


Mesterséges Intelligencia MI

Valószínűségi
temporális
következtetés

Dobrowiecki Tadeusz
Eredics Péter, és mások



BME I.E. 437, 463-28-99

dobrowiecki@mit.bme.hu,

<http://www.mit.bme.hu/general/staff/tade>

\mathbf{X}_t - a t időpillanatban nem megfigyelhető változók halmaza

\mathbf{E}_t - a megfigyelhető (megfigyelt) változók halmaza

$\mathbf{X}_{a:b} = \mathbf{X}_a \mathbf{X}_{a+1}, \dots, \mathbf{X}_{b-1} \mathbf{X}_b$ - változók halmaza \mathbf{X}_a -tól \mathbf{X}_b -ig

(Pl. $\mathbf{U}_{1:3} = U_1, U_2, U_3$ változók)

Egy titkos, földalatti létesítmény biztonsági őre tudni szeretne, hogy aznap esik-e, de egyetlen információja, hogy reggelenként látja az igazgatóját, aki esernyővel vagy esernyő nélkül jön be.

Minden t napon az \mathbf{E}_t halmaz így egyetlen bizonyíték változó,

U_t (van-e esernyője),

és \mathbf{X}_t halmaz az egyetlen állapotváltozó R_t (esik-e kint).

Probléma: szerkeszthető-e ilyen problémára egy valószínűségi háló?
Ha igen, milyen szülőkből lehet itt gazdálkodni?

Markov feltételek

Markov feltétel: X_t függ az $X_{0:t-1}$ korlátos részhalmazától



Elsőrendű (a) Markov folyamat: $P(X_t | X_{0:t-1}) = P(X_t | X_{t-1})$

Másodrendű (b) Markov folyamat: $P(X_t | X_{0:t-1}) = P(X_t | X_{t-2}, X_{t-1})$
stb.

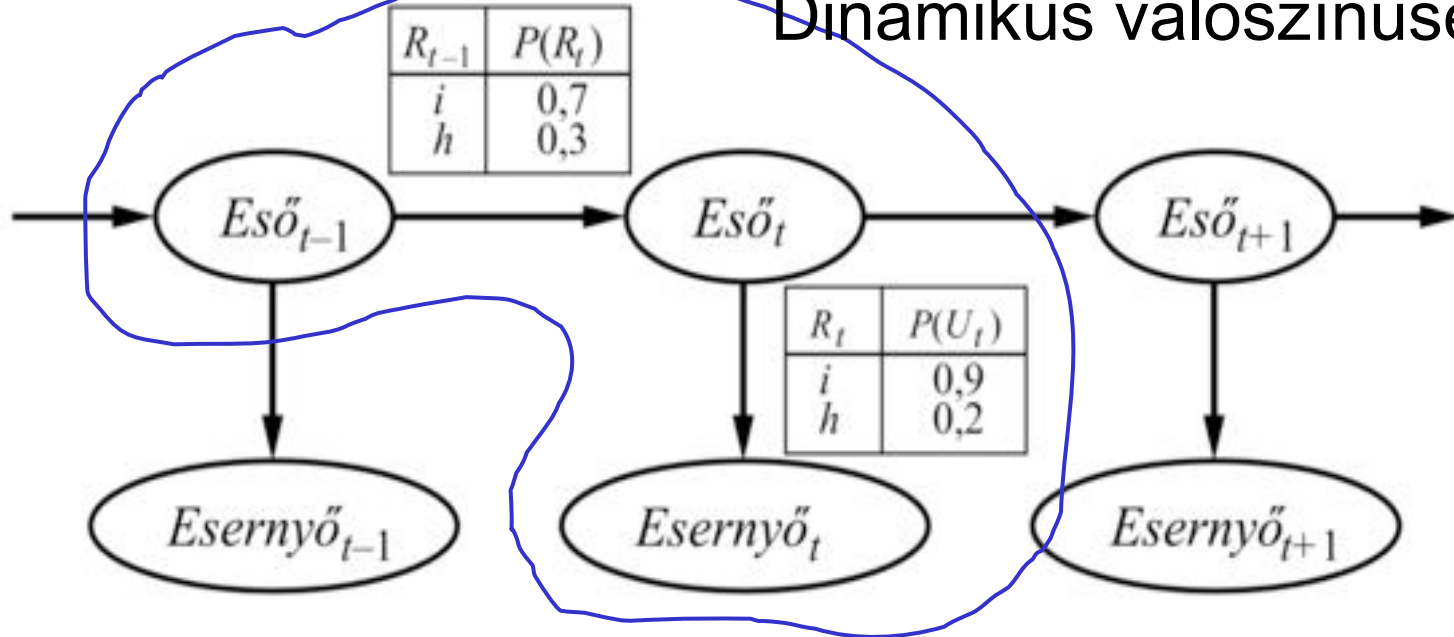
Érzékelő Markov feltétel: $P(E_t | X_{0:t}, E_{0:t-1}) = P(E_t | X_t)$

Stacionárius folyamat: állapotátmenet modell $P(X_t | X_{t-1})$

és érzékelő/megfigyelés modell $P(E_t | X_t)$ nem függ a t-től



Dinamikus valószínűségi hálók



Ha a közelítés túlságosan pontatlan - lehet javítani, pl.:

a Markov folyamat **rendjének növelésével**

pl. egy másodrendű modellt felvéve egy $Eső_{t-2}$ -öt mint az $Eső_t$ szülője (valamivel pontosabb predikció).

az **állapotváltozók halmazának növelésével**

pl. felvenni az $Évszak_t$ változót, vagy hozzáadni a $Hőmérséklet_t$, a $Páratartalom_t$ és a $Légnyomás_t$ változókat...

