

# Neuronové sítě

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

# Neuronové sítě

**– Vrstevnaté neuronové sítě –  
– analýza vlastností –**

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

# Kolmogorovova věta - 1957

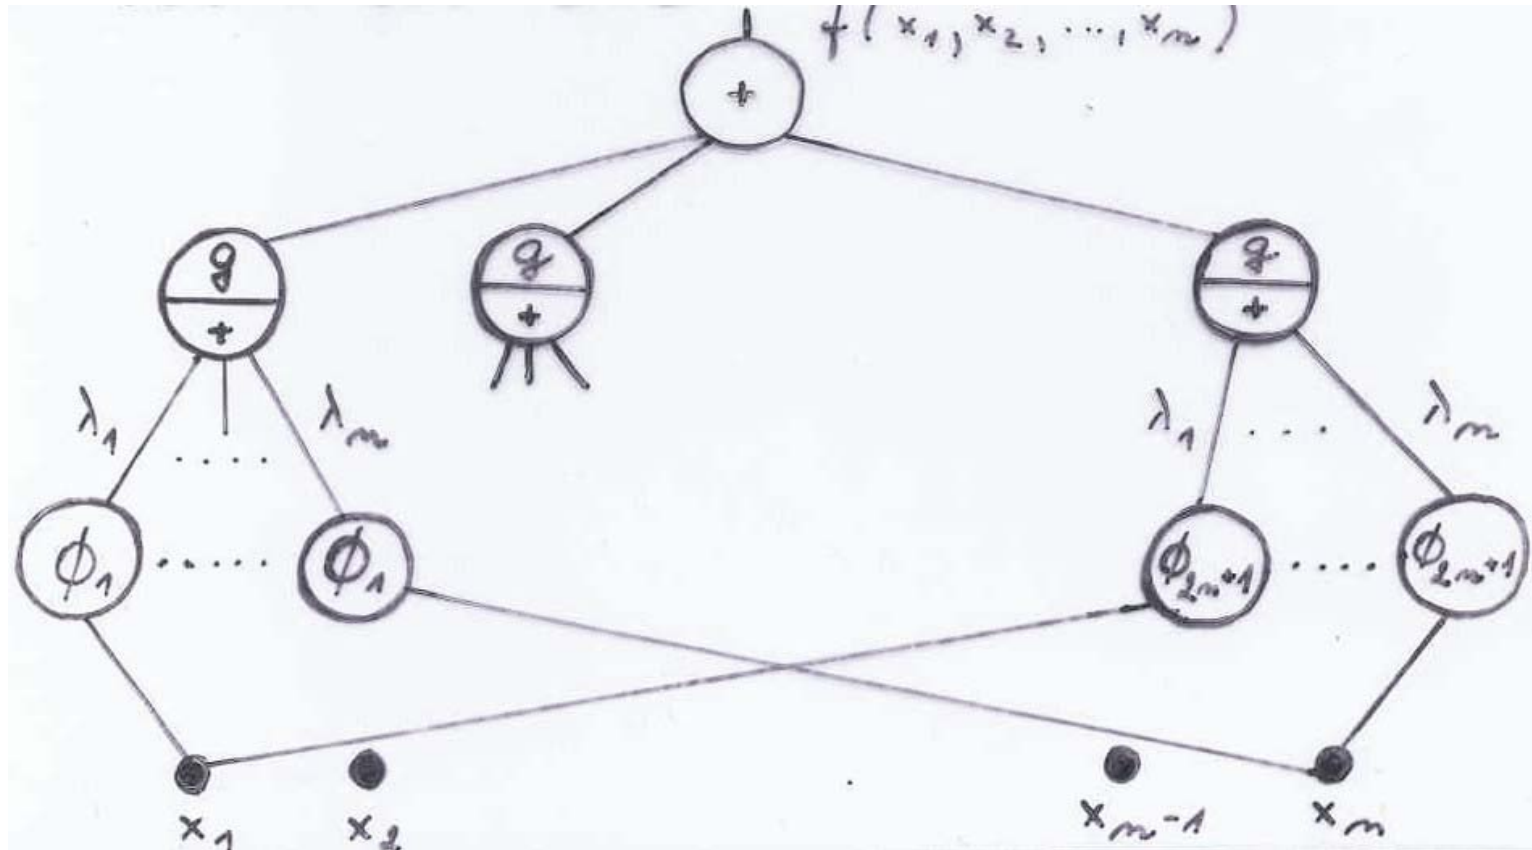
13. Hilbertův problém ~ spojité funkce  $n$  proměnných lze vyjádřit pomocí konečného počtu funkcí jediné proměnné a sčítání

■ Příklad:  $x \cdot y = \exp(\ln x + \ln y)$

V: Necht'  $f: [0, 1]^n \rightarrow [0, 1]$  je spojitá funkce. Potom existují funkce jediné proměnné  $g$  a  $\Phi_q$ , pro  $q = 1, \dots, 2n+1$  a konstanty  $\lambda_p$ , pro  $p = 1, \dots, n$  takové, že

$$f(x_1, \dots, x_n) = \sum_{q=1}^{2n+1} g \left( \sum_{p=1}^n \lambda_p \Phi_q(x_p) \right)$$

# Kolmogorovovy sítě



# Aproximace funkcí (1)

- ◆ Libovolnou spojitou funkci lze vyjádřit pomocí sítě s odpovídajícím počtem výpočetních jednotek (× volba vhodné přenosové funkce)
- ◆ Nejlepší možná aproximace dané funkce (× volba vhodného počtu výpočetních jednotek s uvažovanou přenosovou funkcí)

# Aproximace funkcí (2)

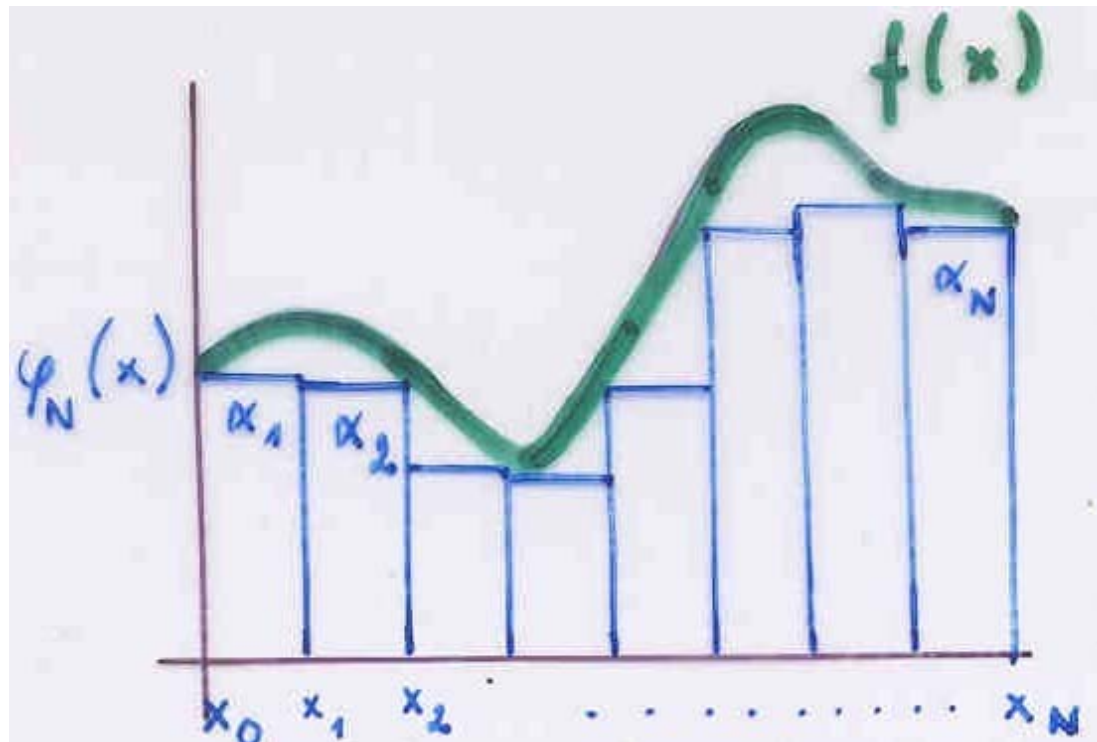
**V:** Spojitou reálnou funkci  $f: [0, 1] \rightarrow [0, 1]$  lze aproximovat pomocí sítě prahových jednotek tak, že celková aproximační chyba  $E$  je menší než libovolné reálné číslo  $\varepsilon > 0$ :

$$E = \int_0^1 |f(x) - \tilde{f}(x)| dx < \varepsilon$$

kde  $\tilde{f}$  označuje funkci realizovanou sítí prahových jednotek.

# Aproximace funkcí (3)

Důkaz: Idea ~ aproximace  $f$  pomocí  $\varphi_N$



# Aproximace funkcí (4)

Důkaz (pokračování):

- ◆ Rozdělme interval  $[0, 1]$  do  $N$  stejně velkých podintervalů pomocí bodů  $x_0, x_1, \dots, x_N \in [0, 1]$ ;  $x_0 = 0, x_N = 1$

- ◆ Funkci  $\varphi_N$  definujme jako:

$$\varphi_N(x) = \min \{ f(x'); x' \in [x_i, x_{i+1}] \text{ pro } x_i \leq x \leq x_{i+1} \}$$

- ◆ Dále necht' funkce  $\varphi_N$  aproximuje funkci  $f$  tak, že aproximační chyba  $E_N$  odpovídá:

$$E_N = \int_0^1 | f(x) - \varphi_N(x) | dx$$



# Aproximace funkcí (5)

Důkaz (pokračování):

- ◆ Protože  $f(x) \geq \varphi_N(x) \quad \forall x \in [0, 1]$ , odpovídá

$$E_N = \int_0^1 f(x) dx - \int_0^1 \varphi_N(x) dx$$

~ dolní součet při výpočtu  
Riemannova integrálu  $f$

- ◆ Spojité funkce lze integrovat  $\rightarrow$  dolní součet konverguje pro  $N \rightarrow \infty$  k integrálu  $f$  na intervalu  $[0, 1]$
- ◆ Platí tedy, že  $E_N \rightarrow 0$  pro  $N \rightarrow \infty$ , a proto pro libovolné reálné  $\varepsilon > 0$  existuje  $M$  takové, že  $E_N < \varepsilon \quad \forall N \geq M$
- ◆ Funkce  $\varphi_N$  je tedy požadovanou aproximací  $f$ .


# Aproximace funkcí (6)

Důkaz (pokračování):

- ◆ Realizace funkce  $\varphi_N(\mathbf{x})$  pomocí sítě prahových jednotek ( $\sim$  neuronová síť)
  - Funkce  $\varphi_N(\mathbf{x})$  je skoková a v každém z  $N$  podintervalů  $[0, 1] : [x_0, x_1), [x_1, x_2), \dots, [x_{N-1}, x_N]$  nabývá odpovídající hodnoty  $\alpha_0, \dots, \alpha_N$

# Aproximace funkcí (7)

Důkaz (pokračování):



# Aproximace funkcí (8)

Důkaz (pokračování):

- ◆ Tato síť je schopna realizovat skokovou funkci  $\varphi_N(\mathbf{x})$ :
  - Jediným vstupem sítě je  $\mathbf{x}$
  - Každá dvojice jednotek s prahem  $x_i$  a  $x_{i+1}$  zaručuje, že jednotka s prahem  $x_i$  bude aktivní pouze pokud  $x_i \leq \mathbf{x} < x_{i+1}$ .
  - Výstupní jednotka sčítá všechny výstupy předchozí vrstvy jednotek a jako výsledek vydá jejich (vážený) součet
  - Jednotka s prahem  $x_N + \delta$ , kde  $\delta$  je malé kladné číslo, slouží k rozpoznání případů  $x_{N-1} \leq \mathbf{x} \leq x_N$ .
- ◆ Tato síť realizuje funkci  $\varphi_N$ , která aproximuje funkci  $f$  nanejvýš s požadovanou chybou. **QED**

# Aproximace funkcí (9)

## Poznámka:

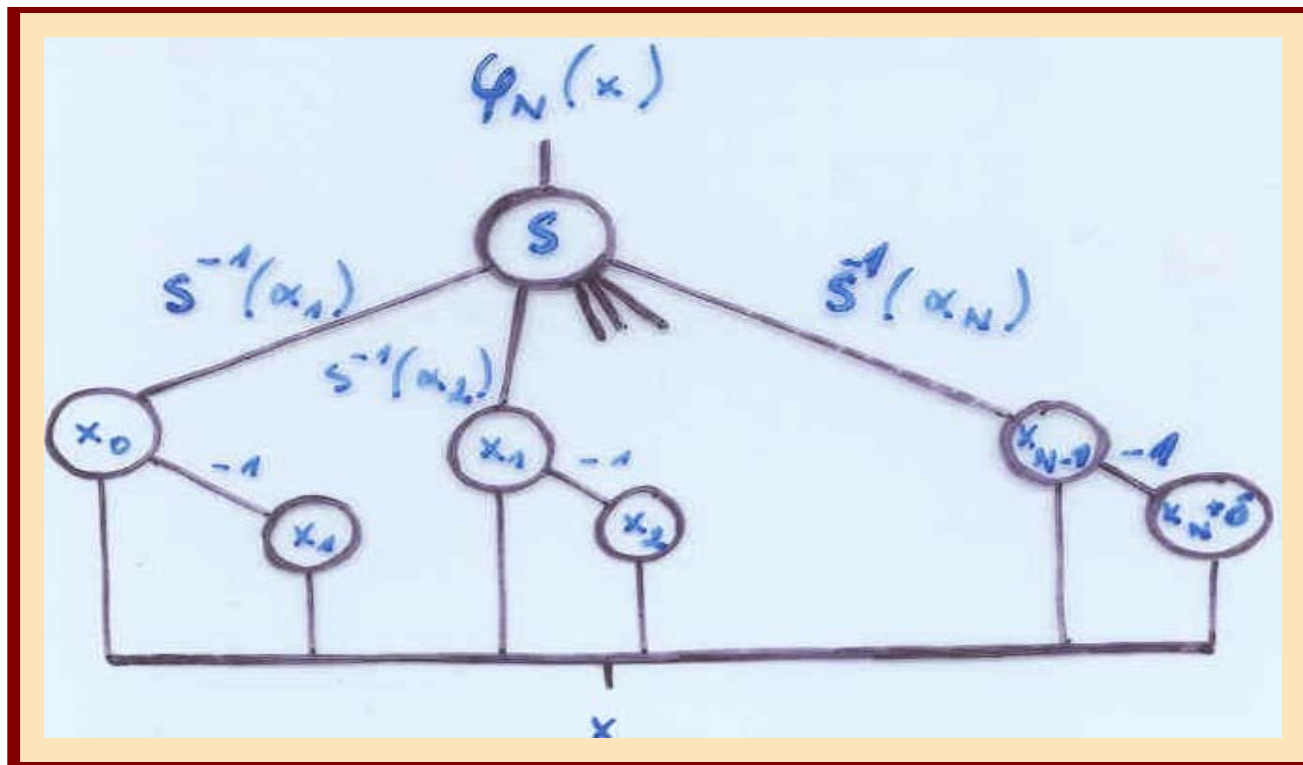
Věta platí i pro jednotky ( $\sim$  neurony) se sigmoidální přenosovou funkcí, kde  $f: [0, 1] \rightarrow (0, 1)$

## Důkaz:

- ◆ Obor hodnot funkce  $f$  je buď omezen na interval  $(0, 1)$
- ◆ Funkci  $f$  lze aproximovat pomocí sítě

# Aproximace funkcí (10)

Důkaz (pokračování):



# Aproximace funkcí (11)

Důkaz (pokračování):

- ◆ Přenosová funkce jednotek s prahem  $x_i$  je dána pomocí  $s_c(x - x_i)$ , kde parametr  $c$  určuje strmost přenosové funkce

$$s_c(x - x_i) = \frac{1}{1 + e^{-c(x - x_i)}}$$

- ◆ Síť realizuje odhad funkce  $\varphi_N$  s takovou aproximační chybou, která je menší než libovolná požadovaná mez ( $> \theta$ )  
(~ prahové funkce lze pomocí parametrizované sigmoidy aproximovat s libovolnou přesností)

# Aproximace funkcí (12)

## Důkaz (pokračování):

- ◆ Váhy (synapsí) mezi první vrstvou jednotek a výstupní jednotkou byly nastaveny tak, že sigmoida bude předávat jako výsledek požadované hodnoty  $\alpha_i$
- ◆ Dále je třeba zaručit, že pro každý vstup  $\mathbf{x}$  bude první vrstva předávat výstupní vrstvě jen jedinou jedničku  
→ první vrstva sítě určí, ke kterému z  $N$  segmentů  $\mathbf{x}$  patří

***QED***



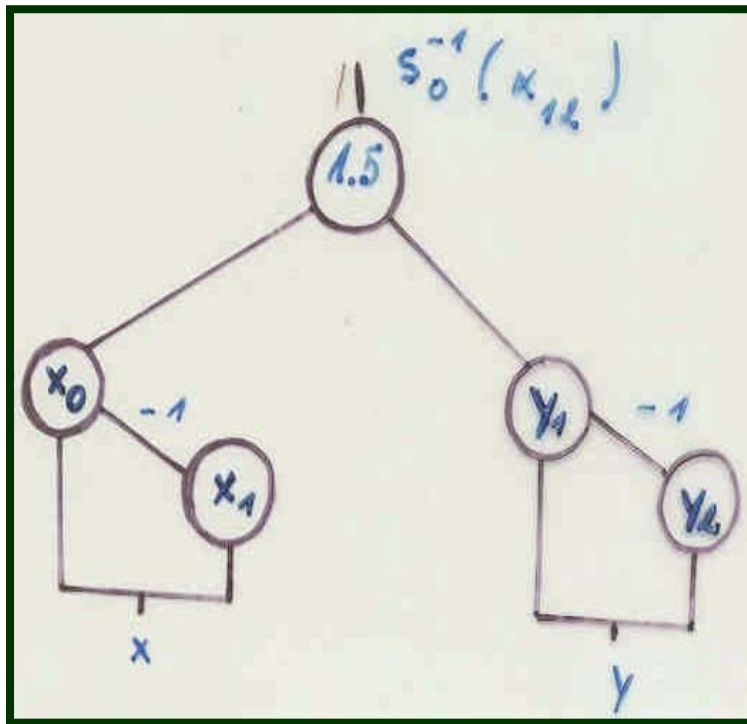
# Aproximace funkcí (13)

## Vícerozměrný případ:

Síť pro aproximaci funkce  $f: [0,1]^n \rightarrow (0,1)$  lze zkonstruovat na základě předchozích myšlenek:

- nutná rozšíření pro dvourozměrný případ
  - Rozpoznání  $x$ -ových i  $y$ -ových „intervalů“
    - 2 jednotky vlevo pro  $x_0 \leq x < x_1$
    - 2 jednotky vlevo pro  $y_0 \leq y < y_1$
  - Jednotka s prahem 1.5 rozpoznává konjunkci obou podmínek ( pro  $x$  a  $y$  )

# Aproximace funkcí (14)



- ◆ „Výstup“ má váhu  $s_0^{-1}(\alpha_{12})$ , takže výstupní jednotka se sigmoidou dává  $\alpha_{12}$
- toto číslo odpovídá požadované aproximaci funkce  $f$  v intervalu:  $[x_0, x_1) \times [y_1, y_2)$

# NP-úplnost problému učení

## Problém splnitelnosti

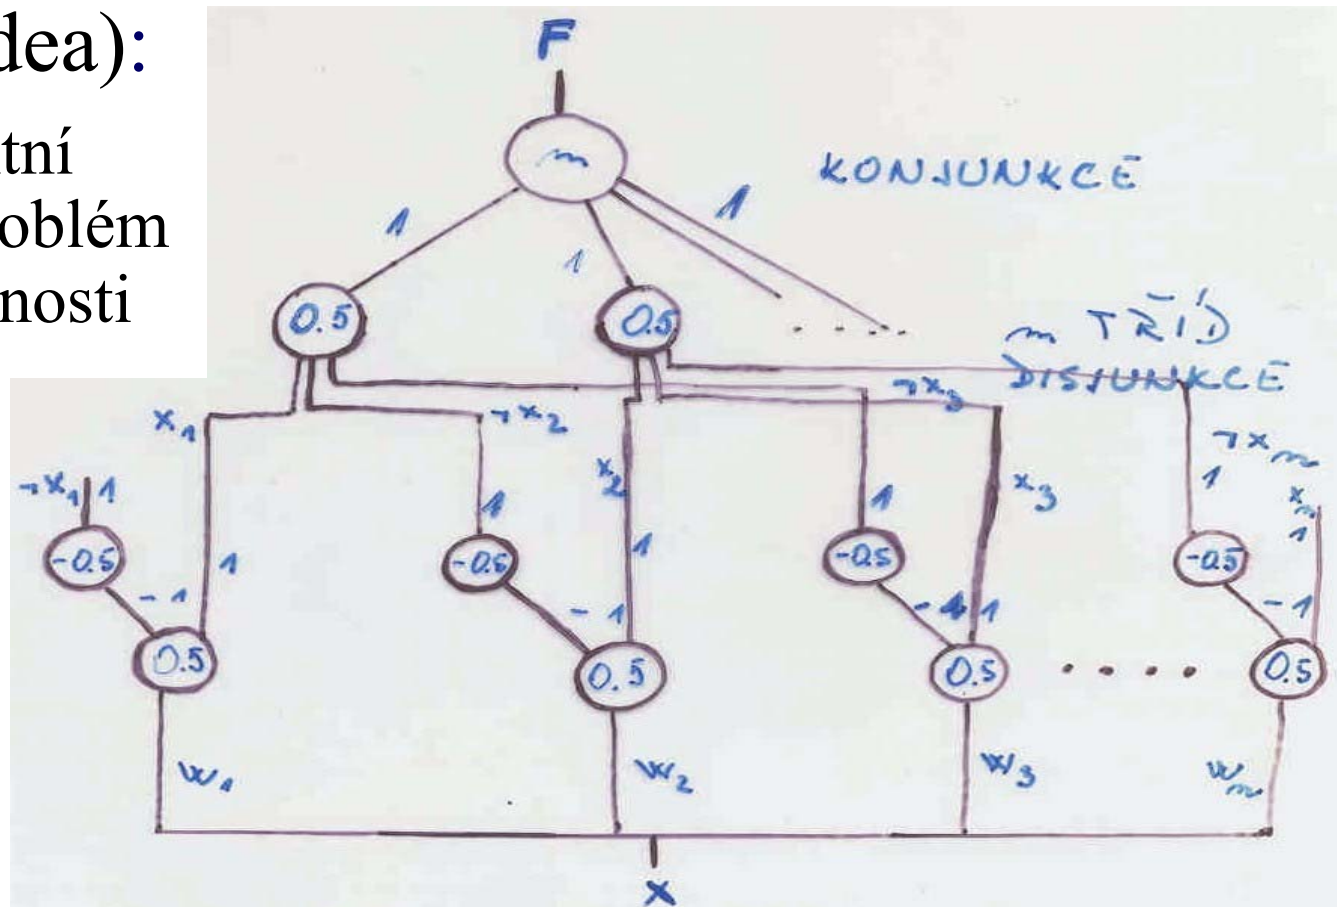
**D:** Necht'  $V$  je množina  $n$  logických proměnných a necht'  $F$  je logická formule v konjunktivní normální formě, která obsahuje jen proměnné z  $V$ . Problém splnitelnosti spočívá v přiřazení pravdivostních hodnot proměnným z  $V$  tak, aby měla formule  $F$  pravdivostní hodnotu *TRUE*.

**V:** Obecný problém učení je pro sítě prahových jednotek NP-úplný.

# NP-úplnost problému učení (2)

Důkaz (idea):

ekvivalentní  
sít' pro problém  
3-splnitelnosti



# NP-úplnost problému učení (3)

## Důkaz (pokračování):

1. 3-splnitelnost logických formulí (3-SAT) lze redukovat (převést) na problém učení neuronových sítí

Logickou formuli  $F$  v konjunktivní normální formě, která obsahuje  $n$  proměnných, lze v polynomiálním čase převést na síť výše uvedeného typu:

- Každé proměnné  $x_i$  je přiřazena váha  $w_i$
- Spoje k výpočetním jednotkám ze třetí vrstvy jsou určeny příslušnou konjunktivní normální formou

# NP-úplnost problému učení (4)

## Důkaz (pokračování):

- Tyto operace lze provést (při vhodném kódování) v polynomiálním čase, protože pro  $m$  různých disjunkcí v 3-SAT-výrazu platí, že  $m \leq (2n)^3$
- Jestliže existuje instance  $A$  s pravdivostními hodnotami proměnných  $x_i$  taková, že  $F$  je splněna, potom existují váhy  $w_1, w_2, \dots, w_n$ , které řeší problém učení

# NP-úplnost problému učení (5)

## Důkaz (pokračování):

- Postačí zvolit váhy  $w_i = 1$ , jestliže  $x_i = 1$ ; a  $w_i = 0$ , jestliže  $x_i = 0$ .  
(V obou případech tedy zvolíme  $w_i = x_i$ .)
- Podobně i opačným způsobem:  
jestliže existují váhy  $w_1, w_2, \dots, w_n$ , které řeší problém učení, potom vede instance  $x_i = 1$  pro  $w_i \geq 0.5$  a  $x_i = 0$  jinak ke splnění  $F$

# NP-úplnost problému učení (6)

## Důkaz (pokračování):

2. Dále je třeba ukázat, že problém učení patří do třídy NP (řešení lze ověřit v polynomiálním čase)
  - Jsou-li dány váhy  $w_1, w_2, \dots, w_n$ , potom lze po jediném „průchodu sítí“ ověřit, zda je její výstup  $F$  roven  $1$
  - Počet výpočetních kroků přímo závisí na počtu proměnných  $n$  a na počtu disjunkcí  $m$  (který je omezen polynomem  $(2n)^3$ )



# NP-úplnost problému učení (7)

## Důkaz (pokračování):

- Čas potřebný k ověření dané („uhodnuté“) instance je tedy omezen polynomem nad  $n$
- Daný problém učení tedy patří do třídy NP

***QED***

## Poznámka:

Pro některé speciální typy jednoduchých neuronových sítí je problém učení řešitelný v polynomiálním čase (pomocí metod lineárního programování)

# Počet oblastí v příznakovém prostoru (1)

- ◆ Kapacita neuronu závisí na dimenzi váhového prostoru a počtu „řezů dělicích nadrovin“

→ **Otázka:**

Kolik oblastí je určeno  $m$  dělicími nadrovinami dimenze  $n - 1$  v  $n$  - rozměrném prostoru?


- přitom budeme uvažovat pouze takové nadroviny, které procházejí počátkem

→ Průnik  $l$  nadrovin ;  $l \leq n$  bude dimenze  $n - l$

# Počet oblastí v příznakovém prostoru (2)

- ◆ 2 – rozměrný případ:


$m$  přímek pocházejících počátkem vytváří nanejvýš  $2 \cdot m$  navzájem různých oblastí



# Počet oblastí v příznakovém prostoru (3)

- ◆ 3 – rozměrný případ:

- každý nový řez zvýší počet oblastí až  $2 \times$



- ◆ obecně:  $n$  řezů  $(n - 1)$  – rozměrnými nadrovinami v  $n$  – rozměrném prostoru vytváří nanejvýš  $2^n$  různých oblastí

# Počet oblastí v příznakovém prostoru (4)

**Věta:** Necht'  $R(m, n)$  označuje počet oblastí určených  $m$  různými dělicími nadrovinami dimenze  $n - 1$  v  $n$  - rozměrném prostoru. Dále necht'  $R(1, n) = 2$  pro  $n \geq 1$  a  $R(m, 0) = 0 \quad \forall m \geq 1$ .

Potom pro  $n \geq 1$  a  $m > 1$ :

$$R(m, n) = R(m - 1, n) + R(m - 1, n - 1)$$

# Počet oblastí v příznakovém prostoru (5)

## Důkaz (indukcí přes $m$ ):

1.  $m = 2$  a  $n = 1$  : Platí, protože

$$R(2, 1) = R(1, 1) + R(1, 0) = 2 + 0 = 2$$

2.  $m = 2$  a  $n \geq 2$  :  $R(2, n) = 4 \Rightarrow$  platí, protože

$$R(2, n) = R(1, n) + R(1, n-1) = 2 + 2 = 4$$

3.  $m + 1$  nadrovin dimenze  $n - 1$  v  $n$ -rozměrném prostoru ( $n \geq 2$ ) :

- Prvních  $m$  nadrovin určuje  $R(m, n)$  oblastí v  $n$  – rozměrném prostoru

# Počet oblastí v příznakovém prostoru (6)

## Důkaz (pokračování):

- $(m + 1)$  - ní nadrovina protíná prvních  $m$  nadrovin v  $m$  nadrovinách dimenze  $n - 2$
- Těchto  $m$  nadrovin (dimenze  $n - 2$ ) rozděljuje  $(n - 1)$  - rozměrný prostor do  $R(m, n - 1)$  oblastí
- Po řezu  $(m+1)$ -ní nadrovinou vzniklo  $R(m, n - 1)$  nových oblastí

→ Nový počet oblastí je tedy:

$$R(m + 1, n) = R(m, n) + R(m, n - 1)$$

***QED***

# Počet oblastí v příznakovém prostoru (7)

- ◆ Možná alternativa výpočtu podle:

$$R(m, n) = 2 \sum_{i=0}^{n-1} \binom{m-1}{i}$$

- × S rostoucím  $n$  roste počet Boolovských funkcí výrazně rychleji než počet různých oblastí vytvořených nadrovinami v obecné poloze
  - tento počet může být obecně větší než počet prahových funkcí nad binárními vstupy



# Počet oblastí v příznakovém prostoru (8)

## Příklad:

$n$	POČET BOOLOVSKÝCH FUNKCÍ ( $2^{2^n}$ )	POČET PRAHOVÝCH FUNKCÍ ( $T(2^n, n)$ )	POČET OBLASTÍ $Z(2^n, n)$
1	4	2	2
2	16	14	14
3	256	104	128
4	65536	1888	3888
5	$4.3 \times 10^9$	94572	412736

# Počet oblastí v příznakovém prostoru (9)

## Důsledek:

**Problémy s učením** ~ je-li počet vstupních vektorů příliš vysoký, nemusí být síť schopna vytvořit s předem daným pevným počtem skrytých neuronů potřebný počet oblastí

- **Zobecňování (generalizace)**

- ~ očekávaný počet správně klasifikovaných vzorů

- **Přeučení**

- ~ chybná interpolace vzorů mimo trénovací množinu

- **Vapnik – Chervonenkisoa dimenze (VC-dimenze)**

- ~ konečná VC-dimenze → „třidu konceptů“ lze naučit

# Vapnik – Chervonenkisova dimenze (VC–dimenze) (1)

**D:** Necht'  $C = \{f_i\}$  je množina funkcí (concept class)

**Množinu**  $m$  trénovacích vzorů  $\{t_k\}_{k=1,\dots,m}$  lze rozčlenit pomocí  $C$ , jestliže pro každé ze  $2^m$  možných označení těchto vzorů  $1/0$ , existuje alespoň jedna funkce  $f_i$ , která tomuto označení vyhovuje.

**D:** VC-dimenze  $V$  množiny funkcí  $C$  je definována jako největší  $m$ , pro které existuje množina  $m$  rozčlenitelných trénovacích vzorů.

# Vapnik – Chervonenkisova dimenze (VC-dimenze) (2)

- ◆ Pokud existuje pro libovolné  $m$  množina  $m$  trénovacích vzorů, které lze rozčlenit pomocí  $C$ , je VC-dimenze  $C$  rovna nekonečnu  
→ Takový problém je „NENAUČITELNÝ“
- ◆ VC-dimenze množiny funkcí obecně nezávisí na počtu parametrů
- ◆ VC-dimenze je důležitá pro správné zobecňování sítí
  - Sít' může mít mnoho parametrů, ale měla by mít malou VC-dimenzi → lepší generalizace
  - Velká VC-dimenze bývá spojena s horší generalizací


# Vapnik – Chervonenkisova dimenze (VC–dimenze) (3)

## Příklad:

1. VC-dimenze množiny lineárních indikačních funkcí

$Q(\vec{z}, \alpha) = \Theta \left\{ \sum_{p=1}^n \alpha_p z_p + \alpha_0 \right\}$  v  $n$  – rozměrném prostoru je rovna  $n + 1$  (tzn. lze rozčlenit nanejvýš  $n + 1$  vzorů)

$n = 2$



# Vapnik – Chervonenkiso dimenze (VC-dimenze) (4)

## 2. VC-dimenze množiny následujících funkcí


$f(z, \alpha) = \theta(\sin \alpha z)$ ,  $\alpha \in \mathbb{R}$  je nekonečná

- Body  $z_1 = 10^{-1}, \dots, z_m = 10^{-m}$  lze rozčlenit pomocí funkcí z této množiny
- K rozčlenění těchto vzorů do dvou tříd (+1/-1) daných posloupností  $\delta_1, \dots, \delta_m$ ;  $\delta_i \in \{0, 1\}$  stačí zvolit hodnotu parametru

$$\alpha = \pi \left( \sum_{i=1}^m (1 - \delta_i) 10^i + 1 \right)$$

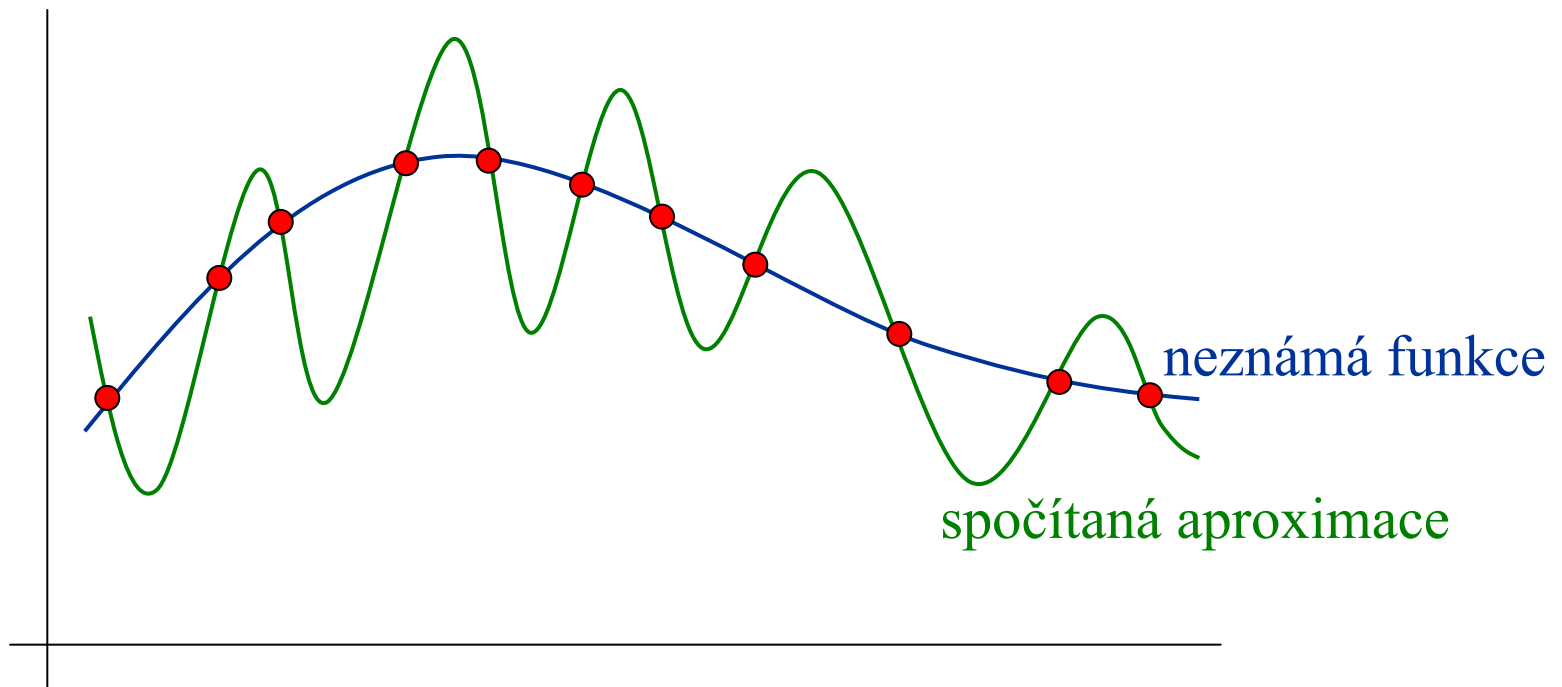
# Vapnik – Chervonenkiso dimenze (VC–dimenze) (5)

- při volbě vhodného koeficientu  $\alpha$  lze pro libovolný počet  $m$  zvolených bodů aproximovat libovolnou funkci omezenou v  $\langle +1 / -1 \rangle$  pomocí  $\sin \alpha z$



# Vapnik – Chervonenkiso dimenze (VC–dimenze) (6)

Problém „přeučení“ ~ síť se naučí i „šum“





# Vapnik – Chervonenkisova dimenze (VC–dimenze) (7)

- ◆ Pro síť s počtem vah  $W$  a počtem neuronů  $N$  a s omezením pro generalizační chybu  $\varepsilon$ , je počet trénovacích vzorů  $P$  potřebných pro správné zobecňování:  $P \geq (W/\varepsilon) \log_2 (N/\varepsilon)$
- ◆ Vrstevnatá síť s  $1$  skrytou vrstvou nemůže dobře zobecňovat, jestliže bylo méně než  $W/\varepsilon$  náhodně vybraných trénovacích vzorů, tj.  $P \geq W/\varepsilon$ 
  - Pro požadovanou přesnost alespoň  $90\%$  je třeba vybrat alespoň  $10 \cdot W$  vzorů