



Koneksionismus

PSY 481

Motivace



Zájem o vývoj umělých neuronových sítí pramení z poznání, že lidský mozek pracuje jiným způsobem než běžné číslicové počítače. Počítače přesně a rychle provádějí posloupnosti instrukcí, které pro ně byly formulovány. Lidský mozek je tvořen neurony, které pracují přibližně milionkrát pomaleji než obvody číslicové ho počítače, přesto člověk dokáže lépe řešit řadu výpočetně náročných úkolů (zpracování vizuální informace, porozumění řeči, hraní šachů , a podobně). Proto vzniká snaha napodobit schopnosti mozku a vytvořit umělou neuronovou síť, která by uměla simulovat chování biologické neuronové sítě živých organismů .

Konekcionalismus



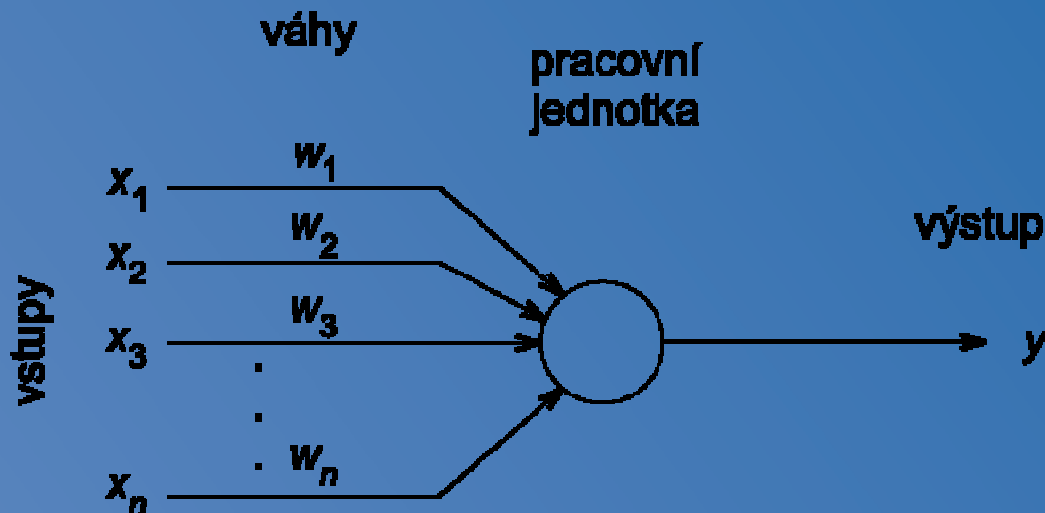
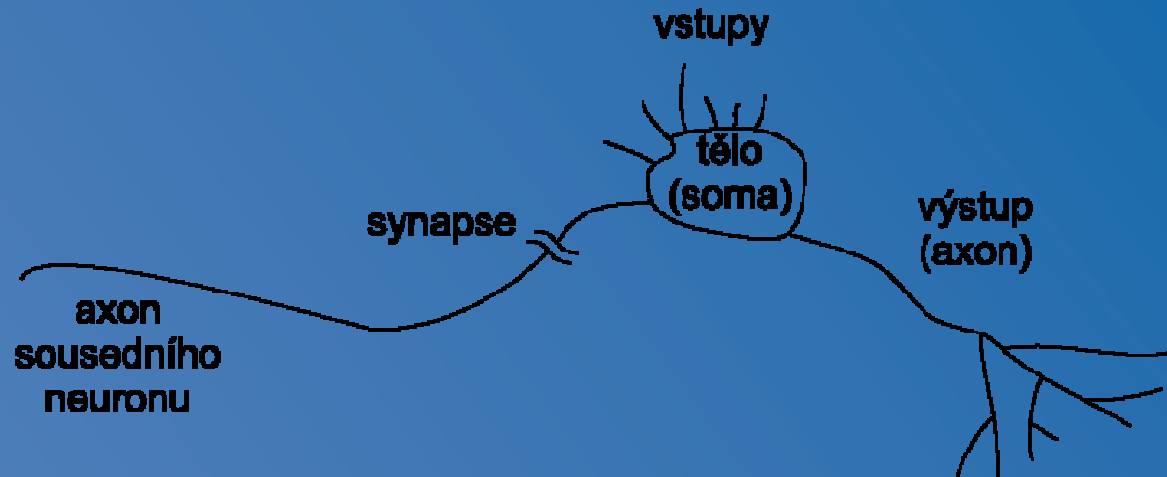
- V 80-tých letech se začíná objevovat nová technika modelování, či přesněji nová architektura.
- Pro svou fundamentální odlišnost od předchozích způsobů se tento přístup stává paradigmatem v oblasti kognitivních věd.
- Přístup se nazývá konekcionalismus a jeho aplikovanou oblastí jsou neuronové sítě, architektura principiálně odlišná od předchozích přístupů.
- Základ tvoří samostatné velmi jednoduché jednotky, jejichž propojení konstituuje síť.
- Výchozí myšlenkou je postulace základní jednotky, funkčně podobné lidskému neuronu.
- Největší rozdíl oproti klasické von neumannovské architektury spočívá v paralelním způsobu práce.