Következtetés időbeli modellekben

Szűrés v. ellenőrző megfigyelés: a **bizonyossági, hiedelmi állapot** kiszámítása = a jelenlegi állapot a posteriori eloszlása, az eddigi összes bizonyíték ismeretében

$$P(X_t | e_{1:t})$$

Előrejelzés, jóslás: egy jövőbeli állapot a posteriori eloszlása, az eddigi összes bizonyíték ismeretében.

$$P(X_{t+k} | e_{1:t}) , k > 0$$

Simítás, visszatekintés: egy múltbeli állapot a posteriori eloszlása, a jelen időpontig vett összes bizonyíték ismeretében.

$$P(X_k | e_{1:t}) , 0 \leq k < t$$

Legvalószínűbb magyarázat:

A megfigyelések ismeretében megtalálni azt az állapotsorozatot, ami a leginkább valószínű, hogy az adott megfigyeléseket generálta.

$$\arg \max_{x_{1:t}} P(x_{1:t} | e_{1:t})$$

és a munkalovak

$$P(A) = \sum_{\xi} P(A\xi) \quad P(A|Bc) = \alpha P(B|Ac) P(A|c)$$

Szűrés

$$P(X_{t+1} | e_{1:t+1}) = f(e_{t+1}, P(X_t | e_{1:t}))$$

$$P(X_{t+1} | e_{1:t+1}) = P(X_{t+1} | e_{1:t}, e_{t+1}) \quad (\text{felosztva a bizonyítékot})$$

$$= \alpha P(e_{t+1} | X_{t+1}, e_{1:t}) P(X_{t+1} | e_{1:t}) \quad (\text{a Bayes szabállyal})$$

$$= \alpha P(e_{t+1} | X_{t+1}) P(X_{t+1} | e_{1:t}) \quad (\text{a bizonyíték Markov tulajdonsága miatt})$$

rekurzív becslés


$$\begin{aligned} P(X_{t+1} | e_{1:t+1}) &= \alpha P(e_{t+1} | X_{t+1}) \sum_{x_t} P(X_{t+1} | x_t, e_{1:t}) P(x_t | e_{1:t}) \\ &= \alpha P(e_{t+1} | X_{t+1}) \sum_{x_t} P(X_{t+1} | x_t) P(x_t | e_{1:t}) \quad (\text{kihasználva a Markov tul-t}). \end{aligned}$$

Lineáris rekurzív becslés

$$\mu_{N+1} = f(e_{N+1}, \mu_N) \quad \mu_N = \frac{1}{N} (e_1 + e_2 + \dots + e_N) \quad e_t = a + N(0, \sigma)$$

$$\mu_{N+1} = \mu_N + \frac{1}{N+1} (e_{N+1} - \mu_N) = \frac{N}{N+1} \mu_N + \frac{1}{N+1} e_{N+1}$$

Szűrés



1. nap: az esernyő feltűnik, **$U1 = igaz$** .

Előrejelzés $t = 0$ -ról $t = 1$ -re: $\mathbf{P}(R1) = \sum_{r_0} \mathbf{P}(R1|r_0) \mathbf{P}(r_0) = \langle .7;.3 \rangle \langle .5;.5 \rangle = \langle .5;.5 \rangle$

a $t = 1$ -beli bizonyítékkal való frissítés azt adja, hogy

$$\mathbf{P}(R1|U1) = \alpha \mathbf{P}(U1|R1) \mathbf{P}(R1) = \alpha \langle .9;.2 \rangle \langle .5;.5 \rangle = \alpha \langle .45;.1 \rangle \approx \langle .818;.182 \rangle.$$

2. nap: az esernyő feltűnik, **$U2 = igaz$** .

Előrejelzés $t = 1$ -ről $t = 2$ -re:

$$\mathbf{P}(R2|U1) = \sum_{r_1} \mathbf{P}(R2|r_1) \mathbf{P}(r_1|U1) = \langle .7;.3 \rangle \langle .818;.182 \rangle \approx \langle .627;.373 \rangle$$

a $t = 2$ -beli bizonyítékkal való frissítés pedig azt adja, hogy

$$\begin{aligned} \mathbf{P}(R2|U1,U2) &= \alpha \mathbf{P}(U2|R2) \mathbf{P}(R2|U1) \\ &= \alpha \langle .9;.2 \rangle \langle .627;.373 \rangle = \alpha \langle .565;.075 \rangle \approx \langle .883;.117 \rangle. \end{aligned}$$

Előrejelzés

$$P(X_{t+1} | e_{1:t}) \rightarrow \sum_{x_t} P(X_{t+1} | x_t) P(x_t | e_{1:t})$$

Mi történik, ahogy egyre távolabbra próbálunk előre jelezni a jövőben?

Megmutatható, hogy az *Eső* előre jelzett eloszlása a $\langle .5; .5 \rangle$ **fix ponthoz** konvergál, ami után állandó marad a továbbiakban.

Ez az átmenet modell által meghatározott Markov folyamat un. **stacionárius eloszlása**.


Keverési idő (mixing time) – kb. a fix pont eléréséig eltelt idő.

Gyakorlatban kudarc minden olyan kísérlet, ami a keverési idő kis hányadánál nagyobb számú lépés múlva kísérli meg az aktuális állapotot előrejelezni.


