

## Projekce a cylindrické rozšíření

Nechť  $R$  je fuzzy relace definovaná relační maticí (1, 2. a totální projekce jsou ukázané):

$R$ :

	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	*
$x_1$	0.1	0.2	0.4	0.8	1.0	0.8	1
$x_2$	0.2	0.4	0.8	1.0	0.8	0.6	1
$x_3$	0.4	0.8	1.0	0.8	0.4	0.2	1
	0.4	0.8	1	1	1	0.8	(1) totální proj.

1. proj.

2. proj.

Výsledná relace (výsledek projekce) se také nazývá "stín".

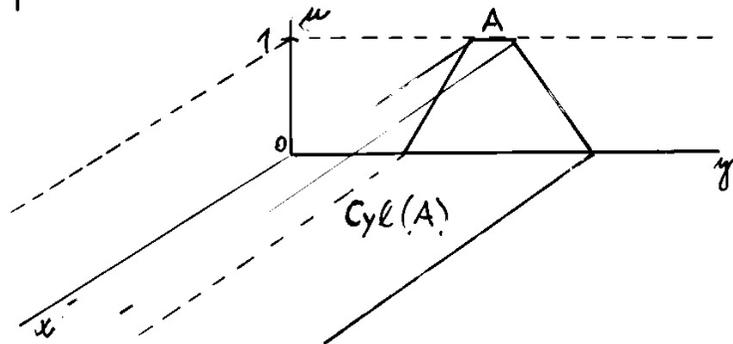
Definice (cylindrické rozšíření):

$R_{QL} \subseteq X$  je největší relací na  $X$ , jejíž projekce je  $R_q$ .  $R_{QL}$  se nazývá cylindrickým rozšířením  $R_q$  a  $R_q$  se nazývá bází  $R_{QL}$ .

Příklad (viz výše): cyl. rozšíření druhé projekce je:

$Cyl(R_2)$ :

	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$
$x_1$	0.4	0.8	1	1	1	0.8
$x_2$	0.4	0.8	1	1	1	0.8
$x_3$	0.4	0.8	1	1	1	0.8



## Lingvistické proměnné

Jedním ze základních nástrojů ve fuzzy logice a přibližném usuzování je pojem lingvistická proměnná:

Definice lingvistické proměnné: (L. Zadeh, 1973)

Lingvistická proměnná je charakterizována pětici  $(x, T(x), U, G, \tilde{M})$ , kde  $x$  je název proměnné;  $T(x)$  nebo zjednodušeně  $T$  označuje tzv. množinu termů proměnné  $x$ , což je množina tzv. lingvistických hodnot pro  $x$ ;  $U$  je universum asociované s tzv. bázevovou proměnou  $w \in U$ ;  $G$  je syntaktické pravidlo (obvykle gramatika) pro generování jména  $X$  proměnné  $x$ ;  $M$  je sémantické pravidlo, které každému jménu  $X$  přiřazuje význam  $\tilde{M}(X)$ , což je fuzzy podmnožina na  $U$ . Konkrétní  $X$  (tj. jméno generované pomocí  $G$ ) se nazývá term.

Příklad:

Nechť  $X$  je lingvistická proměnná s označením "věk" a  $U = [0, 100]$ . Termy této lingvistické proměnné, což jsou fuzzy množiny, mohou být nazvány "starý", "mladý", "velmi starý", atd. Bázevová proměnná je věk udaný v letech života.  $\tilde{M}(X)$  je pravidlo přiřazující význam, tj. fuzzy množinu každému termu:

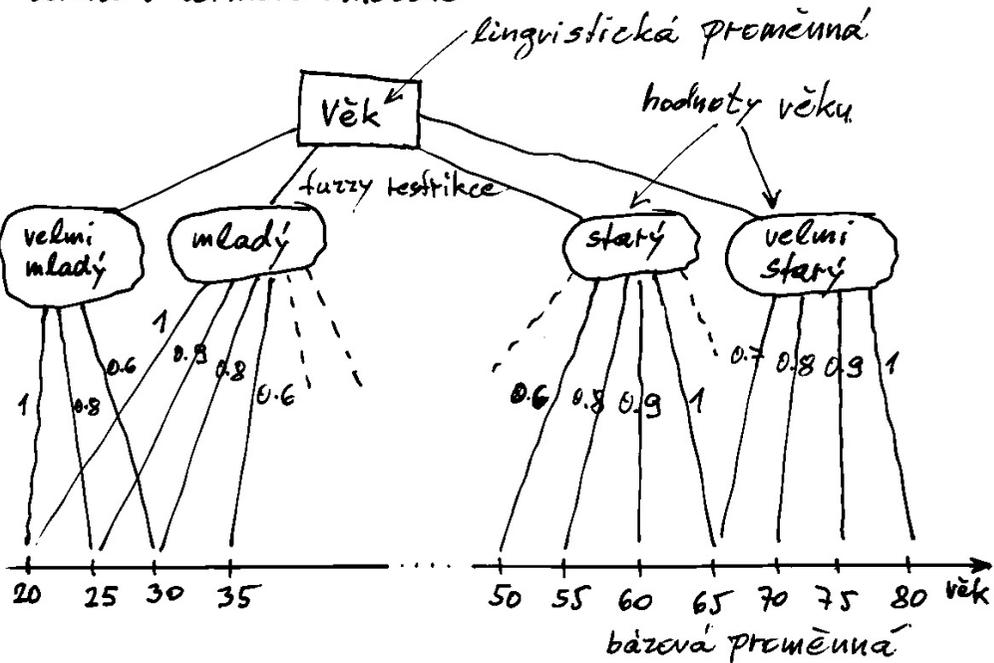
$$\tilde{M}(\text{starý}) = \left\{ (w, \mu_{\text{starý}}(w)), w \in [0, 100] \right\} \text{ kde}$$

$$\mu_{\text{starý}}(w) = \begin{cases} 0 & \text{pro } w \in [0, 50] \\ \left( 1 + \left( \frac{w-50}{5} \right)^{-2} \right)^{-1} & \text{pro } w \in [50, 100] \end{cases}$$

$T(x)$  definuje množinu termů proměnné  $x$ , např.:

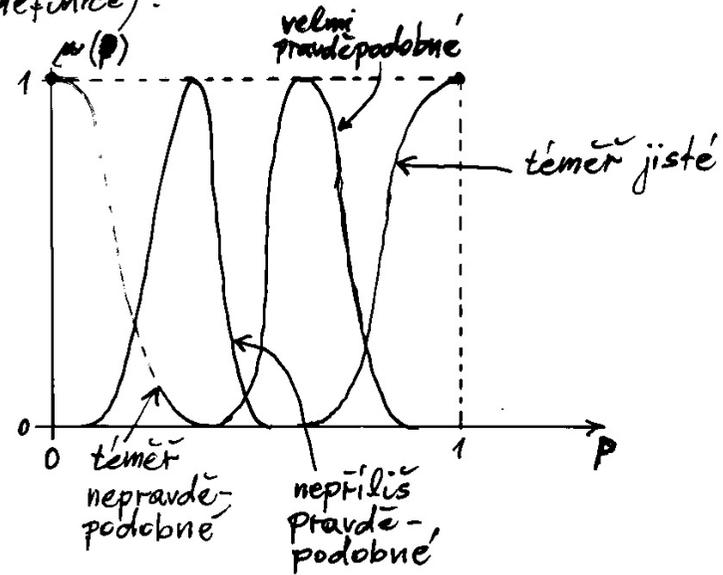
$T(\text{věk}) = \{ \text{starý, velmi starý, nepříliš starý,} \\ \text{vice-méně starý, vice-méně mladý,} \\ \text{zcela mladý, velmi mladý} \}$

přičemž  $G(x)$  je pravidlo pro generování označení termů v termové množině.

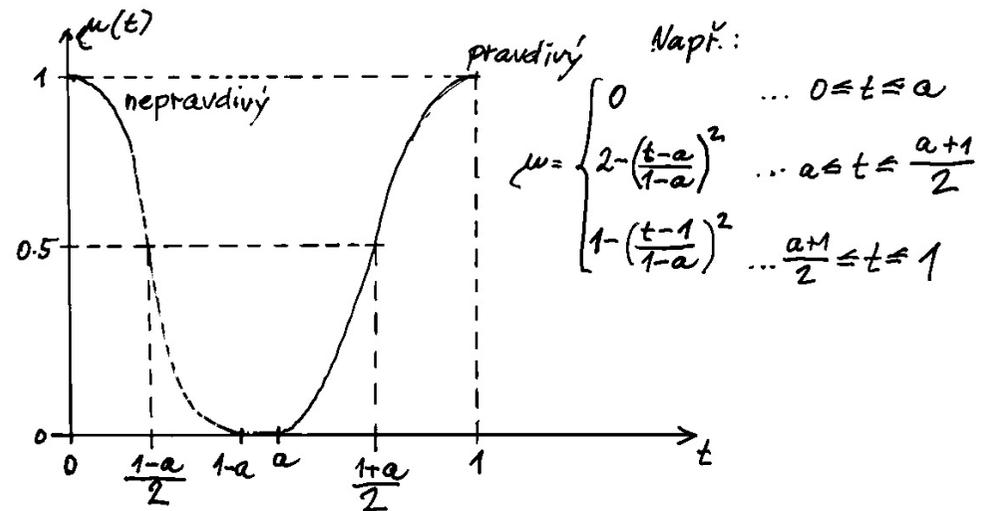


## Některé lingvistické proměnné

Pravděpodobnost - fuzzy vyjádření (příklad možné definice):



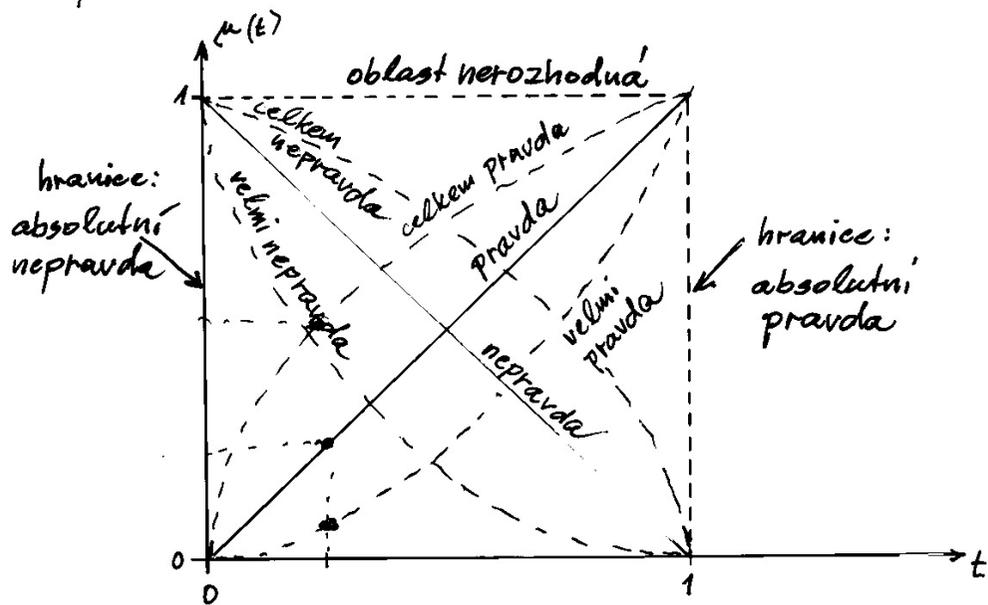
## Pravda



Možný způsob odvozování funkcí příslušnosti pro fuzzy hodnoty fuzzy proměnné  $T$ :

$T(\text{Pravda}) = \{ \text{pravda, nepravda, velmi pravdivý, nepříliš pravdivý, \dots, nepříliš nepravdivý, více-méně nepravdivý, \dots} \}$

Lze vyjít ze základní definice „fuzzy“ pravda a nepravda a aplikovat modifikátory jako velmi apod.:



## t-normy

Triangulární normy (t-normy) tvoří širokou třídu logických spojek pro realizaci průniku a sjednocení.

