



VEKTORINIO KVANTAVIMO MOKYMO TINKLAS



Paskaitos
Turinys

1. Vektorinio kvantavimo mokymo (VKM) tinklas

- Apibrėžimas
- Struktūra
- Artumo funkcijos
- Išėjimo sluoksnio neuronų dėstymas

2. VKM tinklo mokymas

- Mokymas be mokytojo su vieninteliu laiminčiu
- Mokymas be mokytojo su keliais laiminčiais
- Mokymas su mokytoju

3. VKM tinklo atsakas

4. VKM tinklo savybės

- Konvergencija
- Privalumai
- Trūkumai
- Naudojimas

5. VKM tinklo žemėlapiai

6. VKM tinklo ryšių svorių analizė



Pagrindinė
Literatūra

1. Simpson, P.K. (1990). *Artificial Neural Systems: Foundations, Paradigms, Applications, and Implementations*. Pergamon Press, pp. 85-89.
2. Kohonen, T. (1984). *Self-Organization and Associative Memory*. Berlin: Springer-Verlag, pp. 119-157.
3. MATLAB ver. 4.0 (1994). *Neural Networks: Toolbox*. Math Corp., 7 chapter.

Skaidrės Nr.

1




Vektorinio kvantavimo mokymo (VKM) tinklas

Apibrėžimas

Vektorinio kvantavimo mokymo tinklas (angl.k.- *Learning Vector Quantization*) yra autoasociatyvusis artimiausios reikšmės atsako klasifikatorius išimenantis analoginius pavyzdžius $A^k = (a_1^k, \dots, a_n^k)$, $k=1, 2, \dots, m$, naudodamasis klaidos korekcijos procedūra. Ši procedūra panaši į konkurencinį mokymą. Vektorinio kvantavimo mokymo tinklas mokomas nerealiame laike, veikia diskretiniame laike ir yra atvaizduojamas dviejų sluoksnių nuoseklių ryšių struktūra.

Struktūra




Pav. 9.1




Vektorinio kvantavimo mokymo tinklas (tęsinys)

Artumo funkcijos


➤ *tolygi*



➤ *meksikietiškos skrybelės formos*




➤ *Gauso*




Išėjimo sluoksnio neuronų dėstymas

➤ *Vienmatis neuronų dėstymas*



➤ *Dvimatis neuronų dėstymas*





VKM tinklo mokymas

Mokymas be mokytojo su vieninteliu laiminčiu

A. Atsitiktiniu būdu parenkamos mažo dydžio ryšių W svorių reikšmės.

B. Ryšių, jungiančių įėjimo sluoksnio neuronus su j -tuoju neuronu išėjimo sluoksnyje, svoriai sudaro W_j matricą. Su kiekvienu įėjimo pavyzdžiu atlikti šiuos veiksmus:

► 1. Rasti artimiausią A^k vektoriui svorių vektorių W_j :

$$\|A_k - W_g\| = \min_{j=1}^P \|A_k - W_j\|,$$

kur W_g yra pats artimiausias A^k vektoriui iš visų W_j . Vektorių ilgiai skaičiuojami naudojant Euklidinę metriką, kuria remiantis atstumas tarp X ir Y n -mačių vektorių randamas taip:

$$\|X - Y\| = \left[\sum_{i=1}^n (x_i - y_i)^2 \right]^{1/2}.$$

Ši operacija aprašo neuronų varžymąsi tarpusavyje, kai laimėtoju lieka tik vienas stipriausiai sužadintas (artimiausias įėjimo vektoriui) neuronas.

► 2. Pastūmėti W_g arčiau A^k vektoriaus naudojant išraišką:

$$\Delta w_{ij} = \alpha(t) \cdot [a_i^k - w_{ig}],$$

visiems $i=1, 2, \dots, n$, kur Δw_{ig} yra ryšio tarp i -tojo įėjimo neurono su j -tuoju išėjimo neuronu svoris, o $\alpha(t)$ - mokymo greitis laiko momentu t , skaičiuojamas sekančiai:

$$\alpha(t) = t^{-1},$$

arba

$$\alpha(t) = 0.2 \cdot \left[1 - \frac{t}{10000} \right].$$

C. Kartoti B algoritmo žingsnį, kai $t=1, 2, \dots, z$, kur $500 < z < 10000$.



VKM tinklo mokymas (tęsinys)

Mokymas be mokytojo su keliais laiminčiais

Šis mokymas leidžia daugiau negu vienam neuronui būti aktyviam, t.y. leidžia mokyti kartu keleta neuronų.

