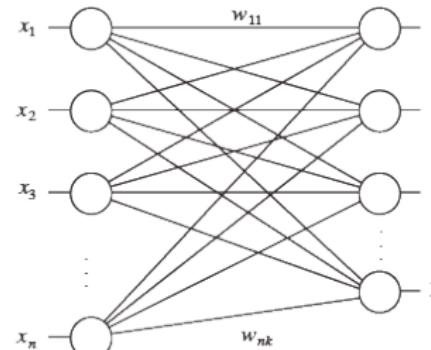


Opakování: Asociativní paměti

Co bylo minule:

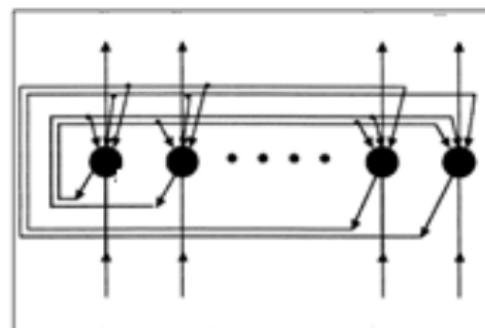
- Asociativní síť (pamět, AM)
 - bez zpětné vazby, se zpětnou vazbou (rekurentní)
 - Hebbovské učení (1942) a metoda pseudoinverzní matice (1972).
- BAM (Bidirektivní asociativní paměti)
 - synchronní rekurentní asociativní paměť s obousměrnými synapsemi.



Hopfieldova síť'

Dnes:

- Hopfieldovy sítě (1982, John Hopfield)
 - Speciální případ asynchronní BAM
 - levá a pravá vrstva neuronů spojeny do jedné

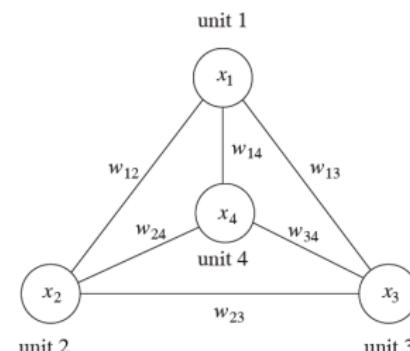


Hopfieldova síť – Architektura

- jen jedna vrstva s n neurony
- neurony mohou a nemusí mít práh
- skoková přenosová funkce:

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

- bipartitní vstupy i výstupy $\{-1; 1\}$
- synaptické hrany s vahami w_{ij} (mezi každýma dvěma neurony i a j)



Hopfieldova síť – Učení a rozpoznávání

Učení s učitelem

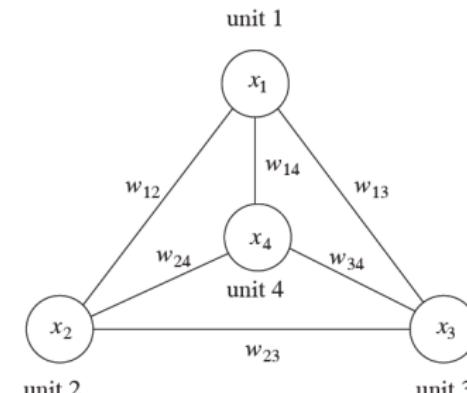
- N trénovacích vzorů (tříd)
- požadované výstupy jsou stejné jako vstupy
- nastavení vah (a prahů)

Rozpoznávání

- asynchronní dynamika

Použití

- Asociativní paměť
- Řešení optimalizačních úloh



Hopfieldova síť - Učení a rozpoznávání

Učení - Hebbovské učení

- Nastavíme hodnoty synaptických vah:

$$w_{ij} = \begin{cases} \sum_{l=1}^N x_i^l x_j^l & \text{pro } i \neq j, \\ 0 & \text{pro } i = j, \end{cases}$$

- $1 \leq i, j \leq n$
- w_{ij} ... váha hrany (synapse) mezi neuronem i a j
- $x_i^l \in \{-1; 1\}$... i -tá složka l -tého vzoru
- výsledná matice vah:

$$W = \sum_{l=1}^N \vec{x}^{lT} \vec{x}^l - N I$$

Hopfieldova síť - Rozpoznávání

- **Inicializace** - předložíme neznámý vstupní vzor \vec{x}
→ počáteční stav sítě:

$$y_i(0) = x_i \text{ pro } 1 \leq i \leq n$$

- $x_i \in \{-1; 1\}$... i -tá složka předloženého vzoru
- $y_i(t)$... výstup neuronu i v čase t