Def.: t-norma je funkce dvou argumentů:

- $t: [0, 1] \times [0, 1] \rightarrow [0, 1]$

taková, že:

a) je v každém argumentu neklesající

$$x \leq y, w \leq z, \text{ pak } x t w \leq y t z$$

b) je komutativní  $x t y = y t x$

c) je asociativní  $(x t y) t z = x t (y t z)$

d) splňuje ohraničující podmínky

$$x t 0 = 0, x t 1 = x, x, y, z, w \in [0, 1]$$

Def.: s-norma (t-konorma) je funkce 2 arg.:

- $s: [0, 1] \times [0, 1] \rightarrow [0, 1]$

taková, že:

a) je neklesající v každém argumentu

b) je komutativní

c) je asociativní

d) splňuje ohraničující podmínky

$$x s 0 = x, x s 1 = 1$$

t-normy korespondují s průnikem (AND), s-normy se sjednocením (OR).

s-normu lze odvodit z t-normy pomocí vztahu:

$$x s y = 1 - ((1-x) t (1-y))$$

## Některé ze základních t-norem

minimum  $\text{MIN}(a, b) = \min\{a, b\} = a \wedge b$

Lukasiewicz  $\text{LAND}(a, b) = \max\{a + b - 1, 0\}$

pravděpod. součin (algebr. součin)  $\text{PAND}(a, b) = a \cdot b$

slabší  $\text{WEAK}(a, b) = \begin{cases} a \wedge b & \text{když } a \vee b = 1 \\ 0 & \text{jinak} \end{cases}$

Hamacher  $(\gamma \geq 0)$   $H_\gamma(a, b) = \frac{ab}{(\gamma + (1-\gamma)(a+b-ab))}$

Dubois & Prade  $(\alpha \in ]0, 1[)$   $\delta_\alpha(a, b) = \frac{ab}{\max\{a, b, \alpha\}}$

?  $(p \geq 1)$   $a \dot{\wedge} b = 1 - \min\left[1, \left((1-a)^p + (1-b)^p\right)^{1/p}\right]$

?  $(0 < w < \infty, w \neq 1)$   $a \dot{\wedge} b = \log_w \left[1 + \frac{(w^a - 1)(w^b - 1)}{(w - 1)}\right]$

?  $(\lambda \geq -1)$   $a \dot{\wedge} b = \max\left[0, (\lambda + 1)(a + b - 1) - \lambda ab\right]$

Všechny t-normy mohou být (pomocí asociativity) rozšířeny na  $n > 2$  argumenty, např.:

$\text{MIN}(a_1, \dots, a_n) = a_1 \wedge a_2 \wedge \dots \wedge a_n$

$\text{PAND}(a_1, \dots, a_n) = a_1 \cdot a_2 \cdot \dots \cdot a_n$   $\left[ \text{LAND}(a_1, \dots, a_n) = \max\left\{\sum_{i=1}^n a_i - n + 1, 0\right\} \right]$

## Některé ze základních s-norem

maximum  $\text{MAX}(a, b) = \max\{a, b\}$

Lukasiewicz  $\text{LOR}(a, b) = \min\{a + b, 1\}$

pravděpod. součet  $\text{POR}(a, b) = a + b - ab$

silnější  $\text{STRONG}(a, b) = \begin{cases} a \vee b & \text{když } a \wedge b = 0 \\ 1 & \text{jinak} \end{cases}$

Hamacher  $(\gamma \geq 0)$   $a \dot{\vee} b = \frac{ab(\gamma - 2) + a + b}{ab(\gamma - 1) + 1}$

?  $(p \geq 1)$   $a \dot{\vee} b = \min\left(1, (a^p + b^p)^{1/p}\right)$

?  $(0 < w < \infty, w \neq 1)$   $a \dot{\vee} b = 1 - \log_w \left[1 + \frac{(w^{1-a} - 1)(w^{1-b} - 1)}{(w - 1)}\right]$

?  $(\lambda \geq -1)$   $a \dot{\vee} b = \min\{1, a + b + \lambda ab\}$

Podobně jako t-normy, lze rozšířit i s-normy na  $n > 2$  argumentů, např.:

$\text{MAX}(a_1, \dots, a_n) = a_1 \vee a_2 \vee \dots \vee a_n = \bigvee_{i=1}^n a_i$

Pro každou  $t$ -normu platí nerovnost:

$$x \wedge y \geq x \dot{+} y \geq \begin{cases} x & \text{když } y=1 \\ y & \text{když } x=1 \\ 0 & \text{jinak} \end{cases}$$

tj. třída  $t$ -normem je ohraničená (shora minimumem, zdola tzv. drastickým součinem).

Podobně pro  $s$ -normy platí:

$$x \vee y \leq x \dot{-} y \leq \begin{cases} x & \text{když } y=0 \\ y & \text{když } x=0 \\ 1 & \text{jinak} \end{cases}$$

Ohraničení shora je tzv. drastickým součtem a zdola maximumem.

Některé  $t$ -normy ( $s$ -normy) obsahují parametry. Volbou parametrů lze modifikovat charakter logických spojek. Např.:

$p=0$  pak  $a \dot{+} b$  se redukuje na drast. součin

$p \rightarrow \infty$  dává minimum

$p=0$  pak  $a \dot{-} b$  se redukuje na drast. součet

$p \rightarrow \infty$  dává maximum

Pozn.: Velmi známé Łukasiewiczovy spojky (pocházející z jeho teorie vícehodnotové logiky) mohou být odvozeny pomocí nastavení  $\lambda$ :

$$\lambda=0: a \dot{+} b = \max(0, a + \frac{b}{\lambda} - 1)$$

$$a \dot{-} b = \min(1, a + b)$$

Nekonečná třída  $t$ -normem (včetně parametrických verzí) dává široký repertoár formálních modelů logických spojek.

Konkrétní výběr operátorů AND (konjunkce) a OR (disjunkce) závisí na typu řešeného problému.

$\wedge$  a  $\vee$  způsobují, že jakmile jeden z argumentů má hodnotu (funkce příslušnosti) větší než ostatní (pro  $\vee$ ) nebo menší než ostatní (pro  $\wedge$ ), pak ty "ostatní" hodnoty nemají žádný vliv na výsledek. Jinými slovy, mezi argumenty není žádná interaktivita.

Výhodou zde je, že nejsou zapotřebí žádné přesné hodnoty funkce příslušnosti - stačí hrubý odhad (chyby měřicího postupu mohou být do velké míry ignorovány). To vede k tzv. robustnosti.

Na druhé straně „necitlivost“ robustních systémů se může ukázat jako nevýhoda když takto získané výsledky neodpovídají charakteru kombinovaných dat a jejich vzájemné interakci. Proto je zapotřebí mít k dispozici různé možnosti (úrovně) interakce.

Př.: nízká cena řízení AND vysoká přesnost sledování

Obě složky (cena, přesnost) představují různé cíle určité řídicí strategie. Formulace problému se spojkou AND indikuje interakci mezi dvěma navzájem konfliktními cíly. Proto zde není vhodné použít  $\wedge$ , nýbrž kupř.  $*$  (algebr. součin).

Př.: nový AND rychlý automobil

Zde není interakce mezi novým a rychlým zřejmá. Proto je v takovém případě použití  $\wedge$  přiměřené.

### Kompenzační operátory

Existuje-li operátor  $C$  takový, že platí:

$$\min \{a, b\} \leq C(a, b) \leq \max \{a, b\}$$

$$\forall a, b \in [0, 1]$$

pak o takovém operátoru říkáme, že je to kompenzační operátor.

## FUZZY IMPLIKACE

### Materiální implikace

Ostré propozice:  $p = "x \text{ je v } A"$  a  $q = "y \text{ je v } B"$   
( $A$  a  $B$  jsou zde klasické množiny.)  
Zápis implikace  $p \rightarrow q$  je interpretován jako  $\neg(p \wedge \neg q)$ , tj.  $p \rightarrow q \equiv \neg p \vee q$ .

Stupeň pravdivosti  $p \rightarrow q$  kvantifikuje, do jaké míry je  $q$  přinejmenším tak pravdivé jako  $p$ :

$$p \rightarrow q \text{ je pravda} \Leftrightarrow \tau(p) \leq \tau(q)$$

$$p \rightarrow q = \begin{cases} 1 & \text{jestliže } \tau(p) \leq \tau(q) \\ 0 & \text{v ostatních případech} \end{cases}$$

Pravdivostní tabulka implikace:

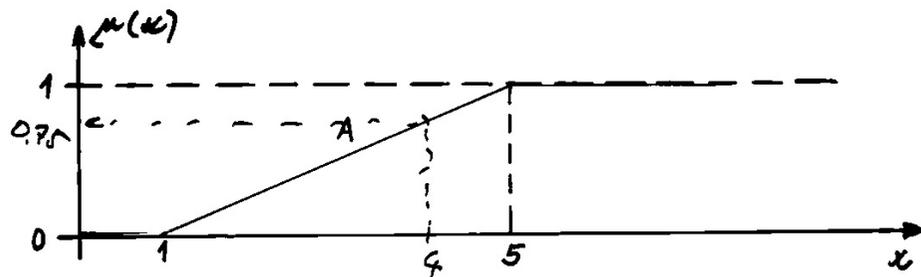
$p$	$q$	$p \rightarrow q$
1	1	1
0	1	1
0	0	1
1	0	0

Př.:  $p = "x \text{ je větší než } 10"$ ,  $q = "x \text{ je větší než } 9"$ .  
 $p \rightarrow q$  je pravdivé (nemůže se stát, že  $x > 10$  a zároveň  $x \leq 9$ ).

