

Asociativní sítě (paměti)

Cíl učení

- Asociace známého vstupního vzoru s daným výstupním vzorem
- Okolí známého vstupního vzoru \vec{x} by se mělo také zobrazit na výstup \vec{y} odpovídající \vec{x}
→ správný výstup pak lze přiřadit i „zašuměným“ vzorům
- **Hebbovské učení**

Typická funkce

- Rozpoznat předem naučené vstupní vzory i v případě, že jsou neúplné nebo mírně poškozené

Asociativní sítě (paměti)

Základní typy asociativních sítí

- heteroasociativní

- Zobrazujeme N vstupních vzorů $\vec{x}^1, \dots, \vec{x}^N$ v n -rozměrném prostoru na N výstupních vzorů $\vec{y}^1, \dots, \vec{y}^N$ v m -rozměrném prostoru tak, že

$$\vec{x}^i \mapsto \vec{y}^i$$

Jestliže $\|\vec{x} - \vec{x}^i\| < \epsilon$, pak

$$\vec{x} \mapsto \vec{y}^i$$

- autoasociativní - oprava poškozených vzorů
- sítě pro rozpoznávání vzorů - identifikace třídy vstupního vzoru

Asociativní síť (paměti)

Základní typy asociativních sítí

- heteroasociativní
- autoasociativní
 - $\vec{x}^i = \vec{y}^i$ pro $i = 1, \dots, N$
 - oprava poškozených vzorů
- síť pro rozpoznávání vzorů
 - Lze je pokládat za speciální typ heteroasociativní paměti
 - Každému vektoru \vec{x}^i je přiřazena třída i pro $i = 1, \dots, N$
 - identifikace třídy vstupního vzoru

Struktura asociativní paměti

Dva základní typy architektury asociativních pamětí:


- asociativní síť bez zpětné vazby
- asociativní síť se zpětnou vazbou

Struktura asociativní paměti bez zpětné vazby

Asociativní paměť lze implementovat pomocí jedné vrstvy neuronů

Parametry

- w_{ij} ... váha mezi vstupem i a neuronem j
- W tvaru $n \times m$... matice vah, n je počet vstupů, m je počet výstupů



Struktura asociativní paměti bez zpětné vazby

Asociativní paměť lze implementovat pomocí jedné vrstvy neuronů

Výpočet

- vstupní vektor $\vec{x} = \{x_1, \dots, x_n\}$ dává excitační vektor $\vec{e} = \vec{x} \cdot W$
- Potom se pro každý neuron spočítá jeho výstup y_i jako hodnota přenosové funkce $f(e_i)$, $i = 1, \dots, m$
 - Pro identitu dostáváme lineární asociátor a výstupem bude právě $\vec{y} = \vec{x} \cdot W$

Struktura asociativní paměti bez zpětné vazby

Obecně

- X ... matice vstupů tvaru $N \times n$ (řádky odpovídají vstupním vektorům)
- Y ... matice výstupů tvaru $N \times m$ (řádky odpovídají výstupním vektorům)

Cíl učení (pro přenosovou funkci identita)

- Najít takovou matici vah W , aby $XW = Y$ (obecně $f(XW) = Y$)
 - Pro autoasociativní síť: $XW = X$
 - Pro $n = m$: $W = X^{-1}Y$... řešení soustavy lineárních rovnic

Struktura asociativní sítě se zpětnou vazbou

Nejjednodušší zpětná vazba:

- výstup sítě se používá opakováně jako její nový vstup, dokud síť nezkonverguje do stabilního stavu
- ne všechny sítě zkonvergují po předložení nového vzoru do stabilního stavu
→ nutná dodatečná omezení na architekturu sítě
- učení je rychlé, ale rozpoznávání je obtížnější

Asociativní sítě se zpětnou vazbou

Nejjednodušší asociativní sítě – s přenosovou funkcí identita

- bez zpětné vazby ... Lineární asociátory ... $XW = Y$
- se zpětnou vazbou ... Vlastní automaty ... $XW = X$

