

NEUR II, zimní semestr 2018/2019

Neuronové sítě II
T204, úterý 9.30

Přednášející:

František Hakl (2.10., 16.10., 30.10., 13.11., 11.12., 18.12.)

Martin Holeňa (9.10., 23.10., 6.11., 20.11., 27.11., 4.12.)

Ústav informatiky AV ČR, Pod Vodárenskou věží 2, Praha 8

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Contents

1 Aproximace I. - S-W	3
2 Approximace II. - Konvoluce	10
3 Approximace III. - Duální prostory	19
4 Approximace IV. - Binární neuronové sítě	23
5 Symetrické prahové vektory	32
6 Vapnik-Chervonenkova dimenze	44
7 Odhadý vzorové složitosti PAC modelu učení	59

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

1 Aproximace I. - S-W

- modul spojitosti
- approxinmace v $C_{\langle 0,1 \rangle}$
- Stone-Weierstrass lemma
- approximace v $C_{\bar{K}}$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť $\tilde{f} : \bar{K} \rightarrow \mathbb{R}$, kde $\bar{K} \subset \mathbb{R}^n$ je kompaktní množina. Potom definujeme MODUL SPOJITOSTI jako číslo

$$\omega(\tilde{f}, \delta) \stackrel{\text{def}}{=} \sup_{\substack{\vec{x}, \vec{y} \in \bar{K} \\ \|\vec{x} - \vec{y}\| < \delta}} \left| \tilde{f}(\vec{x}) - \tilde{f}(\vec{y}) \right|.$$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť $\tilde{\sigma} : \mathbb{R} \rightarrow \mathbb{R}$ je spojitá a nechť platí $\lim_{x \rightarrow -\infty} \tilde{\sigma}(x) \rightarrow 0$ a $\lim_{x \rightarrow +\infty} \tilde{\sigma}(x) \rightarrow 1$. Potom pro libovolnou funkci $\tilde{f} \in C_{\langle 0,1 \rangle}$ platí nerovnost

$$\left\| \tilde{f} - \tilde{g}_n \right\|_{\infty} \leq \omega \left(\tilde{f}, \frac{1}{n} \right) \left(4 + 2 \sup_{x \in \mathbb{R}} |\tilde{\sigma}(x)| \right),$$

kde posloupnost funkcí $\{\tilde{q}_n\}_1^{\infty}$ je definována předpisem

$$\tilde{q}_n(x) \stackrel{\text{def}}{=} \tilde{f}(0) + \sum_{v=1}^n \left(\tilde{f}\left(\frac{v}{n}\right) - \tilde{f}\left(\frac{v-1}{n}\right) \right) \tilde{\sigma}(A_n(nx - v)) \quad (1)$$

a pro číselnou posloupnost $\{A_i\}_1^{\infty}$ platí, že A_n je nejmenší kladné celé číslo, pro které platí

$$|\tilde{\sigma}(x)| \leq \frac{1}{n} \quad \text{pro } x \leq -A_n \quad \text{a} \quad 1 - \frac{1}{n} \leq \tilde{\sigma}(x) \leq 1 + \frac{1}{n} \quad \text{pro } x \geq A_n.$$

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
 zimní semestr 2018/2019, KM FJFI ČVUT
 přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení (Stone-Weierstrass). Nechť \bar{K} je kompaktní množina v \mathbb{R}^n a \mathcal{B} je lineární podprostor v prostoru $C_{\bar{K}}$ takový, že obsahuje konstantní nenulovou funkci a v množině \bar{K} odděluje libovolné dva body (t.j. pro libovolné $\vec{x}, \vec{y} \in \bar{K}$, $\vec{x} \neq \vec{y}$ existuje $\tilde{f} \in \mathcal{B}$ tak, že $\tilde{f}(\vec{x}) \neq \tilde{f}(\vec{y})$) a nechť navíc platí, že pro libovolné $\tilde{f}, \tilde{g} \in \mathcal{B}$ je i $\tilde{f} \cdot \tilde{g} \in \mathcal{B}$. Potom \mathcal{B} je hustá v prostoru $C_{\bar{K}}$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Předpokládejme, že \bar{K} je kompaktní podmnožina prostoru \Re^n . Potom lineární obal množiny funkcí $\bar{\Theta} \stackrel{\text{def}}{=} \left\{ \tilde{\rho}(\vec{x}) = e^{\langle \vec{a} | \vec{x} \rangle} \mid \vec{a} \in \Re^n \right\}$ je hustý v prostoru $C_{\bar{K}}$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť \bar{K} je kompaktní podmnožina prostoru \Re^n a nechť $\tilde{\sigma} : \Re \rightarrow \Re$ je spojitá funkce pro kterou platí $\lim_{x \rightarrow -\infty} \tilde{\sigma}(x) \rightarrow 0$ a $\lim_{x \rightarrow +\infty} \tilde{\sigma}(x) \rightarrow 1$. Potom množina funkcí tvaru

$$\tilde{g}(\vec{x}) \stackrel{\text{def}}{=} \sum_{j=1}^k b_j \tilde{\sigma}(\langle \vec{w}_j | \vec{x} \rangle + c_j),$$

je hustá v prostoru $C_{\bar{K}}$, kde $k \in N$, $c_j, b_j \in \Re$, $\vec{w}_j \in \Re^n$, $j \in \{1, \dots, k\}$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

