

2. prednáška

Logické neuróny a neurónové siete


Mozog a neurónové siete

- *Metafora ľudského mozgu* hrá dôležitú úlohu v modernej informatike. Pomocou tejto metafory boli navrhnuté nové paralelné prístupy k spracovaniu informácie, ktoré sa zásadným spôsobom odlišujú od klasickej sekvenčnej architektúry počítačov podľa von Neumanna.
- Tento nový prístup k spracovaniu informácie je reprezentovaný *teóriou umelých neurónových sietí*, ktorá v súčasnosti tvorí nielen efektívny informatický nástroj na tvorbu a návrh nových paralelných prístupov k riešeniu problémov umelej inteligencie, ale už je aj *integrálnou súčasťou modernej neurovedy*, pomocou ktorej sa prístupuje k počítačovým simuláciám procesov prebiehajúcich v mozgu.


Neurónové siete sú založené na základnom postuláte neurovedy, podľa ktorého základným stavebným kameňom ľudskeho mozgu je neurón, ktorý má tieto tri najdôležitejšie vlastnosti:

- (1) neurón má orgán, pomocou ktorého **prijíma signály** z okolia od ostatných neurónov (dendrity),
- (2) neurón **spracováva** (*integruje*) prijaté signály,
- (3) neurón má orgán (axón) pomocou ktorého **posiela spracované vstupné signály iným neurónom zo svojho okolia**.

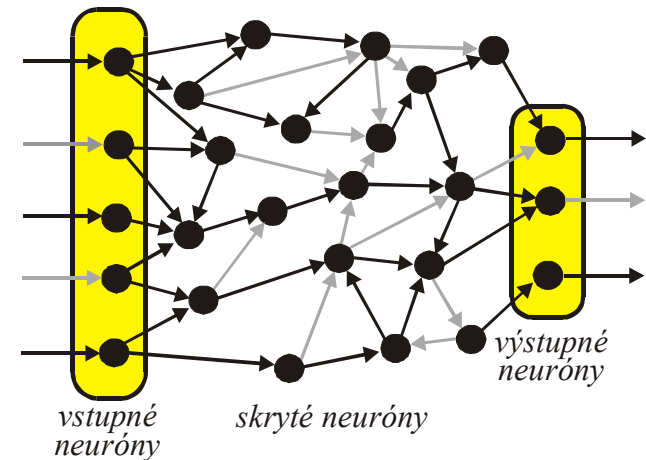
Neuróny sú poprepájané medzi sebou do zložitej sieťovej štruktúry (nazývanej neurónová sieť), pričom jednotlivé **spoje majú buď excitačný alebo inhibičný charakter**. Systém spojov a ich excitačný resp. inhibičný charakter tvoria **architektúru neurónovej siete**, ktorá jediná určuje vlastnosti neurónovej siete.



A



B



C

(A) Typická neurónová bunka, ktorá obsahuje rozsiahly dendritický systém (vstup) a dlhý vetviaci sa axón (výstup).

(B) Vzájomné prepojenie neurónov pomocou spojov medzi dendritmi a axónmi, ktoré je pozorované v mikroanatómii ľudského mozgu.


(C) Architektúra neurónovej siete s dvoma druhmi spojov medzi neurónmi, tmavé (svetlé) spoje znázorňujú exitačné (inhibičné) spoje.

Logické neuróny a teória neurónových sietí

- Budeme študovať najjednoduchší typ neurónových sietí, ktoré boli navrhnuté už pred viac ako polstoročím **McCullochom a Pittsom** v r. 1943. Ich model neurónovej siete je významný medzník v rozvoji teórie neurónových sietí.
- Elementárnou jednotkou McCullochovej a Pittsovej neurónovej siete je **logický neurón** (výpočtová jednotka), pričom stav neurónu je binárny (tj. má dva možné stavy, 1 a 0).
- Dendritický systém logického neurónu obsahuje tak *excitačné vstupy* (opísané binárnymi premennými x_1, x_2, \dots, x_n , ktoré zosilňujú odozvu), ako aj *inhibičné vstupy* (opísané binárnymi premennými $x_{n+1}, x_{n+2}, \dots, x_m$, ktoré zoslabujú odozvu).