- **Iterace**

$$y_j(t+1) = f\left(\sum_{i=1}^n w_{ij} y_i(t)\right) \text{ pro } 1 \leq j \leq n$$

- f ... (skoková) přenosová funkce

Hopfieldova síť - Rozpoznávání

- **Inicializace** - předložíme neznámý vstupní vzor \vec{x}

$$y_i(0) = x_i \text{ pro } 1 \leq i \leq n$$

- **Iterace**

$$y_j(t+1) = f\left(\sum_{i=1}^n w_{ij} y_i(t)\right) \text{ pro } 1 \leq j \leq n$$

- Iterativní proces se při rozpoznávání opakuje, dokud se výstupy neuronů neustálí.
- Výstupy neuronů pak reprezentují ten trénovací vzor, který nejlépe odpovídá předloženému (neznámému) vzoru.

Hopfieldova síť - Učení a rozpoznávání

Vektor potenciálů po předložení vzoru \vec{x}^1 :

$$\begin{aligned}
 \vec{\xi} &= \vec{x}^1 W = \vec{x}^1 \left(\sum_{l=1}^N \vec{x}^{lT} \vec{x}^l - NI \right) \\
 &= \vec{x}^1 \vec{x}^{1T} \vec{x}^1 + \vec{x}^1 \vec{x}^{2T} \vec{x}^2 + \dots + \vec{x}^1 \vec{x}^{NT} \vec{x}^N - N \vec{x}^1 I = \\
 &= n \vec{x}^1 + \alpha_{12} \vec{x}^2 + \dots + \alpha_{1N} \vec{x}^N - N \vec{x}^1 = \\
 &= (n - N) \vec{x}^1 + \sum_{l=2}^N \alpha_{1l} \vec{x}^l
 \end{aligned}$$

- $W = \sum_{l=1}^N \vec{x}^{lT} \vec{x}^l - NI$... matice vah Hopfieldovy sítě
- α_{1l} ... skalárni součin \vec{x}^1 a \vec{x}^l
- $\sum_{l=2}^N \alpha_{1l} \vec{x}^l$... perturbační člen (crosstalk)

Hopfieldova síť - Učení a rozpoznávání

Vektor potenciálů po předložení vzoru \vec{x}^1 :

$$\vec{\xi} = (n - N)\vec{x}^1 + \sum_{l=2}^N \alpha_{1l}\vec{x}^l$$

- Chceme, aby vektor \vec{x}^1 byl stabilní stav sítě (tj. $sgn(\vec{\xi}) = sgn(\vec{x}^1)$)
→ musí být $N < n$ a perturbační člen ($\sum_{l=2}^N \alpha_{1l}\vec{x}^l$) malý
- do paměti lze vložit malý počet navzájem ortogonálních vzorů
 - Kapacita $N < 0.15 n$ nebo $N \sim n/(2\log n)$
 - Problém se stabilitou → orthogonalizace

Hopfieldova síť - Učení a rozpoznávání

Podmínky konvergence ke stabilnímu řešení při rozpoznávání:

- Symetrické váhy $w_{ij} = w_{ji}$
- $w_{ii} = 0$
 - Symetrická váhová matice s nulovou diagonálou
- Asynchronní aktualizace výstupu jednotlivých neuronů
 - Stav neuronů zůstává stejný, dokud nejsou vybrány k aktualizaci
 - Výběr pro aktualizaci se provádí náhodně
 - Pravděpodobnost, že budou dva neurony současně měnit svůj stav, je nulová

Příklady

Hopfieldova síť - Učení a rozpoznávání

Věta

- Hopfieldova síť s asynchronní dynamikou dosáhne z libovolného počátečního stavu sítě stabilního stavu v lokálním minimu energetické funkce.

Energetická funkce Hopfieldovy sítě

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

Pro síť s prahovými neurony:

$$E(\vec{x}) = -\frac{1}{2} \vec{x} W \vec{x}^T + \vec{\theta} \vec{x}^T = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \theta_i x_i$$

Hopfieldova síť - Energetická funkce

Věta

- Hopfieldova síť s asynchronní dynamikou dosáhne z libovolného počátečního stavu sítě stabilního stavu v lokálním minimu energetické funkce.

