

# NN\_skomam4

January 25, 2023

Neuronové sítě

... jako složené funkce s parametry

Jan Kracík

ŠKOMAM 2023

---

## 1 Úvod

(ChatGPT 19.1.2023)



Co je to neuronová síť?



Neuronová síť je typ počítačového modelu, který se inspiroval stavebním principem lidského mozku. Skládá se z vrstvy neuronů (matematických jednotek), které spolu komunikují a učí se na základě tréninku dat. Neuronové sítě se často používají k úlohám, jako je rozpoznávání obrazů, překlad jazyka a predikce budoucích událostí.



Aha, tak nic ...

---

```
[1]: import numpy as np
from matplotlib import pyplot as plt
from matplotlib import cm

import ipywidgets as widgets
from ipywidgets import interact

#from mpl_toolkits.mplot3d import Axes3D
```

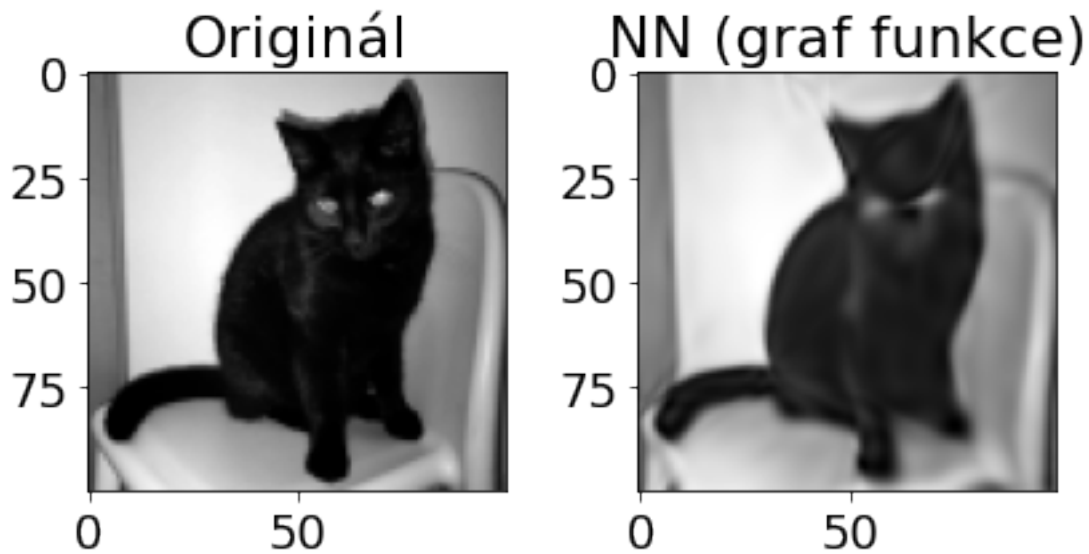
```
%matplotlib inline
```

```
[2]: import matplotlib
```

```
font = {'size' : 18}  
matplotlib.rc('font', **font)
```

```
FS = (6, 6)
```

```
[3]: jerryMLP = np.load('jerryMLP.npy')  
jerryIMG = np.load('jerryIMG.npy')  
plt.subplot(121)  
plt.imshow(jerryIMG, cmap=cm.gray)  
plt.title("Originál")  
plt.subplot(122)  
plt.imshow(jerryMLP, cmap=cm.gray)  
plt.title("NN (graf funkce)")  
plt.tight_layout();
```



```
[ ]:
```

## 2 Funkce jedné proměnné

Z učebnice Matematika pro gymnázia:

Funkce ( $f : A \rightarrow \mathbb{R}$ ) na množině  $A \subset \mathbb{R}$  je předpis, který každému číslu z množiny  $A$  přiřazuje


právě jedno reálné číslo. Množina  $A$  se nazývá definiční obor funkce.