Základné skutočnosti z neurovedy

Podrobná schéma neurónu



obrázok je prevzatý z
<http://www.pfizer.com/brain/image>

Budeme študovať jeden z najjednoduchších modelov neurónov, ktorý v r. 1943 navrhli McCulloch a Pitts. Ich jednoduchý model logického neurónu je v súčasnosti pokladaný za významný medzník v rozvoji umelej inteligencie (menovite teórie umelých neurónových sietí).



Warren McCulloch (1898-1972)




Walter Pitts (1923-196?)

Neurónové siete sú založené na postuláte neurovedy hovoriacom, že základným stavebným kameňom ľudskeho mozgu je *neurón*, ktorý má tieto tri najdôležitejšie vlastnosti:

- neurón má orgán, pomocou ktorého *prijíma signály* z okolia od ostatných neurónov (dendrity),
- neurón *spracováva (integruje)* prijaté signály,
- neurón má orgán (axón) pomocou ktorého *posiela spracované vstupné signály iným neurónom zo svojho okolia*.

Logický neurón McCullocha a Pittsa




Logický neurón je založený na pravidle:

aktivita je jednotková, ak *vnútorný potenciál* neurónu definovaný ako rozdiel medzi sumou excitačných vstupných aktivít a inhibičných vstupných aktivít je väčší alebo rovný prahu ϑ , v opačnom prípade je nulová

$$y = \begin{cases} 1 & (\xi = x_1 + \dots + x_n - x_{1+n} - \dots - x_m \geq \vartheta) \\ 0 & (\xi < \vartheta) \end{cases}$$

Použitím jednoduchej „schodovej“ funkcie

$$s(\xi) = \begin{cases} 1 & (\text{ak } \xi \geq 0) \\ 0 & (\text{ak } \xi < 0) \end{cases}$$



$$y = s\left(\underbrace{x_1 + \dots + x_n - x_{1+n} - \dots - x_m}_{\xi} - \vartheta\right)$$


Aktivita logického neurónu môže byť alternatívne vyjadrená pomocou binárnych váhových koeficientov

$$y = s\left(\underbrace{w_1 x_1 + \dots + w_m x_m}_{\xi} - \vartheta\right) = s\left(\sum_{i=1}^m w_i x_i - \vartheta\right)$$

Implementácia Boolovej binárnej funkcie OR

$$y_{OR}(x_1, x_2) = s(x_1 + x_2 - 1)$$

#	x_1	x_2	$y_{OR}(x_1, x_2)$	$x_1 \vee x_2$
1	0	0	$s(-1)$	0
2	0	1	$s(0)$	1
3	1	0	$s(0)$	1
4	1	1	$s(1)$	1




Boolova funkcia disjunkcie
 $y = x_1 \vee \dots \vee x_n$

Implementácia Boolovej binárnej funkcie AND

$$y_{AND}(x_1, x_2) = s(x_1 + x_2 - 2)$$

#	x_1	x_2	$y_{AND}(x_1, x_2)$	$x_1 \wedge x_2$
1	0	0	$s(-2)$	0
2	0	1	$s(-1)$	0
3	1	0	$s(-1)$	0
4	1	1	$s(0)$	1




Boolova funkcia konjunkcie

$$y = x_1 \wedge \dots \wedge x_n$$

Implementácia Boolovej binárnej funkcie IF-THEN

$$y_{AND}(x_1, x_2) = s(-x_1 + x_2)$$

#	x_1	x_2	$y_{IF-THEN}(x_1, x_2)$	$x_1 \Rightarrow x_2$
1	0	0	$s(0)$	1
2	0	1	$s(1)$	1
3	1	0	$s(-1)$	0
4	1	1	$s(0)$	1




Boolova funkcia implikácie

$$y = x_1 \Rightarrow x_2$$

Implementácia Boolovej inárnej funkcie NOT

$$y_{NOT}(x) = s(-x + 0)$$

#	x	$y_{NOT}(x)$	$\neg x$
1	0	$s(0)$	1
2	1	$s(-1)$	0




Boolova funkcia negácie

$$y = \neg x$$

Veta.