Vlastní automaty (eigenvector automata)

Lineární rekurentní asociativní síť

Výstup sítě představuje její nový vstup:

- všechny neurony počítají svůj výstup současně
- síť dostává v každém kroku (t) na vstup vektor \vec{x}^t a dává nový výstup \vec{x}^{t+1}

Otzáka

- Existuje pevný bod \vec{x} takový, že $\vec{x} = \vec{x} \cdot W$?
... vektor \vec{x} je vlastním vektorem matice W s vlastním číslem 1
- síť se chová jako dynamický systém prvního řádu (každý nový stav je plně určen nejbližším předchůdcem)
→ hledáme pevné body dynamického systému

Vlastní automaty (eigenvector automata)

- Matice vah W tvaru $n \times n$ může mít až n lineárně nezávislých vlastních vektorů \vec{x}^i a vlastních čísel λ_i .

$$\vec{x}^i W = \lambda_i \vec{x}^i \text{ pro } i = 1, \dots, n$$

→ pak W definuje tzv. vlastní automat

- Po předložení libovolného vstupního vzoru bude nalezen vlastní vektor s největším vlastním číslem (pokud existuje) ...
atraktor
 - přibližuje se směr, ne velikost
 - daná složka vektoru musí být nenulová

Vlastní automaty (eigenvector automata)

Příklad 1

- Matice $W = [2 \ 0; 0 \ 1]$ má 2 vlastní vektory $(1,0)$ a $(0,1)$ s vlastními čísly 2 a 1
- Po t iteracích počátečního vektoru (x_1, x_2) , $x_1 \neq 0$ dostaneme $(2^t x_1, x_2)$... konverguje (co se týká směru) k $(1, 0)$

Příklad 2

- Matice $W = [0 \ 1; -1 \ 0]$ nekonverguje do stabilního stavu (rotace o 90%) ... cykly délky 4.

Učení asociativních sítí

Co je cílem učení?

- Použití asociativních sítí jako dynamických systémů, jejichž atraktory by odpovídaly těm vektorům, které chceme do paměti uložit
- Při návrhu sítě chceme rozmístit ve vstupním prostoru co možná nejvíce atraktorů.
- Každý atraktor by měl mít přesně danou a omezenou oblast vlivu
(vlastní automaty – oblast vlivu jedinného atraktoru zahrnovala téměř celý vstupní prostor)

Učení asociativních sítí

- Chceme co nejvíce atraktorů s přesně danou a omezenou oblastí vlivu
 - použijeme nelineární přenosovou funkci, např. skokovou:

$$f(x) = \text{sgn}(x) = \begin{cases} 1 & \text{pro } x \geq 0, \\ -1 & \text{pro } x < 0, \end{cases}$$

- Bipartitní kódování je vhodnější než binární (protože je větší pravděpodobnost vzájemné ortogonality vektorů)

Hebbovské učení (Donald Hebb – 1949)

Vstup

- Neuronová síť s jednou vrstvou a m neurony a skokovou přenosovou funkcí.

Cíl

- Nalézt odpovídající váhy pro zobrazení n -rozměrného vstupního vektoru \vec{x} na m -rozměrný výstupní vektor \vec{y} (obecně N vzorů)

Idea

- Dva neurony, které jsou současně aktivní, by měly mít „vyšší stupeň vzájemné interakce“ než neurony, jejichž aktivita je nekorelovaná – v takovém případě by měla být vzájemná interakce hodně malá nebo nulová

Hebbovské učení

Adaptační pravidlo

- na vstupu je n -rozměrný vektor \vec{x}^1 , na výstupu m -rozměrný vektor \vec{y}^1
- Aktualizace váhy w_{ij} ze vstupu i do neuronu j podle:

$$w_{ij} = w_{ij} + \Delta w_{ij},$$

kde

$$\Delta w_{ij} = \alpha x_i y_j$$

- α ... parametr učení
- W ... váhová matice (na začátku učení nulová)

