

# Sieci Neuronowe

## Wykład 5 Sieć Hopfielda

wykład przygotowany na podstawie.

R. Tadeusiewicz, “Sieci Neuronowe”, Rozdz. 7. Akademicka Oficyna Wydawnicza RM, Warszawa 1993.

S. Osowski, “Sieci Neuronowe w ujęciu algorytmicznym”, Rozdz. 6. WNT, Warszawa 1996

# Sprzężenie zwrotne jako nowa jakość w strukturach sieci

---

Dotychczas opisywane sieci charakteryzowały się *jednokierunkowym przepływem sygnałów*.

Można w nich było wyróżnić warstwę wejściową, wyjściową i ewentualnie warstwy pośrednie (“ukryte”). Jednak przepływ sygnałów w tych sieciach był ściśle jednokierunkowy: od wejścia do wyjścia.

Najbardziej znaną siecią której *kierunek jest odwrócony*, jest

## *sieć Hopfielda*

Została opublikowana w 1982 roku i stała się punktem zwrotnym w badaniach sieci neuronowych.

# Sprzężenie zwrotne jako nowa jakość w strukturach sieci

## sieć Hopfieldda

W sieci tej neurony mają nieliniowe charakterystyki:

$$y_m^{(j)} = \phi(e_m^{(j)})$$

gdzie (po etapie uczenia)

$$e_m^{(j)} = \sum_{i \in M} \omega_i^{(m)} y_i^{(j)} + x_m^{(j)}$$

$$y_m^{(j+1)} = \begin{cases} 1 & \text{gdy } e_m^{(j)} > \omega_0^{(m)} \\ y_m^{(j)} & \text{gdy } e_m^{(j)} = \omega_0^{(m)} \\ -1 & \text{gdy } e_m^{(j)} < \omega_0^{(m)} \end{cases}$$

a nieliniowość jest dana prostą funkcją binarną.

# Sprzężenie zwrotne jako nowa jakość w strukturach sieci

---


Interesujące są dwa elementy podanych wzorów:

⇒ Współczynniki wagowe  $\omega_i^{(m)}$  łączące wyjście **i-tego** neuronu z wejściem **m-tego** neuronu *nie zależą* od  $j$ . Podane wzory dotyczą sieci już nauczonej, a  $j$  oznacza chwilę czasową, określającą w jakim momencie *procesu dynamicznego*, następującego po pobudzeniu sieci, znajduje się ona obecnie.

⇒ Sumowanie sygnałów wyjściowych  $y_i^{(j)}$  z poszczególnych neuronów we wzorze definiującym łączne pobudzenie  $e_m^{(j)}$  odbywa się *po wszystkich elementach* sieci. Oznacza to, że w sieci przewidziane są także połączenia z warstw dalej położonych (wyjściowych) do warstw wcześniejszych – czyli *sprzężenia* zwrotne.

Sieć o takim schemacie połączeń nazywa się *siecią autoasocjacyjną*. W ramach tego sprzężenia każdy neuron jest także połączony jednym z wejść ze swoim własnym wyjściem, zatem zasada autoasocjacyjności odnosi się także do pojedynczych neuronów.

# Sprzężenie zwrotne jako nowa jakość w strukturach sieci



Sieć o takim schemacie nazywa się *siecią autoasocjacyjną*. W ramach tego sprzężenia każdy neuron jest połączony jednym z wejść także ze swoim własnym wyjściem, zatem zasada autoasocjacyjności odnosi się także do pojedynczych neuronów. **Każdy** neuron sieci ma także kontakt z pewnym, odpowiadającym mu sygnałem wejściowym  $x_m^{(i)}$ , zatem zacierą się tu podział na warstwę wejściową i pozostałe warstwy sieci. W związku z tym neurony sieci Hopfielda *nie tworzą* wcale *wyraźnie wydzielonych warstw*, mogą być rozważane w dowolnej topologii.

# Natura procesów w sieci Hopfielda

---

W sieciach autoasocjacyjnych możliwe jest pojawianie się pewnych przebiegów dynamicznych polegających na tym, że uzyskane w pewnym kroku  $j$  wartości sygnałów wyjściowych  $y_m^{(j)}$  wszystkich neuronów sieci ( $m=1,2,\dots,k$ ) stają się automatycznie wartościami wejściowymi  $y_i^{(j+1)}$  w kolejnym kroku symulacji.

Oznacza to, że sieć realizuje nieliniowe wektorowe odwzorowanie.

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

które zwykle podlega dodatkowemu uproszczeniu, ponieważ przyjmuje się, że  $x_m^{(j)} \equiv 0$ , dla wszystkich  $m$  i dla wszystkich  $j > 0$ .

# Natura procesów w sieci Hopfielda

---

Uproszczenie to ma następująca interpretację:

→ w chwili początkowej ( $j=0$ ) do neuronów sieci (wszystkich lub wybranych) doprowadza się sygnały wejściowe  $x_m^{(0)} \neq 0$ .