---

Příklad (lineární funkce)  $f : \mathbb{R} \rightarrow \mathbb{R}$

$$f(x) := 2x - 4$$

```
[4]: xs = np.linspace(-5, 5, 100)
plt.figure(figsize=FS)
plt.plot(xs, 2*xs-4)
plt.xlabel("$x$")
plt.ylabel("$f(x)$")
plt.title("$f(x)=2x-4$")
plt.tight_layout();
```




---

Příklad (exponenciální funkce)  $f : \mathbb{R} \rightarrow \mathbb{R}$

$$f(x) := e^x$$

```
[5]: xs = np.linspace(-5, 5, 100)
plt.figure(figsize=FS)
plt.plot(xs, np.exp(-xs))
plt.xlabel("$x$")
plt.ylabel("$f(x)$")
plt.title("$f(x)=e^{-x}$");
plt.tight_layout();
```




Příklad (logistická funkce)  $\sigma : \mathbb{R} \rightarrow \mathbb{R}$

$$\sigma(x) := \frac{1}{1 + e^{-x}}$$

```
[6]: def sigma(x):  
      return 1/(1+np.exp(-x))
```

```
[7]: xs = np.linspace(-10, 10, 400)  
plt.figure(figsize=FS)  
plt.plot(xs, sigma(xs))  
plt.xlabel("$x$")  
plt.ylabel("$\sigma(x)$")  
plt.title("$\sigma(x)$");  
plt.tight_layout();
```



```
[8]: sigma(-10), sigma(0), sigma(10)
```


```
[8]: (4.5397868702434395e-05, 0.5, 0.9999546021312976)
```

---

Příklad (program jako funkce)

```
[9]: def nejaka_funkce(x):  
    if x<0:  
        vysledek = 0  
  
    if x>=0 and x<=1:  
        v = x  
        for n in range(10):  
            v = 4*v*(1-v)  
        vysledek = v  
  
    if x>1:  
        vysledek = 0  
  
    return vysledek
```

```
[10]: xs = np.linspace(-0.5, 1.5, 400)  
plt.figure(figsize=FS)  
ys = np.array([nejaka_funkce(x) for x in xs])  
plt.plot(xs, ys)  
plt.tight_layout();
```



[ ]:

### 3 Kartézský součin

Nechť  $M, N$  jsou libovolné množiny. Kartézský součin  $M \times N$  je množina všech uspořádaných dvojic  $(m, n)$ , kde  $m \in M$  a  $n \in N$ . Tj.

$$M \times N := \{(m, n) | m \in M, n \in N\}.$$

---

Příklad

$$M = \{a, b, c\}$$

$$N = \{K, L\}$$

$$M \times N = \{(a, K), (a, L), (b, K), (b, L), (c, K), (c, L)\}$$

---

Příklad

$$\mathbb{R}^2 := \mathbb{R} \times \mathbb{R} = \{(x_1, x_2) | x_1 \in \mathbb{R}, x_2 \in \mathbb{R}\}$$

Obdobně pro libovolné  $n \in \mathbb{N}$

$$\mathbb{R}^n := \mathbb{R} \times \mathbb{R} \times \dots \times \mathbb{R} = \{(x_1, x_2, \dots, x_n) | x_1 \in \mathbb{R}, x_2 \in \mathbb{R}, \dots, x_n \in \mathbb{R}\}$$

[ ]:

## 4 Funkce více proměnných

Funkce ( $f : M \rightarrow N$ ) na množině  $M$  s hodnotami v množině  $N$  je předpis, který každému prvku z množiny  $M$  přiřazuje právě jeden prvek z množiny  $N$ .

---

Příklad (lineární funkce)


$$f : \mathbb{R}^2 \rightarrow \mathbb{R},$$

$$f(x_1, x_2) := x_1 + x_2$$

```
[11]: # graf jako projekce
%matplotlib inline
x1s = np.linspace(-20, 20, 100)
x2s = np.linspace(-20, 20, 100)


x1g, x2g = np.meshgrid(x1s, x2s)
yg = x1g+x2g-5
fig, ax = plt.subplots(figsize=FS, subplot_kw={"projection": "3d"})
surf = ax.plot_surface(x1g, x2g, yg, cmap=cm.gray)
fig.colorbar(surf)
ax.set_xlabel('$x_1$')
ax.set_ylabel('$x_2$')
ax.set_zlabel('$f(x_1, x_2)$');
```





```
[12]: # graf jako barevna mapa
      %matplotlib inline
      plt.figure(figsize=FS)
      cp = plt.contourf(x1g, x2g, yg, cmap=cm.gray, levels=100)
      plt.xlabel('$x_1$')
      plt.ylabel('$x_2$')
      plt.tight_layout()
      plt.colorbar(cp)
```

```
[12]: <matplotlib.colorbar.Colorbar at 0x7fe89bbe34f0>
```



