

Dirbtiniai neuroniniai tinklai personalizuotam mokymuisi

Andrius Berniukevičius¹, Eugenijus Kurilovas^{1,2}

¹ *Vilniaus universitetas, Matematikos ir informatikos institutas*
Akademijos g. 4, LT-08663, Vilnius

² *Vilniaus Gedimino technikos universitetas, Fundamentinių mokslų fakultetas*
Saulėtekio al. 11, LT-10223, Vilnius

E. paštas: andriusber@gmail.com, jevgenij.kurilov@mii.vu.lt

Santrauka. Darbo paskirtis yra aprašyti metodą, kurio pagalba būtų galima personalizuoti mokymosi procesą panaudojant dirbtinius neuroninius tinklus. Personalizavimas susideda iš mokymosi stiliaus [2] nustatymo klausimyno pagalba bei to stiliaus priskyrimo konkrečiai mokymosi veiklai (objektui, scenarijui). Tačiau lieka esminis klausimas ar teisingai yra nustatytas mokymosi stilius, nes klausimynas nėra labai efektyvus norint gauti tikslią ir išsamią informaciją apie mokinį, todėl yra poreikis turėti mechanizmą, leidžiantį realiu metu stebėti, analizuoti ir kaupti duomenis apie mokinio sąveiką su mokomąja aplinka ir tokiu būdu nuolat koreguoti ir tikslinti mokymosi stilius ir personalizuotus scenarijus (objektus, veiklas).

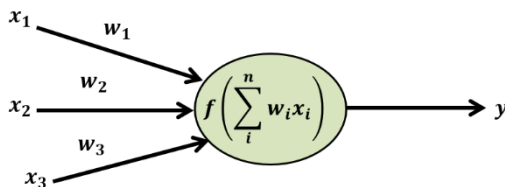
Raktiniai žodžiai: personalizavimas, mokymosi stilius, dirbtinis neuroninis tinklas.

Įvadas

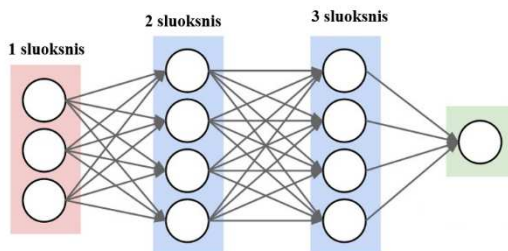
Šiuo metu personalizavimo sąvoka yra labai populiari. Įmonės naudoja intelektualiuosius agentus, kurie analizuoja kiekvieną vartotoją ir pateikia konkrečiam vartotojui aktualias reklamas ir pasiūlymus. Google paieška kiekvienam atskiram vartotojui į tą pačią paieškos frazę pateikia skirtingus rezultatus, priklausomai nuo vartotojo ankstesnės paieškos istorijos ir interesų. Lygiai taip pat personalizavimo idėja yra aktuali pedagogikoje ir ją galima realizuoti dviem būdais:

- „rankinis būdas“: mokytojas individualiai tiria ir analizuoja kiekvieno mokinio mokymosi stilių, žinių lygį ir pan.
- išmanusis būdas: sukuriamas atskiro mokinio profilis, psichologinių klausimynų pagalba yra nustatomas mokinio mokymosi stilius ir pagal tai rekomendavimo sistema siūlo kokias veiklas, mokomuosius objektus ir ištikus scenarijus (kurie susideda iš mokomųjų objektų, veiklų ir aplinkos) pateikti konkrečiam mokiniui.

Realizuoti efektyviai rankinį būdą praktikoje yra neįmanoma dėl žmogiškojo faktoriaus – mokytojas negali detalai ir kruopščiai analizuoti kiekvieną mokinį, parinkti jam tinkančias veiklas (objektus, scenarijus) ir jas kurti. Nebent kiekvienam mokiniui duotume po mokytoją, bet tai yra neracionalu iš finansinės pusės. Išmanusis būdas taip pat turi trūkumų:



1 pav. Dirbtinis neuronas.



2 pav. Dirbtinis neuroninis tinklas.