→ w wyniku, na wyjściach neuronów sieci wytwarza się zestaw sygnałów wyjściowych  $Y^{(1)}$ .

→ sygnały wejściowe zostają odłączone i aż do końca symulacji nie uczestniczą w obliczeniach ( $x_m^{(j)} \equiv 0$ )

→ w sieci zaczyna rozwijać się pewien proces, polegający na wyznaczaniu kolejnych wartości  $Y^{(j+1)} = \Xi ( Y^{(j)} )$

# Natura procesów w sieci Hopfielda

Proces wyznaczamy przez kolejne wartości

$$Y^{(1)}, Y^{(2)}, Y^{(3)}, \dots, Y^{(j-1)}, Y^{(j)}, Y^{(j+1)}, \dots$$

można obserwować w przestrzeni stanu, do której należą wszystkie wektory sygnałów wyjściowych z elementów sieci  $Y^{(j)}$ .

W tej przestrzeni możliwe są wszystkie znane procesy, jakie związane są z realizacją nieliniowej rekurencyjnej zależności  $Y^{(j+1)} = \Xi ( Y^{(j)} )$ , a mianowicie stabilizowanie się przebiegów i ich zbieżność do określonych wartości  $Y^*$ , możliwe jest pojawianie się oscylacji wartości  $Y^{(j)}$  i związanych z nimi *cykli* oraz *orbit* w przestrzeni  $Y$ , możliwe jest pojawianie się *przebiegów rozbieżnych*, wreszcie można w takim systemie przewidzieć możliwość pojawienia się *chaosu*.

O wyborze jednej z tych możliwości decyduje zestaw współczynników wagowych  $\omega_i^{(m)}$ .



# Natura procesów w sieci Hopfielda

---

Stosunkowo wcześniej (1983) Cohen i Grossberg wykazali, że sieć generuje stabilne rozwiązania, jeżeli uniemożliwi się autoasocjacyjność pojedynczych neuronów  $\omega_m^{(m)} = 0$ , oraz zapewni się symetrię sieci  $\omega_i^{(m)} = \omega_m^{(i)}$ .

Ale nawet przy stabilnym zachowaniu pozostaje otwarty problem wyboru punktu docelowego  $Y^*$ .

# Stan równowagi w sieci Hopfielda

Problem wyboru określonego “docelowego” stanu sieci można traktować jako problem wyboru stanu o “minimalnej” energii sieci. Funkcja “energii” (metafora wprowadzona przez Hopfielda) jest też określana nazwą funkcji Lapunowa.

$$E^{(j)} = (-1/2) \sum_{i \in \mathfrak{S}} \sum_{m \in \mathfrak{S}} \omega_i^{(m)} y_i^{(j)} y_m^{(j)} - \sum_{i \in \mathfrak{S}} x_i^{(j)} y_i^{(j)} + \sum_{i \in \mathfrak{S}} \omega_0^{(i)} y_i^{(j)}$$

Na podstawie tej definicji można wprowadzić pojęcie *“zmiany stanu” sieci*

$$\delta E^{(j)} = - \left[ \sum_{m \neq j} \omega_i^{(m)} y_m^{(j)} - x_i^{(j)} - \omega_0^{(i)} \right] \delta y_i^{(j)}$$

Wzór ten można również zapisać w sposób bardziej czytelny

$$\delta E^{(j)} = - \left[ e_i^{(j)} - \omega_0^{(i)} \right] \delta y_i^{(j)}$$

Na podstawie tego wzoru można rozważyć różne zachowania sieci.

# Stan równowagi w sieci Hopfielda

Weźmy pod uwagę jeden z neuronów sieci (o numerze  $i$ ) rozważając wszystkie możliwe stany jego pobudzenia  $e_i^{(j)}$  i sygnału wyjściowego  $y_i^{(j)}$ .

$$\delta E^{(j)} = - [ e_i^{(j)} - \omega_0^{(i)} ] \delta y_i^{(j)}$$

⇒ Jeśli  $e_i^{(j)} > \omega_0^{(i)}$ , zgodnie z zasadą działania rozważanego modelu neuronu – na wyjściu tego neuronu powinien pojawić się sygnał  $y_i^{(j)} = 1$ . Oznacza to że współczynnik  $\delta y_i^{(j)}$  musi być w takim przypadku dodatni lub zerowy – nigdy ujemny. Równocześnie, przy  $e_i^{(j)} > \omega_0^{(i)}$  także czynnik w kwadratowym nawiasie musi być dodatni, a zgodnie z podanym wzorem zmiana całkowitej “energii” sieci musi być ujemna lub zerowa.

# Stan równowagi w sieci Hopfielda

Weźmy pod uwagę jeden z neuronów sieci (o numerze  $i$ ) rozważając wszystkie możliwe stany jego pobudzenia  $e_i^{(j)}$  i sygnału wyjściowego  $y_i^{(j)}$ .

$$\delta E^{(j)} = - [ e_i^{(j)} - \omega_0^{(i)} ] \delta y_i^{(j)}$$

⇒ Jeśli  $e_i^{(j)} < \omega_0^{(i)}$ , to oczywiście  $y_i^{(j)} = 0$  i wtedy czynnik  $\delta y_i^{(j)}$  musi być ujemny lub zerowy. W rezultacie również wtedy, zmiana całkowitej energii  $\delta E^{(j)}$  musi być ujemna (lub zerowa).

