

# Fuzzy neurónové siete

Gabriela Andrejková

Ústav informatiky

Prírodovedecká fakulta, UPJŠ, Košice

## Abstrakt

V prvej časti sa oboznámime s fuzzy číslami, ktoré sú tiež použiteľné pri konštrukcii neurónov.

Spojiť výhody ponúkané fuzzy logikou a teóriou fuzzy množín s prednosťami neurónových sietí sa snaží nové odvetvie – fuzzy neurónové siete.

Podobne ako klasické neurónové siete, aj tieto je možné rozdeliť na statické (feedforward) a dynamické (feedback). Predmetom nášho záujmu budú statické fuzzy neurónové siete.

## Obsah prednášky

---

1. Fuzzy čísla
2. Motivácia, práca jedného fuzzy neurónu
3. Fuzzy neurónové siete

# Fuzzy neuróny

- Základným stavebným prvkom fuzzy neurónových sietí je fuzzy neurón, ktorý pracuje rovnako ako obyčajný neurón, má však navyše schopnosť vysporiadať sa s fuzzy informáciou.
- Podstatný rozdiel medzi oboma typmi neurónov z výpočtového hľadiska spočíva v definícii matematických operácií.
- Tie môžu byť vo fuzzy neuróne predstavované fuzzy aritmetikou alebo operáciami fuzzy logiky.

# Úvod

- Uvažujme  $\mathcal{U}$  klasickú množinu, ktorú budeme nazývať univerzom.
- **Fuzzy množina**  $A$  nad  $\mathcal{U}$  je potom jednoznačne určená jej funkciou príslušnosti  $\mu_A : \mathcal{U} \rightarrow \langle 0, 1 \rangle$  a nazýva sa tiež fuzzy podmnožinou univerza  $\mathcal{U}$ .
- Fuzzy množiny budeme v ďalšom stotožňovať s ich funkciami príslušnosti, teda trieda  $\mathcal{F}(\mathcal{U})$  všetkých fuzzy podmnožín univerza  $\mathcal{U}$  bude triedou všetkých funkcií  $f$  s  $D(f) = \mathcal{U}$  a  $H(f) \subseteq \langle 0, 1 \rangle$ .
- Hodnotu  $\mu_A(x) \in \langle 0, 1 \rangle$ , ktorú fuzzy množina  $A$  priradí prvku  $x \in \mathcal{U}$ , nazývame **stupňom príslušnosti** prvku  $x$  do fuzzy množiny  $A$ . V prípade, že  $\mu_A(x) = 0$ , hovoríme, že  $x$  nepatrí do  $A$ , ak  $\mu_A(x) = 1$ , hovoríme, že  $x$  patrí do  $A$ .
- V prípade, že  $\mu_A(x) \neq 0$  a  $\mu_A(x) \neq 1$ , hovoríme, že  $x$  čiastočne patrí do  $A$ .

## Reálne fuzzy čísla

sú špeciálne fuzzy množiny v univerze reálnych čísel, pomocou ktorých je možné modelovať pojmy ako *asi 2*, *približne 3* a pod.

### Definícia

Fuzzy číslom nazývame konvexnú fuzzy množinu  $A \in \mathcal{F}(\mathbb{R})$ , ktorej funkcia príslušnosti je spojitá a existujú body  $a, b_1, b_2, c \in \mathbb{R}$  také, že  $a \leq b_1 \leq b_2 \leq c$  a platí:

- pre každé  $x \in (-\infty, a) \cup (c, \infty)$  je  $\mu_A(x) = 0$ ,
- $\mu_A$  je rastúca na  $\langle a, b_1 \rangle$  a klesajúca na  $\langle b_2, c \rangle$ ,
- $\mu_A(a) = 0$ ,  $\mu_A(c) = 0$  a pre všetky  $x \in \langle b_1, b_2 \rangle$  je  $\mu_A(x) = 1$ .

Pritom môže byť  $a = -\infty$ ,  $c = \infty$  a  $b_1 = b_2$ .

Množinu všetkých reálnych fuzzy čísel budeme označovať  $\Gamma$ .