1. Mokinio mokymosi stiliaus nustatymas psichologinių klausimynų pagalba nėra patikimas, nes mokiniai gali juos pildyti skubėdami, neįsigilindami ir apmąstydami savo mokymosi stiliaus.
2. Retas suaugęs, o tuo labiau mokinys, giliai, aiškiai save suvokia ir supranta, todėl atsakymai gali būti neadekvatūs ir reikia papildomai rinkti informaciją apie mokinį iš jo sąveikos su aplinka ir nuolat atnaujinti jo profilį. Šio darbo tikslas ir būtų pasiūlyti metodą kaip sukurti dinaminį mokinio profilį bei personalizuotus scenarijus, naudojant dirbtinį neuroninį tinklą.

1 Dirbtinis neuroninis tinklas

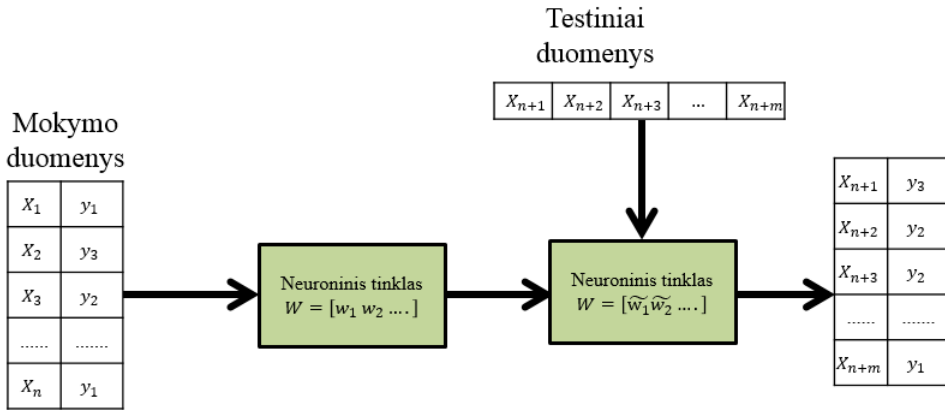
Dirbtiniu neuronu yra vadinama funkcija, kuri turi baigtinį skaičių įvesties reikšmių ir vieną išvesties reikšmę.

Tarpusavyje sujungtus dirbtinius neuronus vadiname dirbtiniu neuroniniu tinklu (DNT). Sluoksnių ir neuronų, esančių kiekviename sluoksnyje skaičius, priklauso nuo sprendžiamo uždavinio tipo ir sudėtingumo.

Imkime klasifikavimo uždavinį. Klasifikavimo uždavinys tai atpažinimo uždavinys, kai tam tikro objekto (vaizdo, garso ir kt.) skaitinius duomenis reikia priskirti kuriai nors klasei (pvz. iš pateiktų gyvūnų nuotraukų atskirti kur katė, o kur šuo). Laikysime, kad objektas yra aprašomas vektoriumi:

$$X = [x_1 \ x_2 \ x_3 \ \dots \ x_n]$$

Aibė $Y = [y_1 \ y_2 \ \dots \ y_m]$ aprašo visas klases y_i , kurioms gali priklausyti objektas X . Mokymo fazėje imame mokymo duomenis t. y. objektus su jiems priskirtomis klasėmis – (X_i, y_j) . Tuomet optimizavimo algoritmų pagalba parenkame neuroninio tinklo



3 pav. Neuroninio tinklo mokymo ir testavimo fazės.

koeficientus $w_1 w_2 \dots w_k$, taip, kad klasifikavimo funkcija K atvaizduotų mokymo fazės objektus X į klasę y , kurioms jie priklauso.

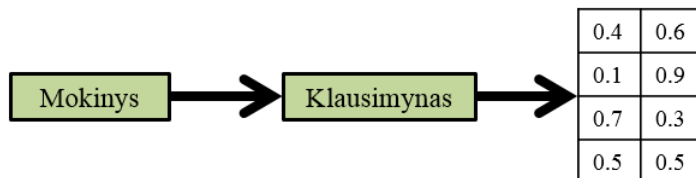
Testavimo fazėje imame kitą aibę porų (X_i, y_j) ir skaičiuojame kiek kartų klasifikatoriaus teisingai klasifikuoja objektus. Remiantis gauta statistika įvertiname klasifikatoriaus tikslumą. Jei tikslumas mus tenkina, sakome, kad neuroninis tinklas paruoštas darbui. Priešingu atveju koreguojame pradinį duomenis, keičiame pradinį reikšmių w_1, w_2 parinkimo būdus ir iš naujo mokome neuroninį tinklą.