Každá Boolova funkcia môže byť vyjadrená pomocou „neurónovej siete“ zloženej z logických neurónov vyjadrujúcich logické spojky.

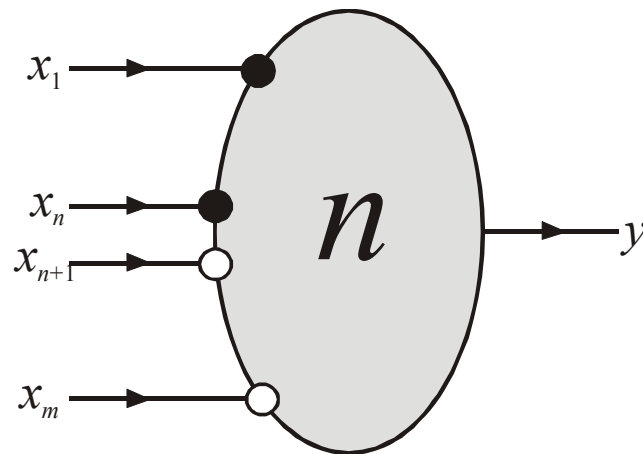
$$\varphi(p, q) = (p \wedge q) \Rightarrow (p \vee q)$$



Implementácia konjunktívnej klauzule

$$x_1 \wedge \dots \wedge x_n \wedge \neg x_{n+1} \wedge \dots \wedge \neg x_m$$

$$val_{\tau}(x_1 \wedge \dots \wedge x_n \wedge \neg x_{n+1} \wedge \dots \wedge \neg x_m) = \begin{cases} 1 & (x_1 = \dots = x_n = 1 \text{ a } x_{n+1} = \dots = x_m = 0) \\ 0 & (\text{ináč}) \end{cases}$$




$$y = s(x_1 + \dots + x_n - x_{n+1} - \dots - x_m - n)$$

Lineárna separovateľnosť

Geometrická interpretácia výpočtu prebiehajúceho v logickom neuróne:

$$w_1x_1 + w_2x_2 + \dots + w_nx_n - \vartheta = 0$$

Táto rovina rozdeľuje stavový priestor na dva polopriestory.



Definícia.

Boolova funkcia $f(x_1, x_2, \dots, x_n)$ je *lineárne separovateľná*, ak existuje taká rovina $w_1x_1 + w_2x_2 + \dots + w_nx_n - \vartheta = 0$, ktorá separuje priestor vstupných aktivít tak, že v jednej časti priestoru sú vrcholy ohodnotené 0, zatiaľ čo v druhej časti priestoru sú vrcholy ohodnotené 1.


Veta.

Logický neurón je schopný simulovať len tie Boolove funkcie, ktoré sú lineárne separovateľné.

Boolovej funkcie XOR nie je lineárne separovateľná

$$\varphi_{XOR}(x, y) = x \oplus y$$

#	x	y	$\varphi_{XOR}(x, y)$
1	0	0	0
2	0	1	1
3	1	0	1
4	1	1	0



V teórii Boolovych funkcií sa dokazuje veta, že každá výroková formula môže byť prepísaná do ekvivalentného disjunktívneho tvaru

$$\varphi = \bigvee_{\substack{\tau \\ (val_{\tau}(\varphi)=1)}} x_1^{(\tau)} \wedge x_2^{(\tau)} \wedge \dots \wedge x_n^{(\tau)}$$

kde

$$x_i^{(\tau)} = \begin{cases} x_i & (\text{ak } val_{\tau}(x_i) = 1) \\ \neg x_i & (\text{ak } val_{\tau}(x_i) = 0) \end{cases}$$