**Minél bizonytalanabb az átmeneti modell,
annál rövidebb a keverési idő és a jövő annál homályosabb.**

$$\begin{aligned} P(X_{t+2} | e_{1:t}) &\rightarrow \sum_{x_{t+1}} P(X_{t+2} | x_{t+1}) P(x_{t+1} | e_{1:t}) \\ &= \sum_{x_{t+1}} P(X_{t+2} | x_{t+1}) \sum_{x_t} P(x_{t+1} | x_t) P(x_t | e_{1:t}) \end{aligned}$$

Pozíció előrejelzése



Simítás

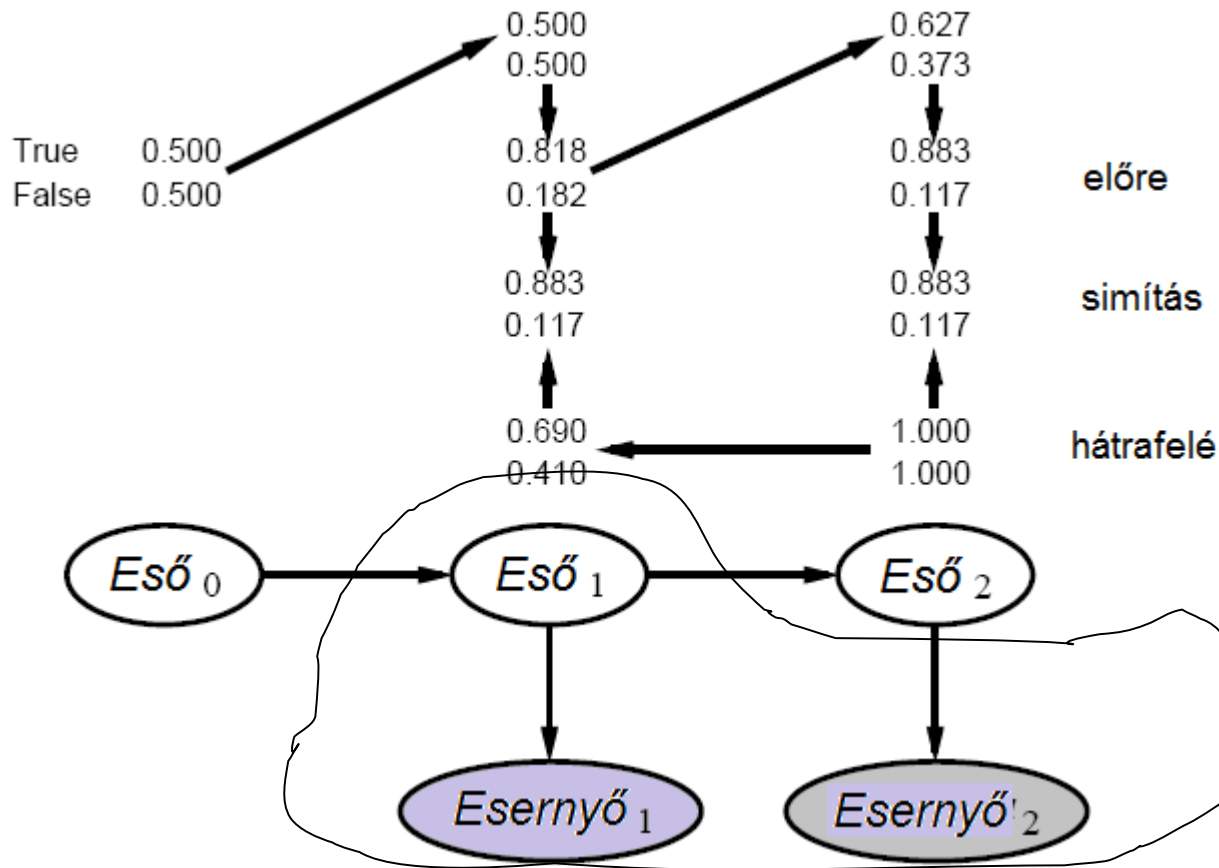


$$\begin{aligned} P(X_k | e_{1:t}) &= P(X_k | e_{1:k}, e_{k+1:t}) && \text{(Bayes szabály)} \\ &= \alpha P(X_k | e_{1:k}) P(e_{k+1:t} | X_k, e_{1:k}) && \text{(a feltételes függetlenség)} \\ &= \alpha P(X_k | e_{1:k}) P(e_{k+1:t} | X_k) \end{aligned}$$

$$\begin{aligned} P(e_{k+1:t} | X_k) &= \sum_{x_{k+1}} P(e_{k+1:t} | X_k, x_{k+1}) P(x_{k+1} | X_k) \\ &= \sum_{x_{k+1}} P(e_{k+1:t} | x_{k+1}) P(x_{k+1} | X_k) \\ &= \sum_{x_{k+1}} P(e_{k+1} | x_{k+1}) P(e_{k+2:t} | x_{k+1}) P(x_{k+1} | X_k) \end{aligned}$$

egy egyszerű rekurzív folyamattal kiszámítható

előre-hátra algoritmus



Az Eső valószínűségének simított becslése $t=1$ -nél, az 1. és 2. napi evidenciából:

$$P(R1|U1,U2) = \alpha P(R1|U1) P(U2|R1).$$

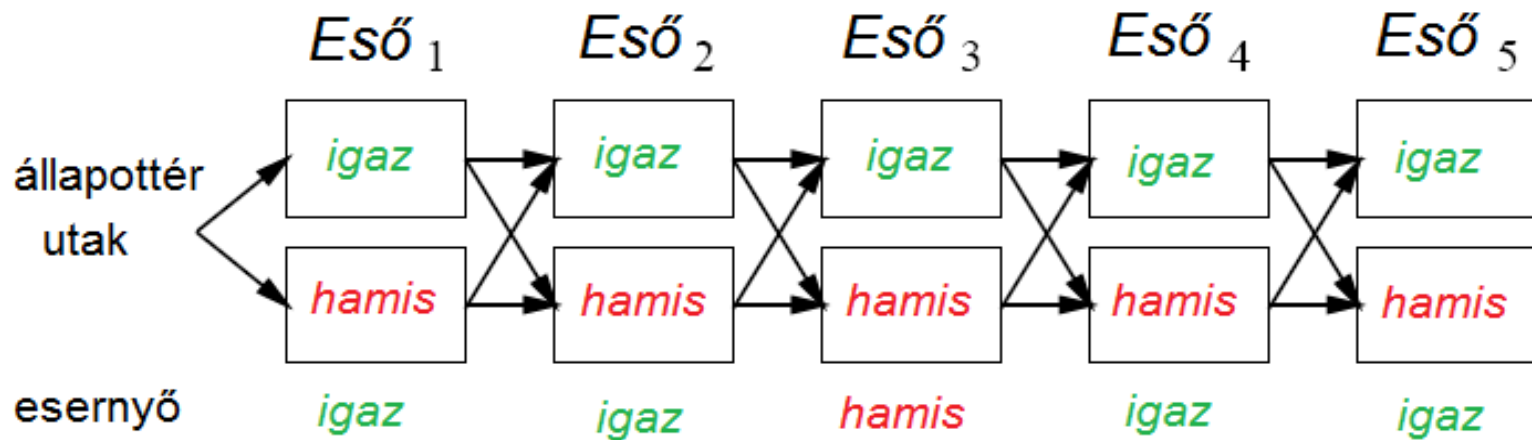
A korábbi szűrésből az első tényező $\langle .818; .182 \rangle$.

$$P(U2|R1) = \sum_{r_2} P(U2|r_2) P(\emptyset|r_2) P(r_2|R1) = .9 \times 1 \times .7 + .2 \times 1 \times .3; = \langle .69; .41 \rangle.$$

Az Eső simítása az 1. napon $P(R1|U1,U2) = \alpha \langle .818; .182 \rangle \langle .69; .41 \rangle \approx \langle .883; .117 \rangle$.

A simított becslés jobb, mint a szűrt becslés (.818). Az Esernyő a 2. napon valószínűbbé teszi, hogy esett a 2. napon, és mivel az eső tartósan esik, még valószínűbbé teszi, hogy esett az 1. napon.

A legvalószínűbb sorozat megtalálása – Viterbi algoritmus



Megfigyelt sorozat: igaz, igaz, hamis, igaz, igaz

Mi a legvalószínűbb: $Eső_1$, $Eső_2$, ..., $Eső_5$ értéke?

$2^5 = 32$ lehetséges sorozat, de lehet egy becslés felsorolás nélkül? Fokozatos szűrések, simítások?

A legvalószínűbb sorozat megtalálása – Viterbi algoritmus

A legvalószínűbb sorozat \neq a legvalószínűbb állapotok sorozata!!!

A legvalószínűbb sorozat X_{t+1} -hez
= a legvalószínűbb sorozat valamelyik X_t -hez és egy lépéssel tovább



$$\begin{aligned} & \max_{x_1, \dots, x_t} P(x_1, x_2, \dots, x_t, X_{t+1} \mid e_{1:t+1}) \\ &= P(e_{t+1} \mid X_{t+1}) \max_{x_t} (P(X_{t+1} \mid x_t) \max_{x_1, \dots, x_{t-1}} P(x_1, x_2, \dots, x_{t-1}, x_t \mid e_{1:t})) \end{aligned}$$

$m_{1:t}(i)$ megadja az i állapothoz vezető pálya valószínűségét.

Félfrissítésben összeg helyett max szerepel.

$$m_{1:t+1} = P(e_{t+1} \mid X_{t+1}) \max_{x_t} (P(X_{t+1} \mid x_t) m_{1:t})$$

A legvalószínűbb sorozat megtalálása – Viterbi algoritmus




Rejtett Markov modell (RMM) (Hidden Markov Model, HMM)

RMM egy időbeli valószínűségi modell. A folyamat állapotát **egyetlen diszkrét** valószínűségi változó írja le. A modell tulajdonsága a rejtett állapot, azaz a (sztochasztikus) állapotfejlődés és annak passzív (sztochasztikus) megfigyelése.

(N tulajdonság, M tünet??)

Kálmán-szűrő

Egy fizikai rendszer állapotának becslése (pl. hely, sebesség) időben egymást követő zajos megfigyelésekből:



átmenetmodell = a mozgás fizikája
érzékelő modell = a mérési folyamat

folytonos változók!

Gauss kiinduló eloszlás,
lineáris Gauss állapotátmenet modell
és megfigyelési modell

Gauss eloszlások frissítése

Ha **szűrés** $P(X_t | e_{1:t})$ Gauss, és az **állapotátmenet** is Gauss,

akkor a $P(X_{t+1} | e_{1:t}) = \int_{x_t} P(X_{t+1} | x_t) P(x_t | e_{1:t}) dx_t$ **jóslás** is Gauss.

Ha a **jóslás** $P(X_{t+1} | e_{1:t})$ Gauss, és a **megfigyelés** is az, akkor a **frissített eloszlás** is Gauss. $P(X_{t+1} | e_{1:t+1}) = \alpha P(e_{t+1} | X_{t+1}) P(X_{t+1} | e_{1:t})$

tehát egy **többszörös** Gauss $N(\mu_t, \Sigma_t)$ minden t-re.