⇒ Jeśli  $e_i^{(j)} = \omega_0^{(i)}$ , to oczywiście  $\delta E^{(j)} = 0$  i energia sieci nie zmienia się.

# Stan równowagi w sieci Hopfielda

---

Z tego prostego rozumowania wynika, że całkowita “energia” sieci może pozostać stała lub może się zmniejszać – natomiast nie może rosnać.

Skoro w trakcie pracy sieci “energia” stale maleje – musi wreszcie osiągnąć stan odpowiadający minimum – lokalnemu lub globalnemu.

Po osiągnięciu tego minimum dalsze zmiany w sieci są niemożliwe, proces się zatrzymuje.

Dynamiczne własności *sieci Hopfielda* wygodnie jest rozważać na podstawie ciągłego modelu zachowania sieci.

# Procesy dynamiczne w sieciach Hopfielda

---

Wektor sumarycznych pobudzeń wszystkich neuronów sieci  $e$  można wtedy związać z wektorami sygnałów wyjściowych z elementów sieci  $Y$  oraz sygnałów wejściowych (zewnętrznych)  $X$  za pomocą macierzowego równania różniczkowego.

$$de/dt = -e/\tau + WY + X$$

uzupełnionego nieliniowym równaniem charakterystyki statycznej jednego elementu

$$y_i = \phi(e_i)$$

Dla takiego nieliniowego elementu systemu dynamicznego możliwe jest określenie *funkcji Lapunowa*

# Procesy dynamiczne w sieciach Hopfielda

Dla takiego nieliniowego elementu systemu dynamicznego możliwe jest określenie *funkcji Lapunowa* w postaci

$$L = -1/2 Y^T W Y - X^T Y + 1/\tau \sum_{i=1}^k \int_0^{y_i} \phi^{-1}(\xi) d\xi$$

która upraszcza się w przypadku funkcji  $\phi$  zbliżonej kształtem do skoku jednostkowego, przyjmując postać

$$L = -1/2 Y^T W Y - X^T Y$$

Siec Hopfielda może być wykorzystywana jako tzw. *pamięć autoasocjacyjna* (skojarzeniowa). Czasem ten rodzaj sieci nazywany też bywa CAM (Content Adressable Memory).

# Pamięć autoasocjacyjna

Przedyskutujmy jej działanie:

⇒ Sieć powinna zapamiętać szereg wektorów  $D_j$  ( $j=1,2,\dots,M$ ) i po pojawieniu się wektora wejściowego  $X$  podobnego do któregoś z zapamiętanych wzorców sieć powinna, na zasadzie zapamiętanych skojarzeń, odnaleźć i odtworzyć ten zapamiętany wektor  $D_j$ , który kojarzy się z wektorem  $X$ .

⇒ Uczymy sieć metodą Hebba, wytwarzając współczynniki wagowe  $\omega_i^{(m)}$  przy połączeniach między  $i$ -tym i  $n$ -tym neuronem zgodnie z zasada

$$\omega_i^{(m)} = \sum y_i^{(j)} y_m^{(j)}$$

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

⇒ W wyniku takiego postępowania, macierz  $W$  połączeń między elementami sieci ma postać

$$W = \sum D_j^T D_j$$



# Pamięć autoasocjacyjna

---

Działanie sieci polega na jednorazowym (impulsowym) podaniu sygnałów wejściowych  $X$  i swobodnej relaksacji sieci do najbliższego stanu stabilnego odpowiadającego minimum energii. Ten stan interpretujemy jako “skojarzony” z bodźcem  $X$  zapamiętany sygnał  $D$ .

Pojemność takiej pamięci jest szacowana przez różnych autorów rozmaicie. Jak wiadomo, sieć binarnych elementów złożona z  $N$  neuronów może znajdować się ogólnie w jednym z  $2^N$  rozróżnialnych stanów, jednak rzeczywista pojemność sieci jest znacznie mniejsza.

# Pamięć autoasocjacyjna

---

Przy opisanych wyżej zastosowaniach sieci neuronowych jako pamięci asocjacyjnej sygnały wyjściowe z elementów sieci przyjmuje się jako ciągle  $y \in [1-, 1]$ , a nieliniowa funkcja  $y_m^{(i)} = \phi(e_m^{(i)})$  może być przedstawiona w formie klasycznej sigmoidy.

$$y_m^{(i)} = \phi(e_m^{(i)}) = 1 / (1 + \exp(-\beta e_m^{(i)}))$$

Dla dużych  $\beta$  funkcja jest stroma i przypomina funkcje progowa. Dla małych  $\beta$  funkcja ta ma przebieg gładki i łagodniejszy i zachowanie sieci przestaje mieć opisany powyżej dyskretny charakter.