Neuroniniai tinklai yra labai paklausūs vaizdų atpažinimo sferoje, nes demonstruoja labai gerą tikslumą – 99% [4]. Antra, lyginant su ankstesniais algoritmais [6] visiškai nereikia rūpintis bruožų išskyrimu (angl. Feature Engineering), nes ne visada aišku kokius bruožus laikyti esminiais, o kokius ne. Viskas ko reikia, DNT – tai tam tikro pradinį duomenų kiekio, kuris priklauso nuo uždavinio sudėtingumo, konkretaus algoritmo ir kt. Per pastaruosius metus vaizdų atpažinimo technologijos sparčiai žengė pirmyn ir dabar jau turime produktus, kurie sugeba iš žmogaus nuotraukos ar vaizdinės medžiagos atpažinti žmogaus emocijas ir nuotaiką [1, 3] (pvz. Microsoft Azure Emotion API). Taip pat puikūs rezultatai gauti testuojant autonomines mašinas (Google Mobile, Tesla), kurios labai tiksliai realiuoju laiku gauna informaciją (gatvės ir kelio vaizdai) iš aplinkos ir remiantis tuo priima sprendimus.

2 Vaizdo atpažinimo technologija personalizuotame mokyme

Individualaus mokinio profilis sudaromas taip:

- Klausimyno pagalba yra nustatomas mokinio mokymosi stilius, remiantis Felder – Silverman metodika [2]. Mokymosi stilius (MS) aprašomas koeficientų matrica.
- Kiekvienai mokomajai veiklai (MV) ir mokomajam objektui (MO) yra priskiriamas koeficientas (tarp 0 ir 1), nusakantis veiklos ar mokomojo objekto tinkamumą konkrečiam mokymosi stiliui. Koeficientai gaunami ekspertinio vertinimo metodu [5].



4 pav. Mokymosi stilių apibūdinanti koeficientų matrica.

- Mokinio mokymosi stiliaus koeficientai yra padauginami iš veiklų ir mokomojų objektų koeficientų.

$$MS_{ij} \cdot MO_{ij} \in [0; 1]$$

$$MS_{ij} \cdot MV_{ij} \in [0; 1]$$

- Tuomet veiklas ir mokomuosius objektus galima išrikiuoti eilės tvarka pagal jų tinkamumą konkrečiam mokiniui.

Toks modelis yra statinis, nes mes vieną kartą klausimyno pagalba nustatant mokinio mokymosi stilių darome prielaidą, kad informacija yra adekvati ir objektyvi. Bet klausimynas pasižymi šiais trūkumais:

- Klausimais atsakymais neįmanoma tiksliai, aiškiai visapusiškai ištirti žmogaus mąstymo, psichikos dėsningumą ir savitumą.
- Klausimynas gali būti pildomas pildomas paviršutiniškai, neįsigilinant į klausimus.
- Mokinys ne visada gali adekvačiai įvertinti savo savybes.

Todėl mums reikalingas dinaminis modelis, kad galėtume realiu laiku stebėti, analizuoti mokinį bei nuolat atnaujinti ir koreguoti informaciją apie jo mokymosi stilių. Mokiniui susidūrus su mokomąja aplinka kils įvairiausios situacijos:

- Mokymosi veikla ar mokomasis objektas neatitinka mokinio mokymosi stiliaus ir informacija per sudėtinga, todėl gali atsirasti apatija
- Mokymosi veikla ar MO neatitinka mokinio mokymosi stiliaus, nors informacija suprantama, todėl mokinį gali apimti nuobodulys
- Mokymosi veikla ir MO atitinka mokymosi stilių, bet žinių lygis yra nepakankamas ir informacija mokiniui per sudėtinga ir t. t.

Turėti atsakymus į šiuos klausimus yra svarbu, nes tada mes galime koreguoti mokinio mokymosi stilių ir mokytojas mato kiekvieno mokinių supratimo, koncentracijos, motyvacijos, žinių ir kt. lygį. Vienas iš galimų būdų išspręsti šį klausimą galėtų būti DNT panaudojimas.

Šiuo metu jau yra sukurti DNT galintys atpažinti žmogaus emocijas. Visi mokiniai yra skirtingi, tačiau visi patiria vienodas emocijas: baimę, apatiją, džiaugsmą ir pan. Kiekvieno žmogaus reakcija į nepažįstamą, į nesuprantamą situaciją (arba atvirkščiai) yra panaši.

