



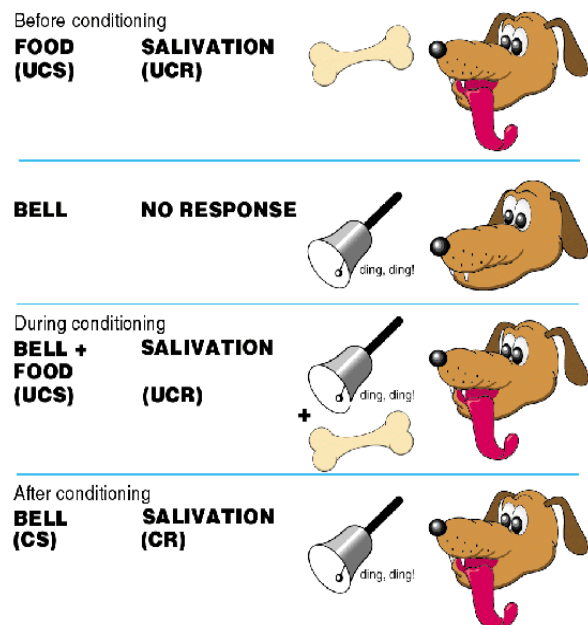
# Tanulás az idegrendszerben



Structure – Dynamics – Implementation – Algorithm – Computation - Function

# Tanulás pszichológiai szinten

- Classical conditioning



- Hebb ötlete:



"Ha az A sejt axonja elég közel van a B sejthez, és ismétlődően vagy folyamatosan hozzájárul annak tüzeléséhez, akkor valamely, egyik vagy mindkét sejtre jellemző növekedési folyamat vagy metabolikus változás következménye az lesz, hogy az A sejt hatékonysága a B sejt tüzeléséhez való hozzájárulás szempontjából megnő."

# A tanulás problémája matematikailag



- Modell paramétereinek hangolása adatok alapján
- Kettős dinamika
  - Változók (bemenet-kimenet leképezés) - gyors
  - Paraméterek - lassú
- Memória és tanulás különbsége
  - Memória használatánál a bemenetre egy konkrét kimenetet szeretnék kapni a reprezentáció megváltoztatása nélkül
  - Tanulásnál minden bemenetet felhasználok arra, hogy finomítsam a reprezentációt, miközben kimenetet is generálok
- Alapvető cél: predikciót adni a jövőbeli történésekre a múlt alapján

# A tanulás alapvető típusai

- Felügyelt
  - Az adat: bemenet-kimenet párok halmaza
  - A cél: függvényapproximáció, klasszifikáció
- Megerősítéses
  - Az adat: állapotmegfigyelések és jutalmak
  - A cél: optimális stratégia a jutalom maximalizálására
- Nem felügyelt, reprezentációs
  - Az adat: bemenetek halmaza
  - A cél: az adat optimális reprezentációjának megtalálása / magyarázó modell felírása
- Egymásba ágyazások




# Perceptron



- Bináris neuron: lineáris szeparáció
  - Két dimenzióban a szeparációs egyenes:


$$\theta = x_1 w_1 + x_2 w_2 \quad \longrightarrow \quad x_2 = \frac{-w_1}{w_2} x_1 + \frac{\theta}{w_2}$$

- Logikai függvények




# Tanulásra alkalmas neurális rendszerek

- Egyetlen sejt
- Előrecsatolt hálózat
- Rekurrens hálózat
- Ezen az órán: rátamodell



$$y = f(\mathbf{xw} - \theta)$$

- Paraméterek: súlyok, küszöbök
- Különböző kimeneti nemlinearitások
  - Lépcső: H (Heavyside)
  - Sigmoid:
  - Lineáris neuron



# Error-correcting tanulási szabályok

- Felhasználjuk azt az információt, hogy milyen messze van a céltól a rendszer
- Rosenblatt-algoritmus – bináris neuron

$$\mathbf{w}(t+1) = \mathbf{w}(t) + \epsilon (t^m - y(\mathbf{x}^m)) \mathbf{x}^m$$