→ adaptovaná váhová matice W je **korelační maticí** pro vektory \vec{x}^1 a \vec{y}^1 :

$$W = [w_{ij}]_{n \times m} = [\alpha x_i^1 y_j^1]_{n \times m} = \alpha \vec{x}^{1T} \vec{y}^1$$

Hebbovské učení

Matrice $W = [x_i^1 y_j^1]_{n \times m}$ zobrazí nenulový vektor \vec{x}^1 právě na vektor \vec{y}^1 :

- Spočteme excitační vektor:

$$\vec{x}^1 W = (y_1^1 \sum_{i=1}^n x_i^1 x_i^1, y_2^1 \sum_{i=1}^n x_i^1 x_i^1, \dots, y_m^1 \sum_{i=1}^n x_i^1 x_i^1) = \vec{y}^1 (\vec{x}^1 \cdot \vec{x}^1)$$

- Pro $\vec{x}^1 \neq \vec{0}$ platí $(\vec{x}^1 \cdot \vec{x}^1) > 0$ a výstup sítě je:

$$sgn(\vec{x}^1 W) = (y_1^1, \dots, y_m^1) = \vec{y}^1$$

- Pro $(-\vec{x}^1)$ je výstup sítě:

$$sgn(-\vec{x}^1 W) = -sgn(\vec{x}^1 W) = -\vec{y}^1$$

Hebbovské učení

Obecně:

- na vstupu je N n -rozměrných vektorů $\vec{x}^1, \dots, \vec{x}^N$, na výstupu N m -rozměrných vektorů $\vec{y}^1, \dots, \vec{y}^N$
- Použijeme Hebbovské učení pro každou dvojici \vec{x}^l a \vec{y}^l
- Výsledná matice vah je $W = W^1 + \dots + W^N$,
kde $W^l = [x_i^l y_j^l]_{n \times m}$ je korelační matice \vec{x}^l a \vec{y}^l
- Váhy se nastaví v jednom průchodu

Hebbovské učení

Předložíme vzor \vec{x}^p .

- Excitační vektor:

$$\begin{aligned}\vec{x}^p W &= \vec{x}^p (W^1 + \dots + W^N) \\ &= \vec{x}^p W^p + \sum_{l \neq p}^N \vec{x}^p W^l \\ &= \vec{y}^p (\vec{x}^p \cdot \vec{x}^p) + \sum_{l \neq p}^N \vec{y}^l (\vec{x}^l \cdot \vec{x}^p)\end{aligned}$$

- excitační vektor tedy odpovídá \vec{y}^p (vynásobenému kladnou konstantou) s perturbačním členem (**crosstalk**)
 $\sum_{l \neq p}^N \vec{y}^p (\vec{x}^l \cdot \vec{x}^p)$

Hebbovské učení

Výstup sítě bude roven:

$$\operatorname{sgn}(\vec{x}^p W) = \operatorname{sgn} \left(\vec{y}^p (\vec{x}^p \cdot \vec{x}^p) + \sum_{l \neq p}^N \vec{y}^l (\vec{x}^l \cdot \vec{x}^p) \right)$$

- Protože $(\vec{x}^p \cdot \vec{x}^p)$ je kladná konstanta:

$$\operatorname{sgn}(\vec{x}^p W) = \operatorname{sgn} \left(\vec{y}^p + \sum_{l \neq p}^N \vec{y}^l \frac{(\vec{x}^l \cdot \vec{x}^p)}{(\vec{x}^p \cdot \vec{x}^p)} \right)$$

Hebbovské učení

Kdy dá síť na výstupu požadovaný vektor \vec{y}^P ?

