

# Mesterséges Intelligencia

Csató Lehel

Matematika-Informatika Tanszék  
Babeş–Bolyai Tudományegyetem, Kolozsvár

2010/2011

Admin ...

... trívia

<http://www.cs.ubbcluj.ro/~csatol/mestint>

## Vizsga

Szóbeli (60%) + Gyakorlat (40%)

## Laborgyakorlatok:

- |   |  |      |
|---|--|------|
| 1 | Gráfok ábrázolása - dedukciós algoritmus | 18%  |
| 2 | Játékelmélet                             | 10%  |
| 3 | Matlab - tanulási algoritmus             | 12%  |
| 4 | Opcionális feladatok - max. 3/személy    | sok% |

## Bemutatók (5–20 pont)

Alkalmazások bemutatása, melyek adaptív, gépi tanulós vagy *mestint* módszereket alkalmaznak.

# Az Előadások Témái

- Bevezető: mi a *mesterséges* intelligencia ...
- „Tudás”-reprezentáció
- Gráfkeresési stratégiák
- Szemantikus hálók / Keretrendszerek
- Játékok modellezése
- Bizonytalanság kezelése
- Fuzzy rendszerek
- Grafikus modellek
- Tanuló rendszerek
- Szimulált kifűtés, Genetikus algoritmusok
- A perceptron modell
- Neurális hálók, önszerveződés
- Gépi tanulás


## A „mesterséges intelligencia”

Nincs pontos definíció.



„Elvárások”

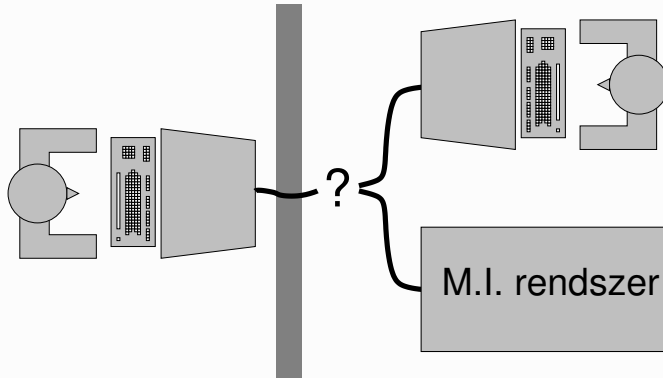
- intelligens viselkedés
- racionális viselkedés
- gondolkodó rendszer
- cselekvő rendszer



Cog.Bot.Lab – München  
J. Schmidhuber

# Turing-teszt

Egy megfigyelő tesztel egy rendszert, melyről nem tudja, hogy **ember vagy gép**. Feladat, hogy a feltett kérdések nyomán találjuk ki, hogy a rendszert **gép vagy ember** vezérli.



## Kérdésvetítés:

**Alan Turing** Képesé **tehető** – programozható – a számítógép a gondolkodás műveletére?

**Neumann János** A fogalmak eléggé **pontos** specifikálása esetén a gép „intelligens” lesz.

# Az M.I. fejlődése

- **1956 – első M.I. konferencia** Dartmouth-ban.
- „Alapítók”:
  - ▶ Minsky (Logo, Neurális háló),
  - ▶ McCarthy (Lisp),
  - ▶ Shannon (információ-elmélet)

## Fejlődési területek:

- **szimbolikus M.I.**
  - ▶ szakértői rendszerek
  - ▶ dedukciós algoritmusok
- „**konnekcionista**” megközelítések
  - ▶ neurális hálók
  - ▶ Boltzmann gépek
  - ▶ evolúciós algoritmusok

## Ezzel párhuzamosan:

- kognitív tudományok - cognitive neuroscience (CNS)
- Fuzzy algoritmusok

# Bevezető fogalmak

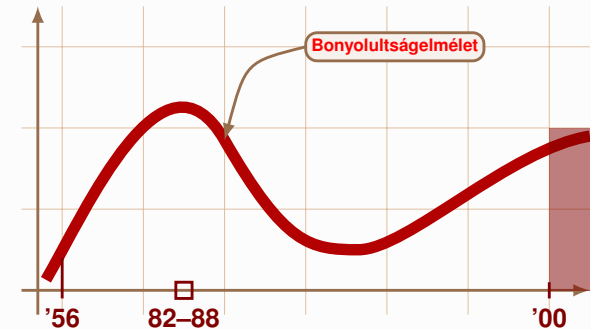
## Mesterséges Intelligencia – „A.I.”

<b>Emberhez hasonlóan</b> gondolkodó rendszerek <b>Bellman:</b> döntéshozatal, problémamegoldás, tanulás automatizálása.	Racionálisan gondolkodó rendszerek <b>Charniak:</b> Mentális képességek tanulmányozása.
<b>Emberhez hasonlóan cselekvő</b> rendszerek <b>Rich:</b> Végeztetni dolgokat, melyeket az emberek jobban tudnak.	Racionálisan <b>cselekvő</b> rendszerek <b>Schalkoff:</b> Utánozni és magyarázni az intelligens viselkedést.

Russell, 1996

# M.I. fejlődésgrafikon

**Fejlődési grafikon**  
cikkek száma,  
konferenciák  
látogatottsága ...



- kezdetek - elméleti háttér: dedukciós algoritmusok, feladatok meghatározása,
- '80-as években – nagyon nagy a támogatottsága,
- később az érdeklődés csökkent, de
- **1997-ben** a DEEP BLUE nyer a sakk-világbajnok ellen

## M.I. fejlődése évszámokban

- '50 Turing: „Computing Machinery and Intelligence”;
- '56 Dartmouth: „Mesterséges Intelligencia”;
- '52–'69 „Look, Ma, no hands!”<sup>1</sup>;
- '50– Sakk – Samuel, logika – Newell & Simon, „Geometry Engine” – Gelernter;
- '65 logikai következtető algoritmus – Robinson;
- '66–'73 Bonyolultságelmélet – csökkenő támogatottság;
- '69–'79 Tudásalapú rendszerek;
- '80– M.I. ipari ágazat;
- '86– Neurális háló modellek újra népszerűek;
- '87– M.I. tudományág;

<sup>1</sup> *vicc utolsó előtti sora. Utolsó: „Look, Ma, no teeth!”*

## M.I. – jelen időben

II

### Cinikusan: M.I. feladat

- = **egyelőre** jó megoldás nem ismert;
- = bizonyított, hogy a megoldáshoz nagyon hosszú idő kell.

### Sikerek:

- **Deep Blue, 1997** – Gary Kasparov-ot legyőzi (rendszerek, melyek legyőzik a Deep Blue-t),
- **Robbins sejtés** bizonyítása,
- **tervezés – ütemezés** az 1991-es iraki háborúban: 50.000 egység koordinálása,
- **Proverb** – keresztrejtvények megfejtése.

## M.I. jelen időben

I



„Modern AI focuses on practical engineering tasks”

† Egy pragmatikus megközelítés.

### Tudományterületek, melyek kiváltak:

- Felismerő rendszerek: minta-, beszéd-, OCR;
- Szakértői rendszerek;
- Gépi fordítás;
- Robotika;
- Játékelmélet;
- Dedukciós algoritmusok – Maple, Mathematica a Fermat-tétel bizonyítása, stb.

† <http://wikipedia.org>

## Könyvészet I



**S.J. Russell, P. Norvig**

***Mesterséges intelligencia modern közelítésben.*** (második kiadás) Panem, 2005.



**I. Futó (szerk)**

***Mesterséges intelligencia.*** Aula, 1999.



**S.J. Russell, P. Norvig**

***Artificial Intelligence: a Modern Approach.*** Prentice Hall, 1995.



**T.M. Mitchell**

***Machine Learning.*** McGraw-Hill, 1997.




**C.M. Bishop**

***Pattern Recognition and Machine Learning.*** Springer Verlag, 2006.

## Könyvészet II

 C.M. Bishop  
*Neural Networks for Pattern Recognition*. Oxford University Press, 1995.

 M.A. Arbib  
*The Handbook of Brain Theory and Neural Networks*. The MIT Press, 2003.

### Könyvészet olvasása kötelező

Az előadás anyaga **csupán** útmutató a tanuláshoz és segít a jegyzetelés megkönnyítésében.


### Könyvészet olvasása kötelező II

A vetített anyag **nem** elégséges a vizsgához.

## M.I. algoritmusok gyakorlatban II

www.agent.ai – '05 szept. 19 – **Pontosan utánoz a műkéz**

A Southampton-i Egyetem mesterséges végtagja



A „**Remedi-Hand**” (**R**ehabilitation and **M**edical Research Trust) parányi feldolgozó egységen keresztül kapcsolódik a karizmokkal. A készüléket a csuklót mozgató **izmok összehúzódásai vezérik**.

## M.I. algoritmusok gyakorlatban I

Index - '05 okt. 2 – **Nyelveket tanul a szoftver**  
**Automatic Distillation Of Structures (ADIOS)**

„Cél az agyban lévő szintaktikus és szemantikus ismeretek ... számítógépes modellezése.”

„A rendszer nyers adatokból (**szöveg, beszéd, aminosav, hangjegy**) **SZABÁLYOKAT** határoz meg.”



<http://adios.tau.ac.il>

## M.I. algoritmusok gyakorlatban III

www.agent.ai – '05 szept. 16 – **Tökéletes ujjlenyomatok**

**Genetikus algoritmusok** a bűnüldözésben



Ujjlenyomatokról készült képek tömörítésekor nagyon óvatosan kell eljárni: a legcsekélyebb torzulás is hasznavehetetlenné teheti az ujjlenyomat képét.

yahoo.com – '05 okt. 9 – **Stanford Volkswagen Wins \$2M Robot Race**



Defense Advanced Research Projects Agency, DARPA director Dr. Tony Tether, sets a medal on Stanford Racing Team's Stanley #03.

Sebastian Thrun

<http://robots.stanford.edu/>

## Feladat

## ?házi?

Találjatok a fentiekhez hasonló példákat, ahol a „mesterséges intelligens” eszközök sikeresek voltak.

+5 pont - kis bemutató

- **mouthed words** in Mandarin
- **11 electrodes** attached on face and neck
- **computer program** to figure out what he was saying



<http://www.post-gazette.com/pg/05301/596293.stm>

Fontos kérdések az implementáció folyamán:

Milyen **modellek**, **rendszerek**, **algoritmusok** voltak használva.


## „Tudás”reprezentáció

Ismeretek számítógépes formában való tárolása




vagy:

Hanoi tornyok feladata



# „Tudás” reprezentáció

Hanoi tornyok feladata




**Szabály:** nem helyezhető egy korong egy nála kisebb korong tetejére.

**Szabály  $\Rightarrow$  Állapottér**

# „Feladat”

**Feladat:**  
a kezdeti állapotból:  
 $(3, 3, 3)$   
a cél-állapotba  
 $(1, 1, 1)$   
eljutni.



# „Állapottér”


**Állapottér:** szabályos lépések sorozata.

**Ábrázolási mód:**  
irányítatlan gráf,  
minden lépés megfordítható.

**Csúcs – állapot**

**Él – lépés**

► Gráf



# Megoldáskeresés az állapottérben

**Hegymászó módszer**

**Heurisztika:** az állapotokhoz rendel egy **numerikus függvényt**, mely maximum a **kezdeti** állapotban és minimum a **vég** állapotban.

$$Val(CS) = \sum_k Poz_k$$

kezdeti = 9

vég = 3

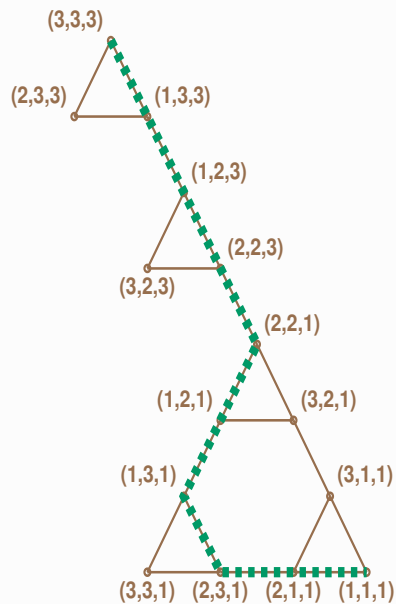
# Megoldás a hegymászó módszerrel

## Hegymászó módszer (Hill climbing)

Hegymászó:

- ÁLLAPOT  $\Leftarrow$  kezdőállapot
- Amíg ÁLLAPOT  $\neq$  CÉLÁLLAPOT
  - ▶ Válassz ÚJ\_ÁLLAPOT-ot
  - ▶ ÁLLAPOT  $\Leftarrow$  ÚJ\_ÁLLAPOT

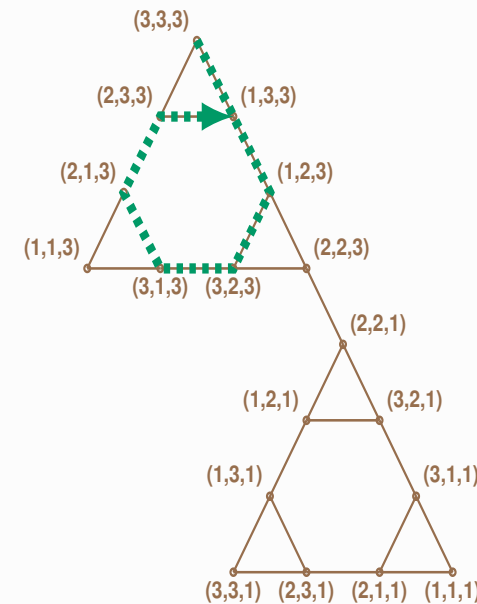
A következő lépés:  
A Val(CS) legkisebb – szülőtől különböző – csúcs.



# Hegymászó módszer

## Jellemzők:

- Heurisztika nem bizonyítható a konvergencia,
- Nem kerüli el a ciklusokat,
- függ a paraméterezéstől: például a (2, 2, 2)-be nem írható algoritmus.



# Backtracking


## Visszalépéses keresés

Visszalép:

- ÚT  $\Leftarrow$  kezdőállapot
- Amíg ÚT-vég nem CÉL
  - ▶ Válassz SZ az út végére alkalmazható műveletek v. visszalép
  - ▶ ÚT  $\Leftarrow$  SZ(ÚT)

A választásnál lehet a definiált célfüggvényt használni.

SZ = szabály




# Backtracking

## Visszalépéses keresés

## Fontos:

- a heurisztika  $\rightarrow$  hatékonyság,
- maximális úthossz korlátozás,
- jobb megoldás de nem optimális.

# Összefoglaló




## Keresés gráfban

Algoritmus:

- GRÁF ← kezdőállapot
- Amíg GRÁF ⊃ CÉL
  - Válassz SZ
  - GRÁF-ra alkalmazható műveletek
  - GRÁF ← SZ(GRÁF)


A választásnál lehet a definiált célfüggvényt használni.

SZ = szabály



## Keresés gráfban

- Felépíti a gráfot,
- A legköltségesebb,
- nem találja meg** a legrövidebb utat; Elérhetjük a célcsúcsot úgy is, hogy olyan csúcs(oka)t hagyunk ki, melyek a legrövidebb út részei lennének.



# Feladat dekompozíció

Rekurzív függvényhívás iskolapéldája

Jelölje:  $\langle n, i, j, k \rangle$  a műveletet, melyben

- a legfelső  $n$  korongot
- az  $i$ -edik rúdról
- a  $j$ -edik rúdra helyezzük
- a  $k$ -adik rúd segítségével


A feladat **dekomponálható**:

$$\langle n, i, j, k \rangle \longrightarrow \langle n-1, i, k, j \rangle \langle 1, i, j, k \rangle \langle n-1, k, j, i \rangle$$

ha  $n > 1$

$n = 1$  – nem kell tovább bontani a feladatot

# Feladat dekompozíció



**ÉS/VAGY gráf:**

- csúcs = probléma
- köteg - a részfeladatok, melyeket meg **kell** oldani a feladat megoldásához.
- Itt nincs **VAGY** csúcs.
- megoldás = részgráf, melyben minden részprobléma csupa megoldható problémára vezethető vissza.



**Szabályalapú következtetés**

$t(i, j)$  – legfelső korong  $i \Rightarrow j$  mozgatása.

A feladat megoldása mozgatások sorozata  $\Rightarrow$  lista

**Lista:**  $a.b.c.nil$

Lista axiómái:

$A(\cdot, \cdot, \cdot)$  – append

- (1)  $A(nil, r, r)$
- (2)  $A(u, v, w) \rightarrow A(s.u, v, s.w)$

- (1) – Üres lista nem változtat az eredményen
- (2) – Ha  $w$  az  $u$  és  $v$  összetétele, ez érvényes egy  $s$  előtaggal is.

Algoritmus:

- $GRÁF \Leftarrow$  célállítás
- Amíg  $GRÁF$ -ban nincs ellentmondásmentes levezetés
- **Válassz SZ**  
a  $GRÁF$ -hoz alkalmazható illesztések vagy visszalépés
- $GRÁF \Leftarrow SZ(GRÁF)$

Egy **ÉS/VAGY** gráfot járunk be és **keresünk** egy gráfot, mely tényekben végződik és nem ellentmondóak az illesztések.

**Hanoi tornyai** axiómái:

- (3)  $H(1, i, j, k, t(i, j).nil)$
- (4)  $H(n - 1, i, k, j, y) \wedge H(1, i, j, k, t(i, j).nil) \wedge H(n - 1, k, j, i, z) \wedge A(y, t(i, j).z, x) \rightarrow H(n, i, j, k, x)$

- (3) – 1 elemet **átteszünk**:  $t(i, j)$
- (4) –  $n$  elem áttételéhez előbb  $n - 1$  elemet mozgatunk  $y$  sorozattal, egy elemet  $t(i, j)$ -vel, majd  $n - 1$ -et vissza.

**Kérdés:**

(5)  $(\exists x) H(2, 1, 2, 3, x)$

(5) – azon mozgatások, melyek megvalósítják 2 korong mozgatását.

**Két elemű Hanoi-toronyra a kérdés:**

$(\exists x) H(2, 1, 2, 3, x)$

**Rezolúció:** bizonyítani, hogy az axiómákból következik a célállítás.  
**Módszer:** Tagadjuk a kijelentést és bizonyítjuk, hogy ez utóbbi hamis.

$\overline{A \rightarrow B} \Leftrightarrow \overline{\overline{A} \vee B} \Leftrightarrow A \wedge \overline{B}$

$\Leftrightarrow (1) \wedge (2) \wedge (3) \wedge (4) \wedge \overline{(5)}$  kielégíthetetlen

$\overline{(5)} = (\forall x) \overline{H(2, 1, 2, 3, x)}$

**Bizonyítás:** ellentmondásos axiómarendszer:

- (1)  $(\forall r) A(\text{nil}, r, r)$
- (2)  $(\forall \dots) \overline{A(u, v, w)} \vee A(s.u, v, s.w)$
- (3)  $(\forall \dots) H(1, i, j, k, t(i, j).nil)$
- (4)  $(\forall \dots) \overline{H(n-1, i, k, j, y)} \vee \overline{H(1, i, j, k, t(i, j).nil)} \vee \overline{H(n-1, k, j, i, z)} \vee \overline{A(y, t(i, j).z, x)} \vee H(n, i, j, k, x)$
- (5)  $(\forall x) \overline{H(2, 1, 2, 3, x)}$


Cáfolati gráf: **létezik út**, melyre fennáll az (1) – (4) és  $\overline{(5)}$ .  
 Figyeljük meg az univerzális kvantorokat!

**Keresőrendszerek (Production systems)**

Különválasztják a

- feladat adatait ;
- az adatokon értelmezett műveleteket ;
- a vezérlést, mely a műveleteket **algoritmussá** szervezi.

Keresőrendszer: (**Adat, Szabály, Vezérlés**)



**Általános stratégia:**

- **ADAT** ← Kezdeti adatbázis
- **AMÍG ADAT** nem terminális
- **Válassz SZ** az ADAT-ra alkalmazható szabályok közül,
- **ADAT** ← SZ(**ADAT**)

**Keresési stratégia:** az alkalmazható szabályok közül egyet kiválaszt.

Keresési stratégia:

- előrehaladó – *hegymászó, visszalépés, gráf*
- visszafelé haladó – *szabályalapú*
- kétirányú – bidirectional

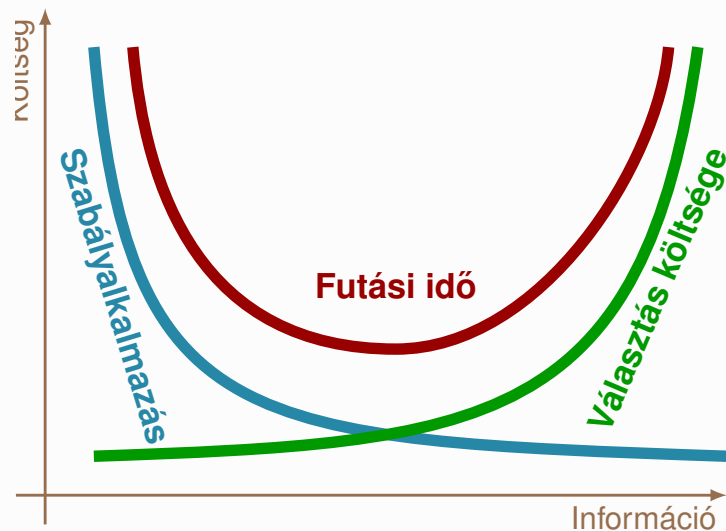
## Ismeretek osztályozása:

- deklaratív ismeret *állapot, részprobléma, axiómák*
- procedurális ismeret *művelet, dekompozíció*
- vezérlési ismeret *VAL függvény*

Közös vonás: **gráf**  $\implies$  **gráfrepresentáció.**

**ADAT** = a reprezentációs gráf egy részgráfja.  
 = „Ablak”, melyet a szabályok módosítanak, egy csúcs, egy részgráf.

## A heurisztika szerepe



No free lunch.

Nehéz a futási időt optimalizálni.  
 Közelítő megoldások „javasoltak”.

## Gráfkeresési stratégiák:

- Elsődleges stratégia
  - ▶ nem-módosítható stratégia (hegymászó, rezolúció)
  - ▶ módosítható stratégia (szabályok választása)
- másodlagos stratégia – figyelembe veszi az adott reprezentációt.


## Módosítható stratégiák:

- visszalépéses keresés – BackTracking
- gráfkereső – GraphSearch

## Négyes hanoi torony

## Opc. feladat


A **háromszlopos hanoi torony**nál az első oszlop korongjait kell egyenként áthelyezni a második oszlopra úgy, hogy mindhárom oszlopon a korongok lentől felfele csökkenő sorrendben legyenek.



Három oszlop esetében  $N$  korong áthelyezéséhez szükséges lépések száma  $2^N - 1$ .  
 A feladatot módosítjuk úgy, hogy egy negyedik oszlopra is pakolhatunk. Ekkor a lépések száma csökken.

### Feladat

Írjunk programot mely a négy-oszlopos Hanoi toronyokat kevés lépésszámmal oldja meg.



(5 pont)

Opcionális feladat

## A WhiteSmoke "szövegértő" szoftvere.

„Előfordul, hogy jól beszélünk angolul, ám fontos leveleinkbe becsúsznak hibák és a címzett az eredeti szándéktól különbözőnek olvashatja mondandónkat. Egy izraeli szoftver a **helyesírás**on és a **nyelvtanon túlmutató megoldást kínál.**”

Míg például a Word helyesírási és nyelvtani ellenőrzője csak e két területen hatékony, addig jelen szoftver lényegesen többet tud: a szöveget **mesterséges intelligencia segítségével** fűrkészi át, majd azt pontosabbá, egyértelműbbé és folyékonyabbá tevő javaslatokkal áll elő. (azaz **?kozmetikáz?**)

agent.ai

## Gráfkereső stratégiák

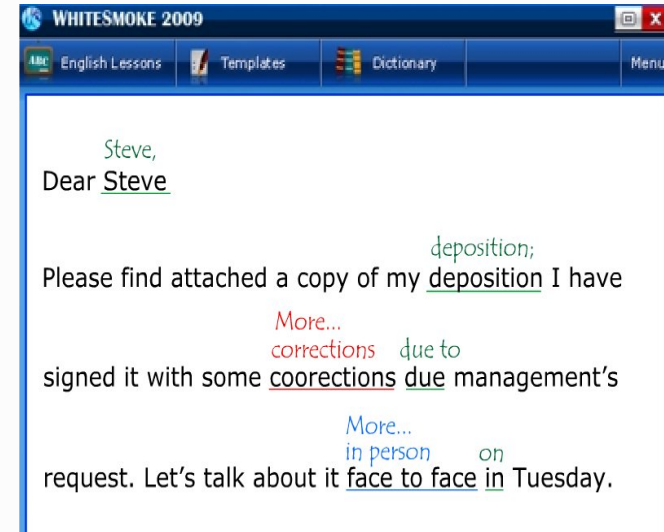
### Egy korai M.I. terület - külön tudományággá fejlődött

Nagyon sok feladatot lehet gráfokkal reprezentálni: a **gráfrepresentáció** az algoritmusok keresési tere.

- 1 irányított gráfok
- 2 ÉS/VAGY gráfok

### Példák:


- ▶ Hanoi tornyok reverzibilis lépések – irányítatlan gráf
- ▶ Irányított gráf?



## Irányított GRÁFOK

### Jelölés:

- $N$  – csúcsok (nodes)
- $A$  – élek  $A \subset N \times N$  (adjacency)
- szülő** – 1 a 2-nek
- utód** – ...
- $c(n, m)$  – költség



### Tulajdonságok:


$\sigma$ -tulajdonság:  $\exists \sigma \forall n \{ \{m | (n, m) \in A \} \leq \sigma$

$\delta$ -tulajdonság:  $\exists \delta > 0 \forall (n, m) \in A \ c(n, m) \geq \delta$

# Gráfok ábrázolása

$\delta$ -gráfok = a  $\delta$  és  $\sigma$  tulajdonsággal rendelkező gráfok.

$\times$	1	2	3	4	5	6	7
1	.	1	.	.	.	.	.
2	.	.	1	.	.	.	.
3	.	.	.	1	.	.	.
4	.	.	1	.	.	.	1
5	1	.	.	.	.	.	1
6	1	.	.	.	1	.	.
7	1	.	1	.	.	.	.



**Konvenció:** amennyiben nem specifikáljuk, az él bejárásának a költsége **1**.

## Optimális út

**Optimális költség:** az  $n$ -ből az  $m$ -be

$$c^*(n, m) = \min_{\alpha \in \{n \rightarrow m\}} c^\alpha(n, m)$$

**Optimális út:** az  $n$ -ből az  $m$ -be

$$\alpha^*(n, m) = \arg \min_{\alpha \in \{n \rightarrow m\}} c^\alpha(n, m)$$

?