Általános (nemlineáris, nem Gauss) folyamat esetében:

a posterior leírása korlátlanul nő, $t \rightarrow \infty!$

$$P(X_t | e_{1:t})$$

Általános Kálmán frissítés

Állapot átmeneti és
megfigyelés modellek:

$$x_{t+1} = Fx_t + w_t$$

$$e_{t+1} = Hx_t + v_t$$

$$P(x_{t+1} | x_t) = N(Fx_t, \Sigma_x)(x_{t+1})$$

$$P(e_t | x_t) = N(Hx_t, \Sigma_e)(e_t)$$

$$\hat{x}_{t+1} = F\hat{x}_t + K_{t+1}(e_{t+1} - HF\hat{x}_t) \quad \Sigma_{t+1} = (I - K_{t+1})(F\Sigma_t F^T + \Sigma_x)$$

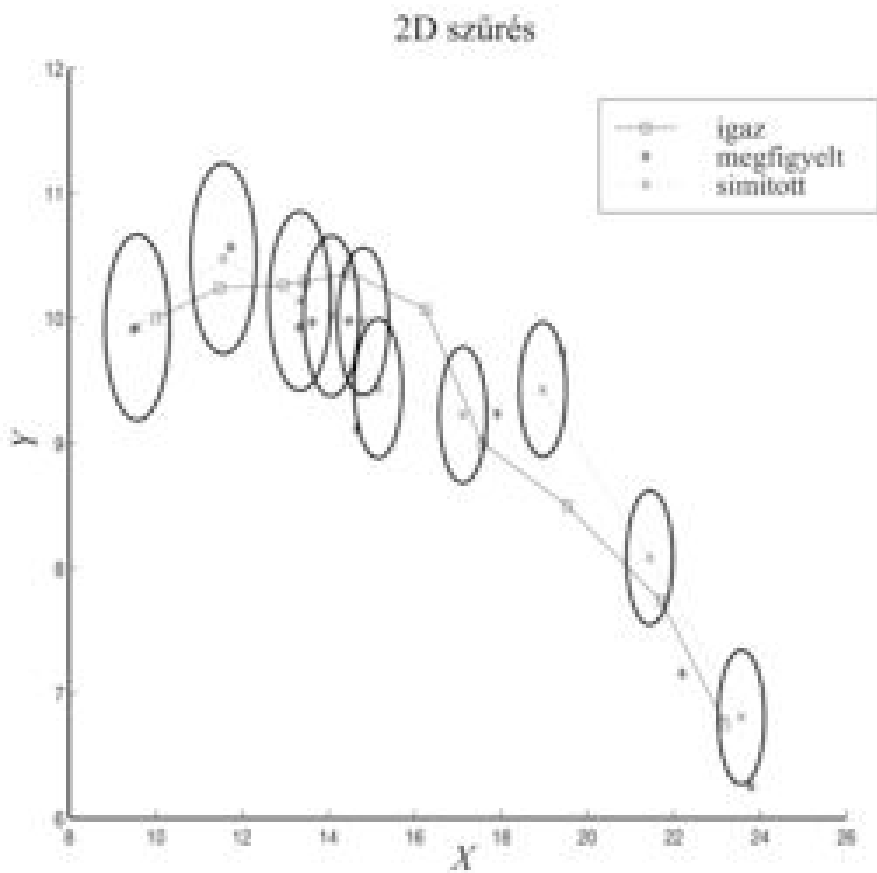
F az állapot átmeneti mátrix; Σ_x az állapot zaj (w) kovarianciája
H a megfigyelés mátrixa, Σ_z a megfigyelési zaj (v) kovarianciája

$$K_{t+1} = (F\Sigma_t F^T + \Sigma_x)H^T (H(F\Sigma_t F^T + \Sigma_x)H^T + \Sigma_e)^{-1}$$