- Delta-szabály

- Folytonos kimenetű neuron – gradiens-módszer

$$w_b(t+1) = w_b(t) - \epsilon \frac{\partial E}{\partial w_b} \quad E = \frac{1}{2} \sum_m^{N_s} (t^m - y(\mathbf{x}^m))^2 \quad \frac{\partial E}{\partial w_b} = - \sum_m^{N_s} (t^m - y(\mathbf{x}^m)) \mathbf{x}^m$$


lineáris neuronra, egy pontpárra vonatkozó közelítéssel:

$$\mathbf{w}(t+1) = \mathbf{w} + \epsilon (t^m - y(\mathbf{x}^m)) \mathbf{x}^m$$


- Minsky-paper 1969: a neurális rendszerek csak lineáris problémákat tudnak megoldani

# Error-correcting tanulási szabályok

## Rosenblatt-algoritmus – bináris neuron



$$y = H(w_1 + w_2 - \Theta)$$



$$y = H(w_1 + w_2 + b)$$

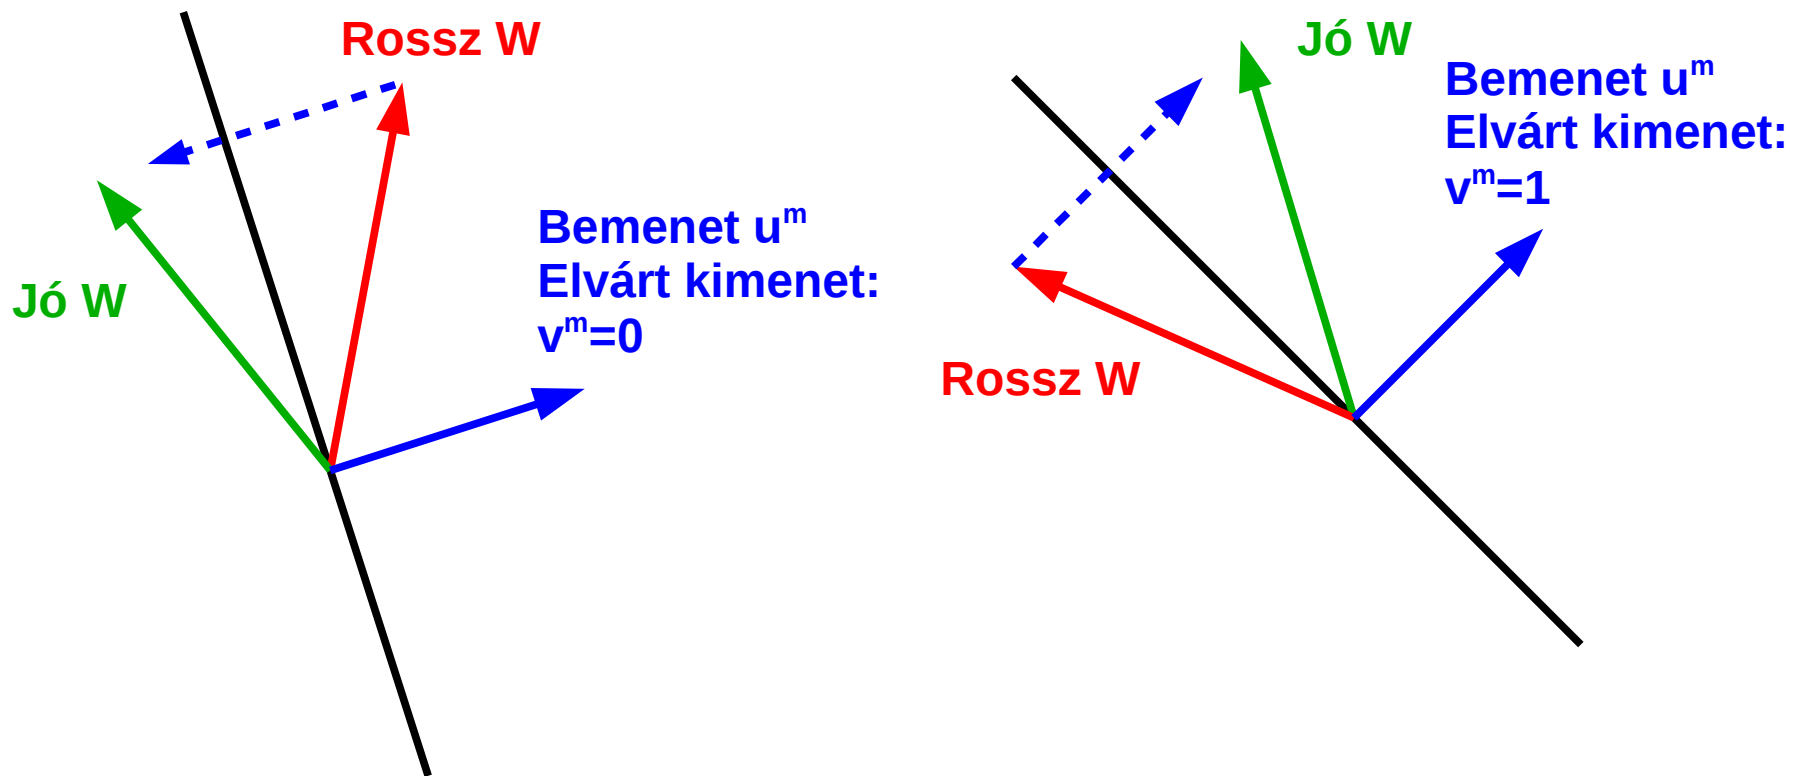
Egy konstans 1 bemenet és a  $b = -\Theta$  (**bias**) bevezetésével kitranszformáljuk a küszöböt. A **bias** tanulása így ekvivalens egy kapcsolatsúly tanulásával.