- Létezik mindig – optimális – út?
- Amennyiben **igen**, egyedi?

nem. Ekkor az út hossza  $\infty$

nem -  $\delta$ -gráf

# Írányított utak


**Írányított út – út:** az  $n$ -ből az  $m$ -be

Ha  $\exists n_1, \dots, n_k$  úgy hogy  $\{(n, n_1), \dots, (n_k, m)\} \in A$ .

Út:  $\alpha = (n = n_0, n_1, \dots, n_k = m)$

Út költsége

$$c^\alpha(n, m) = \sum_{j=1}^k c(n_{j-1}, n_j)$$



**Példa:**  $\alpha = (6, 5, 7, 3, 4, 3, 4, 7, 5, 1, 2)$  költsége **10**.

## Írányított Fa

**Írányított fa:** gráf, melyben egy kitüntetett csúcsból - a **gyökérből** - minden más csúcsba csak **egy** út vezet.

A gyökérbe nem vezet él.

**Levél** – csúcs, melyből nem vezet ki él.

Tulajdonságok:

- Bejárása egyszerű;
- Nem minden feladat ábrázolható **faként**.

# ÉS/VAGY gráfok

## ÉS/VAGY gráfok

Olyan irányított **hipergráfok**, melyekben egy hiperél egy csúcsból egy **csúcshalmazba** vezet.


$$R(N, A) \quad \text{ahol} \quad A \subseteq \{(n, M) \in \mathbb{N} \times 2^N \mid 0 \neq |M| \leq \infty\}$$

Hiperélek:

- (1, {2, 3})    (1, {4})
- (2, {5, 6})    (3, {7})
- (4, {6, 7})    (7, {6})

Élköltség:  $c(n, M)$

**Kérdés:**  $\sigma$  és  $\delta$  tulajdonságok



▶ G

# ÉS/VAGY gráfok átalakítása


ÉS/VAGY gráfok kezelése nehézkes.

Átalakíthatóak **irányított gráfokká**.

**Új csúcsok bevezetése:** utódcsúcs = átalakítandó hiperél utódainak halmaza.

A fenti műveletet kiterjesszük a kezdőcsúcstól a célig.

**Feladat:** az  $1 \rightarrow \{5, 6\}$  egy hiperútjának megfelelő gráfátalakítás.



# Hiperutak ÉS/VAGY gráfokban

## Írányított hiperút $(n, M)$ között


Részgráf, melyben mindegyik csúcsból legfeljebb egy hiperél indul ki.  $M$ -ből nem indul hiperél.

Hiperutak  $1 \rightarrow \{5, 6\}$ :


(1, {2, 3}), (2, {5, 6})

(1, {2, 3}), (3, {6}),

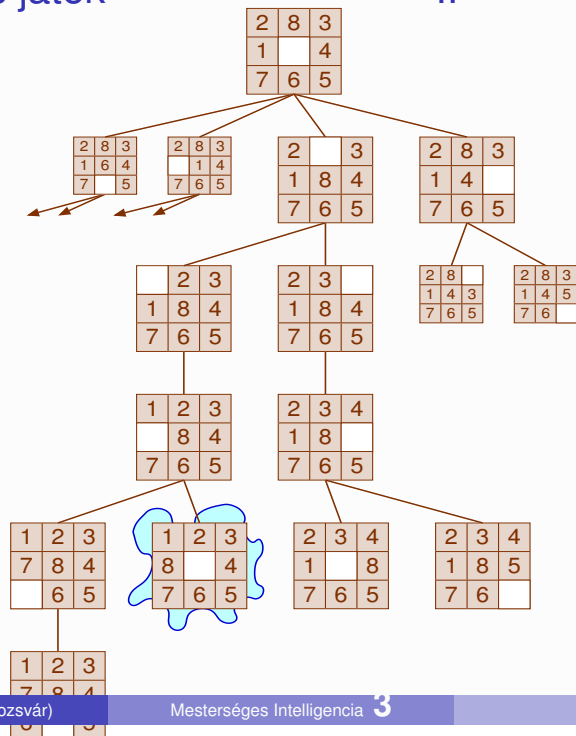
(1, {4}), (4, {5})



# 8-as kirakós játék



- **Kódolás:** 9 hely –  $9! = 362880$  lehetőség.
- **Üres hely mozgatása** – meghatároz egy állapotgráfot.



## Gráfkereső algoritmusok

I

### Nem-módosítható keresések:

Egy lépést – szabályt – nem lehet visszavonni.

#### 1 Hegymászó algoritmus (hill-climbing)


- ▶ kritérium-függvény, mely „vezérli” az algoritmust.
- ▶ nem-determinisztikus
- ▶ gond a **lokális minimum** jelenléte

#### 2 Kommutatív rendszerek (commutative systems)

- ▶ a **D**-re alkalmazható szabályok alkalmazhatóak a **D** leszármazottjaira is.
- ▶ a **D**-ből előállított adatbázis független a műveletek **sorrendjétől** – felcserélhető.
- ▶ ha a **D** kielégíti a terminálási feltételt, akkor annak minden leszármazottja is.

Nincs bonyolult stratégia. Heurisztika  $\Rightarrow$  hatékonyság.

- $4 \times 4$ -es táblán 4 királynőt elhelyezni.
- **Állapot:** sakk-állások 1 – 4 királynővel.
- **Művelet:** egy királynő egy mezőre helyezése.
- **Kezdőállapot:** üres sakktábla.
- **Célállapot:** 4 királynőt tartalmazó sakktábla.



## Visszalépés

I

- Egy **utat** tart nyilván a reprezentációs gráfból.
- Induló érték: **start-csúcs**.

Vezérlési stratégia – visszalépés alkalmazása ha:

- 1 nincs több él – **zsákutca**;
- 2 nincs több „jó út” – **vágás**;
- 3 minden továbbvezető útról visszaléptünk – **torkolat**;
- 4 egy már bejárt csúcshoz jutunk – **kör**;
- 5 túl hosszú a bejárt út – **mélységi korlát**.

Visszalépés ha

- 1 nincs több él – **zsákutca**;
- 2 nincs több „jó út” – **vágás**;
- 3 minden továbbvezető útról visszaléptünk – **torkolat**;
- 4 egy már bejárt csúcshoz jutunk – **kör**;
- 5 túl hosszú a bejárt út – **mélységi korlát**.

### Tétel

A visszalépéses algoritmus az (1) és (2) feltételekkel terminál **véges és körmentes** gráfokon.

## Bűvös négyzetek I

### 1. laborfeladat

**Feladat:** ábrázoljuk a bűvös négyzetek keresését gráf-kiterjesztési feladatként:

- építsük fel a feladat állapotterét; definiáljunk egy gráfot a helyes megoldásokat eredményező kitöltések folyamataként;
- definiáljunk egy gráf-kiterjesztési procedúrát;
- keressük meg az összes lehetséges megoldást gráfkereső (?backtracking?) módszerrel.

**Bűvös négyzet:** az az  $N \times N$ -es négyzet, melyben az elemek száma megegyezik sorok és oszlopok szerint.

$$S_{\text{sor}} = \frac{1}{N} \sum_{n=1}^{N^2} n = \frac{1}{N} \cdot \frac{N^2 (N^2 + 1)}{2} = \frac{N (N^2 + 1)}{2}$$

Visszalépés ha

- 1 nincs több él – **zsákutca**;
- 2 nincs több „jó út” – **vágás**;
- 3 minden továbbvezető útról visszaléptünk – **torkolat**;
- 4 egy már bejárt csúcshoz jutunk – **kör**;
- 5 túl hosszú a bejárt út – **mélységi korlát**.

### Tétel

A visszalépéses algoritmus az (1)–(5) feltételekkel **mindig** terminál. Ha létezik a mélységi korlátnál nem hosszabb megoldás, **megtalálja** azt.

## Bűvös négyzetek II

### 1. laborfeladat

#### Követelmények:

- Dokumentáció, mely tartalmazza a
  - 1 **paraméterterét** a feladatnak,
  - 2 a gráf-kiterjesztés lépéseit,
  - 3 a gráf-bejárás sorrendjét.
- Program, mely az  $N$  szám ismeretében kiírja (pl. egy TXT állományba) az összes megoldást valamint kiírja a képernyőre a megoldások számát.

A bemutatás személyesen történik – valamely futtatási környezetben – úgy, hogy a programban módosítani lehessen paramétereit.

(8 pont)

*Kötelező feladat*



## Bűvös négyzetek II

## Példa

Example:


93	108	123	138	153	168	1	16	31	46	61	76	91
107	122	137	152	167	13	15	30	45	60	75	90	92
121	136	151	166	12	14	29	44	59	74	89	104	106
135	150	165	11	26	28	43	58	73	88	103	105	120
149	164	10	25	27	42	57	72	87	102	117	119	134
163	9	24	39	41	56	71	86	101	116	118	133	148
8	23	38	40	55	70	85	100	115	130	132	147	162
22	37	52	54	69	84	99	114	129	131	146	161	7
36	51	53	68	83	98	113	128	143	145	160	6	21
50	65	67	82	97	112	127	142	144	159	5	20	35
64	66	81	96	111	126	141	156	158	4	19	34	49
78	80	95	110	125	140	155	157	3	18	33	48	63
79	94	109	124	139	154	169	2	17	32	47	62	77

## Sudoku

## 2. laborfeladat

A sudoku-ban számokat helyezünk el egy  $n^2 \times n^2$  méretű négyzetrácsban. Az  $\{1, \dots, n^2\}$  számokat úgy helyezzük el  $n^2$ -szer úgy, hogy egy oszlopban, egy sorban és minden kisebb négyzetben egy szám **egyszer** szerepeljen (lásd ábra).

- Az  $n = 2$ -re mi a paraméter-tér? **1p.**
- Jelenítsük meg „szépen” a megoldásokat az  $n = 2$  és  $n = 3$  esetekre. **1p.**
- Az  $n = 2$  esetre generáljuk az összes megoldást. **1p.**



- Találjuk meg egy részlegesen kitöltött feladat kitöltött változatát. **3p.**

- × **Generáljunk** egy sudoku rejtvényt: egy részlegesen kitöltött feladat, melynek **csak egy** megoldása van. **4p.**

(10 pont)

Kötelező feladat

## Bioinformatika

### A számítástudomány és a molekuláris biológia között<sup>2</sup>

#### David Haussler & Judea Pearl

Kifejlesztették az emberi genomot feltérképező programokat. A lehetőséget a számítógép- technológia és a biokémia fejlődése biztosította. A genom biológiai összetevőinek felderítését és elemzését a tudós által kidolgozott **valószínűségi megközelítés** alapozta meg.



Az emberi génállomány mintegy **hárommilliárd alappárt** képez: a kettős spirál-alakú DNS négy alap-nukleotidból (**A, C, G, T**) épül fel; Minden egyes nukleotid része egy párnak. A mennyiség nagyon nagy, a munka csak számítógépes módszerekkel végezhető el.

agent.ai

<sup>2</sup>Pearl J (2000): **Causality**: Models, Reasoning, and Inference, The CUP Press

## Bioinformatika

2001. júliusában közzétették a módszer vázlatát, majd az emberi és egyéb organizmusok (egér, patkány, stb.) génszekvenciáit elemző, jegyzetekkel ellátott interaktív webalapú keresőket fejlesztettek.


Tudományos fórumot teremtettek, míg programjaikat gyakran használják különböző biomedikális kutatásoknál, kísérleteknél.

#### A gének evolúciója

A CBSE kutatásai az interdiszciplináris megközelítés jegyében folynak. Biológia, információs és nanotechnológia fúziójára, minél kisebb szerkezetek létrehozására törekednek.

Az emberi genom evolúciójának jobb megértése az egyik fő irány: a cél érdekében permanensen fejlesztik az új statisztikai és algoritmikus módszereket.





## Feladatok:

- egy megoldás megtalálása
- minimális út keresése

## Módszerek:

- Heurisztika

# Alapalgoritmus

II

**Kommutatív rendszer** – a kiterjesztések bármilyen sorrendben végrehajthatók.

⇒

- A vezérlési stratégia nem informatív,
- Másodlagos stratégia ⇒ továbblépés.

Módosítás:

$$n \leftarrow \underset{m \in \text{NYILT}}{\text{argmin}} f(m)$$

ahol  $f : \text{NYILT} \rightarrow \mathbb{R}$  kiértékelő függvény, amely

- egy csúcs „jósága”,
- pl. az  $s$ -ből  $m$ -be vivő legkisebb út hossza.
- ⇒ dinamikus függvény.

(felületes def.)

# „Alapalgoritmus\*”

I

(\* – Futó: Mesterséges Intelligencia, 73.o)

Visszalépés – backtracking – hátránya, hogy **nem** találja meg az optimális utat.

## Gráfkereső algoritmus:

- a startcsúcsból indul  $s$
  - feltárja a reprezentációs gráfot  $G$ 
    - 1 kiválaszt egy csúcsot, melynek utódai nem ismertek,  $n \in \text{NYILT}$
    - 2 kiterjeszti a választott csúcsot  $G \leftarrow G \cup \Gamma(n)$
- $\text{NYILT} \leftarrow \text{NYILT} \setminus \{n\}$   
 $\text{NYILT} \leftarrow \text{NYILT} \cup \Gamma(n)$
- addig keres, amíg egy célcsúcsot nem talál és van kiterjeszthető csúcs.

# Alapalgoritmus

III

Bevezetjük:

- kitüntetett **szülő csúcsot** (parent)  $p : G \rightarrow G$   
(az  $s$ -ből **egy** utat specifikál).  $p(s) = \text{nil}$
- **költségfüggvényt:**  $g : G \rightarrow \mathbb{R}$   
 $g(m)$  az  $s$ -ből  $m$ -be vivő út költsége.

Az  $n$  csúcs minden  $k$  utód-csúcsára  $\forall k \in \Gamma(n)$ :

- Ha  $k$  új csúcs, vagy  $k \notin G$
  - Ha nem új **és**  $g(k) > g(n) + c(n, k)$ , akkor  $k \in G$
- $p(k) \leftarrow n$   
 $g(k) \leftarrow g(n) + c(n, k)$

**Probléma:**

- ha  $k$  zárt,
- korábban megkerestük utódjait
- és rövidebb utat találtunk,

⇒

- a  $g, p$  függvények nem helyesek a  $k$  utódain;
- a feszítőfa nem optimális.

**Megoldások:**

- 1  $k$  **összes** leszármazottját újraértékeljük;
- 2 a  $k$  **csúcsot visszatevük a NYILT halmazba.**  
Hátrány:
  - ▶ Nagyobb futási idő;
  - ▶  $p$  nem mindig optimális.
- 3 Olyan  $f$  választása, mely garantálja, hogy **nem lesz ilyen  $k$ .**

Az általános algoritmus tulajdonságai  
Tulajdonságok

## Az általános gráfkereső algoritmus

- egy csúcsot véges sokszor terjeszt ki;
- véges gráfban mindig terminál;
- mindegyik  $n \in NYILT$  csúcs kiterjesztése előtt  $\forall s \rightarrow^* n$  van  $m$  csúcs az optimális úton, mely
  - 1  $m \in NYILT$ ,
  - 2  $g(m) = g^*(m)$ ,
  - 3 minden  $m$ -et előző csúcs az úton **zárt**;
- Egy véges gráfban, ha létezik megoldás, akkor az algoritmus egy célcsúcs megtalálásával terminál.
- Csökkenő kiértékelőfüggvény használata mellett optimális és konzisztens a feszítőfa.

Bizonyítás


- $G \leftarrow \{s\}$ ,  $NYILT \leftarrow \{s\}$ ,  $g(s) \leftarrow 0$ ,  $p(s) \leftarrow nil$ .
- While **nem ures**(NYILT),
  - $n \leftarrow \arg \min_{m \in NYILT} f(m)$
  - If **cél**( $n$ ) then **kilép**.
  - $NYILT \leftarrow NYILT \setminus \{n\}$
  - For  $\forall k \in \Gamma(n)$ 
    - If  $k \notin G$  or  $g(k) > g(n) + c(n, k)$ 
      - $p(k) \leftarrow n$
      - $g(k) \leftarrow g(n) + c(n, k)$
      - $NYILT \leftarrow NYILT \cup \{k\}$
  - endfor
  - $G \leftarrow G \cup \Gamma(n)$
- endwhile

## Nevezetes gráfkereső algoritmusok

*Futó: Mesterséges Intelligencia – pp. 83*

- Nem-informált gráfkeresések
  - 1 Mélységi keresés
  - 2 Szélességi keresés
  - 3 Egyenletes keresés
- Heurisztikus keresések
  - 1 Előretekintő keresés
  - 2  $A$  algoritmus
  - 3  $A^*$  algoritmus
  - 4  $A^c$  algoritmus

## Példa gráfkeresésre



### A harmadik iteráció végén tehát

- a zárt csúcsok halmaza {1, 4, 5};
- a nyílt csúcsok halmaza {2, 3, 6, 7, 8};
- a szülő-függvény (z, p(z)) párok:  
 {(2, 1), (3, 1), (4, 1), (5, 4), (6, 4), (7, 5), (8, 5)}


## Mélységi keresés

- Mindig a legmélyebben fekvő nyílt csúcsot választjuk,
- Ha minden él költsége ugyanannyi (pl.  $c(m, n) = 1$ ), akkor a kiértékelő függvény:

$$f(n) = -g(n) \quad \forall n \in \text{NYILT},$$

- Szükséges (? – mikor) a mélységi korlát bevezetése,
- Az algoritmus nem mindig talál megoldást,
- Iteratív növelése a mélységi korlátnak – megoldást talál (?optimális?).

## Példa gráfkeresésre




A következő csúcs kiválasztása a nyílt halmazból **bármilyen** kritérium alapján történhet. A kritérium alapja az  $f(\cdot)$  függvény.

A függvény megválasztásával különböző **keresési stratégiák**hoz jutunk.


## Mélységi keresés

### Kiterjesztési sorrend:



## Példák


### Ellenpélda:



- Ha megjegyezzük a csúcsokat: A, B, D, F, E, C, G;
- Ha nem: A, B, F, E, A, B, ...

## Szélességi keresés

- A mélységi keresés ellentettje,
- Mindig a legmagasabban fekvő nyílt csúcsot választjuk,



- Ha minden él költsége ugyanannyi (pl.  $c(m, n) = 1$ ), akkor a kiértékelő függvény:

$$f(n) = g(n) \quad \forall n \in \text{NYILT}$$

- Az algoritmus **mindig** talál megoldást – amennyiben ez létezik.

## Előretekintő keresés

- Heurisztikus kereső algoritmus,
- A kiértékelő függvény **csak** a heurisztika:

$$f(n) = h(n) \quad \forall n \in \text{NYILT}$$

- $h(n)$  – heurisztikus függvény.
- pl.  $f(n) = W(n)$  – a 8-as kirakójátékban;
- A keresőgráf kisebb, mint az egyenletes keresés esetében;
- A keresőgráf **nem optimális**;
- Erősen függ a választott keresőfüggvénytől.

## Egyenletes keresés

- Súlyozott változata a szélességi keresésnek,
- A kiértékelő függvény (általános  $c(m, n)$  esetén):

$$f(n) = g(n) \quad \forall n \in \text{NYILT}$$

- Az algoritmus **mindig** talál megoldást – amennyiben ez létezik,
- Dijkstra algoritmus (1959).

## „A” algoritmus

*Futó: Mesterséges Intelligencia – pp. 90*

„... ötvözi az egyenletes keresés óvatosságát az előretekintő keresés célratörésével, egyesítve előnyös tulajdonságait.”

- Kiértékelő függvény:

$$f(n) = g(n) + h(n) \quad \forall n \in \text{NYILT}$$

ahol  $h(n) > 0$ .

- $h(n)$  „becsüli” az  $n$ -ből a cél-csúcsba vivő optimális út költségét.

## „A” algoritmus tulajdonságai

### Tulajdonságok

- $f^*(n) = g^*(n) + h^*(n)$  - a **start**ból a **cél**ba az  $n$ -en keresztül vivő optimális út költségének a becslése.
- Ha az  $A$  algoritmus **nem** terminál, akkor minden **NYILT** halmazba került csúcs véges sok lépés után kiterjesztésre kerül.
- Az  $A$  algoritmus mindig talál megoldást feltéve, hogy létezik megoldás.

## „A<sup>c</sup>” algoritmus

- **Korlátozás a heurisztikus függvényre:**  
 $h(n)$  kielégíti a monoton megszorítás (monotone restriction) feltételét, ha

$$h(n) - h(m) \leq c(n, m) \quad \forall (n, m) \in A$$

- Egy  $n$  csúcs **nem** kedvezőtlen, ha egy utód  $m$  csúcs nagyon kedvező.
- **A<sup>c</sup> algoritmus:** az olyan  $A$  algoritmus, ahol  $h(n)$  monoton megszorításos és  $h(t) = 0$  minden terminális csúcsra.

## „A\*” algoritmus

- $A$  algoritmus kiértékelő függvénye, ahol
- $A$  heurisztikus függvény bármely csúcsban alulról becsüli a a célba vezető optimális út költségét, azaz

$$h(n) < h^*(n) \quad \forall n \in G$$

- A fenti kritérium a heurisztika **megengedhetősége**.  
*Egy gráfkereső algoritmus megengedhető, ha megoldás létezése esetén megtalálja az optimális megoldást.*

### A\* tulajdonságai

- Bármely kiterjesztésre választott csúcsra  $f(n) \leq f^*(n)$ .
- Mindig optimális megoldással terminál, feltéve ha az létezik.

## „A<sup>c</sup>” algoritmus tulajdonságai

### A<sup>c</sup> tulajdonságai

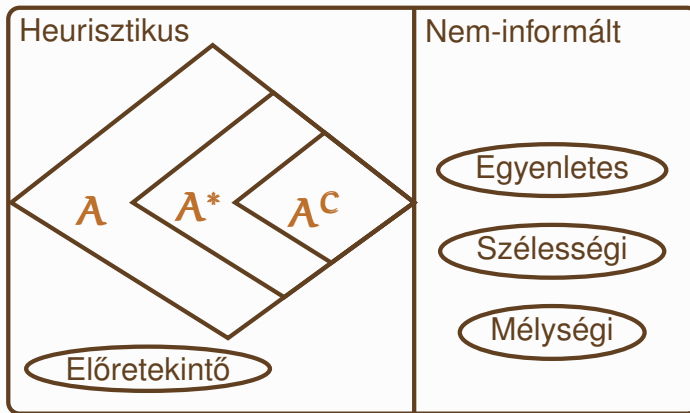
- Ha teljesül a monoton megszorítás, akkor egy  $n$  csúcsba vezető optimális út mentén a  $g + h$  növekvő.
- Bármely  $n$  kiterjesztésre választott csúcshoz az optimális út van megjelölve:

$$g(n) = g^*(n)$$

- Mindig optimális megoldással terminál, feltéve ha az létezik.

## Gráfkereső összefoglaló

- a heurisztika **nagyon fontos** – egy algoritmus alkalmazhatósága a választott heurisztikán áll vagy bukik.



## Blogbányászat

### Ok-okozati viszonyokat tanul a gép

Amerikai kutatók<sup>3</sup> blogok elemzésére tanítják rendszerüket, mely **történetmesélésre** összpontosítva, nyelvi jegyek alapján szelektál közülük. A gyűjtött adatokból a kialakuló trendekre és viselkedésformákra következtet a rendszer.

### A „tanítás” menete:

- 1 Blog-bejegyzéseket osztályoztak **manuálisan** a történet / nem történet osztályokba. **Eredmény:** a **narratívák** azonosítása.
- 2 A történetek elemei között az **oksági kapcsolatok** keresése. PI: késő volt, lefeküdtem. **Eredmény:** tények + oksági kapcsolatok.

### A rendszer sosem unatkozik

Távlati cél egy rendszer kidolgozása, mely napi rendszerességgel gyűjt és rendszerez adatokat. Ez fontos, mert más forrásokból hozzáférhetetlen, működése hasonló Google sertésinfluenza-követő programjához.

### Mire jó a blogbányászat?

A blog-ok általában azonnali reagálást jelentenek, ezért garantált a gyűjtött „bányászott” információ aktualitása. Az élet **legkülönbözőbb** területeit érintik: filmek, könyvek, termékek, nemzetiségi-, vallási ellentétek, kábítószer-kereskedelem...

<sup>3</sup> Andrew Gordon Kreatív Technológiák Intézete Link

## Opcionális feladatok

- Gyakorló feladatok gráfokkal
  - ▶ Az  $A^*$  algoritmust használva jussunk el egy  $I_1 I_2 I_3$  számból egy  $J_1 J_2 J_3$  számba.
  - ▶ Keressük meg az  $\{1, \dots, N\}$  halmaz  $k$  részbe való felosztását.
  - ▶ Fejtsük meg a **SEND + MORE = MONEY** feladatot.(10 pont)
- Írjunk programot, mely megoldja a háromszög-kirakós játékot. (12 pont)
- Rubik-kígyó megoldása. (10 pont)

<http://.../feladatok/labor.pdf>

## Szemantikus hálók

Futó: Mesterséges Intelligencia, pp. 186

### Szemantikus háló:

- az emberi információtárolás és keresés modellezése (Quillian & Collins);
- gyakori név az **asszociatív háló**.
- kognitív pszichológiai kísérletek az „alapjai”;

### Tulajdonságok:

- objektumokhoz tulajdonságokat rendelünk;
- **hierarchia** az objektumok szintjén  $\Rightarrow$  **absztrakció**
- a tulajdonságok a legfelsőbb szinten asszociálódnak.

**Kísérlet:** kérdések a madarokról és a reakcióidők mérése.

Kérdések:

- 1 Tud-e a kanári énekelni? 1.3mp
- 2 Tud-e a kanári repülni? 1.4mp
- 3 Van-e a kanárinak bőre? 1.5mp

**Hosszabb asszociációs lánc** az utolsó kérdésnél.

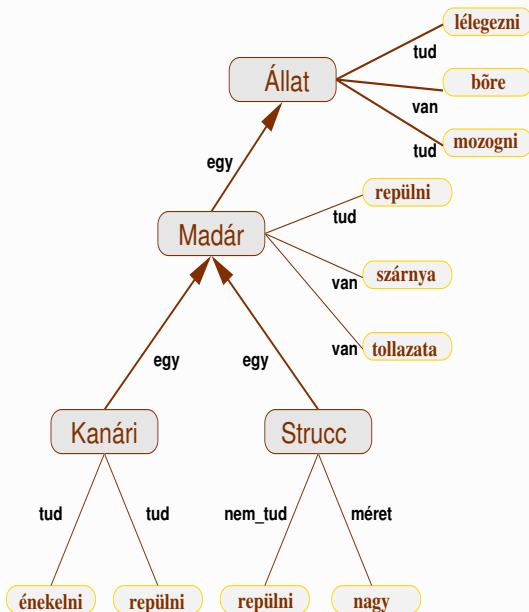
**Magyarázat:** egy szemantikus hálóban a **bőre** és az **énekel** tulajdonságok nem egyforma távolságra vannak a **kanári**-tól.