~~prší~~ prší  $\rightarrow$  je zataženo

## Fuzzy implikace

Uvažme výrok „jestliže je tlak vysoký pak objem je malý“. Funkce příslušnosti fuzzy množiny A, tj. lingvistická hodnota „vysoký tlak“, ilustruje obrázek:



Fuzzy množinu A lze interpretovat takto:

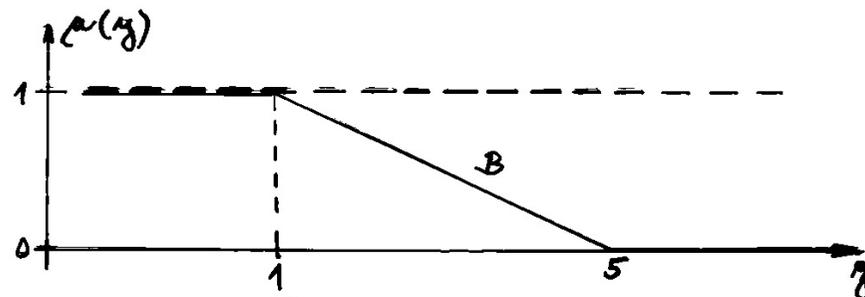
- 1 je v A se stupněm příslušnosti 0.0
- 2 je v A ————— " ————— 0.25
- 4 je v A ————— " ————— 0.75
- x je v A ————— " ————— 1.0  $\forall x \geq 5$

$$A(x) = \begin{cases} 1 & \text{pro } x \geq 5 \\ 1 - \frac{5-x}{4} & \text{pro } 1 \leq x \leq 5 \\ 0 & \text{ostatní případy} \end{cases}$$

Podobně lze interpretovat fuzzy množinu B „malý objem“:

- 5 je v B se stupněm příslušnosti 0.0
- 4 je v B ————— " ————— 0.25
- 2 je v B ————— " ————— 0.75
- x je v B ————— " ————— 1.0  $\forall x \leq 1$

Ilustrace fuzzy množiny B:



$$B(y) = \begin{cases} 1 & \text{pro } y \leq 1 \\ 1 - \frac{y-1}{4} & \text{pro } 1 \leq y \leq 5 \\ 0 & \text{jinak} \end{cases}$$

Je-li p propozice x je A, kde A je fuzzy množina, např. velký tlak, a q propozice y=B, např. malý objem, pak se často používá fuzzy implikace definované jako fuzzy relace:

$$(A \rightarrow B)(x, y) = A(x) \rightarrow B(y)$$

(Existují i jiné definice fuzzy implikace.)

x je velký tlak  $\rightarrow$  y je malý objem  $\equiv A(x) \rightarrow B(y)$

Jedním z možných rozšíření materiálu implikace na implikace s pravdivostními hodnotami mezi 0 a 1:

$$A(x) \rightarrow B(y) = \begin{cases} 1 & \text{pro } A(x) \leq B(y) \\ 0 & \text{jinak} \end{cases}$$

„4 je velký tlak“  $\rightarrow$  „1 je malý objem“ =

$$A(4) \rightarrow B(1) = 0.75 \rightarrow 1 = 1$$

(tzv. standardní striktní fuzzy implikace)

Striktní fuzzy implikace se v mnoha případech ukazuje jako nevhodná pro reálné aplikace:

$$A(x) \rightarrow B(y) = 0.8 \rightarrow 0.8 = 1$$

Existoval-li by malá chyba měření  $B(y)$ , pak můžeme např. dostat:

$$A(x) \rightarrow B(y) = 0.8 \rightarrow 0.7999 = 0$$

Je to ukázka toho, jak nepatrná chyba měření nebo malá změna na vstupu může způsobit velkou odchylku na výstupu: Systém je velmi citlivý na zaokrouhlovací chyby digitálních výpočtů a na malé chyby měření.

"Jemnější" extenze materiální implikace pochází od Gödela:

$$A(x) \rightarrow B(y) = \begin{cases} 1 & \text{pro } A(x) \leq B(y) \\ B(y) & \text{jinak} \end{cases}$$

Další možností je rozšíření původní definice operátoru implikace:  $p \rightarrow q \equiv \neg p \vee q$  za použití definic standardní negace a fuzzy množinového sjednocení:

$$A(x) \rightarrow B(y) = \max\{1 - A(x), B(y)\}$$

Tento operátor se nazývá Kleene-Dienesova implikace.

## Fuzzy logika a klasická logika

V klasické logice je výrok  $A$  či  $B$  buď zcela pravdivý nebo zcela nepravdivý (tj. má konvenční ohodnocení 1 nebo 0). Lze konstruovat pravdivostní tabulky, definující logické operátory ( $\wedge, \vee, \rightarrow, \dots$ ). Existuje (či lze vytvořit)  $2^2 = 16$  pravdivostních tabulek.

Není-li možné jasně označit  $A$  či  $B$  jako zcela pravdivé či zcela nepravdivé, lze přidat další pravdivostní hodnoty (např. "nerozhodnutelný", "nevím" apod.). Tento způsob vede k tzv. vícehodnotovým logikám. Poznamenejme, že pro dva výroky a tři pravdivostní hodnoty již lze vytvořit  $3^2 = 729$  pravdivostních tabulek. Snadnost interpretace, unikátní a výhodná např. v boolské logice, tak zcela mizí.

### Usuzovací schémata (procedury)

Jsou obecně založeny na tautologiích, k nimž patří např. tyto čtyři zřejmě nejužívanější:

modus ponens:  $(A \wedge (A \rightarrow B)) \rightarrow B$

modus tollens:  $((A \rightarrow B) \wedge \neg B) \rightarrow \neg A$

sylogismus:  $((A \rightarrow B) \wedge (B \rightarrow C)) \rightarrow (A \rightarrow C)$

kontrapozice:  $(A \rightarrow B) \rightarrow (\neg B \rightarrow \neg A)$

Nejužívanější modus ponens ("potvrzování pomocí potvrzeného") lze interpretovat takto:

Je-li  $A$  pravdivé a výrok "je-li  $A$  pravdivé pak  $B$  je pravdivé" je také pravdivý, pak také  $B$  je pravdivé.

Fuzzy logika je rozšířením vícehodnotové "množinové" logiky, přičemž pravdivostní hodnoty jsou hodnotami lingvistických proměnných.

Rozšířením operátorů jako  $\vee$ ,  $\wedge$ ,  $\neg$ ,  $\rightarrow$  do fuzzy logiky lze získat možnosti "fuzzy" usuzování:

Je-li  $t(A) \in V = [0, 1]$  bodem na jednotkovém intervalu, reprezentujícím pravdivostní hodnotu proposice "u je  $A$ " (nebo jednoduše  $A$ ), pak pravdivostní hodnota "ne  $A$ " neboli  $\neg A$  je definována takto:

$$t(\neg A) = 1 - t(A)$$

Pro numerické pravdivostní hodnoty  $t(A)$  a  $t(B)$  jsou logické operace AND, OR, NOT, IMPLIKACE definovány takto:

$$t(A) \wedge t(B) = t(A \wedge B) = \{t, \min(\mu_A(t), \mu_B(t))\}$$

$$t(A) \vee t(B) = t(A \vee B) = \{t, \max(\mu_A(t), \mu_B(t))\}$$

$$\neg t(A) = t(\neg A) = \{t, 1 - \mu_A(t)\}$$

$$t(A) \rightarrow t(B) = t(A \rightarrow B) = \{t, \max\{1 - \mu_A(t), \mu_B(t)\}\}$$

↓  
tj.  $\neg A \vee B$

## Přibližné usuzování

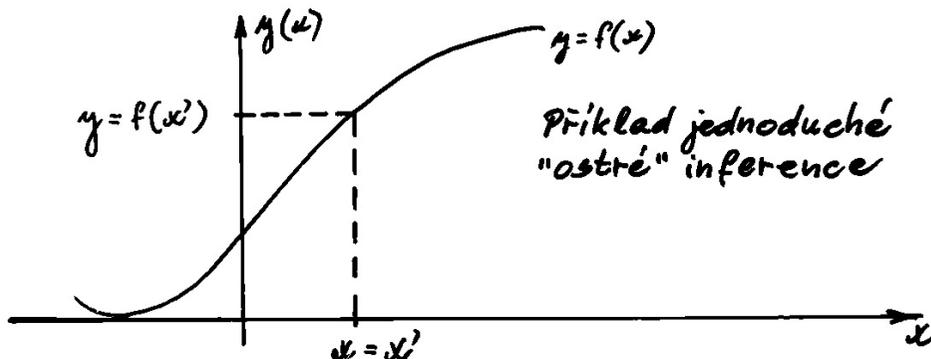
Přibližné usuzování pomocí teorie fuzzy množin pochází od Lotfi Zadeha z r. 1979. Zadehova teorie tvoří základ pro usuzování, je-li k dispozici přibližná, nejistá, vágní, či nepřesná informace. Středobodem Zadehovy teorie je reprezentace proposic jako tvrzení, která proměnným přiřazují fuzzy množiny jako hodnoty.

Předpokládejme, že máme dvě ~~sa~~ veličiny  $x \in X$  a  $y \in Y$  a že kauzální vztah mezi  $x$  a  $y$  je kompletně znám:  $y = f(x)$ .

V takovém případě je snadné inferovat:

premisa	$y = f(x)$
fakt	$x = x'$
zvěř	$y = f(x')$

Uvedené inferenční pravidlo říká, že máme-li  $y = f(x) \forall x \in X$  a existuje-li pozorovaná skutečnost  $x = x'$ , pak  $y$  nabývá hodnoty  $f(x')$ .



Velmi často však neznáme úplný kauzální vztah  $f$  mezi  $x$  a  $y$ , jediné co bývá známo, jsou hodnoty  $f(x)$  pro některé konkrétní hodnoty  $x$ :

$$R_1: \text{IF } x = x_1 \text{ THEN } y = y_1 \text{ OTHERWISE}$$
$$R_2: \text{IF } x = x_2 \text{ THEN } y = y_2 \text{ OTHERWISE}$$

⋮

$$R_n: \text{IF } x = x_n \text{ THEN } y = y_n$$

Předpokládejme, že známe nějakou hodnotu  $x' \in X$  (např. měření) a chceme najít  $y' \in Y$ , korespondující s  $x'$  pomocí báze pravidel:

$R_i: \text{IF } x = x_i \text{ THEN } y = y_i \text{ OTHERWISE ...}$
fakt: $x = x'$
zvěř: $y = y'$

Tento problém ( $x' \neq x_i, \forall i; y' \neq y_i, \forall i$ ) bývá často označován jako interpolace.

