

Gépi tanulás

Hétköznapi szóhasználatban a *tanulás* azt jelenti, hogy egy feladat megoldásához szabályokat találunk, vagy fedezünk fel. Például egy kisgyermek megtanulhatja, hogy a madaraknak van szárnyuk, és képesek repülni – anélkül, hogy ezt valaki pontos szabályok formájában elmagyarázná neki. A gyerek megfigyelései alapján felismeri a jellemző mintákat és kapcsolatokat, és ez alapján képes új esetekre is következtetni.

Formálisan tekintve, a **gépi tanulás** célja olyan függvény megtalálása, amely egy bemeneti adat $\mathbf{x}$ alapján megbízhatóan becsli a hozzá tartozó kimenetet $\mathbf{y}$. Például ha a bemenet egy rendszámtáblát ábrázoló kép, a kimenet a rajta olvasható szöveg lesz.

Ahhoz, hogy ez megvalósuljon, először is összegyűjtünk egy **tanítóhalmazt**, amely bemeneti és kimeneti adatpárokat tartalmaz:

$$\mathcal{D} = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$$

Ezután definiálunk egy **paraméteres modellt** $f(x; w)$, ahol:

- f egy függvény (pl. neurális hálózat),
- w a tanulható paraméterek összessége (súlyok),

cél, hogy $f(x_i; w) \approx y_i$ legyen, azaz tetszőlegesen kiválasztott adatpár bemenetére (x_i) , az (y_i) kimenetet adja.

A tanulás célja

A tanulás célja az optimális w^* paraméter megtalálása, amely mellett a modell jól teljesít. A modell jóságát (teljesítményét) **veszteségfüggvény** segítségével mérjük:

$$\mathcal{L}(w) = \frac{1}{N} \sum_{n=1}^N \ell(y_n, f(x_n; w))$$

ahol ℓ például lehet a **négyzetes hiba**, aminek egyik bemenete a tanító halmaz $\mathcal{D}$ kimenetének értékéből kivonja, a modell által számolt $\hat{y}$ kimenetet és ennek a különbségnek veszi a négyzetét:

$$\ell(y, \hat{y}) = (y - \hat{y})^2$$

Ilyenkor a $\mathcal{L}$ veszteségfüggvény értéke a négyzetes hibák átlaga. Behelyettesítve:

$$\mathcal{L}(w) = \frac{1}{N} \sum_{n=1}^N (y_n - f(x_n; w))^2$$

A tanulás célja, hogy megtaláljuk azt a *paraméterbeállítást*, amely a lehető legjobban teljesít. Ez azt jelenti, hogy olyan **súlyokat** (paramétereket) keresünk, amelyek a lehető legkisebb hibát eredményezik a tanítóadatokon.

Másként fogalmazva: a tanulás során azt a súlyvektort szeretnénk megtalálni w^* , amely minimalizálja a veszteségfüggvényt — vagyis azt, amely mellett a modell becslései a lehető legközelebb esnek a tényleges válaszokhoz az összes tanítópéldára nézve.

$$w^* = \arg\min_w \mathcal{L}(w)$$

Ez a megközelítés számos alkalmazás alapját képezi: képfelismerés, szövegértés, hangfeldolgozás, játéktaktika stb. A modell nem szabályokat programozva működik, hanem adatokból „tanul meg” viselkedni.

Példa: Egyszerű lineáris modell tanulása

Tegyük fel, hogy a modellünk (becslő függvény) így néz ki:

$$f(x; w) = wx$$

és két tanítópéldánk van:


- (1, 2)
- (2, 4)

A cél, hogy olyan w súlyt találjunk, amely a következő veszteségfüggvényt minimalizálja:

$$\mathcal{L}(w) = \frac{1}{2}[(2 - w \cdot 1)^2 + (4 - w \cdot 2)^2]$$

Ez a függvény azt méri, hogy adott w esetén mekkora hibát követ el a modell. Az alábbi ábrán látható a veszteségfüggvény alakja, valamint a minimumhely:

- A minimális veszteség $\mathcal{L}(w) \approx 0.00$
- A hozzá tartozó optimális súly: $w^* = 2.01$




Példa: Összetettebb modell

Legyen a modell több paraméteres:

$$f(x; w) = \sum_{k=1}^K w_k f_k(x)$$

ahol:

- $\{f_k(x)\}$ előre definiált bázisfüggvények (pl. Gauss-görbék, szinuszok, polinomok stb.)