# Maszyny Boltzmanna

---

Z dyskutowaną siecią Hopfielda kojarzone są zwykle tak zwane

## *Maszyny Boltzmanna.*

Koncepcja takiej maszyny oparta jest na założeniu, że stan (sygnał wyjściowy  $y_m^{(j)}$ ) każdego neuronu może się zmieniać w sposób losowy z określonym prawdopodobieństwem.

Prawdopodobieństwo to zależy od “energii” i “temperatury” sieci, podobnie jak w systemach fizycznych (termodynamicznych), w których gęstość prawdopodobieństwa  $p(E,T)$  energii systemu  $E$  związana jest z temperaturą  $T$  znanym wzorem Boltzmanna

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

gdzie  $k$  jest stałą Boltzmanna.

# Maszyny Boltzmann

Przenosząc to prawo do informacyjnego systemu, jakim jest sieć neuronowa, możemy na każdym kroku  $j$  związać z neuronem o numerze  $m$  “energię”  $E_m^{(j)}$  wyrażającą nadwyżkę jego łącznego pobudzenia  $e_m^{(j)}$  ponad progiem pobudzenia  $\omega_0^{(m)}$ .

$$E_m^{(j)} = e_m^{(j)} - \omega_0^{(m)}$$

Następnie w oparciu o energię  $E_m^{(j)}$  wyznaczane jest prawdopodobieństwo  $p_m^{(j)}$  zgodnie z regułą będącą *uogólnieniem prawa Boltzmann*.

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

gdzie  $\delta$  jest pewną arbitralnie dobieraną stałą, a  $T^{(j)}$  reprezentuje symulowaną w  $j$ -tym kroku “*temperature*” sieci.

# Maszyny Boltzmanna

---

Algorytm doprowadzania sieci do stanu równowagi sprowadza się do kolejnego wykonywania dwóch kroków:

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 neuronów  $y_m^{(j)}$ .
2. Obniża się stopniowo wartość  $T^{(j)}$  w kolejnych krokach, np.  $T^{(j+1)} = T^{(j)} - \varepsilon$  lub  $T^{(j+1)} = T^{(j)} (1 - \varepsilon)$ .

Powtarza się punkt (1) aż do osiągnięcia stanu równowagi.

# Maszyny Boltzmanna

---

Proces ten – na podstawie analogii z procesem tzw. odprężania stosowanego w cieplnej obróbce metali nazywa się zwykle symulowanym odprężaniem (simulated annealing), ponieważ podobnie jak obrabianemu materiałowi – sieci nadaje się na początku wysoką “temperaturę”  $T^{(i)}$ , a potem stopniowo się ją obniża doprowadzając do osiągnięcia globalnego minimum łącznej energii wewnętrznej sieci.

*Technika “maszyny Boltzmanna”* może być stosowana do dowolnej sieci, nie tylko sieci Hopfielda (autoasocjacyjnych). Jeśli sieć ma wyróżnione sygnały wejściowe i wyróżnione sygnały wyjściowe, to wówczas także można skorzystać z koncepcji osiągania przez sieć “*stanu równowagi*” termodynamicznej.

# Implementacja sprzętowa sieci Hopfielda

*Sieć Hopfielda*, ze względu na równoległą strukturę układową i powtarzalny typ elementów, nadaje się do realizacji sprzętowej przy użyciu standardowych elementów technologii mikroelektronicznej.

Punktem wyjścia jest opis sieci równaniem różniczkowym

$$\tau_i \frac{du_i}{dt} = -u_i + \sum W_{ij} f(u_j) + b_i$$

gdzie

$$u_j = \sum W_{ij} x_j$$

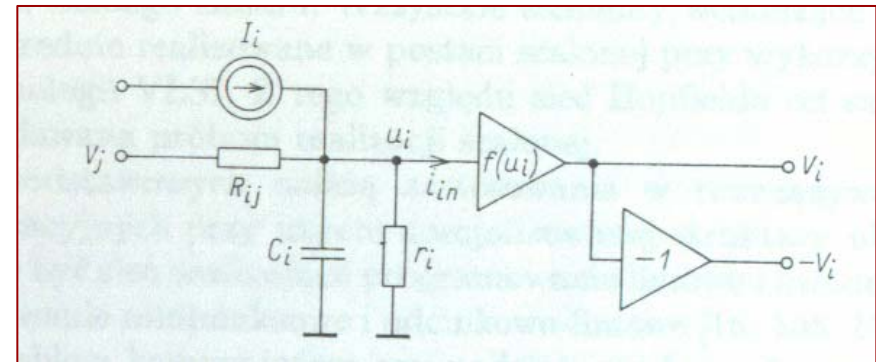
a  $b_i$  jest pewną wartością progową.

Dobieramy rezystancję  $r_i$  małą w porównaniu z pozostałymi  $R_{ij}$ .