Ilustračný príklad

#	x_1	x_2	x_3	$y = f(x_1, x_2, x_3)$	<i>konjunktívna klauzula</i>
1	0	0	0	0	
2	0	0	1	0	
3	0	1	0	1	$\bar{x}_1 \wedge x_2 \wedge \bar{x}_3$
4	0	1	1	1	$\bar{x}_1 \wedge x_2 \wedge x_3$
5	1	0	0	0	
6	1	0	1	1	$x_1 \wedge \bar{x}_2 \wedge x_3$
7	1	1	0	0	
8	1	1	1	0	

$$y = f(x_1, x_2, x_3) = (\bar{x}_1 \wedge x_2 \wedge \bar{x}_3) \vee (\bar{x}_1 \wedge x_2 \wedge x_3) \vee (x_1 \wedge \bar{x}_2 \wedge x_3)$$


Táto Boolova funkcia môže byť zjednodušená tak, že prvá a druhá klauzula sa zjednodušia

$$(\bar{x}_1 \wedge x_2 \wedge \bar{x}_3) \vee (\bar{x}_1 \wedge x_2 \wedge x_3) = \bar{x}_1 \wedge x_2 \wedge \underbrace{(\bar{x}_3 \vee x_3)}_1 = \bar{x}_1 \wedge x_2$$


Potom

$$y = f(x_1, x_2, x_3) = (\bar{x}_1 \wedge x_2) \vee (x_1 \wedge \bar{x}_2 \wedge x_3)$$


Konjunktívne klauzule $x_1^{(\tau)} \wedge x_2^{(\tau)} \wedge \dots \wedge x_n^{(\tau)}$ môžeme vyjadriť jedným logickým neurónom




Výstupy z týchto neurónov spojíme do disjunkcie pomocou neurónu




Trojvrstvová neurónová sieť



Ilustračný príklad – konštrukcia XOR funkcie



$$\varphi_{XOR}(x_1, x_2) = (\neg x_1 \wedge x_2) \vee (x_1 \wedge \neg x_2)$$



Veta.

Ľubovoľná Boolova funkcia f je simulovaná pomocou 3-vrstvovej neurónovej siete.


Komentár.

3-vrstvové neurónové siete obsahujúce logické neuróny sú univerzálne výpočtové zariadenia pre doménu Boolových funkcií.

Príklad

$$\frac{\alpha_1 \quad \alpha_2}{\beta_1 \beta_2}$$

$$\beta_1 = \alpha_1 \wedge \alpha_2$$
$$\beta_2 = \alpha_1 \oplus \alpha_2 = (\neg \alpha_1 \wedge \alpha_2) \vee (\alpha_1 \wedge \neg \alpha_2)$$



Logické neuróny vyšších rádov

Ak vnútorný potenciál neurónu ξ je určený ako lineárna kombinácia vstupných aktivít (t.j. len prvou sumou), potom logický neurón je štandardný a nazýva sa "*logický neurón prvého rádu*". Ak tento potenciál neurónu ξ obsahuje aj kvadratické a prípadne aj ďalšie členy, potom sa nazýva "*logický neurón vyššieho rádu*".

$$y = s \left(\underbrace{\sum_{i=1}^n w_i x_i + \sum_{\substack{i,j=1 \\ (i < j)}}^n w_{ij} x_i x_j + \dots}_{\xi} - \vartheta \right)$$

Podľa Minského a Paperta (v knihe *Perceptron*) perceptróny vyššieho rádu sú schopné simulovať aj množiny objektov, ktoré nie sú lineárne separovateľné.

Veta.

Ľubovoľná Boolova funkcia f je Boolova funkcia je simulovaná logickým neurónom vyššieho rádu.

