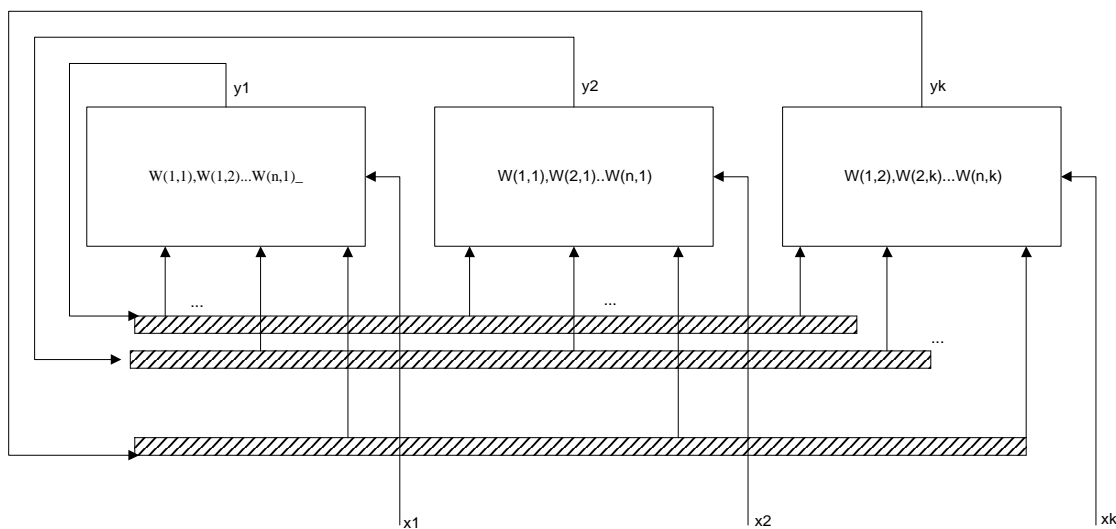


# Sieć Hopfielda

Zdefiniowana w roku 1982, wprowadziła sprzężenie zwrotne do struktur sieci

Cechy charakterystyczne:

- brak jednokierunkowego przepływu sygnału
- nie możemy wyróżnić warstwy wejściowej, wyjściowej, pośredniej



Jednowarstwowy, jednowymiarowy model sieci.

W sieci tej neurony mają nieliniowe charakterystyki :

$$y_m^{(j)} = \varphi(e_m^{(j)}) \quad \text{gdzie:} \quad e_m^{(j)} = \sum_{i \in \xi} e_i^{(m)} * y_i^{(j)} + x_m^{(j)}$$

a nieliniowość  $y = \varphi(e)$  dana jest prostą binarną funkcją:

$$y_m^{(j+1)} = \begin{cases} 1 & \text{dla } e_m^{(j)} > w_0^{(m)} \\ y_m^{(j)} & \text{dla } e_m^{(j)} = w_0^{(m)} \\ -1 & \text{dla } e_m^{(j)} < w_0^{(m)} \end{cases}$$

- współczynniki wagowe  $w_i^{(m)}$  łączące wyjście  $i$ -tego neuronu z wejściem  $m$ -tego neuronu **nie zależą od  $j$** , przy czym  $j$  określa chwilę czasową w procesie dynamicznego pobudzenia sieci, w której się ona obecnie znajduje.
- sumowanie sygnałów wyjściowych  $y_i^{(j)}$  z poszczególnych neuronów we wzorze definiującym łączne pobudzenie  $e_m^{(j)}$  odbywa się po **wszystkich** elementach sieci, a zatem w sieci przewidziane są połączenia z warstw wyjściowych do warstw wcześniejszych - czyli **sprzężenia zwrotne**.

Sieć o takim schemacie połączeń nazywać będziemy siecią **autoasocjacyjną**.

## Procesy w sieciach Hopfielda

Ze względu na specyficzną architekturę sieci możliwe staje się generowanie przebiegów dynamicznych na skutek tego, iż w pewnym momencie  $j$  sygnały wyjściowe  $y_m^{(j)}$  stają się automatycznie wartościami wejściowymi  $y_i^{(j+1)}$ .