## Reálne fuzzy čísla

sú vlastne špeciálne fuzzy množiny, ktoré je možné zapisovať v rôznych tvaroch. Pri práci s fuzzy číslami budeme využívať ich dva rôzne zápisy. Prvý spôsob zápisu fuzzy čísla  $A$  je

$$A = \bigcup_{x=a}^c (x, \mu_A(x)) = \bigcup_{x=a}^{b_1} (x, \mu_{A_L}(x)) \cup \bigcup_{x=b_1}^{b_2} (x, 1) \cup \bigcup_{x=b_2}^c (x, \mu_{A_R}(x)),$$


kde  $A_L$  predstavuje rastúcu a  $A_R$  klesajúcu časť fuzzy množiny. Fuzzy čísla  $\tilde{2}$  asi 2 a  $\tilde{3}$  asi 3 je možné modelovať napríklad takto:

$$\tilde{2} = \bigcup_{x=1}^2 (x, x-1) \cup \bigcup_{x=2}^3 (x, 3-x), \quad (1)$$

$$\tilde{3} = \bigcup_{x=2}^3 (x, x-2) \cup \bigcup_{x=3}^4 (x, 4-x). \quad (2)$$

## Znázornenie fuzzy čísel

Tieto fuzzy čísla sú znázornené na nasledujúcom obrázku. Takéto fuzzy čísla, ktorých funkcia príslušnosti je trojuholníkového tvaru so základňou v  $\langle a, c \rangle$  a vrcholom v  $b_1 = b_2$ , nazývame tiež **trojuholníkové** fuzzy čísla.



*Grafické znázornenie možného tvaru fuzzy čísel  $\tilde{2}$  a  $\tilde{3}$ .*



## Iný spôsob zápisu fuzzy čísla

$$A = \bigcup_{x \in \mathcal{U}} (x, \mu_A(x)) \quad (3)$$

je pomocou  $\alpha$ -rezov

$$A = \bigcup_{\alpha=0}^1 \alpha \cdot A_{(\alpha)}, \quad (4)$$

pričom  $A_{(\alpha)}$  znamená  $\alpha$ -rez fuzzy množiny  $A$  a  $\alpha$  je reálne číslo. (Rez  $A_{(\alpha)} = \{x; \alpha \leq \mu_A(x)\}$ , je to klasická množina.)

Symbol  $\alpha \cdot A_{(\alpha)}$  však nepredstavuje množinu prvkov z  $\alpha$ -rezu  $A_{(\alpha)}$  vynásobených číslom  $\alpha$ , ale fuzzy množinu, ktorej funkciu príslušnosti dostaneme vynásobením charakteristickej funkcie  $\alpha$ -rezu  $A_{(\alpha)}$  číslom  $\alpha$ .

## Iný spôsob zápisu fuzzy čísla

Nech  $A$  je nejaké fuzzy číslo a  $\alpha$  reálne číslo z  $\langle 0, 1 \rangle$ . Charakteristická funkcia  $\mathcal{X}_{A_{(\alpha)}}$   $\alpha$ -rezu  $A_{(\alpha)}$  je potom

$$\mathcal{X}_{A_{(\alpha)}}(x) = \begin{cases} 1 & \mu_A(x) \geq \alpha \\ 0 & \text{inak.} \end{cases}$$

Fuzzy množina  $\alpha \cdot A_{(\alpha)}$  je teda určená takouto funkciou príslušnosti

$$\mu_{\alpha \cdot A_{(\alpha)}}(x) = \begin{cases} \alpha & \mu_A(x) \geq \alpha \\ 0 & \text{inak.} \end{cases}$$

Nosič fuzzy množiny  $A$  je klasická množina  $SuppA = \{x; Ax \neq 0\}$

## Kladné, záporné, inverzné fuzzy číslo

### Definícia

Fuzzy číslo  $A$  je **kladné** (resp. **záporné**), akk  $SuppA \subseteq (0, \infty)$  (resp. ak  $SuppA \subseteq (-\infty, 0)$ ). Ak  $A$  nie je ani kladné, ani záporné, potom je **nulové**. **Opak**  $A$  je fuzzy číslo  $-A$  s funkciou príslušnosti

$$\mu_{-A}(x) = \mu_A(-x).$$

Ak  $A$  nie je nulové fuzzy číslo, potom k nemu **inverzné** fuzzy číslo je  $A^{-1}$  s funkciou príslušnosti

$$\mu_{A^{-1}}(x) = \begin{cases} \mu_A(1/x) & x \neq 0 \\ 0 & x = 0. \end{cases}$$