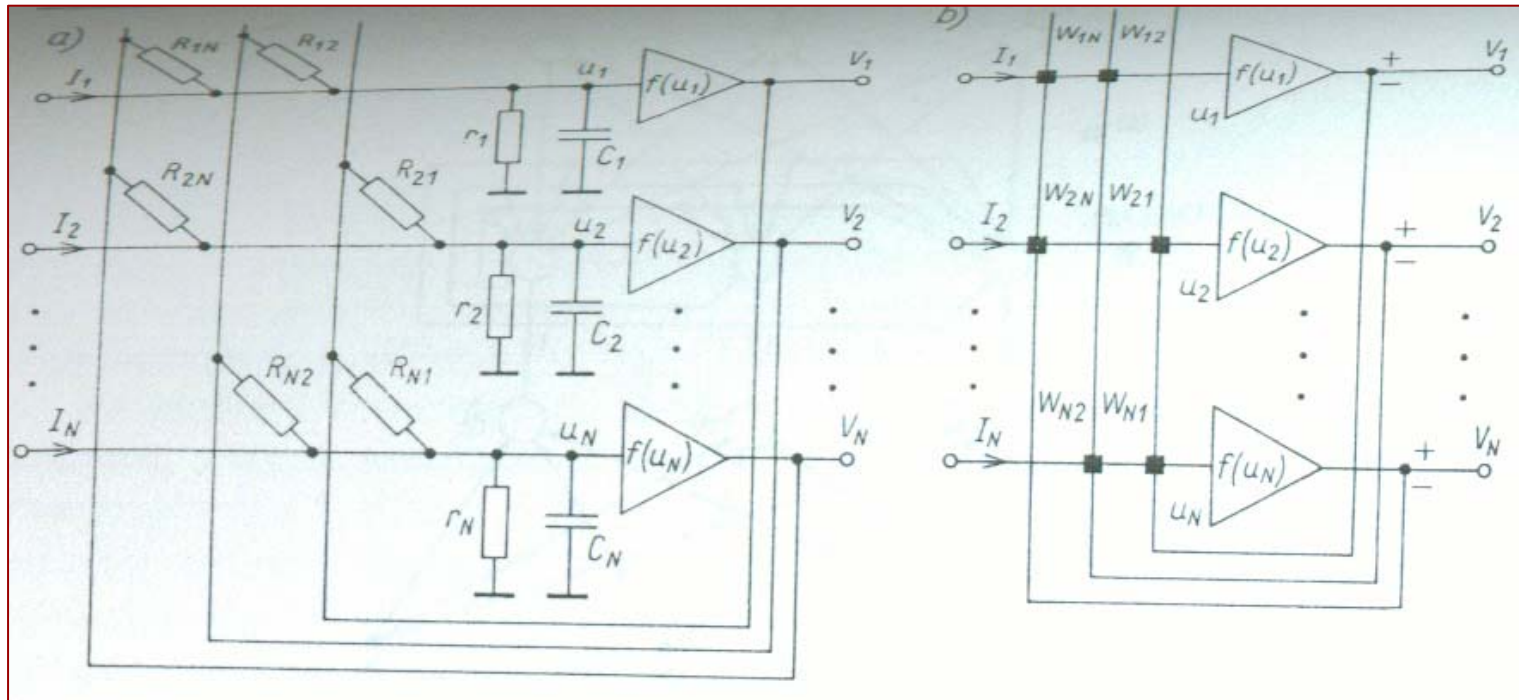
Wówczas  $\tau_i \cong r_i C_i$

$$W_{ij} \cong r_i / R_{ij}$$

$$b_i \cong r_i I_i$$



# Implementacja sprzętowa sieci Hopfielda



*Schemat układu* zaproponowany przez Hopfielda nie jest jedyną możliwą realizacją. Niezależnie od technologii implementacji, sieci Hopfielda charakteryzują się budową modułową o powtarzalnej strukturze każdego kanału.



# Zastosowania sieci Hopfielda

---

Do podstawowych należą zastosowania w rozwiązywaniu zagadnień optymalizacyjnych przy użyciu specjalizowanej struktury układu.

Przykładem może być *siec realizująca programowanie liniowe i kwadratowe, programowanie minimaksowe i odcinkowo-liniowe*. Sieć rozwiązująca *problem komiwojażera*, lub *podziału grafu na 2 części* zapewniające minimalną liczbę połączeń między obu częściami.

Drugą rodzinę zastosowań stanowi przetwarzanie sygnałów przy użyciu *struktury Hopfielda*. W tej grupie można wyróżnić *przekształcenie Fouriera* czy *przetwarzanie i dekompozycję sygnałów*.

# Zastosowania sieci Hopfielda

---

Wspólną cechą wszystkich układów opartych na sieci Hopfielda jest *duża szybkość działania*. Dobierając stałą czasową integratorów  $\tau_i$  w zakresie nanosekund można uzyskać rozwiązanie określonego problemu w czasie o rząd lub najwyżej dwa rzędy wielkości dłuższym niż stała czasowa integratora, co odpowiada czasowi mikrosekund. Mówi się wówczas, że układ działa w czasie rzeczywistym.

Problemem który należy rozwiązać korzystając z implementacji sprzętowej sieci Hopfielda, jest stosunkowo skomplikowana metoda projektowania.