- když je crosstalk nulový
→ pokud jsou vstupní vzory navzájem ortogonální
- když je crosstalk „menší“ než $\vec{y}^P(\vec{x}^P \cdot \vec{x}^P)$

Hebbovské učení

- Aby byl výstup sítě roven \vec{y}^p , musí platit

$$\vec{y}^p = \operatorname{sgn} \left(\vec{y}^p + \sum_{l \neq p}^N \vec{y}^l \frac{(\vec{x}^l \cdot \vec{x}^p)}{(\vec{x}^p \cdot \vec{x}^p)} \right)$$

- To bude splněno, pokud bude absolutní hodnota všech složek perturbačního členu menší než 1.
- Pro biparitní vektory to znamená, že skalární součin $(\vec{x}^l \cdot \vec{x}^p)$ musí být menší než druhá mocnina délky \vec{x}^p

Hebbovské učení

Pokud jsou náhodně zvoleným biparitním vektorům přiřazeny (jiné) náhodně zvolené biparitní vektory, je pravděpodobnost, že budou navzájem ortogonální, poměrně vysoká (pokud jich ovšem nebylo zvoleno příliš mnoho)

V takovém případě bude crosstalk malý a Hebbovské učení povede k volbě vhodných vah pro asociativní síť

Hebbovské učení - geometrická interpretace

- Pro jeden uložený vzor \vec{x}^I a příslušnou matici W^I : vstupní vektor \vec{z} bude zobrazen do lineárního podprostoru L_I určeného vektorem \vec{x}^I
 - pro autoasociativní síť: $\vec{z}W^I = \vec{z}\vec{x}^{IT}\vec{x}^I = c_I\vec{x}^I$, kde c_I je konstanta
 - obecně neortogonální projekce
- Celkem pro matici $W = W^1 + \dots + W^N$ bude vstupní vektor \vec{z} zobrazen do lineárního podprostoru určeného vektory $\vec{x}^1, \dots, \vec{x}^N$:
$$\vec{z}W = \vec{z}W^1 + \vec{z}W^2 + \dots + \vec{z}W^N = c_1\vec{x}^1 + c_2\vec{x}^2 + \dots + c_N\vec{x}^N$$

Hebbovské učení - analýza chování

Sféra vlivu jednotlivých atraktorů (pevných bodů systému)

- Pro bipartitní vzory se měří Hammingovou vzdáleností (~ počet různých složek dvou vektorů).
- Index

$$I = \sum_{h=0}^{n/2} hp_h,$$

kde p_h je procento vzorů s Hamm. vzd. h , které „zkonvergovaly“ k danému atraktoru.

Hebbovské učení - analýza chování


- S rostoucím počtem ukládaných vzorů se „sféry vlivu“ jednotlivých atraktorů zmenšují a hrozí vznik **nepravých stabilních stavů**
 - Inverzní vzory k uloženým
 - Velký crosstalk - pokud bude příliš velký, může být dříve uložený vzor i „zapomenut“

Rekurentní síť (se zpětnou vazbou)

- Lepší konvergence oproti asociativní paměti bez zpětné vazby
- Větší „sféry vlivu“ jednotlivých atraktorů → větší problém s kapacitou sítě

Hebbovské učení - analýza chování

Příklad - srovnání indexu pro síť s a bez zpětné vazby



Odhad kapacity sítě

- m ... počet vzorů, které lze uložit do autoasociativní paměti s maticí W tvaru $n \times n$
- $m \sim 0.18n$... maximální kapacita sítě
- Pro korelované vzory může být problém i pro $m < 0.18n$

Hebbovské učení - analýza chování

- V reálných aplikacích jsou vzory téměř vždy korelované a crosstalk pak může v případě Hebbovského učení ovlivnit rozpoznávání $\vec{x}^P W = \vec{y}^P (\vec{x}^P \cdot \vec{x}^P) + \sum_{I \neq P}^N \vec{y}^I (\vec{x}^I \cdot \vec{x}^P)$
- Vzájemná korelace ukládaných vzorů vede ke snížení kapacity asociativní paměti (počtu vzorů, které lze uložit a rozpoznat)
- ukládané vzory pak nepokrývají rovnoměrně celý příznakový prostor, ale soustředí se do menší oblasti

Metoda pseudoinverzní matice

- je třeba hledat alternativní metody učení schopné minimalizovat perturbaci mezi ukládanými vzory
- **použití pseudoinverzní matice namísto korelační**

Metoda pseudoinverzní matice

Definice

- Pseudoinverzní maticí k matici $n \times m$ reálných čísel X je matice X^+ reálných čísel s následujícími vlastnostmi:
 - 1 $XX^+X = X$
 - 2 $X^+XX^+ = X^+$
 - 3 X^+X a XX^+ jsou symetrické

Pseudoinverzní matice vždy existuje a je jednoznačně určena.