Paimkime mokinį, pasodinkime jį prieš monitorių. Iš pradžių kamerų pagalba remiantis jo kūno kalba, veido išraiška nustatoma pradinė emocija, nuotaika. Tuomet ekrane atsiranda užduotis, kurią reikia atlikti ar informacija, kurią reikia suprasti. Ir tada realiu laiku mokinys yra stebimas. DNT gali kaupti tokio pobūdžio duomenis:

- Mokinys susikaupęs ar blaškosi?
- Jis susidomėjęs, nuobodžiauja, apatiškas, neutralus ir pan.?
- Kiek laiko jis bandė atlikti užduotį, po kiek laiko jis pradėjo blaškytis?

Klausimų galima iškelti įvairiausių ir jie mums gali duoti gana objektyvią ir adekvačią informaciją apie mokinio gebėjimus, mokymosi stilių, žinias, nes žmogaus kūno kalba žymiai tiksliau aprašo esamą situaciją nei žodžiai.

Tokių klausimų yra dar daugiau ir mokytojui labai svarbu turėti grįžtamąjį ryšį ir matyti kaip mokiniai reagavo į mokomąsias veiklas ir MO. DNT pagalba visą šią informaciją galima būtų fiksuoti ir identifikuoti. Šiai dienai Microsoft Azure Emotion klasifikatorius geba skirti šias emocijas: pyktis, panieka, pasišlykštėjimas, baimė, laimė, neutralumas, liūdesys, nuostaba. Analizuodamas konkretų veidą ir nuotaiką neuroninis tinklas kiekvienai emocijai priskiria koeficientą tarp 0 ir 1, kuris parodo tos emocijos buvimo tikimybę.

DNT mokymo fazėje paimti tūkstančius mokinių ir įvairiausių uždavinių bei veiklų pagalba fiksuoti besimokančiųjų emocijas ir nuotaikas. Išmokytas DNT gali būti naudojamas analizuojant mokinius mokomosiose veiklose ir sąveikoje su mokomaisiais objektais, tam kad koreguoti mokymosi stiliaus matricos koeficientus.

3 Išvados

Mokinio mokymosi stilius identifikuotas klausimyno pagalba turėtų būti nuolat analizuojamas ir koreguojamas, stebint mokinį mokomosiose veiklose ir sąveikaujant su mokomaisiais objektais. Šiam tikslui pasiekti galėtų būti panaudotas dirbtinis neuroninis tinklas, dėl jo puikių rezultatų atpažįstant vaizdus ir emocijas.

Dirbtiniai neuroniniai tinklai gali padėti mokytojui tiksliau nustatyti mokinių mokymosi stilius ir pagal jų duomenis sukurtus personalizuotus mokymosi scenarijus, tuo padidinant mokinių motyvaciją ir mokymosi rezultatus

Literatūra

- [1] D. Dagar, A. Hudait and H.K. Tripathy. Automatic emotion detection from facial expression. In *2016 International Conference on Advanced Communication Control and Computing Technologies (ICACCCT), Ramanathapuram, India*, pp. 77–85, 2016.
- [2] R.M. Felder and L.K. Silverman. Learning and teaching styles in engineering education. *Eng. Educ.*, **78**(7):674–681, 1988.
- [3] K. Han, D. Yu and I. Tashev. Speech emotion recognition using deep neural network and extreme machine learning. In *Interspeech*, pp. 223–227, 2014.
- [4] A. Krizhevsky, I. Sutskever and G.E. Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*, pp. 1097–1105, 2012.
- [5] J. Kurilova and E. Kurilovas. Matematikos mokomųjų veiklų tinkamumo besimokančiajam rodikliai. *Liet. matem. rink. LMD darbai, ser B*, **57**:49–54, 2016.

- [6] L. Yi-Shin, N. Wai-Seng and L. Chun-Wei. *A Comparison of Different Face Recognition Algorithms*. National Taiwan University, 2010.

SUMMARY

Artificial neural network for learning personalisation

A. Berniukevičius, E. Kurilovas

The paper aims to suggest a method of using artificial neural for learning personalisation. Learning personalisation consists form learning style identification then linking it to learning activities and objects which correspond to learning style. But the problem is that learning style identified by questionnaire cannot guarantee adequacy and objectivity. In order to overcome this issue we can use artificial neural network which could analyse learner in learning activities and interaction with learning objects and correct learning style and scenarios characteristics according to collected information.

Keywords: personalisation, artificial neural network, learning style.