

brmiversity: Umělá inteligence a teoretická informatika

Přednáška č. 15

Petr Baudiš [⟨pasky@ucw.cz⟩](mailto:pasky@ucw.cz)

brmlab 2011



Outline

- 1 Dnešní paběrkování
- 2 Neuronové sítě
- 3 Umělá inteligence

Témata

- Neuronové sítě
- Gödelovy věty
- Umělá inteligence: Pravděpodobnostní sítě, MCMC a Kálmánovy filtry

Outline

- 1 Dnešní přednáška
- 2 Neuronové sítě
- 3 Umělá inteligence

RBF síť

- RBF: Radial Basis Function $R_i(\vec{x}) = \rho(\|\vec{x} - \vec{c}_i\|)$
- $\|\vec{x} - \vec{c}_i\|$ je vzdálenost mezi \vec{x} a \vec{c}_i
- ρ je bázová funkce, typicky Gaussovka $\rho(x) = \exp(-\beta x^2)$
- Vstupní vrstva předává data, výstupní vrstva je lineární asociátor (klasický neuron)
- Jedna skrytá vrstva, kde přechodové funkce jsou RBF
- Tedy výstup sítě je $\sum_{i=1}^N a_i \rho(\|x - c_i\|)$
- Obvykle je výstup RBF normalizovaný, aby součet vstupů asociátoru byl 1
(Pak se na to dá dívat jako na laterální spoje a speciální Kohonenovskou vrstvu.)
- Učení gradient descentem (třeba backprop)
- Silná metoda pro aproximaci funkcí
- Rekurzivní predikce časové posloupnosti v rámci dynamického systému

Kaskádová korelace

- Problémy klasických ANN: Jak by síť měla vypadat?
 - Local Optimum Problem
 - Step Size Problem
 - Moving Target Problem
- Idea: Přidávat neurony během učení, “tak, jak budou potřeba”
 - Tedy s váhami nastavenými pro minimalizaci chyby
- Kaskáda: Každý neuron je napojený na všechny předchozí
- Každý neuron reprezentuje *odstranění určité systematické chyby*

Obrázky: Large Scale Reinforcement Learning using $Q - SARSA(\lambda)$ and Cascading Neural Networks

Učení kaskádové korelace

- Síť učíme backpropem a zároveň si chystáme několik nových neuronů
- Nemenší-li se chyba, vybereme jeden z nových neuronů a přidáme ho do sítě
- Vstupní váhy neuronu jsou zmrazeny, výstup se učí backpropem
- Cíl učení: Maximalizace kovariance mezi výstupy neuronu a chybou sítě

$$S = \left| \sum_p (c_p - \mathbb{E}c)(e_p - \mathbb{E}e) \right|$$

$$\frac{\partial S}{\partial w_k} = \sum_p \rho(e_p - \mathbb{E}e) f'_p l_{p,k}$$

Adaptive Resonance Theory

- ART síť: Odskočíme si k učení bez učitele
- Chceme roztrždit vstup do kategorií, které si sami vytvoříme
- Stability-plasticity dilemma
- Trénujeme zvláště bottom-up klasifikaci senzory vs. top-down očekávání pozorovatele

- Comparison field: Vstup
- Recognition field: Repräsentanti
- Reset modul: Vigilance síť
- Trénování: Vyberu nejbližší neuron s dostatečně silným matchem (vigilanční test) a ten posunu směrem ke vstupu
- Pokud žádný nenajdu, mám novou kategorii a naalokuji nový neuron

Counter-propagation NN

- Vzpomínáte na Kohonenovy mapy?
- Lze je použít jako součást složitějšího klasifikátoru
- Přidáme na výstup speciální výstupní vrstvu neuronů zpracovávající Kohonenovu mapu
- Síť se vstřícným šířením
- Kohonenovu mapu učíme klasicky
- Výstupní neurony učíme posunem vah synapsí aktivovaných neuronů z Kohonenovy mapy k očekávaným výstupům

Otázky?

To je vše!

V současnosti nejpopulárnější variace jsou Support Vector Machines.

Outline

- 1 Dnešní paběrkování
- 2 Neuronové sítě
- 3 Umělá inteligence

Bayesovské sítě

- Mnoho náhodných proměnných, převážně podmíněně nezávislých
- Klasicky: Sdružená pravděpodobnost a marginály — moc!
- Závislosti proměnných lze modelovat jako graf
- Podmíněná nezávislost odpovídá separaci
- Markovovský obal
- Eliminace, vzorkování