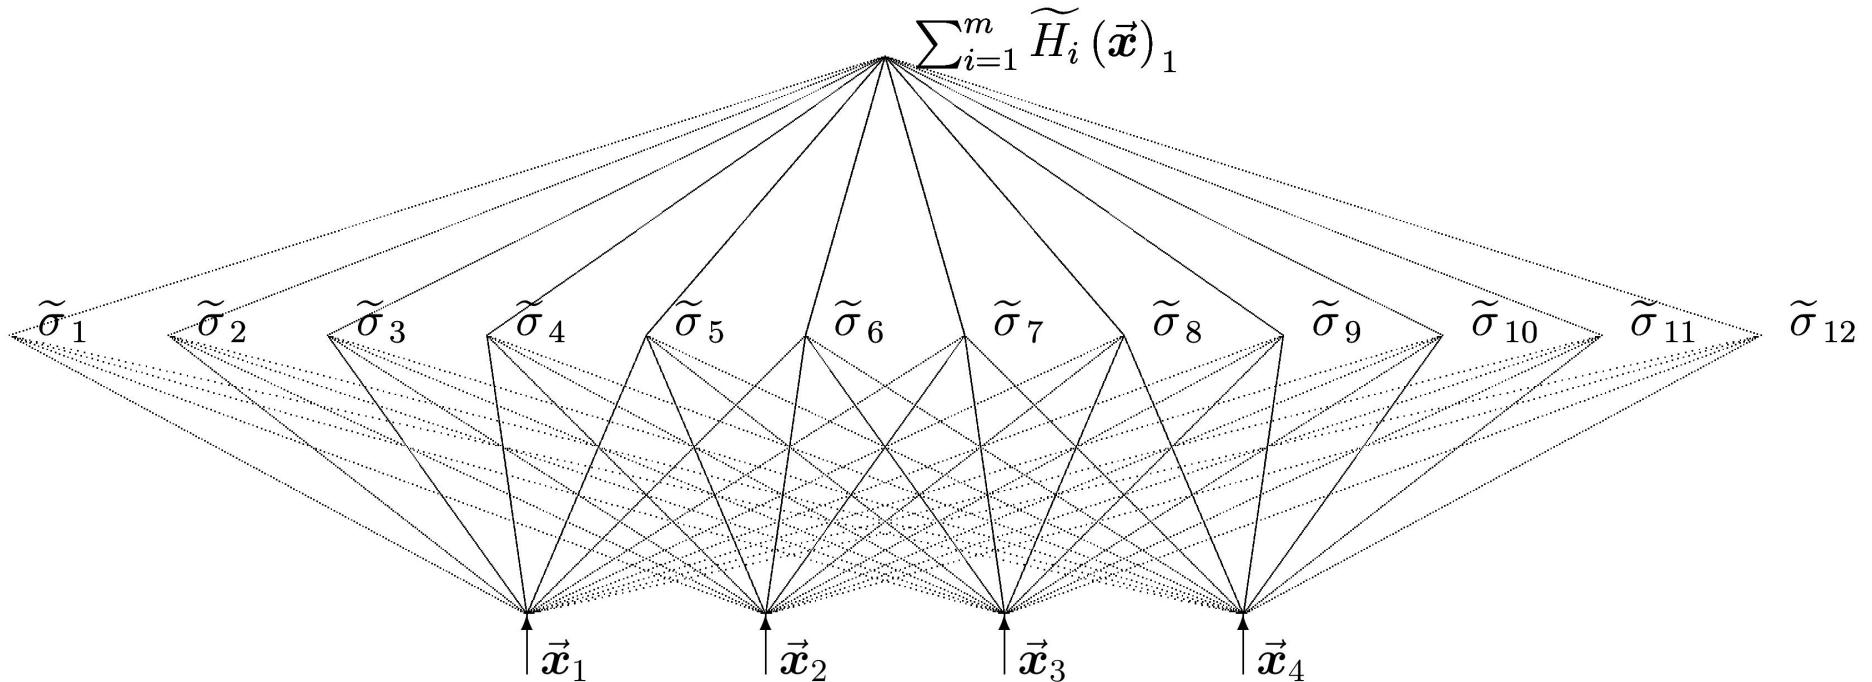


Figure 1: Odpovídající neuronová síť s jednou výpočetní vrstvou.

Prezentace z přednášky Neuronové sítě II.
 zimní semestr 2018/2019, KM FJFI ČVUT
 přednášející: František Hakl, hakl@cs.cas.cz

2 Approximace II. - Konvoluce

- approximace konvolucí
- konvoluční jádro
- volba konvolučního jádra

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Předpokládejme, že \tilde{f} je omezená, stejnoměrně spojitá funkce na \mathbb{R}^n a že pro $\tilde{g} \in \mathcal{L}_1^{\mathbb{R}^n}$ platí $\int_{\mathbb{R}^n} \tilde{g}(\vec{x}) d(\vec{x}) = 1$. Dále definujme funkce $\widetilde{g_m}(\vec{x}) \stackrel{\text{def}}{=} m^n \tilde{g}(m\vec{x})$. Potom platí:

1. $\left(\tilde{f} * \widetilde{g_m} \right) = \int_{\mathbb{R}^n} \tilde{f}(\vec{x} - \vec{t}) \widetilde{g_m}(\vec{t}) d(\vec{t})$ konverguje stejnoměrně k funkci \tilde{f} pro $m \rightarrow \infty$ na \mathbb{R}^n .
2. pro libovolné číslo $R > 0$ platí: $\left\| \left(\tilde{f} * \widetilde{g_m} \right) - \tilde{f} \right\|_{\infty} \leq \omega \left(\tilde{f}, \frac{2R}{m} \right) \|\tilde{g}\|_1 + 2 \left\| \tilde{f} \right\|_{\infty} \int_{\|\vec{s}\| > R} |\tilde{g}(\vec{s})| d\vec{s}$, kde norma $\|.\|_{\infty}$ je brána vzhledem k celému \mathbb{R}^n .
3. Nechť \tilde{f} Lipstichovská s konstantou λ a nechť $M \stackrel{\text{def}}{=} \int_{\mathbb{R}^n} \|\vec{x}\| |\tilde{g}(\vec{x})| d\vec{x} < \infty$. Potom platí odhad $\left\| \left(\tilde{f} * \widetilde{g_m} \right) - \tilde{f} \right\|_{\infty} \leq \frac{M\lambda}{m}$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
 zimní semestr 2018/2019, KM FJFI ČVUT
 přednášející: František Hakl, hakl@cs.cas.cz

Definice. Pro libovolnou spojitou funkci $\tilde{\phi} \in C_{\mathfrak{R}}$ definujme KONVOLUČNÍ JÁDRO jako funkci $\widetilde{G}_{\tilde{\Phi}} : \mathfrak{R}^n \rightarrow \mathfrak{R}$ definovanou předpisem

$$\widetilde{G}_{\tilde{\phi}}(\vec{x}) \stackrel{\text{def}}{=} \frac{1}{\alpha_n} \int_{\|\vec{u}\|=1} \tilde{\phi}(\langle \vec{x} | \vec{u} \rangle) d(\vec{u}), \quad \text{kde } \alpha_n \stackrel{\text{def}}{=} \int_{\|\vec{u}\|=1} d(\vec{u}), \quad (2)$$

(α_n je povrch jednotkové koule v prostoru \mathfrak{R}^n).

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť pro nějaké $a > 0$ je $\bar{K} \stackrel{\text{def}}{=} \langle a, a \rangle^n$ a $\tilde{\phi} \in C_{\mathfrak{R}}$ je stejnoměrně spojitá. Předpokládejme, že $\tilde{G}_{\tilde{\phi}}(\vec{x})$ je definována podle 2. Nechť $\tilde{G}_{\tilde{\phi}}(\cdot) \in \mathcal{L}_1^{\mathfrak{R}^n}$ a současně

$$\int_{\mathfrak{R}^n} \tilde{G}_{\tilde{\phi}}(\vec{x}) d(\vec{x}) \neq 0 .$$

Potom lineární obal funkcií ve tvaru $\tilde{\phi}(\langle \vec{x} | \vec{a} \rangle - c)$, $\vec{a} \in \mathfrak{R}^n$, $c \in \mathfrak{R}$, je hustý v prostoru $C_{\bar{K}}$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť $p, R \in \mathbb{R}$, $R > 0$ a $\vec{x} \in \mathbb{R}^n$. Potom platí, že

$$\int_{\|\vec{x}\| \geq R} \frac{1}{\|\vec{x}\|^p} d(\vec{x}) < \infty$$

právě když $p > n$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť $\tilde{G}_{\tilde{\phi}}(\vec{x})$ je definováno dle 2. Potom $\tilde{G}_{\tilde{\phi}}(\vec{x}) = \tilde{g}_0(\tilde{\phi}, r)$, kde $r \stackrel{\text{def}}{=} \|\vec{x}\|$ a

$$\begin{aligned} \tilde{g}_0(\tilde{\phi}, r) &= \frac{\alpha_{n-2}}{\alpha_{n-1}} \int_{-1}^1 \tilde{\phi}(rs) (1-s^2)^{\frac{n-3}{2}} d(s) \\ &= \frac{\alpha_{n-2}}{\alpha_{n-1}} \int_{-r}^r r^{2-n} \tilde{\phi}(t) (r^2 - t^2)^{\frac{n-3}{2}} d(t), \quad r \neq 0. \end{aligned} \tag{3}$$

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť n je liché a pro $\tilde{\psi}(t) \stackrel{\text{def}}{=} \tilde{\phi}(1+t) + \tilde{\phi}(1-t)$ a pro nějaké $\eta > 0$ platí $|\tilde{\psi}(t)| \leq \frac{\eta}{|t|^p}$, $p > n - 2$. Potom $\tilde{G}_{\tilde{\phi}}(\cdot) \in \mathcal{L}_1^{\Re^n}$ tehdy a jen tehdy, je-li

$$\int_0^\infty \tilde{\psi}(t) t^{2j} d(t) = 0, \quad j \in \{0, \dots, \frac{n-3}{2}\}. \quad (4)$$

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Předpokládejme, že n je liché a že funkce $\tilde{\psi}$ splňuje předpoklady a tvrzení lemmy . Dále předpokládejme, že $\tilde{\psi}$ je sudá funkce. Potom platí

$$\int_{\Re^n} \tilde{G}_{\tilde{\phi}}(\vec{x}) d(\vec{x}) = -2\alpha_{n-2}\tau_n \int_0^\infty \tilde{\psi}(t) t^{n-1} d(t), \quad (5)$$

kde je

$$\tau_n \stackrel{\text{def}}{=} \int_0^1 r (1 - r^2)^{\frac{n-3}{2}} d(r) > 0.$$

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť $\tilde{\sigma} \in C_{\mathfrak{R}}$ je stejnoměrně spojitá na \mathfrak{R} a $\tilde{\psi}(t) \stackrel{\text{def}}{=} \tilde{\sigma}(1+t) + \tilde{\sigma}(1-t)$. Předpokládejme, že n je liché a $\bar{K} = \langle -a, a \rangle^n$, $a > 0$ a pro nějaké $\eta > 0$ platí $|\tilde{\psi}(t)| \leq \frac{\eta}{|t|^p}$, $p > n-2$. Dále nechť

$$\int_0^\infty \tilde{\psi}(t)t^{n-1}d(t) \neq 0.$$

Potom lineární obal množiny funkcí ve tvaru $\tilde{\sigma}(\langle \vec{x} | \vec{w} \rangle + c)$, kde $\vec{w} \in \mathfrak{R}^n$ a $c \in \mathfrak{R}$, je hustý v prostoru $C_{\bar{K}}$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

3 Approximace III. - Duální prostory

- věta o vztahu hustoty funkcí a nulového funkcionálu
- aplikace na prostor $\mathcal{L}_p^{\bar{K}}$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť \mathcal{X} je úplný normovaný vektorový prostor nad tělesem \mathbb{R} , \bar{V} je jeho podprostor. Potom \bar{V} je hustý v \mathcal{X} , právě když jediný lineární omezený funkcionál na \mathcal{X} , v jehož nulovém prostoru je \bar{V} obsažen, je nulový funkcionál.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť \tilde{g} je funkce definovaná na kompaktní množině $\bar{K} \subset \mathbb{R}^n$ splňující následující podmíinku:

$$(\forall \vec{a} \in \mathbb{R}^n, \|\vec{a}\| = 1) (\forall \vec{y} \in \bar{K}) \left(\int_{\langle \vec{a} | \vec{x} \rangle < \langle \vec{a} | \vec{y} \rangle} \tilde{g}(\vec{x}) d(\vec{x}) = \int_{\langle \vec{a} | \vec{x} \rangle > \langle \vec{a} | \vec{y} \rangle} \tilde{g}(\vec{x}) d(\vec{x}). \right)$$

Potom \tilde{g} je skoro všude na \bar{K} rovna nule.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

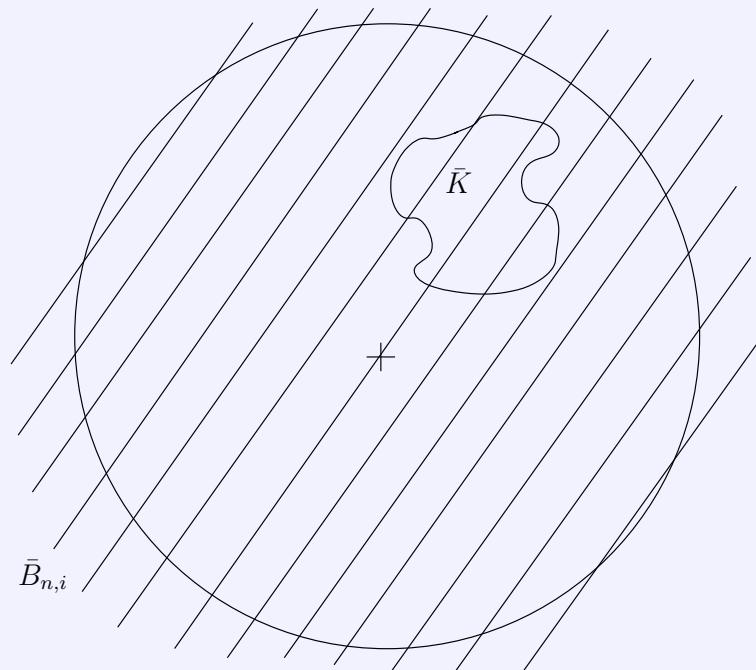
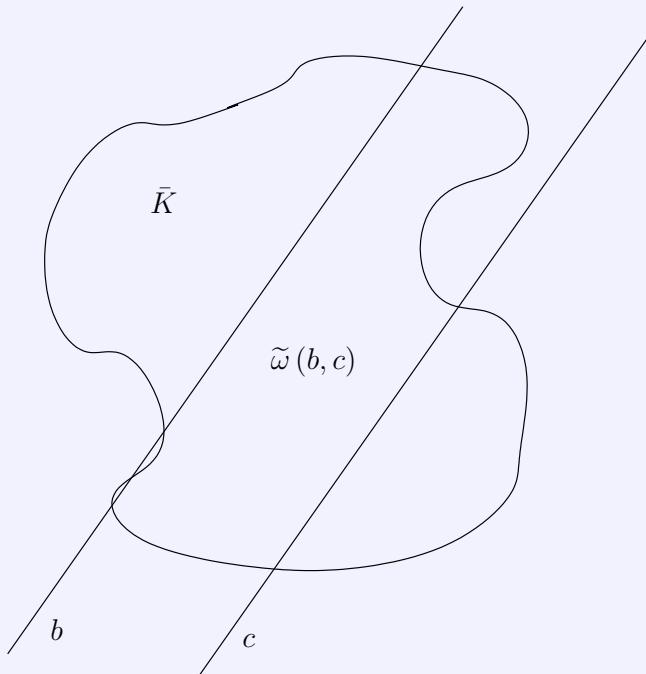


Figure 2: Definition of sets $\bar{B}_{n,i}$ and of the mapping $\tilde{\omega}$.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

4 Approximace IV. - Binární neuronové sítě

- pojem prahového vektoru
- základní vlastnosti prahového vektoru
- odhad počtu vektorů
- dolní odhad počtu vektorů

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť funkce $\widetilde{sgn} : \mathbb{R}^n \rightarrow \{-1, +1\}$ je definována jako

$$\widetilde{sgn}(z) \stackrel{\text{def}}{=} \begin{cases} 1 & \text{pro } x > 0 \\ -1 & x \leq 0 \end{cases}.$$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť $\vec{x}_1, \dots, \vec{x}_S$ jsou vektory z $\{-1, +1\}^n$. Potom říkáme, že vektor \vec{y} je PRAHOVÝM VEKTOREM systému $\vec{x}_1, \dots, \vec{x}_S$ právě když existují čísla w_1, \dots, w_S tak, že vektor $\sum_{i=1}^S w_i \cdot \vec{x}_i$ má pouze nenulové složky a platí:

$$\vec{y} \stackrel{\text{def}}{=} \widetilde{\operatorname{sgn}} \left(\sum_{i=1}^S w_i \cdot \vec{x}_i \right).$$

(Funkce $\widetilde{\operatorname{sgn}}$ je aplikována na vektory po složkách).

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť $\vec{y}^T (\vec{x}_1, \dots, \vec{x}_S) = \vec{0}^T$. Potom \vec{y} není prahovým vektorem systému $(\vec{x}_1, \dots, \vec{x}_S)$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť \vec{y}^T je prahovým vektorem systému $(\vec{x}_1, \dots, \vec{x}_S)$, $\vec{x}_i \neq \vec{0}$, $i \in \{1, \dots, S\}$ a sloupce matici \mathbf{X} jsou rovny vektorům \vec{x}_i . Potom pro všechny vektory $\vec{z} \in \{-1, +1\}^n$, $\vec{y} \neq \vec{z}$, platí

$$\vec{y}^T \cdot \mathbf{X} \neq \vec{z}^T \cdot \mathbf{X}.$$

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Existuje nejvýše $(n + 1)^S$ různých prahových vektorů systému $\vec{x}_1, \dots, \vec{x}_S \in \{-1, +1\}^n$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Předpokládejme, že vektory $\vec{x}_1, \dots, \vec{x}_S$ jsou lineárně nezávislé a nechť

$$\vec{y} \stackrel{\text{def}}{=} \sum_{i=1}^S \beta_i \vec{x}_i + \vec{y}^\perp,$$

kde \vec{y}^\perp je z ortogonálního doplnku $[\vec{x}_1, \dots, \vec{x}_S]_\lambda$. Označme vektor $\vec{\beta} \stackrel{\text{def}}{=} (\beta_1, \dots, \beta_S)$ jako ZOBEZNÉ SPEKTRUM vektoru \vec{y} a číslo

$$\beta_{\max} \stackrel{\text{def}}{=} \max \{ |\beta_i| \mid i \in \{1, \dots, S\} \}$$

jako MAXIMUM ZOBEZNÉHO SPEKTRA vektoru \vec{y} .

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Je-li \vec{y} prahovým vektorem systému $(\vec{x}_1, \dots, \vec{x}_S)$ tak platí

$$\sum_{i=1}^S |\vec{\beta}_i| \geq 1.$$

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť \vec{y} je prahový vektor systému ortogonálních vektorů $\vec{x}_1, \dots, \vec{x}_S \in \{-1, +1\}^n$. Potom

$$S \geq \frac{n}{\max_i |\langle \vec{y} | \vec{x}_i \rangle|}. \quad (6)$$

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

5 Symetrické prahové vektory

- vlastnosti prahů základních vektorů parity
- obvod pro symetrické vektory

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť \mathbf{A} je reálná matice o rozměrech $r \times s$ a \mathbf{B} je reálná matice o rozměrech $m \times n$. Potom TENSOROVÝ SOUČIN matic \mathbf{A} a \mathbf{B} je matice $\mathbf{A} \odot \mathbf{B}$ o rozměrech $mr \times ns$ definovaná jako

$$\mathbf{A} \odot \mathbf{B} \stackrel{\text{def}}{=} \begin{pmatrix} \mathbf{Ab}_{1,1} & \mathbf{Ab}_{1,2} & \dots & \mathbf{Ab}_{1,n} \\ \mathbf{Ab}_{2,1} & \mathbf{Ab}_{2,2} & \dots & \mathbf{Ab}_{2,n} \\ \vdots & & & \vdots \\ \mathbf{Ab}_{m,1} & \mathbf{Ab}_{m,2} & \dots & \mathbf{Ab}_{m,n} \end{pmatrix}.$$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Čtvercová matici A je ROSTOUCÍ, jestliže její prvky v každém řádku a v každém sloupci tvoří neklesající posloupnost. Matici A je POTENCIÁLNĚ ROSTOUCÍ, jestliže existují permutační matice P a Q tak, že matici $P \cdot A \cdot Q$ je rostoucí.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Čtvercová matice A s prvky z $\{-1, 1\}$ je potenciálně rostoucí právě když neobsahuje jako svojí podmatici matici $\begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix}$ nebo $\begin{pmatrix} -1 & 1 \\ 1 & -1 \end{pmatrix}$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť n je přirozené, $i \in \{1, \dots, n\}$, a $e^{(k)}$ označuje vektor jedniček délky 2^k . Potom i -TÝ ZÁKLADNÍ VEKTOR PARITY je definován jako $\overset{\rightarrow}{\tilde{p}}_i \stackrel{\text{def}}{=} e^{(i-1)} \odot (1, -1) \odot e^{(n-i)}$.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Předpokládejme že $n \stackrel{\text{def}}{=} 2k$, $\vec{y} \in \{-1, +1\}^{2^n}$ a $M_{\vec{y}}$ je čtvercová matice řádu $2^{\frac{n}{2}}$, jejíž sloupce jsou tvořeny po sobě jdoucími podvektory vektoru \vec{y} délky $2^{\frac{n}{2}}$. Potom matici $M_{\vec{y}}$ nazveme SDRUŽENOU MATICÍ vektoru \vec{y} .

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť $\tilde{\mathbf{p}}_1, \dots, \tilde{\mathbf{p}}_n$ jsou základní vektory parity pro $n \stackrel{\text{def}}{=} 2k$. Dále nechť $\mathbf{E}^{(i)}$ je čtvercová matice jedniček dimenze 2^i . Potom:

1. pro $1 \leq j \leq k$ platí

$$\mathbf{M}_{\tilde{\mathbf{p}}_j} = \mathbf{E}^{(j-1)} \odot \begin{pmatrix} 1 & 1 \\ -1 & -1 \end{pmatrix} \odot \mathbf{E}^{(k-j)} \quad a \quad \mathbf{M}_{\tilde{\mathbf{p}}_{k+j}} = \mathbf{E}^{(j-1)} \odot \begin{pmatrix} 1 & -1 \\ 1 & -1 \end{pmatrix} \odot \mathbf{E}^{(k-j)}.$$

2. Pro $1 \leq j \leq k$ platí

$$\mathbf{M}_{\tilde{\mathbf{p}}_{k+j}} = \mathbf{M}_{\tilde{\mathbf{p}}_j}^T.$$

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Je-li $n \stackrel{\text{def}}{=} 2k$ a $\vec{y} \in \{-1, +1\}^{2^n}$ je prahový vektor základních vektorů parity a konstantního vektoru, tak sdružená matice $M_{\vec{y}}$ je potenciálně rostoucí.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť $\vec{x} = (\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n) \in \{-1, +1\}^n$ a definujeme číslo $nint(\vec{x}) \in \{0, \dots, 2^n - 1\}$ jako

$$nint(\vec{x}) \stackrel{\text{def}}{=} \sum_{k=1}^n \left(\frac{\vec{x}_k + 1}{2} \right) 2^{n-k}.$$

Dále nechť $i \in \{0, \dots, 2^n - 1\}$ a $\vec{\alpha} \in \{0, 1\}^n$ jsou taková, že $i = \sum_{j=1}^n \vec{\alpha}_j 2^{n-j}$. Potom

$$vbin(i) \stackrel{\text{def}}{=} \vec{\alpha} \quad \text{and} \quad vpm(i) \stackrel{\text{def}}{=} 2 \cdot \vec{\alpha} - \vec{1}.$$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť $n \in N$, $\vec{y} \in \{-1, +1\}^{2^n}$ a $\alpha \in \{0, \dots, 2^n - 1\}$. Potom vektor \vec{y} nazveme α -SYMETRICKÝ VEKTOR když ($\forall i, j \in \{0, \dots, 2^n - 1\}$)

$$\left(\sum_{k=1}^n (vbin(i))_k \cdot (vbin(\alpha))_k = \sum_{k=1}^n (vbin(j))_k \cdot (vbin(\alpha))_k \right) \Rightarrow \vec{y}_i = \vec{y}_j.$$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť $n \in N$ a vektor $\vec{y} \in \{-1, +1\}^{2^n}$ je $(2^n - 1)$ -symetrický vektor. Nechť d_1, \dots, d_m jsou délky po sobě jdoucích konstantních úseků posloupnosti $\vec{y}_0, \vec{y}_{2^1-1}, \vec{y}_{2^2-1}, \dots, \vec{y}_{2^n-1}$. Dále pro každé $k \in \{1, \dots, m\}$ definujme funkci $\tilde{v}_k : \{-1, +1\}^n \rightarrow \{-1, +1\}$ jako

$$\tilde{v}_k(\vec{x}) \stackrel{\text{def}}{=} \widetilde{\operatorname{sgn}} \left(\sum_{j=1}^n \vec{x}_j + n - 2 \sum_{j=1}^k d_j + \frac{1}{2} \right) \quad (7)$$

a navíc definujme $\tilde{S}(\vec{x}) \stackrel{\text{def}}{=} \vec{y}_0 \left(1 + \sum_{j=1}^m (-1)^j (\tilde{v}_j(\vec{x}) + 1) \right)$. Potom pro všechna $\vec{x} \in \{-1, +1\}^n$ platí $\tilde{S}(\vec{x}) = \vec{y}_{n \operatorname{int}(\vec{x})}$.

Důkaz byl prezentován na přednášce.

Prezentace z přednášky Neuronové sítě II.
 zimní semestr 2018/2019, KM FJFI ČVUT
 přednášející: František Hakl, hakl@cs.cas.cz

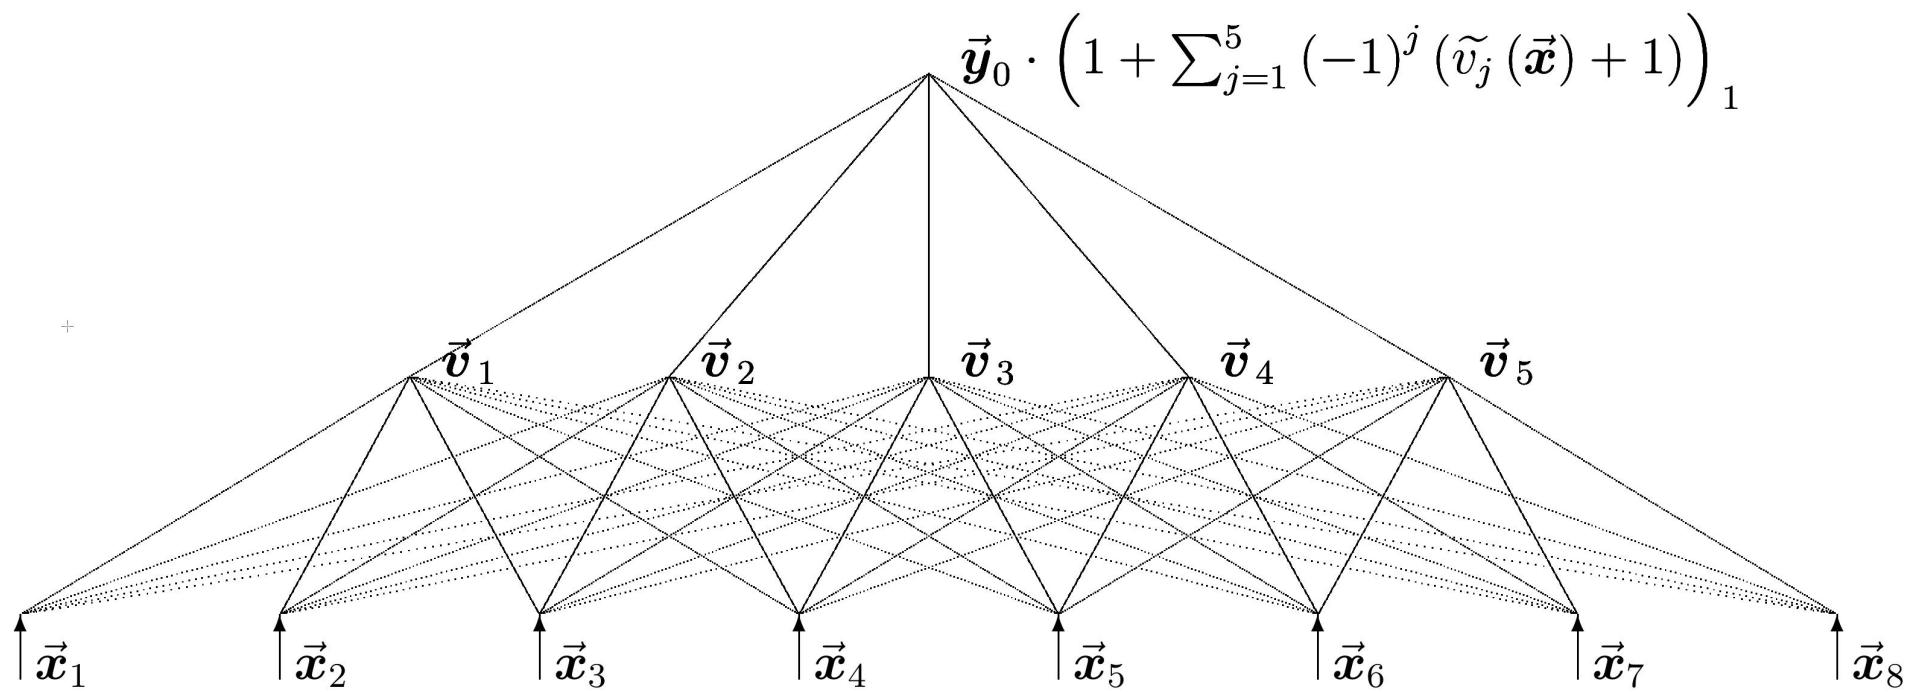


Figure 3: Příklad neuronové sítě pro výpočet symetrických vektorů.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

6 Vapnik-Chervonenkova dimenze

- Vapnik-Chervonenkova dimenze
- Radonovo lemma, VC dimenze poloprostorů a koulí
- odhady Vapnik-Chervonenkovy dimenze neuronových sítí

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť \bar{X} je libovolná množina. Potom $\bar{c} \subset \bar{X}$ nazveme KONCEPT (nad \bar{X}). Neprázdný systém množin $C \subset 2^{\bar{X}}$ nazveme TŘÍDOU KONCEPTŮ (nad množinou \bar{X}). Prvky této třídy $\bar{c} \in C$ nazýváme koncepty z třídy C .

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť \tilde{f} je zobrazení z \bar{X} do $\{-1, +1\}$. Potom definujeme koncept $\bar{c}_{\tilde{f}}$ jako

$$\bar{c}_{\tilde{f}} \stackrel{\text{def}}{=} \left\{ x \in \bar{X} \mid \tilde{f}(x) = 1 \right\}.$$

Definice. Předpokládejme, že \bar{F} je libovolná množina funkcí zobrazujících \bar{X} do $\{-1, +1\}$. Potom řekneme, že \bar{F} REPREZENTUJE TŘÍDU KONCEPTŮ

$$C_{\bar{F}} \stackrel{\text{def}}{=} \left\{ \bar{A} \subset \bar{X} \mid (\exists \tilde{f} \in \bar{F})(\bar{A} = \bar{c}_{\tilde{f}}) \right\}.$$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť n je přirozené číslo a

$$\bar{F} \stackrel{\text{def}}{=} \left\{ \tilde{f} : \Re^n \rightarrow \{-1, +1\} \mid \tilde{f}(\vec{x}) = \widetilde{\operatorname{sgn}} (\langle \vec{x} | \vec{w} \rangle - t), \quad t \in \Re, \quad \vec{w}, \vec{x} \in \Re^n \right\}.$$

Potom definujeme **HALFSPACE** $_n \stackrel{\text{def}}{=} C_{\bar{F}}$.

Definice. Nechť n je přirozené číslo a

$$\bar{F} \stackrel{\text{def}}{=} \left\{ \tilde{f} : \Re^n \rightarrow \{-1, +1\} \mid \tilde{f}(\vec{x}) = \widetilde{\operatorname{sgn}} (\|\vec{x} - \vec{c}\|_E - r), \quad r \in \Re^+, \quad \vec{c}, \vec{x} \in \Re^n \right\}.$$

Potom definujme **BALL** $_n \stackrel{\text{def}}{=} C_{\bar{F}}$.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť \bar{X} je daná množina, $\bar{Y} \subset \bar{X}$, $C \subset 2^{\bar{X}}$. Potom \bar{Y} JE ROZDĚLENA TŘÍDOU C právě když:

$$(\forall \bar{z} \subset \bar{Y})(\exists \bar{c} \in C)(\bar{c} \cap \bar{Y} = \bar{z}).$$

Dále definujme pojem VAPNIK-CHERVONENKOVA DIMENZE systému množin C jako

$$\text{VC}_{dim}(C) \stackrel{\text{def}}{=} \sup \left\{ |\bar{Y}| \mid \bar{Y} \text{ je rozdělena třídou } C \right\}.$$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť C je konečná třída konceptů. Potom $\text{VC}_{\text{dim}}(C) \leq \log_2(|C|)$.

Bez důkazu.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma (Sauer). Nechť \bar{X} je konečná množina a $C \subset 2^{\bar{X}}$. Potom

$$|C| \leq \sum_{i=0}^{\text{VC}_{\dim}(C)} \binom{|\bar{X}|}{i}.$$

Dále existuje $C \subset 2^{\bar{X}}$ taková, že platí rovnost.

Bez důkazu.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Důsledek. Nechť \bar{X} je konečná množina, $C \subset 2^{\bar{X}}$ a $\text{VC}_{\text{dim}}(C) > 0$. Potom

$$\text{VC}_{\text{dim}}(C) > \frac{\ln(|\bar{C}|)}{1 + \ln(|\bar{X}|)}.$$

Bez důkazu.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma (Radon). Nechť $\bar{S} \stackrel{\text{def}}{=} \{\vec{x}_1, \dots, \vec{x}_k\} \subset \Re^n$, $k \geq n+2$, \vec{x}_i jsou vzájemně různé. Potom existují množiny \bar{S}_1 a \bar{S}_2 tak, že $\bar{S}_1 \cup \bar{S}_2 = \bar{S}$, $\bar{S}_1 \cap \bar{S}_2 = \emptyset$ a

$$[\bar{S}_1]_\kappa \cap [\bar{S}_2]_\kappa \neq \emptyset$$

(symbol $[\bar{S}]_\kappa$ označuje konvexní obal množiny \bar{S}).

Bez důkazu.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. $\text{VC}_{dim}(\text{HALFSPACE}_n) = \text{VC}_{dim}(\text{BALL}_n) = n + 1$.

Bez důkazu.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť $\mathsf{C} \subset 2^{\bar{X}}$ je třída konceptů. Pak pro každé přirozené číslo k definujeme množiny

$$\mathsf{U}_{k,\mathsf{C}} \stackrel{\text{def}}{=} \left\{ \bigcup_{i=1}^k \bar{c}_i \mid (\forall i \in \{1, \dots, k\}) (\bar{c}_i \in \mathsf{C}) \right\} \quad a \quad \mathsf{I}_{k,\mathsf{C}} \stackrel{\text{def}}{=} \left\{ \bigcap_{i=1}^k \bar{c}_i \mid (\forall i \in \{1, \dots, k\}) (\bar{c}_i \in \mathsf{C}) \right\}.$$

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Lemma. Nechť $\mathcal{C} \subset 2^{\bar{X}}$ je třída konceptů, nechť $\text{VC}_{\text{dim}}(\mathcal{C}) = d \geq 1$ je konečná a $k \geq 1$. Potom $\text{VC}_{\text{dim}}(\mathsf{U}_{k,\mathcal{C}}) \leq 2dk\log_2(3k)$ a $\text{VC}_{\text{dim}}(\mathsf{I}_{k,\mathcal{C}}) \leq 2dk\log_2(3k)$.

Bez důkazu.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Předpokládejme, že je dán souvislý orientovaný acyklický graf s množinou vrcholů \bar{V} a množinou hran \bar{E} . Nechť pro vrchol $j \in \bar{V}$ označuje číslo d_j^+ počet hran vedoucích do vrcholu j a d_j^- počet hran vedoucích z vrcholu j . Dále nechť platí:

1. Existuje právě jeden vrchol s $d_j^- = 0$ (tzv. VÝSTUPNÍ VRCHOL) a existuje alespoň jeden vrchol s $d_j^+ = 0$ (tzv. VSTUPNÍ VRCHOLY). Ostatní vrcholy nazveme VNITŘNÍ VRCHOLY.
2. Pro každý vrchol $j \in \bar{V}$ existuje zobrazení $\widetilde{Z}_j : \left\{ \mathbb{R}^{d_j^+} \times W_j \right\} \rightarrow \mathbb{R}$, kde W_j je daný parametrický prostor zobrazení \widetilde{Z}_j .

Potom $(\bar{V}, \bar{E}, (\widetilde{Z}_j, W_j), j \in \bar{V})$ nazveme SLOŽENÉ ZOBRAZENÍ.

Označme vrcholy grafu pevným vlastním očíslováním. Nechť $(\vec{w}_1, \dots, \vec{w}_{|\bar{V}|}) \in \bar{W}_1 \times \bar{W}_2 \cdots \times \bar{W}_{|\bar{V}|}$

$$(\forall j \in \bar{V}) \left(v_j = \widetilde{Z}_j \left(\left(v_{j_1} \cdots v_{j_{d_j^+}}, \right), \vec{w}_j \right) \quad a \quad (\forall i \in \{1, \dots, d_j^+\}) ((j_i, j) \in \bar{E}) \right).$$

Potom hodnotu $v_{|\bar{V}|}$ nazveme HODNOTOU SLOŽENÉHO ZOBRAZENÍ pro parametrizaci $(\vec{w}_1, \dots, \vec{w}_{|\bar{V}|})$.

Prezentace z přednášky Neuronové sítě II.

zimní semestr 2018/2019, KM FJFI ČVUT

přednášející: František Hakl, hakl@cs.cas.cz

Příklad: $\tilde{s} : \mathbb{R}^3 \times \bar{W}_s \times \bar{W}_f \times \bar{W}_g \times \bar{W}_h \rightarrow \mathbb{R}$, kde $\bar{W}_s, \bar{W}_f, \bar{W}_g, \bar{W}_h$ jsou parametrické prostory zobrazení $\tilde{s}, \tilde{f}, \tilde{g}, \tilde{h}$, a

$$\tilde{s}\left(\tilde{f}(x, y, z, \vec{w}_f), \tilde{g}\left(y, \tilde{h}(z, \vec{w}_h), \vec{w}_g\right), \vec{w}_s\right).$$

Odpovídající graf je uveden na následujícím obrázku:

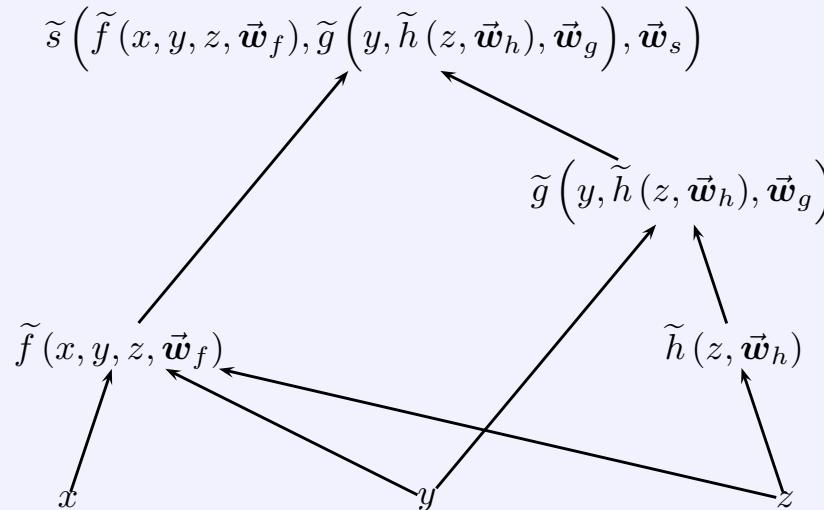


Figure 4: Corresponding graph for composed mapping.

Prezentace z přednášky Neuronové sítě II.
 zimní semestr 2018/2019, KM FJFI ČVUT
 přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť $\mathbf{D} \stackrel{\text{def}}{=} \left(\bar{V}, \bar{E}, \left(\widetilde{Z}_j, \bar{W}_j \right), j \in \bar{V} \right)$ je složené zobrazení a $z \geq 2$ je počet nevstupních vrcholů. Dále nechť pro každý nevstupní vrchol je $\text{VC}_{\dim} \left(\mathcal{C}_{\widetilde{Z}_k} \right) = d_k > 0$, $d_k < +\infty$, $k \in \{1, \dots, z\}$ a definujme

$$q \stackrel{\text{def}}{=} \sum_{k=1}^z d_k . \quad (8)$$

Potom platí

$$\text{VC}_{\dim} (\mathcal{C}_{\mathbf{D}}) < 2q \log_2 (ez) . \quad (9)$$

Bez důkazu.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

7 Odhadové složitosti PAC modelu učení

- Probably Approximately Correct (PAC) učení - schéma
- třídy konceptů a hypotéz, chyba hypotézy vůči konceptu
- (ϵ, δ) -algoritmus
- odhadové složitosti pro (ϵ, δ) -učení

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Realita

universum \bar{X} s podmnožinou $C \subset 2^{\bar{X}}$, definovanou pravděpodobností \tilde{P} na \bar{X} a cílovou množinou $\bar{c} \in C$

 \bar{X}, \tilde{P} C \bar{c} **Proces**

na dotaz
vybere $x_i \in \bar{X}$
podle \tilde{P}

 x_i

0 or 1

Algoritmus

provádí výpočet
dotazuje Process nebo Moudro
je-li třeba
na konci
vybere $\bar{h} \in C$
 \bar{h} by měla být
"podobná" \bar{c}

 x_i

0 or 1

Moudro

```
if  $x_i \in \bar{c}$ 
    return 1
else
    return 0
```

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.vut.cz

hypotéza $\bar{h} \sim \bar{c}$

Figure 5: Učení s učitelem s dotazy na příslušnost .

Definice. Nechť C je třída konceptů a systém množin H splňuje podmínu $C \subset H \subset 2^{\bar{X}}$. Potom H je TŘÍDA HYPOTÉZ pro třídu konceptů C .

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť \bar{X} je pravděpodobnostní prostor s pravděpodobnostní funkcí \tilde{P} . Dále nechť \mathbb{C} je třída konceptů nad množinou \bar{X} a \mathbb{H} je třída hypotéz pro \mathbb{C} . Potom pro každé $\bar{c} \in \mathbb{C}$ a $\bar{h} \in \mathbb{H}$ je číslo

$$\mathbf{e}_{\tilde{P}}(\bar{c}, \bar{h}) \stackrel{\text{def}}{=} \text{Prob}_{\tilde{P}}(\bar{h} \triangle \bar{c})$$

CHYBOU HYPOTÉZY \bar{h} VŮCI KONCEPTU \bar{c} při pravděpodobnosti \tilde{P} (symbol $\bar{h} \triangle \bar{c}$ označuje symetrickou differenci množin \bar{h} a \bar{c} , t.j. $\bar{h} \triangle \bar{c} = (\bar{c} - \bar{h}) \cap (\bar{h} - \bar{c})$).

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

” \bar{h} by měla approximovat \bar{c} ”

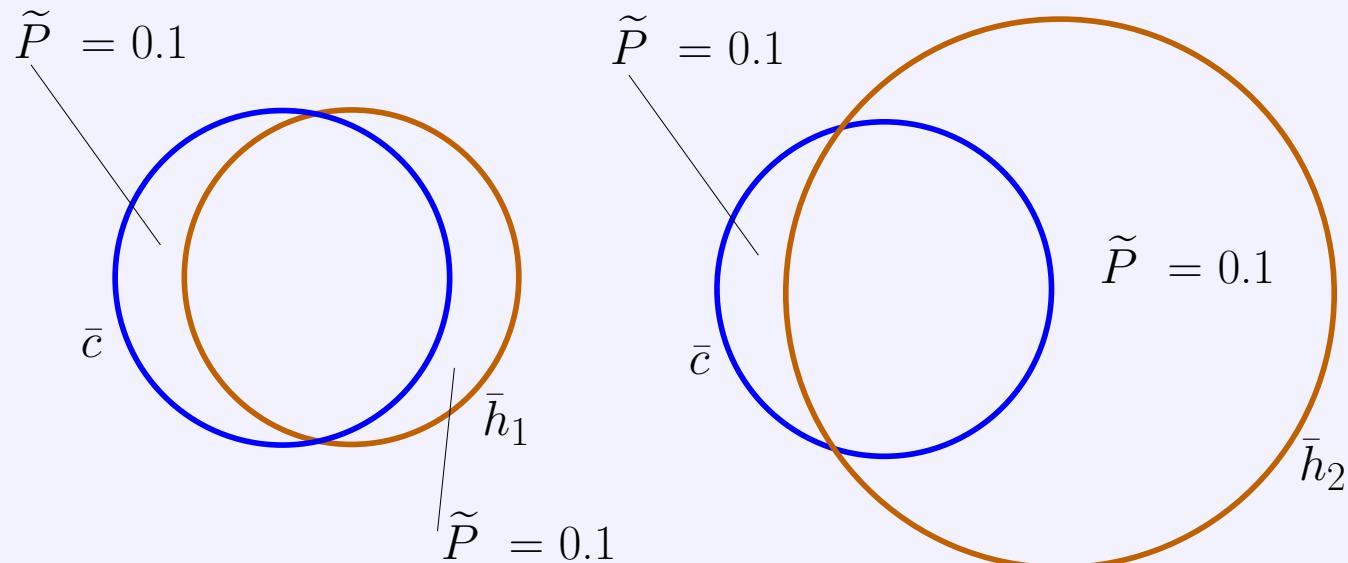


Figure 6: Příklad dvou hypotéz se stejnou chybou.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť $\bar{x} \stackrel{\text{def}}{=} \{x_1, \dots, x_m\}$, $x_i \in \bar{X}$, $i \in \{1, \dots, m\}$, $\vec{z} \in \{-1, +1\}^m$ a nechť $\bar{c} \subset \bar{X}$. Potom uspořádaná dvojice (\bar{x}, \vec{z}) je VZOREK KONCEPTU \bar{c} DÉLKY m právě když

$$(\forall i \in \{1, \dots, m\}) ((x_i \in \bar{c}) \Leftrightarrow (\vec{z}_i = 1)).$$

Pro třídu konceptů C definujme PROSTOR VZORKŮ TŘÍDY KONCEPTŮ jako

$$\bar{S}_C \stackrel{\text{def}}{=} \bigcup_{m \geq 1} \left\{ \bigcup_{\bar{c} \in C} \left\{ (\bar{x}, \vec{z}) \mid (\bar{x}, \vec{z}) \text{ je vzorek délky } m \text{ konceptu } \bar{c} \right\} \right\}.$$

Množina $\bar{b} \subset \bar{X}$ je KONZISTENTNÍ MNOŽINA se vzorkem (\bar{x}, \vec{z}) právě když pro všechna $i \in \{1, \dots, m\}$ platí $(x_i \in \bar{b} \Leftrightarrow \vec{z}_i = 1)$.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz

Definice. Nechť funkce $\tilde{m}(\epsilon, \delta)$ zobrazuje množinu $(0, 1) \times (0, 1)$ do množiny přirozených čísel a nechť H je třída hypotéz pro třídu konceptů C definovanou nad množinou \bar{X} . Potom UČICÍ ALGORITMUS SLOŽITOSTI $\tilde{m}(\epsilon, \delta)$ třídy konceptů C je každé zobrazení $\widetilde{\mathbf{A}}^* : \bar{S}_{\mathsf{C}} \rightarrow \mathsf{H}$ takové, že pro všechny $\bar{c} \in \mathsf{C}$, pro všechna $0 < \epsilon < 1$, $0 < \delta < 1$ a pro libovolnou pravděpodobnost \tilde{P} definovanou na \bar{X} je pravděpodobnost množiny

$$\left\{ \bar{x} \in \bar{X}^m \mid \left(\bar{x}, \vec{z} \right) \text{ je vzorek } \bar{c} \quad \text{a} \quad \mathbf{e}_{\tilde{P}} \left(\bar{c}, \widetilde{\mathbf{A}}^* \left(\left(\bar{x}, \vec{z} \right) \right) \right) \geq \epsilon \right\}$$

menší než číslo δ . Jestliže takovýto algoritmus existuje, říkáme že C JE UNIFORMNĚ NAUČITELNÁ podle třídy hypotéz H . Každý takovýto algoritmus nazveme (ϵ, δ) -UČICÍ ALGORITMUS.

Prezentace z přednášky Neuronové sítě II.
 zimní semestr 2018/2019, KM FJFI ČVUT
 přednášející: František Hakl, hakl@cs.cas.cz

Tvrzení. Nechť \mathcal{C} netriviální, dobrě utvořená třída konceptů. Potom platí následující:

1. Je-li $\text{VC}_{\dim}(\mathcal{C}) = d$ a $d < \infty$ tak

(a) pro $0 < \epsilon < \frac{1}{2}$ neexistuje (ϵ, δ) -učící algoritmus, který použije méně než

$$\max \left(\frac{1 - \epsilon}{\epsilon} \ln \left(\frac{1}{\delta} \right), d(1 - 2(\epsilon(1 - \delta) + \delta)) \right) \quad (10)$$

učících vzorů.

(b) pro libovolné $0 < \epsilon < 1$ každý učící algoritmus, který použije alespoň

$$\max \left(\frac{4}{\epsilon} \log_2 \left(\frac{2}{\delta} \right), \frac{8d}{\epsilon} \log_2 \left(\frac{12.611}{\epsilon} \right) \right) \quad (11)$$

učících vzorů a vždy generuje konzistentní hypotézu je (ϵ, δ) -učící algoritmus.

2. \mathcal{C} je uniformně naučitelná právě když $\text{VC}_{\dim}(\mathcal{C}) < \infty$.

Bez důkazu.

Prezentace z přednášky Neuronové sítě II.
zimní semestr 2018/2019, KM FJFI ČVUT
přednášející: František Hakl, hakl@cs.cas.cz