Náznak důkazu

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

Hopfieldova síť - Energetická funkce

Náznak důkazu – pokračování

- Počáteční stav sítě \sim předložený vzor $\vec{x} = \{x_1, \dots, \underline{x_k}, \dots, x_n\}$
Odpovídá mu energie:

$$E(\vec{x}) = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \theta_i x_i$$

- K aktualizaci vyberu neuron k
 - k nezmění svůj stav $\rightarrow E(\vec{x})$ se nezmění
 - k změní svůj stav $\rightarrow E(\vec{x})$ se sníží (...)

Hopfieldova síť - Energetická funkce

Náznak důkazu – dokončení

- Nový stav sítě $\sim \vec{x}' = \{x_1, \dots, x'_k, \dots, x_n\}$
Odpovídá mu energie:

$$E(\vec{x}') = -\frac{1}{2} \sum_{i \neq k}^n \sum_{j \neq k}^n w_{ij} x_i x_j - \sum_{i=1}^n w_{ik} x_i x'_k + \sum_{i \neq k}^n \theta_i x_i + \theta_k x'_k$$

- Rozdíl energií v původním a novém stavu sítě:

$$\begin{aligned} E(\vec{x}) - E(\vec{x}') &= - \sum_{i=1}^n w_{ik} x_i x_k + \theta_k x_k - \left(- \sum_{i=1}^n w_{ik} x_i x'_k + \theta_k x'_k \right) \\ &= -(x_k - x'_k) \left(\sum_{i=1}^n w_{ik} x_i - \theta_k \right) \\ &= -(x_k - x'_k) \xi_k > 0 \end{aligned}$$

→ nový stav má nižší energii

Perceptronové učení pro Hopfieldův model

Motivace

- V některých případech nelze nalézt pomocí Hebbovského učení vahovou matici Hopfieldovy sítě tak, aby N daných vektorů odpovídalo stabilním stavům sítě (i když taková matice existuje)
 - pokud leží vektory, které mají být do sítě uloženy, hodně blízko, může být „crosstalk“ příliš velký
→ horší výsledky Hebbovského učení
- **Alternativa:** perceptronové učení pro Hopfieldovy sítě

Perceptronové učení pro Hopfieldův model

- **Je dáno:** Hopfieldova síť s n neurony, které mají nenulový práh a skokovou přenosovou funkci.
- Má-li si síť „zapamatovat“ vektor $\vec{x} = (x_1, \dots, x_n)$, bude tento vektor odpovídat stabilnímu stavu sítě tehdy, jestliže se po jeho „předložení“ stav sítě nezmění
→ potenciál každého neuronu by měl mít stejně znaménko jako jeho předchozí stav

Perceptronové učení pro Hopfieldův model

Měly by platit následující nerovnosti:

- pro neuron 1: $\operatorname{sgn}(x_1)(0 + x_2 w_{12} + \dots + x_n w_{1n} - \theta_1) > 0$
- pro neuron 2: $\operatorname{sgn}(x_2)(x_1 w_{21} + 0 + \dots + x_n w_{2n} - \theta_2) > 0$
- ...
- pro neuron n:
 $\operatorname{sgn}(x_n)(x_1 w_{n1} + x_2 w_{n2} + \dots + x_{n-1} w_{n(n-1)} + 0 - \theta_n) > 0$

Protože $w_{ij} = w_{ji}$ → nenulových prvků váhové matice je
 $n(n - 1)/2$ a prahů n

→ vytvoříme vektor \vec{v} dimenze $n + n(n - 1)/2$:

$$\vec{v} = (w_{12}, w_{13}, \dots, w_{1n}, w_{23}, w_{24}, \dots, w_{2n}, \dots, w_{n-1n}, -\theta_1, \dots, -\theta_n)$$

(složky odpovídají prvkům w_{ij} nad diagonálou matice W a n
prahům se záporným znaménkem)

Perceptronové učení pro Hopfieldův model

Vektor \vec{x} můžeme transformovat do n pomocných vektorů $\vec{z}_1, \dots, \vec{z}_n$ dimenze $n + n(n - 1)/2$:

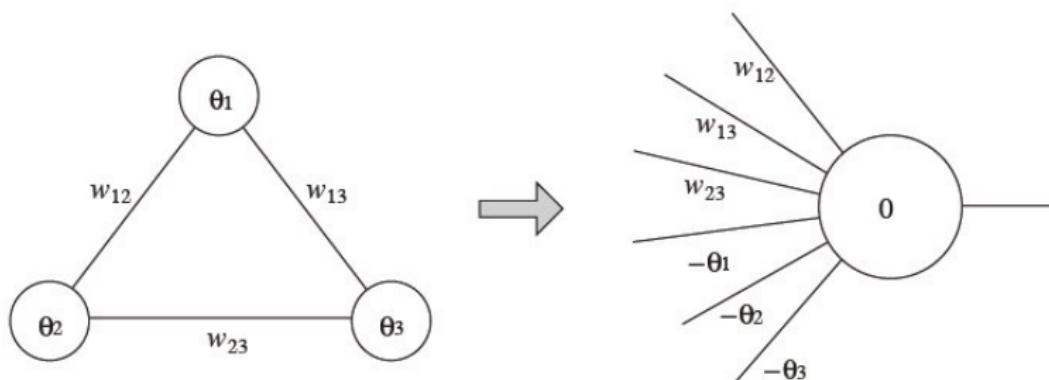
- $\vec{z}_1 = (x_2, x_3, \dots, x_n | 0, 0, \dots, 0 | 0 | 1, 0, \dots, 0)$
- $\vec{z}_2 = (x_1, 0, \dots, 0 | x_3, \dots, x_n | 0, 0, \dots, 0 | 0, 1, \dots, 0)$
- ...
- $\vec{z}_n = (0, 0, \dots, x_1 | 0, 0, \dots, x_2 | 0, 0, \dots | x_{n-1} | 0, 0, \dots, 1)$

Potom lze přepsat nerovnosti na:

- pro neuron 1: $sgn(x_1)\vec{z}_1\vec{v} > 0$
- pro neuron 2: $sgn(x_2)\vec{z}_2\vec{v} > 0$
- ...
- pro neuron n: $sgn(x_n)\vec{z}_n\vec{v} > 0$

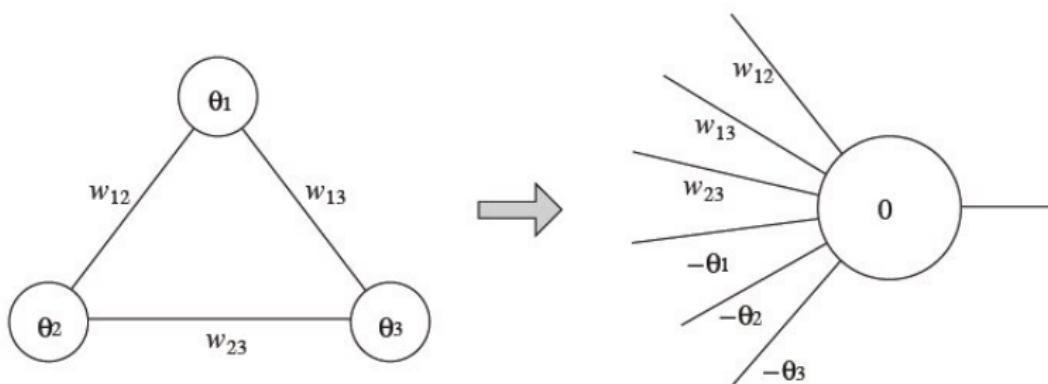
Perceptronové učení pro Hopfieldův model

- k lineární separaci vektorů $\vec{z}_1, \dots, \vec{z}_n$ podle $\text{sgn}(x_i)$ lze použít perceptronové učení →
 - ① pomocí perceptronu spočteme vektor vah \vec{v} nutný pro lineární separaci $\vec{z}_1, \dots, \vec{z}_n$
 - ② nastavíme váhovou matici W a prahy Hopfieldovy sítě podle \vec{v}



Perceptronové učení pro Hopfieldův model

- Pokud si má Hopfieldova síť „zapamatovat“ N vektorů, je třeba použít popsanou transformaci pro každý vektor
 $\rightarrow N \cdot n$ pomocných vektorů, které je třeba lineárně odseparovat
- Pokud jsou vektory lineárně separabilní, najde perceptronové učení řešení „zakódované“ ve formě \vec{v}