Historie



1943	považován za začátek vývoje umělých neuronových sítí, navržen McCullochův-Pittsův model neuronu
1949	Hebbův zákon učení (1. zákon učení neuronových sítí)
1958	navržen nejznámější model neuronu (perceptron), autorem Frank Rosenblatt
začátek 60. let 20. stol	první model neuronových sítí (lineární sítě), navržena pravidla pro jejich učení
polovina 60. let až polovina 80. let 20. stol.	pokles zájmu o neuronové sítě, někteří nadšenci přesto pokračují ve výzkumu (např. T. Kohonen navrhuje tzv. samoorganizující se sítě a S. Grossberg zákony pro jejich učení)
od poloviny 80. let 20. stol. dosud	období renesance neuronových sítí, objevují se tzv. vícevrstvé nelineární sítě a pravidla pro jejich učení

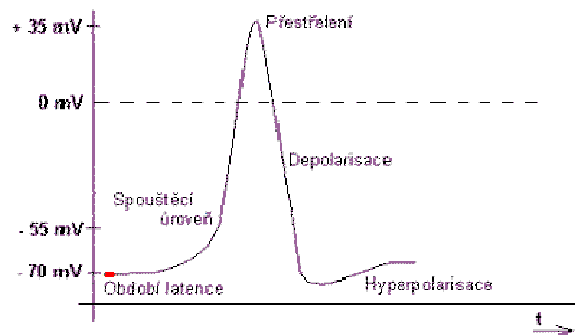
Neuron



Neuron




Průběh akčního potenciálu



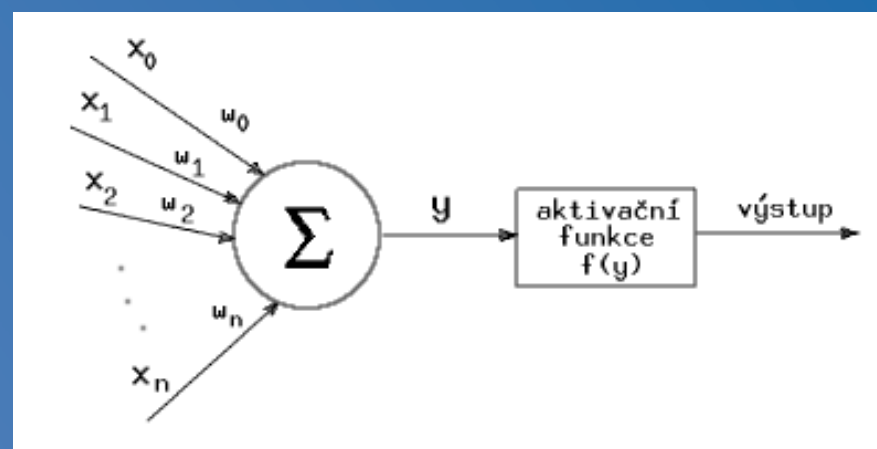
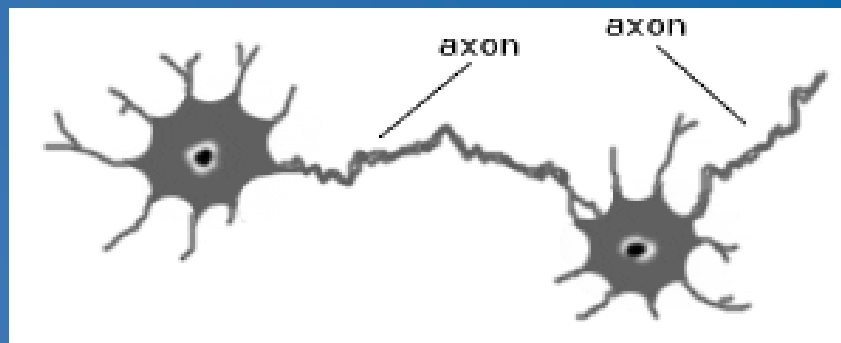

- - K^+
- - Na^+

vně buňky



buněčná membrána

uvnitř buňky



Srovnání





Rozdíly neuronových sítí
a biologických mozku
při simulaci

1. Komplexnost
2. Lidské schopnosti nejsou arbitrární, ale pevně kódované.
3. Není znám přesný způsob excitace či inhibice.
4. Model učení z chyb není použitelný obecně.

(Kosslyn, 1992)

Subsymbolický přístup



Symbolický	Subsymbolický
	
Shora dolů	Zdola nahoru
explicitní	implicitní
pravidla	příklady
sériový	paralelní
Digitální (pravda/ nepravda)	Analogový (fuzzy)
křehký	robustní

Subsymbolický přístup



- Rozdíl mezi symbolickým a subsymbolickým přístupem je podle Smolenského v tom, že kontext symbolu je u symbolického manifestován OKOLO pomocí symbolů, a u subsymbolického UVNITŘ pomocí subsymbolů.
- V některých případech konekcionistický subsymbolický přístup selhává, jelikož nám obraz, nebo jeho části neumožňuje zachytit ty znaky, které jsou nutné pro manipulace s reprezentacemi (káva jako zrnka a následně jako nápoj).