Pažymėkime laiminčiam neuronui b_g artimiausių neuronų grupę N_g . Vietoje to, kad adaptuoti tik b_g neuroną siejančius ryšius W_g , adaptuosime ir greta jo esančių neuronų N_g ryšius.

Mokymo su keliais laiminčiais neuronais algoritmas nuo anksčiau pateikto algoritmo skiriasi tik B.2 žingsniu, kai naudojama nauja ryšių svorių adaptacijos išraiška:

$$\Delta w_{ig} = \begin{cases} \alpha(t) \cdot [a_i^k - w_{ig}], & \text{jei } i \in N_g, \\ 0, & \text{kitu atveju,} \end{cases}$$

kur N_g yra laiminčiam neuronui b_g gretimų neuronų grupė.

Mokymas su mokytoju

Šis mokymas naudotinas tada, kai yra žinoma kuriai klasei priskirti kiekvieną iš įėjimo pavyzdžių A^k .

Mokymas vyksta “apdovanojant” (pastūmiant W_g arčiau prie įėjimo vektoriaus) teisingą klasifikavimą ir “baudžiant” (pastūmiant W_g toliau nuo įėjimo vektoriaus) klaidingą klasifikavimą.

Algoritmo B.2 žingsnyje naudojama sekanti išraiška:

$$\Delta w_{ig} = \begin{cases} +\alpha(t) \cdot [a_i^k - w_{ig}], & \text{jei } b_g \text{ reikiama,} \\ -\alpha(t) \cdot [a_i^k - w_{ig}], & \text{kitu atveju,} \end{cases}$$

kur b_g yra įėjimo vektoriui A^k parinkta klasė.



VKM tinklo atsakas. Savybės

VKM tinklo atsakas

Vektorinio kvantavimo mokymo tinklo atsako formavimo metu randama klasė (b_g), atitinkanti ryšių svorių vektorių (W_g), kuris yra labiausiai susietas su pateiktu įėjimo pavyzdžiu A . W_g nustatomas randant įėjimo pavyzdžiui A artimiausią (Euklidinėje metrikoje) vektorių W_j .

Visi neuronai išėjimo sluoksnyje varžosi ir to rezultate tik vienas iš jų lieka laimėtoju. Todėl varžymosi pabaigoje neuronas atstovaujantis ieškomą klasę savo išėjime turės 1 lygio signalą, o visi kiti neuronai - 0 lygio signalus, t.y.:

$$b_g = \begin{cases} 1, & \text{jei } \|A - W_g\| = \min \|A - W_j\|, \\ 0, & \text{kitu atveju,} \end{cases}$$

kur b_j yra j -tojo neurono atsakas, o A - įėjimo pavyzdys.

Konvergencija

VKM tinklas konverguoja, nes tai priklauso nuo mokymo parametro $\alpha(t)$, o šis:

$$t \rightarrow \infty \Rightarrow \alpha(t) \rightarrow 0.$$

Privalumai

- naudojamas neparametrinis pavyzdžių klasifikavimo būdas
- artimiausios reikšmės atsakas formuojamas realiame laike

Trūkumai

- ilgai trunka mokymas nerealiam laike
- klasių skaičiaus negalima padidinti be tinklo naujo mokymo


Naudojimas

- vaizdų apdorojime
- kalbos apdorojime
- valdymo uždaviniuose
- duomenų tankinime
- kombinatoriniame optimizavime



VKM tinklo žemėlapiai


Vieno pavyzdžio žemėlapis



Tamsesne spalva pažymėtos vietos, kuriose įėjimo pavyzdys yra panašesnis į ryšių svorių vektorius

☒ *Juoda spalva rodo kuriai klasei įėjimo pavyzdys yra priskirtas.*

Skaičiuojamasis žemėlapis



Tamsumas rodo įėjimo pavyzdžių, kurie buvo suklasifikuoti į parodytą žemėlapių vietą, skaičių.