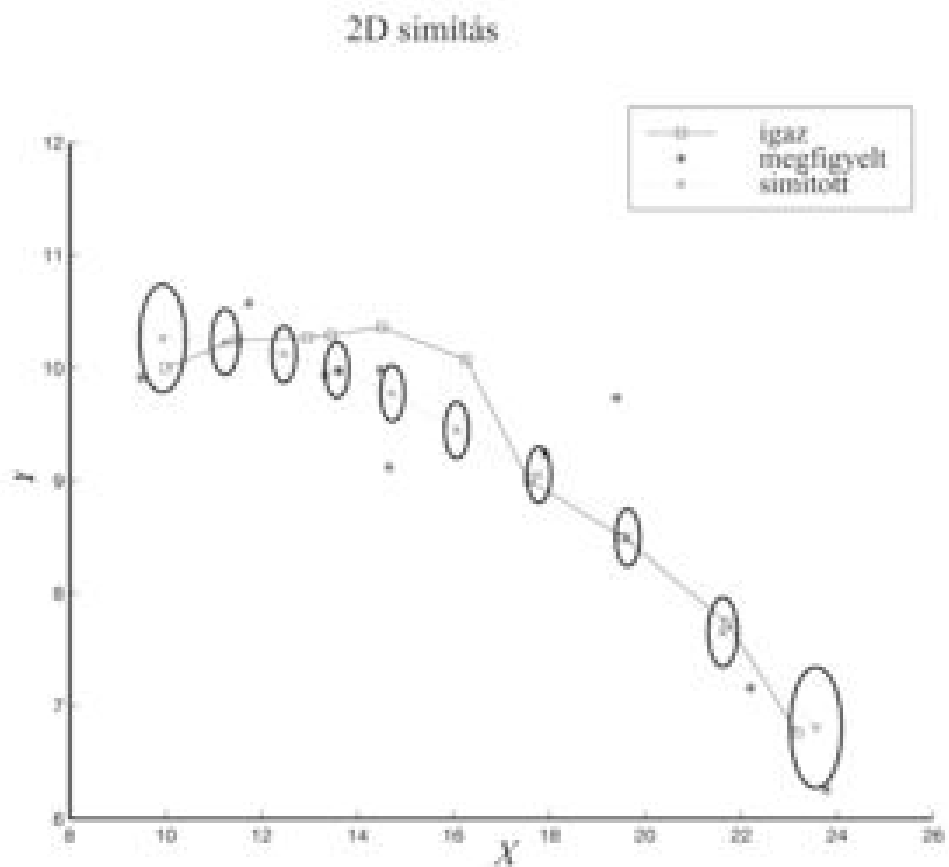
az un. **Kálmán erősítés mátrix**

A K_t, Σ_t a megfigyelésektől függetlenek, számíthatók off-line

2-D követés - példa

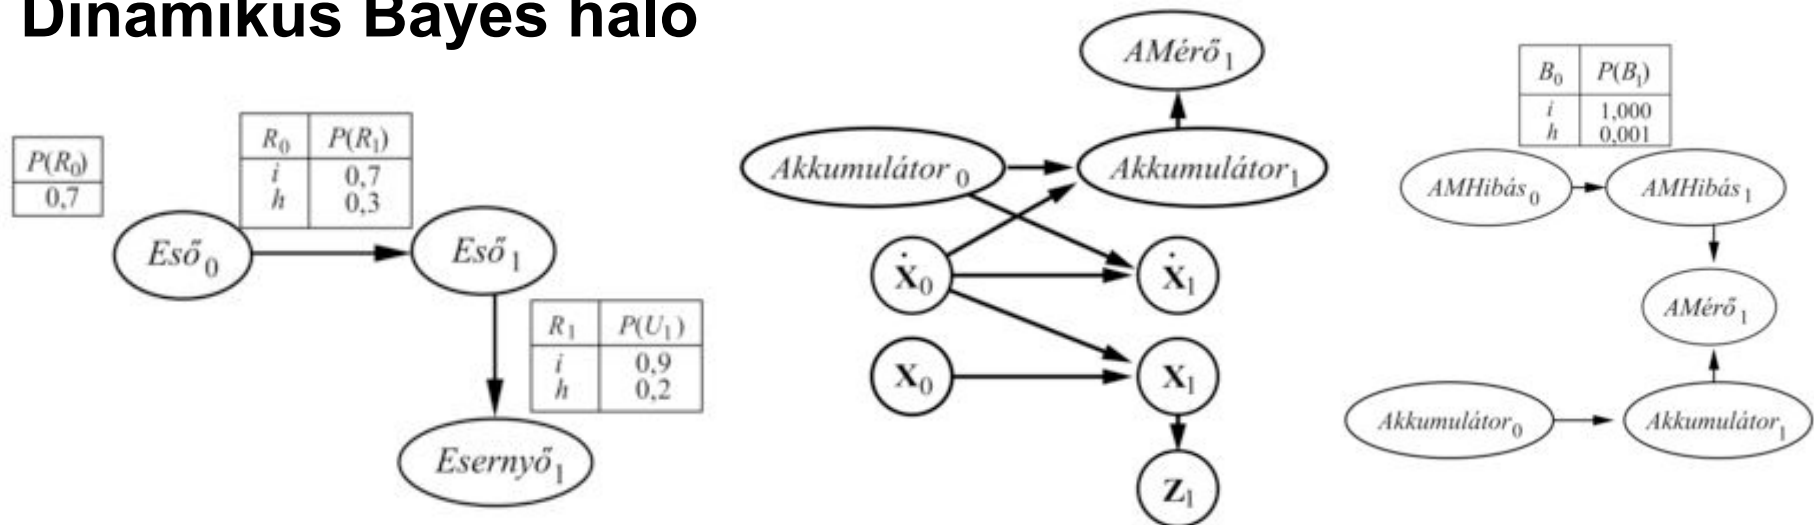


(a)



(b)

Dinamikus Bayes háló



Minden egyes szeletben tetszőleges számú állapotváltozója (\mathbf{X}_t) és bizonyítékváltozója (\mathbf{E}_t) lehet.

Egyszerűsítés: a változók és kapcsolataik pontosan ismétlődnek szeletről szeletre = elsőrendű Markov folyamat, így minden változónak csak a saját szeletében vagy a közvetlenül megelőző szeletben lehetnek szülei.

Minden RMM reprezentálható, mint egy DBH egyetlen állapotváltozóval és egyetlen bizonyítékváltozóval.

Minden diszkrét változós DBH reprezentálható, mint egy RMM. A DBH összes állapotváltozója összekombinálható egyetlen állapotváltozóvá, aminek az értékei az egyes állapotváltozók értékeinek az együttese.