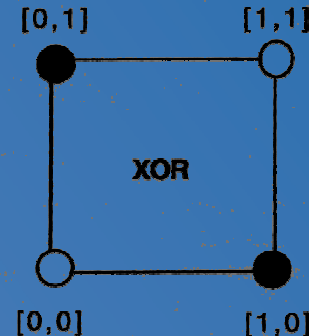
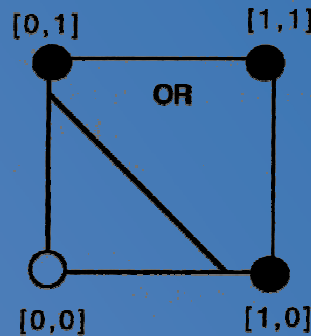
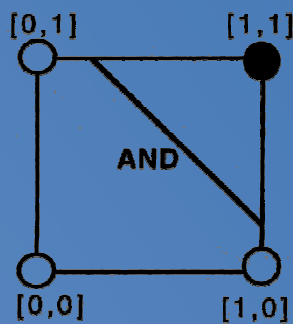
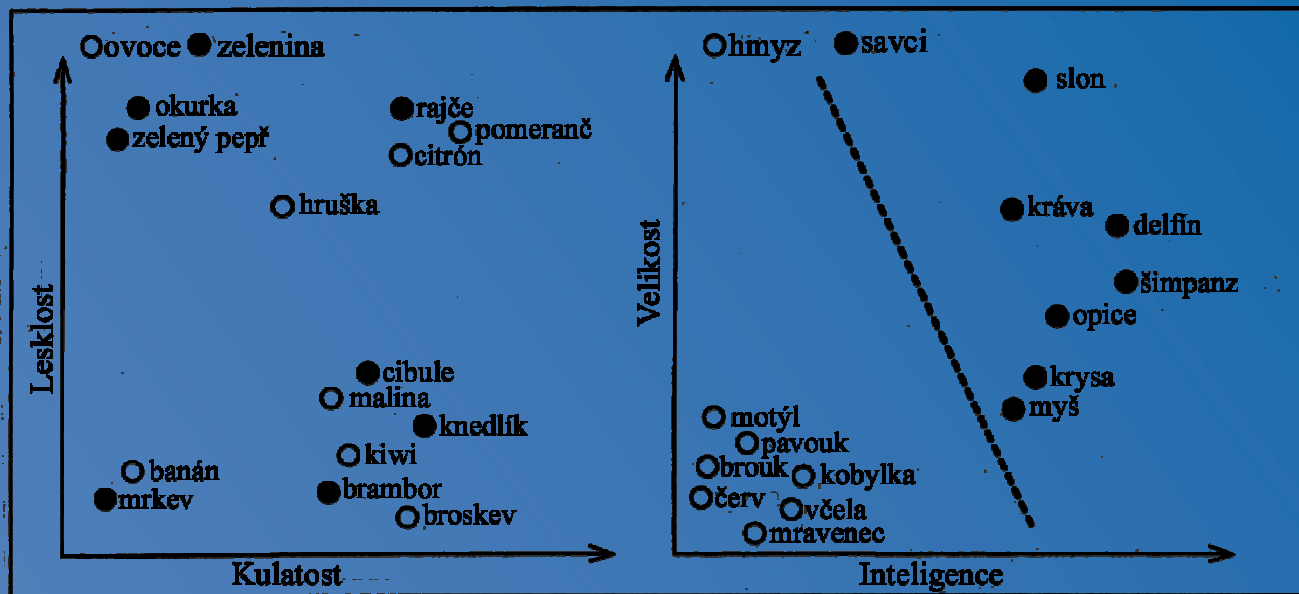


Subsymbolický přístup

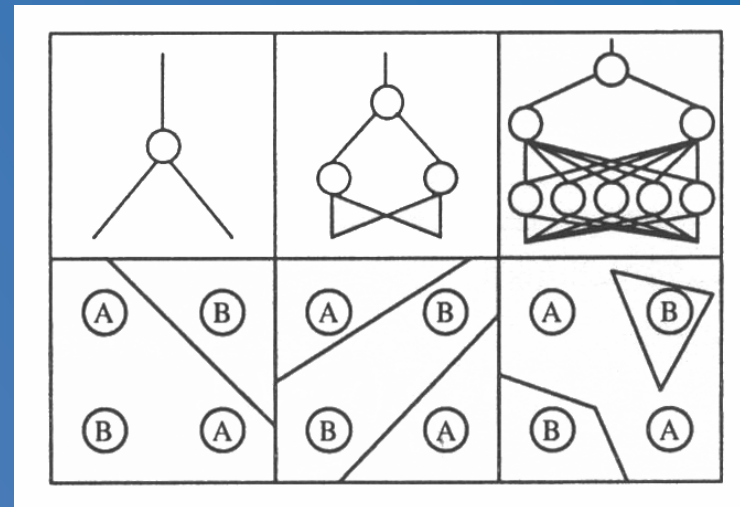


- Problémy s koncepty a kompozicemi, díky tomu, že konekcionismus manipuluje s reprezentacemi které jsou kontextuální.
- Nevýhodou konekcionismu v úrovni kontextu je, že neumožňuje komputaci definovanou nad symboly.
- Smolenský říká, že není taková architektura, která by mohla manipulovat se syntaxem i sémantikou zároveň, pomocí symbolů. Toto musí robíhat ve dvou úrovních (popisu).