Metoda pseudoinverzní matice

Úloha

- Na vstupu je N n -rozměrných vektorů $\vec{x}^1, \dots, \vec{x}^N$
... matice X tvaru $N \times n$
- Na výstupu je N m -rozměrných vektorů $\vec{y}^1, \dots, \vec{y}^N$
... matice Y tvaru $N \times m$
- Hledáme takovou matici vah, že $XW = Y$
(ve zjednodušeném případě, obecně ještě aplikace přenosové funkce ... $f(XW) = Y$)

Metoda pseudoinverzní matice

Hledáme matici W t.ž. $XW = Y$

- Nápad: $W = X^{-1}Y$
 - Problém: k matici X nemusí existovat inverzní matice X^{-1}
 - obecně $m \neq n$
 - vektory $\vec{x}^1, \dots, \vec{x}^N$ nemusí být navzájem lineárně nezávislé
- hledáme matici, která by minimalizovala $\|XW - Y\|^2$
... minimalizace pomocí $W = X^+Y$

Metoda pseudoinverzní matice


Věta

- Nechť X je matice reálných čísel tvaru $N \times n$, Y je matice reálných čísel tvaru $N \times m$. Matice $W = X^+ Y$ tvaru $n \times m$ minimalizuje $\|XW - Y\|^2$.
- Zároveň X^+ minimalizuje $\|XX^+ - I\|^2$.
 - pokud X^{-1} existuje, bude navíc $\|XX^+ - I\|^2 = 0$, tj. $X^+ = X^{-1}$.
 - pokud X^{-1} neexistuje, bude X^+ její nejlepší možná aproximace

Metoda pseudoinverzní matice

Jak spočítat pseudoinverzní matici?

- např. aproximace pomocí BP-sítí ... BP-sít využita k nalezení vah asociativní sítě



- o ... skutečný výstup
- y ... požadovaný výstup

Metoda pseudoinverzní matice


Výpočet pseudoinverzní matice pomocí BP-sítě

- Pro l -tý vstupní vektor se porovná výstup sítě s vektorem \vec{y}^l a spočítá se E_l .
- Celková kvadratická odchylka $E = \sum_{i=1}^N E_i$ pak odpovídá $\|XW - Y\|^2$.
- Algoritmus zpětného šíření pak najde matici W , která minimalizuje $\|XW - Y\|^2$.

Bidirektivní asociativní síť (paměť')

BAM = Bidirectional Associative Memory

- synchronní rekurentní asociativní paměť s obousměrnými synapsemi.



Bidirektivní asociativní síť (paměť)

BAM = Bidirectional Associative Memory

- synchronní rekurentní asociativní paměť s obousměrnými synapsemi.
 - Skládá se ze dvou vrstev neuronů, které si mezi sebou rekurzivně posílají informace.
 - Vstupní vrstva posílá výsledky svého výpočtu výstupní vrstvě – prostřednictvím vah sítě.
 - Výstupní vrstva vrací výsledky svých výpočtů zpět vstupní vrstvě – prostřednictvím stejných vah.

Otzáka: Dosáhne síť stabilního stavu, kdy se po několika iteracích už nebude měnit informace posílaná sem a tam?