Hopfieldova síť pro řešení optimalizačních úloh

- binární kódování
- kódování optimalizačních problémů pomocí energetické funkce

MULTIFLOP

- x_1, \dots, x_n ... binární stavy jednotlivých neuronů Hopfieldovy sítě
- Síť by se měla dostat do stavu, kdy bude právě 1 neuron aktivní; stav všech ostatních neuronů by měl být 0
- **Cíl:** nalézt minimum funkce $E(x_1, \dots, x_n)$

$$E(x_1, \dots, x_n) = \left(\sum_{i=1}^n x_i - 1 \right)^2$$

Hopfieldova síť pro řešení optimalizačních úloh

MULTIFLOP

$$\begin{aligned} E(x_1, \dots, x_n) &= \left(\sum_{i=1}^n x_i - 1 \right)^2 = \sum_{i=1}^n x_i^2 + \sum_{i \neq j}^n x_i x_j - 2 \sum_{i=1}^n x_i + 1 \\ &= \sum_{i \neq j}^n x_i x_j - \sum_{i=1}^n x_i + 1 \\ &= -1/2 \sum_{i \neq j}^n (-2)x_i x_j + \sum_{i=1}^n (-1)x_i + 1 \end{aligned}$$

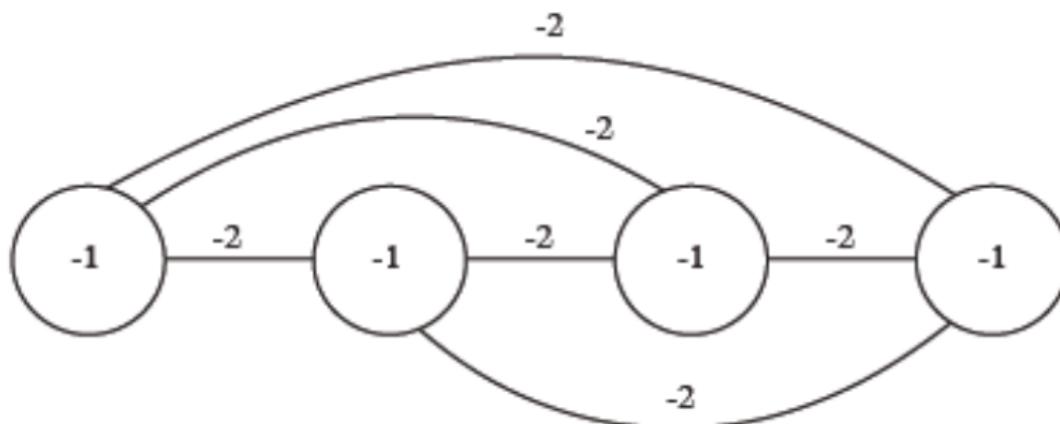
→ nastavíme váhy a prahy sítě...

Hopfieldova síť pro řešení optimalizačních úloh

MULTIFLOP

$$E(x_1, \dots, x_n) = -1/2 \sum_{i \neq j}^n (-2)x_i x_j + \sum_{i=1}^n (-1)x_i + 1$$

→ nastavíme váhy a prahy sítě:



Hopfieldova síť pro řešení optimalizačních úloh

Problém n věží

- Umístit na šachovnici ($n \times n$) n věží tak, aby se navzájem neohrožovaly
 - každá věž by měla být v jiném řádku i sloupci než ostatní
 - x_{ij} ... stav neuronu na pozici (i, j) šachovnice ($n \times n$)
 - $\sum_{i=1}^n x_{ij}$... počet stavů = 1 ve sloupci j
 - $\sum_{j=1}^n x_{ij}$... počet stavů = 1 v řádku i
 - v každém sloupci a řádku by měla být jen jedna „jednička“

Hopfieldova síť pro řešení optimalizačních úloh

Problém n věží

Cíl: nalézt minimum funkce

$$E(x_{11}, \dots, x_{nn}) = E_1(x_{11}, \dots, x_{nn}) + E_2(x_{11}, \dots, x_{nn})$$