Príklad

Boolovu binárnu funkciu *XOR* vyjadríme pomocou logického neurónu druhého rádu

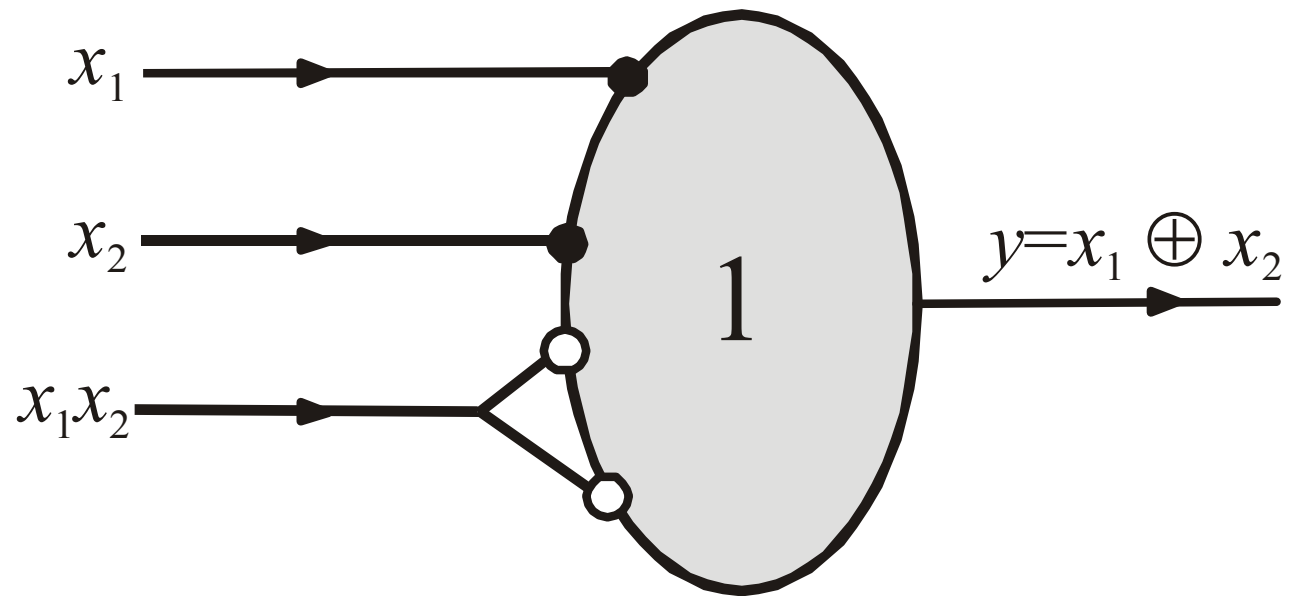
$$y = s \left(\underbrace{w_1 x_1 + w_2 x_2 + w_{12} x_1 x_2}_{\xi} - \vartheta \right)$$

Koeficienty sú určené podmienkami


$$\begin{array}{rcl} & -\vartheta < 0 & (\textit{pre}(0,0)/0) \\ w_2 & -\vartheta \geq 0 & (\textit{pre}(0,1)/1) \\ w_1 & -\vartheta \geq 0 & (\textit{pre}(1,0)/1) \\ w_1 + w_2 + w_{12} - \vartheta & < 0 & (\textit{pre}(1,1)/0) \end{array}$$

Postupným riešením týchto nerovniíc dostaneme, že váhové koeficienty a prah majú napr. takéto riešenie




$$\vartheta = 1, w_1 = w_2 = 1, w_{12} = -2$$



Transformácia logického neurónu 2. rádu na neurónovú sieť obsahujúcu dva logické neuróny prvého rádu



Grafická interpretácia logického neurónu 2. rádu



Definícia.

Boolova funkcia f sa nazýva *kvadraticky separovateľná*, ak existujú také váhové koeficienty w_i , w_{ij} a prahový faktor ϑ , že pre každú špecifikáciu premenných x_1, x_2, \dots, x_n platí

$$y_{req}(x_1, x_2, \dots, x_n) = 1 \Rightarrow \sum_{i=1}^n w_i x_i + \sum_{\substack{i,j=1 \\ (i < j)}}^n w_{ij} x_i x_j \geq \vartheta$$

$$y_{req}(x_1, x_2, \dots, x_n) = 0 \Rightarrow \sum_{i=1}^n w_i x_i + \sum_{\substack{i,j=1 \\ (i < j)}}^n w_{ij} x_i x_j < \vartheta$$