Bidirektivní asociativní síť (paměť)

Popis modelu BAM

- Skoková přenosová funkce (sgn).
- Biparitní kódování hodnot.
- Váhová matice W je tvaru $n \times m$

Výpočet BAM

- Síť zobrazí n -rozměrný vstupní vektor \vec{x}^0 na m -rozměrný výstupní vektor \vec{y}^0
- Po prvním dopředném průchodu sítí dostaneme:
$$\vec{y}^0 = \text{sgn}(\vec{x}^0 W)$$
- Po prvním zpětném průchodu dostaneme:
$$\vec{x}^1 = \text{sgn}(W \vec{y}^{0T})$$
- Po dalším dopředném průchodu:
$$\vec{y}^1 = \text{sgn}(\vec{x}^1 W)$$

Bidirektivní asociativní síť (paměť)

Výpočet BAM

- Po N iteracích máme $N + 1$ dvojic vektorů $\vec{x}^0, \dots, \vec{x}^N$ a $\vec{y}^0, \dots, \vec{y}^N$ pro které platí:

$$\begin{aligned}\vec{y}^i &= sgn(\vec{x}^i W) \\ \vec{x}^{i+1} &= sgn(W \vec{y}^{iT})\end{aligned}$$

- **Oázka:** Naleze systém po několika iteracích pevný bod (\vec{x}, \vec{y}) tak, aby platilo:

$$\begin{aligned}\vec{y} &= sgn(\vec{x} W) \\ \vec{x} &= sgn(W \vec{y}^T)\end{aligned}$$

Bidirektivní asociativní síť (paměť)

Výpočet váhové matice ... pomocí Hebbovského učení

- pro jeden vzor (\vec{x}^I, \vec{y}^I) :

$$W^I = \vec{x}^{IT} \vec{y}^I$$

$$\begin{aligned}\vec{y}^I &= sgn(\vec{x}^I W^I) = sgn(\vec{x}^I \vec{x}^{IT} \vec{y}^I) \\ &= sgn(\|\vec{x}^I\|^2 \vec{y}^I) = \vec{y}^I\end{aligned}$$

a zároveň

$$\begin{aligned}\vec{x}^{IT} &= sgn(W^I \vec{y}^{IT}) = sgn(\vec{x}^{IT} \vec{y}^I \vec{y}^{IT}) \\ &= sgn(\vec{x}^{IT} \|\vec{y}^I\|^2) = \vec{x}^{IT}\end{aligned}$$

- pro více vzorů $\vec{x}^1, \dots, \vec{x}^N$:

$$W = W^1 + \dots + W^N$$

Bidirektivní asociativní síť (paměť)

Výpočet váhové matice

- Lze použít Hebbovské učení nebo Metodu pseudoinverzní matice
- Vzory by měly být navzájem ortogonální (\rightarrow menší crosstalk)
- BAM lze použít i jako autoasociativní síť, protože matice vah jsou symetrické ($X = XW$ a $X^T = WX^T$)

Asynchronní BAM

- Každý neuron náhodně spočítá svou excitaci a
- Změní svůj stav na 1 nebo -1 nezávisle na ostatních (ale podle znaménka své excitace)
- Pravděpodobnost, že budou dva neurony současně měnit svůj stav, je nulová
- Předpoklad: stav neuronu se nemění, je-li celková excitace nulová

Asynchronní BAM

Stabilní stav BAM

= dvojice vektorů (\vec{x}, \vec{y}) , pro kterou platí:

$$\begin{aligned}\vec{y} &= sgn(\vec{x}W) \\ \vec{x} &= sgn(W\vec{y}^T)\end{aligned}$$

Věta

- Bidirektivní asociativní paměť s libovolnou maticí vah W dosáhne stabilního stavu v konečném počtu iterací – a to jak pomocí synchronní, tak také pomocí asynchronní aktualizace.
→ libovolná reálná matice vah W má bidirektivní stabilní bipartitní stavy

Asynchronní BAM

Definice: Energetická funkce sítě BAM

$$E(\vec{x}, \vec{y}) = -\frac{1}{2} \vec{x} W \vec{y}^T = -1/2 \sum_{i=1}^n \sum_{j=1}^n \vec{x}_i w_{ij} x_i y_j$$

Náznak důkazu věty

- Lokální minima energetické funkce odpovídají stabilním stavům.
- Každá aktualizace stavu sítě vede ke snížení její celkové energie.
- Stavů je konečně mnoho → výpočet skončí v konečném počtu kroků.