Lineární separovatelnost



Lineární separovatelnost



Na konci 80-tých let přichází období stagnace klasického symbolického přístupu v oblasti modelování, hledají se alternativní metody a konekcionismus prožívá svou renesanci. Důležitým je i fakt, že Minský opravil svá tvrzení o omezenosti neuronových sítí jako architektury vhodné pro simulaci (funkce XOR je řešitelná neuronovou sítí za použití více vrstev).

Charakteristika neuron. sítí



1. Jsou tvořeny velkým počtem jednoduchých procesních jednotek, komunikujících přes množinu propojení, které mají různou váhu a sílu.
2. Paměť je reprezentována jako vzorec hodnot vah, mající propojení mezi jednotlivými prvky. Informace je zpracovávána jako šíření se měnících se vzorců aktivity mezi prvky.
3. Sítě jsou spíše učeny a trénovány než programovány.
4. Místo oddělené paměti, procesoru a externímu programu, který řídí operace systému jako u digitálního počítače, operace neuronových sítí jsou implicitně kontrolovány třemi vlastnostmi: kombinační funkcí neuronu, způsobem propojení a učícím pravidlem

Charakteristika neuron. sítí



6. Neuronové sítě jsou schopny generalizace; mohou se naučit charakteristiky obecné kategorie.
7. Jsou odolné proti chybám. Díky paralelní distribuované formě uložení paměti „degradují s grácií“
8. Neuronové sítě mají schopnost sebeorganizace. Dokáží reagovat na vstupy z prostředí změnou své funkční dynamiky
9. Neuronové sítě jsou schopné emergence nových vlastností či chování.

Emergence

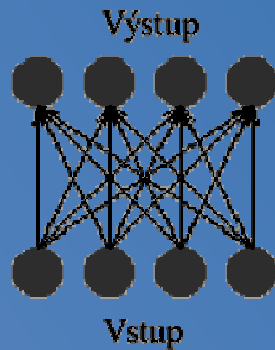


Hlavním důvodem pro vznik emergentního chování je redundance v propojení. Klasická sériová architektura obsahuje pouze propojení, která jsou nutná mezi jednotlivými jednotkami. I proces zpracování informace v takovém systému je pevně zakotven designérem systému .

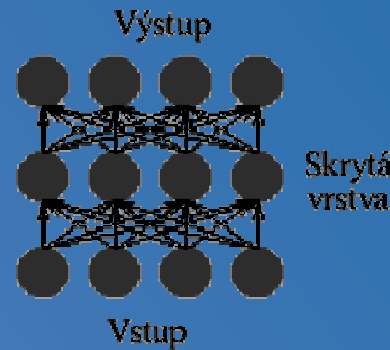
Naopak neuronové sítě jsou typ architektury, která je hned v počátcích připravená na více způsobů implementace úlohy. Pokud je jeden neuron propojen se všemi neurony vedlejší vrstvy a pro učení jsou používány jen některá propojení pro funkci systému, v klasické von neumannovské architektuře by to vedlo k odstranění těch spojení, která nejsou používána.

Rozdíl ve způsobu propojení komponent je, že pokud se objeví nový stimul, který má neuronová síť zpracovat, mohou být používány spojení, které byly v předchozím případě nevyužita. Což nás vede k závěru, že redundance je nutnou podmínkou emergence.