## Kanári szemantikus háló

### Szemantikus háló:

Írányított gráf, ahol

- **Csúcsok:** objektumok, objektumosztályok és tulajdonságok értékei;
- **Élek:** a csúcsok közötti kapcsolat neve.



### Szemantikus háló:

- az emberi információtárolás és keresés modellezése (Quillian & Collins);
- gyakori név az **asszociatív háló**.
- kognitív pszichológiai kísérletek az „alapjai”;

Tulajdonságok:

- objektumokhoz tulajdonságokat rendelünk;
- **hierarchia** az objektumok szintjén ⇒ **absztrakció**
- a tulajdonságok a legfelsőbb szinten asszociálódnak.

## Wordnet

## Nagy szemantikus háló

### Noun

- **S: (n) canary, canary bird** (any of several small Old World finches)
  - **S: (n) finch** (any of numerous small songbirds with short stout bills adapted for crushing seeds)
  - **S: (n) oscine, oscine bird** (passerine bird having specialized vocal apparatus)
  - **S: (n) passerine, passeriform bird** (perching birds mostly small and living near the ground with feet having 4 toes arranged to allow for gripping the perch; most are songbirds; hatchlings are helpless)
  - **S: (n) bird** (warm-blooded egg-laying vertebrates characterized by feathers and forelimbs modified as wings)
    - **S: (n) vertebrate, craniate** (animals having a bony or cartilaginous skeleton with a segmented spinal column and a large brain enclosed in a skull or cranium)
    - **S: (n) chordate** (any animal of the phylum Chordata having a notochord or spinal column)
    - **S: (n) animal, animate being, beast, brute, creature, fauna** (a living organism characterized by voluntary movement)
      - **S: (n) organism, being** (a living thing that has (or can develop) the ability to act or function independently)
      - **S: (n) living thing, animate thing** (a living (or once living) entity)
      - **S: (n) whole, unit** (an assemblage of parts that is regarded as a single entity)
        - **S: (n) object, physical object** (a tangible and visible entity; an entity that can cast a shadow)
        - **S: (n) physical entity** (an entity that has physical existence)
        - **S: (n) entity** (that which is perceived or known or inferred to have its own distinct existence (living or nonliving))

<http://wordnetweb.princeton.edu>



# Feladatmegoldás szemantikus hálókkal

**Feladat:** lekérdezés megválaszolása adott tárgyköri tudással.

**Tárgyköri tudás:** egy taxonomikus hierarchia – azaz egymásba ágyazott objektumok halmaza – számítógépes reprezentációja.

Adatbázis

**Lekérdezés:** egy célháló illesztése a szemantikus hálóba.

Illesztés

# Összefoglaló – szemantikus hálók

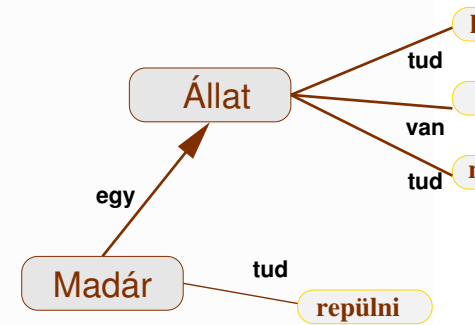
- Fogalmak és kapcsolataik modellezése.
- Asszociatív memóriák.
- Információk egyszerű reprezentációja – Ismiley! programozási paradigma jött létre.
- Ezt használjuk információ reprezentálására?

# Milyen feladatokra megfelelő

Klasszikus logika nyelvén:

$$\forall x(x \in \text{MADARAK} \Rightarrow x \in \text{REPUL})$$

Kivételek kezelése (strucc) nehézkes.



Melyik alkalmazás modellezhető szemantikus hálóval:

- játékok,
  - vízelemző rendszerek,
  - rendszerkonfigurálás
- ?

osztályozás,  
nyelvelemzés

# Definiációs hálók

Supreme genus:

Differentiae:

Subordinate genera:

Differentiae:

Subordinate genera:

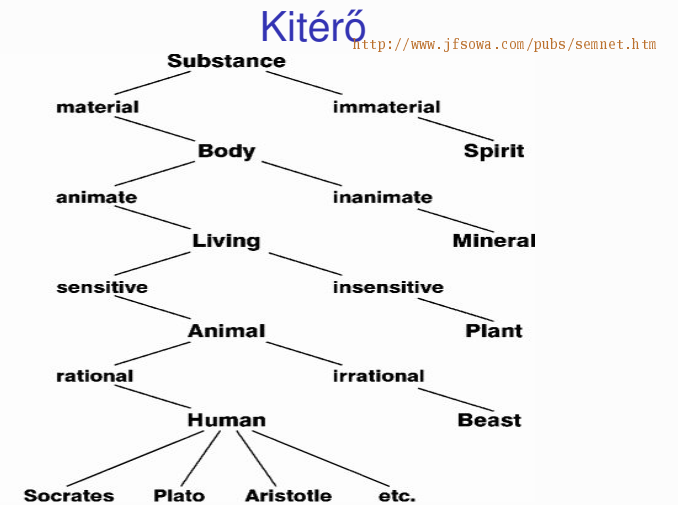
Differentiae:

Proximate genera:

Differentiae:

Species:

Individuals:



Porfirius (i.sz. 300 körül) - magyarázata Arisztotelész „Kategoría”jához.

Típus és különbözőség szerint rajzolt egy definiációs hálót, ahol alá- és fölérendelt kategóriákat különböztetett meg.

## Keretalapú Ismeretreprezentáció

Futó. pp.198

- 1975 Minsky - látás egy pszichológiai modelljének a leírása.
- A tanulmányozott világ fizikai vagy fogalmi entitásainak egy **strukturált szimbolikus** modellje.
- hasonlít a szemantikus hálókhoz – annak továbbfejlesztése.
- Új elem a **procedurális reprezentáció**.

Majdnem **OOB** - a különbség, hogy az OOB keretrendszer célja a kódolás és nem a **tudásreprezentáció**.

Level 5 Object

## Démonok

### Démonok

- Eljárások, melyeket osztályokhoz illetve azok attribútumaihoz lehet hozzárendelni.
- „paraméterezés”: mikor lépjenek működésbe (milyen esemény bekövetkeztek).

*when-needed-demon*  
*when-changed-demon*  
*when-deleted-demon*  
*when-added-demon*

Frame-rendszer működése: rendszer összes démonának együttes működése

(pl. **útkereszteződés működtetése**).

# FRAME-es reprezentáció

*frame Személy*  
*instance-of: Class*  
*azonosító: személyi*  
*vezetéknév:*  
*keresztnev:*  
*end*

*frame Főiskolás*  
*is-a: Személy*  
*közös-cím: 'hallg@foisk.hu'*  
*levél-cím:*  
*end*

*frame Kosarazó*  
*is-a: Személy*  
*havi-juttatás:*  
*end*

*frame Kosár-center*  
*is-a: Kosárlabdázó*  
*end*

*frame Kosárcsapat*  
*instance-of: Class*  
*edző: Személy*  
*játékosok: collection-of Személy*  
*end*

*frame Főiskolás-kosárcsapat*  
*instance-of: Kosárcsapat*  
*edző: Oktató*  
*játékosok: collection-of Főiskolás*

*frame Szöcskék*  
*instance-of: Főiskolás-kosárcsapat*  
*játékosok: Péter, Tamás, ...*  
*end*

*frame Péter*  
*instance-of: Főiskolás*  
*instane-of: Kosár-center*  
*levél-cím: 'peter@foisk.hu'*  
*magasság: 193*  
*havi-juttatás: 10000*  
*end*

## FRAME-ek tulajdonságai

- Egy keret **vagy** osztály **vagy** példány. Különbség az **is-a** illetve az **instance-of** között.
- **Többszörös öröklődés** - amikor egy osztály lehet több osztálynak az utóda.
- Példányok a hierarchia alján - nem lehet tovább példányosítani.

Mi történik egy hiányos osztályleírás esetén?  
A rendszer a megszorítások alapján

- kiegészíti
- vagy nem

a hiányzó információkat (pl. **Péter** nem főiskolás).

... *problems arising when we try to plan ahead in presence of hostile agents*  
 ... *Russell&Norvig, pp. 122*

- Babbage (1846) - gépet tervez, mely **Tic-tac-toe**-t játszik,
- Leonardo Torres y Quevedo (1890) - sakk végjáték,
- von Neumann & Morgenstern (1944) - *Theory of games and Economic Behaviour*
- Shannon és Turing (1950) - sakkprogram, **mert**
  - 1 „intelligencia” szükséges a játékhoz,
  - 2 egyszerű szabályok,
  - 3 teljes informáltság,
- McCarthy (1956) - vágások.

## Játékok típusai

	determinisztikus	valószínűségi
Teljes információs	sakk, go	Dáma, Monopoly
Részleges információs	battleship	bridge, póker

?? Kupacos játék - Maya.

# Játékok és keresés

„Ismeretlen” ellenfél:

- Nem ismerjük a lépéseit,
- Feltételezzük, hogy nyerni akar.

**Válasz:** egy **stratégia**, mely az ellenfél minden lehetséges lépését figyelembe veszi.

Sakk-program esetében: nincs lehetőség az **összes** lehetőség vizsgálatára ⇒ szükségesek a közelítések.

*Mit közelítünk?*

## Kétszemélyes játékok

**Kétszemélyes teljes információs játékok:**

- két játékos lép felváltva, **adott** szabályok szerint;
- a játékosok minden információval rendelkeznek;
- minden állapotban véges számú lépés létezik;
- véges a játszma ideje;
- az egyik játékos mindig nyer (esetenként lehetséges döntetlen...)

Ezzel a játékosztállyal foglalkozunk.

**Formális definíció:**

- Két játékos, legyen **MAX** illetve **MIN**;
- **MAX** kezd;
- ismert kezdőállapot;
- műveletek, melyek leírják a lehetséges lépéseket;
- játék végének a tesztje;
- nyereség-függvény;

**Stratégia:** szabály az egyik – **MAX** – játékos optimális lépéseinek megadására.

**Nim játék**

A játék állásai:

- **Nyerő** – ha a játékos tud úgy lépni, hogy az ellenfél lépéseitől függetlenül nyer;
- **Vesztő** – ha **nincs nyerő lépés**.

Nyerő stratégia:

$$\begin{array}{r}
 0 \ 0 \ 1 \ 1 \ = \ 3 \\
 0 \ 1 \ 0 \ 1 \ = \ 5 \\
 1 \ 0 \ 0 \ 0 \ = \ 8 \\
 \hline
 1 \ 1 \ 1 \ 0 \ \text{(XOR)}
 \end{array}$$



**Állítás:** azon állások vesztek, melyekre az **XOR** csupa nullát eredményez.

**Nim játék**

**Nim** = „nip” + „muster”

Játék:

- gyufaszálak több sorban;
- adott gyufaszál minden sorban;
- lépés = **egy** sorból valahány gyufaszál elvétele;
- játék vége: elfogynak a gyufaszálak;
- veszít az a játékos, mely már nem tud gyufaszálat felvenni.

$$\begin{array}{l}
 m \\
 [n_1, \dots, n_m] \\
 i \\
 0 \leq n'_i < n_i \\
 \forall i; n_i = 0
 \end{array}$$

**Változatok:** vesztes az utolsó gyufaszálat felvevő; nem lehet tetszőleges számú elemet felvenni, *etc.*

**Nim játék tulajdonságai**

**Állítás:** azon állások vesztek, melyekre az **XOR** csupa nullát eredményez.

**1. Lemma**

Ha egy állásban az **XOR** nem csupa nullát eredményez, akkor van lépés, mely az **XOR** szerint nullát eredményez.

**2. Lemma**

Ha egy állapotban az **XOR** csupa nulla, akkor **nincs** lépés, mely eredményeként az **XOR** nulla lesz.

**Nyerő stratégia**

Ha **XOR** nem nulla, akkor le tudjuk nullázni **és** az ellenfél nem tud olyat lépni, hogy számunkra megint nulla legyen.

⇒ **nyerő stratégia.**

# Nim játék példa

Kezdeti állapot:

$$\begin{array}{r}
 0\ 0\ 1\ 1 = 3 \\
 0\ 1\ 0\ 1 = 5 \\
 1\ 0\ 0\ 0 = 8 \\
 \hline
 1\ 1\ 1\ 0 \quad (\text{XOR})
 \end{array}$$

Válasszuk az utolsó (8 elemes) sort.  
Ahhoz, hogy mindenhol 0 legyen

$$0\ 1\ 1\ 0 = 6$$

kell maradjon, tehát 2 elemet kell elvenni.

Az új pozíció **vesztes**.




# Nim játék gráfja

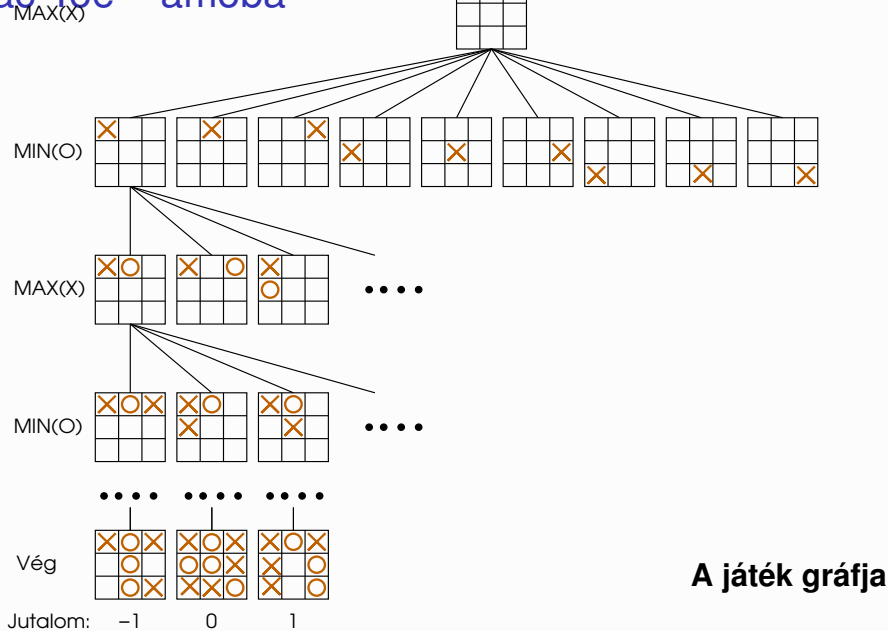
- játék gráfja véges mélységű;

**Nyerő stratégia:**

- mindig van legalább egy olyan lépés, melyből győzni tud;
- függetlenül attól, hogy az ellenfél mit lép;



# Tic-Tac-Toe – amőba



# Nyerő stratégia létezése

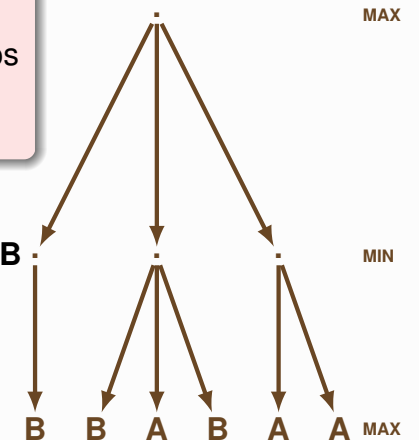
## Tétel

Egy teljes információjú kétszemélyes játék esetén mindig létezik egy játékos számára nyerő stratégia (ha nincs döntetlen).

## Bizonyítás:

Az élek címkézése letről felfelé. Ha **B** lép,

- $\exists$  ág, mely **B**-vel van címkézve, akkor **B**,
- ellenkező esetben **A**.



**Kuglizás** – ahol az összes bábú egy sorban van, tehát **csak** egy vagy két – *egymásmelletti* – bábút tudunk leütni.  
Vesztes, akinek először nem marad bábúja.

**Feladat:**

- Határozzuk meg a játék állapotterét  $k = 3$  egymásmelletti bábúra;
- Határozzuk meg, hogy az kezdő játékos nyer vagy veszít.
- Számítsuk ki, hogy a kezdő játékos nyertes-e  $k = 5$  egymás-melletti bábú esetén.
- Írjunk programot, mely meghatározza, hogy a kezdő játékos nyer-e tetszőleges konfigurációnál.

## Minimax algoritmus

**Minimax algoritmus:**

- bonyolultabb játékok esetén használják;
- nem építhető meg a teljes játékfa;
- **nem talál biztosan nyerő** stratégiát;
- „erős” vagy „elég jó” lépés;

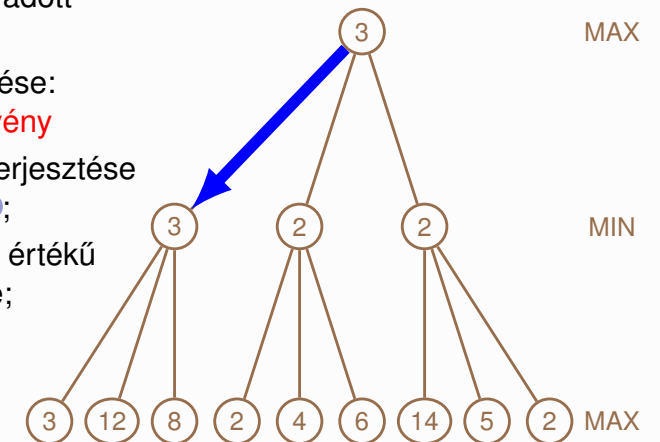
Közelítéseket adunk a nyerő/vesztes értékelés helyett.

## Stratégiák keresése

- Stratégia nem kereshető mert a teljes gráf nem fér el a memóriában;
  - túl sok állapot.
  - Sakk:
    - ▶  $\approx 45$  lépés tehát 90 mélységű fa,
    - ▶  $\approx 35$  lehetőség;
    - ▶  $35^{90} = 10^{139}$  levél.
- $10^{80}$  összes elektron
- **Deep Blue** – 32CPU  $\times$  8 dedikált sakk-processzor (13-30 mélységig; 30 milliárd lépés/perc)

## Minimax algoritmus játékfákon


- Játékfa építése adott mélységig;
- Levelek címkézése: **kiértékelő függvény**
- Értékek visszaterjesztése lásd [Nyerő stratégia](#);
- A gyökér-címke értékű lépés megtétele;



# Negamax algoritmus

- A **minimax** algoritmusnál a különböző játékosok lépéseinél minimumot vagy maximumot kerestünk;
- A **negamax** algoritmus egyesíti a kétfajta optimális lépést:
  - ▶ minden lépésben maximumot számol,
  - ▶ ellenben az előző szint **negált** értékei szerint.
  - ▶ a javasolt lépés a csúcs negált értékű utódjába történő lépés;

# Negamax algoritmus működése



## Minimax/Negamax tulajdonságok

### Tulajdonságok:

- Teljesség – megtalálja az optimális lépést, ha ilyen létezik?  
**Ha a játéka véges.** igen
- Optimalitás – a legjobb lépést találja meg?  
**Ha az ellenfél is racionális.** igen
- Bonyolultság:  $\mathcal{O}(b^m)$  kimenő élek –  $b$   
kiértékelés mélysége –  $m$
- Memóriaigény:  $\mathcal{O}(bm)$

**Sakk-program:**  $b \approx 35$ ,  $m \approx 100 \Rightarrow 35^{100}$   
 $35^{100} = 10^{139}$  levél v.ö:  $10^{80}$  **összes elektron**

### Hatékonyabbá tételése: VÁGÁSOK

## Alfa-béta vágás

- **Minimax/negamax algoritmus költséges** mert nagyon sok csúcsot kell generálni; azonban
- **Tudjuk**, hogy az értékelés a **minimax** szabály szerint történik;
- Az **alfa-béta** vágások módszere figyelembe veszi a már kiszámított csúcsok értékét (McCarthy 1956 – sakk)
- és **csak** olyan csúcsokat **nem** értékel ki, ahova racionális játék során eljutunk.

### Kiértékelés során bevezetett változók:

$\alpha$  – MAX szint utódjainak maximuma;

csak növekedhet.

$\beta$  – MIN szint utódjainak minimuma;

csak csökkenhet.

**Vágás:** művelet, melynek eredményeként **nem** értékeljük ki egy csúcshoz tartozó többi utódcsúcsot.

**Vágási kritériumok:**

- **MIN** csúcs alatt vágunk, ha az egyik őséhez rendelt  $\alpha$  érték nagyobb, mint a csúcs  $\beta$  értéke.


alfa vágás

- **MAX** csúcs alatt vágunk, ha az egyik őséhez rendelt  $\beta$  érték kisebb, mint a csúcs  $\alpha$  értéke.

béta vágás

Egy kiértékelést abba lehet hagyni, ha:

$$\alpha \geq \beta$$



Alfa-béta algoritmus tulajdonságai

- a vágások **nem módosítják** a megoldások minőségét;
- hatékony vágások (első eset) megvalósítása a csúcsok rendezésével: idő-komplexitás:  $O(b^{m/2})$
- Fontos a tudás – hol lehet „jó csúcsokat” találni – kódolása.

Létező játékprogramok:

- **Dáma** – Chinook program 40 éves nyerési sorozatot szakított meg ...
- **Sakk** – Deep Blue 1997-ben megverte Kasparov-ot.
- **Reversi** – nem játszanak: gép ... mindig nyer.
- **Go** – nem játszanak: gép ... mindig veszít.




Figure 5.12 Ratings of human and machine chess champions.



**Jellemzők:**

- két játékos van: a **sor** illetve az **oszlop** játékos.
- a sor-játékos a számára elérhető  $m$  stratégia közül **pontosan** egyet választ.
- az oszlop-játékos a számára elérhető  $n$  stratégia közül **pontosan** egyet választ.
- A választások egymástól **függetlenek**.
- Ha a sor játékos az  $i$  opciót, az oszlop játékos a  $j$  opciót választotta, a sor játékos nyeresége  $a_{ij}$ .

**Stratégia:** szabályrendszer, mely előírja, hogy egy játékos mit kell lépjen.

Neumann János tétele - kevert stratégiákra **null-összegű játékokon**.

Minimax tulajdonság

**Nyereségmátrix:** (a sor játékos számára)

-1	3	2	9	-1
5	4	-2	6	-2
8	-2	6	-2	-2

Azon stratégiát válassza, mely a **legkisebb nyereségek maximumát** adja.

Minimax játékos:

$$\max_i \left( \min_j M_{ij} \right) \leq \min_j \left( \max_i M_{ij} \right)$$

azaz: az **A legalább min max**-ot nyer.

A sor-játékos az első sort választja **-1** nyereséggel

Két játékos, mindegyiknek van valahány stratégiája, melyek közül választhat ( $A \rightarrow 3$ , illetve  $B \rightarrow 4$ ).

**Nyereségmátrix** az A számára; veszteség B-nek.

	B.1	B.2	B.3	B.4
A.1	-1	3	2	9
A.2	5	4	-2	6
A.3	8	-2	6	-2

? Ha A nem tudja, hogy B mit fog lépni, melyik a legjobb lépés?

Kevert stratégia

**Nyereségmátrix:**

-1	3	2	9	-1
5	4	-2	6	-2
8	-2	6	-2	-2

- **De:** vannak a nyereségmátrixnak **sokkal** nagyobb elemei is, tehát **kell legyen jobb választás**;
- **Kevert** stratégiával játszunk: a **sor** játékos válassza:
  - $x_1$  valószínűséggel az első sort;
  - $x_2$  valószínűséggel a második sort;
  - $x_3$  valószínűséggel a harmadik sort ( $x_3 = 1 - x_1 - x_2$ );

**Az oszlop** játékos ugyanígy választhat.

Feltételezzük, hogy **sokszor** játszunk ugyanazon mátrix szerint.

# Kevert stratégia létezési tétele

## Neumann-tétel

**Minden** nulla-összegű játék esetén létezik egy olyan keveréke a stratégiáknak, mely **minimax tulajdonsággal** rendelkezik.

### Bizonyítás:

Átlagnyereség:  $\mathbf{x}^T \mathbf{M} \mathbf{y}$

$$\mathbf{x} = [x_1, \dots, x_n] \in \Pi_n \quad \mathbf{y} \in \Pi_m$$

$$\max_{\mathbf{x} \in \Pi_n} \min_{\mathbf{m} \in \Pi_m} \mathbf{x}^T \mathbf{M} \mathbf{y} = \underbrace{V = \bar{V}} = \min_{\mathbf{m} \in \Pi_m} \max_{\mathbf{x} \in \Pi_n} \mathbf{x}^T \mathbf{M} \mathbf{y}$$

teljes biz. Finta - operációs kutatások

# Olló – papír – kő

## Szabályok:

- két játékos játszik
- egyszerre mutatnak egy ...
  - ▶ papírt
  - ▶ követ
  - ▶ ollót
- **papír**: becsomagolja a követ;
- **kő**: kicsorbítja az ollót;
- **olló**: elvágja a papírt

0	1	-1
-1	0	1
1	-1	0


Teljes szimmetria  $\Rightarrow$  nincs optimális stratégia.

„Optimális” kevert stratégia:  $[1/3, 1/3, 1/3]$ .

# Minimax tétel

Példa:  $\begin{bmatrix} 0 & 1 \\ 2 & 0 \end{bmatrix}$  Arányokkal:  $\begin{bmatrix} x \\ 1-x \end{bmatrix}^T M \begin{bmatrix} y \\ 1-y \end{bmatrix}$

XMAPLE KÓD



A nyeresége maximális, ha  $2/3$  valószínűséggel az első,  $1/3$ -dal a második stratégia szerint játszik.

# Egy paradoxon

Székely J.G.: Paradoxonok a valószínű matematikájában.

# Stratégiák

Ketten játszanak: Q és R.

- Egy vagy két ujjat mutatnak fel;
- Páros ujj-szám esetén Q fizet R-nek, ellenkező esetben fordítva;
- annyit nyernek/veszítene, ahány ujjat felmutattak.

Ismételt játékok esetén mi a nyerő stratégia?

