


# Neurális hálók

## Neuron modellezése


Az alábbi képen a biológiai neuront és annak mesterséges intelligencia modellekben használt analógját látjuk. A biológiai neuron az emberi agy alapvető építőeleme, amely információkat dolgoz fel és továbbít más neuronok felé. A neuron **dendritekkel** rendelkezik, amelyek a környező neuronoktól érkező jeleket fogadják. Ezeket a jeleket a sejt (amelyben a mag található) dolgozza fel, majd továbbküldi az **axonon** keresztül. Az **axon** végén található axon-végződések **szinapszisokon** keresztül kapcsolódnak más neuronokhoz, így biztosítva az információáramlást.



A mesterséges neuron, a fenti biológiai modell alapján működik, leegyszerűsítve annak alapvető működését. A mesterséges neuron bemeneteket fogad, amelyeket (matematikailag) súlyoz (ezzel vezérli a bemenet fontosságát), majd összegez. Az így kapott értéken egy aktivációs függvényt futtat, amely meghatározza, hogy a neuron "tüzel-e", azaz továbbküldi-e a jelet. Az aktivációs függvény eredménye képezi a neuron kimenetét, amelyet továbbít a hálózat következő rétegeinek.

## Hálózati Modell

Az alábbi kép egy mesterséges neurális hálózat egyszerű modelljét ábrázolja.




A hálózat bemeneti réteggel indul, amely a zöld színű  $x_1$  és  $x_2$  elemeket tartalmazza. Ezek a bemeneti változók képviselik azokat az adatokat, amelyeket a modell feldolgoz. A bemeneteket súlyokkal szorozzák, majd átadják a rejtett rétegek neuronjaiba, amelyeket a kék színű  $z_1$ ,  $z_2$  és  $z_3$  jelöl.

A *rejtett réteg(ek)ben* minden neuron kiszámítja a saját kimenetét egy **aktivációs függvény**

([https://en.wikipedia.org/wiki/Activation\\_function](https://en.wikipedia.org/wiki/Activation_function)) segítségével, amely a bemeneti jelek összegét alakítja át (nemlineáris módon). Ezek a kimenetek aztán tovább haladnak a következő rétegekbe (a példában csak 1 rejtett réteget használunk, ezért itt nincs továbbadás), míg végül eléri a kimeneti réteget, amelyet itt az **y\_pred** (y predikció) narancssárga elem jelöl.


Az **y\_pred** a modell végső előrejelzése, egy számérték, amely például egy *osztályozási* vagy *regressziós* (közelítési) probléma megoldásaként jelenik meg.

Ez az ábra segít megérteni a neurális hálózatok alapvető működési elvét: a bemenetek fokozatos átalakulását a különböző rétegeken keresztül, amelyek végül egy konkrét kimeneti értékhez vezetnek. Ezt a folyamatot a gépi tanulás során finoman hangolják (optimalizálják), például *visszaterjesztés* (backpropagation) és *gradienscsökkentés* (gradient descent) segítségével, hogy a modell pontos előrejelzéseket tudjon adni.



Ha egy kép a bemenet, akkor a pixeleit sorban is be lehet adni a hálónak (nem vesszük figyelembe, hogy a kép téglalap). A finomhangolás során - a bemutatott minták alapján - a háló megtanulja a pixelek közötti összefüggéseket, és választ tud majd adni, hogy mosolyog-e a képen látható személy, egy olyan képen is, amit korábban nem mutattak meg a hálónak (a modellnek). Megjegyzés: olyan modellek természetesen jobban működnek, amik figyelembe veszik a szomszédos pixeleket is (pl. konvolúciós háló).

Az ábrán, a *fully-connected* layer azt jelenti, hogy a minden bementi neuron minden a következő réteg minden neuronjával össze van kapcsolva.



## Neurális háló, mint osztályozó - Generatív hálók


Az alábbi link a számok felismerését teszi láthatóvá: [https://adamharley.com/nn\\_vis/](https://adamharley.com/nn_vis/)

Az alábbi linken bemutatjuk, hogyan működik az osztályozás? Autoencoder és generatív modellek.