## Definícia

*Nech  $U$  je univerzum je na ňom definovaná binárna operácia  $*$  a  $A, B$  su fuzzy podmnožiny  $U$ . Rozšírenie tejto operácie na fuzzy množiny  $A, B$  je fuzzy množina  $C = A * B$  s funkciou príslušnosti*

$$Cz = \vee \{Ax \wedge By; x, y \in U \text{ a } z = x * y, \text{ inak } 0\}$$

*pre všetky  $z \in U$ .*

## Kladné, záporné, inverzné fuzzy číslo

Táto definícia je v súlade s princípom rozšírenia, podľa ktorého je

$$\mu_{-A}(z) = \sup_{x \in \mathcal{U}, z = -x} (\mu_A(x)) = \mu_A(-z)$$

a

$$\mu_{A^{-1}}(z) = \sup_{x \in \mathcal{U}, z = 1/x} (\mu_A(x)) = \mu_A(1/z).$$

Opakom kladného fuzzy čísla  $\tilde{2}$  z predchádzajúceho príkladu je záporné fuzzy číslo  $-\tilde{2} =$

$$\bigcup_{x=-2}^{-1} (x, -x-1) \cup \bigcup_{x=-3}^{-2} (x, 3+x) = \bigcup_{\alpha=0}^1 \alpha \cdot \langle \alpha-3, -2 \rangle \cup \bigcup_{\alpha=0}^1 \alpha \cdot \langle -2, -\alpha-1 \rangle.$$

## Kladné, záporné, inverzné fuzzy číslo

Inverzné fuzzy číslo k  $\tilde{z}$  je  $\tilde{z}^{-1} =$

$$\bigcup_{x=1/2}^1 \left(x, \frac{1}{x}-1\right) \cup \bigcup_{x=1/3}^{1/2} \left(x, 3-\frac{1}{x}\right) = \bigcup_{\alpha=0}^1 \alpha \cdot \left\langle \frac{1}{2}, \frac{1}{(\alpha+1)} \right\rangle \cup \bigcup_{\alpha=0}^1 \alpha \cdot \left\langle \frac{1}{(3-\alpha)}, \frac{1}{2} \right\rangle.$$

Uvažujme teraz fuzzy čísla  $A, B$ . Ich súčtom je fuzzy číslo  $C = A \oplus B$ , ktorého funkciu príslušnosti môžeme určiť pomocou princípu rozšírenia nasledovne.

$$\mu_C(z) = \sup_{x,y \in \mathcal{U}, z=x+y} (\mu_A(x) \mathbf{t} \mu_B(y)).$$

## Ďalšie operácie - kniha V. Nováka

Vo všeobecnosti je však ťažké funkciu príslušnosti  $\mu_C$  presne vyjadriť. Na určenie súčtu, súčinu, prípadne iných operácií na množine fuzzy čísel je preto možné využiť nasledovné tvrdenie, ktoré nám umožňuje previesť operácie s fuzzy číslami na operácie s ich  $\alpha$ -rezmi.

### Veta

*Nech  $A_1, A_2$  sú fuzzy čísla,  $f : \mathbb{R}^2 \rightarrow \mathbb{R}$  je rastúca (resp. klesajúca) spojitá binárna funkcia a  $B = f(A_1, A_2)$  fuzzy číslo indukované z  $A_1, A_2$  pomocou princípu rozšírenia, kde  $\mathbf{t} = \mathbf{t}_G$ . Potom pre každé  $\alpha \in \langle 0, 1 \rangle$  je*

$$B_{(\alpha)} = f(A_{1\alpha}, A_{2\alpha}),$$

*kde  $f(A_{1\alpha}, A_{2\alpha}) = \{y \mid y = f(x_1, x_2) \ \& \ \mu_{A_1}(x_1) \geq \alpha \ \& \ \mu_{A_2}(x_2) \geq \alpha\}$ .*