W zastosowaniach praktycznych przy określaniu optymalnych wag sieci korzysta się z *metody obliczeniowej* opartej na pojęciu *funkcji energetycznej Lapunowa*.

# Metoda projektowania sieci Hopfielda

---

Dla konkretnego problemu definiuje się funkcję celu wyrażoną jako funkcje wag sieci Hopfielda. Przez porównanie jej do ogólnej postaci funkcji energetycznej uzyskuje się układ równań umożliwiający określenie wartości dobieranych wag.

*Wagi połączeń międzyneuronowych są więc obliczane*, a nie uzyskiwane w wyniku klasycznego uczenia sieci. Sieć Hopfielda spełniająca określoną funkcję ma wagi stałe nie podlegające uczeniu. W tym sensie każda sieć jest specjalizowana do wykonania określonego zadania.

Zmiana warunków zadania wymaga ponownego przeprojektowania sieci, a nie douczenia, jak w przypadku sieci jednokierunkowych. Zmienia się przy tym zwykle struktura połączeń międzyneuronowych.

# Metoda projektowania sieci Hopfielda

---

Dobierane wagi sieci stanowią *pamięć długoterminową*. Podanie warunków niezerowych na sieć powoduje uruchomienie procesu rekurencyjnego prowadzącego do jednego z minimów lokalnych, jakim odpowiadają zakodowane wagi sieci. *Stan stabilny neuronów* stanowi tak zwaną *pamięć krótkoterminową*.

Niestety, oprócz minimów lokalnych właściwych powstają również *minima pasożytnicze*, w których może utknąć aktualny punkt pracy, generując niewłaściwe rozwiązanie.

*Przeciwdziałanie niepożądanym punktom równowagi* odbywa się na etapie projektowania, przez uwzględnienie ich wpływu drogą odpowiedniej modyfikacji funkcji energetycznej lub stworzenia bardziej rozbudowanego układu logicznego współpracującego z siecią Hopfielda.

# Przykład: konwerter

---

Przykład realizacji przetwornika analogowo-cyfrowego (Tanka, Hopfield, 1986).

⇒ Role neuronów w opisywanym systemie odgrywały wzmacniacze operacyjne połączone w ten sposób, że wyjście każdego z nich było podawane na wejścia wszystkich pozostałych przez regulowane rezystory pełniące funkcje współczynników wagowych (elektrycznym analogonem wartości wagi jest przewodność określonego rezystora wejściowego).

⇒ Zapis  $\omega_i^{(j)}$  jest rozumiany jako waga i-tego wejścia w neuronie o numerze  $j$ . Wzmacniacze posiadają wejścia odwracające fazę i wejścia proste – możliwe jest realizowanie zarówno wartości  $\omega_i^{(j)} > 0$  i  $\omega_i^{(j)} < 0$ .

⇒ Dla zapewnienia stabilności działania sieci wykluczono połączenia łączące wyjście danego neuronu z jego wejściem ( $\omega_i^{(i)} = 0$ ) oraz zapewniono symetrie sieci ( $\omega_i^{(j)} = \omega_j^{(i)}$ ).

# Przykład: konwerter

Na wejścia wszystkich elementów sieci podawany jest ten sam sygnał wejściowy  $X$  przez rezystory odpowiadające wadze  $\omega_x^{(j)}$ . Zadaniem sieci jest wytworzenie na wyjściach  $y^{(j)}$  wszystkich neuronów ( $j=1,2,\dots,k$ ) sygnałów  $y^{(j)}$  odpowiadających binarnemu  $k$ -bitowemu kodowi sygnalizującemu analogową wartość  $X$ .

⇒ Sygnały  $y^{(j)}$  powinny być przy tym binarne (czyli 0 lub 1), a wartości liczby dwójkowej reprezentowanej przez wartości  $y^{(j)}$  (wynosząca  $\sum_{j=0}^{k-1} 2^j y^{(j)}$ ) powinna być jak najbliższa wartości  $X$ .

W takiej sieci poprawna praca systemu jest zapewniona, jeśli dokonana jest minimalizacja *funkcji "energii"* o postaci

$$E^{(j)} = (-1/2) ( X - \sum 2^j y^{(j)} )^2 + \sum ( 2^{2j-1} ) [ y_i^{(j)} (1- y_i^{(j)}) ]$$

Działanie sieci polega na minimalizowaniu funkcji energii.

# Przykład: konwerter

Działanie sieci polega na minimalizowaniu funkcji “energii” o postaci

$$E^{(j)} = (-1/2) \left( X - \sum_{j=0}^{k-1} 2^j y^{(j)} \right)^2 + \sum_{j=0}^{k-1} \left( 2^{2j-1} \right) [ y_i^{(j)} (1 - y_i^{(j)}) ]$$

→ Pierwszy składnik wzoru może być traktowany jako suma kwadratów błędów popełnianych przez sieć.