Neurónové siete a vzťah medzi mozgom a mysl'ou

- V informatike (menovite v jej časti nazývanej umelá inteligencia) stojíme pred zložitými otázkami, **čo je ľudská myseľ**, aký je jej vzťah k mozgu, môžeme chápať ľudskú myseľ ako program implementovaný v počítači mozgu, aká je architektúra tohto programu?
- Žiaľ odpovedať na ne nie je vôbec jednoduché, preto v súčasnosti sú stále predmetom záujmu oblasti filozofie nazývanej „**filozofia mysle**“.
- Poskytnúť jednoduchý informatický pohľad na vzťah medzi mysl'ou a mozgom, ktorý je založený na všeobecných predstavách teórie neurónových sietí (nazývanej v kognitívnej vede „**konekcionizmus**“).
- V rámci *konekcionistického prístupu* vzťah medzi mozgom a mysl'ou sa rieši pomocou koncepcií modernej neurovedy a neurónových sietí.

V kognitívnej vede je *je mozog/mysel' charakterizovaný ako počítač*

- (1) ktorý transformuje symboly pomocou syntaktických pravidiel na iné symboly, pričom
- (2) myšlienky sú symbolické reprezentácie implementované pomocou jazyka myslenia, a
- (3) mentálne procesy sú postupnosti symbolov (medzi ktorými sú príčinné vzťahy) generované syntaktickými pravidlami.

- Použitie termínu „počítač“ obvykle evokuje predstavu sekvenčného počítača von neumannovskej architektúry, kde je možné striktné oddeliť hardware od software; kde na tom istom počítači – hardware môže byť vykonávaných nepreberné množstvo naprosto rozdielnych programov – softvérov.
- Pre tieto počítače existuje striktná dichotómia medzi počítačom a programom – t. j. medzi hardvérom a softvérom.

- ✚ Moderný prístup k chápaniu vzťahu medzi mozgom a mysl'ou je založený na konekcionistickom poňatí tak mozgu, ako aj mysle.
- ✚ Základná predstava o mozgu je, že je tvorený z neurónov navzájom poprepájaných pomocou jednosmerných synaptických spojov. Ľudský mozog vykazuje neobyčajnú plasticitu, v priebehu učenia neustále vznikajú (ale taktiež aj zanikajú) synaptické spoje. Architektúra mozgu je určená spojmi medzi neurónmi, ich inhibičným, alebo excitačným charakterom, a taktiež aj ich intenzitou.
- ✚ Možno konštatovať, že *schopnosť mozgu vykonávať nielen kognitívne aktivity, ale byť aj pamäťou, je plne zakódovaná do jeho architektúry.*

■ *Mysel' s mozgom tvoria jeden integrálny celok; myseľ je v tomto prístupe možné chápať ako program vykonávaný mozgom, avšak tento program je špecifikovaný architektúrou distribuovanej neurónovej siete reprezentujúcej mozog.*

■ Program v tomto paralelnom počítači je priamo zabudovaný do architektúry neurónovej siete, t. j. ľudský mozog je jednoúčelový paralelný počítač reprezentovaný neurónovou sieťou, ktorý nie je možné preprogramovať bez zmeny jeho architektúry.

■ Na základe týchto neurovedných poznatkov bazálneho charakteru môžeme konštatovať, že počítačová paradigma ľudského mozgu/mysle sa musí formulovať tak, že mozog je paralelný distribuovaný počítač (obsahujúci mnoho miliárd neurónov, elementárnych procesorov, ktoré sú medzi sebou poprepájané do zložitej neurónovej siete).


Záver

- (1) Každá Boolova funkcia je reprezentovaná *neurónovou sieťou*, ktorej architektúra je určená syntaktickým stromom funkcie. Táto vlastnosť môže byť zosilonená do tvrdenia
- (2) Každá Boolova funkcia je reprezentovaná *3-vrstvovou neurónovou sieťou*.
- (3) Logický neurón klasifikuje len Boolove funkcie, ktoré sú *lineárne separovateľné*.
- (4) Boolove funkcie, ktoré nie sú lineárne separovateľné, ale sú kvadraticky, kubicky, ... separovateľné, sú reprezentované *logickým neurónom 2., 3., ... rádu*.
- (5) Každá Boolova funkcia je reprezentovaná logickým neurónom vyššieho rádu.
- (6) Neurónové siete s logickými neurónmi *nie sú schopné učenia*, ich architektúra a váhové koeficienty spojov sú fixné.

