

Lösningar till tentamen i kursen
ARTIFICIELLA NEURONNÄT OCH ANDRA LÄRANDE SYSTEM (2D1432)
den 10/3 2001, kl. 08⁰⁰ - 13⁰⁰

KG = Kevin Gurney

Uppgift 1

- 1 – d
- 2 – f
- 3 – c
- 4 – g
- 5 – b
- 6 – e
- 7 – i
- 8 – a
- 9 – h

Uppgift 2

Se KG avsnitt 2.5. Detta är alltså en neuronmodell som summerar sina viktade insignaler på vanligt sätt men som också har en tidskonstant som fördröjer/filtrerar summan enl en differkv (2.6). Tidskonstanten motsvarar den membrantidskonstant man har i verkliga neuron. Sen ges utsignalen av t ex en sigmoid aktiveringfunktion.

Uppgift 3

$w_1 = -2$, $w_2 = -1$, $b = 2$ (see KG section 3.1, slides 8-12 lecture 2).

Uppgift 4

inputs: water levels $x_1(t-1)$, $x_1(t-2)$... $x_1(t-6)$ and amount of rain $x_2(t-1)$,..., $x_2(t-6)$
target/output : water level $x_1(t)$ from the time series $x_1(t)$, $x_2(t)$ generate training patterns $t=6..N$

$x_1(t-1)$, $x_1(t-2)$... $x_1(t-6)$, $x_2(t-1)$,..., $x_2(t-6)$ -> $x_1(t)$

Network architecture 12-input, M-hidden units, 1 output unit, with $M \sim 4..10$ Train the network by error backpropagation by presenting one pattern at a time and update the weight according to the BP training rule.

Uppgift 5

see section 4.3 KG. Converges if patterns are linearly separable and learning rate alpha is sufficiently small see page 43 and slide 20 lecture 2.

Uppgift 6

A hypothesis A overfits the data if it has a smaller training error than another hypothesis B but B has a smaller test set error. (see lecture 3 slides 38-40). Use crossvalidation or holdout method to detect overfitting. The risk of overfitting is high when the model has a large number of parameters (degrees of freedom) and one only has few training examples.

Uppgift 7

En Hebbisk synaps är plastisk, förändrar sin styrka, enligt Hebb's regel. Den biologiska versionen av Hebb's regel säger att när ett presynaptiskt neuron i bidrar till att aktivera ett postsynaptiskt dito j så förstärks synapsen mellan dem. När det gäller ANN brukar detta formuleras som

$$\Delta w_{ij} = \alpha x_i^p x_j^p$$

där x_i är 1 om den presynaptiska (sändande) enheten är aktiv annars 0, och samma sak för mottagarenheten (den postsynaptiska), j . α är en inlärningshastighet. Man kan också använda bipolära aktiviteter -1 och $+1$ och samma regel med en liknande men lite annan effekt.

Uppgift 8

I kompetitiv inlärning tävlar enheterna i ett lager om att aktiveras av inmönstret. Detta kan t ex göras i form av kompetitiv dynamik i ett nätverk med inhibitoriska kopplingar mellan dessa enheter. Den enhet som har en viktvektor som ger starkast aktivering från inmönstret kommer att undertrycka de andra och till slut vara den enda aktiva enheten (vinnande enhet). En annan version av samma sak gör att den vinnande enhet (k) som har en viktvektor med minst avstånd till insignalen (x) utses till vinnare, enligt:

$$\text{finn } k : \|x - w_k\| = \min_i \|x - w_i\|$$

den vinnande nodens w uppdateras (flyttas mot x) enligt: $\Delta w_k = \alpha(x - w_k)$, $w_k' = w_k + \Delta w_k$ där α är en inlärningshastighet $\ll 1$.

Syftet med kompetitiv inlärning kan t ex vara klustering av eller extraktion av prototypvektorer ("kodord") från en datamängd.