Nyereség-mátrix:

	Q.1	Q.2
R.1	2	-3
R.2	-3	4

$$\mathbf{r}^T \mathbf{M} \mathbf{q} = 2r_1q_1 - 3r_1q_2 - 3r_2q_1 + 4r_2q_2$$

Mindegyik játékos úgy játszik, hogy az eredmény **ne** függjön a másik játékosról, valamint tudva, hogy  $p_2 = 1 - p_1$  és  $q_2 = 1 - q_1$ , a játék értéke:

$$V = (12r_1 - 7)q_1 + (4 - 7r_1)$$

R választása:  $12r_1 - 7 = 0$ .

A megoldás:

$$r_1 = 7/12, r_2 = 5/12, q_1 = 7/12, q_2 = 5/12$$

Átlagnyereség:  $-1/12$

## Tizenegyes-rúgások

## Példa

- Tizenegyes-rúgás: a játékos **rúg**, a kapus **véd**.
- A kapus a lövés előtt elmozdul.
- A játékos szintén a lövés előtt dönt.

	B	K	J
B	5	8	9
K	8	4	8
J	9	8	5

### Milyen stratégiát kövessenek?

A büntetőt **B**alra, **K**özépre, vagy **J**obbra lehet löni, a kapus is erre vetődhet. Kevert stratégiákat keresünk. Játékos  $\mathbf{x} = [x_1, x_2, 1 - x_1 - x_2]$  és kapus  $\mathbf{y} = [y_1, y_2, 1 - y_1 - y_2]$ .

$$\begin{aligned} \mathbf{x}^T \mathbf{M} \mathbf{y} &= \\ &= -8y_1x_1 - 4y_1x_2 + 4y_1 - 7y_2x_2 + 3y_2 + 4x_1 - 4x_1y_2 + 3x_2 + 5 \\ &= -x_1(8y_1 + 4y_2 - 4) - x_2(4y_1 + 7y_2 - 3) + 4y_1 + 3y_2 + 5 \end{aligned}$$

Innen:  $y_1 = 2/5$ ;  $y_2 = 1/5$   $\Rightarrow y_3 = 2/5$ .  
(szimmetria okán a **kapus** ugyanígy kell eljárjon.)

## Bizonytalanság

*Russell & Norvig, 1995, 415. o.*

„In which we see what an agent should do when not all is crystal clear.” *Futó et.al. 321–372*

Ezidáig: következtetések olyan esetekben, ahol

- **tudtuk** egy esemény – tény – bekövetkezését.
- ismertük az események közötti kapcsolatrendszer: ok–okozat

Problémamegoldás során a tudásunk:

**hiányos** – nem tudunk/akarunk válaszolni;

**nem megbízható** – tudjuk, hogy **max. 70%**...

**nem precíz** – nincs megfelelő formalizmus a leíráshoz;

**ellentmondásos** – több forrás  $\Rightarrow$  konfliktus;

## Játékok – összefoglaló

### Játékok – fontos szemléltető eszközök:

- **Nincs** tökéletes megoldás, tehát közelítenünk kell;
- **Formalizálás:** „jó ötlet azon gondolkodni, hogy min kell gondolkodni”;
- Játékok: mint a **Formula 1** az autók számára.

## Bizonytalanság típusai

Hiányzó adat	Rosszul kitöltött kérdőív
Bizonytalan adat	A betegség csak valószínűsíthető
Bizonytalan fogalmak	Pl. „gyorsan hajtott”
Ellentmondások	Összegzésnél egymásnak ellentmondó adatok

## Numerikus modellek

- Bayes-modell,
- Bayes-hálók,
- Dempster–Schafer: megbízhatóságelmélet,
- Fuzzy modell

## Szimbolikus modellek

- nem-monoton rendszerek

## Bayes modell

- A legrégebbi modell, legjobban definiált technika (kockajáték);
- Alapja a valószínűségi számítás;
- Első modellt Cardano<sup>4</sup> alkotta; illetve Galilei 1660 körül, majd Borel és Kolmogorov a XX. században;

- **Valószínűségi számítás:** véletlen kísérletek;
- Kísérletek eredményei: **elemi események**;
- **Eseménytér:** összes esemény  $\Omega$

- ▶ teljes esemény  $T = \Omega$ ,
- ▶ üres esemény  $T = \emptyset$ ,
- ▶ ellentett esemény  $\bar{A} = \Omega \setminus A$ ,
- ▶ egymást kizáró események ha  $A \cap B = \emptyset$ ,

<sup>4</sup>Gerolamo Cardano (1501–1576): *De Ludo Aleae* (1663)


# Cardano és Galilei

**Gerolamo Cardano (1501–1576): *Liber de ludo aleae* - 1663**

„Olasz matematikus, természettudós, csillagász és hazárdjátékos.”  
Először írja le a *tífuszt*.

Legismertebbek az **algebrában** elért eredményei: megoldotta a harmad- és negyedfokú egyenleteket – Ars Magna – és a megoldás során felismerte az **imaginárius rész** szükségességét. Termodinamikai megfontolások alapján tagadta az *örökmozgók* létezését.

Mindig pénzszerűben volt – ? $\Rightarrow$ ? – sakkozott és kockázott. Az játékokról írt könyve először foglalkozik a **valószínűség** fogalmával.



Cardano wiki


**Galileo Galilei (1564–1642)**

Olasz természettudós, matematikus, csillagász és filozófus, a tudományos forradalom úttörője.

*S. Hawking:* „Galileo a modern tudományok úttörője.”

Javított a teleszkópok képességein, tökéletesítette a körzőt, bevezette a kinematikát, az asztronómiát, először írta le a Vénusz fázisait.

Kijelentette, hogy a *természet törvényei* matematikai jellegűek, valamint azt, hogy a Föld forog a Nap körül, (majdnem megégett).



Galileo wiki

## rev. Thomas Bayes

**Thomas Bayes (1702–1761):** angol matematikus és lelkész, a nevével elnevezett tétel egy specifikus alakját alkotta meg.



Bayes wiki

**Valószínűség:**  $P : 2^\Omega \rightarrow [0, 1]$  függvény, melyre

$$P(T) = 1 \quad T \text{ teljes esemény;}$$

$$P(F) = 0 \quad F \text{ üres esemény;}$$

$$P(A \cup B) = P(A) + P(B)$$

ha  $A$  és  $B$  egymást kizáró események.

$P(A)$  – az  $A$  esemény bekövetkezése a valószínűsége ha *semmi információ nem áll rendelkezésünkre* más események bekövetkeztéről.

**Tulajdonság:**  $P(A) + P(\bar{A}) = 1.$

**Bayes szabály:** feltételes valószínűség szabálya

$$\text{azaz } P(A|B) = \frac{P(AB)}{P(B)} \quad \text{ha } P(B) \neq 0$$

Tipikus felírás:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B|A)P(A) + P(B|\bar{A})P(\bar{A})} \quad \text{ha } P(B) \neq 0$$

### Általános Bayes-szabály

Egy  $\{A_1, \dots, A_N\}$  teljes eseményrendszer esetén

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_j P(B|A_j)P(A_j)} \quad \text{ha } P(B) \neq 0$$

**Teljes eseményrendszer** azon  $\{A_1, \dots, A_N\}$ ,  $N > 0$  halmazok, melyekre

$$A_1 \cup A_2 \cup \dots \cup A_N = \Omega \quad \text{és} \quad A_i \cap A_j = \emptyset \quad \forall i \neq j$$

**Tétel:** minden  $\{A_1, \dots, A_N\}$  teljes eseményrendszer esetén

$$P(A_1) + P(A_2) + \dots + P(A_N) = P(A_1 \cup A_2 \cup \dots \cup A_N) = P(\Omega) = 1$$

**Jelölés:**  $A \cap B \stackrel{\text{def}}{=} AB$  és  $P(A \cap B) \stackrel{\text{def}}{=} P(AB).$

**Feltételes valószínűség:**

$B$  esemény hatása az  $A$ -ra:  $P(A|B)$

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_j P(B|A_j)P(A_j)} \quad \text{ha } P(B) \neq 0$$

A  $B$  eseményből következtetünk az  $A_i$  esemény feltételes valószínűségére.

Ismernünk kell az elsődleges valószínűségeket

– **a-priori valószínűségeket:**

- $P(A_j)$ ;
- $P(B|A_j)$  feltételes valószínűségeket.

# Bayes modell

# példa

Adott a következő szabály:

Ha a beteg megfázott, akkor lázas. (75%)

Kérdés:

Ha a beteg lázas, akkor megfázott. ??%

Jelölés:

M – a beteg megfázott  
L – a beteg lázas

Szükségesek:

$P(M) = 0.2$  – megfázott

$P(L|M) = 0.75$  – lázas, feltéve, hogy megfázott

$P(L|\bar{M}) = 0.2$  – lázas, feltéve, hogy nem fázott meg

Ekkor:

$$P(M|L) = \frac{P(L|M)P(M)}{P(L|M)P(M) + P(L|\bar{M})P(\bar{M})} \quad \text{ha } P(L) \neq 0$$

Azaz  $P(M|L) = 0.15/0.31 = 0.483$

# Bayes háló

# I

- Bayes–modell hátránya a nagy valószínűségi tábla specifikálása,
- Bayes–háló (vélekedésháló, **belief network**) egyszerűsíti ezt a feladatot,
- Eszköze az **okági kapcsolatok** leírása.

## Bayes–háló

Egy adott feladat változóinak okági struktúráját leíró **irányított körmentes** gráf.

Csomópontok az állítások, élek a kapcsolatok.

Élekhez rendelünk feltételes valószínűségi táblákat: összegzik a szülő változó hatását.

# Bayes modell

# összefoglaló


- Alkalmazható, ha **minden** információval rendelkezünk.
- Gyakorlatban az egymást kizáró eseményrendszer ritka...
- Előnyök:
  - ▶ Elméleti alap,
  - ▶ Jól definiált szemantika;
- Hátrányok:
  - ▶ nagyon sok valószínűséget kell megadni,
  - ▶ valószínűséget megadása nehéz,
  - ▶ változ(tat)ások követése nehéz.

# Bayes háló



# II

Kiegészítés:

T - tüdőgyulladásos a beteg



Fordítva:

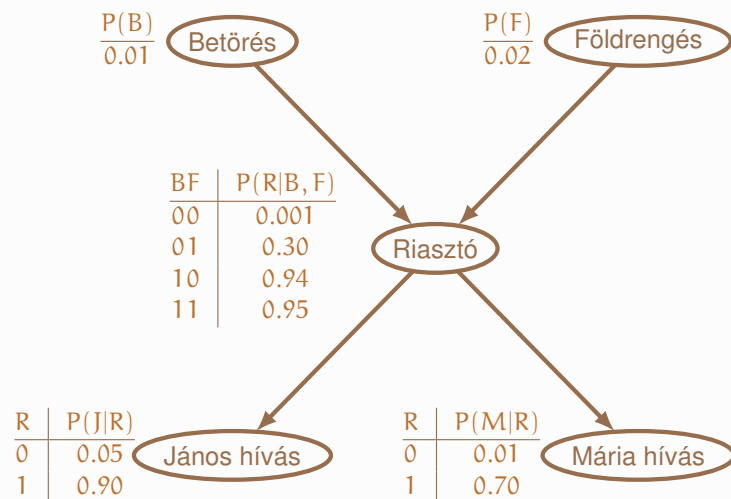


Bayes-háló – egy adott terület teljes körű leírása.

„Algoritmus”:

- 1 A területet leíró változók meghatározása;
- 2 Írjuk fel a többi változótól független csomópontokat – tehát **gyökérváltozók**;
- 3 Amíg vannak csomópont nélküli változók:
  - 1 Válasszunk egy olyant, mely **csak** a már leírt változóktól függ.
  - 2 Képezzük azt a minimális halmazt, melyek mind közvetlenül hatnak az új csomópontra;
  - 3 Rajzoljuk be az új éleket és töltsük ki a **felt.val.** táblát;

*Russell & Norvig pp. 437*



Sorrend a háló

építésénél: B, F, R, M, J .

Háló építésének az alapja

$$P(v_1, v_2, \dots, v_N) = P(v_1 | v_2, \dots, v_N) P(v_2, \dots, v_N)$$

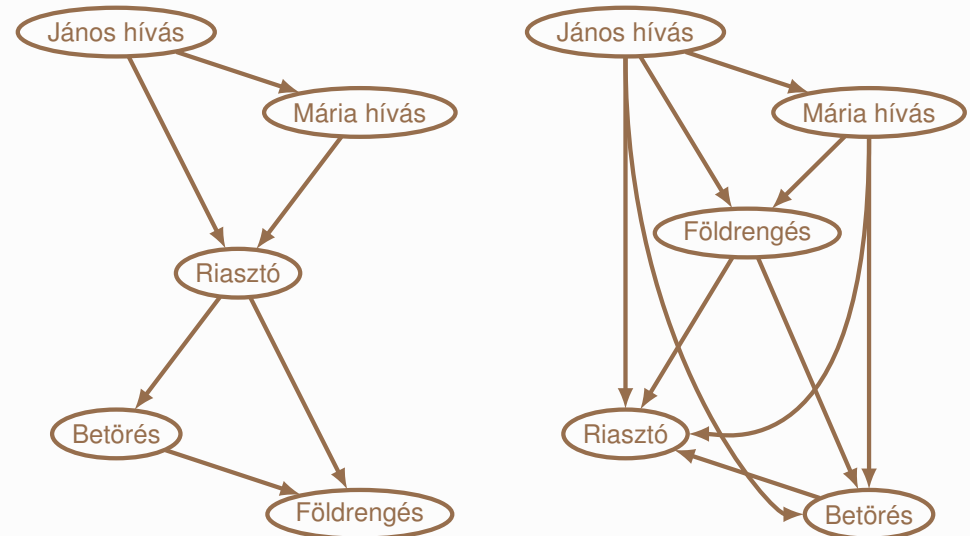
Az indirekt függőségek kiesnek.

A felt.val. törvénye érvényes bármely **rendezésre**:

$$P(v_{\pi_1}, v_{\pi_2}, \dots, v_{\pi_N}) = P(v_{\pi_1} | v_{\pi_2}, \dots, v_{\pi_N}) P(v_{\pi_2}, \dots, v_{\pi_N})$$

ahol  $\pi$  egy **permutáció**.

Jó – könnyen értelmezhető – Bayes-hálónál fontos az építés sorrendje.



Sorrend: J, M, R, B, F .

Sorrend: J, M, F, B, R .

- **Diagnosztizáló:** hatásokból az okokra;
- **Oksági kapcsolatokat vizsgáló;**
- **Kölcsönös kapcsolatokat vizsgáló;**

Egyszerű műveletek, ha a háló egyszeresen összekötött.

Példa: Számoljuk ki a betörés (B) valószínűségét ha János hívott (J):

$P(B|J)$

illetve akkor, ha hallottuk, hogy földmozgás is volt (F):

$P(B|J, F)$

Grafikus modelleknél visszatérünk

### Verziók:

- I – szabályalapú rendszer, bizonytalanság beépítése nélkül;
- II – kísérletek különböző modellekkel: Bayes háló a legjobb (10%).
- III – Az „alig-valószínű” események.
- IV – Valószínűségi háló – *Belief Net* – használata.
  - 8 óra – szótár meghatározása;
  - 35 óra – háló meghatározása;
  - 40 óra – val.-ek becslése (1400 val.g).

PATHFINDER IV – „jobb”, mint az azt alkotó szakértők.

### PATHFINDER:

- szakértői rendszer nyirokmirigy-gyulladások diagnosztizálására;
- Fejlesztője D. Heckermann; Stanford Medical Computer Science '80-as években;
- > 60 betegség típus és > 100 szimptóma illetve teszt-eredmények.



<http://research.microsoft.com/~heckerman>

**Motiváció:** szeretnénk döntéseket hozni akkor is, ha az események valószínűségeit nem ismerjük.

**Például:** Pacino-t meggyilkoltatta a maffia. A rendőrség a következő tényeket gyűjtötte össze:

- három bérnyilkos van: Tom, John, illetve Angie;
- a gyilkos kiválasztása a következő volt: ha egy dobás fej, akkor Tom, ellenkező esetben John vagy Angie;
- DNS-vizsgálatok eredménye 80%-ban férfit valószínűsít.

**Kérdés:** Mekkora az egyes személyek bűnösségének a valószínűsége?



**Nincs** megfelelő valószínűségi modell, mely egyesíteni tudná a két állítást.

**Bizonytalanság:** A tények ismeretében **nem tudunk** személyt azonosítani.

**Ábrázolás:** a két tényhalmazt ábrázoljuk mértékekkel ( $e_1$  és  $e_2$  arányban megbízható információ) :

**Első:**  $e_1 - m(T) = e_1 \cdot 50\%$  és  $m(J, A) = e_1 \cdot 50\%$

**Második:**  $e_2 - m(T, J) = e_2 \cdot 80\%$  és  $m(A) = e_2 \cdot 20\%$

**Ismerethiány:** nem tudunk valószínűségi modellt építeni, melyben ábrázolhatjuk **mindkét** forrást.

- **Cél:** megkülönböztetni
  - ▶ a bizonytalanságot (*uncertainty*)
  - ▶ az ismerethiánytól (*ignorance*).

- Egy atomi **B** esemény valószínűségét **nem** ismerjük;

A valószínűség-tábla:

$m(T)$	$m(J, A)$	$m(T, J)$	$m(A)$
25%	25%	40%	10%

**Például:** a fentiek alapján tudjuk, hogy

$$p(T) \geq 25\%, \text{ ugyanakkor } p(T) \leq 65\%.$$

### Dempster-Schafer modell

Egy módja a többféle információ–forrás összetételének.

**Amennyiben**  $e_1 + e_2 = 1$

$$m(T) + m(J, A) + m(T, J) + m(A) = 1$$

Ha  $e_1 = e_2 = 50\%$ , tudjuk a halmazok valószínűségét.

**Nem tudjuk** a személyek valószínűségeit.

**Szeretnénk** a fenti információkkal műveleteket végezni.

Nyilvántartjuk azt, hogy

- mennyire támogatunk egy állítást  $Bel(F)$ ; **(belief)**
- mennyire „esélyes” az állítás  $Pl(F)$ ; **(plausibility)**

**Példa:** egy érme **szabályossága** a vizsgálat előtt:

$$Bel(F) = 0 \quad \text{illetve} \quad Bel(\bar{F}) = 0$$

de ha **90%**-ban megállapítottuk, hogy szabályos, akkor

$$Bel(F) = 0.5 \cdot 0.9 \quad \text{illetve} \quad Bel(\bar{F}) = 0.5 \cdot 0.9$$

A „fennmaradó” **10%** a bizonytalanságot tükrözi.

**Példa folyt.:**

intervallum-logika

- vizsgálat előtt:  $p(F) \in [0, 1]$ ;
- vizsgálat után:  $p(F) \in [0.45, 0.55]$ ;

**Dempster-Schafer modell:** intervallumok kombinálása.

**Bayes analógia:** alsó- illetve felső korlátai egy esemény valószínűségének.

**Segédfüggvények bevezetése:**

- $Bel(A_i)$  – alsó korlát;
- $PI(A_i)$  – felső korlát;

Belief  
Plausibility

$$Bel(A) = \sum_{B \subset A} m(B),$$

$$PI(A) = \sum_{B \cap A \neq \emptyset} m(B)$$

- bármely  $A$  halmazra  $Bel(A) \leq PI(A)$

$$B \subset A \Rightarrow B \cap A \neq \emptyset$$

- bármely  $A$  halmazra  $Bel(A) = 1 - PI(\bar{A})$

$$B \subset A \Leftrightarrow \overline{B \cap \bar{A}} \neq \emptyset$$

$$B \subset A \Leftrightarrow B \cap \bar{A} = \emptyset$$

- a  $Bel$  függvény szubadditív:  
 $Bel(A \cup B) \leq Bel(A) + Bel(B)$

$$C \subset A \wedge C \subset B \Rightarrow C \subset A \cup B$$

- a  $PI$  függvény szuperadditív:  
 $PI(A \cup B) \geq PI(A) + PI(B)$

„Belief”

$$Bel(A_1 \cup A_2) \geq \sum_{i=1}^2 Bel(A_i) - Bel(A_1 \cap A_2)$$

„Plausibility”

$$PI(A_1 \cap A_2) \leq \sum_{i=1}^2 PI(A_i) - PI(A_1 \cup A_2)$$

**A Bel és PI függvények jellemzése:**

Egy  $m : 2^\Omega \rightarrow [0, 1]$  függvény segítségével, melyre

$$m(\emptyset) = 0,$$

$$\sum_{A \in \Omega} m(A) = 1$$

$$Bel(A) = \sum_{B \subset A} m(B),$$

$$PI(A) = \sum_{B \cap A \neq \emptyset} m(B)$$

**Jellemezzük az érménket megfigyelés előtt:**

- legyen  $m(\{F, I\}) = 1$  és minden másra  $m(B) = 0$ ;
- ekkor  $Bel(F) = m(\{F\}) = 0$  és  $PI(F) = m(\{F\}) + m(\{F, I\}) = 1$ .

**Megfigyelések után:**

- $m(\{F\}) = m(\{I\}) = 0.45$  és  $m(\{F, I\}) = 0.1$ ;

– az összeg 1;

• ezért:

- 1  $Bel(F) = m(\{F\}) = 0.45$ , illetve
- 2  $PI(F) = m(\{F\}) + m(\{F, I\}) = 0.55$ ;

- azonosítani tudjuk a „határozatlan” részt:

$$m(\{F, I\}) = 0.1$$

## Logikai műveletek definíciója:

- logikai és:

$$\text{Bel}(A_1 \wedge A_2) = \sum_{B \subset (A_1 \cap A_2)} m(B);$$

$$\text{Pl}(A_1 \wedge A_2) = \sum_{B \cap (A_1 \cap A_2) \neq \emptyset} m(B);$$

- logikai vagy:

$$\text{Bel}(A_1 \vee A_2) = \sum_{B \subset (A_1 \cup A_2)} m(B);$$

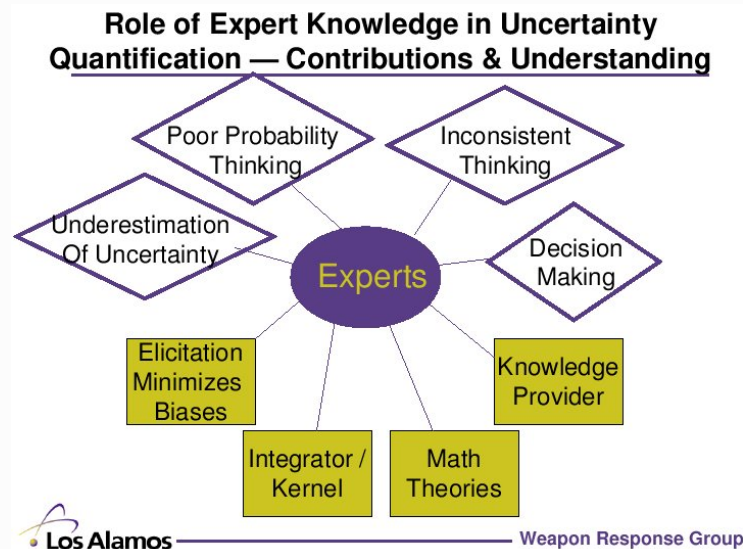
$$\text{Pl}(A_1 \vee A_2) = \sum_{B \cap (A_1 \cup A_2) \neq \emptyset} m(B);$$

## Általánosított entrópia:

$$\text{AU}(\text{Bel}) = \max_{p_x} \left( - \sum_{x \in \Omega} p_x \log p_x \right), \quad \text{Bel}(A) \leq \sum_{x \in A} p_x$$

## Dempster–Schafer modell alkalmazása

## Használják: ...



## Feltételes Bel és Pl függvények

- Amennyiben megfigyelünk egy eseményt, a halmazokhoz rendelt súly változik:

- ▶ Ha C igaz, akkor csak a C-t tartalmazó halmazok maradnak, melyekből a C-t töröljük, mint véletlen eseményt:

- 1 a súlyokat újraszámoljuk;
- 2 normalizáljuk a rendszert.

- Egy más „univerzum” keletkezik.

- A C nem teljesül, akkor csak C-t nem tartalmazó halmazokat használjuk.

## Dempster–Schafer modell

## Összefoglaló

- Konzisztens keretrendszer, mellyel lehet számításokat végezni;
- A  $\text{Bel}(\cdot)$  és  $\text{Pl}(\cdot)$  függvények definíciója „természetes”;
- Könnyű bizonytalanságot rendelni az eseményekhez – ignorancia;
- Megfigyelt események kezelése – kondicionálás – nagyon nehéz, újra kell számolni a függvények értelmezési tartományát.

Döntések bizonytalan helyzetekben – a D.S. rendszerhez hasonlóan akkor, amikor a valószínűség szabályai nem alkalmazhatóak.

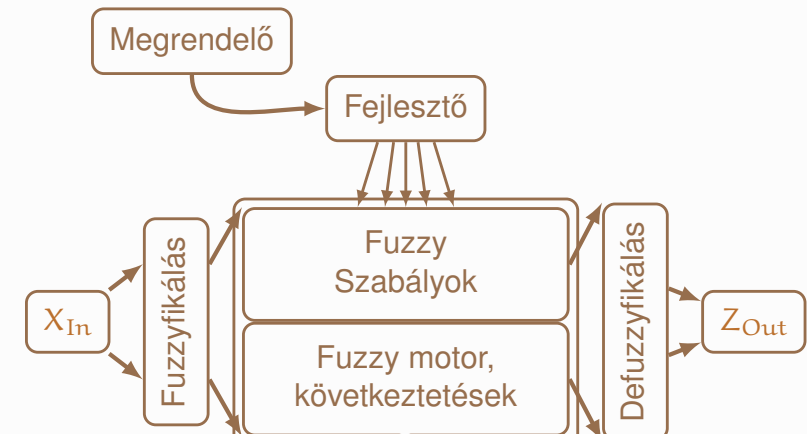
**Tipikusan:**

- „Tények” gyorsan hajtott, magas ember, kb. 180 cm, olajos ruha, ...
- „Szabályok” ha gyorsan hajt és lassan lélegzik akkor lassítson az elektronika ...