Keďže sčítanie, ako aj násobenie kladných čísel, je rastúca operácia a násobenie záporných čísel je klesajúca operácia, môžeme dané tvrdenie aplikovať na súčet  $\oplus$  a násobenie  $\odot$  kladných, resp. záporných fuzzy čísel. Násobenie fuzzy čísel s rozdielnymi znamienkami, ako aj rozdiel  $\ominus$  dvoch fuzzy čísel je možné realizovať, ak si uvedomíme, že  $(-A) \odot B = -(A \odot B)$  a  $A \ominus B = A \oplus (-B)$ . Podobne podiel  $\oslash$  dvoch fuzzy čísel je možné previesť na násobenie

$$A \oslash B = A \odot B^{-1}$$

v prípade, že  $B$  nie je nulové fuzzy číslo.



Podľa tvrdenia je teda možné súčet a súčin dvoch fuzzy čísel  $A$ ,  $B$  vyjadriť nasledovne:

$$A \oplus B = \bigcup_{\alpha=0}^1 \alpha \cdot (A \oplus B)_{(\alpha)} = \bigcup_{\alpha=0}^1 \alpha \cdot (A_{(\alpha)} + B_{(\alpha)})$$

$$A \odot B = \bigcup_{\alpha=0}^1 \alpha \cdot (A \odot B)_{(\alpha)} = \bigcup_{\alpha=0}^1 \alpha \cdot (A_{(\alpha)} \cdot B_{(\alpha)}).$$

Ak teda opäť uvažujeme fuzzy čísla  $\tilde{2}$  a  $\tilde{3}$ , tak

$$\tilde{2} \oplus \tilde{3} = \bigcup_{\alpha=0}^1 \alpha \cdot \langle 2\alpha + 3, 5 \rangle \cup \bigcup_{\alpha=0}^1 \alpha \cdot \langle 5, 7 - 2\alpha \rangle$$

$$\tilde{2} \odot \tilde{3} = \bigcup_{\alpha=0}^1 \alpha \cdot \langle \alpha^2 + 3\alpha + 2, 6 \rangle \cup \bigcup_{\alpha=0}^1 \alpha \cdot \langle 6, 12 - 7\alpha + \alpha^2 \rangle.$$

Podobným spôsobom ako súčet alebo súčin dvoch fuzzy čísel je pre fuzzy čísla možné zaviesť aj iné analógie operácií a pojmov bežne používaných pri práci s reálnymi číslami.

To umožňuje rozšíriť už známe matematické alebo výpočtové modely tak, že sú schopné pracovať aj istou neistotou týkajúcou sa ich vstupných parametrov.

## Fuzzy neuróny

Základným stavebným prvkom fuzzy neurónových sietí je fuzzy neurón, ktorý pracuje rovnako ako obyčajný neurón, má však navyše schopnosť vysporiadať sa s fuzzy informáciou.

Podstatný rozdiel medzi oboma typmi neurónov z výpočtového hľadiska spočíva v definícii matematických operácií.

Tie môžu byť vo fuzzy neuróne predstavované

- fuzzy aritmetikou - vstupy aj váhy sú fuzzy čísla a operácie v neuróne sú reprezentované fuzzy aritmetikou,
- operáciami fuzzy logiky - vstupy a váhy sú z intervalu  $\langle 0, 1 \rangle$  a neurónové operácie sú vyjadrené pomocou operácií fuzzy logiky.