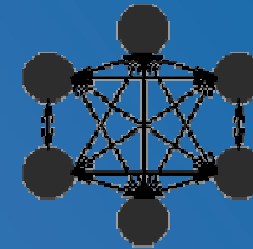
Základní typy neuron. sítí



Jednovrstvé dopředné síť

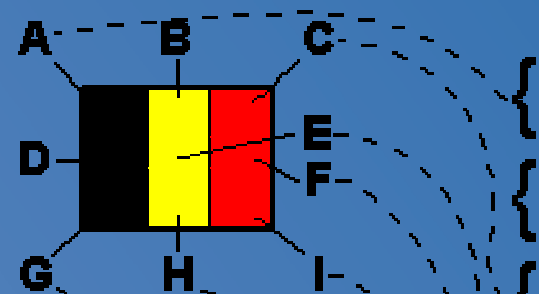


Mnohovrstvé dopředné síť



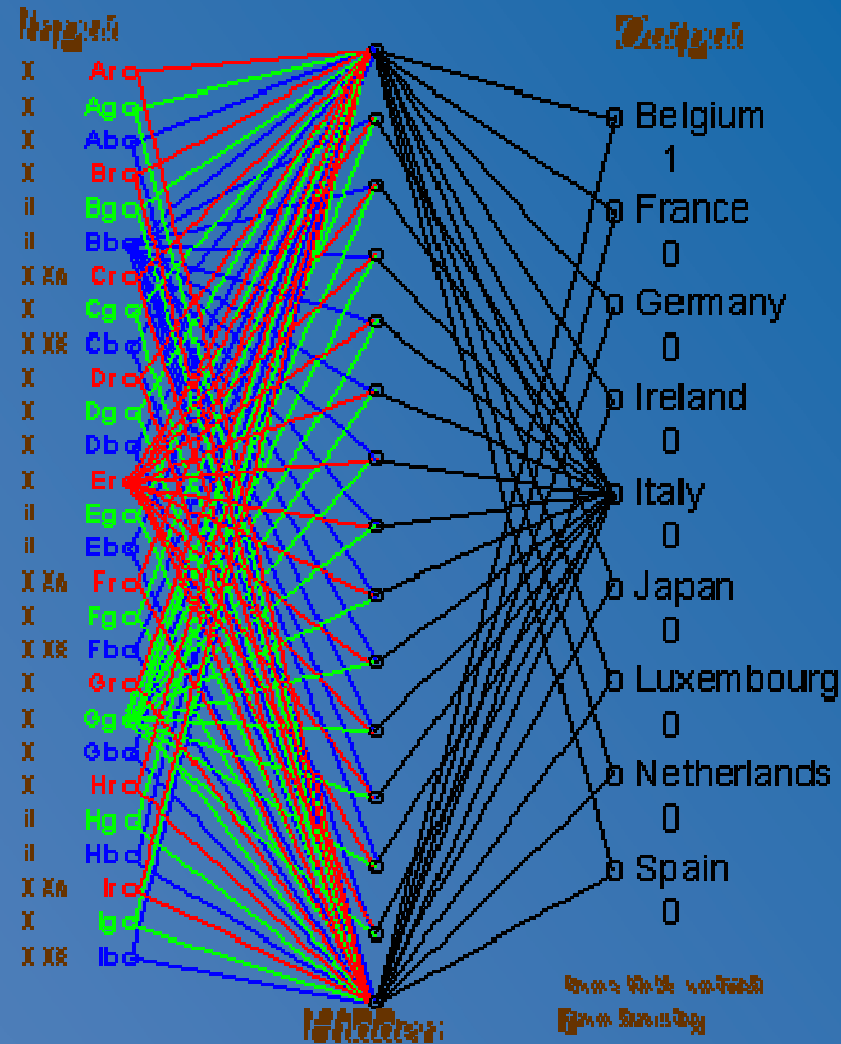
Plně propojené síť

Základní funkce



Flag colour measurements

Using a neural network for flag recognition



Typy neuronových sítí



- Neuronové sítě bývají nejčastěji rozděleny podle způsobu svého propojení.
- Dopředné (feedforward) sítě obsahuje pouze dopředné propojení, tedy propojení v jednom směru neobsahující zpětnovazebné smyčky.
- Sítě obsahující několik vrstev propojených pouze dopředně se nazývají vícevrstvé dopředné sítě.
- Je-li každý neuron v jedné vrstvě sítě propojen s každým neuronem následující vrstvy sítě pouze jednosměrně, nazýváme tuto síť plně propojenou.
- Sítě, kde jsou všechny neurony propojeny s ostatními obousměrně se nazývají Hopfieldovy sítě

Příklady použití neuron. sítí



Klasifikátory

- úkolem je zařadit vstupní data do skupin (tříd) podle vzájemné podobnosti

Aproximátory funkcí

- z několika naměřených hodnot je třeba sestavit funkční závislost (např. predikce počtu slunečních skvrn, vývoj kursu koruny apod.)

Asociativní paměti

- na základě předloženého vstupu je síť schopna “vybavit si” odpovídající výstup.

Fáze činnosti neuronové sítě



- 1) fáze nastavování (učení , trénování)
- 2) fáze pracovní

Fáze učení

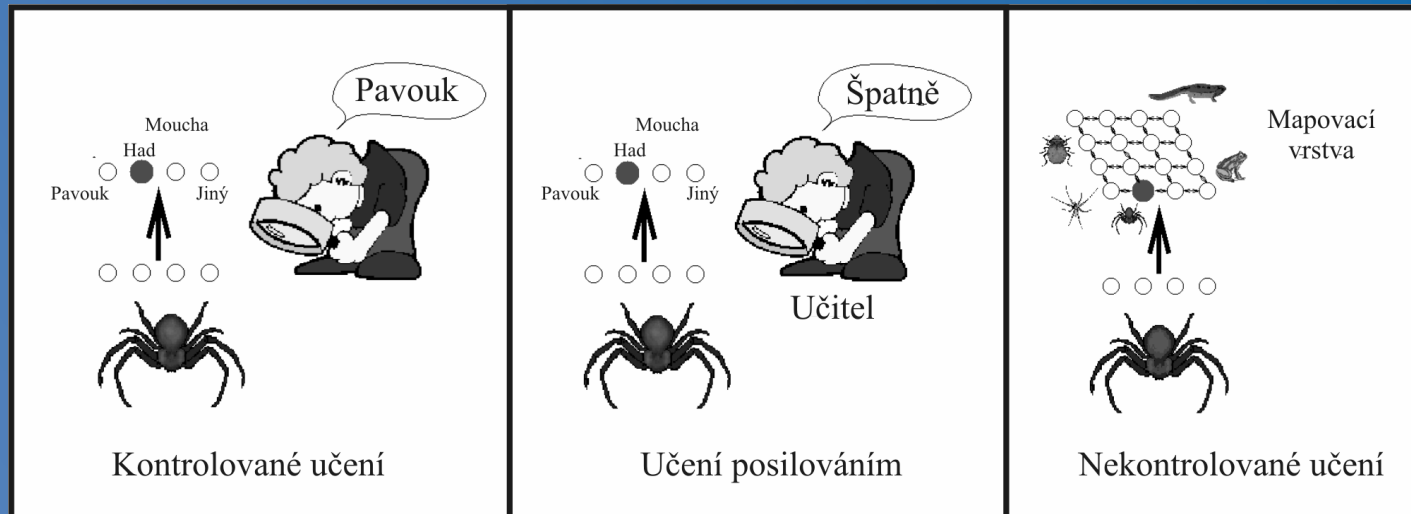
Cílem učení je nastavit váhy jednotlivých neuronů tak, aby síť prováděla požadovanou činnost. Existují 3 způsoby učení:

- a) učení s učitelem (supervised learning)
- b) učení bez učitele (unsupervised learning)
- c) učení posilováním (conditioned learning)

Fáze pracovní

Neuronová síť reaguje na předložené vstupy podle nastavení, které se “naučila” ve fázi učení.

Typy učení



Kontrolované (supervised) typy učení se používají při aplikaci v oblastech kontroly, automatizace, robotiky a počítačového vidění. Nekontrolované (unsupervised) učení se používá při plánování, osvojování si zkušeností (akvizice) a při převodu analogového do digitálního kódu.

Paměť neuronových sítí



Nejčastěji hovoříme o celé síti neuronů, ve které je paměť obsažena v distribuované formě. Konekcionistické modely paměti se dají rozčlenit do tří základních skupin.

První je tvořena vícevrstevnými dopřednými sítěmi pro rekognici a kategorizaci.

Druhou tvoří autoasociativní sítě pro rekognici a rozpoznávání vzorů.

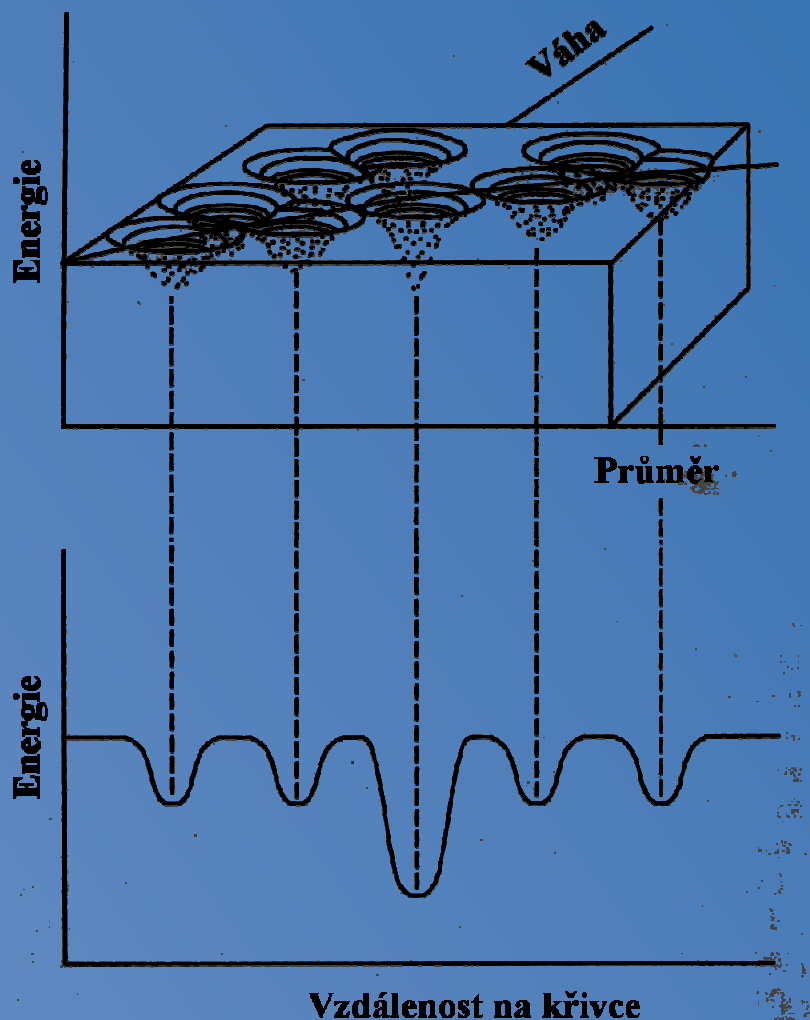
Třetí tvoří rekurentní heteroasociativní sítě paměťových sekvencí.

Hopfieldovy sítě



- Hopfieldova neuronová síť, navržená začátkem osmdesátých let, je typickým příkladem autoasociativní sítě.
- V současné době existuje několik modifikací sítě. Může být použita jako asociativní paměť, klasifikátor (kategorizace) nebo k řešení optimalizačních problémů.
- Asociativnost hopfieldovské paměti je dána tím, že vybavovaný vzor zadáváme jistou jeho částí, do značné míry libovolnou. Vzor je vybavován podle části svého „obsahu“, tj. prostorového umístění, nikoliv odkazem na nějakou jeho „adresu“ (jako u paměti RAM). Jedná se o content adressable memory (CAM).