Szükség van egy keretrendszerre, mely a fentieket képes programozni:

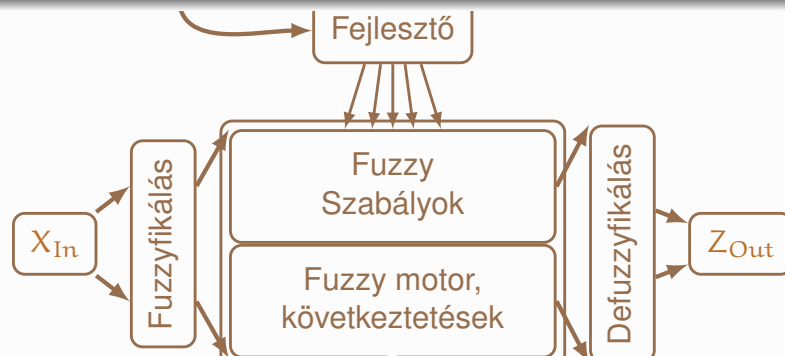
- 1 Szabályokat tudunk megadni;
- 2 Információt – adatokat – tudunk bevinni;
- 3 Következtetéseket tudunk levonni ⇒ döntéshozatal;

Egy fuzzy rendszer építésének logikai sémája:



Egy fuzzy rendszer építésének logikai sémája:

- A megrendelő közli a fejlesztővel a
  - ▶ változókat
  - ▶ szabályokat
- a fejlesztő a szabályokat „átírja” a fuzzy logika szerint;
- a szabályok köré építi a „következtetőt”, ami a rendszert eredményezi.



**Egy fuzzy rendszer működéséhez**

Szükségünk van:

- Keretrendszerre, mely a szabályokat értelmezni tudja;
- „Fuzzyfikáló” modulra, mely a megfigyeléseket átalakítja a fuzzy logika nyelvére;
- Következtető modulra;
- „De-fuzzyfikáló” modulra.

**Eszköz**

- Fuzzy halmazelmélet;
- Fuzzy logika.

# Történelmi visszatekintő

**Fuzzy:** homályos, zavaros, bizonytalan, kócos

- '65 – Zadeh: „Fuzzy Sets”;
- '70 – Fuzzy elmélet robotikai alkalmazása;
- '75 – Japán ...
- '80–'95 – Empirikus vizsgálatok és széles körű alkalmazások;
- '00–'05 – Technológiai standard,



Lotfi A. Zadeh

## Felhasználás:

Ha **magas** a hőmérséklet, akkor a nyomás is **magas**;

# Fuzzy halmazok

II

## Klasszikus logika

Egy kijelentés

igaz: – 1;  
vagy hamis – 0.

## Fuzzy logika

Egy kijelentés

igazságértéke  $\mu(p) \in [0, 1]$


Egy **A** halmazra:

$$I_A(x) = \begin{cases} 1 & \text{ha } x \in A \\ 0 & \text{ha } x \notin A \end{cases}$$

$$\mu_A(x) \in [0, 1] \quad \forall x \in \Omega$$

Egy halmaz =  $\mu_A$

**Például:** **M** – magas hőmérséklet



# Fuzzy halmazok

I


## Fuzzy halmazelmélet

- Eszköz annak a leírására, hogy egy objektum milyen mértékben illeszkedik egy bizonytalan tényhez;
- Alkalmas bizonytalan kijelentések formalizálására.
- **Nem valószínűségi** modell.
- Döntések hozatala „igazság-értékek” alapján.
- **Fuzzy halmazok:** nem „teljes” hozzátartozás specifikálása.

# Fuzzy halmazok

III

A definíciós intervallumot általában felosztjuk **több fuzzy halmazra:**



Egy **fuzzy halmaz** tehát **függvény**,  $\mu_K : \Omega \rightarrow [0, 1]$ :

$$\mu_K(x) = \begin{cases} 1 & \text{ha } x \in [50, 70] \\ (x - 40)/10 & \text{ha } x \in [40, 50] \\ (90 - x)/20 & \text{ha } x \in [70, 90] \\ 0 & \text{ha } x \leq 40 \text{ vagy } x \geq 90 \end{cases}$$

- A logikai műveletek **halmazműveletekre** vezethetők vissza:
  - a logikai **vagy** az **egyesítés**:

$$A \vee B \stackrel{\text{def}}{=} A \cup B$$

- a logikai **és** a **metszet**:

$$A \wedge B \stackrel{\text{def}}{=} A \cap B$$

- a logikai **negáció** a **komplementer**:

$$\bar{A} \stackrel{\text{def}}{=} \Omega \setminus A$$

- A fuzzy logikai műveletek fuzzy halmazok egyesítése, metszete, illetve komplementere.

- A három logikai művelet **redundáns**:

$$\overline{A \vee B} = \bar{A} \wedge \bar{B} \Rightarrow \boxed{A \vee B = \overline{\bar{A} \wedge \bar{B}}}$$

- Csak a **konjunkciót** és a **negációt** kell specifikálnunk.

**Példa:**

- A konjunkciónak megfelelő **T-norma**:

$$T(a, b) = \min(a, b)$$

$$T(0, 0) = T(0, 1) = T(1, 0) = 0, \text{ illetve } T(1, 1) = 1.$$

- A **negáció** legyen:

$$C(x) = 1 - x$$

$$C(1) = 0, \text{ illetve } C(0) = 1.$$

- A diszjunkció meghatározása:

$$S(a, b) = 1 - T(1 - a, 1 - b)$$

$$\begin{aligned} S(a, b) &= 1 - T(1 - a, 1 - b) = 1 - \min(1 - a, 1 - b) \\ &= 1 + \max(-1 + a, -1 + b) = \max(1 - 1 + a, 1 - 1 + b) \\ &= \max(a, b) \end{aligned}$$

- A fuzzy rendszerekben a **konjunkciót** és a **negációt** specifikáljuk.
  - A konjunkció egy **T-norma**:

$$T : [0, 1] \times [0, 1] \rightarrow [0, 1]$$

A  $T(1, 1) = 1$  kivételével minden sarokpontban az értéke 0 kell, hogy legyen (hogy kapjuk vissza a klasszikus logikát).

- A negáció egy-argumentumú függvény:

$$C : [0, 1] \rightarrow [0, 1]$$

A sarokfeltételek:  $C(0) = 1$ , illetve  $C(1) = 0$ .

- A diszjunkciót a **De-Morgan** reláció alapján számoljuk ki (S-konormának nevezzük):

$$S : [0, 1] \times [0, 1] \rightarrow [0, 1]$$



$$\boxed{S(a, b) = C(T(C(a), C(b)))}$$

**Logikai szabályok:**

$$\mu_{A \wedge B}(x) = \min[\mu_A(x), \mu_B(x)]$$

$$\mu_{A \vee B}(x) = \max[\mu_A(x), \mu_B(x)]$$

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$$





Logikai szabályok:  $a, b \in \{0, 1\}$

ÉS = 1 **csak ha**  $a = 1$  és  $b = 1$   
 VAGY = 0 **csak ha**  $a = 0$  és  $b = 0$

Alternatív formák:

$$\mu_{A \wedge B}(x) = \mu_A(x) \cdot \mu_B(x), \quad \mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

$$\mu_{A \vee B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x)$$



A negációt szeretnénk úgy meghatározni, hogy

- legyen folytonos, bijektív;
- teljesüljön a **negált negáltja önmaga**, azaz  $C(C(x)) = x$
- legyen  $C(0) = 1$  és  $C(1) = 0$

A  $C(x)$  bijektív, alkalmazva a  $z = C(x) \Leftrightarrow x = C^{-1}(z)$ :

$$C(z) = C^{-1}(z)$$

azaz a  $C(\cdot)$  függvény a főátló szerint szimmetrikus.

A  $C(x) = 1 - x$  **egy** megoldás.

Egy megoldás-család – pozitív  $q$  értékekre – a

$$C_q(x) = \sqrt[q]{1 - x^q}$$

Fuzzy logika inkonzisztens

$x$  vagy  $A$ -nak vagy  $\bar{A}$ -nak eleme, azaz  $\mu_{A \cap \bar{A}} = 1$ .


$$\mu_{A \vee \bar{A}}(x) = \begin{cases} 1 & \text{klasszikusan} \\ \max[\mu_A(x), 1 - \mu_A(x)] & \text{fuzzy logika 1 def.} \\ 1 - \mu_A(x) [1 - \mu_A(x)] & \text{fuzzy logika 2 def.} \end{cases}$$

Ugyanígy: szeretnénk, hogy  $\mu_{A \wedge \bar{A}} = 0$ . Helyette:

$$\mu_{A \wedge \bar{A}}(x) = \begin{cases} 0 & \text{klasszikusan} \\ \min[\mu_A(x), 1 - \mu_A(x)] & \text{fuzzy logika 1 def.} \\ \mu_A(x) [1 - \mu_A(x)] & \text{fuzzy logika 2 def.} \end{cases}$$

vizsga feladattípus: határozzuk meg a „modus ponens” szabály fuzzy változatát.

A  $C_q(x) = \sqrt[q]{1 - x^q}$  **grafikus képei** a  $q = \{1/3, 1/2, 1, 2, 3\}$  értékekre:



- **Érthető formában** írják le egy rendszer működését:
  - ▶ Könnyű megfogalmazni;
  - ▶ Könnyen ellenőrizhető;
  - ▶ Módosításokhoz nem kell az egész rendszert átírni.
- Használják a **fuzzy logika** következtetési mechanizmusait;
  - ▶ Logikai szabályok alapján;
  - ▶ Fuzzy változók értékeit számolják;
  - ▶ De-fuzzyfikálás után az eredmény jó kontroll-változó.

## Fuzzy szabályok:

X	Y		
	Alacsony	Közepes	Magas
Alacsony	–	Közepes	Alacsony
Közepes	–	Magas	Közepes
Magas	Közepes	Magas	Alacsony

– nem megengedett állapot

## Szabályok alkalmazása:

Megfigyelt értékek:

$$x = 50, y = 78.75$$

**Fuzzyfikálás** – fuzzy halmazokra való áttérés: X szerint **csak** az **Alacsony** csoportot kell vizsgálni.

Y szerint a **Közepes** és **Magas** csoportokat.


## Példa:

Ha **magas** a hőmérséklet, akkor a nyomás is **magas**;

## Fuzzy szabályok:

HA [ X **alacsony** ÉS Y **magas** ] AKKOR Z **közepes**

Definiáljuk az **alacsony**, **magas** és **közepes** halmazokat:




$$\mu_{al}(x) = 1 \text{ illetve}$$

$$\mu_{mag}(y) = 0.75;$$

$$\mu_{koz}(y) = 0.25;$$

Kombinálás: **VAGY** = max



Kontroll esetén

**Egy érték kiírása:** súlyozott közép  $Z = 53$ .



**Mitsubishi légkondicionáló rendszer** Ipari légkondicionáló mely rugalmasan reagál a környezeti változásokra.

### Megvalósítás:

- 50 fuzzy szabály
- 6 nyelvi változó, közöttük a szoba és a fal hőmérséklete, illetve ezek időbeli változásai;
- 4 nap – prototípus; 20 nap – teszt/integrálás; 80 nap – tesztelés;  
⇒ mikrokontroller implementálás.
- Előnyök: kevesebb szenzor, változó környezet, 24%-kal kisebb fogyasztás;

## Fuzzy rendszerek

## Összefoglaló

### Fuzzy rendszerek:

- Főként kontroll feladatokra használjuk.
- **Ajánlottak ha:**
  - ▶ komplex rendszerek esetén, nincs matematikai modell;
  - ▶ nemlineáris modellek esetén;
  - ▶ szakértői tudás bevitelére.
- **Nem ajánlottak ha:**
  - ▶ hagyományos kontroll megfelelő;
  - ▶ létező – egyszerű – matematikai modell;
  - ▶ nincs megoldás.

### Más alkalmazások:

**Sony PalmTop** – „fuzzy” döntési fa implementálása karakterfelismerésre (Kanji).

### Alkalmazások:

- Erőművek kontrollja (Tokio);
- Egyszerűsített robot-kontroll (Fuji, Toshiba, Omron);
- Fényképezőgép automata irányítása (Omron);
- Motor-fogyasztás, irányítás (Nissan, Subaru);
- Gyártósorok szilícium-lapkáinak vágása (Canon);
- Rák diagnózis (Kawasaki Med. School);
- Jogi eljárások szimulációja (Meihi Gakuin Univ, Nagoya Univ.)
- ... Matsushita, Sony, Canon, Minolta, Sanyo, Hitachi, Ricoh, Fujitech, Toshiba, ...

[http://www.esru.strath.ac.uk/Reference/concepts/fuzzy/fuzzy\\_appl.00.htm](http://www.esru.strath.ac.uk/Reference/concepts/fuzzy/fuzzy_appl.00.htm)

## Fellendülőben az MI

### Újabb MI-divat?

2007.09.12.

Az MI célja, hogy a gépek **emberre jellemző** tulajdonságokkal rendelkezzenek: nyelvhasználat, **fogalomalkotás, elvonatkoztatás**, nem triviális problémák megoldása, öntökeletesítés. (McCarthy, Minsky, Shannon)



### MI a mindennapokban

„A kifejezetten mérnöki munka és alkalmazott tudományok terén elért eredményeket figyelembe véve, a gépi tanulás technikáinak különböző problémákra (webes keresés, pénzügyek, molekuláris rendszerek megértése) történt alkalmazása a legsikeresebb MI-részterület.” – Terry Winograd szerint. „Ezek az eredmények, és más területek, például a robotika fejlődése intelligensebb gépekhez vezetnek.”

<http://www.agent.ai>

Winograd home

## Grafikus modellek (probabilistic graphical models - PGM)

Kevin Murphy

A gráfelmélet és a valószínűségi számítás ötvözése.

- **gráf**, mely egy rendszer függőségeit ábrázolja;
- csúcsokhoz rendelt **függvények**, melyek a változók közötti kapcsolatot írják le;

„Minden grafikus modell”

szemléletmód<sup>5</sup>

- Bayes-háló – irányított aciklikus gráfú PGM;
- Markov modell – irányítatlan PGM.


<sup>5</sup> „minden feladat szeg”, ha egy kalapácsot tartunk a kezünkben ...

# GM feladattípusok


**Feladatok** – adott GM struktúrára:

- események (**felt.**) val.-nek kiszámítása;
- állapítsuk meg két csúcs (**feltételes**) függetlenségét;
- adatok alapján építsünk optimális gráfot (indukció).

**Inferencia**  $P(X_{13}|X_7, X_8, X_9, X_{16})$




**Optimális struktúra keresése**



$\mathcal{D}$

## Irányított GM




- feltételes függetlenség;
- kauzális relációk;

$$X \perp Y$$

(láttuk)

## Irányítatlan GM



- feltételes függetlenség;
- szimmetrikus;

$$X \perp Y \mid \{W, Z\}$$

$$W \perp Z \mid \{X, Y\}$$

# Irányított GM


**Bayes-labda algoritmus:** feltételes függetlenség-teszt.

## d-szeparáltság


Egy grafikus modellben  $X$  az  $Y$ -tól **d-szeparált** a  $Z$  ismeretében, ha minden  $X$ -et és  $Y$ -t összekötő irányítatlan úton létezik  $w$  úgy, hogy:

vagy  $\rightarrow w \leftarrow$  és a  $w$  vagy utódai nincsenek a  $Z$ -ben;

vagy  $w$  **nem**  $\rightarrow w \leftarrow$  és  $w \in Z$ .




$$X \perp Y$$



$$X \not\perp Y$$

## Írányított GM



### Kérdések

- ?  $X_1 \perp X_{10} \mid \{X_7, X_8, X_9\}$
- ?  $X_1 \perp X_{10} \mid \emptyset$
- ?  $X_1 \perp X_{15} \mid \{X_5, X_6, X_{13}\}$

nem  
igen  
igen

## Írányítatlan GM

II

**Klikkek:** teljesen összekötött csúcsok.

$$P(\mathbf{X}) = \frac{1}{Z} \prod_{c \in \text{Klikkek}} \phi_c(\mathbf{x}_c) \quad Z = \sum_{\mathbf{X}} \prod_{c \in \text{Klikkek}} \phi_c(\mathbf{x}_c)$$

ahol

$\phi_c(\mathbf{x}_c) \geq 0$     potenciál-függvény  
Z    partíciós függvény


### Gibbs-eloszlás

Egy eloszlás, mely ábrázolható egy H gráffal és  $\{\phi_c\}_c$  potenciál-függvényekkel, H fölötti Gibbs-eloszlásnak nevezünk.

## Írányítatlan GM

I

**Különbség:**



**Függetlenség:** gráfon. Pl:

$$\{X_1, X_2\} \perp \{X_{11}, X_{12}, X_{13}\} \mid \{X_5, X_6\}$$

$$\prod P(X_i \mid \text{Szomszed}_i)$$

- felt. val.-gek: nem jók;
- ? – Nem konzisztens

• **Helyette**

$$\prod \Phi(X_i, \text{Szomszed}_i)$$

**klikkek jellemzése.**

## Írányítatlan GM

III



A gráf alapján  $X \perp Z \mid Y$

$$P(X, Y, Z) = P(X \mid Y)P(Y, Z) = \phi_{xy}(X, Y)\phi_{yz}(Y, Z)$$

$$P(X, Y, Z) = P(Z \mid Y)P(X, Y) = \phi_{yz}(Y, Z)\phi_{xy}(X, Y)$$

$\phi_c$  – potenciál-függvények

- „kompatibilitást”, „összeférhetőséget” jelölnek;
- **nem** eloszlás-függvények.

Exponenciális eloszláscsalád:

$$P(\mathbf{X}) = \frac{1}{Z} \prod_{c \in K \text{likkek}} \phi_c(\mathbf{x}_c)$$

$$= \exp \left[ -\log Z(\boldsymbol{\theta}) + \sum_{i \in I} f_i(\mathbf{x}_{c_i}) \right]$$

ahol


$$f_i \stackrel{\text{def}}{=} \log \phi_{c_i} \quad I - \text{index-halmaz}$$

Példa: Gaussz-eloszlás (teljes kapcsolat)

$$P(\mathbf{X}) = \exp \left[ -\frac{d \log(2\pi) + \log |\Sigma| + \mathbf{X}^T \Sigma^{-1} \mathbf{X}}{2} \right]$$

<http://www.cs.bkk.eluj.ro/~csatolehel/mestint/USPS>

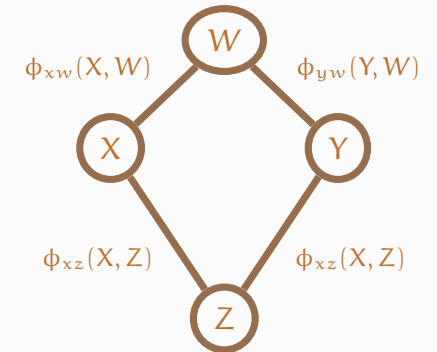
I



$$X, Y, Z, W \in \{0, 1\}$$

Ismerjük:

$$[\phi_{xw}, \phi_{yw}, \phi_{xz}, \phi_{yz}]$$



**Számítsuk ki:**  $p(Y = 1 | W = 1)$

Milyen esetekben jók/nem jók a GM-ek ?

<http://www.cs.bkk.eluj.ro/~csatolehel/mestint/USPS>

II

USPS adatok


- United States Postal Service;
- kézzel írott számjegyek  $16 \times 16$ -os bit-térképe;
- $\approx 7200$  tanulási- és  $\approx 2000$  teszt-adat;

Feladat:

- **Bináris osztályozás:** válasszuk el a négyeseket (4) a hetesektől (7).
- Írjunk **egy** osztályozási algoritmust a következők közül: Döntési fa; Neurális háló; SVM; Bayes osztályozó.
- Értékeljük az algoritmust a következők szerint:
  - ▶ osztályozási hiba tanulási adatokon;
  - ▶ **osztályozási hiba teszt-adatokon – 10% alatt!**;
  - ▶ tanulási idő;
  - ▶ vizsgáljuk meg a rosszul osztályozott „pontokat”;

# Osztályozás

III



4 7 7 4 4 7 7 4 4 4 4 7 7 7 4 7  
-1 +1 +1 -1 -1 +1 +1 -1 -1 -1 -1 +1 +1 +1 -1 +1

# Osztályozás

V

## Program + dokumentáció:

(dolg...)

- Algoritmus kiválasztása;
- Tanulás – paraméterek becslése;
  - ▶ tanulási adatok beolvasása;
  - ▶ adatok transzformációja – pre-processzálás;
  - ▶ algoritmus paramétereinek inicializálása;
  - ▶ paraméterek tanulása.
- Tesztelés;
  - ▶ **teszt-adatok beolvasása** – függetlenek a tanulási mintáktól!;
  - ▶ adatok transzformációja – pre-processzálás;
  - ▶ algoritmus paramétereinek **beolvasása** – tanulási eredmény;
  - ▶ hiba mérés.
- Dokumentálás: algoritmus, módszer, **statisztika**

# Osztályozás

IV

## Osztályozó algoritmus:



### Tanulás:

- $\theta_0$  kezdőértékek
- tanulási adatok

$$D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\}$$

- Becslés:  $\theta_1 \rightarrow \dots \rightarrow$
- $\theta_{post}$ .

Közben: tanulási hiba mérés.

### Tesztelés:

- $\theta_{post}$  használata;
- új adatokra:

$$D_{test} = \dots$$

- hiba mérés tesztadatokon.

# Osztályozás

# Program

binclass.m

```
clear all;
% data generation
nTr = 200; nTe = 400;
[dX dY] = cL_data(nTr, [], 0);
ii_1 = find(dY==1);
d1 = dX(ii_1, :);
d2 = dX(setdiff([1:nTr], ii_1), :);
N_1 = size(d1, 1);
N_2 = size(d2, 1);

pi1 = N_1/nTr; pi2 = N_2/nTr;

mu1 = sum(d1, 1)/N_1; % class means
mu2 = sum(d2, 1)/N_2;

d = d1 - repmat(mu1, [N_1 1]);
sig1 = d'*d/N_1; sig1inv = sig1^(-1);

d = d2 - repmat(mu2, [N_2 1]);
sig2 = d'*d/N_2; sig2inv = sig2^(-1);

% generating nTe test data
[dX, dY] = cL_data(nTe, [], 0);
ii_1 = find(dY==1);
data1 = dX(ii_1, :);
data2 = dX(setdiff([1:nTe], ii_1), :);
N_1 = size(data1, 1);
N_2 = size(data2, 1);
```

```
% performing classification
log_sig1 = log(det(sig1))-log(pi1);
log_sig2 = log(det(sig2))-log(pi2);

% classification for data1
p_1=data1-repmat(mu1, [length(data1) 1]);
p_1=sum(((p_1*sig1inv).*p_1), 2);

p_2=data1-repmat(mu2, [length(data1) 1]);
p_2=sum(((p_2*sig2inv).*p_2), 2);

class(1, 1) = length( ...
    find(-p_1+p_2 > log_sig1-log_sig2) );
class(1, 2) = N_1 - class(1, 1);

% SIMILARLY for the second dataset
p_1=data2-repmat(mu2, [length(data2) 1]);
p_1=sum(((p_1*sig2inv).*p_1), 2);



p_2=data2-repmat(mu1, [length(data2) 1]);
p_2=sum(((p_2*sig1inv).*p_2), 2);

class(2, 2) = length( ...
    find(-p_1+p_2 > log_sig2-log_sig1));
class(2, 1) = N_2 - class(2, 2);


% the confusion matrix:
class
```

... grafikus ábrázolás ...


## Eredmény:

Class-cond. prob.  $C_1$ Class-cond. prob.  $C_2$ 

Posterior probability



Classification boundary



## „Tanuló” rendszerek

pp. 525 – Russell &amp; Norvig, 1995

„Agents that can improve their behaviour through diligent study of their own experiences.”

- Algoritmus változtatható állapottérrel, mely működése során az újabb – ugyanolyan típusú – feladatokat **jobban** oldja meg.
- Példák: genetikus algoritmus, neurális hálók, stb.
- „Machine Learning” – „Gépi tanulás”.
- Induktív rendszerek – inferencia.



A gépi fordítás – annak ellenére, hogy régóta vizsgált tudományág – nem versenyezhet a tolmácsokkal.

Még akkor sem, ha az egyértelmű szókészlettel rendelkező, kifejezetten formális szövegeket produkáló területeken – például a repülőgép-gyártásban – figyelemreméltó eredményeket érnek el.

## Korpusz

- Nagymennyiségű strukturált, elektronikusan tárolt szövegbázis;
- Egy adott nyelvet reprezentál, akár több tízmillió szóból is állhat;
- Általában alterületen használják: statisztikai elemzésekre, illetve nyelvi törvények érvényességének vizsgálatára.
- A gyűjtemény lehet egyetlen (monolingual) vagy két (több) nyelvű (multilingual). A rendszer így tanulja meg, hogy egy nyelv szavai és kifejezései miként kapcsolódnak egy másik nyelv kifejezéseihez és szavaihoz.

Bebizonyosodott, hogy **METISII** a hosszú évtizedek fejlesztésének eredményeként létrejött piacvezető – szabályalapú – rendszerrel is képes felvenni a versenyt.

## Indukció

– | –


## Dedukció

## Induktív megoldás

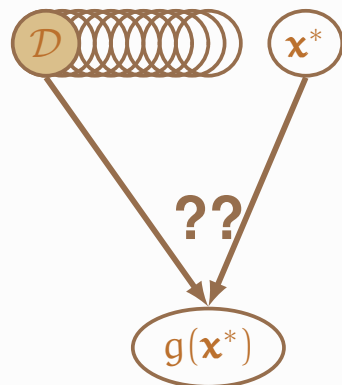
## Deduktív megoldás

- Modell feltételezése:  $f(\mathbf{z}, \theta)$ ,
- Adatok halmaza:  
 $\mathcal{D} = \{\mathbf{z}_1, \dots, \mathbf{z}_N\}$
- Illesztő – hiba – függvény:  
 $L(f(\mathbf{z}))$
- „optimális modell”:  $\theta^*$
- **Predikció**:  $f(\mathbf{z}, \theta^*)$ .
- Nincs modell,
- Adatok:  $\mathcal{D} = \{\mathbf{z}_1, \dots, \mathbf{z}_N\}$
- Illesztési művelet egy  $\mathbf{z}$  új mintára,
- használunk minden adatot.

## Induktív megoldás



## Deduktív megoldás



„Levezetjük” a  $g$  függvény  $x^*$ -hoz tartozó értékét.

## Induktív módszerek

I

adatokból „információt” vonnak ki;<sup>6</sup>

## Inductive learning methods

Systematically produce intensional concept descriptions from extensional concept descriptions.

I.e, **from the specific knowledge** provided by domain examples, ~ obtain **general domain knowledge**.

## Információ induktív rendszereknél

Egy indukció folyamán az adatokból „nyert” információt a modell paramétereit tárolják.