## Fuzzy neuróny

Neurón predstavuje zobrazenie  $\nu: \mathbb{R}^n \rightarrow \mathbb{R}$ , ktoré je možné vyjadriť ako

$$\nu(\mathbf{x}) = \Psi(\Lambda(\mathbf{x}, \mathbf{w})),$$

kde  $\mathbf{x} \in \mathbb{R}^n$  reprezentuje  $n$ -rozmerný vstup do neurónu,  $\mathbf{w}$  je vektor váh,  $\Psi: \mathbb{R} \rightarrow \mathbb{R}$  je nejaká nelineárna prenosová funkcia a  $\Lambda: \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$  je funkcia vyjadrujúca mieru podobnosti vektorov  $\mathbf{x}$  a  $\mathbf{w}$ . V prípade, že agregáčná funkcia  $\Lambda$  je reprezentovaná skalárnym súčinom, tak pre výstup  $y$  neurónu platí:

$$y = \nu(\mathbf{x}) = \Psi\left(\sum_{i=1}^n x_i w_i\right). \quad (5)$$

Tento neurón využijeme ako základ na demonštráciu oboch typov fuzzy neurónu.

Vstupy v bežných neuronových sieťach sú konkrétne hodnoty z intervalov  $I_1, \dots, I_n$  transformované do intervalov  $\langle 0, 1 \rangle$ , prípadne  $\langle -1, 1 \rangle$ .

V niektorých prípadoch je výhodnejšie zostrojiť nad jednotlivými intervalmi  $I_j$  niekoľko fuzzy množín a ako vstupy do siete uvažovať stupne príslušnosti týchto fuzzy množín.

Vektor vstupných signálov  $\mathbf{x}$  do neurónu je teda v tomto prípade ohraničený jednotkovou hyperkockou  $\langle 0, 1 \rangle^n$ . Podobne aj vektor váh  $\mathbf{w}$  uvažujeme z  $\langle 0, 1 \rangle^n$ .

## Norma a konorma

Binárna operácia **T** v reálnom intervale  $\langle 0, 1 \rangle$  sa nazýva *t*-norma, akk:

- je asociatívna a komutatívna,
- je neklesajúca v prvom – a teda v každom – argumente,
- má 1 ako neutrálny prvok,  $T(u, 1) = T(1, u) = u$ , pre každé  $u$  patriace do  $\langle 0, 1 \rangle$ .

Binárna operácia **S** v reálnom intervale  $\langle 0, 1 \rangle$  sa nazýva *t*-konorma, akk:

- je asociatívna a komutatívna,
- je neklesajúca v oboch argumentoch,
- má 0 ako neutrálny prvok,  $S(u, 0) = S(0, u) = u$ , pre každé  $u$  patriace do  $\langle 0, 1 \rangle$ .

Matematické operácie na týchto signáloch sú reprezentované zovšeobecnenými pravdivostnými funkciami konjunkcie, disjunkcie, negácie, prípadne implikácie.

Ak vo vzťahu (5) nahradíme operátor  $\cdot$   $t$ -normou  $\mathbf{t}$  a operátor  $+$  príslušnou  $t$ -konormou  $\mathbf{s}_t = \mathbf{s}$ , potom mieru podobnosti vektorov  $\mathbf{x}$  a  $\mathbf{w}$  môžeme vyjadriť ako

$$\Lambda(\mathbf{x}, \mathbf{w}) = \mathbf{s}_{i=1}^n (x_i \mathbf{t} w_i) \in \langle 0, 1 \rangle. \quad (6)$$

Výstup  $y$  tohoto neurónu bude

$$y = \nu(\mathbf{x}) = \Psi\left(\mathbf{s}_{i=1}^n (x_i \mathbf{t} w_i)\right) \in \langle 0, 1 \rangle,$$

kde  $\Psi$  je nejaká nelineárna aktivačná funkcia.

- Jednou z charakteristických vlastností funkcie  $\Lambda$  je to, že je neklesajúca. To znamená, že pre ľubovoľné dva vektory  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$  také, že  $x_i \leq y_i, i = 1, \dots, n$ , platí  $\Lambda(\mathbf{x}, \mathbf{w}) \leq \Lambda(\mathbf{y}, \mathbf{w})$ .
- Skutočne, vzhľadom na to, že  $t$ -norma aj  $s$ -konorma sú neklesajúce funkcie, je aj funkcia  $\Lambda$  neklesajúca.
- Funkcia  $\Psi$  je sigmoidálna, čiže tiež neklesajúca, preto aj funkcia  $\nu$  je neklesajúca.
- Každý takto definovaný fuzzy neurón teda predstavuje neklesajúcu funkciu.