$$E_1(x_{11}, \dots, x_{nn}) = \sum_{j=1}^n (\sum_{i=1}^n x_{ij} - 1)^2$$

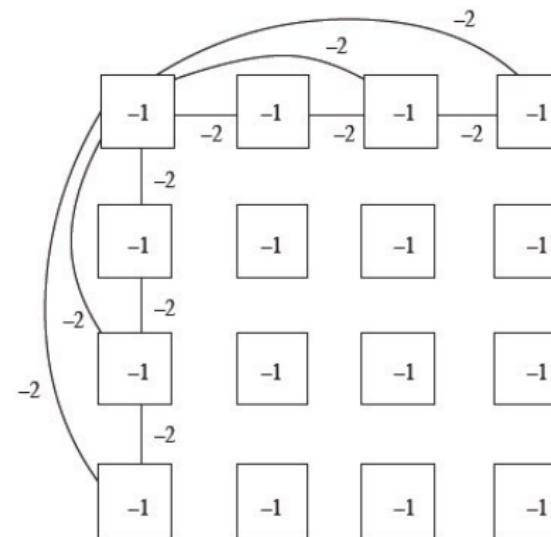
$$E_2(x_{11}, \dots, x_{nn}) = \sum_{i=1}^n (\sum_{j=1}^n x_{ij} - 1)^2$$

... rozšíření multiflopů

Hopfieldova síť pro řešení optimalizačních úloh

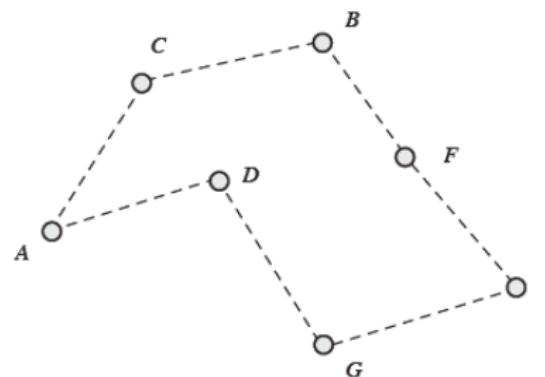
Problém n věží

→ nastavíme váhy a prahy sítě:



Hopfieldova síť pro řešení optimalizačních úloh

TSP (Problém obchodního cestujícího) (NP-úplný problém)



- Nalézt cestu přes n měst M_1, \dots, M_n tak, aby bylo každé město navštívено alespoň jednou a délka „okružní jízdy“ byla minimální

Hopfieldova síť pro řešení optimalizačních úloh

TSP (Problém obchodního cestujícího)

- Reprezentace pomocí matice, kde řádky odpovídají městům a sloupce odpovídají pořadí návštěvy
 - x_{ik} ... stav neuronu na pozici (i, k) matice
 - $x_{ik} = x_{jk+1} = 1$... město M_i bylo navštívěno v k -tém kroce a město M_j bylo navštívěno v $(k+1)$ -ním kroce
 - d_{ij} ... vzdálenost mezi městy M_i a M_j
→ d_{ij} musíme přičíst k celkové délce cesty

Hopfieldova síť pro řešení optimalizačních úloh

TSP (Problém obchodního cestujícího)

- **Cíl:** minimalizace délky cesty:

$$L = 1/2 \sum_{i,j,k}^n d_{ij} x_{ik} x_{jk+1}$$

- **Ale:** povolena jediná návštěva vždy jen jednoho města
→ přidáme požadavky na přípustnou cestu:

$$\begin{aligned} E &= 1/2 \sum_{i,j,k}^n d_{ij} x_{ik} x_{jk+1} + \\ &+ \gamma/2 \left[\sum_{j=1}^n \left(\sum_{i=1}^n x_{ij} - 1 \right)^2 + \sum_{i=1}^n \left(\sum_{j=1}^n x_{ij} - 1 \right)^2 \right] \end{aligned}$$

TSP (Problém obchodního cestujícího)

$$\begin{aligned}
 E &= 1/2 \sum_{i,j,k}^n d_{ij} x_{ik} x_{jk+1} + \\
 &+ \gamma/2 \left[\sum_{j=1}^n \left(\sum_{i=1}^n x_{ij} - 1 \right)^2 + \sum_{i=1}^n \left(\sum_{j=1}^n x_{ij} - 1 \right)^2 \right] \\
 &= -1/2 \sum_{i,j,k}^n (-d_{ij}) x_{ik} x_{jk+1} + \\
 &- 1/2 \sum_{i \neq j}^n (-\gamma) x_{.i} x_{.j} + \sum_{i=1}^n (-\gamma/2) x_{.i} + \gamma/2 + \\
 &- 1/2 \sum_{j \neq i}^n (-\gamma) x_{i.} x_{j.} + \sum_{j=1}^n (-\gamma/2) x_{j.} + \gamma/2
 \end{aligned}$$

Hopfieldova síť pro řešení optimalizačních úloh

TSP (Problém obchodního cestujícího)

→ nastavení vah a prahů sítě:

- $w_{ik,jk+1} = -d_{ij} + t_{ik,jk+1}$, kde

$$t_{ik,jk+1} = \begin{cases} -\gamma & \text{pro neurony ve stejném řádku nebo sloupci,} \\ 0 & \text{jinak} \end{cases}$$

- $\theta_{ij} = -\gamma/2$

Stochastické modely neuronových sítí

- Hopfieldův model se používá k řešení optimalizačních problémů, které lze vyjádřit ve formě minimalizované energetické funkce (i když není zaručeno nalezení globálního optima)
- **Problém:** zabránit „uvíznutí“ v lokálním minimu energetické funkce

Stochastické modely neuronových sítí

Modifikace Hopfieldova modelu k zlepšení konvergence a omezení lokálních minim

- ① strategie: zvětšení počtu možných cest k řešení ve stavovém prostoru
 - dovolit i stavy ve formě reálných hodnot (sigmoidální přenosová funkce)
 - **spojitý model**
- ② strategie: omezení lokálních minim energetické funkce pomocí „zašuměné dynamiky sítě“
 - dočasné povolení aktualizace stavu sítě i za cenu přechodného zvýšení energetické hladiny
 - **stochastické modely: simulované žíhání, Boltzmannův stroj**

Spojitý model Hopfieldovy sítě

- Aktivace neuronu i vybraného pro aktualizaci podle:

$$x_i = s(\xi_i) = \frac{1}{1 + e^{-\xi_i}}$$

ξ_i je potenciál (excitace) neuronu i

- Pomalá změna potenciálu neuronu v čase podle:

$$\xi_i(t+1) = (1-\alpha)\xi_i(t) + \alpha \sum_{j=1}^n w_{ij}x_j = (1-\alpha)\xi_i(t) + \alpha \sum_{j=1}^n w_{ij}s(\xi_j)$$

- $0 \leq \alpha \leq 1$... adaptační parametr
- w_{ij} ... váha mezi neuronem i a j

Spojitý model Hopfieldovy sítě

- Tedy:

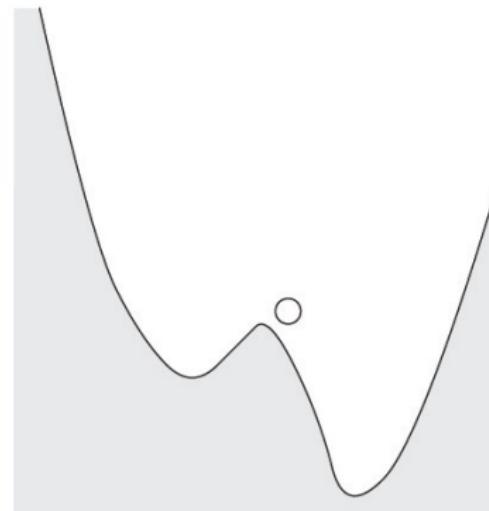
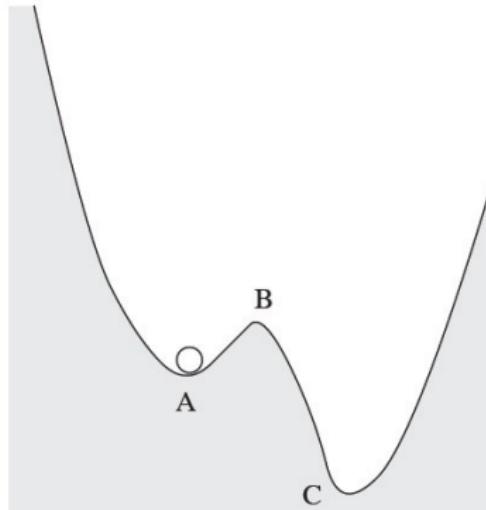
$$\Delta \xi_i(t) = -\alpha \xi_i(t) + \alpha \sum_{j=1}^n w_{ij} s(\xi_j)$$

- Při simulacích spočítat diskrétní approximaci $\Delta \xi_i(t)$ a přičíst ji k aktuální hodnotě $\xi_i(t)$
výsledkem bude nový stav $x_i = s(\xi_i)$
- Asynchronní dynamika – vede k dosažení rovnovážného stavu

Spojitý model Hopfieldovy sítě

- Pro kombinatorické problémy může spojitý model nalézt lepší řešení než model diskrétní
- Pro velmi složité problémy (typu TSP) ovšem spojitý model obecně nenachází výrazně lepší řešení
- Snadná hardwarová implementace