Egy  $\mathcal{F} \stackrel{\text{def}}{=} \{f(x|\theta), \theta \in \Omega\}$  modell esetén a  $\mathcal{D}$  adatokat az optimális  $\hat{\theta}$  paraméter helyettesíti.

<sup>6</sup>Hogyan definiáljuk az információ fogalmát?

„Becslés” egy modell ismeretében.

- Modell-osztály;
- Modellek közötti preferencia  $\Rightarrow \hat{\theta}$ ;
- Predikció a modell alapján;
- PI: lineáris becslések, neurális hálók;
- Döntési/regressziós fák;
- Rejtett változós modellek

- A cél **egy ismert** adatra egy választ fogalmazni;
- A válasz: kategoriális, folytonos ...
- K-nn:  $K$  legközelebbi szomszéd alapján történő közelítés;
- Rezolúció: egy ismert predikátumról eldönteni, hogy igaz vagy hamis.

A továbbiakban **Induktív módszerekkel** foglalkozunk.

## Induktív módszerek

II

„Információ” -  $\hat{\theta}$ :

- egy  $f(x|\theta)$  függvényt keresünk.
- $\hat{\theta}$  az optimális függvény „koordinátája”.
- **Nem ismerjük az adatokat generáló függvényt**

**Melyik paraméter jobb?**

**Tesztelési módszer:**

- az adatokat kettéosztjuk: tanulási- illetve **teszt**-adathalmaz;
- az optimális  $\hat{\theta}$  meghatározásához **csak** a tanuló-adatokat használjuk;
- Tesztelés: **hiba mérése a teszt-adathalmazon**.

## Cross-validation:

- módszer, mely méri a tanulási folyamat eredményességét;
- olyan esetekben használatos, ahol nincs modell illetve külön teszt-adat;

## Módszer:

- a **teljes** adat felosztása:  $K$  részre;
- tanulási-, illetve teszt-adatok **definiálása**:
  - ▶  $j$ -dik rész a **teszt-adat**;
  - ▶  $\{1..K\} \setminus j$  tanulási adatok.
- minden  $j$ -re mérjük a teszt-hibákat. (összegezzük / átlagoljuk)

# Döntési/Regressziós fák

## Regresszió:

$$f : \Omega \rightarrow \mathbb{R}$$

## Osztályozás:

$$f : \Omega \rightarrow \{\text{Igen}, \text{Nem}\}$$

### Definíció:

- fa formájában tárol egy függvényt;
- leszármazottak nélküli csúcs - levél; másképp belső csúcs;
- minden **belső csúcs**hoz van egy predikátum rendelve; Például:
  - ▶  $\text{Kor} < 20$ ,
  - ▶  $\text{Fogl} \in \{\text{Diak}, \text{Tanar}\}$ .

- szabályok megállapítására szolgál;
- általánosítások – extrapolálás;
- Nem fontos az adatok diszkrét/folytonos léte;

## Cross-validation

### Előnye:

- nem függ a hibafüggvénytől illetve az adatok típusától (diszkrét, folytonos, strukturált);
- könnyen kódolható.

### Hátránya:

- Nagy adathalmazra sokáig fut;
- **Nem alkalmazható paraméterek becslésére.**

# Döntési fák I

- sorrend-függő az eredmény;
- szomszédság/topológia meghatározása: modellezési kérdés.
- Sok adat  $\implies$  **nagy fa**, redundáns modellezés.

## Logikai bemenő adatok esetén:

- Bináris fa természetes;

## Folytonos bemenő adatok esetén:

- El kell dönteni egy-egy ág érvényességét;  $\Leftrightarrow$
- Diszkrétizálni kell a teret;  $\Leftrightarrow$
- Modellezési feladat



## Döntési fa építése

### Rekurzívan:

- Vizsgáljuk meg az adatokat és állapítsuk meg a **legjobb vágást**;
- Osszuk ketté az adatokat a vágás szerint;

### ? Kérdések ?

- Megállás;
- Legjobb vágás keresése;

**Vágások minősége:** CART (Classification and Regression Trees) algoritmus.

# Netlab

## II

### Netlab használata:

- Installálás: letöltés és: `addpath('_netlab_path_')`
- Demók indítása: `demnlab`
- Programozás a demók módosításával, pl. `demmlp1`

### Példa:

```
%data generation.
ndata = 20;
noise = 0.2;
x = {0:1/(ndata - 1):1}';
t = sin(2*pi*x) + noise*randn(ndata, 1);
% Set up network parameters.
nin = 1; % Number of inputs.
nhidden = 3; % Number of hidden units.
nout = 1; % Number of outputs.
alpha = 0.01; % weight-decay prior.
% Initialisation
net = mlp(nin, nhidden, nout, 'linear', alpha);
```

```
% Option vector intialisation
options = zeros(1,18);
options(1) = 1; % display error values.
options(14) = 100; % Number of training cycles.
% Train using scaled conjugate gradients.
[net, options] = netopt(net, options, x, t, 'scg');
% Plot for TEST data
plotvals = {0:0.01:1};
y = mlpfwd(net, plotvals);
```

A **Netlab** programmal egyszerűen megoldható a laborfeladat.

Ian T. Nabney: NETLAB  
Algorithms for Pattern Recognition  
Springer 2002

<http://www.ncrg.aston.ac.uk/netlab>

### Matlab függvény-gyűjtemény

- Ingyenesen letölthető; egyszerűen kezelhető;
- **Nagyon** sok modell és algoritmus tesztelhető – anélkül, hogy a modelleket implementálni kellene;

### Implementált modellek és algoritmusok: (módosítható demó-k)

- Regresszió
- Osztályozás
- Klaszterezés
- Bayes-módszerek
- Optimalizálás
- Mintavételezés

# Nehéz feladatok

Néha NEM lehet a gradiens-szabályokat alkalmazni mert:

- Túl bonyolult a modellben a paraméter–kimenet kapcsolat. PI.
- A paraméterek **nem** numerikusak. PI. szemantikus hálók vagy Bayes-hálók tanulása.

### Azonban:

- képesek vagyunk a  $\theta$  paraméter jóságának a mérésére,
- Van egy „szomszédosság-reláció” a paraméterek között,

## Hibafűggvény:

Méri az  $\mathcal{F}$  modellcsalád egy elemének – az  $f(\mathbf{x}|\boldsymbol{\theta})$  függvénynek – a „jóságát”.

Például - négyzetes hiba:

$$L(\mathcal{D}, f(\cdot|\boldsymbol{\theta}), \mathcal{F}) = \sum_n (y_n - f(\mathbf{x}_n|\boldsymbol{\theta}))^2$$

Egy  $\mathcal{D}$  adathalmaz hibája – **empirikus hiba**

## Szomszedság:

A  $\boldsymbol{\theta} \in \Omega$  paraméterek (pl. fák) esetén:

$$\boldsymbol{\theta}' \in \delta_\epsilon(\boldsymbol{\theta}) \quad \text{ha } d(\boldsymbol{\theta}, \boldsymbol{\theta}') < \epsilon$$

A paraméter-tér bejárására szolgál  $\rightarrow$  összekötött halmazoknál jó.

**Gyakorlatban** nehezen kivitelezhető, mert:

- **Nem** lehet felsorolni az  $\Omega$  összes elemét;
- **Nem** könnyű egy modell hibájának a kiszámítása – gyakran műszeres mérésekről van szó;  $\implies$

**Közelítő módszerek alkalmazása** – a „szomszedság” felhasználásával:

$$\boldsymbol{\theta}_0 \rightarrow \boldsymbol{\theta}_1 \rightarrow \dots \rightarrow \boldsymbol{\theta}_T$$


ahol az iterációk alatt „javul” a  $\boldsymbol{\theta}$  illeszkedése az adatokhoz.

## Eloszlás:

$$p(\boldsymbol{\theta}|\beta) \propto \exp \left[ -\frac{1}{\beta} L(\mathcal{D}, f(\cdot|\boldsymbol{\theta}), \mathcal{F}) \right]$$

$$p(\boldsymbol{\theta}|\beta) = \frac{\exp \left[ -\frac{1}{\beta} L(\mathcal{D}, f(\cdot|\boldsymbol{\theta}), \mathcal{F}) \right]}{\sum_{\boldsymbol{\theta} \in \Omega} \exp \left[ -\frac{1}{\beta} L(\mathcal{D}, f(\cdot|\boldsymbol{\theta}), \mathcal{F}) \right]}$$

- Az  $f(\mathbf{x}, \hat{\boldsymbol{\theta}})$  modell optimális a legnagyobb  $p(\hat{\boldsymbol{\theta}})$ -nál;
- $\beta$  – „hőmérséklet” paraméter;
- $\beta$  kezdőértéke nagy  $\implies$  nincsenek nagy különbségek;
- $\beta \searrow 0$  - egy állapot választódik ki.



Általában a „hűtést” szabályozzuk:  $\{\beta_t\}_1^\infty$ .

## Algoritmus:

- 1 Adat-beolvasás:  $\mathcal{D}$ ;  $t = 0$ ;  
Inicializálás:  $\boldsymbol{\theta}_0$ ; Számítjuk:  $L(\mathcal{D}, f(\mathbf{x}|\boldsymbol{\theta}_t))$ ;
- 2 Választunk a szomszedság alapján:  $\boldsymbol{\theta}' \in \delta_\epsilon(\boldsymbol{\theta}_t)$   
Számítjuk:  $L(\mathcal{D}, f(\mathbf{x}|\boldsymbol{\theta}')) \rightarrow p(\boldsymbol{\theta}'|\beta_t)$ ;
- 3 Ha  $p(\boldsymbol{\theta}'|\beta_t) > p(\boldsymbol{\theta}_t|\beta_t)$ , akkor  $\boldsymbol{\theta}_{t+1} = \boldsymbol{\theta}'$ ,
- 4 ellenkező esetben –  $\alpha \in [0, 1]$  véletlen szám – ha  $\alpha \leq p(\boldsymbol{\theta}'|\beta_t)/p(\boldsymbol{\theta}_t|\beta_t)$  akkor  $\boldsymbol{\theta}_{t+1} = \boldsymbol{\theta}'$   
másképp  $\boldsymbol{\theta}_{t+1} = \boldsymbol{\theta}_t$
- 5  $t = t + 1$  Goto 2

Használható esetekben, ahol

- van hibafüggvény;
- nem folytonos a paraméterhalmaz;
- nincs gradiens információ – vagy nem használható;

Például: VLSI-design.

~ használata

- könnyű – nem igényel sok kódolást vagy tanulmányozást;
- **nem hatékony** – a futási idő nagyon nagy – egyszerű feladatoknál is.

Genetikus algoritmusok

I

A szimulált kifűtés továbbfejlesztése:

- 1 Nem **egyetlen** paramétert optimalizál;

populáció  $\forall t \{ \theta_k^{(t)} \}_{k=1}^K$

- 2 Definiálja a **genetikus operátorokat**.

kereszteződés  $cr(\theta_k^{(t)}, \theta_l^{(t)}) = \theta_m^{(t+1)}$

mutáció  $m(\theta_k^{(t)}) = \theta_m^{(t+1)}$

az operátorok az egyedek szintjén működnek.

Az iterációs séma hasonló

$$\{ \theta_k^{(0)} \}_{k=1}^K \rightarrow \{ \theta_k^{(1)} \}_{k=1}^K \rightarrow \dots \rightarrow \{ \theta_k^{(T)} \}_{k=1}^K$$



John R. Koza - Stanford University

<http://www.genetic-programming.com/coursemainpage.html>

Genetikus algoritmusok


II

Genetikus algoritmusok működése

- „természetes” **szelekció**;
- genetikus operátorok a paraméter-tér bejárására.

Algoritmus: (minden  $t$  időpontban)

$$\{ \theta_k^{(t)} \}_{k=1}^K \Leftrightarrow f_k^{(t)} = \exp \left[ -\frac{1}{\beta} L(\mathcal{D}, f(\cdot | \theta_k^{(T)})) \right]$$



Következő generáció létrehozása:

- 1 Az  $[f_k^{(t)}]_k$  „fitnessz” faktorral arányosan választunk szülőket:  $\theta_l^{(t)}, \theta_l^{(t)}$
- 2 Bemásoljuk azokat a populációba vagy
- 3 alkalmazzuk a genetikus operátorokat: kereszteződés, mutáció;

## „Fitnessz”-függvény

- méri az **egyedek** megfelelését – **jóságát**
- Fordítottan arányos az  $L(\cdot)$  **hibával**

$$\{\theta_k^{(t)}\}_{k=1}^K \Leftrightarrow f_k^{(t)} = \exp \left[ -\frac{1}{\beta} L(\mathcal{D}, f(\cdot | \theta_k^{(T)})) \right]$$

- a cél, hogy minél több egyed legyen, melynek nagy a „fitnessz”-értéke;
- $\beta$  - hőmérséklet-paraméter
  - 1 a relatív érzékenységet modulálja;
  - 2 nagy hőmérséklet = különbségek nem jelentősek;
  - 3 kis hőmérséklet  $\beta \searrow 0$  – a leg-„fittebb” egyed sokkal jobb, mint bármely más;

## Operátorok

keresztveződés és mutáció

- Keresztveződés
  - ▶ a szülők „tulajdonságait” kombinálja;
  - ▶ a gyerekek „közel” lesznek a szülőkhöz;

## Keresztveződés

„születnek” egyedek, melyek **halmozzák** a jó tulajdonságokat;

- Mutáció
  - ▶ szelekció nyomán csak a jó egyedek maradnak fent;
  - ▶ ez a genetikus operátor biztosítja a változatosságot;
  - ▶ olyan értékek is kiválasztódnak, melyek nem voltak a korábbi generációkban;

## Mutáció


„radikális” változás, mely esetenként jobb eredményhez vezet;

## Szelekció

- garantálja a következő **populáció** optimalitását;
- **csak** a kiválasztott – szelektált – egyedek részei a következő generációknak;
- véletlen, de **súlyozott** választás;


## Szelekciós algoritmus:

- 1 Számoljuk ki:  $F(t) = \sum_k f_k^{(t)}$
- 2 generáljuk  $\alpha = \text{rand}(0, 1)$
- 3  $l = 0, s = 0$
- 4 amíg  $s < \alpha \cdot F(t)$ 
  - ▶  $l = l + 1$
  - ▶  $s = s + f_l^{(t)}$



miért maradnak csak a jobb egyedek?

## Genetikus operátorok: – folyamatos paraméterter

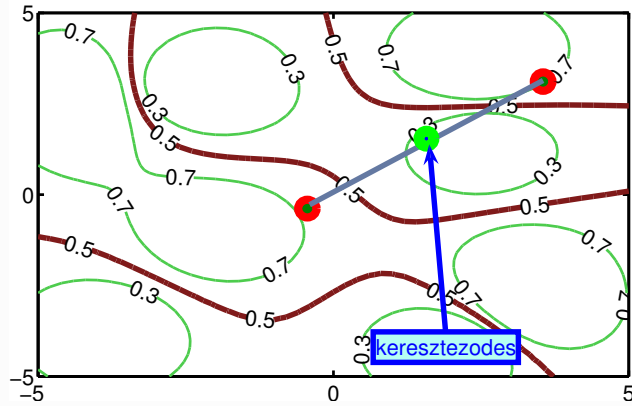
Mutáció: ha  $\theta \in \mathbb{R}^m$ 

$$m(\theta) \stackrel{\text{def}}{=} \theta + \delta$$

Keresztveződés:

$$cr(\theta_1, \theta_2) \stackrel{\text{def}}{=} (\theta_1 + \theta_2) / 2$$

**Kereszteződés / mutáció : ! heurisztikák !**



**Heurisztika:** Nem mindig működik;

Jobb eredményeket remélünk, garancia **nélkül**.


- Genetikus algoritmusok ⇔ az operátorok **definíciója**;
- **Numerikus esetek** kevésbé érdekesek;

**Példa: Utazóügynök (Travelling SalesPerson – TSP)**

- Városokat bejárni úgy, hogy a **megtett út** minimális legyen.
- **Egzakt megoldás:** nagyon időigényes; NP-teljes feladat.
- **Genetikus algoritmus:**
  - ▶ nem garantálja a **legrövidebb** út megtalálását;
  - ▶ azonban egy közel-optimális utat **gyorsan** megtalál;


**Kódolás:** az utak egy permutációja.

Pl. [1, 2, 5, 3, 4, 6, 7, 8, 10, 9, 11, 12]




**Genetikus operátorok:**

**Mutáció:**




**Kereszteződés:**



**Genetikus programozás**

- a populáció egyedei **programok**;
- programok egy **függvényt** implementálnak;
- genetikus operátorok a programok terén értelmezettek;
- program = függvény.



○○○

## Genetikus algoritmusok

- populációkkal operálnak;
- szelekciós és reprodukciós operátorok használata;
  - ▶ genetikus operátorok gyorsítják a keresést;
  - ▶ szükséges a program-/paraméter-tér ismerete.
- a „fitnessz”-érték irányadó ⇔ optimalizálás;

## „Genetikus” Algoritmus


- általános optimum-keresési módszerek, „szomszédság”-ismerete elégséges;
- ha a fitnessz-függvény differenciálható, numerikus módszerek használata ajánlott;

## Történeti áttekintő

## IdegSejt




Ramon y Cajal



- 1894 – 1900 közötti időszakban;
- idegrendszer vizsgálata;
- építőegység azonosítása: **neuron**;
- idegsejt – mint az idegrendszer építőeleme

„**Twendy-One**”, a „**Wendy**” robot 21.-edik századi reinkarnációja.

A robot képes törékeny tárgyak hordozására valamint emberek segítségére a leülés illetve felállás műveleteiben. Érzékelőin keresztül válaszol az emberi érintésekre.



Képes egy szelet kenyér megfogására, ugyanakkor képes embereket kiségetni az ágyukból.


„Az első ennyire nagyfokú integrációval rendelkező robot.” – mondta Shigeki Sugano, a Waseda Egyetem tanára, a *Twendy-One projekt* vezetője.

pcWorld hír

ABCnews hír

## Történeti áttekintő

## Neuron



Ramon y Cajal

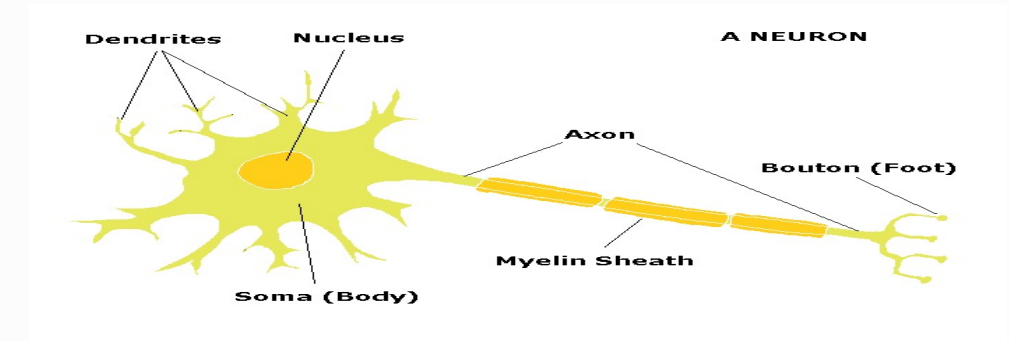

Nobel díj 1906

*The cerebellar cortex (a kitten cerebellum).*

*The letter A marks the Purkinje cells with dendritic ramifications.*

<http://nobelprize.org/medicine/articles/cajal/>

Idegsejt fényképe:

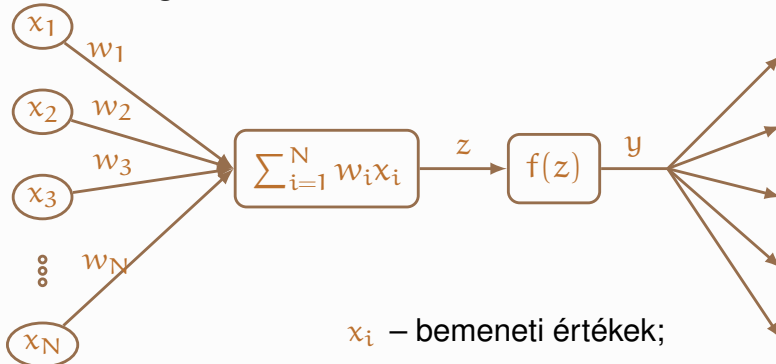


## Neuron alkotóelemei

- Szóma (sejtmag) – az információ **feldolgozása**;
- Dendrit – az információ **összegyűjtése**;
- Axon – az információ **terjesztése**;


*mi az információ?*<http://www.ship.edu/~cgboeree><http://en.wikipedia.org/wiki/Neuron>

## „Mesterséges” Neuron


 $x_i$  – bemeneti értékek; $w_i$  – súlyok (dendritek); $\sum \dots$  – összegző (szóma); $f(z)$  – átalakító;

→ – kapcsolatok (axonok);

Ahol:



- aszinkron működés;
- **nagyon** sok kapcsolat;
- **?hogyan?** kreáljunk/töröljünk kapcsolatokat;




- szinkron – ciklusos – működés;
- rétegek  $\Rightarrow$  korlátolt számú kapcsolat;

- Idegrendszer = információ-feldolgozó egység.  
Kérdések (nincsenek kellően tisztázva):
  - ▶ Mi az információ,
  - ▶ Hogyan történik a feldolgozás.
- biológiai neuronok aszinkron-működésűek: miért jó a mesterséges neuron szinkronizált jellege.
- mesterséges neuronok egymáshoz kapcsolódása csekély: a biológiai rendszerek nagyságrendekkel több kapcsolatot kezelnek.

## Perceptron

I

## Egyszerűsített természetes neuron-modell:



- Korai neuron-modell: McCulloch-Pitts ~ 1958;
- $x_i$  és  $y$  értékek binárisak;
- Aktivációs függvény a lépcsőfüggvény:

$$H(z) = \begin{cases} -1 & \text{ha } z < 0 \\ +1 & \text{ha } z \geq 0 \end{cases}$$

## Perceptron

II

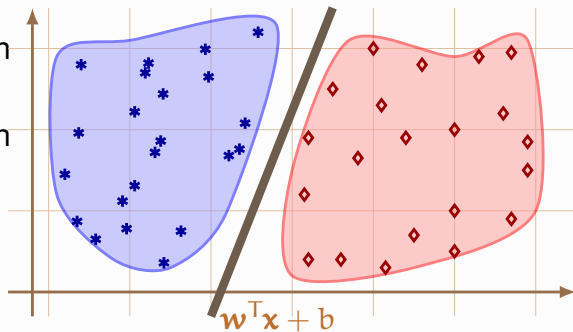
## Perceptron

- ON/OFF neuron állapotok  
*A neuronok vagy aktívak vagy nem, mint a bináris logikában*  
*rezolúció-szerű működés*
- Tanulási szabály: ha  $(\mathbf{x}^{(n)}, \mathbf{y}^{(n)})$ -en hiba történt, akkor
 
$$w_i(t+1) \Leftarrow w_i(t) + x_i^{(n)} y^{(n)}$$
 ahol  $w_{ij}$  súly,  $\mathbf{x}^{(n)}$  bemeneti minta,  $\mathbf{y}^{(n)}$  a minta osztálya.
- Konvergencia-tétel: Ha a
  - ▶ tanulási minták
  - ▶ elválaszthatóak, def
 akkor a perceptron konvergál.
 
$$\{(\mathbf{x}^{(n)}, \mathbf{y}^{(n)})\}_{n=1}^N$$
 (osztályozási feladat)



# Elválaszthatóság

kék osztály kódja legyen +1;  
 piros osztály kódja legyen -1;



**Szeperáló** hipersík a  $\{w, b\}$  vektorral illetve valós szám által meghatározott felület, ha

$$w^T x_i + b > 0 \quad \forall i \quad ; \quad y_i > 0.$$

$$w^T x_i + b < 0 \quad \forall i \quad ; \quad y_i < 0.$$

## Perceptron

## Konvergenciatétel

### Konvergenciatétel

A tanulási szabály alkalmazásával a perceptron **véges** idő alatt konvergál.

**Biz:**

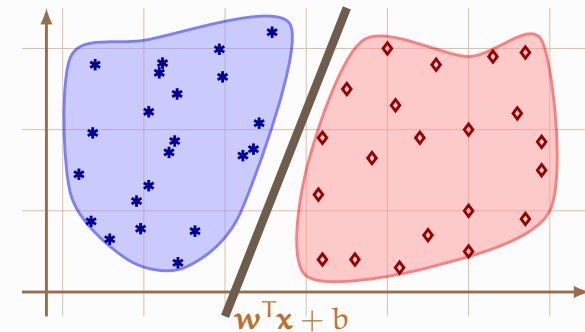
*Módszer:* találjunk – felső és alsó – korlátot a lépések számának.

1 Újrdefiniáljuk a bemeneti adatokat:

$$\hat{x}_i \stackrel{\text{def}}{=} [x_i, 1]^T \in \mathbb{R}^{d+1} \quad \Rightarrow \quad w \stackrel{\text{def}}{=} [w, b]^T \in \mathbb{R}^{d+1}$$

$$x_i \stackrel{\text{def}}{=} y_i \hat{x}_i$$

# Elválaszthatóság



**Szeperáló** hipersík:

$$y_i (w^T x_i + b) > 0 \quad \forall i = 1, N.$$

ahol  $x_i$  -  $i$ -edik mintavektor és  $y_i$  az ahhoz tartozó osztály kódja.

▶ vissza

## Konvergenciatétel

## II

2 Újrdefiniált feladat

Találjunk **egy** (1)  $w \in \mathbb{R}^{d+1}$  értéket úgy, hogy

$$\forall i \quad ; \quad w^T x_i > 0$$

minden  $x_i$ -re (már tartalmazzák a címkéket is).

3 Tanítási szabály

Ha hiba történt, akkor módosítjuk a perceptron súlyait:

$$w_i(t+1) \Leftarrow w_i(t) + x_i^{(n)}$$

(rekurzívan visszafejtve:  $w(t+1) = x^1 + \dots + x^t$ )

4 Hiba  $\Leftrightarrow w^T(t)x^{(n)} < 0.$

(1) Amennyiben van egy érték, akkor **nagyon sok** elfogadható érték létezik.