→ Drugi składnik osiąga małą wartość dla  $y_i^{(j)} = 0,1$  przy innych  $y_i^{(j)}$  wartościach składnika wzrasta stanowiąc swoistego rodzaju “karę” za niewłaściwe wartości wyjść.

Minimalizacja wskazanej funkcji energii sprawia, że na wyjściach pojawiają się wartości zbliżone do wartości binarnych, kodujące zgodnie z arytmetyką dwójkową wartości wejściowego sygnału X.

Współczynniki wagowe w podanym wzorze to  $\omega_i^{(j)} = -2^{(i+j)}$ ,  $\omega_x^{(j)} = 2^j$ .

Takie sieci realizowano i pracowały efektywnie, choć przetwornik A/C można też zbudować znacznie prościej bez wykorzystania sieci.

# Przykład: problem komiwojażera

---

Podobny przykład – efektywnego zastosowania sieci do rozwiązania zadania możliwego do rozwiązania też innymi metodami, to słynna praca Van den Bouta i Milera (1988), pokazująca zastosowanie sieci Hopfielda do rozwiązania klasycznego problemu optymalizacyjnego, tak zwanego *“problemu komiwojażera”* zwanego TSP (*Traveling Salesman Problem*).

## Problem:

ustalenie optymalnej trasy objazdu miast przez wędrownego sprzedawcę, który musi być we wszystkich miastach przynajmniej raz i chce jak najmniej wydać na same podróże.

Jako dane przy rozwiązywaniu problemu podane są odległości  $d_{ij}$  pomiędzy wszystkimi miastami, a koszt podróży sprzedawcy jest równy długości sumarycznie przebytej przez niego drogi.



# Przykład: problem komiwojażera

---

Problem ten należy do *zadań NP-zupełnych*, czyli jego rozwiązanie rośnie wykładniczo przy wzroście liczby rozważanych miast  $n$ . Przy  $n$ -miastach możliwe jest zbudowanie  $D=n!/(2n)$  rozróżnialnych tras. ( $n=60$ ,  $D=69,34155 \cdot 10^{78}$ )

Technika rozwiązania tego problemu przy pomocy sieci Hopfielda  
 $\Rightarrow$  *nie jest wolna od wad* – w szczególności przy jego rozwiązywaniu sieć “łatwo” ulega “wciąganiu” w lokalne minima, co prowadzi do rozwiązań suboptymalnych. Zdarza się to stosunkowo rzadko (dane z literatury).  
 *ma oczywiste zalety* – pracując współbieżnie neurony sieci mogą rozwiązać postawiony problem w krótkim czasie mimo jego niewielomianowej złożoności. Wzrost wymiaru problemu będzie wymagał rozbudowy sieci lecz nie będzie powodował znacznego wzrostu czasu obliczeń.

# Przykład: problem komiwojażera

---

*Kluczem do sukcesu* przy stosowaniu sieci neuronowej w *problemie TSP* jest odnalezienie odpowiedniej reprezentacji danych.

W opisanym przez Tanka rozwiązaniu, każde miasto reprezentowane jest za pomocą wiersza zawierającego  $n$  neuronów. W takim wierszu dokładnie jeden neuron może przyjmować wartość “1”, a wszystkie pozostałe mają sygnały wyjściowe wartości “0”. Pozycja (od 1 do  $n$ ) na której występuje neuron sygnalizujący “1” odpowiada kolejności, w jakiej właśnie to miasto ma być odwiedzone przez wędrownego sprzedawcę. Liczba wierszy musi odpowiadać liczbie miast, zatem łączna liczba neuronów jest  $n^2$ .

# Przykład: problem komiwojażera

Każdy neuron w sieci musi być indeksowany dwoma wskaźnikami. Pierwszy z nich dotyczy numeru miasta, a drugi kolejności, w jakiej to miasto powinno być odwiedzane. Tak więc w tej sieci sygnał  $y_{xi}$  oznaczać będzie sygnał wyjściowy z neuronu wchodzącego w skład wiersza odpowiadającego miastu numer  $x$ , przy czym neuron ten odpowiada  $i$ -tej pozycji w tym wierszu, czyli  $y_{xi} = 1$  oznacza, że  $x$ -te miasto należy odwiedzić w  $i$ -tej kolejności. Opisując funkcje “energii” minimalizowanej przez rozważaną sieć trzeba brać pod uwagę cztery jej składniki:

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

$E_1 = 0$  tylko gdy w każdym wierszu jest najwyżej jedna jedynka.  
 $E_1 \neq 0$  to “kara” za niejednoznaczność kolejności odwiedzin.

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

$E_2 = 0$  tylko gdy w każdej kolumnie jest najwyżej jedna jedynka.  
 $E_2 \neq 0$  to “kara” za niejednoznaczność kolejności odwiedzin.

$$E_3 = C/2 \left[ \left( \sum_x \sum_i y_{xi} y_{xj} \right) - n \right]^2$$

$E_3 = 0$  tylko gdy w macierzy jest dokładnie  $n$  jedynek.