<http://showroom.iit.uni-miskolc.hu/gans>

Interaktív neurális háló szimulátor: <https://dcato98.github.io/playground/>

## Modell paramétereinek kiszámítása



A neurális hálót, az összeköttetéseihez rendelt súlyok segítségével tudjuk használni. A bemenetből és a rejtett réteg két neuronjának ( $z_1$ ) és ( $z_2$ ) értékét az alábbi képlettel számolhatjuk:

$$z_1 = x_1 \cdot w_{11} + x_2 \cdot w_{21} \quad z_2 = x_1 \cdot w_{12} + x_2 \cdot w_{22}$$

A rejtett réteg teljesen összekötött (fully connected), ezért minden bemenet kapcsolódik minden rejtett neuronhoz.

A következő kimeneti réteg  $(z_3 = y_{\text{pred}})$  értékét, ami egyetlen neuronból áll így számíthatjuk:

$$z_3 = z_1 \cdot w_{31} + z_2 \cdot w_{32}$$

Egyben ez lesz a háló előrejelzése  $(y_{\text{pred}})$ . Ezt a fenti műveletet *forward pass*-nak nevezzük.

## Mátrixok alkalmazása háló modellekben

Az egységesítés és a könnyebb kezelhetőség miatt, a fenti képleteket mátrixos és vektoros formában is felírhatjuk:

Rejtett réteg súlymátrixa:  $(W_1 = \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{bmatrix})$

A kimeneti réteg vektor:  $(W_2 = \begin{bmatrix} w_{31} \\ w_{32} \end{bmatrix})$

Bemeneti és rejtett réteg vektorok:  $(\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}, \quad \mathbf{z} = \begin{bmatrix} z_1 \\ z_2 \end{bmatrix})$

Ezek alapján a rejtett réteget a bement és a súlymátrix alapján így számolhatjuk:

$$\mathbf{z} = W_1 \cdot \mathbf{x} \text{ behelyettesítve: } \begin{bmatrix} z_1 \\ z_2 \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

A kimenet eredménye egy számérték (skalár) lesz:

$$y_{\text{pred}} = \begin{bmatrix} w_{31} \\ w_{32} \end{bmatrix} \cdot \begin{bmatrix} z_1 \\ z_2 \end{bmatrix}$$

Teljes mátrixos formában:

$$y_{\text{pred}} = W_2 \cdot W_1 \cdot \mathbf{x}$$

## Példa konkrét számértékekkel (forward pass)

Tegyük fel hogy:

$$W_1 = \begin{bmatrix} 0.5 & 0.3 \\ 0.2 & 0.7 \end{bmatrix}, \quad W_2 = \begin{bmatrix} 0.6 \\ 0.4 \end{bmatrix}, \quad \mathbf{x} = \begin{bmatrix} 0.8 \\ 0.6 \end{bmatrix}$$

Rejtett réteg számítása:

$$\mathbf{z} = \begin{bmatrix} 0.5 & 0.3 \\ 0.2 & 0.7 \end{bmatrix} \cdot \begin{bmatrix} 0.8 \\ 0.6 \end{bmatrix} = \begin{bmatrix} (0.5 \cdot 0.8 + 0.3 \cdot 0.6) \\ (0.2 \cdot 0.8 + 0.7 \cdot 0.6) \end{bmatrix} = \begin{bmatrix} 0.58 \\ 0.58 \end{bmatrix}$$

Kimeneti réteg számítása:

$$y_{\text{pred}} = \begin{bmatrix} 0.58 \\ 0.58 \end{bmatrix} \cdot \begin{bmatrix} 0.6 \\ 0.4 \end{bmatrix} = (0.52 \cdot 0.6 + 0.66 \cdot 0.4) = 0.58$$

## A súlyok módosítása a hiba függvényében

**“Loss”** a neurális háló teljesítményének mérésére szolgáló függvény, amely azt jelzi, hogy a háló által számolt kimenetek mennyire térnek el a várt kimenetektől.

$$\text{Loss} = \frac{1}{2} (y - y_{\text{pred}})^2$$

### Loss Deriváltja a Kimeneti Réteg Súlyaira

A *back-propagation* során a Loss függvény deriváltját (gradiensét) használjuk a súlyok frissítéséhez. Mivel a Loss függvény közvetlenül nem függ a súlytól, ezért a láncszabályt kell alkalmazni a deriváláskor.

$$\frac{\partial \text{Loss}}{\partial w_{31}} = \frac{\partial \text{Loss}}{\partial y_{\text{pred}}} \cdot \frac{\partial y_{\text{pred}}}{\partial w_{31}} \quad \frac{\partial \text{Loss}}{\partial w_{32}} = \frac{\partial \text{Loss}}{\partial y_{\text{pred}}} \cdot \frac{\partial y_{\text{pred}}}{\partial w_{32}}$$

A fenti két derivált kifejezi, hogy a két súly mennyire van hatással a hibára.