Realizowane jest więc nieliniowe wektorowe odwzorowanie :

$$Y^{(j+1)} = \Xi(X^{(j)}, Y^{(j)})$$

przy założeniu iż  $x_m^{(j)} \equiv 0$  dla wszystkich  $m$  i dla wszystkich  $j > 0$  zależność upraszcza się do :

$$Y^{(j+1)} = \Xi(Y^{(j)})$$

Kolejne wartości  $Y^{(1)}, Y^{(2)}, \dots, Y^{(j-1)}, Y^{(j)}$  obserwujemy w przestrzeni stanu  $\gamma \subseteq R^k$  do której należą wszystkie wektory sygnałów wyjściowych  $Y^{(j)}$ . Możliwe więc jest pojawienie się oscylacji, przebiegów rozbieżnych, a nawet pojawienie się chaosu. W 1983 Cohen i Grossberg wykazali, iż sieć generuje stabilne rozwiązania, jeśli uniemożliwi się autoasocjacyjność pojedynczych neuronów :

$$w_m^{(m)} = 0$$

oraz zapewni się symetrię sieci:

$$w_i^{(m)} = w_m^{(i)}$$

## Stany równowagi w sieci Hopfielda

Stan równowagi sieci można potraktować jako problem wyboru stanu o minimalnej „energii” sieci. Definiuje się więc funkcję energii (funkcję Lapunowa) o następującej postaci:

$$E^{(j)} = -\frac{1}{2} \sum_{i \in \xi} \sum_{m \in \xi} w_i^{(m)} y_i^{(j)} y_m^{(j)} - \sum_{i \in \xi} x_i^{(i)} y_i^{(j)} + \sum_{i \in \xi} w_0^{(i)} y_i^{(j)}$$

Zmiana  $\delta E$  zachodząca na skutek zmiany stanu sieci spowodowanej zmianą sygnału wyjściowego  $i$ -tego neuronu wynosi:

$$\delta E^{(j)} = -\left[ \sum_{m \neq i} w_m^{(i)} y_m^{(j)} + x_i^{(j)} - w_0^{(i)} \right] \delta y_i^{(j)}$$

albo:

$$\delta E^{(j)} = -[e_i^{(j)} - w_0^{(i)}] \delta y_i^{(j)}$$

Przyjmijmy, że dla kroku  $j$  pobudzenie neuronu  $e_i^{(j)}$  przekracza próg  $w_0^{(i)}$ .

Wówczas na wyjściu pojawia się sygnał  $y_i^{(j)} = 1$ , zatem czynnik  $\delta y_i^{(j)}$  musi być dodatni lub zerowy. Równocześnie ze względu na:  $e_i^{(j)} > w_0^{(i)}$  czynnik w nawiasie kwadratowym musi być dodatni, a więc zmiana energii może być jedynie **ujemna** lub **zerowa**.

Analogicznie dla:  $e_i^{(j)} < w_0^{(i)}$ , zmiana energii jest również ujemna lub zerowa, natomiast przy  $e_i^{(j)} = w_0^{(i)}$  energia nie zmienia się.

Powyższe rozumowanie potwierdza, iż sieć dąży do osiągnięcia minimum, następnie do zahamowania zmian i osiągnięcia stanu stabilnego.

## Pamięć autoasocjacyjna

Pamięć autoasocjacyjna (pamięć skojarzeniowa) nazywana czasami **CAM** od **C**ontent **A**dressable **M**emory.

Sieć powinna zapamiętać szereg wzorców  $D_j$ , a po pojawieniu się wektora  $X$  podobnego do jednego z zapamiętanych wzorców sieć powinna odtworzyć zapamiętany wektor  $D$  podobny do wektora  $X$ .

Algorytm uczenia - metoda Hebba :

$$w_i^{(m)} = \sum_{j=1}^M y_i^{(j)} y_m^{(j)}$$

gdzie:  $y_i^{(j)}$  jest  $i$ -tą składową wektora  $D_j$ .