- Ak takéto fuzzy neuróny zoskupíme do jednej vrstvy, tá bude tiež predstavovať neklesajúce zobrazenie.
- Vzhľadom na to, že vo viacvrstvových sieťach sú vstupmi do neurónov buď vstupy z vonkajšieho sveta (pre vstupnú vrstvu), alebo výstupy neurónov z predchádzajúcej vrstvy (pre vyššie vrstvy), aj viacvrstvová sieť zložená z takýchto neurónov predstavuje neklesajúce zobrazenie.
- Znamená to teda, že takýmito sieťami je možné aproximovať nanajvýš neklesajúce funkcie. Na odstránenie tohoto obmedzenia je potrebné zvoliť inú funkciu, ktorá by vyjadrovala mieru podobnosti vektorov  $\mathbf{x}$  a  $\mathbf{w}$ .

## Príklad

$$\Lambda_1(\mathbf{x}, \mathbf{w}) = \prod_{i=1}^n (1 - |x_i - w_i|) = \prod_{i=1}^n (\xi_1(x_i, w_i)) \quad \text{alebo}$$

$$\begin{aligned} \Lambda_2(\mathbf{x}, \mathbf{w}) &= \prod_{i=1}^n \left[ \frac{1}{2} \left( (x_i \phi_{\mathbf{t}} w_i) \mathbf{t}(w_i \phi_{\mathbf{t}} x_i) + (\mathbf{n}_{\mathbf{t}}(x_i) \phi_{\mathbf{t}} \mathbf{n}_{\mathbf{t}}(w_i)) \mathbf{t}(\mathbf{n}_{\mathbf{t}}(w_i) \phi_{\mathbf{t}} \mathbf{n}_{\mathbf{t}}(x_i)) \right) \right] \\ &= \prod_{i=1}^n (\xi_2(x_i, w_i)), \end{aligned}$$

pričom

$$\begin{aligned} \mathbf{n}_{\mathbf{t}}(z) &= n_{\mathbf{tL}}(z) = 1 - z, \\ \phi_{\mathbf{t}}(u, v) &= \phi_{\mathbf{tG}}(u, v) = \begin{cases} 1 & \text{ak } u \leq v \\ v & \text{ak } u > v. \end{cases} \end{aligned}$$

## Príklad - pokračovanie

O  $\Lambda_1$  ukážeme, že nie je monotónna v prípade, že  $s = \max$ . Pre jednoduchosť sa obmedzíme na dvojrozmerný prípad.

Potrebuje nájsť trojicu bodov  $\mathbf{x} < \mathbf{y} < \mathbf{z}$  takých, že

$$\Lambda_1(\mathbf{x}) < \Lambda_1(\mathbf{y}) \quad \& \quad \Lambda_1(\mathbf{y}) > \Lambda_1(\mathbf{z}).$$

Vezmime  $\mathbf{y} = \mathbf{w} = (w_1, w_2)$ ,  $\mathbf{x} = (w_1 - \delta, w_2 - \delta)$ ,  $\mathbf{z} = (w_1 + \delta, w_2 + \delta)$  pre nejaké vhodné  $\delta > 0$ . Potom platí

$$1 - |y_1 - w_1| = 1 - |y_2 - w_2| = 1,$$

$$1 - |x_1 - w_1| = 1 - |x_2 - w_2| = 1 - \delta < 1,$$

$$1 - |z_1 - w_1| = 1 - |z_2 - w_2| = 1 - \delta < 1.$$

Z týchto vzťahov a definície funkcie  $\Lambda_1$  vyplýva, že

$$\Lambda_1(\mathbf{x}) < \Lambda_1(\mathbf{y}) \quad \& \quad \Lambda_1(\mathbf{z}) < \Lambda_1(\mathbf{y}).$$

Čo sme chceli ukázať.