**1.)** Első tényező:  $\left( \frac{\partial \text{Loss}}{\partial y_{\text{pred}}} \right)$  a Loss függvény deriváltja a  $(y_{\text{pred}})$ -re:

$$\frac{\partial \text{Loss}}{\partial y_{\text{pred}}} = -(y_{\text{true}} - y_{\text{pred}}) = -e$$

ahol  $(e = y - y_{\text{pred}})$  a hiba.

**2.)** Második tényező:  $\left( \frac{\partial y_{\text{pred}}}{\partial w_{31}} \right)$

Az  $(y_{\text{pred}})$  függ a rejtett kimenettől  $(z_1)$ :

$$y_{\text{pred}} = z_1 \cdot w_{31} + z_2 \cdot w_{32}$$

Ezért:

$$\frac{\partial y_{\text{pred}}}{\partial w_{31}} = z_1$$

Teljes derivált:

Összekapcsolva a két tényezőt:

$$\frac{\partial \text{Loss}}{\partial w_{31}} = -e \cdot z_1$$

hasonlóan:

$$\frac{\partial \text{Loss}}{\partial w_{32}} = -e \cdot z_2$$

### 3.) Gradiens a kimeneti súlyokra ( $W_2$ )

A súlyok gradiensének mátrixos formája:

$$\Delta W_2 = \begin{bmatrix} \frac{\partial \text{Loss}}{\partial w_{31}} \\ \frac{\partial \text{Loss}}{\partial w_{32}} \end{bmatrix} = \begin{bmatrix} z_1 \cdot e \\ z_2 \cdot e \end{bmatrix}$$

A kimeneti réteg hibáját ( $e$ ) visszaterjesztjük a rejtett réteg neuronjaira ( $h_1, h_2$ ):

$$\Delta_{\text{hidden}} = \begin{bmatrix} e \cdot w_{31} \\ e \cdot w_{32} \end{bmatrix}$$

Ez a rejtett réteg hibája.

A bemeneti réteg és a rejtett réteg közötti súlyok gradiensét a bemenetek ( $x$ ) és a rejtett réteg hibájának ( $\Delta_{\text{hidden}}$ ) szorzata adja:

$$\Delta W_1 = \begin{bmatrix} x_1 \cdot \Delta_{z_1} & x_1 \cdot \Delta_{z_2} \\ x_2 \cdot \Delta_{z_1} & x_2 \cdot \Delta_{z_2} \end{bmatrix}$$

$$\text{ahol: } \Delta_{z_1} = e \cdot w_{31}, \quad \Delta_{z_2} = e \cdot w_{32}$$

A súlyok frissítését a gradiensek ( $\Delta W_1, \Delta W_2$ ) és a tanulási ráta ( $\eta$ ) segítségével frissítjük:

$$W_1 = W_1 - \eta \cdot \Delta W_1 \quad W_2 = W_2 - \eta \cdot \Delta W_2$$

A teljes eljárás c implementációja:

```
#include <stdio.h>
#include <stdlib.h>
#include <math.h>

// Adatok (bemenetek és várt kimenetek)
#define INPUT_NODES 2
#define HIDDEN_NODES 2
#define OUTPUT_NODES 1
#define SAMPLES 3
#define EPOCHS 1000
#define LEARNING_RATE 0.01

// Adatok és súlyok inicializálása
double inputs[SAMPLES][INPUT_NODES] = {
```

```
    {0.3, 0.1},
    {0.8, 0.6},
    {0.5, 0.5}
};

double expected_outputs[SAMPLES][OUTPUT_NODES] = {
    {0.2},
    {0.7},
    {0.5}
};

// Súlyok
double weights_input_to_hidden[INPUT_NODES][HIDDEN_NODES];
double weights_hidden_to_output[HIDDEN_NODES][OUTPUT_NODES];

// Véletlen szám generálása 0 és 1 között
double random_double() {
    return (double)rand() / RAND_MAX;
}

// Forward pass függvény: Egyetlen minta alapján kiszámítja a kimenetet
void forward_pass(double *input, double *hidden_output, double
*final_output,
                  double *weights_input_to_hidden, double
*weights_hidden_to_output) {
    // 1. Bemenet -> Rejtett réteg
    for (int i = 0; i < HIDDEN_NODES; i++) {
        hidden_output[i] = 0.0;
        for (int j = 0; j < INPUT_NODES; j++) {
            hidden_output[i] += input[j] * weights_input_to_hidden[j *
HIDDEN_NODES + i];
        }
    }

    // 2. Rejtett réteg -> Kimeneti réteg
    for (int i = 0; i < OUTPUT_NODES; i++) {
        final_output[i] = 0.0;
        for (int j = 0; j < HIDDEN_NODES; j++) {
            final_output[i] += hidden_output[j] * weights_hidden_to_output[j
* OUTPUT_NODES + i];
        }
    }
}

// Súlyok frissítése
void update_weights(double *weights, double *gradients, int rows, int cols)
{
    for (int i = 0; i < rows; i++) {
        for (int j = 0; j < cols; j++) {
            weights[i * cols + j] += LEARNING_RATE * gradients[i * cols +
j];
        }
    }
}
```

```
    }  
}  
  
int main() {  
    // Véletlenszerű súlyok inicializálása  
    for (int i = 0; i < INPUT_NODES; i++) {  
        for (int j = 0; j < HIDDEN_NODES; j++) {  
            weights_input_to_hidden[i][j] = random_double();  
        }  
    }  
    for (int i = 0; i < HIDDEN_NODES; i++) {  
        for (int j = 0; j < OUTPUT_NODES; j++) {  
            weights_hidden_to_output[i][j] = random_double();  
        }  
    }  
  
    double hidden_layer_output[HIDDEN_NODES];  
    double output[OUTPUT_NODES];  
    double error[OUTPUT_NODES];  
  
    // Tanítási ciklus  
    for (int epoch = 0; epoch < EPOCHS; epoch++) {  
        double total_loss = 0.0;  
  
        for (int sample = 0; sample < SAMPLES; sample++) {  
            // 1. Forward pass egy mintára  
            forward_pass((double *)inputs[sample], hidden_layer_output,  
output,  
                        (double *)weights_input_to_hidden, (double  
*)weights_hidden_to_output);  
  
            // 2. Hibaszámítás  
            for (int i = 0; i < OUTPUT_NODES; i++) {  
                error[i] = expected_outputs[sample][i] - output[i];  
                total_loss += error[i] * error[i];  
            }  
  
            // 3. Visszaterjesztés (backpropagation)  
            double gradients_hidden_to_output[HIDDEN_NODES][OUTPUT_NODES] =  
{0};  
            for (int i = 0; i < HIDDEN_NODES; i++) {  
                for (int j = 0; j < OUTPUT_NODES; j++) {  
                    gradients_hidden_to_output[i][j] =  
hidden_layer_output[i] * error[j];  
                }  
            }  
  
            double gradients_input_to_hidden[INPUT_NODES][HIDDEN_NODES] =  
{0};  
            for (int i = 0; i < INPUT_NODES; i++) {
```

```
        for (int j = 0; j < HIDDEN_NODES; j++) {
            double back_error = 0.0;
            for (int k = 0; k < OUTPUT_NODES; k++) {
                back_error += error[k] * weights_hidden_to_output[j
* OUTPUT_NODES + k];
            }
            gradients_input_to_hidden[i][j] = inputs[sample][i] *
back_error;
        }
    }

    // 4. Súlyok frissítése
    update_weights((double *)weights_hidden_to_output, (double
*)gradients_hidden_to_output, HIDDEN_NODES, OUTPUT_NODES);
    update_weights((double *)weights_input_to_hidden, (double
*)gradients_input_to_hidden, INPUT_NODES, HIDDEN_NODES);
}

// Hiba kiírása minden epoch után
if (epoch % 100 == 0) {
    printf("Epoch %d, Loss: %.4f\n", epoch, total_loss / SAMPLES);
}

// Eredmények kiírása tanító adatokon
printf("\nVégső kimenetek tanítás után:\n");
for (int sample = 0; sample < SAMPLES; sample++) {
    forward_pass((double *)inputs[sample], hidden_layer_output, output,
                (double *)weights_input_to_hidden, (double
*)weights_hidden_to_output);

    printf("Bemenet: [%.2f, %.2f], Várt: %.2f, Kimenet: %.4f\n",
           inputs[sample][0], inputs[sample][1],
expected_outputs[sample][0], output[0]);
}

// Tesztelés új bemenetekkel
double test_inputs[3][INPUT_NODES] = {
    {0.4, 0.6}, // Átlag: 0.5
    {0.2, 0.8}, // Átlag: 0.5
    {0.9, 0.1}  // Átlag: 0.5
};

printf("\nTeszt kimenetek:\n");
for (int i = 0; i < 3; i++) {
    forward_pass((double *)test_inputs[i], hidden_layer_output, output,
                (double *)weights_input_to_hidden, (double
*)weights_hidden_to_output);

    double expected = (test_inputs[i][0] + test_inputs[i][1]) / 2.0; //
A bemenetek átlaga
```

```
        printf("Bemenet: [%.2f, %.2f], Várt (átlag): %.2f, Kimenet: %.4f\n",  
               test_inputs[i][0], test_inputs[i][1], expected, output[0]);  
    }  
  
    return 0;  
}
```