[ ]:

\_\_\_\_\_  
 Příklad (lineární funkce)

$$f : \mathbb{R}^3 \rightarrow \mathbb{R}^2,$$

$$f(x_1, x_2, x_3) := (x_1 + x_2, x_2 - x_3)$$

[ ]:

## 5 Funkce s parametry

Příklad (lineární funkce s parametry  $a, b \in \mathbb{R}$ )

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

$$f(x) := ax + b$$

Funkci  $f$  lze chápat jako

$$F : \mathbb{R}^2 \times \mathbb{R} \rightarrow \mathbb{R},$$

$$F((a, b), x) := ax + b$$

---

Funkci s parametrem z množiny  $P$  definovanou na množině  $M$  s hodnotami v množině  $N$  lze chápat jako

$$F : P \times M \rightarrow N.$$

Pro zvolené  $p \in P$  definujme

$$F_p : M \rightarrow N,$$

$$F_p(x) := F(p, x).$$

---

Příklad (lineární funkce s parametry  $a, b \in \mathbb{R}$ )

$$F : \mathbb{R}^2 \times \mathbb{R} \rightarrow \mathbb{R},$$

$$F((a, b), x) := ax + b$$

```
[13]: %matplotlib inline
      #matplotlib qt
      def F(a, b, x):
          return a*x+b

      fig = plt.figure(figsize=FS)
      ax = fig.add_subplot(111)
      xs = np.linspace(-10, 10, 200)
      c, = ax.plot(xs, F(1, 1, xs))
```

```

plt.xlabel('$x$')
plt.ylabel('$F_{(a, b)}(x)$')

@interact(a=(-2, 2, 0.01), b=(-5, 5, 0.01))
def plot_F(a=1, b=0):
    ys = F(a, b, xs)
    c.set_ydata(ys)
    plt.pause(0.1)
    plt.draw()

plot_F()

```

```

interactive(children=(FloatSlider(value=1.0, description='a', max=2.0, min=-2.0,
↳step=0.01), FloatSlider(value=...

```

<Figure size 432x288 with 0 Axes>

<Figure size 432x288 with 0 Axes>

[ ]:

## 6 Skládání funkcí

Uvažujme funkce

$$f : M \rightarrow N,$$

$$g : N \rightarrow Q.$$

Složenou funkcí  $g \circ f$  rozumíme funkci

$$g \circ f : M \rightarrow Q,$$

$$g \circ f(x) := g(f(x)).$$

Příklad (složená funkce s parametry)

$$f_{(a,b)} : \mathbb{R} \rightarrow \mathbb{R},$$

$$f_{(a,b)}(x) := ax + b,$$

$$(a, b) \in \mathbb{R}^2.$$

$$\sigma : \mathbb{R} \rightarrow \mathbb{R},$$

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

$$F_{(a,b)} := \sigma \circ f_{(a,b)} : \mathbb{R} \rightarrow \mathbb{R},$$

$$F_{(a,b)}(x) = \frac{1}{1 + e^{-(ax+b)}}$$

```
[14]: %matplotlib inline
      #matplotlib qt

      def F(a, b, x):
          return a*x+b

      fig = plt.figure(figsize=FS)
      ax = fig.add_subplot(111)
      xs = np.linspace(-20, 20, 200)
      #d, = ax.plot(xs, (F(1, 1, xs)))
      #ax.twinx()
      c, = ax.plot(xs, sigma(F(1, 1, xs)))

      plt.xlabel('$x$')
      plt.ylabel('$F_{(a, b)}(x)$')

      @interact(a=(-10, 10, 0.01), b=(-100, 100, 0.01))
      def plot_F(a=1, b=0):
          ds = F(a, b, xs)
          cs = sigma(ds)
          c.set_ydata(cs)
          #d.set_ydata(ds)
          plt.pause(0.1)
          plt.draw()

      plot_F()
```

```
interactive(children=(FloatSlider(value=1.0, description='a', max=10.0, min=-10.
↵0, step=0.01), FloatSlider(val...
```

```
<Figure size 432x288 with 0 Axes>
```