Nechť  $x$  a  $y$  jsou lingvistické proměnné (tj. nabývají lingvistických hodnot), např. " $x$  je velké" a " $y$  je malé". Základním problémem je najít funkci příslušnosti konsekventu  $B$  ze znalostní pravidlové báze  $\{R_1, R_2, \dots, R_n\}$  a z faktu  $A'$ :

$R_i: \text{IF } x \text{ je } A_i \text{ THEN } y \text{ je } B_i \dots$
fakt: $x \text{ je } A'$
zvěř: $y \text{ je } B'$

L. Zadeh navrhl množství pravidel, umožňujících reprezentaci některých obecných lingvistických výroků v termínech propozice našeho jazyka:

Příčinné pravidlo:

$x$ je A	Marie je velmi mladá
$A \subset B$	$\text{velmi mladá} \subset \text{mladá}$
$x$ je B	Marie je mladá

Konjunktivní pravidlo:

$x$ je A	tlak není velmi vysoký
$x$ je B	tlak není velmi nízký
$x$ je $A \cap B$	tlak není velmi vysoký a není velmi nízký

Disjunktivní pravidlo:

$x$ je A	tlak není velmi vysoký
OR $x$ je B	OR tlak není velmi nízký
$x$ je $A \cup B$	tlak není velmi vysoký nebo velmi nízký

Projekční pravidlo

$(x, y)$ má relaci R	$(x, y)$ má relaci R
$x$ je $P_x(R)$	$y$ je $P_y(R)$

$(x, y)$ je blízké (3, 2)	$(x, y)$ je blízké (3, 2)
$x$ je blízké 3	$y$ je blízké 2

Negační pravidlo

$\neg (x \text{ je } A)$	$\neg (x \text{ je vysoké})$
$x$ je $\neg A$	$x$ není vysoké

V přibližném usuzování prostřednictvím fuzzy logiky je nejdůležitějším fuzzy inferenčním pravidlem tzv. generalizovaný modus ponens (GMP).

Klasické (ne-fuzzy) inferenční pravidlo modus ponens:

premisa	IF p THEN q
fakt	p
zvěř	q

Toto inferenční pravidlo lze interpretovat takto: Je-li p pravda a  $p \rightarrow q$  je pravda pak q je pravda.

Fuzzy implikační inference je založena na kompozičním pravidle inferencí dle L. Zadeha:

Definice (kompoziční inferenční pravidlo):

premisa	IF $x$ je $A$ THEN $y$ je $B$
fakt	$x$ je $A'$
<hr/>	
závěr	$y$ je $B'$

kde obecně platí  $A' \neq A$  a  $B' \neq B$ . Přitom  $B'$  se učí jako kompozice faktu a fuzzy implikačního operátoru:

$$\underline{B'} = A' \circ (A \rightarrow B) \quad \text{tj.}$$

$$B'(y) = \sup_{x \in X} \min \{ A'(x), (A \rightarrow B)(x, y) \}, \quad y \in Y$$

Konsekvent  $B'$  je projekce  $(A \rightarrow B)$  na  $A'$ .

GMP se redukuje na klasický MP když  $A'=A$  a  $B'=B$ .

Jiným pravidlem odvození je modus tollens, které ve své klasické podobě říká: je-li  $p \rightarrow q$  pravda a  $q$  není pravda, pak  $p$  není pravda. Zobecněné pravidlo GMT:

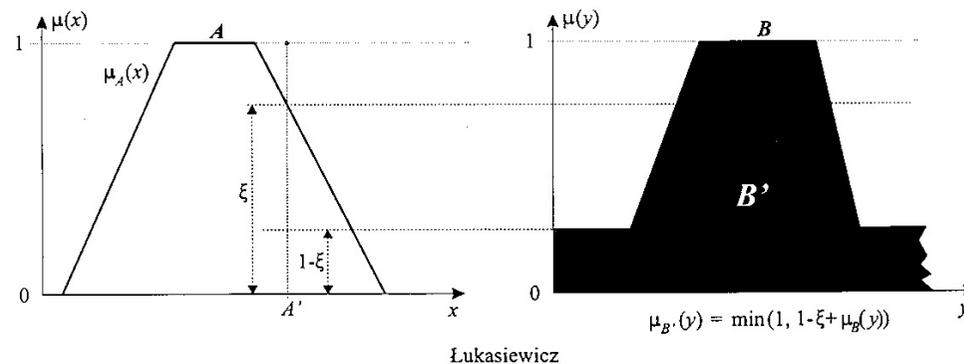
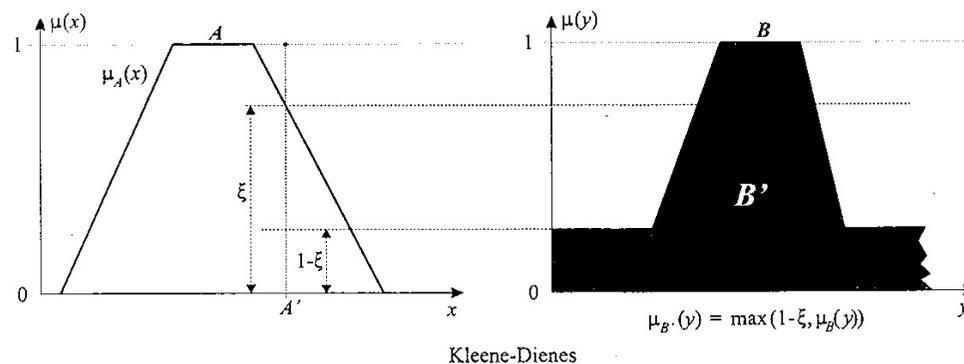
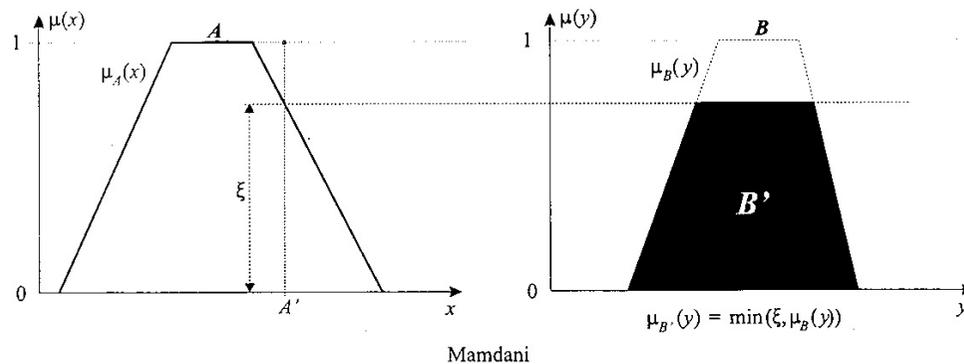
premisa	IF $x$ je $A$ THEN $y$ je $B$
fakt	$y$ je $B'$
<hr/>	
závěr	$x$ je $A'$

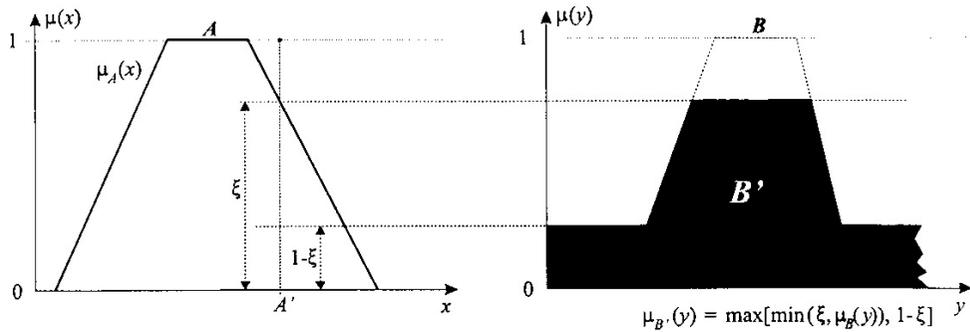
(pro  $B = \neg B$  a  $A' = \neg A$  dostaneme klasický MT)