Energetická funkce



Při vybavování neznámého vzoru, který chceme pomocí Hopfieldovy sítě identifikovat, jej budeme reprezentovat kuličkou, pohybující se po pomyslné krajině a snažící se dostat na co nejnižší položené místo. Může se však dostat i do lokálního minima, které také představuje řešení, avšak nikoliv řešení optimální (kulička zůstane v údolí, které neodpovídá její velikosti). Z tohoto důvodu bude energetická funkce (rozlišovací schopnost pro hledání minima) sítě poněkud složitější.

Nevýhody



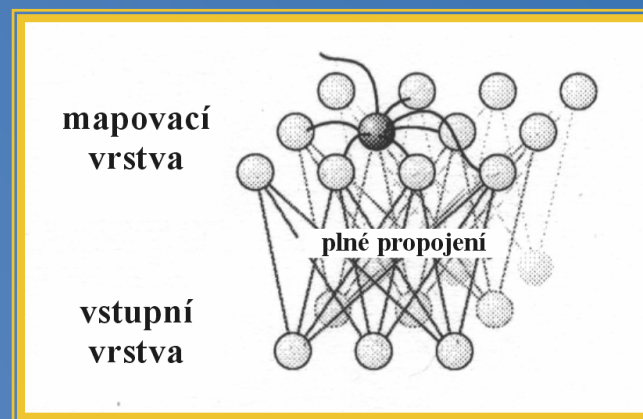
- Je-li Hopfieldova síť použita jako asociativní paměť, má dvě hlavní omezení.
- Prvním je, že počet vzorů, které můžeme síť naučit, je poměrně nízký. Jestliže naučíme síť příliš mnoho vzorů, může síť konvergovat k nějakému zvláštnímu obrazci, na který nebyla naučena. Síť je potom přeučená.
- Nevýhodou Hopfieldovy sítě jsou také veliké nároky na paměť. To může způsobit chybu při identifikaci předloženého vzoru.
- Další důležitou vlastností Hopfieldovy sítě, obtížně pojmenovatelné jako výhoda či nevýhoda, je automatické rozpoznávání inverzních vzorů k již naučeným vzorům. Hopfieldovu síť tedy nemusíme inverzní vzory učit.

Kohonenovy sítě



Jestliže tvoří Hopfieldovy sítě způsob paměťového systému blízky lidskému, rozšiřuje Kohonenův model schopnosti neuronových sítí ještě blíže směrem k lidské inteligenci.

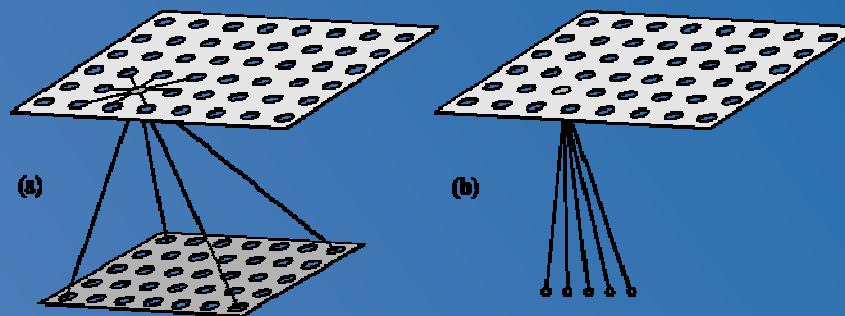
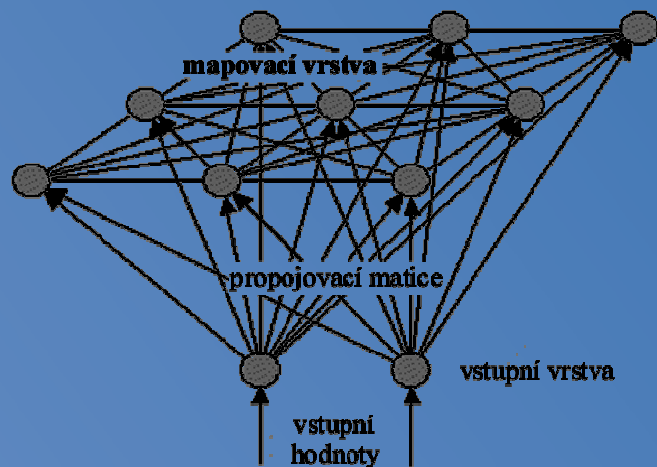
Jím navržená síť obsahuje schopnosti, které bychom v psychologii nazvali: exaktnější kategorizace, zapomínání, selektivita a díky mapovací vrstvě, informace o funkci systému s možností jejich využití při kontrole či zpětné vazbě.