- Fekete pontok: zajos tanítóadatok $\{(x_n, y_n)\}$
- Kék görbék: a 10 darab Gauss-alakú bázisfüggvény $\{f_k(x)\}$
- Piros görbe: a tanult függvény $f(x; w^*) = \sum w_k f_k(x)$

A modell megtanulta, milyen súlyokkal (w -kel) kombinálja a bázisfüggvényeket úgy, hogy a piros görbe minél jobban kövesse a tanítóadatokat, azaz minimalizálja a négyzetes hibát.

A következő Python program hozta létre a fenti ábrát.

```
import numpy as np
import matplotlib.pyplot as plt
from sklearn.metrics import mean_squared_error
from scipy.linalg import solve

# 1. Tanítóadat generálása (zajos szinuszgörbe)
np.random.seed(42)
N = 30
x_train = np.linspace(0, 1, N)
y_train = np.sin(2 * np.pi * x_train) + 0.1 * np.random.randn(N)

# 2. Bázisfüggvények: Gauss-görbék
K = 10 # Bázisfüggvények száma
centers = np.linspace(0, 1, K)
width = 0.1

def gaussian_basis(x, c, s):
```

```
    return np.exp(-0.5 * ((x - c)/s)**2)

# 3. Design mátrix  $\Phi$  (N x K)
Phi = np.stack([gaussian_basis(x_train, c, width) for c in centers], axis=1)

# 4. Optimális súlyok kiszámítása (normálegyenlet)
#  $\Phi w = y \Rightarrow w = (\Phi^T \Phi)^{-1} \Phi^T y$ 
w_star = solve(Phi.T @ Phi, Phi.T @ y_train)

# 5. Kiértékelés új pontokon
x_test = np.linspace(0, 1, 200)
Phi_test = np.stack([gaussian_basis(x_test, c, width) for c in centers],
axis=1)
y_pred = Phi_test @ w_star

# 6. Eredmény kirajzolása
plt.figure(figsize=(10, 6))
for k in range(K):
    plt.plot(x_test, Phi_test[:, k], '--', color='blue', alpha=0.3) #
    bázisfüggvények

plt.plot(x_test, y_pred, color='red', label='Lineáris kombináció (becslés)')
plt.scatter(x_train, y_train, color='black', label='Tanítóadatok')
plt.title("Basis function regression Gaussian bázisfüggvényekkel")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
```

Underfitting és overfitting (gyenge és túlzott illeszkedés)

A modell kapacitása és a rendelkezésre álló tanítóadatok mennyiségének viszonya fontos szerepet játszik a tanulás sikerességében.


Ha a modell **túl egyszerű** (kevés paramétert vagy kevés bázisfüggvényt használ), akkor nem lesz elég rugalmas ahhoz, hogy megtanulja az adatok mögötti összefüggéseket. Ez az eset az **underfitting** (gyenge illeszkedés): a modell nem tud alkalmazkodni még a tanítóadatokhoz sem, és mind a tanító-, mind a teszt példákon nagy hibát vét.

Ezzel szemben, ha a modell **túl bonyolult** (pl. túl sok paraméterrel dolgozik), akkor hajlamos arra, hogy a tanítóadatokra túlzottan "ráilleszkedjen". Ez az **overfitting** (túlzott illeszkedés), amely során a modell tökéletesen teljesít a tanítóhalmazon, de új, ismeretlen adatokra gyengén általánosít. Megtanulja a tanító halmazban lévő "zajt", pl. az esetleges hibás vagy kiugró értékeket is.