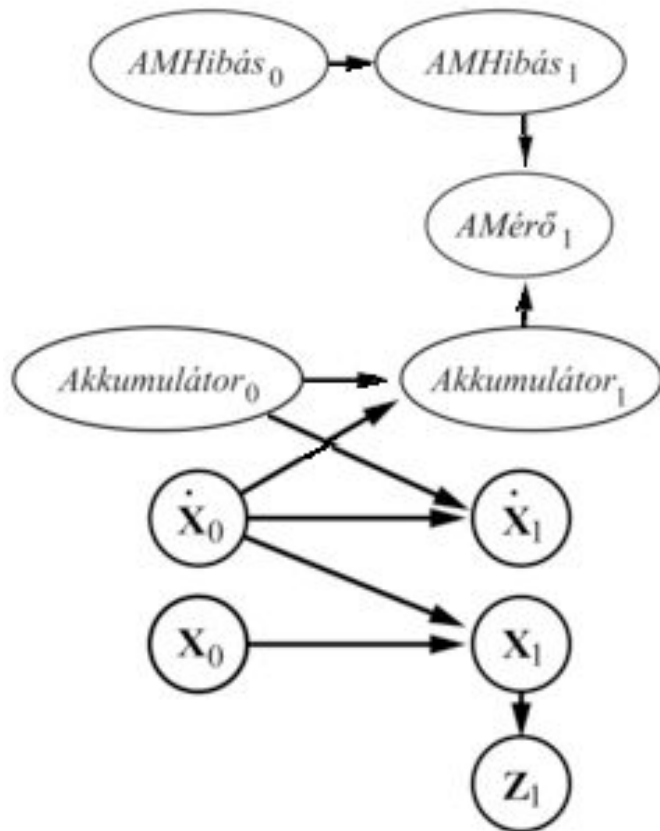

Minden Kálmán-szűrő reprezentálható egy DBH-ban folytonos változókkal és lineáris Gauss feltételes eloszlásokkal

De nem minden DBH reprezentálható egyetlen Kálmán-szűrő modellel.

Kálmán-szűrő: az aktuális állapoteloszlás mindig egy egyedülálló többváltozós Gauss eloszlás – egyetlen „dudor” egy konkrét helyen.

A DBH-k ezzel szemben tetszőleges eloszlást képesek modellezni

Bivariate Normal Density – $r = 0.7$




$$f_X(x_1, \dots, x_N) = \frac{1}{(2\pi)^{N/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu)^\top \Sigma^{-1}(x - \mu)\right)$$

$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left[\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2} - \frac{2\rho xy}{(\sigma_x\sigma_y)}\right]\right)$$

$$\Sigma = \begin{bmatrix} \sigma_x^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_x\sigma_y & \sigma_y^2 \end{bmatrix}$$

Egzakt következtetés DBH-kban

Naiv módszer: a háló kibontása és akármilyen egzakt algoritmus.



Probléma: következtetés költsége idővel nő. Kibontásos szűrés: $t+1$ szelet hozzáadása, t szelet kiösszegzése változó eliminálással. Faktorok nagysága, felfrissítés költsége exponenciális, nincs pontos és hatékony következtetés.

Közelítő következtetés DBH-kban

Valószínűségi súlyozás: pontossága leromlik, ha a bizonyítékváltozók „lentebbiek” a mintavételezett változóknál, ekkor a minták generálására nincsen hatással a bizonyíték.

Egy DBH tipikus struktúrája: Az állapotváltozók egyikének sincs egyetlen bizonyítékváltozója sem az ősei között!

Egy adott pontossági szint fenntartásához, a minták számát exponenciálisan növelni kell t függvényében.

Részecske szűrés (particle filter)

	Kalman szűrő	Részecske szűrő
Állapotegy.	Lineáris állapot és megfigyelési egyenlet	Nemlineáris állapot és megfigyelési egyenlet
Zaj típusa	Gauss, unimodális	Akármilyen , uni- v. multimodális
Kimenet	$\hat{x}_t \quad \Sigma_t$	$p(x_t)$
Megoldás	Egzakt, optimális	Közelítő
Számítás	Gyors	Lassú

Egzakt modell közelítő megoldása, a közelítő modell egzakt megoldása helyett

(Sequential) Monte Carlo filters
Bootstrap filters
Condensation
Interacting Particle Approximations
Survival of the fittest

Részecske szűrés (particle filter)



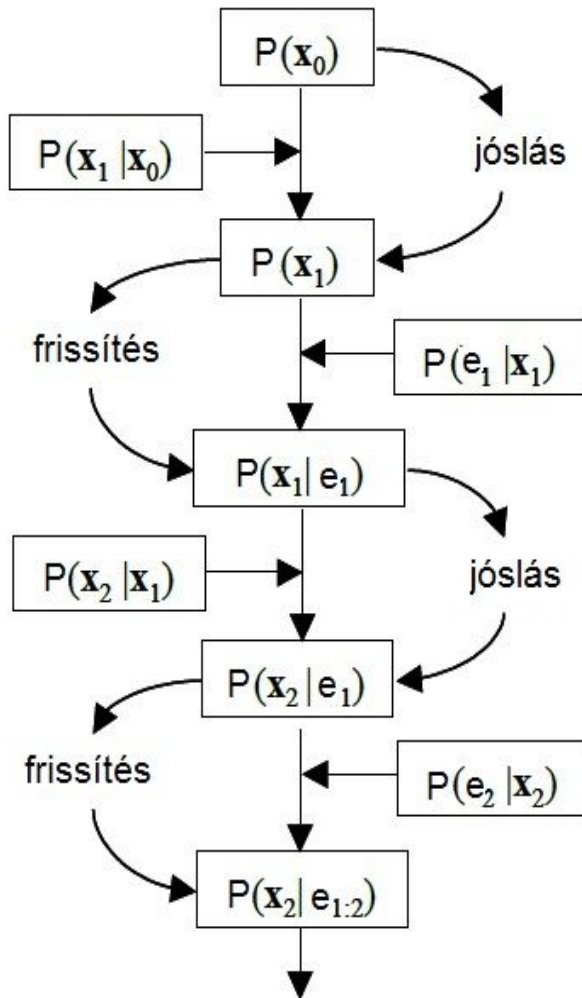
rekurzív szűrés

$$P(X_{t+1} | e_{1:t+1}) = \alpha P(e_{t+1} | X_{t+1}) \sum_{x_t} P(X_{t+1} | x_t) P(x_t | e_{1:t})$$

frissítés
evidenciával

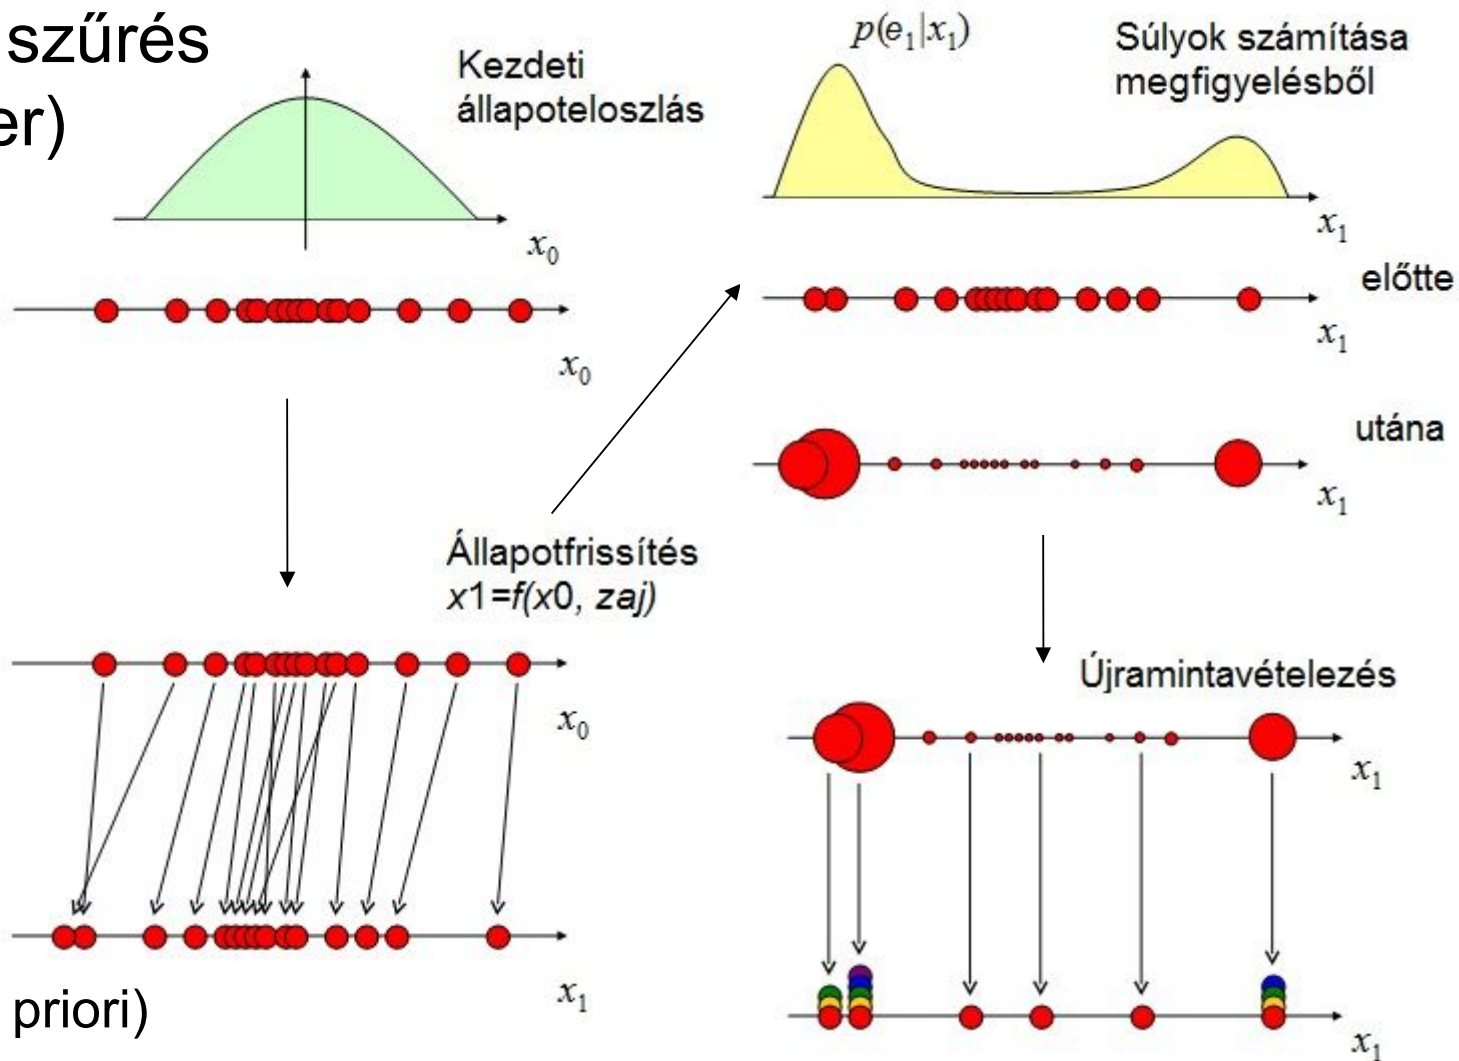
jóslás
dinamikával

részecskefelhő



$$P_N(x_{0:t} | e_{1:t}) = \sum_{i=1}^N w_t^i \delta(x_{0:t} - x_{0:t}^i)$$

Részecske szűrés (particle filter)



Alap algoritmus:

1. Inicializálás (a priori)
2. Dinamikus frissítés (részecskék elmozdulnak)
3. Evidenciafüggő frissítés (súlymódosítás)
4. Újramintavételezés (ha szükséges)
5. Új evidencia - goto 2