Stochastické systémy - simulované žíhání



Simulované žíhání

Při minimalizaci energetické funkce E se tento jev simuluje následujícím způsobem:

- Hodnota proměnné x se změní vždy, když může aktualizace Δx zmenšit hodnotu energetické funkce E
- Pokud by se při aktualizaci x naopak hodnota E zvýšila o ΔE , bude nová hodnota x (tj. $x + \Delta x$) přijata s pravděpodobností $p_{\Delta E}$:

$$p_{\Delta E} = \frac{1}{1 + e^{\Delta E/T}}$$

kde T je tzv. teplotní konstanta.

Simulované žíhání

- Pro velké hodnoty T bude $p_{\Delta E} \sim 1/2$
a aktualizace stavu nastane zhruba v polovině těchto případů
- Pro $T = 0$ bude docházet pouze k takovým aktualizacím, kdy se hodnota E sníží
- Postupná změna hodnot T z velmi vysokých hodnot směrem k nule odpovídá zahřátí a postupnému ochlazování v procesu žíhání

Navíc:

- Lze ukázat, že touto strategií lze dosáhnout (asymptoticky) globálního minima energetické funkce
- Sigmoida nejlépe odpovídá funkcím používaným v termodynamice (pro analýzu teplotní rovnováhy)

Stochastické systémy - Boltzmannův stroj

Definice

- Boltzmannův stroj je Hopfieldova síť, která se skládá z n neuronů se stavami x_1, x_2, \dots, x_n .
Stav neuronu i se aktualizuje asynchronně podle pravidla:

$$x_i = \begin{cases} 1 & \text{s pravděpodobností } p_i, \\ 0 & \text{s pravděpodobností } 1 - p_i, \end{cases}$$

kde

$$p_i = \frac{1}{1 + e^{-(\sum_{j=1}^n w_{ij}x_j - \theta_i)/T}}$$

- T je kladná teplotní konstanta
- w_{ij} a θ_i jsou váhy a prahy neuronů

Boltzmannův stroj

Energetická funkce Boltzmannova stroje

$$E(\vec{x}) = -1/2 \vec{x} W \vec{x}^T + \vec{\theta} \vec{x}^T = -1/2 \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \theta_i x_i$$

- Rozdíl mezi Boltzmannovým strojem a Hopfieldovým modelem spočívá ve stochastické aktivaci neuronů

Boltzmannův stroj

- Pokud je T velmi malé, bude:
 $p_i \sim 1$, jestliže je excitace neuronu kladná

$$\sum_{j=1}^n w_{ij}x_j - \theta_i > 0$$

$p_i \sim 0$, jestliže je excitace neuronu záporná
→ dynamika Boltzmannova stroje approximuje dynamiku diskrétní Hopfieldovy sítě a Boltzmannův stroj najde lokální minimum energetické funkce

Boltzmannův stroj

- Pro $T > 0$ je pravděpodobnost změny anebo posloupnosti změn ze stavu x_1, x_2, \dots, x_n do jiného stavu vždy nenulová.
→ Boltzmannův stroj nezůstane v jediném stavu
→ snižování a zároveň možnost zvyšování energie systému
- Pro velké hodnoty T projde síť téměř celý stavový prostor
- V ochlazovací fázi má síť tendenci zůstávat déle v oblastech blízkých atraktorům lokálních minim

Důležité

Pokud se teplota snižuje správným způsobem, můžeme očekávat, že systém dosáhne globálního minima s pravděpodobností 1

Jak je to v Matlabu

- speciální typ sítě – lineárně saturovaná přenosová funkce, synchronní dynamika, matice nemusí být symetrická s nulovou diagonálou
- *newhop* ... vytvoření „Hopfieldovy“ sítě
 - `net = newhop(T)`
 - `net.LW{1,1}` ... matice vah
 - `net.b{1,1}` ... prahy neuronů
- *sim* ... rozpoznávání
 - $[Y, Pf, Af] = sim(net, Pocet_vzoru, [], T)$.
 $Y = Af$... výsledek
 - $[Y, Pf, Af] = sim(net, \{Pocet_vzoru, Pocet_iteraci\}, \[], T)$.
 $Af\{1, 1\}$... výsledek
 $Y\{1, k\}$... výsledek po k iteracích
- dema