5 **Feltételezzük**, hogy létezik szeparáló hipersík:

$$\exists \mathbf{w}_0 \in \mathbb{R}^{d+1} \forall i ; \mathbf{w}_0^T \mathbf{x}^{(n)} \geq \alpha > 0$$

6 Vizsgáljuk a  $\mathbf{w}_0^T \mathbf{w}(t+1)$  skaláris szorzatot:

$$\mathbf{w}_0^T \mathbf{w}(t+1) = \mathbf{w}_0^T \mathbf{x}^1 + \dots + \mathbf{w}_0^T \mathbf{x}^t \geq t\alpha$$

7 Cauchy-Schwartz egyenlőtlenség  $\|\mathbf{a}\|^2 \|\mathbf{b}\|^2 \geq (\mathbf{a}^T \mathbf{b})^2$  alkalmazzuk:

$$\|\mathbf{w}_0\|^2 \|\mathbf{w}(t+1)\|^2 \geq (\mathbf{w}_0^T \mathbf{w}(t+1))^2 \geq (t\alpha)^2$$

vagyis

$$\|\mathbf{w}(t+1)\|^2 \geq \frac{(t\alpha)^2}{\|\mathbf{w}_0\|^2}$$

## Matlab Demó

## I

**Kódoljuk** a perceptron algoritmust:

- generáljuk az adatokat. Specifikáljuk:
  - ▶ az adatok dimenzióját, számát;
  - ▶ az elválasztó hipersíkot;
  - ▶ generáljuk a bemeneti mintákat illetve az azokhoz tartozó kimeneti osztálykódokat.
- Transzformálunk a konvergenciatétel szerint.
- Inicializáljuk a perceptront **zeró** értékekkel.
- Futtatjuk az algoritmust:
  - ▶ mérjük a hibajavító lépéseket;
  - ▶ mérjük a ciklusok számát.

Másrészt - minden **tanuló lépésnél**:

8  $\mathbf{w}(t+1) = \mathbf{w}(t) + \mathbf{x}^{(t)}$ , tehát:

$$\begin{aligned} \|\mathbf{w}(t+1)\|^2 &= \|\mathbf{w}(t) + \mathbf{x}^{(t)}\|^2 \\ &= \|\mathbf{w}(t)\|^2 + 2\mathbf{w}(t)^T \mathbf{x}^{(t)} + \|\mathbf{x}^{(t)}\|^2 \\ &\leq \|\mathbf{w}(t)\|^2 + \|\mathbf{x}^{(t)}\|^2 = t\beta^2 \end{aligned}$$

Ahol  $\beta^2 = \max \{\|\mathbf{x}^{(n)}\|^2 ; n = 1..N\}$

9 Van tehát két egyenlőtlenség, melyből kiszámítható a **t maximális értéke**:

$$t_{\max} \leq \frac{\|\mathbf{w}_0\|^2 \beta^2}{\alpha^2}$$

Tehát a perceptron konvergál □

## Matlab Demó

## II

**Matlab kód:**

```
1 % ADATOK parameterei
dim = 9;
N = 200;
% az elvalasztó hipersík
w_0 = [1;-3; 4;-1; 2;-6;-5; 5; 3];
6 b = 2;
% adatgeneralas
X = sign(rand(N,dim) - 0.5);
% cimkek generalasa
Y = sign(X*w_0 + b);
11 % hatar-mintak szurese
idx = find(~Y);
idx = setdiff([1:N],idx);
X = X(idx,:); Y=Y(idx);
N = length(Y);
```

```

%% Perceptron tanulas %%%%%%%%%
% 1 mintak atalakitasa
X = [ X ones(N,1)];
% 2
5 XX= diag(Y) * X;
%% Tanulas -- lokalis valtozok beallitasa
w = zeros(dim+1,1);
Term = 0;
steps = 0; sweeps = 0;

```

Kiíratjuk a statisztikákat:

```

1 fprintf('\nTeljes bejarasok szama: %d\n',sweeps);
fprintf('Eredmeny: ');
fprintf('%4d ',w); fprintf('\n');
fprintf('Kezdo hipersik:');
fprintf('%4d',[w_0;b]); fprintf('\n');

```


```

1 while ~Term;
   Term = 1;

   for ii=1:N;
       if XX(ii,:) * w <= 0
           w = w + XX(ii,:)' ;
           steps = steps + 1;
           fprintf('%d:',steps); % megj.
           fprintf('%4d',w); fprintf('\n');
           Term = 0;
       end;
   end;
   sweeps = sweeps +1;
end;

```


## Összefoglaló



- '60-as évek tanulási paradigmája;
- Logikai függvényeket keres – bemenet és kimenet **binárisak**;
- Cél a gondolkodás modellezése
- **Nem tudja** szeparálni az **XOR** művelet kimeneteit (Minsky és Papert '62)

### Feladat:

találjunk **konfigurációt**, mely az **XOR**-t helyesen osztályozza.



- A perceptron egy **black-box** – fekete doboz – módszer;
- Valós életről vett feladatok megoldására lehet használni:
  - 1 Gyűjtünk adatokat,
  - 2 Építünk modellt,
  - 3 Tanítjuk a modellt,
  - 4 **Paraméterek** = modell kiválasztása.
- A későbbi neurális háló modellek jó példái a fenti **automatizált** feladatmegoldási paradigmának.
- A neurális hálózat modelleket nagyon sokáig – ma is – használ(j)ták modellezésre.



A very smart group: (left to right) Andrew Ng, Gary Bradski, Chris Manning, STAIR, Nils Nilsson, Sebastian Thrun, and Daphne Koller


A robotok programozásánál **nem volt lehetséges** speciális előprogramozás nélkül összeszedni a mosatlant vagy megegetetni a cicákat.  
 A robotok hagyományosan 3D-s modellt készítenek környezetükről. Erre általában két kamerát használtak, a távolságokat idő- és számítási kapacitás-igényes munkával, az adott tárgy pontjainak tömege alapján határozták meg.  
 A STAIR alternatív megoldást kínál: pontok sokasága helyett az algoritmus az adott tárgy megfogható részének a középpontját azonosítja. Élek hosszúságát számolja ki, majd az eredményt az adatbázisban levő statisztikailag hasonló tárgyakkal veti össze.  
 A szoftver ezek alapján hozza létre a háromdimenziós modelleket; lényegesen gyorsabban és kevesebb munkával, mint a régi megközelítésben.

Stanford STAIR

agens.ai

Többrétegű Hálók


- Az információ – **számok** – a bemeneti **X** rétegből a kimeneti **Y** réteg fele halad.
- Egy mintára kiszámítjuk a kimeneti értékét, minden neuron értékét kiszámítva.
- Feltételezzük, hogy minden – adat és súly – folytonos.



MLP **NEM** Bayes-háló

A neurális hálók kapcsolatai **kommunikációt**, a Bayes-hálók kapcsolatai **függőséget** jelentenek.

Többrétegű Hálók



MI az információ?

„Formálisan”:

- A neuronháló csúcsai az **információt** feldolgozzák.

$$y_{ki} \stackrel{\text{def}}{=} f_{akt}(x_{be})$$

- Az élek: a csúcsok közötti kapcsolatok.

$$x_{be}^{(i)} \stackrel{\text{def}}{=} \sum_j w_{ij} x_{ki}^{(j)}$$

- A fenti lépések ismétlődnek.


definíció szerint  $x_{ki} \in \mathbb{R}^k$

A **bemenő** aktivitás:

$$y_j = \sum_i w_{ij} x_i + b_j.$$

A perceptron tanulási algoritmushoz hasonlóan:

- előbb:  $\mathbf{x}'_i = [x_1, \dots, x_d, 1]^T$
- $\Rightarrow \mathbf{w}'_j = [w_1, \dots, w_d, b]^T$



## Univerzális approximáció


A következő rendszer:

$$f_M(z|\mathbf{w}, \mathbf{b}) = \sum_{m=1}^M w_m f(z - b_m)$$


univerzális approximátor, azaz

$$\forall \delta > 0 \forall g \in L^2(\mathbb{R}^d) \exists M, \mathbf{w}, \mathbf{b} \text{ ú.h. } \|g - f_M(z|\mathbf{w}, \mathbf{b})\|_{L_2} \leq \delta$$

## Aktivációs függvények



Véletlen függvények a függvényosztályokból:



**Univerzális approximátor:** bizonyítás a szint-halmazokon alapszik (lásd Lebesgue integrálás).

**Vizualizálás:**

Mintavételezés a

$\mathbf{w}$  és  $\mathbf{b}$  értékekből

```
%Generato rfuggvények
f = inline('((x>0)-0.5).*2');
g = inline('2./(1+exp(-2*x))-1');
% komponensek szama
mComp = 10;
% fv.-nyek szama
nF = 6;
% X tengely
xx=-10:0.05:10;
xd= repmat(xx, [mComp, 1]);
% plot init
clf; hf = subplot(1,2,1);
set(gca, ...
'Position',[0.05 0.1 0.42 0.85],...
'YTick', [], 'XTick', []);
hold on; box on; ylim([-25, 25]);
set(gca, ...
'Position',[0.55 0.1 0.42 0.85],...
'YTick', [], 'XTick', []);
hold on; box on; ylim([-25, 25]);

hg = subplot(1,2,2);
% megjelenitesi stilus
style = {'b', 'r', 'k', 'm', 'c', 'g'};
% F.v.-nyek generalasa
for ii=1:nF;
% egyutthatok
ss=(2*rand(mComp, 1) -1)*6;
ww=(2*rand(mComp, 1) -1)*6;
bb=(2*rand(mComp, 1) -1)*10;
bd=diag(bb)*ones(size(xd));
y_f = sum(diag(ww) * f(diag(ss)*xd + bd));
y_g = sum(diag(ww) * g(diag(ss)*xd + bd));
% megjelenites
plot(hf, xx, y_f, style{ii}, 'LineWidth', 3);
plot(hg, xx, y_g, style{ii}, 'LineWidth', 3);
end;
% nyomtatás
print -depsc2 rand_fn.eps
```

## Backpropagation

- **Nem bináris függvényt közelít.**

A bemeneti/kimeneti értékek folytonosak.

$$f_{NN} : \mathbb{R}^d \rightarrow \mathbb{R}$$

- Folytonos esetben használható a **négyzetes hibafüggvény**:

$$E(\mathbf{w}_{NN}) = \frac{1}{2} \sum_{n=1}^N (y_n - f_{NN}(\mathbf{x}_n))^2$$

ahol  $\mathbf{w}_{NN}$  a neuronháló paraméterei.

- Differenciálható akt. függvényeknél a **gradiens szabály** alkalmazható  $\Rightarrow$  **backpropagation szabály**.

## Backpropagation

II

- **Error back-propagation**  $\Leftrightarrow$  négyzetes hiba visszaterjesztése
- Egy adott **tanulási halmazhoz** és egy  $w_{NN}$  neurális háléhoz rendelt négyzetes hiba

$$E(w_{NN}) = \frac{1}{2} \sum_{n=1}^N (y_n - f_{NN}(x_n))^2$$

akkor zéró, ha a neurális háló **minden** adatot jól közelít.

- Egy adott  $w_{NN}^{(0)}$  hálónál jobban közelítő hálót kapunk ha egy kis lépést végzünk a negatív gradiens irányába.

## Backpropagation


IV

**Differenciálás szabálya:**

$$\frac{\partial f(g_1(w_i), \dots, g_k(w_i))}{\partial w_i} = \sum_{g_j} \frac{\partial f(g_1, \dots, g_k)}{\partial g_j} \frac{\partial g_j}{\partial w_i}$$

**Neuronháló függvénye:**

$$y = \dots \left( \dots, f_j \left( \sum_i h_i w_{ij} \right), \dots \right)$$



$$\partial_{w_{ij}} E(\cdot) = \sum_j \partial_{f_j} E(\cdot) \partial_{w_{ij}} f_j \left( \sum_i w_{ij} h_i \right)$$

## Backpropagation

III

- **„Képletesen”**

$$w_{NN}^{(t+1)} \Leftarrow w_{NN}^{(t)} - \alpha \frac{\partial E(w_{NN}^{(t)})}{\partial w_{NN}^{(t)}}$$

$$\Leftarrow w_{NN}^{(t)} - \alpha \partial_w E(w_{NN}^{(t)})$$

ahol


$\alpha$  – tanulási együttható;

$\partial_w E(w_{NN}^{(t)})$  – a hiba gradiense (vektorok!).

**Kérdés:** milyen  $\alpha$  értékek megfelelőek?

**Kis lépések**  $\Rightarrow$  hosszú konvergencia.

**Nagy lépések**  $\Rightarrow$  nem konvergál.



## Backpropagation

V

(folyt)

$$\partial_{w_{ij}} E(\cdot) = \partial_{f_j} E(\dots) \partial_{w_{ij}} f_j \left( \sum_{n=1}^N w_{ij} h_i \right)$$


$$= h_i f_j' \left( \sum_{n=1}^N w_{ij} h_i \right) \partial_{f_j} E(\cdot)$$

**A bemeneti érték és a kimeneti hiba szorzódnak.**

$$\text{És } \partial_{f_j} E(\cdot) = \partial_{f_j} E \left( \dots, g_k \left( \sum_j v_{jk} f_j \right), \dots \right)$$

Lánc-deriválás szerint:

$$\partial_{f_j} E(\cdot) = \sum_k v_{jk} \partial_{g_k} E(\cdot) g_k'(\cdot)$$




**Az egyéni hibák súlyozottan összeadódnak.**

(folyt)

**Tehát:** amíg a működésnél a **jel előre** terjed, a tanulás folyamán a hiba **viisszafele**; a kimeneti réteg felől a háló bemenete felé „terjed”.

### Hiba-visszaterjesztés (BP)




azaz az osztópontok összegzővé alakulnak;



azaz az összegző csomópontok meg hiba-elosztóvá.

- A **BP** algoritmus a gradiens szabály alkalmazása a neuronhálókra;
- Az alap a **négyzetes** hiba;
- Egyszerűen implementálható;
- Nagyon sok alkalmazás;



### Hátrányok:

- Mivel gradiens, lassú  $\Rightarrow$  nagyon sokáig tarthat a tanulás.
- **Más módszerekkel** állítani be a súlyokat: *Newton, Konjugált gradiens*.
- **Nincs** a becült mennyiségre **konfidencia**  $\Rightarrow$  valószínűségi módszerek szükségesek.

Rosenbrock

**Feladat:** keressük a  $h(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$  függvény minimumát a gradiens szabály használatával.

$$\partial_1 h(\cdot) = 400(x_2 - x_1^2)x_1 + 2(x_1 - 1)$$

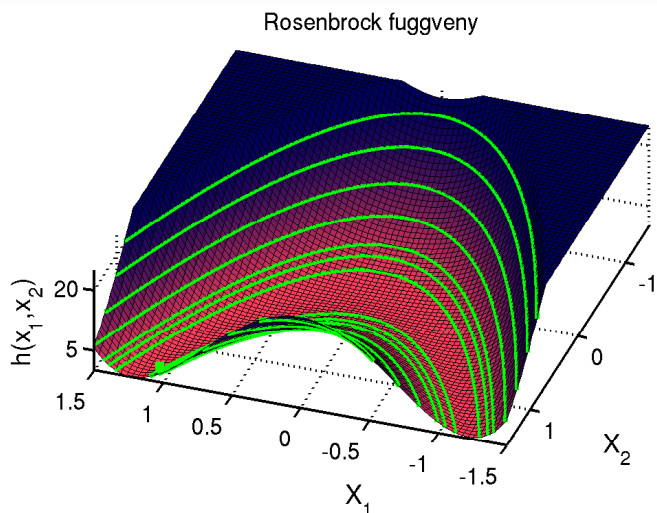
$$\partial_2 h(\cdot) = 200(x_2 - x_1^2)$$

A második egyenlet

$$\Leftrightarrow x_2 = x_1^2$$


Behelyettesítve  $x_1 = 1$ .

Induljunk a  $(-1, 1)$  pontból.



**BP szabály = gradiens** – általában **nagyon lassú**.

Rosenbrock fv. optimalizálás



- Neurális hálók **fekete-doboz** módszerek:
  - 1 minden feladat megoldására potenciálisan alkalmazhatóak;
  - 2 jó eredményekhez (majdnem mindig) kell egy kis igazítás a módszeren;
  - 3 siker függ a tapasztalattól;<sup>7</sup>

- **BackPropagation = gradiens tanulás**

- 1 általában **nagyon lassú**;
- 2 fejlett módszerek: konjugált gradiens módszerek, quasi-Newton, etc. **gyorsítanak a konvergencián**.
- 3 **lokális optimumok elkerülésére** többszálú optimalizálás, pl. mintavételezéssel kijelölni a kezdőértékeket.

<sup>7</sup>Érdemes tehát tovább tanulni.

### Organization of Behavior:

*When an axon of cell A is near enough to excite B and repeatedly or persistently takes part in firing it, some growth process or metabolic change takes place in one or both cells such that A's efficiency, as one of the cells firing B, is increased.*

(p. 62)

Neuroscience ⇔ „Hebb synapse”

„Hebb szabály”

$$\Delta w_{ij} = \alpha a_i a_j$$

Ahol

$a_i, a_j$  – neuronok aktivitásai;

$w_{ij}$  – az összekötő szinapszis erőssége;

$\alpha$  – tanulási együttható.



**D.O. Hebb**

*The organization of behavior*

### A neurális moduláció alapelvei:

- Két neuron között a kapcsolat erőssége arányos a neuronok pre-, illetve poszt-szinaptikus tevékenységével;
- Azon neuron-csoportok, melyek általában egyszerre tüzelnek, egy egységet alkotnak; (modularitás)
- A *gondolkodás* folyamata ezen sejt-csoportok szekvenciális aktivációja;

### Haykin: Neural Networks

A comprehensive foundation, IEEE press, 1994

### Cél:

- **Struktúrák** felfedezése az adatokban;
- **„Felügyelet” nélküli** működés ⇒ önszervezés.

### Tanulási szabályok:

- lokális szabályok, melyek – sok neuronra alkalmazva – egy globális függvényt határoznak meg.

- Alapja (Turing 1952):

*„Global order can arise from local interactions.”*



Önszervező rendszerek alapelvei (von der Malsburg):

- A szinapszisok önmegerősítők

A pre-, illetve posztzinaptikus neuronok egyidejű aktivációja erősíti a szinapszist (lásd Hebb).

- A szinapszisok versengenek az erőforrásokért

A legerősebb szinapszis **biztos**, hogy túléli. Ez a többi rovására történik (winner-takes-all).

- A szinapszisok változásai koordináltak

Egy szinapszis nem kódol **robosztusan**, ezért egy régió neuronjai – majdnem – azonos bemenet–kimenet kapcsolatot kódolnak.

Hebb-féle tanulás

Hebb tanulás - auto-asszociatív rendszerek

- A rendszer bemenete egy minta - **nincs** kimeneti jel.
- A „kimeneten” vagy:
  - ▶ az eredeti mintát; vagy
  - ▶ egy csoportosítást, „sűrített” ábrázolást szeretnénk visszkapni.
- csoportosításkor a kimeneti neuronok **versengenek**:

$$\hat{y}_j = \sum_i x_i w_{ij}$$


$$y_l = \begin{cases} 1 & l = k \\ 0 & l \neq k \end{cases} \quad \text{ahol } k = \operatorname{argmax}_j \hat{y}_j$$

Önszervező tanulás



Struktúra-felismerés

- A vizuális rendszer önszervező:
  - ▶ fejlődésének elején csak a felismerésre való **képesség** van jelen;
  - ▶ a működés során egyes kép-csoportok – klaszterek – együttesen lesznek ábrázolva;
- A származtatott fogalmak ábrázolása a **hierarchia** egy felsőbb szintjén történik.




Példa:

- neurális rendszer **pixelcsoportokat** keres.
- némely pixelcsoport **gyakori**; ezen csoportok rögzülnek a rendszerben.
- a **felső** szinten a rendszer **címkézést** végez.

Hebb-féle tanulás

$$y_l = \begin{cases} 1 & l = k \\ 0 & l \neq k \end{cases} \quad \text{ahol } k = \operatorname{argmax}_j \hat{y}_j$$

- **Végleges** kimeneti érték az **argmax** művelet után.
- **Versengés** a bemeneti mintákért.



- Feltételezve egy kezdő **W** – véletlen – súlyvektort, a **v** minta bemutatása után
- csak a **w.4** súlyok változnak a kompetitív tanulás során.

$$\Delta w_{ij} = \alpha x_i y_j$$

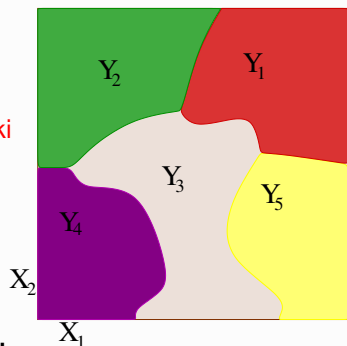
- minden  $y_k$  neuron attraktorként működik.

receptív mezők alakulnak ki

- $\alpha \rightarrow 0$  tanulási mód, pl.

$$\alpha_t = \frac{K}{t}$$

- az **asszociatív háló** konvergál (lásd).



**ami nincs:** kapcsolatok a kimeneti neuronok között:

**Kohonen-hálók**

**Jellemzők:**

- kétrétegű háló, egy bemeneti és egy kimeneti réteggel; (mint előbb)

- kompetitív háló: csak egy neuron lesz aktív; (mint előbb)

- a kimeneti rétegen **topológia** van értelmezve

**(ÚJ)**

**Teuvo Kohonen**

Since the 1960's, ~ introduced several new concepts to neural computing: theories of distributed associative memory and optimal associative mappings, the **self-organizing feature maps (SOMs)**, the learning vector quantization (LVQ), ...

the Adaptive-Subspace SOM (ASSOM) in which invariant-feature filters emerge ...

A new SOM architecture WEBSOM has been developed in his laboratory for exploratory textual data mining.


<http://websom.hut.fi/websom/>



Wikipedia link

**Topológia – szomszédságot jelent**

- segít a tanulásban: a **szomszédok** is tanulnak – kevésbé ...
- értelmezhető eredmény: a **szomszédok** aktivitása is aktivitása alapján pontosabb rekonstrukció
- a kimeneti  $n_{ij}$  neuronok megcímkézhetőek: **Kohonen:** ... fonéma annotáció



## Az algoritmus iteratív:

1 minták egyenként; a  $t$ -edik időpontban legyen  $\mathbf{x}_t$

2 kiszámítjuk a kimeneti neuronok aktivitását:

$$y_j = \sum_i w_{ij} x_i(t) = \mathbf{W} \mathbf{x}(t)$$

3 megkeressük a nyertes kimeneti neuront:

$$k \stackrel{\text{def}}{=} \operatorname{argmax}_j y_j$$

4 Az **összes** szomszédos neuron súlyát módosítjuk:



$$w_{ij}(t+1) = w_{ij}(t) + \alpha \eta(j, k) x_i(t)$$

Normáljuk a súlyokat  $w_{.j} \leftarrow w_{.j} / \|w_{.j}\|$

5 GOTO 1

## Szavakban:

- a **nyertes** neuron „aktivizálódik”;
- A nyertes neuront és szomszédait „közelebb” hozzuk a bemenethez;
- Mindegyik neuron specializálódik a mintákra: arra lesz a legnagyobb a kimenete;



**Eredmény:** a neuronok elhelyezkedését a bemeneti minták **sűrűségfüggvénye** határozza meg – több neuron kerül a sűrűbb régiókba.

- Az adatokhoz **nincs** kimeneti érték rendelve;
- A rendszer általában az adatok egy **csoportosítását** valósítja meg;
- Ez implicit módon a bemeneti adatok terének a **felosztását** jelenti;
- **Zajsűrés/Sűrítés:** a teljes bemeneti adatok helyett a hozzá tartozó osztály kódját küldjük.

## Példa

–

## Térképészgép

Walter Bischof, Jun Zhou (U. Alberta) és Terry Caelli (Australian N.U.) a kartográfiát (részben) automatizáló programmal álltak elő.

A **program embertől tanulja**, miként fedezzen fel és azonosítson légi felvételeken korábban **nem szereplő vagy megváltozott** elemeket: utakat, vasutakat, épületeket.



Ágens portál

Walter Bischof projektek

### Működése:

Egyre többet tud meg – „okosabb” lesz. Kellő mennyiségű gyakorlás után az operátor rábízta a munkát. **Bayes-féle következtetést használ:** korábbi mérések alapján végez új becsléseket. A legjobbakból állapítja meg az adott országút soron következő pontjait, és ezt mindaddig folytatja, amíg az új elemek pozíciója **megfelel az elvárásoknak**.

## Gépi tanulás

Történelmi háttér / Motiváció:


- nagyon nagy mennyiségű **adat**, melyet szeretnénk **automatikusan** feldolgozni;
- A matematikai modellek **általánosak** – **nem egy adott feladatra vannak kiélezve**,
- Szükség van esetenkénti tanulmányozására egy-egy feladattípusnak ⇒ „tudomány-ág”, mely a modelleket a feladatokhoz **„idomítja”**.

## Példa

## Ágensek filmvászonon


A **Massive céggel** a Gyűrűk Ura trilógiában találkozhattunk 2001-ben.

Az összes **csatajelenet az ő programjukkal készült**. Nem véletlen, hogy a tavalyi (2005) King Kong-ban **statiszták helyett** a Massive ágenseit használták.



Ágens portál

Walter Bischof projektek



**Hangya-kolónia szimuláció** egy kedvelt M.I. téma. A „buta” hangya-ágensek **feromon nyomokat** hagynak maguk után; ezek alapján mozognak. Nincs globális információ a környezetről: csak a feromon-nyomot követik. A kolónia **intelligens** viselkedést mutat: megtalálja a legrövidebb utat a fészek és az élelemforrás között.

Gulyás László, ELTE

## Gépi tanulás

## Meghatározás

### Gépi tanulás

Módszerek – statisztikai, valószínűségi – gyűjteménye **valós feladatok** megoldására.

### Például:

- Zajszűrés: (nem–)lineáris regresszió és (nem–)normális zajt feltételezve;
- Osztályozás: bináris, több-osztályos, illetve
- Részlegesen címkézett adatokra;
- Klaszterezés – adatok csoportosítása,
- Függvényinverzió,
- Sűrűségbecslés,
- „Kakukktojások” felfedezése – *novelty detection*.

**Szükséges az adatok modellezése.**

... is concerned with the question of how to construct programs that *automatically* improve with *experience*.

In recent years (1997) successful ML algorithms have been developed in

- data-mining – fraud detection,
- filtering for user's preferences,
- vehicles that learn to drive on highways;
- advances in the **theory and algorithms** that form the foundations of this field.



Thomas Mitchell

### Tanuló rendszer

olyan számítógépes program, melyek képességei a **működés során** javulnak.


## Rejtett változós modellek



### Szükséges:

- **Adatok halmaza** – megfigyelés során gyűjtjük.
- **Függvény osztály feltételezése.** Lehet:
  - ▶  $K$ -ad fokú polinomok,
  - ▶ Fourier polinomok,
  - ▶ Wavelet-ek;
- A megfigyelési folyamat ismerete – **a zaj** kódolása;
- Algoritmus a **legmegfelelőbb** függvény kiválasztására.