Az alábbi ábra ezt a jelenséget szemlélteti:

- A fekete vonal a valódi (ismeretlen) függvény, amely szerint az adatok keletkeztek.
- A fekete pontok a tanítópéldák.

- A kék szaggatott görbe egy túl egyszerű modell (underfitting): nem tudja követni a mintát.
- A piros szaggatott görbe egy túltanult modell (overfitting): jól illeszkedik a pontokra, de a valódi görbétől eltér.



Olyan modellt érdemes tervezni, amely **épp elég rugalmas** ahhoz, hogy meg tudja tanulni az adatok szerkezetét, de **nem annyira rugalmas**, hogy a véletlen zajokat is megtanulja.

A következő program hozza létre a fenti ábrát:

```
import numpy as np
import matplotlib.pyplot as plt

# Valódi (rejtett) függvény
def true_function(x):
    return np.sin(2 * np.pi * x)

# Tanítóadat
np.random.seed(1)
x_train = np.linspace(0, 1, 7)
y_train = true_function(x_train) + 0.1 * np.random.randn(len(x_train))

# Teszteléshez sűrű intervallum
x_test = np.linspace(0, 1, 300)
y_true = true_function(x_test)

# Gauss bázisfüggvények
def gaussian_basis(x, c, s):
    return np.exp(-0.5 * ((x - c)/s)**2)

def design_matrix(x, centers, width):
```

```
    return np.stack([gaussian_basis(x, c, width) for c in centers], axis=1)

# Underfitting (kevés bázis)
centers_under = np.linspace(0, 1, 3)
Phi_under = design_matrix(x_train, centers_under, 0.3)
Phi_under_test = design_matrix(x_test, centers_under, 0.3)
w_under = np.linalg.lstsq(Phi_under, y_train, rcond=None)[0]
y_under_pred = Phi_under_test @ w_under

# Overfitting (sok bázis)
centers_over = np.linspace(0, 1, 15)
Phi_over = design_matrix(x_train, centers_over, 0.05)
Phi_over_test = design_matrix(x_test, centers_over, 0.05)
w_over = np.linalg.lstsq(Phi_over, y_train, rcond=None)[0]
y_over_pred = Phi_over_test @ w_over

# Ábra
plt.figure(figsize=(10, 6))
plt.plot(x_test, y_true, color='black', linewidth=2, label='Valódi függvény')
plt.plot(x_test, y_under_pred, color='blue', linestyle='--', label='Underfitting (kevés bázis)')
plt.plot(x_test, y_over_pred, color='red', linestyle='--', label='Overfitting (sok bázis)')
plt.scatter(x_train, y_train, color='black', label='Tanítóadatok')
plt.title("Underfitting és overfitting példája")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
```

A gépi tanulási modellek fő típusai

A gépi tanulási modelleket három nagy csoportba sorolhatjuk a tanulás célja és a kimenet jellege alapján:

Regresszió

A regressziós feladat célja egy **folytonos mennyiség** becslése. Ilyenkor a modell egy bemenethez $x \in \mathbb{R}^d$ tartozó kimeneti értéket $y \in \mathbb{R}^k$ próbál megjósolni.

Példák:

- Egy tárgy térbeli pozíciójának becslése egy képből.
- Egy hőmérséklet vagy ház árának előrejelzése.

Osztályozás (klasszifikáció)

Osztályozás során a cél az, hogy a modell egy véges számú lehetséges címke (osztály) közül válasszon ki egyet egy adott bemenethez. Azaz:

$$y \in \{1, 2, \dots, C\}$$

A modell általában nem közvetlenül egy címkét ad vissza, hanem **pontszámokat vagy valószínűségeket** rendel minden lehetséges osztályhoz:

$$f(x; w) = \text{softmax}(s_1, s_2, \dots, s_C)$$

ahol s_i a i -edik osztályhoz tartozó nyers pontszám. A predikció:

$$\hat{y} = \arg\max_i f_i(x; w)$$

A tanítóadat itt is (x_n, y_n) párokból áll, de a y_n most egy osztályindex.