Macierz  $W$  połączeń pomiędzy elementami sieci ma postać:

$$W = \sum_{j=1}^M D_j^T D_j$$

Działanie sieci polega na jednorazowym podaniu sygnałów wejściowych  $X$  i oczekiwaniu na określony stan stabilny odpowiedzi wzorca  $D$  skojarzonego z sygnałem wejściowym.

Pojemność tak utworzonej sieci szacuje się na około  $0.15N$ , gdzie  $N$  jest liczbą neuronów w sieci.

Sygnały wyjściowe przy pamięciach skojarzeniowych traktuje się jako ciągłe z przedziału domkniętego  $\langle -1, 1 \rangle$  ( $y_m^{(j)} \in [-1, 1]$ ).

Nieliniowa funkcja aktywacji  $y_m^{(j)} = \varphi(e_m^{(j)})$  może być przedstawiona w postaci:

- funkcji liniowej

$$y_m^{(j)} = \varphi(e_m^{(j)}) = k e_m^{(j)},$$

- gdzie  $k$  jest zadany współczynnikiem,
- funkcji skoku jednostkowego

$$y_m^{(j)} = \varphi(e_m^{(j)}) = \begin{cases} 1 & \text{dla } e_m^{(j)} > 0 \\ 0 & \text{dla } e_m^{(j)} \leq 0 \end{cases},$$

- funkcji signum

$$y_m^{(j)} = \varphi(e_m^{(j)}) = \begin{cases} 1 & \text{dla } e_m^{(j)} > 0 \\ 0 & \text{dla } e_m^{(j)} = 0, \\ -1 & \text{dla } e_m^{(j)} < 0 \end{cases},$$

- zmodyfikowanej funkcji signum

$$y_m^{(j)} = \varphi(e_m^{(j)}) = \begin{cases} 1 & \text{dla } e_m^{(j)} > 0 \\ -1 & \text{dla } e_m^{(j)} \leq 0 \end{cases},$$

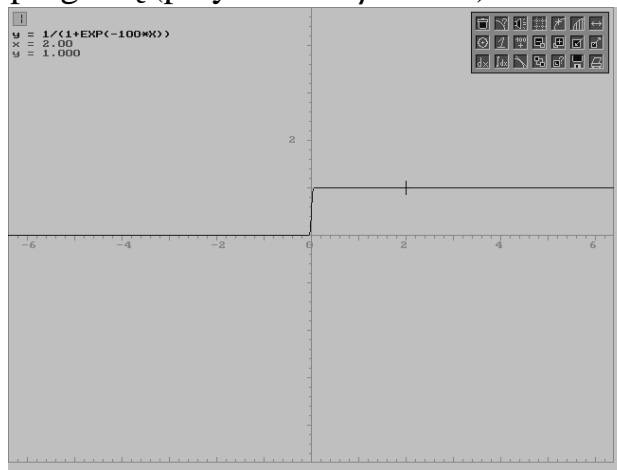
- funkcji perceptronowa

$$y_m^{(j)} = \varphi(e_m^{(j)}) = \begin{cases} e_m^{(j)} & \text{dla } e_m^{(j)} > 0 \\ 0 & \text{dla } e_m^{(j)} \leq 0 \end{cases},$$

- funkcji sigmoidalnej

$$y_m^{(j)} = \varphi(e_m^{(j)}) = \frac{1}{1 + \exp(-\beta e_m^{(j)})},$$

gdzie  $\beta$  jest zadany parametrem. Pożądane jest duże  $\beta$ , dla którego funkcja przypomina funkcję progową (przykład dla  $\beta = 100$ ):



- funkcji tangensoidalnej

$$y_m^{(j)} = \varphi(e_m^{(j)}) = \operatorname{tgh}\left(\frac{\alpha e_m^{(j)}}{2}\right) = \frac{1 - \exp(-\alpha e_m^{(j)})}{1 + \exp(-\alpha e_m^{(j)})},$$

gdzie:  $\alpha$  jest zadany parametrem, a  $\operatorname{tgh}(\cdot)$  jest funkcją tangens hiperboliczny.