## Adatmodellezés



### Feltételezzük, hogy:

- „Valahol”: **létezik** a  $t = f(x)$  függvény, mely generál adatokat;
- A **megfigyelt értékek** zajosak: **nem**  $y = f(x)$ -et kapunk, hanem például:

$$y_n = t_n + \epsilon \quad \text{additív zaj}$$

$$y_n = h(t_n, \epsilon) \quad h \text{ módosító függvény}$$

- **Feladat: találjuk meg az  $y = f(x)$  függvényt.**

## Rejtett változós modellek

II

### Adottak:

- **Adathalmaz**  $\mathcal{D} = \{(x_1, y_1), \dots, (x_N, y_N)\}$ .
- **Függvényosztály** (feltételezzük, hogy a megoldás megfelelő):

$$(1) \quad \mathcal{F} = \{\mathbf{w}^T \mathbf{x} + b \mid \mathbf{w} \in \mathbb{R}^d, b \in \mathbb{R}\}$$

$$(2) \quad \mathcal{F} = \left\{ a_0 + \sum_{k=1}^K a_k \sin(2\pi kx) + \sum_{k=1}^K b_k \cos(2\pi kx) \right. \\ \left. \mid \mathbf{a}, \mathbf{b} \in \mathbb{R}^K, a_0 \in \mathbb{R} \right\}$$

- A megfigyelési folyamat egy modellje:

$$y_n = f(\mathbf{x}_n) + \epsilon \quad \text{with } \epsilon \sim N(0, \sigma^2).$$

Általánosan:

1 Adatok:  $\mathcal{D} = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\}$ .

2 Függvényosztály:

$$\mathcal{F} = \{f(\mathbf{x}, \boldsymbol{\theta}) | \boldsymbol{\theta} \in \mathbb{R}^p\}$$

3 Megfigyelés – definiáljuk a hibafüggvényt:

$$L(y_n, f(\mathbf{x}_n, \boldsymbol{\theta}))$$

Gauss-zaj esetén:

$$L(y_n, f(\mathbf{x}_n, \boldsymbol{\theta})) = (y_n - f(\mathbf{x}_n, \boldsymbol{\theta}))^2.$$

Paraméterbecslés

M.L.

$L(\mathcal{D}, \boldsymbol{\theta})$  – (log)likelihood függvény.

M.L. = maximum likelihood értékű  $\boldsymbol{\theta}$ :

$$\boldsymbol{\theta}^* = \arg \min_{\boldsymbol{\theta} \in \Omega} L(\mathcal{D}, \boldsymbol{\theta})$$

Példa – legkisebb négyzetes hibával történő becslés:

$$L(\mathcal{D}, \boldsymbol{\theta}) = \sum_{n=1}^N (y_n - f(\mathbf{x}_n, \boldsymbol{\theta}))^2$$

$$\boldsymbol{\theta}^* = \arg \min_{\boldsymbol{\theta} \in \Omega} \sum_{n=1}^N (y_n - f(\mathbf{x}_n, \boldsymbol{\theta}))^2$$

Hátrány: Túl pontos illeszkedés – **over-fitting**.

Paraméterbecslés

Találjuk meg a  $\boldsymbol{\theta}$  paraméter-vektor optimális értékét.

Optimalitás:

$$\boldsymbol{\theta}^* = \arg \min_{\boldsymbol{\theta} \in \Omega} L(\mathcal{D}, \boldsymbol{\theta})$$

ahol

- $\Omega$  a paraméterek értelmezési tartománya.
- $L(\mathcal{D}, \boldsymbol{\theta})$  az adatokhoz rendelt hibafüggvény.

Példa a hibafüggvényre


Független megfigyelések esetén:

$$L(\mathcal{D}, \boldsymbol{\theta}) = \sum_{n=1}^N L(y_n, f(\mathbf{x}_n, \boldsymbol{\theta}))$$

miért független?

M.L. becslés

Over-fitting



MAP becsléshez szükségünk van **valószínűségekre**:

- A  $\mathcal{D}$  adathalmaz valószínűsége (log-lik).  
 $\theta$  paraméterhez – az adatok által – rendelt fgv:

$$P(y_n | \mathbf{x}_n, \theta, \mathcal{F}) \propto \exp[-L(y_n, f(\mathbf{x}_n, \theta))]$$

$\propto$  – normálni is kell.

- A-priori – előzetes – valószínűség  
Milyen  $\theta$  értékek a legvalószínűbbek

$$p_0(\theta) \propto \exp\left[-\frac{\|\theta\|^2}{2}\right]$$

az adatok ismerete előtt **specifikáljuk**.

**M.A.P. becslés** – a legvalószínűbb  $\theta$  megtalálása:

$$\theta_{MAP}^* = \arg \max_{\theta \in \Omega} p(\theta | \mathcal{D}, \mathcal{F})$$

**Példa:**

Az általános  $L(y_n, f(\mathbf{x}_n, \theta))$  hibafüggvényt és Gauss-féle a-priori valószínűsége.

A  $\theta_{MAP}^*$  kiszámítása (exp-ben levő tagok):

$$\theta_{MAP}^* = \arg \max_{\theta \in \Omega} K - \sum_n L(y_n, f(\mathbf{x}_n, \theta)) - \frac{\|\theta\|^2}{2\sigma_0^2}$$

Ha  $\sigma_0^2 \rightarrow \infty$  a **maximum likelihood** módszer.

egy előjelcsere és  $\max \rightarrow \min$  helyettesítés után.

A becslés a fenti valószínűségek – lik. & prior – kombinálása.

Bayes-szabály alkalmazása a  $\theta$  és  $\mathcal{D}$  változókra:

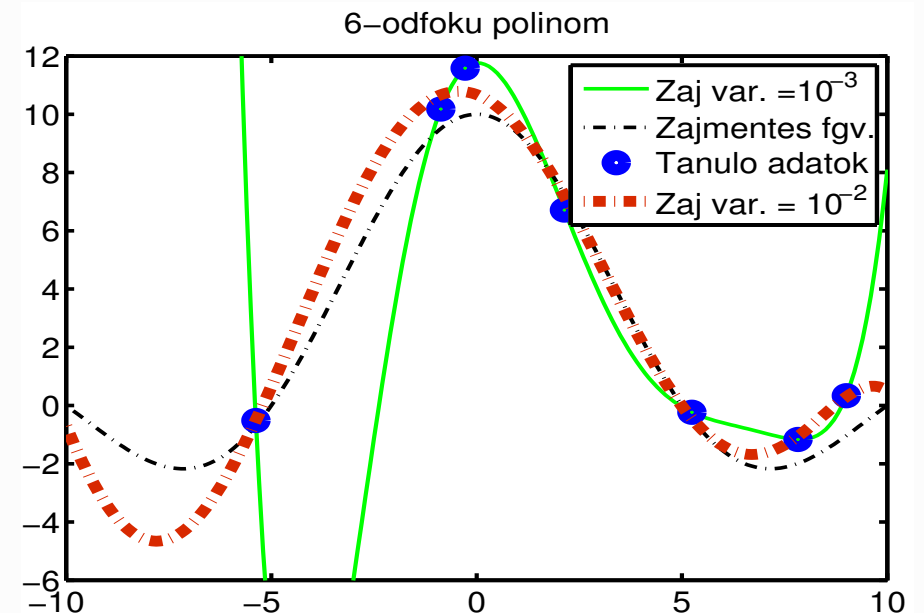
$$p(\theta | \mathcal{D}, \mathcal{F}) = \frac{P(\mathcal{D} | \theta) p_0(\theta)}{p(\mathcal{D} | \mathcal{F})}$$

$$p(\mathcal{D} | \mathcal{F}) = \int_{\Omega} d\theta P(\mathcal{D} | \theta) p_0(\theta)$$

ahol  $p(\mathcal{D} | \mathcal{F})$  – az adatok **teljes valószínűsége** az adott  $\mathcal{F}$  modellre.

$P(\theta | \mathcal{D}, \mathcal{F})$  minden  $\theta$  értékhez egy valószínűség

$\Rightarrow$  egyszerűsítés szükséges.



Bayes – feltételes valószínűség – szabálya:

$$p(\boldsymbol{\theta}|\mathcal{D}, \mathcal{F}) = \frac{P(\mathcal{D}|\boldsymbol{\theta})p_0(\boldsymbol{\theta})}{p(\mathcal{D}|\mathcal{F})}$$

$$p(\mathcal{D}|\mathcal{F}) = \int_{\Omega} d\boldsymbol{\theta} P(\mathcal{D}|\boldsymbol{\theta})p_0(\boldsymbol{\theta})$$

és megpróbáljuk a **teljes eloszlást tárolni**.

Miért?

Mivel nincs mindig képlet a **poszt. eloszlásra**, a

$$p_{\text{post}}(\boldsymbol{\theta}|\mathcal{D}, \mathcal{F})$$

sűrűségfüggvényt **közelítjük**.

## Bayes–becslés

## II

### Bayes–becslés folyamán

Foglalkozunk

- a poszterior-eloszlás **közelítésével**:

$$\hat{p}(\boldsymbol{\theta}) \approx p_{\text{post}}(\boldsymbol{\theta}|\mathcal{D}, \mathcal{F})$$

- egy **új** adat valószínűségével – **predikció**:

$$\hat{p}(y^*|\mathbf{x}^*) \approx \int_{\Omega} d\boldsymbol{\theta} \hat{p}(\boldsymbol{\theta})P(y^*|\mathbf{x}^*, \boldsymbol{\theta})$$

- Teljes valószínűségnek a közelítésével:

$$p(\mathcal{F}|\mathcal{D}) = p(\mathcal{D}|\mathcal{F})p_0(\mathcal{F})$$

A  $p(\mathcal{F}|\mathcal{D})$  használható – elvileg – két különböző modell **összehasonlítására**.

**Apróbetű:** A statisztikák szerepe:

Az adatok helyettesítése

- Feltételezzük, hogy **létezik** egy generátor, mely az adatokat létrehozta;
- Ismerjük a generátor **alakját**:  $(\mathbf{x}_i, y_i) = \Gamma(\mathbf{z}_i|\theta_1, \dots, \theta_k)$ .
- $\mathbf{z}_i$  – paraméterek, változók.
- $\boldsymbol{\theta} = [\theta_1, \dots, \theta_k]^T$  – a **modell** paraméterei.

**Az elemzéshez**

- a **teljes** adathalmazt helyettesítjük a
- megfelelő **paraméterekkel**.
- A **predikcióhoz** nem használjuk az adatokat,
- „csak” a kinyert paramétereket és a **modellt**.

## Bayes–becslés

## közelítés

$$\hat{p}(\boldsymbol{\theta}) \approx p_{\text{post}}(\boldsymbol{\theta}|\mathcal{D}, \mathcal{F})$$

A közelítés alapja egy **divergencia**: méri, hogy a közelítő eloszlás minőségét:

$$\hat{p}(\boldsymbol{\theta}) = \underset{p(\boldsymbol{\theta}) \in \Omega}{\text{argmin}} d(p_{\text{post}}(\boldsymbol{\theta}|\mathcal{D}, \mathcal{F}), p(\boldsymbol{\theta}))$$

A Bayes-becslések során fontos:

- **milyen családban** keressük az optimális eloszlást,
- **milyen divergenciát használunk** a „távolságok” mérésére. Gyakori a Kullback-Leibler divergencia.



Gyakori a Kullback-Leibler divergencia:

$$d_{KL}(p_1(\theta)|p_2(\theta)) = \int_{\Omega_\theta} d\theta p_1(\theta) \log \frac{p_1(\theta)}{p_2(\theta)}$$

Tulajdonságok:

- $d_{KL}(p_1|p_2) \geq 0$

$$0 = \log \left( \int d\theta p_2(\theta) \right) = \log \left( \int d\theta p_1(\theta) \frac{p_2(\theta)}{p_1(\theta)} \right)$$

alkalmazzuk a **Jensen** egyenlőtlenséget:

$$0 > \int d\theta p_1(\theta) \log \frac{p_2(\theta)}{p_1(\theta)}$$

$$0 > -d_{KL}(p_1|p_2)$$

- $d_{KL}(p_1|p_2) = 0 \iff p_1(\theta) = p_2(\theta)$

kivéve egy **nulla-mértékű** halmazt...

- $d_{KL}(p_1|p_2) \neq d_{KL}(p_2|p_1)$

- Nem** teljesül a háromszög-egyenlőtlenség.

$$d_{KL}(p_1|p_2) \not\leq d_{KL}(p_1|p_3) + d_{KL}(p_3|p_2)$$

▶ következő

Példa közelítésre:

$$\Omega = \left\{ \exp \left[ -\frac{1}{2}(\theta - \mu_\theta)^T \Sigma_\theta^{-1} (\theta - \mu_\theta) \right] \mid \mu_\theta \in \mathcal{R}^d, \Sigma \in \mathcal{R}^d \right\}$$

ahol  $\Sigma$  egy pozitív-definit mátrix.

Paraméter-optimalizálás lépései:

- A  $p_{\text{post}}(\theta|\mathcal{D}, \mathcal{F})$  **a-posteriori** eloszlás és az  $\Omega$  eloszláscsalád meghatározása;

- $d_{KL}(p_{\text{post}}(\theta)|p(\theta|\mu, \Sigma))$  kiszámítása –  $(\mu, \Sigma)$  vált.;


- $(\hat{\mu}, \hat{\Sigma})$  meghatározása:

$$(\hat{\mu}, \hat{\Sigma}) \Rightarrow \operatorname{argmin}_{p \in \Omega} d_{KL}(p_{\text{post}}(\theta)|p(\theta|\mu, \Sigma))$$

Jensen egyenlőtlenség

Legyen  $f(x)$  egy konvex függvény az  $[a, b]$  intervallumon. Ekkor  $\forall \lambda \in [0, 1]$

$$f(\lambda a + (1 - \lambda)b) \leq \lambda f(a) + (1 - \lambda)f(b)$$



A **logaritmus**: függvény **konkáv**, tehát:

$$\log(\lambda a + (1 - \lambda)b) \geq \lambda \log(a) + (1 - \lambda) \log(b) \quad \text{ahol } a, b > 0.$$

Sok együttthatóra:

$$\log \left( \sum_i \pi_i a_i \right) \geq \sum_i \pi_i \log(a_i) \quad \text{ahol } \sum_i \pi_i = 1 \text{ és } \pi_i \geq 0.$$

$$\log \left( \int d\theta p(\theta) f(\theta) \right) \geq \int d\theta p(\theta) \log(f(\theta)) \quad \text{ahol } f(\theta) > 0.$$

▶ vissza

Feltételezzük, hogy

- meghatároztuk a **legjobb közelítő**  $\hat{p}(\theta)$  eloszlást.
- ismerjük a bemenet–kimenet összefüggéseket: a  $P(y|x, \theta)$  felt. valószínűségeket.

**Predikció:**

Adott bemenetre mi lesz a **kimeneti** értékek eloszlása?

Ha  $P(y|x, \theta)$  eloszlás az  $y$  szerint, akkor a **prediktív disztribúció**:

$$p(y^*|x^*, \mathcal{D}) = \int_{\Omega_\theta} d\theta \hat{p}(\theta|\mathcal{D}) P(y^*|x^*, \theta)$$

**Prediktív disztribúció:**

$$p(y^*|\mathbf{x}^*, \mathcal{D}) = \int_{\Omega_{\theta}} d\theta \hat{p}(\theta|\mathcal{D}) P(y^*|\mathbf{x}^*, \theta)$$

**A Gyakorlatban:**

- fontos a modell választása: ha  $\mathcal{M}$  a modell-család, akkor minden valószínűség függ az  $\mathcal{M}$ -től:

$$\hat{p}(\theta|\mathcal{D}) \stackrel{\text{def}}{=} \hat{p}(\theta|\mathcal{D}, \mathcal{M})$$

- A  $p_{\text{post}}(\theta)$ -hoz hasonlóan a prediktív eloszlás **sem** írható fel analitikusan: **közelítések szükségesek**.
- A prediktív eloszlást általában a  $\hat{p}(\theta)$ -hoz hasonló módszerekkel keressük.

$$\begin{aligned} \langle f(\mathbf{x}_1)f(\mathbf{x}_2) \rangle_{\alpha_0, \dots, \alpha_6} &= \left\langle \left( \sum_{k=0}^6 \theta_k \alpha_k \mathbf{x}_1^k \right) \left( \sum_{k=0}^6 \theta_k \alpha_k \mathbf{x}_2^k \right) \right\rangle \dots \\ &= \sum_{k=0}^6 1 \alpha_k^2 \mathbf{x}_1^k \mathbf{x}_2^k = \sum_{k=0}^6 \binom{6}{k} (\mathbf{x}_1 \mathbf{x}_2)^k \\ &= (1 + \mathbf{x}_1 \mathbf{x}_2)^6 \end{aligned}$$

$\mathcal{F}$  tehát egy függvényosztály, melynek átlaga 0 és szórása fent látható.

**Feladat:**

Közelítsünk a Bayes–modell segítségével.

**Függvénycsalád:** legyen az

$$\mathcal{F} = \left\{ f(\mathbf{x}) \stackrel{\text{def}}{=} \sum_{k=0}^6 \theta_k \alpha_k \mathbf{x}^k \mid \theta_k \sim N(0, 1), \alpha_k = \sqrt{\binom{6}{k}} \right\}$$

ahol  $\theta = [\theta_1, \dots, \theta_6]^T$  a függvény paraméterei.

Ekkor **átlagban:**

$$\begin{aligned} \langle f(\mathbf{x}) \rangle_{\theta_0, \dots, \theta_6} &= \left\langle \sum_{k=0}^6 \theta_k \alpha_k \mathbf{x}^k \right\rangle_{\theta_0, \dots, \theta_6} = \\ &= \sum_{k=0}^6 0 \alpha_k \mathbf{x}^k = 0 \end{aligned}$$

illetve ...

**Szükséges a zaj ismerete;** Feltételezzük, hogy az Gauss eloszlású, tehát:

$$P(y|f(\mathbf{x}, \theta), \sigma_o) = \frac{1}{\sqrt{2\pi}} \exp \left[ -\frac{(y - f(\mathbf{x}))^2}{2\sigma_o^2} \right]$$

ahol  $\sigma_n$  a zaj (noise) szórása.

Az adatok:  $\mathcal{D} = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\}$

**Feltételes valószínűségük:**

$$P(\mathcal{D}|\theta, \sigma_o) = \prod_{n=1}^N P(y_n|f(\mathbf{x}_n, \theta), \sigma_n)$$

A-posteriori eloszlás:

$$p_{\text{post}}(\boldsymbol{\theta}|\mathcal{D}, \sigma_o) = \frac{P(\mathcal{D}|\boldsymbol{\theta}, \sigma_o) p_0(\boldsymbol{\theta})}{\int d\boldsymbol{\theta} P(\mathcal{D}|\boldsymbol{\theta}, \sigma_o)p_0(\boldsymbol{\theta})}$$

ahol  $p_0(\boldsymbol{\theta})$  a változók **feltételezett – a-priori –** eloszlása.

**Megjegyzések:**

- Normál **a-priori** eloszlás esetén:

$$\log p_0(\boldsymbol{\theta}) \propto -\frac{\|\boldsymbol{\theta}\|^2}{2\sigma_p^2}$$

azaz **regularizációs** megkötés a paramétereken.

- A modell a **paraméterekben** lineáris  $\Rightarrow$  gaussz-eloszlás lesz az eredmény is.
- a jobb oldalon eloszlás van, a nevező normalizáló  $\Rightarrow$  annak értékét nem kell kiszámítani.

$$\boldsymbol{\theta}^T \left( \frac{\mathbf{X}^T \mathbf{X}}{\sigma_n^2} + \frac{\mathbf{I}_7}{\sigma_p^2} \right) \boldsymbol{\theta} - \mathbf{y}^T \mathbf{X} \boldsymbol{\theta} + K_1$$

$$\boldsymbol{\theta}^T \mathbf{A} \boldsymbol{\theta} - \mathbf{b}^T \mathbf{A} \boldsymbol{\theta} + K_1$$

ahol  $\mathbf{A} \stackrel{\text{def}}{=} \frac{\mathbf{X}^T \mathbf{X}}{\sigma_n^2} + \frac{\mathbf{I}_7}{\sigma_p^2}$ ;  $\mathbf{b} \stackrel{\text{def}}{=} \mathbf{A}^{-1} \mathbf{X}^T \mathbf{y}$

A  $\log p_{\text{post}}(\boldsymbol{\theta}|\mathcal{D}, \sigma_o)$  tehát tartalmaz egy **teljes négyzetet** és egy **konstanst**.

Mivel a teljes négyzet Gaussz-eloszlást jelent, a konstans értékét ismerjük. Az eredmény:

$$\log p_{\text{post}}(\boldsymbol{\theta}|\mathcal{D}, \sigma_o) = \mathcal{N}(\boldsymbol{\theta}|\mathbf{b}, \mathbf{A}^{-1})$$

$$-2 \log p_{\text{post}}(\boldsymbol{\theta}|\mathcal{D}, \sigma_o) = \log p(\mathcal{D}|\mathcal{M}) + \sum_{n=1}^N \frac{(y_n - f(\mathbf{x}_n|\boldsymbol{\theta}))^2}{\sigma_n^2} + \frac{\|\boldsymbol{\theta}\|^2}{\sigma_p^2}$$

ahol  $\log p(\mathcal{D}|\mathcal{M})$  a normalizáló konstans.

Jelölések:

$$\hat{\mathbf{x}} \stackrel{\text{def}}{=} [\mathbf{x}^0, \mathbf{x}^1, \dots, \mathbf{x}^6]^T.$$


$$f(\mathbf{x}_n|\boldsymbol{\theta}) \stackrel{\text{def}}{=} \boldsymbol{\theta}^T \mathbf{x}_n \quad \|\boldsymbol{\theta}\|^2 = \boldsymbol{\theta}^T \boldsymbol{\theta}$$

$$\mathbf{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix} \quad \mathbf{X} = \begin{bmatrix} x_1^0 & \dots & x_1^6 \\ \vdots & \ddots & \vdots \\ x_N^0 & \dots & x_N^6 \end{bmatrix}$$

A fenti jelölésekkel az összeg **szorzattá** alakul. Csoportosítva:

$$\boldsymbol{\theta}^T \left( \frac{\mathbf{X}^T \mathbf{X}}{\sigma_n^2} + \frac{\mathbf{I}_7}{\sigma_p^2} \right) \boldsymbol{\theta} - \mathbf{y}^T \mathbf{X} \boldsymbol{\theta} + K_1$$


Pol. 6 – N.var  $\sigma^2 = 1$



- Max–Lik. becslésnél: nincs a–priori eloszlás, a becslés esetenként rossz.
- M.A.P. becslésnél: eloszlásokról beszélünk, azonban a becslés eredménye nem valószínűségi, hanem egy érték.
- Bayes–becslésnél: a becslés eredménye egy valószínűségi eloszlás.

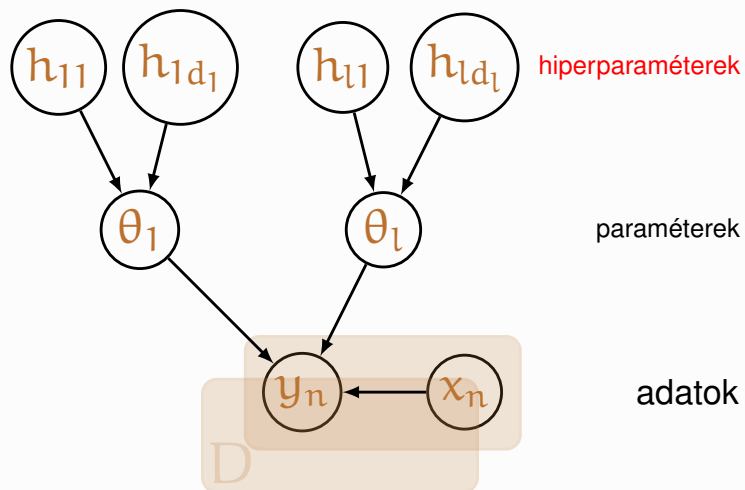
A paraméterek **függőségi gráfja** a regressziós példánál.

Lényeges, hogy a **nem** a  $\theta$  paramétert **becsüljük**; hanem a  $p(\theta)$  eloszlás paramétereit,  
 $\Rightarrow$  jelen esetben ezek  $\mu$  és  $\sigma$ .



**Grafikus modelleket** akkor használunk, ha egy modell egyes paramétereit megfigyeljük – pl.  $(x_n, y_n)$  – másokra meg következtetni kell.

A következtetés alapja a **megfigyelések** és a **modell**.



- M.I – racionális vs. imitáló illetve cselekvő/gondolkodó.
- Tudásreprezentáció – állapotter, feladat definíció.
- Megoldás-keresések az állapotterben: hegymászó, backtracking.
- Gráfkeresés – kapcsolata a M.I. rendszerekkel.
- Dekompozíciós módszer.
- Predikátumkalkulus, rezolúció.
- Gráfok, utak, irányított gráfok, /Sigma/delta/ tulajdonságok.

- ÉS/VAGY gráfok, hiperutak és-vagy gráfokban.
- ÉS/VAGY gráfok átalakítása irányított gráffá.
- Játékok gráfjai, puzzle, 4 királynő.
- Gráfkereső alapalgoritmus.
- Gráfkereső algoritmus tulajdonságai.
- Keresési algoritmusok: mélységi, szélességi, egyenletes, előretekinthető.
- A\* algoritmus család, tulajdonságok.
- Szemantikus hálók, tulajdonságok, operációk.
- Keretrendszerek, démonok.

- Játékok: keresés, kétszemélyes játékok, stratégia.
- NIM játék: leírás, nyerő stratégia (b).
- Nyerő stratégia teljes információs játékoknál (b).
- Minimax algoritmus, minimax tétel (b).
- Minimax, negamax algoritmusok.
- Alfa-béta vágás.
- Bizonyt.ság: Bayes-modell.
- Bayes-hálók, grafikus modellek.
- Dempster-Shafer modell, Bel, Pl és m függvények.
- Fuzzy logika, ~ rendszerek.
- Tanulás: induktív és/vagy deduktív rendszerek.
- Tanuló rendszerek típusai.
- Exploration vs. exploitation – visszacsatolásos tanulás.
- Genetikus algoritmusok, hamiltoni rendszerek,
- Neurális hálózatok, topológiák.
- Neurális hálózatok tanítási szabályai, optimalizálás.