3. Finite state machine



Marvin Minsky



References

- Kleene, S. C.: Representation of events in nerve nets and finite automata. In C. E. Shannon and J. McCarthy, editors, *Automata Studies*. Princeton University Press, Princeton, 1956, pp. 3-41.
- Minsky, M.: Some universal elements for finite automata. In C. E. Shannon and J. McCarthy, editors, *Automata Studies*, Princeton University Press, Princeton, 1956, pp. 117- 128.
- Minsky, M. L.: *Computation. Finite and Infinite Machines*. Prentice-Hall, Englewood Cliffs, NJ, 1967.

Finite state machine works in discrete time events $1, 2, \dots, t, t+1, \dots$. It contains two tapes: of input symbols and of output symbols, whereas new states are determined by input symbols and an actual state of machine.


$$\begin{aligned} state_{t+1} &= f(state_t, input\ symbol_t) \\ output\ symbol_{t+1} &= g(state_t, input\ symbol_t) \end{aligned}$$

where function f and g specified given finite state machine and are understand as its basic specification:

- (1) **transition function** f determines forthcoming state from an actual state and an input symbol,
- (2) **output function** g determines output symbol from an actual state and an input symbol.

Representation of finite state machine as a calculating device

$$o^{(t+1)} = g(s^{(t)}, i^{(t)})$$
$$s^{(t+1)} = f(s^{(t)}, i^{(t)})$$




Theorem 1. Any neural network may be represented by equivalent finite-state machine with output.

Theorem 2. Any finite-state machine with output (Mealy automaton) may be represented by equivalent recurrent neural network.