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

$E_4$  oznacza długość wybranej drogi  
 (wskaźniki brane modulo  $n$  czyli  $y_{n+j} = y_j$ )

# Przykład: problem komiwojażera

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

$E_1 = 0$  tylko gdy w każdym wierszu jest najwyżej jedna jedynka.  
 $E_1 \neq 0$  to "kara" za niejednoznaczność kolejności odwiedzin.

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

$E_2 = 0$  tylko gdy w każdej kolumnie jest najwyżej jedna jedynka.  
 $E_2 \neq 0$  to "kara" za niejednoznaczność kolejności odwiedzin.

$$E_3 = C/2 \left[ \left( \sum_x \sum_i y_{xi} y_{xj} \right) - n \right]^2$$

$E_3 = 0$  tylko gdy w macierzy jest dokładnie  $n$  jedynek.

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

$E_4$  oznacza długość wybranej drogi  
 (wskaźniki brane **modulo**  $n$  czyli  $y_{n+j} = y_j$ )

Współczynniki  $A, B, C, D$  są wybierane arbitralnie i oznaczają względne wagi poszczególnych warunków.

→ Duże wartości  $A, B, C$  oznaczają silne związanie poszukiwanych rozwiązań z warunkami zadania

→ Duże wartości  $D$  oznaczają silne związanie rozwiązania z optymalizowana funkcja celu

(minimalizacja kosztów podróży).

# Przykład: problem komiwojażera

W rozważanej sieci współczynniki wagowe określające parametry połączeń pomiędzy **i-tym** neuronem **x-tej** warstwy, a **j-tym** neuronem **z-tej** warstwy wyrażają się wzorem:

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

gdzie  $\delta_{ij}$  oznacza funkcje Kronekera ( $\delta_{ij} = 1$  dla  $i=j$  oraz  $0$  w pozostałych przypadkach).

Dodatkowym elementem parametryzującym sieć jest zestaw wyrazów wolnych (od progów pobudzenia), których wartości dla wszystkich elementów sieci są identyczne i wynoszą:

$$\omega_{xz}^0 = C n$$

Również istotny jest wybór wartości  $d_{xz}$  (optymalne wyniki dla  $d_{xz} = 0.375$ ).

# Przykład: problem komiwojażera

W cytowanych już pracach Tanka i Hopfielda stosowano nieliniową funkcję opisującą neurony  $y_{xz} = \phi(e_{xz})$  w postaci

$$y_{xz} = \frac{1}{2} [ 1 + \tanh(e_{xz}/e_0) ]$$

Charakterystyka ta zależy od parametru  $e_0$ , który reguluje jej kształt:

→ przyjęcie zbyt dużej wartości  $e_0$  prowadzi do ustalanie się w sieci stanów końcowych, którym odpowiadają wartości  $y_{xz}$  nie będące wartościami bliskimi 0 albo 1, a więc rozwiązania są niejednoznaczne.

→ przyjęcie zbyt małej wartości  $e_0$  utrudnia znalezienie optymalnego rozwiązania.

W oryginalnej pracy, Hopfield stosował  $e_0 = 0.2$ .

# Przykład: problem komiwojażera

Dynamika sieci rozwiązującej *zadanie TSP* może być opisana układem równań różniczkowych,

$$de_{xi}/dt = -e_{xi}/\tau - A \sum_{i \neq j} y_{xj} - B \sum_{z \neq x} y_{zi} - C \left[ \left( \sum_x \sum_j y_{xj} \right) - n \right]^2 - D \sum_{z \neq x} d_{xz} (y_{z,i+1} + y_{z,i-1})$$

opisujących zachodzące w czasie zmiany sygnałów wyjściowych  $y_{xi}$  wszystkich neuronów sieci oraz ich sumarycznych pobudzeń  $e_{xi}$ , oraz równań algebraicznych ustalających wartości sygnałów wyjściowych. Na wyniki uzyskiwane przy rozwiązywaniu problemu komiwojażera duży wpływ mogą mieć warunki początkowe, przyjmowane dla neuronów sieci przy jej startowaniu.

# Przykład: problem komiwojażera

---

Faktycznie, niestety nigdy nie udało się odtworzyć oryginalnych wyników publikowanych przez Hopfielda i Tanaka.

Dopiero istotne modyfikacje pomysłu wprowadzone przez Aiyer, Niranjani i Fallside (1990) umożliwiły eksperymentalne obserwacje dobrego działania “*sieci Hopfielda*” dla *problemu TSP*.

*(patrz następne wykłady)*



## Zestaw pytań do testu

---

1. Czy sieć Hopfielda ma sprzężenie zwrotne?
2. Czy w sieci Hopfielda można określić warstwy, jeżeli nie to dlaczego?
3. Czy sieć Hopfielda ma jakiś związek z maszyną Boltzmanną? Na czym polega to skojarzenie?
4. Na czym polega zdolność do pamięci krótkoterminowej i długoterminowej w sieciach Hopfielda?
5. Czy wagi sieci Hopfielda ulegają zmianie w procesie uczenia?
6. Co to znaczy że sieć Hopfielda osiąga stan równowagi?