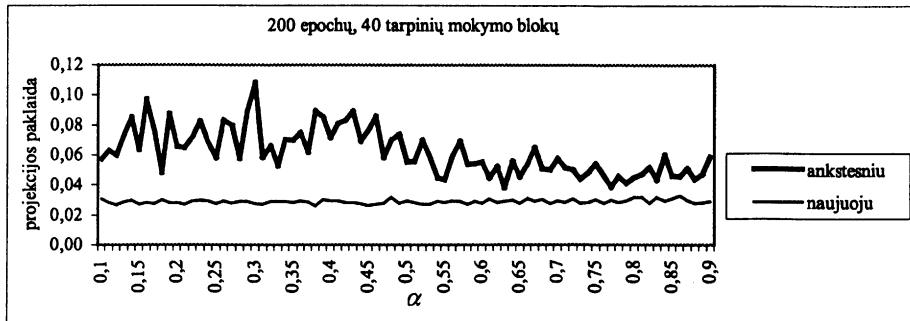
c)



2 pav. Projekcijos paklaidų santykis, kai SOM epochų skaičius yra: a) 100, b) 200, c) 300.

4. Išvados

Lyginant vidutines projekcijos paklaidas, gautas savireguliuojančių neuroninių tinklų ir Sammono atvaizdavimo kombinacija 1b, su šiame straipsnyje pasiūlytu nauju kombinavimo algoritmu, kai atsižvelgiama į neuroninio tinklo mokymosi eigą, matyti, kad nau-



3 pav. Paklaidos priklausomybė nuo α reikšmės.

juoju algoritmu gautos mažesnės projekcijos paklaidos, t. y. gaunama tikslėsnė projekcija. Kuo daugiau vertinama tarpinių neuroninio tinklo rezultatų, tuo pagerėjimas didėja. Gal būt analizuojant po kiekvienos neuroninio tinklo epochos gautus vektorius-nugalėtojus gautume dar geresnius rezultatus. Bet čia susiduriame su labai išaugančiu skaičiavimų laiku. Naujuoju algoritmu pavykdavo išvengti nuliniai antros eilės išvestinių, kurios naujojamos dvimačių vektorių koordinacijų skaičiavimui. Be to, naujuoju algoritmu gautų projekcijos paklaidų priklausomybė nuo α reikšmės yra mažesnė negu 1b algoritmu.

Literatūra

- [1] J.W. Sammon, A nonlinear mapping for data structure analysis, *IEEE Transactions on Computers*, **C-18**, 401–409 (1969).
- [2] G. Dzemyda, Visualization of a set of parameters characterized by their correlation matrix, *Computational Statistics and Data Analysis*, **36**(1), 15–30 (2001).
- [3] T. Kohonen, *Self-Organizing Maps*, 3rd ed., Springer Series in Information Sciences, **30**, Springer-Verlag (2001).
- [4] I. Apostal, W. Szpankowski, Indexing and mapping of proteins by Sammon's projection algorithm, *Journal of Computational Chemistry*, **20**, 1049–1059 (1999).
- [5] P. Hellemaa. *The Development of Coastal Dunes and their Vegetation in Finland*, Dissertation, Fenia 176:1, Helsinki (1998),
<http://ethesis.helsinki.fi/julkaisut/mat/maant/vk/hellemaa/index.html>

Visualization of multidimensional data taking into account the learning flow of the self organizing neural network

G. Dzemyda, O. Kurasova

In the paper we discuss the visualization of multidimensional vectors taking into account the learning flow of the self organizing neural network. A new algorithm realizing a combination of the self-organizing map (SOM) and Sammon's mapping has been proposed. It takes into account the intermediate learning results of the SOM. The experiments showed that the algorithm gives lower average projection errors compared with a consequent application of the SOM and Sammon's mapping.