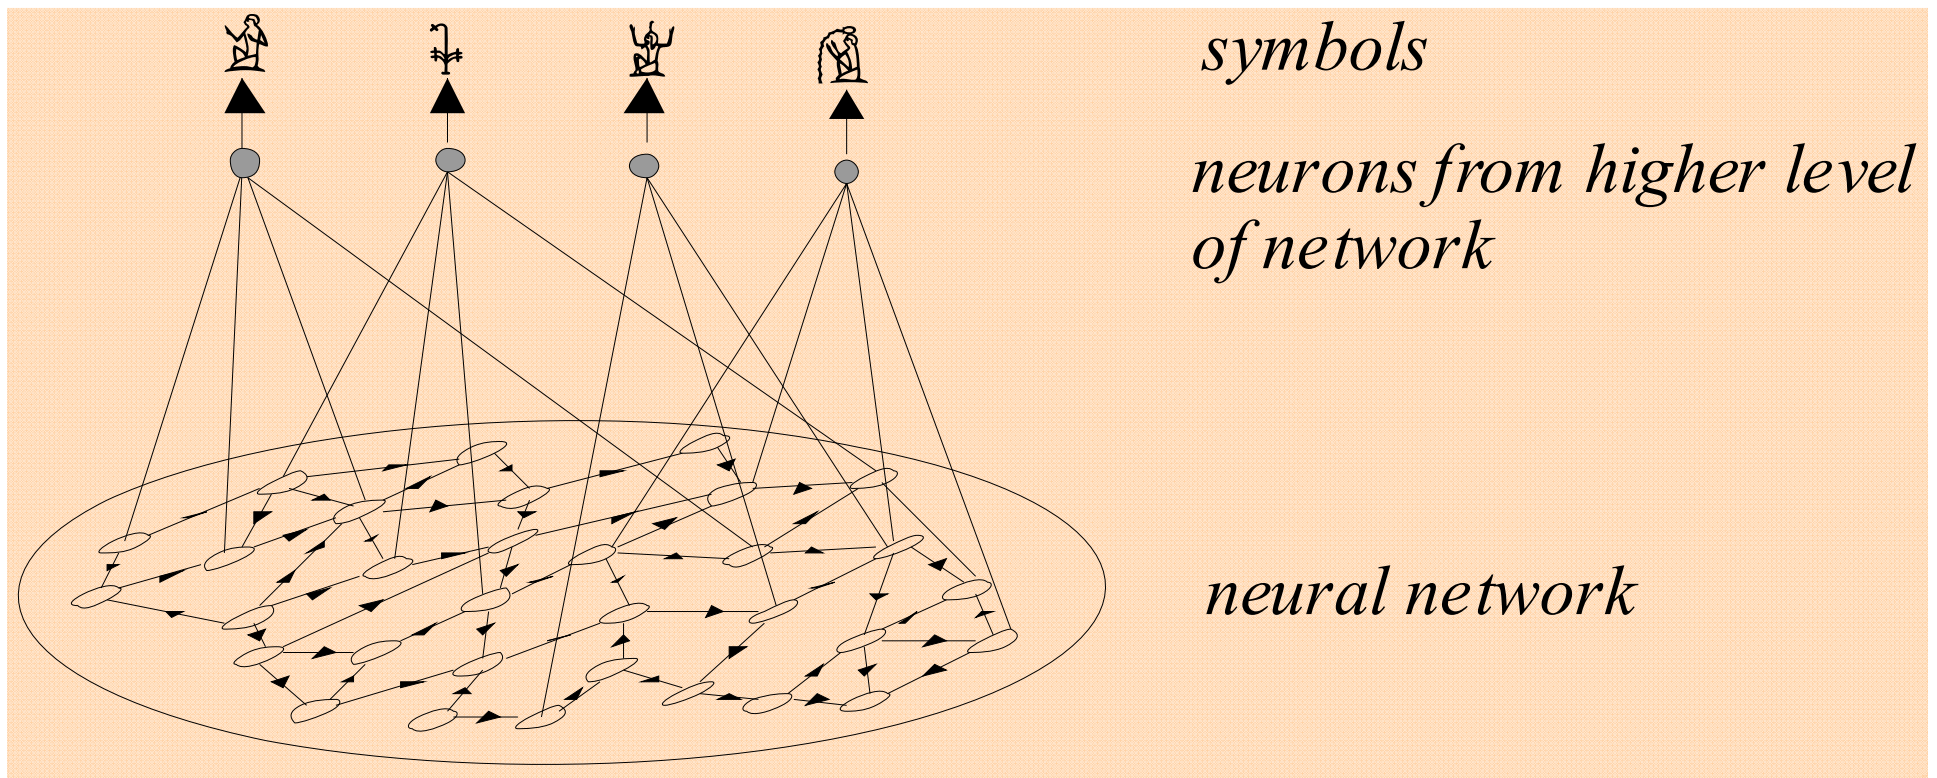
Recurrent neural network, which represents a finite-state machine

Theorems 1 and 2 make possible to study a classical problem of connectionism (neural networks), a relationship between a *subsymbolic representation* (neural, which is represented by patterns composed of neural activities) and a *symbolic representation* (which is used by classical AI):

- (1) According to the Theorem 1, each subsymbolic neural network can be transformed onto symbolic finite-state machine, whereas symbols may be created by making natural numbers that are assigned to binary vectors of activities.
- (2) According to the Theorem 2, each symbolic finite-state machine may be transformed onto an equivalent subsymbolic neural network. Symbols from the representation of finite-state machine are represented by binary vectors.



Above mentioned theory for the transfer from subsymbolic to symbolic representation and conversely may be used for a study of properties of these models and a transfer among them.



Smolensky's idea of hierarchically ordered neural networks, where neurons from the top level of network represent symbols.

Main conclusions from the lecture

- Symbolic vs. subsymbolic (connectionist) representations applied in AI and CogSci *are not contradictory paradigms* that are mutually eliminated, rather they are *complementary dual*.
- Symbols are *grounded* through activity of neurons
- Connectionist solution of mind-body problem, a brain may be interpreted as special *highly-parallel neural computer*, where running program (mind) is wired in via its connectionist structure