# Error-correcting tanulási szabályok

## Rosenblatt-algoritmus – bináris neuron

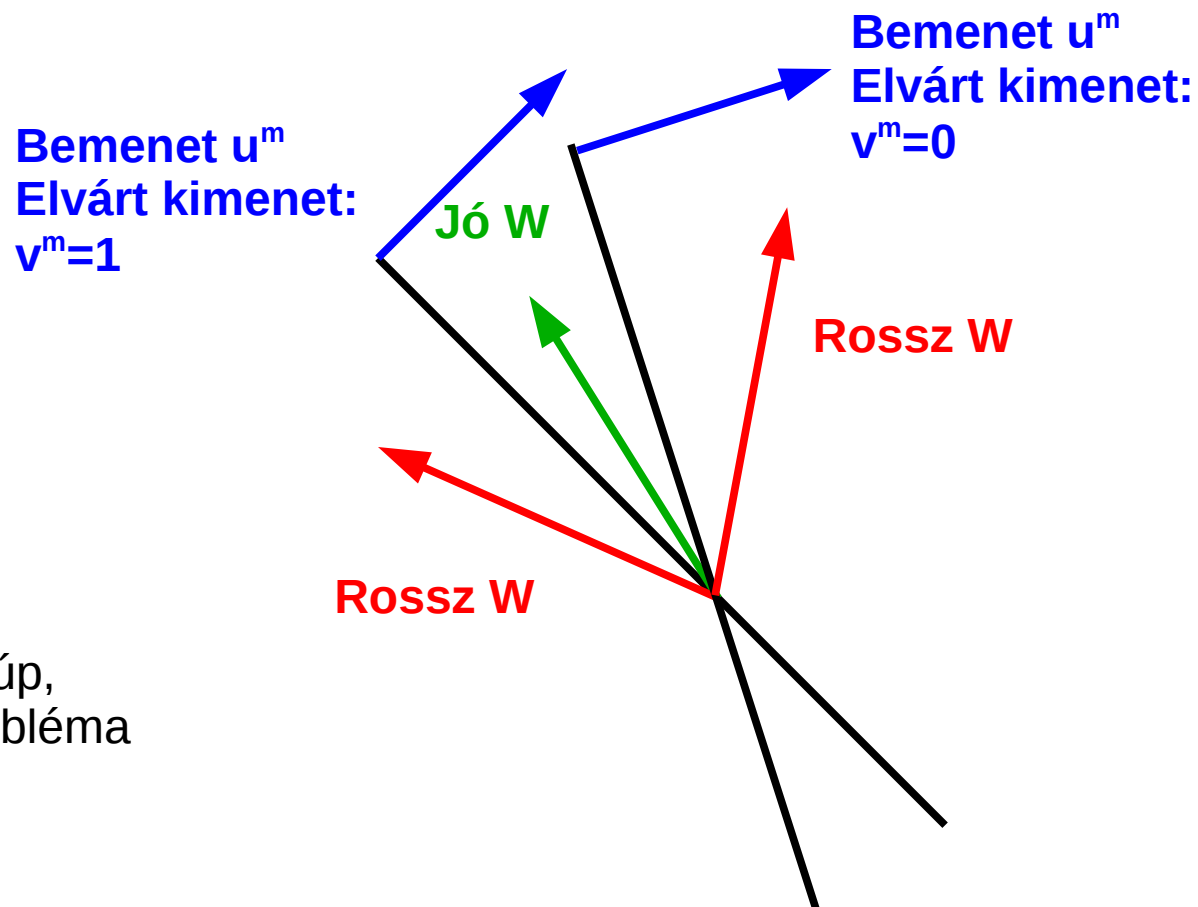
$$\mathbf{w} \rightarrow \mathbf{w} + \epsilon (v^m - v(\mathbf{u}^m)) \mathbf{u}^m$$