☒ *Išskiriamos trys skirtingos įėjimo pavyzdžių grupės.*



VKM tinklo žemėlapis (tęsinys)

Požymių žemėlapis

The figure shows a 10x10 grid of symbols. Each cell contains either a plus sign (+), a minus sign (-), a cross (X), or is empty. The symbols are arranged in a pattern that suggests a Latin square, with each row and column containing a unique set of symbols. The symbols include plus signs, minus signs, crosses, and empty cells.

“+”, “-” pažymėti įėjimo pavyzdžių požymiai bei vietos žemėlapyje, kuriose buvo suklasifikuoti tuos požymius turintys įėjimo pavyzdžiai. “x” pažymėtos vietos, kuriose sugrupuoti turintys “+” ar “-” požymį įėjimo pavyzdžiai.

☒ *VKM tinklas pakankamai gerai išskyrė du skirtingus požymius turinčius įėjimo pavyzdžius.*

Grupės pažymių žemėlapis

A	A	A	A	A	A	A			
A	A	A	A	A					
						B		B	
						B		B	B
						X		B	B
						C		B	B
						C		B	B
						C		B	B
						C		B	B

A, B, C raidėmis pažymėti požymiai bei įėjimo pavyzdžių, turinčių šiuos požymius, suklasifikavimo vietos žemėlapyje. X raide pažymėtos vietos, kuriose sugrupuoti keli įėjimo pavyzdžiai turintys skirtingus požymius.

☒ *Aiškliai išskirta grupė įėjimo pavyzdžių turinčių A požymį. Tuo tarpu B ir C požymius turintys pavyzdžiai kartais persidengia.*




VKM tinklo ryšių svorių analizė

Mokant VKM tinklą pastebėta, kad ryšių svorių vektoriai stengiasi nuosekliai aproksimuoti įėjimo pavyzdžių pasiskirstymą. Todėl ryšių svorių analizė leidžia geriau suprasti VKM mokymosi eigą.

Tarkime, kad turime dvimačius įėjimo pavyzdžius, todėl ir ryšių svorių vektoriai bus dvimačiai. Ryšių svorių vektorių narius galime priimti kaip koordinates, tada kiekvieną iš šių vektorių galima bus atvaizduoti tašku plokštumoje. Taškus sujungę linijomis (jungiami tik tie taškai, kurie atitinka kaimyninius neuronus) gauname plokštuminių ryšių svorių matricos būsenos pasirinktu laiko momentu vaizdą.

VKM tinklas buvo mokomas įsisąvinti sferinio paviršiaus priekinį vaizdą:



- DNT išėjimo sluoksnio neuronai išdėtyti kvadratu.
- Mokant tinklą panaudota paprasčiausia tolygi artumo funkcija, kai įvertinti tik artimiausi neuronai.
- Mokymo pavyzdžiai buvo parenkami visiškai atsitiktinai.
- Skaičiai rodo kiek epochų DNT buvo mokomas.



Pagrindiniai teiginiai

- ✎ *Vektorinio kvantavimo mokymo tinklas yra dviejų sluoksnių autoasociatyvusis artimiausios reikšmės atsako klasifikatorius įsimenantis analoginius pavyzdžius naudodamasis klaidos korekcijos procedūra.*
- ✎ *Naudojant vektorinio kvantavimo mokymo tinklą parenkamas neuronų tarpusavio artumo funkcijos tipas bei išėjimo sluoksnio neuronų išsidėstymas*
- ✎ *VKM tinklo mokymo algoritmo esmė: įsimenant kiekvieną įėjimo pavyzdį, visi teisingi įsiminimo žingsniai yra “apdovanojami”, o už kiekvieną neteisingą žingsnį yra “baudžiama”.*
- ✎ *VKM tinklui formuojant atsaką į duotą įėjimo pavyzdį išėjimo sluoksnio neuronai varžosi kuris iš jų “laimės” (liks aktyvus).*
- ✎ *VKM tinklų pagalba galima sukurti keturių tipų žemėlapius, kurie atveria naujas galimybes įėjimo pavyzdžių pasiskirstymo analizei, klasifikavimui bei kodavimui .*
- ✎ *Didžiausias VKM tinklo trūkumas - klasių skaičiaus negalima padidinti be naujo tinklo mokymo, didžiausias privalumas - naudojamas neparametrinis pavyzdžių klasifikavimo būdas.*
- ✎ *VKM tinklai gerai tinka tose situacijose, kai reikia atlikti duomenų kvantavimą, t.y. statistinėje analizėje, duomenų kodavime bei tankinime.*