IF  $x$  je  $A$  THEN  $y$  je  $B$   
 $x$  je  $A'$   

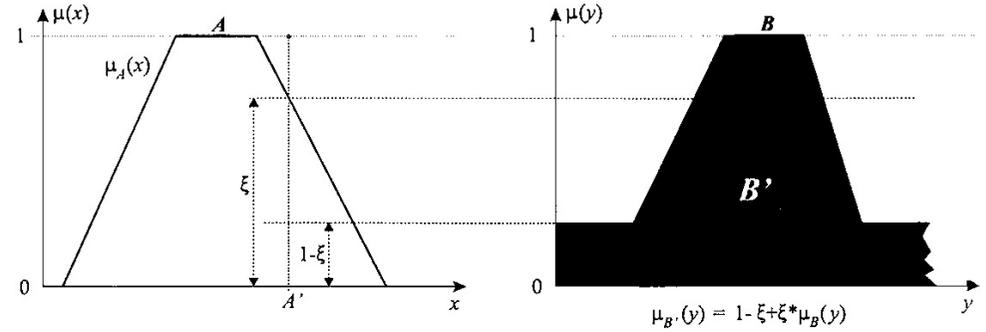

---

 $y$  je  $B'$

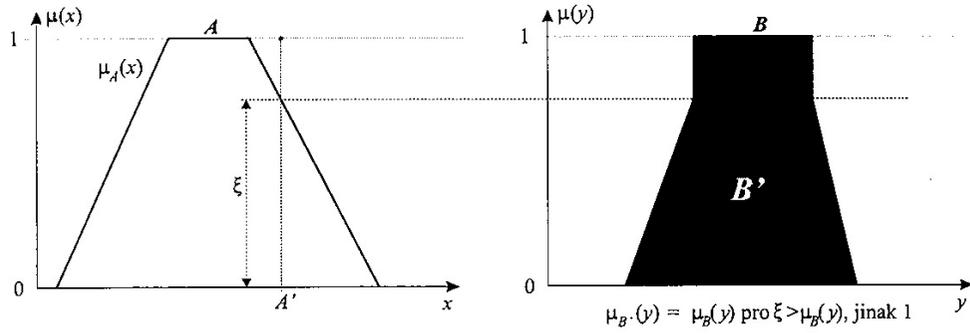




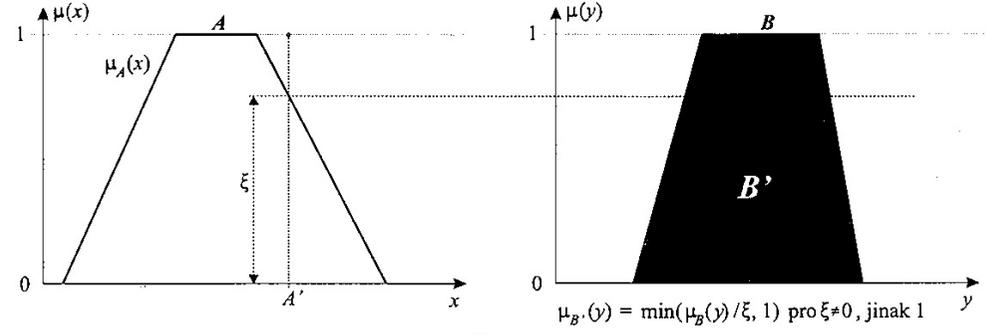
Zadeh-Willmott



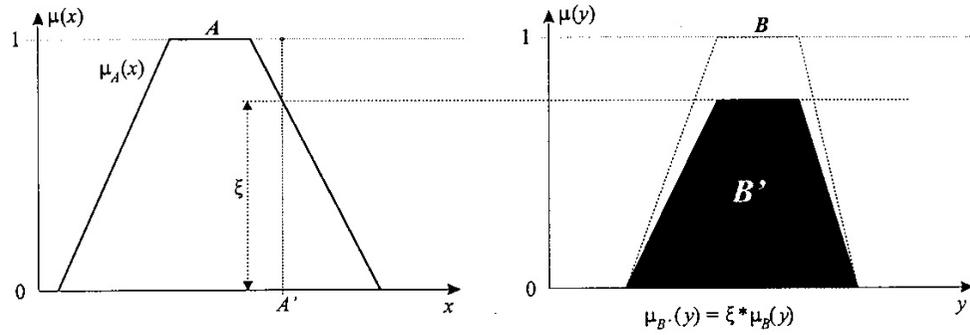
Reichenbach



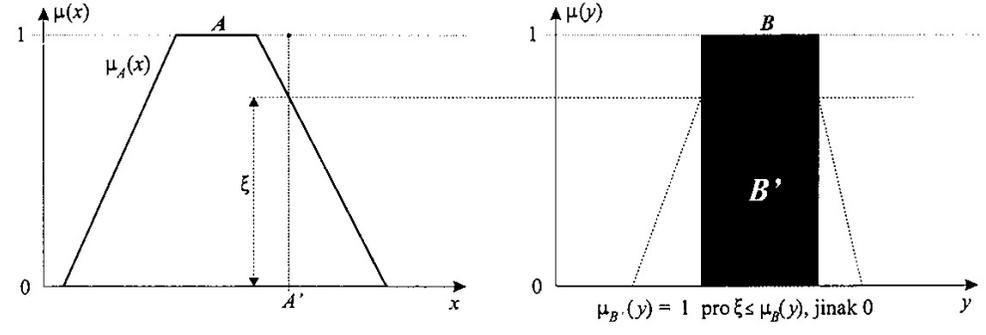
Brouwer-Gödel



Goguen



Larsen



Rescher-Gaines

## Přibližné usuzování pomocí GMP

Nechť  $A, A', B, B', C, C', D, D'$  jsou fuzzy množiny.  
GMP říká:

premisa	$x$ je $A'$
implikace	IF $x$ je $A$ THEN $y$ je $B$
závěr	$y$ je $B'$

Pomocí této implikace a různých premis získáme různé závěry:

viditelnost je poněkud nízká  
IF viditelnost je nízká THEN podmínky jsou špatné  
∴ podmínky jsou poněkud špatné

modifikátor      fuzzy množina

viditelnost je velmi nízká  
IF viditelnost je nízká THEN podmínky jsou špatné  
∴ podmínky jsou velmi špatné

Fuzzy množiny: nízká ≠ poněkud nízká  
špatné ≠ poněkud špatné  
špatné ≠ velmi špatné  
velmi špatné ≠ poněkud špatné

Fuzzy inference je založena na dvou základních konceptech:

- 1) Fuzzy implikace
- 2) Kompoziční pravidlo inference

ad 1) Fuzzy implikace je reprezentována jako

$$A \rightarrow B$$

kde  $A$  a  $B$  jsou fuzzy množiny.

Fuzzy implikace je definována jako fuzzy relace. Fuzzy relace bývá reprezentována pomocí matice.

Fuzzy relace  $R$  asociovaná s implikací  $A \rightarrow B$  je fuzzy množina na kartézském součinu  $X \times Y$  kde  $A \in X$  a  $B \in Y$ .

Nejpoužívanější fuzzy implikace je založena na operátoru min čili  $\wedge$ :

$$\mu_R(x, y) = \min(\mu_A(x), \mu_B(y)), \quad x \in X, y \in Y$$

Je-li tedy  $R$  fuzzy relace z  $X$  do  $Y$  a  $\tilde{x}$  je fuzzy podmnožina na  $X$ , pak fuzzy podmnožina  $\tilde{y}$  na  $Y$  indukovaná pomocí  $\tilde{x}$  je dána jako kompozice  $R$  a  $\tilde{x}$ :

$$\tilde{y} = \tilde{x} \circ R \quad (\text{kompoziční pravidlo})$$

Nejúžívanější metodou kompozice fuzzy množin je tzv. max-min kompozice. Při použití této metody je  $\tilde{y}$  počítáno jako max-min produkt  $\tilde{x}$  a  $R$ . Operace je velmi podobná násobení vektoru a matice (skalární součin); rozdíl je v tom, že násobení je nahrazeno operací min a sečítání operací max:

$$\mu_B(y) = \max_{x \in X} \min(\mu_A(x), \mu_R(x, y)), \quad \forall y$$

$$= \max_{x \in X} (\mu_A(x) \wedge \mu_R(x, y)), \quad \forall y$$

Poznámka: je-li  $R = (A \rightarrow B)$  a  $\tilde{x} = A$  dostaneme

$$\tilde{y} = \tilde{x} \circ (A \rightarrow B) = B \quad (\text{přesná identita})$$

(ověřte si za domácí úkol).

### Fuzzy pravidla

Fuzzy pravidlo definujeme pomocí relace mezi pozorováním (antecedent) a akcí (konsekvent). Fuzzy pravidlo je ekvivalentní fuzzy implikaci. Pro každé pravidlo IF A THEN B by bylo obecně nutno generovat matici, což pro rozsáhlejší soubory pravidel by vyžadovalo mnoho matic, což je časově i paměťově náročné obdobně jako výpočty spojené s inferencí.

Ve speciálním případě lze inferovat pomocí A a B bez nutnosti generovat matice. Lze to tehdy, pokud operátor implikace (tj. relace!) a produkt jsou tytéž. Použijeme-li pro vytvoření relace operace min a takéž použijeme min pro produkt, výpočty se značně zjednoduší.

Předpokládejme, že máme k dispozici pozorování A' a relaci R. Potom závěr B' vypočteme jako

$$B' = A' \circ R$$

Rozepíšeme-li kompozici:

$$\mu_{B'}(y) = \max_x (\mu_{A'}(x) \wedge \mu_R(x, y)) =$$

$$= \max_x \left( \mu_{A'}(x) \wedge (\mu_A(x) \wedge \mu_B(y)) \right) =$$

$$= \max_x \left( (\mu_{A'}(x) \wedge \mu_A(x)) \wedge \mu_B(y) \right) =$$

$$= \left( \max_x (\mu_{A'}(x) \wedge \mu_A(x)) \right) \wedge \mu_B(y) =$$

$$= \xi \wedge \mu_B(y)$$

kde

$$\xi = \max_x (\mu_{A'}(x) \wedge \mu_A(x))$$

Vše, co potřebujeme, je aplikovat operaci min na vektory A a A' a pak najít maximální prvek výsledku. Toto maximum  $\xi$  se použije jako jeden z operandů operace min spolu s vektorem B.

Ukázaný postup lze rozšířit i pro pravidla, jejichž podmínková část je složena z více podmínek.  
Např. uvažme pravidlo:

IF A AND B THEN C

A, B, C jsou fuzzy množiny definované na <sup>(příslušných)</sup> universech X, Y, Z. Podmínková část pravidla je nyní dvourozměrná. Relace R je tedy reprezentována takto:

$$R = (A \times B) \rightarrow C$$

Kde  $A \times B$  je kartézský součin A a B. Spojka AND se interpretuje jako průnik, takže kartézský součin je realizován pomocí operace min. S použitím "min" pro " $\rightarrow$ " pak dostáváme:

$$\mu_R(x, y, z) = \mu_A(x) \wedge \mu_B(y) \wedge \mu_C(z)$$

$x \in X, y \in Y, z \in Z$

Vznikne ternární relace R (třírozměrné pole).

Nechť existují pozorování A' a B'. Pak fuzzy závěr C' se spočítá jako:

$$C' = (A' \times B') \circ R$$

což po rozepsání obdobně jako v dvourozměrném případě dá následující výsledek:

$$\mu_C(z) = \max_x \max_y \left( \left( \mu_{A'}(x) \wedge \mu_{B'}(y) \right) \wedge \left( \mu_A(x) \wedge \mu_B(y) \wedge \mu_C(z) \right) \right) =$$

$$= \max_x \max_y \left( \mu_{A'}(x) \wedge \mu_{B'}(y) \wedge \left( \mu_A(x) \wedge \mu_B(y) \wedge \mu_C(z) \right) \right) =$$

$$= \max_x \left( \mu_{A'}(x) \wedge \mu_A(x) \right) \wedge \max_y \left( \mu_{B'}(y) \wedge \mu_B(y) \right) \wedge \mu_C(z)$$

$$= \xi \wedge \mu_C(z)$$

ověřte si ze domácí úlohou

Obdobně lze zobecnit pravidlo pro lib. počet podmínek.

### Kombinace dvou a více pravidel

Pravidla jsou kombinována pomocí spojky ELSE (někdy také označované OTHERWISE pro odlišení od "vylučovacího" chápání ELSE např. v systémech založených na klasické logice).

- R<sub>1</sub>: IF A<sub>1</sub> AND B<sub>1</sub> THEN C<sub>1</sub> ELSE  
 R<sub>2</sub>: IF A<sub>2</sub> AND B<sub>2</sub> THEN C<sub>2</sub> ELSE  
 R<sub>3</sub>: IF A<sub>3</sub> AND B<sub>3</sub> THEN C<sub>3</sub> ELSE ...

Interpretace ELSE záleží na tom, co od této spojky očekáváme.