# Error-correcting tanulási szabályok

## Rosenblatt-algoritmus – bináris neuron




$$\mathbf{w} \rightarrow \mathbf{w} + \epsilon (v^m - v(\mathbf{u}^m)) \mathbf{u}^m$$



Megoldáskúp,  
Konvex probléma

# Multi-Layer Perceptron

- Nemlineáris szeparáció
- regresszió
- egyenletesen sűrű I2-ben egy rejtett réteggel
- A reprezentációs képességet a rejtett réteg növelésével tudjuk növelni
- Idegrendszerben – látórendszer ...



# Error backpropagation

- Bemenet/aktiváció:  $z$
- Elvárt kimenet:  $t_n$
- Aktuális kimenet:  $y$
- A hibafüggvény parciális deriváltjai:
- Mivel gradiens-módszer, a hibafüggvény lokális minimumába fog konvergálni.

$$z = \mathbf{xw} + b$$

$$y = f(z) = \frac{1}{(1 + e^{-z})}$$

$$\frac{\partial E}{\partial w_{bi}} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial z} \frac{\partial z}{\partial w_{bi}}$$

$$\frac{\partial E}{\partial y} = t^n - y(\mathbf{x})$$

$$\frac{dy}{dz} = y(1 - y)$$

$$\frac{\partial z}{\partial w_i} = x_i$$

$$w_i(t+1) = w_i(t) + (y - t^n) y(1 - y) x_i$$

$$\delta_j = y_j(1 - y_j) \sum w_{jq} \delta_q$$

# Lassú konvergencia a korrelált változók mentén

Probléma:

Erősen korrelált változók esetén a gradiens gyakran/általában majdnem merőleges a minimum valódi irányára.

## Lehetséges megoldások:


Momentum módszer,

Hessian mátrix

Hessian mentes optimalizátor

Konjugált Grádiensek

Adaptív lépésköz




# Rekurrens Hálózatok

Lehetséges tanítási technikák

Hiba visszaterjesztés az időben


Echo state network

Long short term memory



# Hebbi tanulás perceptronnal


- Nem felügyelt  
A bemeneti adatok főkomponensei irányába állítja be a súlyokat



- Felügyelt



$$\tau_w \frac{d\mathbf{w}}{dt} = \frac{1}{N_s} \sum_{m=1}^{N_s} v^m \mathbf{u}^m$$

- A kimenetet is meghatározzuk
- Nem minden tanítóhalmazra lehet így megkonstruálni a szeparáló súlyokat



# Asszociatív memória

- Heteroasszociatív
  - pl. hely-objektum
- Autoasszociatív
  - Töredékes jelből az eredetit
- Különbség a számítógép memóriája és az AM között: címzés módja




- Kapacitás: hány mintát tudunk eltárolni úgy, hogy azok visszahívhatók legyenek (többféle definíció)
- Stabilitás: minden mintára a legközelebbi tárolt mintát szeretnénk visszakapni




# Attraktorhálózatok

- Attraktorok típusai
  - Pont
  - Periodikus
  - Kaotikus
- Vonzási tartományok
- Realizáció: rekurrens neurális hálózatok
- Attraktorok tárolása: szinaptikus súlyokon
  - Offline tanulás
  - Online tanulás
  - One-shot learning
- Előhívás: konvergencia tetszőleges pontból egy fix pontba



# Hopfield-hálózat



- Asszociatív memória
- Bináris MCP-neuronok
- Minták tárolása: bináris vektorok
- Szimmetrikus súlymátrix
- Dale's law: egy sejt nem lehet egyszerre serkentő és gátló – ezt most megsértjük
- Rekurrens (dominánsan) hálózatok az agyban: hippokampusz CA3 régió, ...