<Figure size 432x288 with 0 Axes>

[ ]:

## 7 Skládání funkcí více proměnných

---

Uvažujme funkce

$$\begin{aligned} f_1 &: M \rightarrow Q, \\ f_2 &: M \rightarrow Q, \\ &\vdots \\ f_n &: M \rightarrow Q, \end{aligned}$$

$$g : Q \times Q \times \cdots \times Q \rightarrow N.$$

Složenou funkcí  $g \circ (f_1, f_2, \dots, f_n)$  rozumíme funkci

$$g \circ (f_1, f_2, \dots, f_n) : M \rightarrow N,$$

$$g \circ (f_1, f_2, \dots, f_n)(x) := g(f_1(x), f_2(x), \dots, f_n(x)).$$

---

Příklad (složená funkce více proměnných s parametry)

$$\begin{aligned} f_{(a_1, b_1)} &: \mathbb{R} \rightarrow \mathbb{R}, \\ f_{(a_1, b_1)}(x) &:= \sigma(a_1 x + b_1) \end{aligned}$$

$$\begin{aligned} g_{(a_2, b_2)} &: \mathbb{R} \rightarrow \mathbb{R}, \\ g_{(a_2, b_2)}(x) &:= \sigma(a_2 x + b_2) \end{aligned}$$

$$\begin{aligned} h &: \mathbb{R}^2 \rightarrow \mathbb{R}, \\ h_{(p_1, p_2, q)}(x_1, x_2) &:= \sigma(p_1 x_1 + p_2 x_2 + q) \end{aligned}$$

$$\begin{aligned} F_{(a_1, b_1, a_2, b_2, p_1, p_2, q)} &:= h_{(p_1, p_2, q)} \circ (f_{(a_1, b_1)}, g_{(a_2, b_2)}) : \mathbb{R} \rightarrow \mathbb{R}, \\ F_{(a_1, b_1, a_2, b_2, p_1, p_2, q)}(x) &= \sigma(p_1 \sigma(a_1 x + b_1) + p_2 \sigma(a_2 x + b_2) + q) \end{aligned}$$

Funkce  $F_{(a_1, b_1, a_2, b_2, p_1, p_2, q)}$  představuje jednoduchou neuronovou síť (perceptron s jednou skrytou vrstvou obsahující 2 neurony).

```
[15]: %matplotlib inline
      #matplotlib qt
      def F(a1, b1, a2, b2, p1, p2, q, x):
          s1 = sigma(a1*x+b1)
          s2 = sigma(a2*x+b2)
          return sigma(p1*s1+p2*s2+q)

      fig = plt.figure(figsize=FS)
      ax = fig.add_subplot(111)
      xs = np.linspace(-20, 20, 200)
      #d, = ax.plot(xs, (F(1, 1, xs)))
      #ax.twinx()
      c, = ax.plot(xs, F(1, 0, -1, 0, 1, 1, 0, xs))
      plt.ylim(0, 1)
      plt.xlabel('$x$')
      plt.ylabel('$F_{(\cdots)}(x)$')

      @interact(a1=(-10, 10, 0.01), b1=(-10, 10, 0.01),
                a2=(-10, 10, 0.01), b2=(-10, 10, 0.01),
                p1=(-10, 10, 0.01), p2=(-10, 10, 0.01), q=(-10, 10, 0.01))

      def plot_F(a1=-8, b1=-6, a2=1.6, b2=-8.3, p1=-1.25, p2=-2.5, q=0.7):
          #def plot_F(a1=1, b1=0, a2=-1, b2=0, p1=1, p2=1, q=0):
              cs = F(a1, b1, a2, b2, p1, p2, q, xs)
              c.set_ydata(cs)
              #d.set_ydata(ds)
              plt.pause(0.1)
              plt.draw()

      plot_F()
```

```
interactive(children=(FloatSlider(value=-8.0, description='a1', max=10.0,
    ↪min=-10.0, step=0.01), FloatSlider(v...
```