Sűrűségmodellezés

A harmadik kategória a **sűrűségmodellezés**, amelynek célja nem kimeneti érték előrejelzése, hanem **magának az adatnak a valószínűségi eloszlását** megtanulni:

$$p(x) \approx \hat{p}(x; w)$$

Ilyenkor csak x_n példák állnak rendelkezésre (nincs hozzájuk tartozó y_n), és a modell azt próbálja megtanulni, **mennyire jellemzőek** az egyes minták, vagy hogyan lehet **új mintákat generálni** az eloszlásból.

Jellegzetes célfüggvény itt az eloszlás **log-likelihood maximálása**:

$$\mathcal{L}(w) = -\frac{1}{N} \sum_{n=1}^N \log \hat{p}(x_n; w)$$

Felügyelt és felügyelet nélküli tanulás

- A regresszió és osztályozás esetén mindig szükség van egy **célértékre** (y), ezért ezeket **felügyelt tanulásnak** nevezzük.
- A sűrűségmodellezés során nincs célérték, csak maga az x szerepel, ezért ez a **felügyelet nélküli tanulás** kategóriájába soroljuk.

Megjegyzés

Ezek a kategóriák **nem zárják ki egymást**. Például:

- Osztályozás megvalósítható regressziós formában is (pontszámokat tanulunk).
- Sűrűségmodellezésből származtathatunk osztályozót (pl. Bayes-szabály szerint).
- Léteznek összetett modellek, amelyek többféle célt is egyszerre tanulnak (pl. képgenerálás és címkézés együtt).

Hatékony számítási módszerek

A modern gépi tanulási modellek gyakorlati megvalósítása és alkalmazása, szorosan összefügg a hatékony számítási megoldásokkal. Ezek a modellek hatalmas adathalmazokon dolgoznak, így a háttérben zajló számításokat olyan eszközökön érdemes végrehajtani, amelyek párhuzamosan képesek nagy mennyiségű művelet elvégzésére.

GPU-k, TPU-k és batch feldolgozás

A legtöbb mélytanulási számítás **grafikus feldolgozóegységek (GPU-k)** segítségével történik. Ezeket eredetileg képfeldolgozásra tervezték, de mivel képesek **több ezer szálon párhuzamos számításokat végezni**, kiválóan alkalmasak a gépi tanulás modelljeinek betanítására és futtatására is.

A GPU-k saját gyors memóriával rendelkeznek, amelyben az adatokat és a modell súlyait is tárolni lehet. A legnagyobb lassulást (szűk keresztmetszet) általában az okozza, ha az adatokat a CPU memóriájából át kell másolni a GPU-ba. Ezért fontos, hogy a számításokat úgy szervezzük, hogy az adatok a GPU memóriájában maradjanak.

A hatékony működés érdekében az adatokat gyakran **batch-ekre (kötegekre)** osztjuk, vagyis egyszerre több mintát dolgozunk fel. A GPU szinte ugyanolyan gyorsan képes feldolgozni egy batch-et, mint egyetlen mintát, mivel a szűk keresztmetszet ilyenkor is a GPU-ba történő adatbetöltés marad.

Egy tipikus GPU elméleti teljesítménye:

10^{13} – 10^{14} FLOP/s (floating point művelet másodpercenként)

A lebegőpontos számokat jellemzően 32 biten (FP32) tároljuk, de sok esetben **16 bites (FP16)** vagy kisebb pontosság is elegendő, ami még tovább gyorsíthatja a számítást. FP16-os tárolással közel kétszeres sebességnövekedés érhető el, az FP32-vel szemben.

Tenzorok használata

A mélytanulási könyvtárak, mint a PyTorch vagy a JAX, a számításokat **tenzorokkal** végzik. Egy tenzor nem más, mint egy tömb, amely elemei (számok) több dimenzió mentén vannak elrendezve. A vektorok és mátrixok a tenzorok speciális esetei:

Vektor: $\mathbb{R}^n$, Mátrix: $\mathbb{R}^{n \times m}$,
Tenzor: $\mathbb{R}^{N_1 \times N_2 \times \dots \times N_k}$

A tenzorokkal reprezentáljuk:

- a bemeneti adatokat (pl. képek, hangminták),
- a modell paramétereit (súlyok),
- a rejtett rétegek aktivációit.