- Offline learning tanulandó minták:

$$\{s^1 \dots s^N\}$$

$$W_{ij} = \frac{1}{N} \sum_n s_i^n s_j^n \quad \leftarrow \text{Hebbi szabály}$$

$$\mathbf{x}^{t+1} = \text{sgn}(\mathbf{W} \mathbf{x}^t - \boldsymbol{\theta}) \quad x_k^{t+1} = \text{sgn}\left(\sum_i^K W_{ik} x_i^t - \theta_k\right)$$

- Léptetési szabályok: szinkron és szekvenciális

# A HN dinamikája

- Nemlineáris rendszerek stabilitás-analízise: Lyapunov-függvény segítségével definiáljuk az állapotokhoz rendelhető energiát.

Ha a függvény:

- Korlátos
- Belátható, hogy a léptetési dinamika mindig csökkenti (növeli)

Akkor a rendszer minden bemenetre stabil fix pontba konvergál.

- Hopfield-hálózat Lyapunov-függvénye:

$$E = -\frac{1}{2} \mathbf{x}^T \mathbf{W} \mathbf{x} - \boldsymbol{\theta} \mathbf{x}$$

- Attraktorok az eltárolt mintáknál, de más helyeken is
- A HN használható kvadratikus alakra hozható problémák optimalizációjára is

# A HN kapacitása

- Információelméleti kapacitás

- A tárolandó mintákat tekintjük Bernoulli-eloszlású változók halmazának

$$P(s_i^n = 1) = P(s_i^n = 0) = 0.5$$

- Követeljük meg az egy valószínűségű konvergenciát

$$\lim_{n \rightarrow \infty} P(s^a = \text{sgn}(\mathbf{W}s^a)) = 1 \quad \forall a = 1 \dots M$$

- Ekkor (sok közelítő lépéssel) megmutatható, hogy

$$M \approx \frac{N}{2 \log_2 N}$$

- Összehasonlítás a CA3-mal

- Kb. 200000 sejt, kb. 6000 minta tárolható

- Más becslések

- figyelembevéve a minták ritkaságát

$$P(s_i^n = 1) = \alpha$$

$$M \approx N \frac{1}{\alpha \log_2 \frac{1}{\alpha}}$$

# Boltzmann-gép

- Eloszlások reprezentációja – mennyiségek közti statisztikai összefüggések
- Sztochasztikus állapotátmenet

$$\mathbf{I} = \mathbf{W}\mathbf{u} + \mathbf{M}\mathbf{v}$$


$$P(v_a^{t+1} = 1) = \frac{1}{1 + e^{-I_a}}$$

- A hálózat határeloszlása

Energia:

$$E(\mathbf{v}) = -\mathbf{v}^T \mathbf{W}\mathbf{u} + \frac{1}{2} \mathbf{v}^T \mathbf{M}\mathbf{v}$$

A




output  $\mathbf{v}$   
 $\mathbf{W}$   
input  $\mathbf{u}$

Boltzmann-eloszlás:

$$P(\mathbf{v}) = \frac{e^{-E(\mathbf{v})}}{\sum_{\mathbf{v}} e^{-E(\mathbf{v})}}$$

B



# Tanulás Boltzmann-géppel

- Felügyelt tanulás, csak  $W$ -re,  $M$  analóg
- Hiba: Kullback-Leibler-divergencia a közelítendő és a megvalósított eloszlás között

$$D_{KL}[P(\mathbf{v}|\mathbf{u}), P(\mathbf{v}|\mathbf{u}, \mathbf{W})] = \sum_{\mathbf{v}} P(\mathbf{v}|\mathbf{u}) \ln \frac{P(\mathbf{v}|\mathbf{u})}{P(\mathbf{v}|\mathbf{u}, \mathbf{W})}$$

nem függ  $W$ -től

# Tanulás Boltzmann-géppel

- Felügyelt tanulás, csak  $W$ -re,  $M$  analóg
- Hiba: Kullback-Leibler-divergencia a közelítendő és a megvalósított eloszlás között

$$D_{KL}[P(\mathbf{v}|\mathbf{u}), P(\mathbf{v}|\mathbf{u}, \mathbf{W})] = \sum_{\mathbf{v}} P(\mathbf{v}|\mathbf{u}) \ln \frac{P(\mathbf{v}|\mathbf{u})}{P(\mathbf{v}|\mathbf{u}, \mathbf{W})}$$

nem függ  $W$ -től

a  $P(\mathbf{v}|\mathbf{u})$  -val súlyozott kimeneti összegzés helyett bemeneteke vett átlag:

$$\langle D_{KL} \rangle = -\frac{1}{N_s} \sum \ln P(\mathbf{v}^m|\mathbf{u}^m, \mathbf{W}) - K$$