## Generatív nyelvi modellek

A generatív nyelvi modellek az emberi nyelv megértésére és szöveg generálására irányuló kutatások központi elemei. Ezek a modellek arra képesek, hogy a bemenetként adott szöveg alapján értelmes és összefüggő szöveget állítsanak elő. Az alábbiakban bemutatjuk a generatív nyelvi modellek fejlődését, amely a GPT (Generative Pre-trained Transformer) családkhoz vezetett.

### 1.) Hagyományos megközelítések (1950-2000-es évek)

- **Statikus modellek:** A nyelv feldolgozásához egyszerű szabályalapú rendszereket (pl. grammatikai szabályok) használtak.
- **Markov-láncok:** Egy szó valószínűségét csak az előző szavak határozták meg, így a kontextus figyelembevétele korlátozott volt.

Hiányosságok: A modellek nem tudták kezelni a hosszabb távú összefüggéseket. Az adatok mennyisége és feldolgozási kapacitás limitált volt.

### 2.) Neurális hálózatok alkalmazása (2010 körül)

**Word Embeddingek: Word2Vec (2013):** Az egyes szavak vektortérbeli reprezentációját hozta létre, amely tükrözi a szemantikai kapcsolataikat (king - man + woman  $\approx$  queen).

**Recurrent Neural Networks (RNNs)** Az RNN-ek a szekvenciális adatok feldolgozására készültek. Például egy szó vektora a korábbi szavak kontextusán alapult.

Hiányosságok: Lassúak és nehezen tanulhatók nagy mennyiségű adat esetén. Nem tudtak hatékonyan kezelni nagyon hosszú szövegeket.

### 3.) Attention Mechanizmus és Transformer (2017)

**Attention Mechanizmus:** A figyelem-alapú modellek a bemenetek bizonyos részeire nagyobb súlyt helyeztek, ezáltal hatékonyabbá tették az összefüggések felismerését.

**Transformer Architektúra (2017):** Az „Attention is All You Need” című cikkben a Google kutatói bevezették a Transformer modellt. Kulcseleme az önfigyelem (self-attention), amely lehetővé tette, hogy a modell párhuzamosan dolgozza fel az adatokat, szemben az RNN-ek szekvenciális feldolgozásával.

Előnyök: Jobb skálázódás nagyobb adathalmazokon. Hatékony hosszú szövegek feldolgozása.

#### 4. Generatív Pre-Trained Modellek (GPT család)

**GPT-1 (2018):** Az első modell, amely a Transformer architektúrát alkalmazta nagyméretű nyelvi korpuszokon.

**GPT-2 (2019):** Nagyobb és erősebb modell, amely képes volt teljes cikkeket generálni emberi beavatkozás nélkül.

**GPT-3 (2022):** Egy óriási ugrás: 175 milliárd paraméter.

**GPT-4 (2023):** Még fejlettebb modell, több multimodális képességgel (pl. szöveg és kép feldolgozása).

Számlafeldolgozó minta bemutatása.