## Maszyny Boltzmann

Koncepcja maszyny Boltzmann oparta jest na założeniu, że stan  $y_m^{(j)}$  każdego neuronu (sygnału wyjściowego) może zmieniać się w sposób losowy z określonym prawdopodobieństwem zależnym od energii i temperatury.

$$p(E, T) = e^{-\frac{E}{kT}}$$

W odniesieniu do systemu informatycznego wzór powyższy przyjmuje postać:

$$p_m^{(j)} = 1/[1 + \exp(-\delta E_m^{(j)} / T^{(j)})]$$

gdzie:  $E_m^{(j)} = e_m^{(j)} - w_0^{(m)}$  jest nadwyżką energii łącznego pobudzenia  $e_m^{(j)}$  ponad próg pobudzenia  $w_0^{(m)}$  dla każdego kroku  $j$

$\delta$  - pewna arbitralnie dobierana stała

$T^{(j)}$  - symulowana temperatura sieci dla kroku  $j$ -tego

### Algorytm doprowadzania sieci do równowagi:

1. Dla ustalonego  $T^{(j)}$  wyliczane są wszystkie wartości  $p_m^{(j)}$ , a następnie **losowo** z prawdopodobieństwem  $p_m^{(j)}$  ustawiane są wartości sygnałów wyjściowych  $y_m^{(j)}$ .  
Konkretnie dla każdego kroku  $j$  i dla każdego neuronu  $m$  losowana jest z konkretnym rozkładem prawdopodobieństwa wartość przypadkowa  $\xi \in [0, 1]$ , a następnie ustala się wartość  $y_m^{(j)}$  zgodnie z regułą:

$$y_m^{(j)} = \begin{cases} 1 & \text{dla } \xi \leq p_m^{(j)} \\ 0 & \text{w przeciwnym wypadku} \end{cases}$$

2. Obniża się stopniowo wartość  $T^{(j)}$  w kolejnych krokach np. według reguły:

$$T^{(j+1)} = T^{(j)} - \varepsilon$$

albo

$$T^{(j+1)} = T^{(j)}(1 - \varepsilon)$$

i powtarza się (1) aż do osiągnięcia stanu równowagi.

## Uogólniony algorytm Hintona i Sejnowskiego

zbiór uczący  $U = \{ \langle \mathbf{X}^k, \mathbf{Z}^k \rangle, k = 1, 2, N \}$

$\mathbf{X}$ -wektor niektórych sygnałów wejściowych

$\mathbf{Z}$ -wektor określający oczekiwane sygnały wyjściowe niektórych elementów sieci

### A. Obliczanie „związanych” prawdopodobieństw.

1. Wymusza się wynikające z ciągu uczącego wartości wejść  $X^k$  i wyjść  $Z^k$  wyróżnionych neuronów wejściowych i wyjściowych.
2. Pozwala się sieci dojść do stanu równowagi
3. Rejestruje się sygnały wyjściowe  $y_m^{(k)}$  wszystkich elementów sieci
4. Powtarza się powyższe punkty dla wszystkich elementów ciągu uczącego  $x$  zbierając statystykę, dzięki której po zakończeniu pokazów wszystkich elementów ciągu uczącego możliwe jest obliczenie prawdopodobieństwa  $P_{ij}^+$  tego że sygnały neuronów o numerach  $i$  oraz  $j$  mają **równocześnie** wartość 1

### B. Obliczanie „nie związanych” prawdopodobieństw.

1. Wymusza się **przypadkowe** wartości sygnałów wyjściowych wszystkich elementów sieci
2. Pozwala się sieci dojść do stanu równowagi
3. Rejestruje się sygnały wyjściowe  $y_m^{(k)}$  wszystkich elementów sieci
4. Powtarza się poprzednie punkty wielokrotnie, zbierając statystykę, dzięki której po zakończeniu pokazów wszystkich elementów ciągu uczącego możliwe jest obliczenie prawdopodobieństwa  $P_{ij}^-$  tego, że sygnały wyjściowe neuronów o numerach  $i$  oraz  $j$  mają **równocześnie** wartość 1

C. Na podstawie  $P_{ij}^+$  oraz  $P_{ij}^-$  koryguje się wartości współczynników wagowych  $w_i^{(j)}$  oraz  $w_j^{(i)}$  łączących neurony o numerach  $i$  oraz  $j$ . Wartości te są zwiększane o wartość  $\delta_{ij}$  wyliczoną ze wzoru :

$$\delta_{ij} = \eta [P_{ij}^+ - P_{ij}^-]$$

Wartości odpowiednich współczynników dają się znaleźć już po kilku iteracjach.