Példák:

- Egy RGB kép (64 pixel $\times$ 64 pixel): $(\mathbb{R}^{3 \times 64 \times 64})$
- 32 ilyen kép: $(\mathbb{R}^{32 \times 3 \times 64 \times 64})$

A népszerű mélytanulási könyvtárak lehetővé teszik ezek **formátumának gyors átalakítását**, például:

- dimenziók átrendezése (transpose),
- szeletek kivágása,
- sorozatok kibontása (reshape).

Ezek a műveletek gyakran **memóriamásolás nélkül** végrehajthatók, ami különösen hatékonyá teszi őket.

Példák tenzorátalakításokra

A mélytanulási könyvtárakban, mint a PyTorch vagy JAX, a **tenzorokkal való munka** egyik alappillére az adatok szerkezetének (dimenzióinak) átrendezése vagy módosítása. Az alábbi példák három gyakori műveletet mutatnak be:

1. Dimenziók átrendezése (transpose)

Ha van egy mátrixunk:

$$A = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{bmatrix} \in \mathbb{R}^{2 \times 3}$$

A transzponáltja:

$$A^{\top} = \begin{bmatrix} 1 & 4 \\ 2 & 5 \\ 3 & 6 \end{bmatrix} \in \mathbb{R}^{3 \times 2}$$

PyTorch-ban:

```
A = torch.tensor([[1, 2, 3],
                  [4, 5, 6]])
A_T = A.T # vagy A.transpose(0, 1)
```

2. Szeletek kivágása

Tegyük fel, hogy van egy 3 $\times$ 4-es mátrix, és csak az első két oszlopra van szükségünk:

$$B = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 5 & 6 & 7 & 8 \\ 9 & 10 & 11 & 12 \end{bmatrix}$$

Kivágva az első két oszlop:

$$B[:, 0:2] = \begin{bmatrix} 1 & 2 \\ 5 & 6 \\ 9 & 10 \end{bmatrix}$$

PyTorch-ban:

```
B = torch.arange(1, 13).reshape(3, 4)
slice = B[:, 0:2] # minden sor, az első két oszlop
```

3. Sorozatok kibontása (reshape)

Egy hosszú vektor:

$$v = [1, 2, 3, 4, 5, 6] \in \mathbb{R}^6$$

Ezt átalakíthatjuk egy 2 soros, 3 oszlopos mátrixszá:

$$\text{reshape: } \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{bmatrix} \in \mathbb{R}^{2 \times 3}$$

PyTorch-ban:

```
v = torch.tensor([1, 2, 3, 4, 5, 6])
reshaped = v.reshape(2, 3)
```

Tenzoralapú számítási modell előnyei

A modern mélytanulási rendszerek tervezése során a következő célok fontosak:

- A számításokat **tenzoros formában** szervezzük meg, mert ez lehetővé teszi a párhuzamos végrehajtást.
- Minden szint – a modell, a programkönyvtár, a hardver – **kompatibilis** kell legyen ezzel a reprezentációval.
- A tenzoros struktúra támogatja a memóriabeli **lokalitást**, vagyis a gyakran használt adatok közel maradnak egymáshoz a memóriában, ezáltal gyorsabb az elérésük.

A mesterséges intelligencia modellek gyakorlati hatékonysága így nemcsak a matematikai ötleteken, hanem a **tenzorokra épülő implementáció minőségén** is múlik.

From:

<https://edu.iit.uni-miskolc.hu/> - Institute of Information Science - University of Miskolc

Permanent link:

https://edu.iit.uni-miskolc.hu/muszaki_informatika:gepi_tanulas?rev=1747911055

Last update: 2025/05/22 10:50