## Štruktúra fuzzy neurónových sietí založených na fuzzy aritmetike

- Budeme využívať niektoré poznatky z oblasti fuzzy aritmetiky.
- Štruktúra fuzzy neurónových sietí tohoto typu je opäť rovnaká ako u bežných neurónových sietí, avšak vstupy do neurónov, váhy, ako aj výstupy z neurónov sú fuzzy čísla.
- V tomto prípade fuzzy neurón predstavuje zobrazenie  $\nu : \Gamma^n \rightarrow \Gamma$ , pričom  $\Gamma$  označuje množinu všetkých reálnych fuzzy čísel.
- Agregáčnú a prenosovú funkciu fuzzy neurónu získame z agregáčnej a prenosovej funkcie klasického neurónu pomocou princípu rozšírenia.
- Takéto fuzzy neurónové siete sú v literatúre označené ako regulárne fuzzy neurónové siete, skrátene FNN.

- V prípade, že umožníme, aby agregáčn é a prenosové funkcie boli definované aj inak, než z príslušných funkcií klasického neurónu cez princíp rozšírenia a tiež, aby sa v sieti mohli vyskytovať aj klasické neuróny, dostávame sieť, ktorú v literatúre označujú ako hybridnú fuzzy neurónovú sieť, skrátene HFNN.
- Je to teda sieť, ktorej vstupy aj výstupy sú fuzzy čísla, avšak vnútorná štruktúra siete je hybridná. To znamená, že sa v sieti môžu vyskytovať
  - a) vyššie uvažované fuzzy neuróny,
  - b) neuróny, ktorých vstupmi aj výstupmi môžu byť ako reálne čísla, tak aj fuzzy čísla,
  - c) klasické neuróny.

Kedže sa v sieti môžu vyskytovať aj neuróny typu b), c), upustíme aj od požiadavky, aby všetky váhy boli fuzzy čísla.

Vstupy do siete sú fuzzy čísla  $N, M$ . Neuróny vo vstupnej vrstve predstavujú identické zobrazenie, teda výstup z neurónu  $N_1$  je  $N$ , z neurónu  $N_2$  je  $M$ . Výstupom agregáčnej funkcie  $\Lambda_3$  neurónu  $N_3$  je


$$\Lambda_3(N, M, W_{13}, W_{23}) = L_3 = (N \odot W_{13}) \oplus (M \odot W_{23}), \quad (7)$$

kde  $\odot, \oplus$  predstavujú fuzzy súčin, resp. súčet získaný princípom rozšírenia. To znamená, že ak označíme  $P = A \oplus B$  a  $Q = A \odot B$ , tak

$$\mu_P(z) = \sup_{z=x+y} (\mu_A(x) \mathbf{t} \mu_B(y)), \quad (8)$$

$$\mu_Q(z) = \sup_{z=x \cdot y} (\mu_A(x) \mathbf{t} \mu_B(y)). \quad (9)$$

## Príklad



*Príklad jednoduchej fuzzy neurónovej siete.*

Podobne pre neurón  $N_4$

$$\Lambda_4(N, M, W_{14}, W_{24}) = L_4 = (N \odot W_{14}) \oplus (M \odot W_{24}).$$

Prenosové funkcie neurónov  $N_3$ ,  $N_4$  a  $N_5$  uvažujeme rovnaké  $\Psi_3 = \Psi_4 = \Psi_5 = \Psi$ , získané napríklad z funkcie  $f : \mathbb{R} \rightarrow \mathbb{R}$ ,  $f(x) = (1 + e^{-x})^{-1}$  princípom rozšírenia. Výstup  $O_3$  neurónu  $N_3$  je teda

$$O_3 = \Psi(L_3), \quad (10)$$

podobne výstupom neurónu  $N_4$  je

$$O_4 = \Psi(L_4).$$



Výstupom neurónu  $N_5$  je

$$Y = \Psi(L_5),$$

kde

$$L_5 = \Lambda_5(O_3, O_4, W_{35}, W_{45}) = (O_3 \odot W_{35}) \oplus (O_4 \odot W_{45}).$$

Táto FNN teda zobrazuje  $(N, M)$  na  $Y$  (fuzzy číslo v  $\langle 0, 1 \rangle$ ), čo budeme označovať  $Y = FNN(N, M)$ .