# Tanulás Boltzmann-géppel

- Felügyelt tanulás, csak  $W$ -re,  $M$  analóg
- Hiba: Kullback-Leibler-divergencia a közelítendő és a megvalósított eloszlás között

$$D_{KL}[P(\mathbf{v}|\mathbf{u}), P(\mathbf{v}|\mathbf{u}, \mathbf{W})] = \sum_{\mathbf{v}} P(\mathbf{v}|\mathbf{u}) \ln \frac{P(\mathbf{v}|\mathbf{u})}{P(\mathbf{v}|\mathbf{u}, \mathbf{W})}$$

nem függ  $W$ -től

a  $P(\mathbf{v}|\mathbf{u})$  -val súlyozott kimeneti összegzés helyett bemeneteke vett átlag:

$$\langle D_{KL} \rangle = -\frac{1}{N_s} \sum \ln P(\mathbf{v}^m | \mathbf{u}^m, \mathbf{W}) - K$$

- Gradient descent – egyetlen bemenetre

$$\frac{\partial \ln P(\mathbf{v}^m | \mathbf{u}^m, \mathbf{W})}{\partial W_{ij}} = v_i^m u_j^m - \sum_{\mathbf{v}} P(\mathbf{v} | \mathbf{u}^m, \mathbf{W}) v_i u_j$$

a Boltzmann-eloszlásból



# Tanulás Boltzmann-géppel

- Felügyelt tanulás, csak  $W$ -re,  $M$  analóg
- Hiba: Kullback-Leibler-divergencia a közelítendő és a megvalósított eloszlás között

$$D_{KL}[P(\mathbf{v}|\mathbf{u}), P(\mathbf{v}|\mathbf{u}, \mathbf{W})] = \sum_{\mathbf{v}} P(\mathbf{v}|\mathbf{u}) \ln \frac{P(\mathbf{v}|\mathbf{u})}{P(\mathbf{v}|\mathbf{u}, \mathbf{W})}$$

nem függ  $W$ -től

a  $P(\mathbf{v}|\mathbf{u})$  -val súlyozott kimeneti összegzés helyett bemeneteke vett átlag:

$$\langle D_{KL} \rangle = -\frac{1}{N_s} \sum \ln P(\mathbf{v}^m | \mathbf{u}^m, \mathbf{W}) - K$$

- Gradient descent – egyetlen bemenetre

$$\frac{\partial \ln P(\mathbf{v}^m | \mathbf{u}^m, \mathbf{W})}{\partial W_{ij}} = v_i^m u_j^m - \sum_{\mathbf{v}} P(\mathbf{v} | \mathbf{u}^m, \mathbf{W}) v_i u_j^m$$

a Boltzmann-eloszlásból

- Delta-szabály – az összes lehetséges kimenetre való átlagot az aktuális értékkel közelítjük

$$W_{ij} \rightarrow W_{ij} + \epsilon_w (v_i^m u_j^m - v_i(\mathbf{u}^m) u_j^m)$$

Két fázis:    hebbi                      anti-hebbi

# Tanulás Boltzmann-géppel

- Felügyelt tanulás, csak  $W$ -re,  $M$  analóg
- Hiba: Kullback-Leibler-divergencia a közelítendő és a megvalósított eloszlás között

$$D_{KL}[P(\mathbf{v}|\mathbf{u}), P(\mathbf{v}|\mathbf{u}, \mathbf{W})] = \sum_{\mathbf{v}} P(\mathbf{v}|\mathbf{u}) \ln \frac{P(\mathbf{v}|\mathbf{u})}{P(\mathbf{v}|\mathbf{u}, \mathbf{W})}$$

nem függ  $W$ -től

a  $P(\mathbf{v}|\mathbf{u})$  -val súlyozott kimeneti összegzés helyett bemeneteke vett átlag:

$$\langle D_{KL} \rangle = -\frac{1}{N_s} \sum \ln P(\mathbf{v}^m | \mathbf{u}^m, \mathbf{W}) - K$$

- Gradient descent – egyetlen bemenetre

$$\frac{\partial \ln P(\mathbf{v}^m | \mathbf{u}^m, \mathbf{W})}{\partial W_{ij}} = v_i^m u_j^m - \sum_{\mathbf{v}} P(\mathbf{v} | \mathbf{u}^m, \mathbf{W}) v_i u_j^m$$

a Boltzmann-eloszlásból

- Delta-szabály – az összes lehetséges kimenetre való átlagot az aktuális értékkel közelítjük


$$W_{ij} \rightarrow W_{ij} + \epsilon_w (v_i^m u_j^m - v_i(\mathbf{u}^m) u_j^m)$$

Két fázis: hebbi ↑ ↑ anti-hebbi

- Nem felügyelt

$$D_{KL}[P(\mathbf{u}), P(\mathbf{u}, \mathbf{W})]$$

# Megerősítéses tanulás



- Állapottér: a szenzorikus (vagy egyéb bemeneti) változók lehetséges értékeinek kombinációjából előálló halmaz
- Jutalomszignál: bizonyos állapotokban kapunk információt a cselekvésünk sikerességéről
- Cselekvés: a tanuló megvalósít egy állapotátmenetet (legalábbis megpróbálja)
- Cél: a jutalom hosszú távú maximalizálása
- Értékfüggvény: az egyes állapotokhoz rendelt hasznosság
- Értékfüggvény reprezentációja:
  - Táblázattal (machine learningben)
  - Általános függvényapproximátorral – pl. előrecsatolt neurális hálózat
    - Beágyazhatunk egy felügyelt rendszert a megerősítésesbe a háló tanítására

# Temporal difference learning

- Prediction error felhasználása a tanuláshoz
- Az állapotérték frissítése neurális reprezentációban:

$$w(\tau) \rightarrow w(\tau) + \epsilon \delta(t) u(t-\tau) \quad \delta(t) = \sum_{\tau} r(t+\tau) - v(t)$$



- A prediction error kiszámítása
  - A teljes jövőbeli jutalom kellene hozzá
  - Egylépéses lokális közelítést alkalmazunk

$$\sum_{\tau} r(t+\tau) - v(t) \approx r(t) + v(t+1)$$

- Ha a környezet megfigyelhető, akkor az optimális stratégiához konvergál
- A hibát visszaterjeszthetjük a korábbi állapotokra is (hasonlóan a backpropagation algoritmushoz)
- Akciókiválasztás: exploration vs. exploitation

# TD tanulás neurális hálózattal

- Gerald Tesauro: TD-Gammon
  - Előrecsatolt hálózat
  - Bemenet: a lehetséges lépések nyomán elért állapotok
  - Kimenet: állapotérték (nyerési valószínűség)
- Minden lépésben meg kell határozni a hálózat kimeneti hibáját
  - Reward signal alapján
- Eredmény: a legjobb emberi játékosokkal összemérhető




# The effect of reward in dopaminergic cell of basal ganglia


An interpretation:

Dopamine cells signal the difference between the expected and received reward.


► The Basal Ganglia




No prediction  
Reward occurs



Reward predicted  
Reward occurs



Reward predicted  
No reward occurs

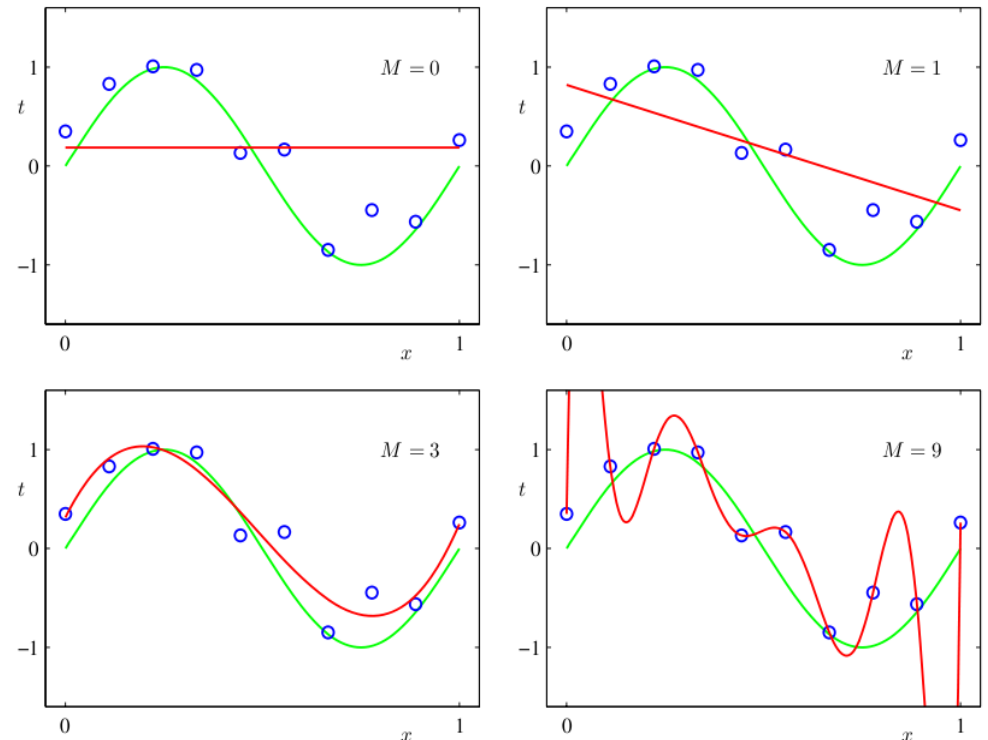


# Problémák tanulórendszerekben

- Bias-variance dilemma
  - Strukturális hiba: a modell optimális paraméterekkel is eltérhet a közelítő függvényről (pl lineáris modellt illesztünk köbös adatra)
  - Közelítési hiba: a paraméterek pontos hangolásához végtelen tanítópontra lehet szükség



- Pontosság vs. általánosítás

- A sokparaméteres modellek jól illeszkednek, de rosszul általánosítanak: túlillesztés
- A magyarázó képességük is kisebb (lehet): Ockham borotvája





# Idegrendszeri plaszticitás

- A plaszticitás helye: szinapszisok, posztzinaptikus sejtek tüzelési küszöbei (excitabilitás)
- Potenciáció, depresszió
- STP: kalciumdinamika, transzmitterkimerülés tartam < 1 perc



- LTP: génexpresszió (induction, expression, maintenance), NMDA magnézium-blokkja tartam > 1 perc




- Korreláció a molekuláris és pszichológiai szint között



# A Hebb-szabály


- Timing-dependent plasticity:
  - Ha a posztzinaptikus neuron nagy frekvenciával közvetlenül a preszinaptikus után tüzel, akkor erősödik a kapcsolat
  - Az alacsony frekvenciájú tüzelés gyengíti a kapcsolatot
  - Sok más lehetőség




- A Hebb-szabály formalizációja:  
lineáris ráta-modellben

$$\tau_w \frac{d w}{d t} = v u$$


**a** Excitatory to excitatory



**b** Excitatory to inhibitory



**c** Inhibitory to excitatory



# Stabilizált Hebb-szabályok

- Problémák a Hebb szabállyal:
  - csak nőni tudnak a súlyok
  - Nincs kompetíció a szinapszisok között – inputszelektivitás nem megvalósítható
- Egyszerű megoldás: felső korlát a súlyokra
- BCM: a posztszinaptikus excitabilitás felhasználása a stabilizásra

$$\tau_w \frac{d \mathbf{w}}{dt} = v \mathbf{u} (v - \theta_u) \qquad \tau_\theta \frac{d \theta_u}{dt} = v^2 - \theta_u$$

- Szinaptikus normalizáció

- Szubsztraktív normalizáció

$$\tau_w \frac{d \mathbf{w}}{dt} = v \mathbf{u} - \frac{v (\mathbf{1} \cdot \mathbf{u}) \mathbf{1}}{N_u}$$

Globális szabály, de generál egyes megfigyelt mintázatokat (Ocular dominance)

- Oja-szabály

$$\tau_w \frac{d \mathbf{w}}{dt} = v \mathbf{u} - \alpha v^2 \mathbf{u}$$

Lokális szabály, de nem generálja a megfigyelt mintázatokat

# Soft-max kimeneti réteg, valószínűségi eloszlások reprezentációjára

A logisztikus függvény 0 és 1 közé képi le az aktivációt:

$$y = f(z) = \frac{1}{(1 + e^{-z})}$$

A softmax réteg a logisztikus függvény általánosítása több változóra:

$$p_i = y_i = \frac{e^{\frac{z_i}{T}}}{\sum e^{\frac{z_i}{T}}}$$

$$\frac{\partial y_i}{\partial z_i} = y_i(1 - y_i)$$

Nem lokális, a kimenet a softmax réteg  
Minden neuronjának bemenetétől függ,  
nem csak az adott neuronétól.

T: hőmérséklet paraméter  
T->inf: egyenletes eloszlást ad  
T->0: konvergál a Max függvényhez

A deriváltja szépen viselkedik és lokális,  
Mint a logisztikus függvény esetében