## Rozwiązywanie problemu komiwojażera

Problem polega na ustaleniu optymalnej trasy objazdu  $n$  miast przez wędrownego sprzedawcę, który chce odwiedzić wszystkie miasta i przebyć najkrótszą drogę.

Czas rozwiązywania tego problemu rośnie wykładniczo przy wzroście liczby miast  $n$  i możliwe jest utworzenie  $D = n!/(2n)$  rozróżnialnych tras.

$$n=60 \text{ to } D=69.34155 \cdot 10^{78}$$

Przy zastosowaniu do obliczeń sieci neuronowej kluczem jest odpowiednia reprezentacja danych wejściowych. Jedno z możliwych możliwości zakłada, że:

- każde miasto reprezentowane jest przez jeden wiersz zawierający  $n$  neuronów,
- 
- w każdym wierszu **dokładnie** jeden neuron powinien przyjmować wartość 1,
- 
- pozycja na której neuron przyjmuje wartość 1 określa jednoznacznie *nr miasta* i kolejność, w której ma być ono odwiedzone.

**Łączna liczba neuronów wynosi  $n^2$ .**



Funkcję energii opisują cztery składniki:

$$E_1 = \frac{A}{2} \sum_x \sum_i \sum_{i \neq j} y_{xi} y_{xj}$$

$$E_2 = \frac{B}{2} \sum_i \sum_x \sum_{z \neq x} y_{xi} y_{zj}$$

$$E_3 = \frac{C}{2} [\sum_x \sum_i y_{xi} - n]^2$$

$$E_4 = \frac{D}{2} \sum_x \sum_{z \neq x} \sum_i d_{xz} y_{xi} (y_{z,i+1} + y_{z,i-1})$$

Znaczenie poszczególnych składników:

$E_1$ - ma zerową wartość wtedy i tylko wtedy jeśli w każdym wierszu jest najwyżej jedna jedynka,

$E_2$  - wartość zerowa wtedy i tylko wtedy, gdy w kolumnie oznaczającej konkretny etap podróży będzie najwyżej jedna jedynka,

$E_3$  - zero, gdy w macierzy jest dokładnie  $n$  jedynek,

$E_4$  - długość wybranej drogi.

Wybierane arbitralnie współczynniki A,B,C,D są względnymi wagami poszczególnych składników.

Przykładowe wartości tych współczynników są w pakiecie NeuralWorks Professional II/PLUS firmy NeuralWare następujące:

$$A \cong B \cong D \cong 1000$$

C dobierane jest w zależności od relacji pomiędzy parametrem  $n$  używanym we wzorze dla składnika  $E_3$ , a rzeczywistą liczbą miast  $n^*$

$$C = 3/4*(n - n^*)$$

W rozważanym pakiecie modelującym sieć neuronową współczynniki wagowe określające parametry połączeń pomiędzy  $i$ -tym neuronem z  $x$ -tej warstwy, a  $j$  - tym neuronem z  $z$  - tej warstwy wyrażają się wzorem:

$$w_{xi,zj} = -A \delta_{xz} (1 - \delta_{ij}) - B \delta_{ij} (1 - \delta_{xz}) - C - D \delta_{xz} (\delta_{j,i+1} + \delta_{j,i-1})$$

gdzie:  $\delta_{ij}$  oznacza funkcję Kroneckera

$$\delta_{ij} = \begin{cases} 1 & \text{dla } i = j \\ 0 & \text{w przeciwnym wypadku} \end{cases}$$

Parametrami dodatkowymi są wyrazy wolne (progi pobudzenia) identyczne dla wszystkich elementów:

$$w_{xz}^0 = Cn$$

Główną zaletą zastosowania sieci neuronowej do rozwiązywania problemu TSP jest to, iż wzrost rozmiaru problemu  $n$  nie powoduje wydłużenia czasu obliczeń, a jedynie pociąga za sobą rozbudowę sieci.