<Figure size 432x288 with 0 Axes>

<Figure size 432x288 with 0 Axes>

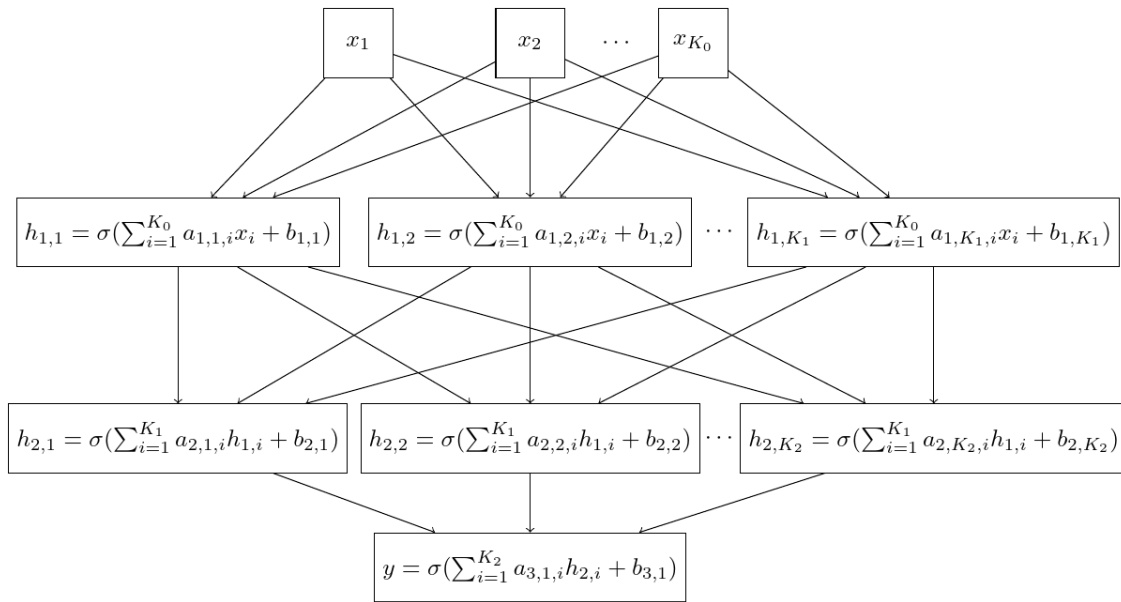
## 8 Umělé neuronové sítě

Umělé neuronové sítě lze chápat jako parametrické funkce

$$F : P \times M \rightarrow N,$$

$P$  ··· množina parametrů,

$M \dots$  množina vstupních hodnot,  
 $N \dots$  množina výstupních hodnot.



[ ]:

## 8.1 Učení neuronové sítě

Učení neuronové sítě spočívá v nalezení vhodného parametru  $\hat{p} \in P$  tak aby  $F_{\hat{p}}$  byla “ve shodě” s trénovacími daty.

- Trénovací data: zadané dvojice

$$(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n) \in M \times N$$

- Ztrátová funkce (udává kvalitu aproximace dat):

$$L : P \times (M \times N)^n \rightarrow \mathbb{R}$$

Např. kvadratická ztrátová funkce:

$$L(p, (X_1, Y_1), \dots, (X_n, Y_n)) := \sum_{i=1}^n (Y_i - F_p(X_i))^2$$

- Hledáme parametr  $\hat{p} \in P$  tak, aby pro každé  $p \in P$  platilo

$$L(\hat{p}, (X_1, Y_1), \dots, (X_n, Y_n)) \leq L(p, (X_1, Y_1), \dots, (X_n, Y_n)).$$

- Místo optimální hodnoty  $\hat{p} \in P$  se zpravidla spokojíme s vhodnou aproximací



## 8.2 Použití naučené neuronové sítě

- $x$  ... nová vstupní hodnota
- $y := F_{\hat{p}}(x)$  ... hodnota predikovaná naučenou neuronovou sítí

[ ]: