

Jellemzőkinyerés és gépi tanulás a jelfeldolgozásban

Bognár Gergő

ELTE IK Numerikus Analízis Tanszék

Bolyai Kollégium, 2023. október 17.

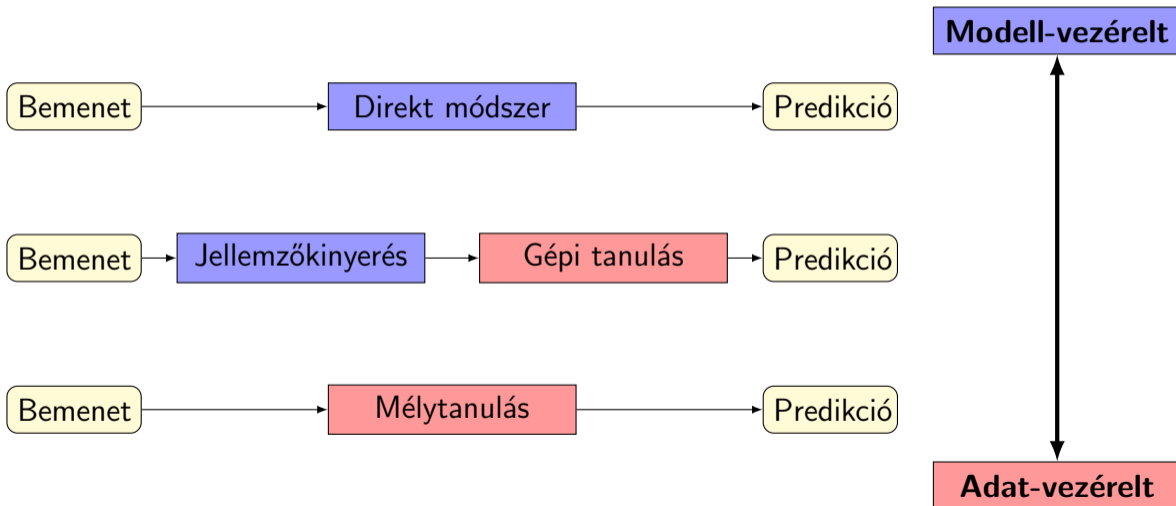
Tartalom

- 1 Bevezetés
- 2 Jelfeldolgozás
- 3 Jellemzőkinyerés
- 4 Gépi tanulás
- 5 Alkalmazás
- 6 Összefoglalás

Tartalom

- 1 Bevezetés
- 2 Jelfeldolgozás
- 3 Jellemzőkinyerés
- 4 Gépi tanulás
- 5 Alkalmazás
- 6 Összefoglalás

Predikciós módszerek



Predikciós módszerek

Modell-vezérelt direkt módszerek

- Ismert vagy közelítő modell
- *Előny*: modell-információ, hatékonyság
- *Hátrány*: érzékenység, szuboptimális közelítések

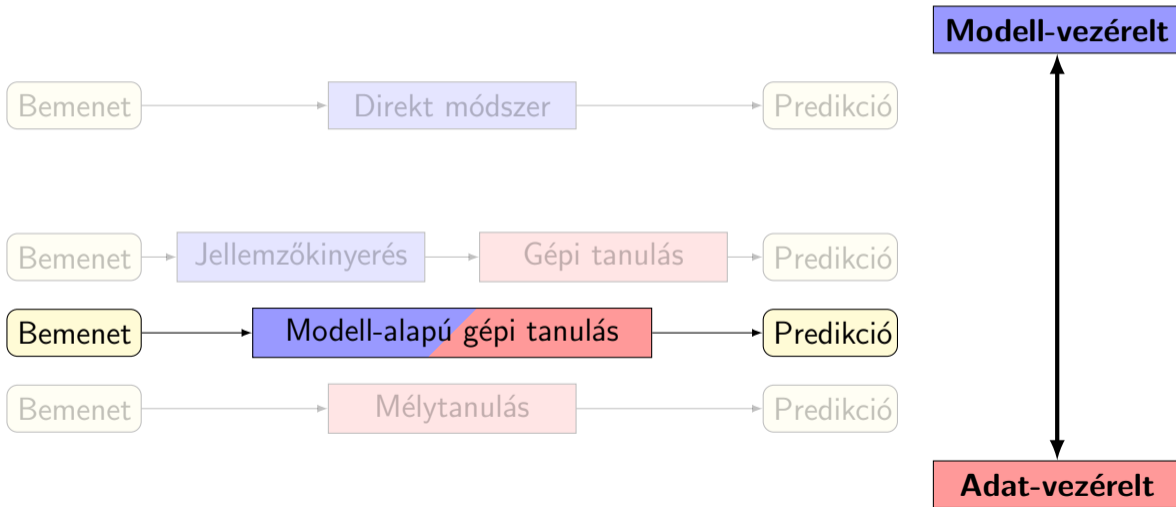
Hagyományos gépi tanulás

- Modell-alapú jellemzőkinyerés és gépi tanulás
- *Előny*: modell-információ és valódi adatok kombinációja
- *Hátrány*: Két független optimalizálás → közös eredmény szuboptimális lehet

Mélytanulás

- Teljesen adatvezérelt, magas absztrakciójú tanuló modell
- *Előny*: valódi adatok statisztikája, általános modell
- *Hátrány*: fekete doboz, adatéhség, sok paraméter, számítási igény



Modell-alapú gépi tanulás



Tartalom

- 1 Bevezetés
- 2 Jelfeldolgozás**
- 3 Jellemzőkinyerés
- 4 Gépi tanulás
- 5 Alkalmazás
- 6 Összefoglalás

Digitális jelfeldolgozás






Digitális jel

- Diszkrétizáció: mintavételezés és kvantálás

$$f : \mathbb{R} \rightarrow \mathbb{R} \quad \longrightarrow \quad x = (x_0, x_1, \dots, x_{n-1}) \in \mathcal{S}^n$$

- Nyquist–Shannon-tétel
- Artifaktumok: zaj, alias jelenség, Gibbs-effektus, ...

Digitális képfeldolgozás



Digitális kép

- Diszkretizáció: mintavételezés és kvantálás (szín és intenzitás)

$$f : \mathbb{R}^2 \rightarrow \mathbb{R}^k \quad \longrightarrow \quad A \in \mathcal{S}^{n \times m \times k}$$

- Artifaktumok: zaj, alias jelenség (Moiré-effektus), ringing, ...

Jelfeldolgozási problémák

Feladatok

- Jelek és képek automatikus feldolgozása és analízise
- Szűrés, tömörítés, transzformáció, jellemzőkinyerés, szegmentálás, osztályozás, események predikciója, anomália detektálás, ...

Megközelítések

- Modell-vezérelt: fizikai, statisztikai, matematikai modell alapján (ha ismert)
- Adat-vezérelt: tanulás reprezentatív mintaadaton
- Kombinált:
 - Modell-alapú jellemzőkinyerés és adat-vezérelt tanulás
 - Modell-alapú gépi tanulás konstrukciók

Tartalom

- 1 Bevezetés
- 2 Jelfeldolgozás
- 3 Jellemzőkinyerés**
- 4 Gépi tanulás
- 5 Alkalmazás
- 6 Összefoglalás

Jellemzőkinyerés


Célok

- Releváns információk kiemelése (modell-ismeret)
- Dimenziócsökkentés
- Gépi tanulás hatékonyságának növelése

Módszerek (jel- és képfeldolgozás)

- Főkomponens analízis (PCA), független komponens analízis (ICA)
- Geometriai és statisztikai jellemzők
statisztikai mérőszámok, jellemzőpontok, skála-invariáns deskriptorok
- Transzformációs módszerek
Fourier, Wavelet, adaptív projekciók (VP)

Lineáris transzformációk




$$v \mapsto Av + b$$

$$v \in \mathbb{R}^n$$

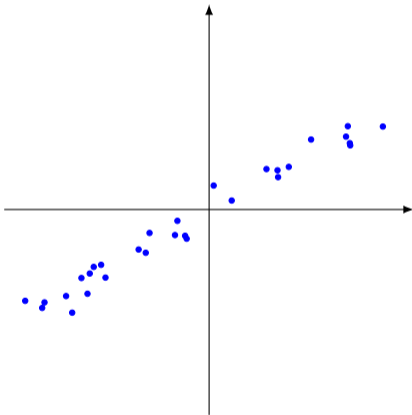
$$A \in \mathbb{R}^{m \times n}$$

$$b \in \mathbb{R}^m$$





Lásd pl. elemi transzformációk (eltolás, forgatás, skálázás, ...)


Példa




Példa: lineáris transzformáció



Példa: dimenziócsökkentés





Példa



- Feladat: ponthalmazok szeparálása (osztályozás/klaszterezés)
- Jellemzőkinyerés?

Példa: nemlineáris transzformáció



- Feladat: ponthalmazok szeparálása (osztályozás/klaszterezés)
- Jellemzőkinyerés: $(x, y) \mapsto x^2 + y^2$ (dimenziócsökkentés)

Főkomponens analízis (PCA)

Adatok

- $x_1, x_2, \dots, x_N \in \mathbb{R}^n$ mérések (koordinátánként normalizált)
- Mátrix reprezentáció: $X = [x_1 \ x_2 \ \dots \ x_N] \in \mathbb{R}^{n \times N}$

Főkomponens analízis

- Ortogonális transzformáció, koordináták variancia szerinti rendezése
- Szinguláris érték felbontás: $X = U\Sigma V^T$
- Transzformáció: $T := U^T X$

Dimenziócsökkentés

- $\mathbb{R}^n \mapsto \mathbb{R}^m$ transzformáció ($m \ll n$)
- PCA projekció: $T_m := U_m^T X$

Sorfejtés, Hilbert-térbeli approximáció

Ortogonalis modell

- $\Phi_0, \Phi_1, \dots, \Phi_{M-1} \in \mathbb{R}^N$ ortogonalis rendszer

$$x \approx \hat{x} = \sum_{k=0}^{M-1} c_k \Phi_k = \Phi c$$

- Legkisebb négyzetes optimalizálás:

$$\|x - \Phi c\|_2^2 \rightarrow \min_c$$

Megoldás

- Együtthatók: $c_k = \langle x, \Phi_k \rangle$, $c = \Phi^T x$
- Ortogonalis projekció: $\hat{x} = \Phi \Phi^T x$

Példák

- Fourier-transzformáció, waveletek, ...

Sorfejtés, Hilbert-térbeli approximáció

Általános modell

- $\Phi_0, \Phi_1, \dots, \Phi_{M-1} \in \mathbb{R}^N$ rendszer

$$x \approx \hat{x} = \sum_{k=0}^{M-1} c_k \Phi_k = \Phi c$$

- Legkisebb négyzetes optimalizálás:

$$\|x - \Phi c\|_2^2 \rightarrow \min_c$$

Megoldás

- Együtthatók: $c = \Phi^+ x$ (általánosított Fourier-együtthatók)
- Ortogonális projekció: $\hat{x} = \Phi \Phi^+ x$

Példák

- Hatványsorok, Hermite-függvények, spline approximáció, ...

Adaptív projekciók (VP)

Adaptív modell

- $\Phi_0(\theta), \Phi_1(\theta), \dots, \Phi_{M-1}(\theta) \in \mathbb{R}^N$ paraméteres függvényrendszer

$$x \approx \hat{x} = \sum_{k=0}^{M-1} c_k \Phi_k(\theta) = \Phi(\theta)c$$

- Legkisebb négyzetes optimalizálás:

$$r(c, \theta) := \|x - \Phi(\theta)c\|_2^2 \rightarrow \min_{c, \theta}$$

Megoldás

- Lineáris és nemlineáris paraméterek szeparálhatóak
- Együtthetők: $c = \Phi^+(\theta)x$ (általánosított Fourier-együtthetők)
- Ortogonális projekció: $\hat{x} = \Phi(\theta)\Phi^+(\theta)x$
- VP funkcionál: $r_2(\theta) := \|x - \Phi(\theta)\Phi^+(\theta)x\|_2^2 \rightarrow \min_{\theta}$

VP példák

Racionális függvények

- Szabad paraméterek: inverzpólusok
- Alapfüggvények: $r_{a,k}(z) := \frac{1}{(1 - \bar{a}z)^k}$ ($z \in \mathbb{T}$, $a \in \mathbb{D}$, $k \in \mathbb{N}^+$)
- Racionális rendszer: $\{r_{a_j, k_j} : j = 1, 2, \dots, N, k_j = 1, 2, \dots, m_j\}$





Adaptív Hermite-függvények

- Szabad paraméterek: transzláció és dilatáció
- Függvények: $\Phi_k(\tau, \lambda; x) := \sqrt{\lambda} \cdot \psi_k(\lambda(x - \tau))$ ($x \in \mathbb{R}$, $\tau \in \mathbb{R}$, $\lambda > 0$)

B-spline-ok

- Szabad paraméterek: csomópontok

Példa: racionális alapfüggvények



VP jellemzők

Tulajdonságok

- *Előnyök*: jel-specifikus reprezentáció, interpretálható paraméterek
- *Kihívások*: nem-lineáris optimalizálás, alapfüggvények választása

Interpretáció

- Approximáció, nemlineáris szűrés: $x \mapsto \hat{x}$
- Jellemzőkinyerés (lokális): $x \mapsto c$
- Jellemzőkinyerés (globális): $x \mapsto \theta$

Alkalmazások

- Paraméterbecslés, rendszeridentifikáció
- Modellezés, tömörítés, adaptív szűrés
- Jellemzőkinyerés gépi tanuláshoz: szegmentálás, klasszifikáció, ...

Tartalom

- 1 Bevezetés
- 2 Jelfeldolgozás
- 3 Jellemzőkinyerés
- 4 Gépi tanulás**
- 5 Alkalmazás
- 6 Összefoglalás

Gépi tanulás alapok


Koncepció

- Ismeretlen/részben ismert/nehezen számítható modell
- Reprezentatív mintaadat
- Általános tanuló rendszerek
- Paradigmák: felügyelt/felügyelet nélküli/megerősítéses tanulás


Felügyelt tanítás

- Bemenet \mapsto predikció (regresszió/osztályozás)
- Annotált, címkézett tanítóadat
- Tanuló rendszer: univerzális approximátor (pl. neurális háló, SVM, döntési fa)
- Tanítás: paraméteroptimalizáció

Mesterséges neuron



Előrecsatolt neurális háló



- Architektúra: teljes, előrecsatolt hálózat
- Rejtett és kimeneti rétegek: lineáris leképezés és nemlineáris aktiváció (Sigmoid, ReLU, SoftMax, stb.)

$$x \mapsto f^{(\ell)}(x) = \rho(A^{(\ell)}x + b^{(\ell)}) \quad (x \in \mathbb{R}^N)$$

Előrecsatolt neurális háló

Architektúra


- $f : \mathbb{R}^N \rightarrow \mathbb{R}^M$ típusú, nemlineáris leképezés:

$$f = f^{(L)} \circ f^{(L-1)} \circ \dots \circ f^{(1)}$$
- Paraméterek: rétegek száma, mérete, súlyai


Tanítás

- Numerikus optimalizálási probléma
- Tanítóadat: bemenet-kimenet $(x^{(k)}, y^{(k)})$ párok
- Költségfüggvény: pl. $\sum \|y^{(k)} - f(x^{(k)})\|_2 \rightarrow \min$
- Iteratív optimalizálás: sztochasztikus gradiens módszer (backpropagation)
- Tanult paraméterek: háló súlyai ($A^{(\ell)}$ és $b^{(\ell)}$)
- Hiperparaméterek: háló mérete, tanulási együttható, ...

Konvolúciós neurális háló (CNN)



- Konvolúciós réteg: konvolúció és nemlineáris aktiváció
- Pooling réteg: dimenziócsökkentés
- Reprezentáció tanulás: beépített többlépcsős jellemzőkinyerés

VPNet¹

- Modell-alapú neurális háló, modell-információ beépítése
- VP rétegek: VP projekció vagy jellemzőkinyerés:

$$x \mapsto f^{(\text{vp})}(x) = \Phi^+(\theta)x = c \quad (\text{klasszifikáció})$$

vagy

$$x \mapsto f^{(\text{vp})}(x) = \Phi(\theta)\Phi^+(\theta)x = \hat{x} \quad (\text{regresszió})$$


¹<https://doi.org/10.1142/S0129065721500544>

Tartalom

- 1 Bevezetés
- 2 Jelfeldolgozás
- 3 Jellemzőkinyerés
- 4 Gépi tanulás
- 5 Alkalmazás**
- 6 Összefoglalás


Elektrokardiogram (EKG)

Name: [REDACTED] | 12-Lead 2 | HR 62 bpm | • Normal ECG ^{AA}Unconfirmed^{AA}
 ID: [REDACTED] | 14:37:18 | • Normal sinus rhythm
 Patient ID: [REDACTED] | PR 0.138s | QRS 0.112s
 Incident: [REDACTED] | QT/QTc 0.398s/0.395s
 Age: 26 | Sex: [REDACTED] | P-QRS-T Axes 27° 88° 49°
 aVR



https://en.wikipedia.org/wiki/File:12-lead_ECG.jpg

EKG szívtések



EKG szívtések

- QRS komplexus
- P, T hullámok
- Szegmensek, intervallumok

EKG szívütés-osztályozás

Feladat

- Predikció: szívütések normális-abnormális osztályozása
- Modell-információ: ismert morfológiai tulajdonságok

Hagyományos gépi tanulás



- Modell-alapú jellemzőkinyerés
- Adat-vezérelt osztályozás (pl. neurális háló)

Mélytanulás

- Mélyháló (pl. CNN), reprezentáció tanulás
- Modell-információ figyelmen kívül hagyása




Modell-alapú gépi tanulás

- Modell-információ kombinációja neurális hálóval





MIT-BIH Arrhythmia Database, PhysioNet

Példa: EKG reprezentáció



Racionális adaptív projekció (VP)

Példa: EKG reprezentáció



Racionális modell interpretációja

EKG szívütés-osztályozás – eredmények

Hagyományos gépi tanulás

- Jellemzők: statisztikai, hullámforma, Fourier, Wavelet, ICA, PCA, racionális², Hermite, spline, fúzió³, ...
- Tanuló módszer: LD, DT, SVM, NN, ...

Mélytanulás

- CNN, U-Net, transformer, ...

Modell-alapú gépi tanulás

- VPNet, VP deep unfolding (folyamatban)

²<https://doi.org/10.1016/j.bspc.2020.102034>

³https://doi.org/10.1016/10.1007/978-3-030-45096-0_44

Tartalom

- 1 Bevezetés
- 2 Jelfeldolgozás
- 3 Jellemzőkinyerés
- 4 Gépi tanulás
- 5 Alkalmazás
- 6 Összefoglalás**

Összefoglalás

Feladatkör

- Jel- és képfeldolgozási problémák
- Modell-információ és reprezentatív tanítóadat

Jellemzőkinyerés

- Jobb reprezentáció, dimenziócsökkentés
- Modell-információ alkalmazása
- Gépi tanulás hatékonyságának növelése
- Jó jellemzők kiválasztása nehéz

Gépi tanulás megközelítések

- Hagyományos: jellemzőkinyerés és gépi tanulás, szuboptimális lehet
- Mélytanulás: hatékony adat-vezérelt, de fekete doboz megközelítés
- Modell-alapú: reprezentáció tanulás modell-információ alapján

Köszönöm a figyelmet!