#### Neurális hálózatok, felmerülő kérdések

1. Magyarázható-e a működése? (a súlyok alapján érthető-e a döntés?)
2. Van-e itt intelligencia egyáltalán?

## Ellenőrző kérdések

#### Mi a neurális hálózatok alapvető építőeleme?

- A) Node
- B) Neuron
- C) Hurok
- D) Adatbázis

Megoldás: B

#### Milyen műveleteket végez egy neuron alapvetően?

- A) Csak adatot tárol
- B) Memóriát kezel
- C) Súlyozott összegzést és aktivációt végez
- D) Csak véletlenszerű értékeket generál

Megoldás: C

#### Mi a tipikus célja a neurális hálózatok tanításának?

- A) A bemenet másolása a kimenetre változtatás nélkül
- B) Az adatokban található mintázatok megtanulása és általánosítása
- C) Minél több neuron használata
- D) A memóriahasználat csökkentése

Megoldás: B

---

### **Miért alkalmazunk aktivációs függvényeket a neurális hálózatokban?**

- A) Csak esztétikai okokból
- B) Azért, hogy lineáris problémákat oldjunk meg
- C) A hálózat nemlinearitásának biztosítására
- D) A bemenet normalizálására

Megoldás: C

---

### **Mi az alábbiak közül egy közismert aktivációs függvény?**

- A) XOR
- B) NAND
- C) Sigmoid
- D) AND

Megoldás: C

---

### **Hogyan nevezzük azt a folyamatot, amikor a hibát visszafelé terjesztjük a hálózaton a tanítás során?**

- A) Feedforward
- B) Backpropagation
- C) Regularizáció
- D) Dropout

Megoldás: B

---

### **Mi az "epoch" fogalma neurális háló tanítása során?**

- A) Egyetlen neuron frissítése
- B) Egy súlyfrissítés lépése
- C) A teljes tanító adathalmaz egyszeri áthaladása
- D) A tanítás sebessége

Megoldás: C

---

**Mi a célja a tanulási rátának (learning rate)?**

- A) Meghatározza, hogy a háló hány rétegből álljon
- B) Meghatározza, hogy mennyire gyorsan tanuljon a hálózat (a súlyok frissítésének mértéke)
- C) Megadja, hány neuron legyen egy rétegben
- D) Meghatározza a tanítás során használt neuronok számát

Megoldás: B

---

**Mi a "túlillesztés" (overfitting) jelensége neurális hálók esetén?**

- A) A hálózat nem tanul eleget az adatokból
- B) A hálózat túl általános megoldást ad
- C) A hálózat túl jól illeszkedik a tanuló adathalmazra, de nem jól általánosít
- D) A hálózat nem tudja kezelni a bemeneteket

Megoldás: C

---

**Mi lehet egy jó módszer a túlillesztés csökkentésére?**

- A) Több réteg hozzáadása
- B) Nagyobb neuronok számának használata
- C) Dropout vagy regularizáció alkalmazása
- D) Tanítási adatok csökkentése

Megoldás: C

---

**Mi a felügyelt tanulás (supervised learning) jelentése?**

- A) A neurális háló saját maga fedezi fel a mintázatokat
- B) Az adatok mellé címkéket (helyes válaszokat) is adunk a tanításhoz
- C) A hálózat nem kap visszajelzést a tanulás során
- D) Véletlenszerű tanítási módszer használata

Megoldás: B

---

**Mi igaz a „feedforward” folyamatra egy neurális hálóban?**

- A) A bemenetet visszafelé dolgozza fel
- B) A bemenetet a kimenet felé haladva dolgozza fel a háló
- C) Csak hibaszámításra alkalmas
- D) A súlyok módosítására használjuk

Megoldás: B

---

### Mi történik egy neurális háló tanításakor, ha túl nagy a learning rate?

- A) A tanulás gyorsabb és stabilabb lesz
- B) A hálózat túl lassan tanul
- C) A tanítás instabillá válhat, és nem konvergál optimálisan
- D) A neurális háló egyáltalán nem tanul

Megoldás: C

From:

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

Permanent link:

[https://edu.iit.uni-miskolc.hu/muszaki\\_informatika:neuralis\\_halok\\_alapjai](https://edu.iit.uni-miskolc.hu/muszaki_informatika:neuralis_halok_alapjai)

Last update: **2025/03/13 22:57**