Uppgift 9

Nätet kommer att ha $N = 900$ enheter. Om de lagrade mönstren var slumpmässiga och innehöll ca hälften svarta pixlar (vilket verkar rimligt) borde det kunna lagra ca $0.15 \cdot 900 = 135$ mönster och alltså skilja på så många personer (enl KG 7.6). Problemet är att ansiktsbilder kommer att vara starkt korrelerade varför kapaciteten blir betydligt mindre. I labben om Hopfieldnät kunde ett nät med $N=100$ lagra ca 4 korrelerade mönster mot 15 om dom varit slumpmässiga, dvs 25% av maxkapaciteten. Så med $N=900$ skulle det kunna bli drygt 30 mönster om inte korrelationerna är ännu större för ansikten än mönstren i lab 1. Experiment behövs för en säkrare uppskattning!

Uppgift 10

A reward function defines the goal in a RL problem. It maps each perceived state (or state-action pair) of the environment to a scalar number, a reward, that indicates the desirability of the state.

The value function describes the expected discounted future rewards that the agent obtains when starting in state S and following a policy π . The value function depends on the reward function, but also on the policy exhibited by the agent and the state transition probabilities. A value function specifies what is good in the long run or the long-term desirability of a state, the reward function specifies the short term pay-offs. The reward function is given and fixed, the value function depends on the policy and hence can be optimized by the agent. (see pages 3, 4, 5 of the RL tutorial and slides 8-11 lecture 5.

Uppgift 11

Because the threshold function is not differentiable and has no well-defined first order derivative, and therefore one can not compute the gradient of the error function with respects to the weights.

Uppgift 12

Med "spurious states" avses stabila attraktortillstånd i ett Hopfieldnät som är andra än de som lagrats i nätet under träningen. Det kan vara t ex inverser eller linjärkombinationer av träningsmönstren. Det är ett icke önskvärt fenomen – helst vill man förstås att precis de mönster man tränat med är stabila tillstånd och inga andra.

Uppgift 13

Ett nät med radialbasfunktioner i det gömda lagret tränas i två faser: dels gäller det att justera parametrarna som bestämmer RBF-enheterna (t ex medelpunkt och diameter, μ och σ), dels att träna vikterna från det gömda lagret till utlagret. RBF-enheternas parametrar kan tränas oövervakat (oklassade data kan användas, jfr lab 4a) medan vikterna från gömt lager till utlager måste tränas övervakat.

Uppgift 14

(Jfr lab 3 som utnyttjar ett "BCPNN" och föreläsning "Belief propagation...").

Kopplingarna i ett sådant nät är $w_{iq} = \log \frac{p(i,q)}{p(i)p(q)} = \log \frac{p(i|q)}{p(i)} = \log \frac{p(q|i)}{p(q)}$ där q och i

indexerar pre-enhet (sändande) resp post-enhet (mottagare) och $p(\cdot)$ betecknar (estimerade) sannolikheter för aktivering resp samtidig/betingad aktivering. Av detta framgår t ex att om q är oftare aktiv givet att i är aktiv än utan hänsyn till om i är aktiv eller ej ($p(q|i) > p(q)$) är vikten positiv, om q 's aktivitet är oberoende av i 's ($p(q|i) = p(q)$) är vikten 0 och om q är mer sällan aktiv givet att i är aktiv än utan hänsyn till om i är aktiv eller ej ($p(q|i) < p(q)$) är w_{iq} negativ.

Uppgift 15

Reasonable values for the vigilance parameter are 0.3-1.0, it defines how closely patterns should match to be considered similar. For large ρ , patterns have to have a large number of '1's in common to be considered similar, resulting in more, fine-grained prototypes, for small ρ ART generates fewer templates that match the patterns more coarsely. (see KG section 9.3)

Uppgift 16

You present a possible tour by a string that is a permutation of the set of cities A,B,C..F visited in that order (e.g. BDFEA is a tour B-D-F-E-A-B) The fitness of a tour is the inverse of the sum of intercity distances $\sum d_{ij}$ where ij are neighboring cities in the string, $d_{BD}, d_{DF}, d_{FE}, d_{EA}, d_{AB}$. You create an initial population of tours, select strings according to their fitness as parents, apply edge-recombination crossover (to obtain valid tours) to a pair of strings and replace the current generation by the population of offsprings. (see slides 21, 22 lecture 12).