Samoorganizující se sítě



Základem Kohonenových sítí je plné propojení vstupní vrstvy s mapovací vrstvou. Tato vrstva má laterální propojení se všemi neurony své vrstvy. Pro neblížší neurony jsou propojení posilující), pro vzdálené inhibiční při zachování topologie. V praxi to znamená, že jsou blízké body ve vstupním prostoru mapovány na blízké body ve výstupním prostoru. Již zmíněnou vlastností Kohonenových sítí je schopnost Hebbovského učení. Díky tomu se sítě dají považovat jako neurobiologicky plausibilní.



Hebbovské učení



- Základní pravidlo kanadského neurobiologa Donalda Hebba říká, že pokud se nachází neuron A v dostatečné blízkosti, aby excitoval neuron B a opakovaně pálí, tak v obou neuronech nastanou metabolické procesy, které zvýší pálení. A podporuje pálení B, je-li dostatečně blízko.
- Možnosti biologických sítí se dají převést i do jejich umělých variant. Základní princip Hebbovského učení vychází ze zvyšování hodnot vah neuronů, které jsou spolu propojeny a během učení jsou aktivovány společně.
- Koukolík uvádí složitější variantu Hebbovského učení, kdy neurony mají schopnost se koaktivovat podle vzorce pálení. Nestačí pouhá aktivita a blízkost v prostoru, ale nutná je i znalost vzorce. Využití pulzních neuronů v oblasti Hebbovského učení rozšiřuje možnosti koaktivace i mezi vzdálenými neurony.

Robustnost

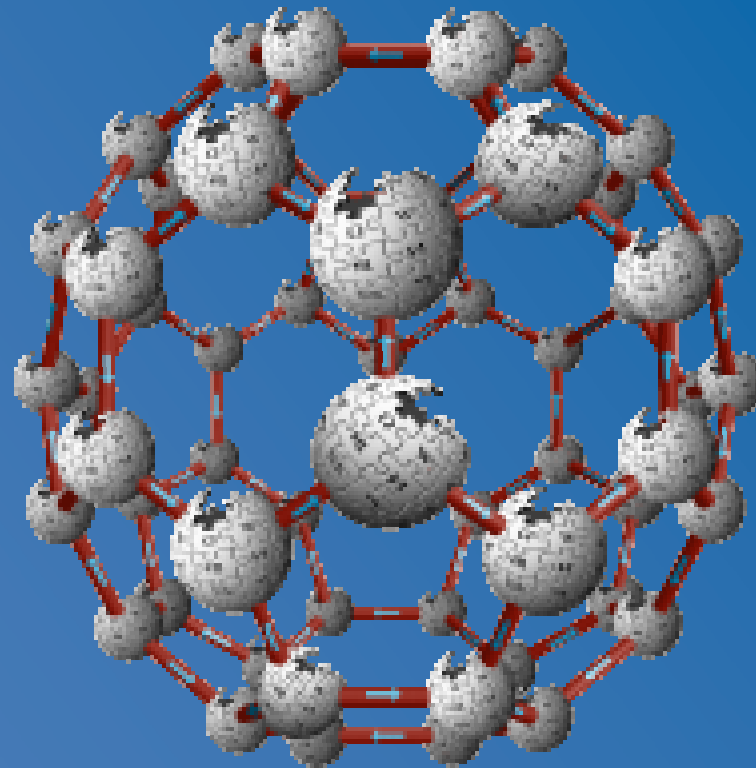


- Pro toto slovo můžeme najít mnoho synonym jako pružnost, houževnatost apod. Jeho hlavním cílem je obrana proti zhroucení i pokud je část systému poškozená, nebo pokud jsou podmínky pro uskutečnění úlohy nedostačující. Příkladem (poněkud zjednodušujícím) je rýma u člověka, zabraňující dýchání nosem. Robustnost systému znamená možnost dýchání pusou.
- Slovo je v podstatě velmi blízké pojmu redundance. V oblasti inteligence se spíše mluví o robustnosti mozkové neuronové sítě, mající takové množství propojení a funkčních jednotek (neuronů), že při i výpadku většího počtu neuronů či propojení nedojde k vážnějšímu porušení funkčnosti systému.

Výhody neuronových sítí



- Paralelismus
- Schopnost adaptace
- Sebeorganizace
- Distribuovaná paměť
- Odolnost proti chybám
- Schopnost generalizace
- Jednoduchá konstrukce



Nevýhody neuronových sítí



- Neuronové sítě jsou paralelní systémy, ale bývají často simulované pomocí klasických sériových počítačů.
- Čas na zpracování úlohy roste exponenciálně se složitostí úlohy – Scaling problem
- Neuronové sítě jsou tedy využívány pouze k řešení jednoduchých úloh.
- Výkonnost sítě je závislá na kvalitě a druhu předzpracovaných dat.
- Neuronové sítě nedokáží vysvětlit své výsledky. Pravidla podle kterých operují jsou neznámá.

Příště



V následující hodině se budeme zabývat

Lingvistika a sémantika

Úkol do příště:

S. Harnad: The symbol grounding problem

Dostupný na adrese:

<http://www.ecs.soton.ac.uk/~harnad/Papers/Harnad/harnad90.sgproblem.html>

V informačním systému jej naleznete v sekci studijních materiálů.

Přečtěte kolik stihnete

Konec



Děkuju za pozornost