Chápeme-li soubor fuzzy pravidel jako sjednocení ~~základních~~ částečných znalostí reprezentovaných individuálními pravidly, pak lze (jak se v praxi téměř výhradně děje) interpretovat ELSE jako spojku OR, která je nejčastěji realizována pomocí max:

$$R = R_1 \text{ OR } R_2 \text{ OR } \dots \text{ OR } R_m =$$

$$= R_1 \cup R_2 \cup \dots \cup R_m =$$

$$= \bigcup_{i=1}^m R_i$$

$$\mu_R = \max(\mu_1, \mu_2, \dots, \mu_m)$$

## Inference pomocí fuzzy pravidel

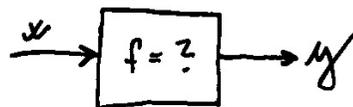
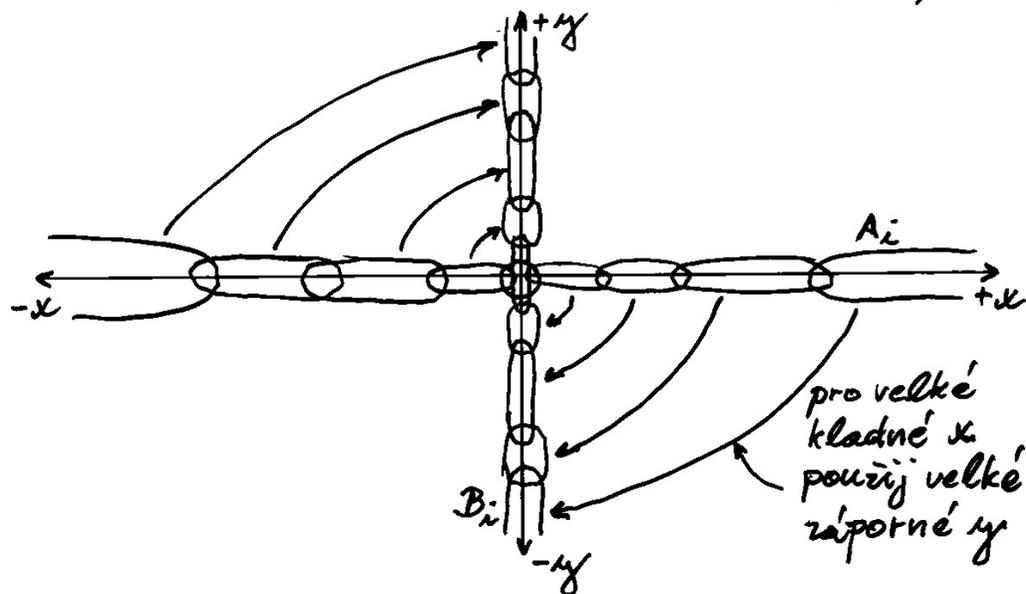
Jednoduchý případ: 1 vstupní proměnná, 1 výstupní:  
Pravidlo ( $i$ -té z nějaké báze pravidel):

$$R_i: \text{ IF } x = A_i \text{ THEN } y = B_i$$

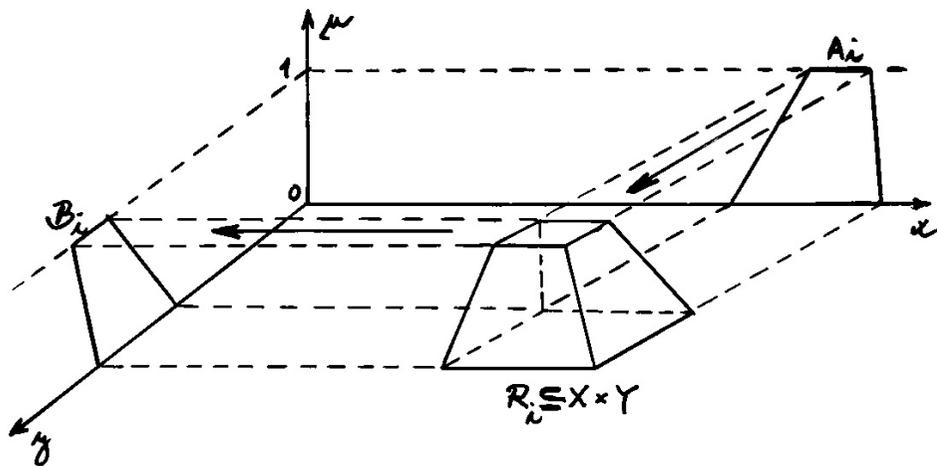
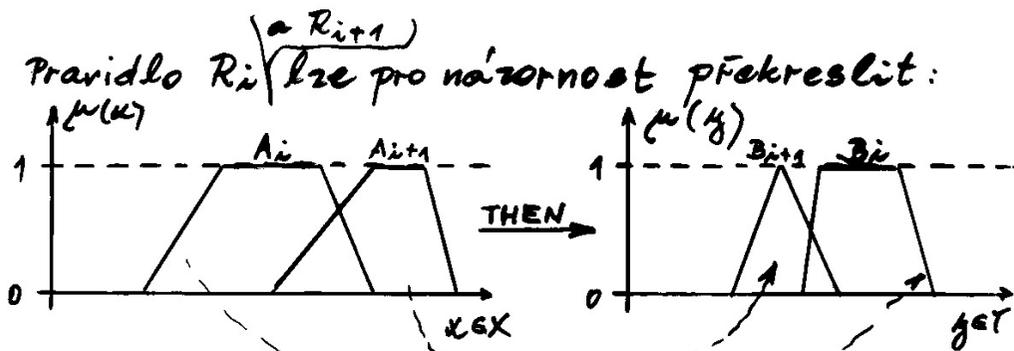
$$x \in X, y \in Y, A_i \subseteq X \times Y, B_i \subseteq X \times Y$$

$$A_i, B_i \text{ jsou fuzzy množiny. } X \subseteq \mathbb{R}, Y \subseteq \mathbb{R} \text{ (obecně)}$$

Pravidla aproximují neznámou nelineární závislost  $y = f(x)$ , kde jsou k dispozici pouze některé vstup/výstupní dvojice  $\{A_i, B_i\}$ , jejich počet nemusí být velký (např. řádu  $10^0, 10^1, 10^2$ ).



Pravidlo  $R_i$  lze pro názornost překreslit:

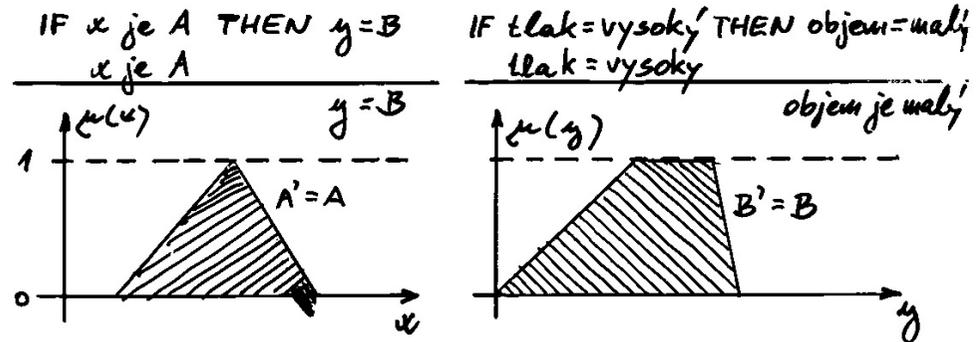


Logická spojka THEN může být implementována libovolnou t-normou (dává-li to smysl vzhledem ke konkrétní aplikaci). Nejběžnější implementace je pomocí minima  $\wedge$ . Často se používá i algebraický součin (někdy zvaný jako „Larsenův operátor“).

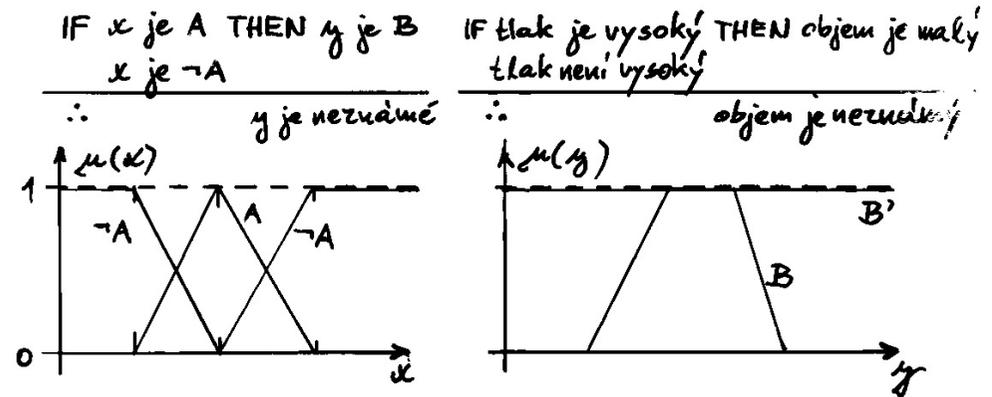
Pozn.: MT (GMT) je svázán se zpětnou inferencí řízenou cílem, která se často používá v medicínských expertních systémech (v diagnostice).

Necht  $A, B, A'$  jsou fuzzy čísla. GMP splňuje některé rozumné předpoklady:

(1) Základní vlastnost:

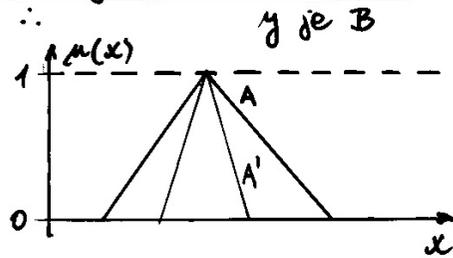


(2) Úplná indetetminence:

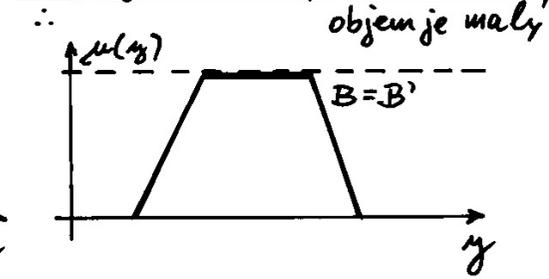


(3) Podmnožina:

IF  $x$  je A THEN  $y$  je B  
 $x$  je A'CA



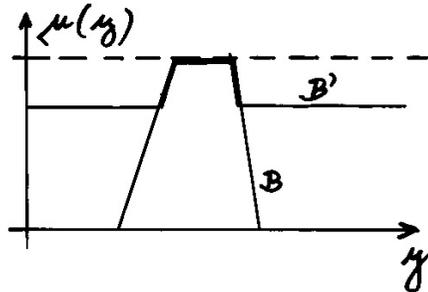
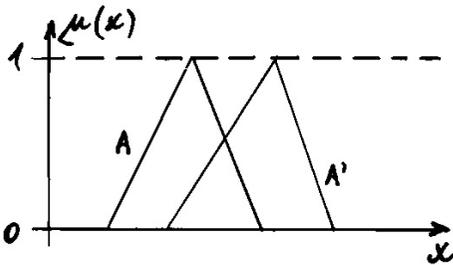
IF tlak je velký THEN objem je malý  
 tlak je velmi velký



(4) Nadmnožina:

IF  $x$  je A THEN  $y = B$   
 $x$  je A'

$\therefore y$  je  $B' \supset B$



Pozn.: Nejužívanější GMP s tzv. Mamdaniho implikací nesplňuje ~~čtyřevýše uvedené vlastnosti~~ čtyřevýše uvedené vlastnosti:  
 ↗ některé ze

Př.: GMP s Mamdaniho implikací:

IF  $x$  je A then  $y$  je B  
 $x$  je A'

$\therefore y$  je B'

$B'(y)$  je definováno jako

$$B'(y) = \sup \{ A'(x) \wedge A(x) \wedge B(y) \mid x \in R \}, y \in R$$

Základní vlastnost: necht'  $A' = A$ :  $\boxtimes$

$$\begin{aligned} B'(y) &= \sup_x \min \{ A(x), \min \{ A(x), B(y) \} \} = \\ &= \sup_x \min \{ A(x), B(y) \} = \min \{ B(y), \sup_x A(x) \} = \\ &= \min \{ B(y), 1 \} = B(y) \text{ splněno} \end{aligned}$$

Úplná indeterminace: necht'  $A' = \neg A = 1 - A$

$$\begin{aligned} B'(y) &= \sup_x \min \{ 1 - A(x), \min \{ A(x), B(y) \} \} = \\ &= \sup_x \min \{ A(x), 1 - A(x), B(y) \} = \end{aligned}$$

$$= \min \{ B(y), \sup_x \min \{ A(x), 1 - A(x) \} \} =$$

?

$$= \min \{ B(y), 1/2 \} = \frac{1}{2} B(y) < 1 \text{ nesplněno}$$

Podmnožina: necht'  $A' \subset A$

$$\begin{aligned} B'(y) &= \sup_x \min \{ A'(x), \min \{ A(x), B(y) \} \} = \\ &= \sup_x \min \{ A(x), A'(x), B(y) \} = \\ &= \min \{ B(y), \sup_x A'(x) \} = \\ &= \min \{ B(y), 1 \} = B(y) \text{ splněno} \end{aligned}$$

Nadmnožina:

$$\begin{aligned} B'(y) &= \sup_x \min \{ A'(x), \min \{ A(x), B(y) \} \} = \\ &= \sup_x \min \{ A(x), A'(x), B(y) \} \leq B(y) \text{ nesplněno} \end{aligned}$$

Podobně např. pro Larsenovu implikaci:

Základní vlastnost: necht'  $A' = A$  ( $x \in R, y \in R$ )

$$B'(y) = \sup_x \min \{ A(x), A(x) \cdot B(y) \} = B(y) \text{ splněno}$$

Úplná indeterminace: necht'  $A' = \neg A = 1 - A$

$$\begin{aligned} B'(y) &= \sup_x \min \{ 1 - A(x), A(x) \cdot B(y) \} = \\ &= \frac{B(y)}{1 + B(y)} < 1 \text{ nesplněno} \end{aligned}$$

Podmnožina: necht'  $A' \subset A$

$$\begin{aligned} B'(y) &= \sup_x \min \{ A'(x), A(x) \cdot B(y) \} = \\ &= \sup_x \min \{ A(x), A'(x) \cdot B(y) \} = B(y) \text{ splněno} \end{aligned}$$

Nadmnožina:

$$B'(y) = \sup_x \min \{ A'(x), A(x) \cdot B(y) \} \leq B(y) \text{ nesplněno}$$

Inference (fuzzy inference) vychází ze zobecněného modus ponens:

	premise		závěr	
$R_1$ :	IF $x = A_1$	THEN	$y = B_1$	}
$R_2$ :	IF $x = A_2$	THEN	$y = B_2$	
$\vdots$	$\vdots$			
$R_n$ :	IF $x = A_n$	THEN	$y = B_n$	
	$x = A'$			fakt
$\therefore$				$y = B'$

Postup:

1. Zjistí (naměří...) se fakt, že  $x = A'$  ( $A' \in X, x \in X$ ), přičemž obvykle  $A'$  je ostrá hodnota.
2. Hledá se, která premisa (obecně premisy za předpokladu, že fuzzy množiny  $A_i$  se překrývají) odpovídá (je konsistentní s) faktu. Je-li konsistence  $> 0$ , pak se pravidlo uplatní (do míry dané založené na konsistenci).
3. Aktivované pravidlo  $R_i$ , u něhož došlo k částečné nebo úplné shodě mezi  $A'$  a  $A_i$ , přispěje k celkovému výsledku inference svou pravou stranou (konsekventem  $B_i$ ), modifikovanou na základě míry konsistence mezi  $A_i$  a  $A'$ , tj. pravidlo poskytne  $B'_i$  (obecně  $B'_i \neq B_i$ ).
4. Individuální příspěvky  $B'_i$  jsou pomocí

vhodného agregačního operátoru OTHERWISE akumulovány do celkového výsledku  $B'$  inferenčního kroku:

$$B' = \text{OTHERWISE}_{i=1}^n B'_i \quad B' \in Y, B'_i \in Y$$

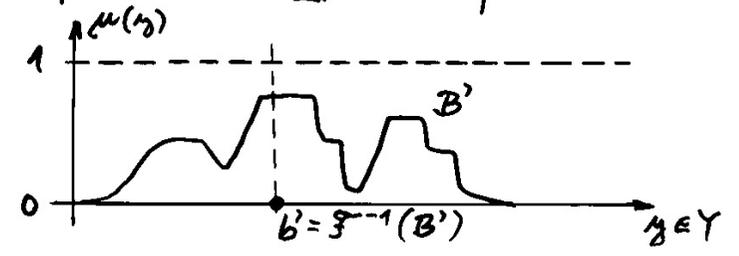
5. Obecně vznikne fuzzy množina  $B'$  (nemusi být normální a konvexní).

Výsledek je nutno vhodně (z hlediska aplikace) interpretovat.

Obecně je interpretace složitě množiny  $B'$  (vzniklé kompozicí  $B_i, i=1, \dots, n$ ) obtížný. Lze např. výsledek převést na lingvistickou hodnotu, ale neexistuje exaktní návod, jak postupovat - interpretaci je nutno mít na paměti již při sestavování fuzzy modelu.

Často se  $B'$  transformuje na bod  $b' \in Y$  pomocí tzv. defuzzifikace, což je postup, pro nějž rovněž neexistuje jednoznačný návod. Existují různé metody  $b' = \mathcal{F}^{-1}(B')$ .

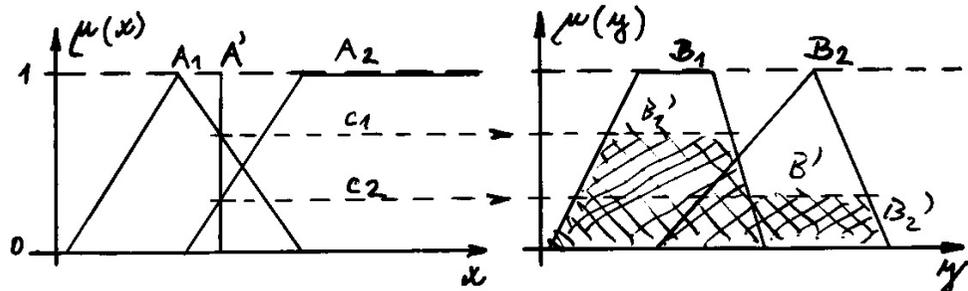
Z  $b'$  obecně nelze zpětně stanovit  $B'$ , tj. defuzzifikací se ztrácí informace:



Defuzifikace se většinou používá pro numerická universa  $Y$ ; aplikace fuzzy inference na řízení procesů vyžadují defuzifikaci vždy, protože reálné regulační elementy (ventily, ...) umí pracovat jen s ostrými hodnotami.

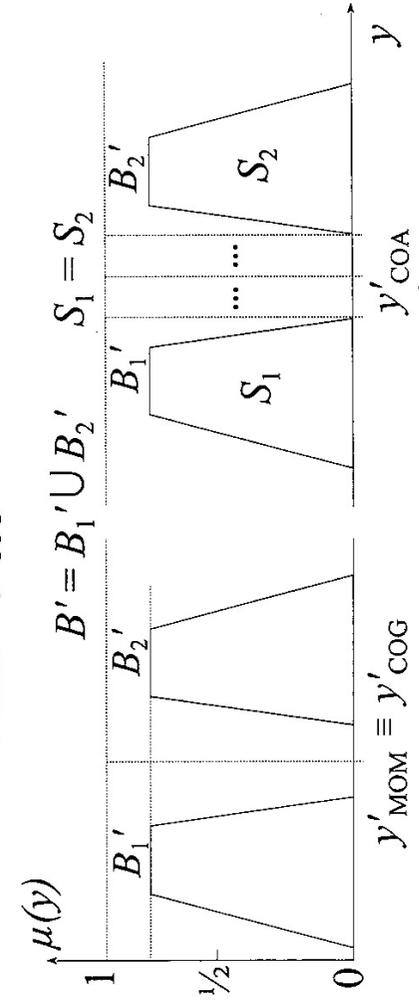
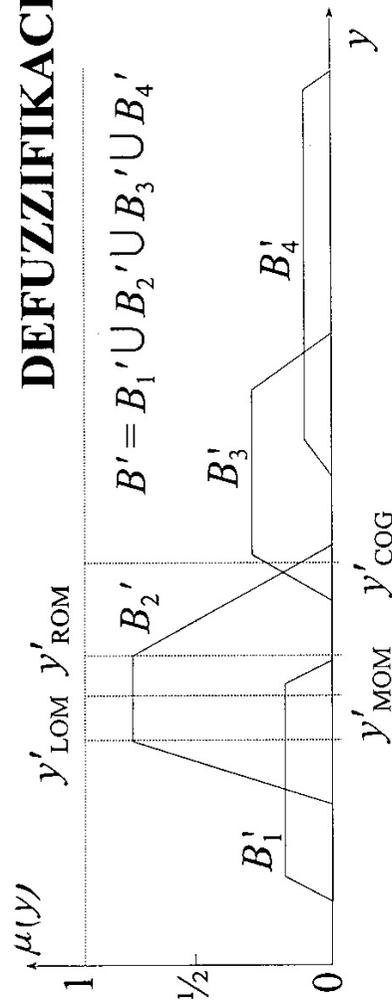
Př.: Předpokládejme pro jednoduchost, že existují pouze dvě pravidla:

- $R_1$ : IF  $x = A_1$  THEN  $y = B_1$
- $R_2$ : IF  $x = A_2$  THEN  $y = B_2$

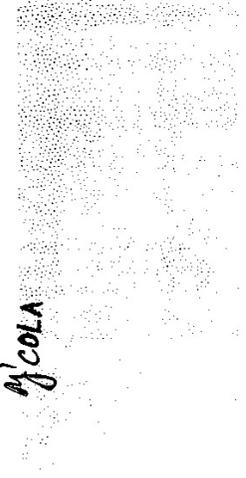


$B'_1 = ? \quad B'_2 = ? \quad B' = ? \quad \underline{\underline{f^{-1}(B') = ?}}$

### DEFUZZIFIKACE



COG:  $y'_{COG} = \frac{\sum y_i \mu_y(y_i)}{\sum \mu_y(y_i)}$

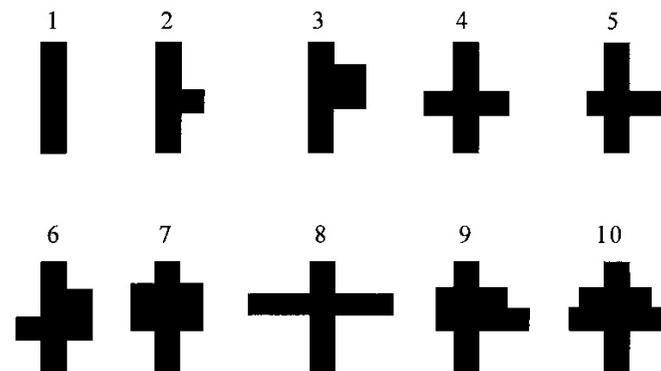


## FUZZY PRAVIDLA

Jako jednoduchý příklad operátorů fuzzy množin uvažme problém rozpoznávání vzorů. Vzory mohou reprezentovat objekty zkoumané z hlediska kvality, např. vyráběné součástky či sklizené ovoce. Jiným typem důležitého rozpoznávání vzorů jsou lékařské snímky, seismická data z minerálních a ropných průzkumů aj.

Následující tabulka ukazuje hypotetická data reprezentující stupeň příslušnosti do fuzzy množin raket, stíhaček a dopravních letadel, odpovídajících nějakým obrazcům. Takové obrazce mohou být vytvářeny laserovým televizním systémem na velké vzdálenosti a obsahovat nejistotu vlivem pohybu a orientace cíle, šumu apod.

obrazec	stupeň příslušnosti		
	raketa	stíhačka	dopravní
1	1.0	0.0	0.0
2	0.9	0.0	0.1
3	0.4	0.3	0.2
4	0.2	0.3	0.5
5	0.1	0.2	0.7
6	0.1	0.6	0.4
7	0.0	0.7	0.2
8	0.0	0.0	1.0
9	0.0	0.8	0.2
10	0.0	1.0	0.0



Sjednocení fuzzy množin lze považovat za reprezentaci pravidel typu

IF  $e$  THEN  $h$

kde  $e$  je pozorovaný obrazec a  $h$  je sjednocení fuzzy množin. Například:

IF  $obrazec_4$  THEN  $cil(0.2/R + 0.3/S + 0.5/D)$

kde  $R=raketa$ ,  $S=stíhačka$  a  $D=dopravní letadlo$ . Výraz v závorce je sjednocená fuzzy množina cíle. Pravidlo může být případně vyjádřeno jako

IF  $obrazec_4$  THEN  $cil_4$  kde  $cil_4 = 0.2/R + 0.3/S + 0.5/D$

Předpokládejme, že je nějaký čas na provedení dalšího pozorování cíle a že získáme  $obrazec_6$ :

IF  $obrazec_6$  THEN  $cil_6$  kde  $cil_6 = 0.1/R + 0.6/S + 0.4/D$

Všechny naměřené elementy cíle tedy jsou:

$$\begin{aligned}
 cil &= cil_4 + cil_6 = \\
 &= 0.2/R + 0.3/S + 0.5/D + 0.1/R + 0.6/S + 0.4/D = \\
 &= 0.2/R + 0.6/S + 0.5/D
 \end{aligned}$$

tj. ve sjednocení (fuzzy množině  $cil$ ) zůstaly pouze maximální stupně příslušnosti.

Je-li element s nejvyšším stupněm příslušnosti *interpretován* jako *nejvíce možný cíl* (nejvíce do úvahy připadající typ cíle), pak to bude stíhačka s hodnotou 0.6. Avšak kdyby dopravní letadlo mělo také stupeň příslušnosti do množiny *cíl* o velikosti = 0.6, pak by bylo třeba říci, že cíl je se stejnou *možností* stíhačka nebo dopravní letadlo.

Obecně, je-li dáno  $N$  pozorování a pravidel:

IF  $e_1$  THEN  $h_1$   
 IF  $e_2$  THEN  $h_2$   
 .  
 .  
 IF  $e_N$  THEN  $h_N$

kde všechny  $h_i$  souvisejí s nějakou obecnou hypotézou  $h$ , pak sjednocení hypotéz  $h_i$  určuje stupeň příslušnosti  $h$ :

$$\mu_h = \max(\mu_{h1}, \mu_{h2}, \dots, \mu_{hN})$$

$\mu_h$  hypotézy  $h$  se nazývá pravdivostní hodnota  $h$ .

Je rozumné stanovit předpoklad, že pravdivost hypotézy nebude větší než pravdivost jejího antecedentu. Tedy:

$$\mu_h = \max(\mu_{h1}, \mu_{h2}, \dots, \mu_{hN}) = \max[\min(\mu_{e1}), \min(\mu_{e2}), \dots, \min(\mu_{eN})]$$

kde každé  $e_i$  může být nějakým fuzzy výrazem. Například  $e_1$  by mohlo být definováno jako

$$e_1 = e_A \text{ AND } (e_B \text{ OR } \neg e_C)$$

a k vyhodnocení by se použily fuzzy operátory:

$$\mu_{e_1} = \min[\mu_{e_A}, \max(\mu_{e_B}, 1 - \mu_{e_C})]$$

Kombinovaný stupeň příslušnosti antecedentu se nazývá jako *pravdivostní hodnota antecedentu*.

## Max-min kompozice

Uvedený vztah pro  $h$  je tzv. *max-min kompoziční pravidlo* fuzzy logiky (kompoziční pravidlo inference). V jednoduchém případě dvou důkazů na pravidlo:

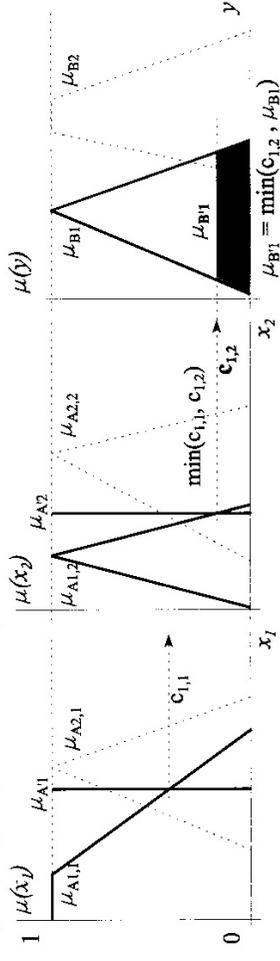
IF  $e_{11}$  AND  $e_{12}$  THEN  $h_1$   
 IF  $e_{21}$  AND  $e_{22}$  THEN  $h_2$   
 .  
 .  
 IF  $e_{N1}$  AND  $e_{N2}$  THEN  $h_N$

je max-min kompoziční pravidlo inference

$$\mu_H = \max[\min(\mu_{e11}, \mu_{e12}), \min(\mu_{e21}, \mu_{e22}), \dots, \min(\mu_{eN1}, \mu_{eN2})]$$

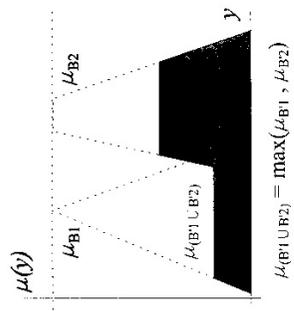
s obdobným rozšířením pro další důkazy  $e_{i3}, e_{i4}$  atd.

**R<sub>1</sub>:** if  $x_1 = A_{1,1}$  and  $x_2 = A_{1,2}$  then  $y = B_1$

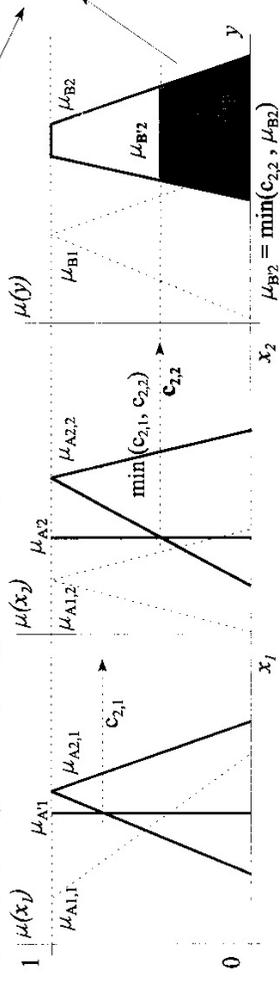


$$x_1 = A'_{1,1}, x_2 = A'_{1,2}$$

$$y = B'_{1,1} \cup B'_{1,2}$$



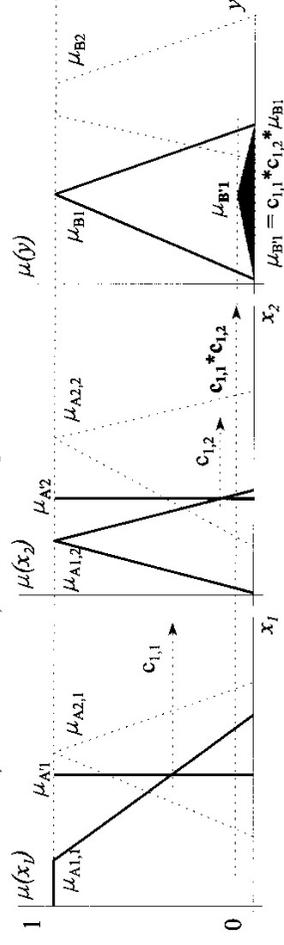
**R<sub>2</sub>:** if  $x_1 = A_{2,1}$  and  $x_2 = A_{2,2}$  then  $y = B_2$



$$\mu_{B_2} = \min(c_{2,2}, \mu_{B_2})$$

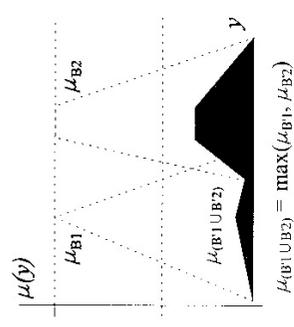
Inference MIN-MAX

**R<sub>1</sub>:** if  $x_1 = A_{1,1}$  and  $x_2 = A_{1,2}$  then  $y = B_1$

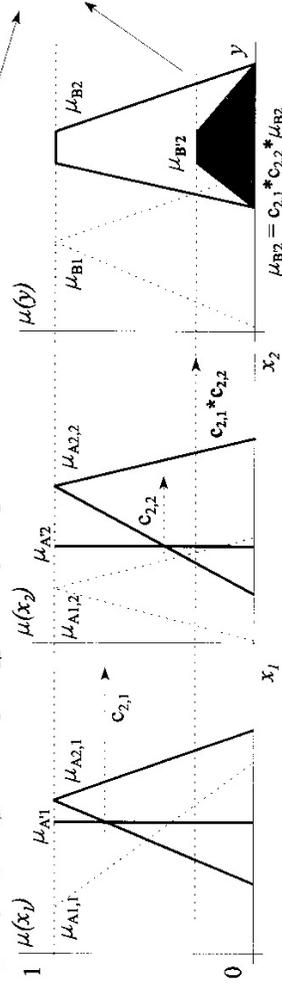


$$x_1 = A'_{1,1}, x_2 = A'_{1,2}$$

$$y = B'_{1,1} \cup B'_{1,2}$$



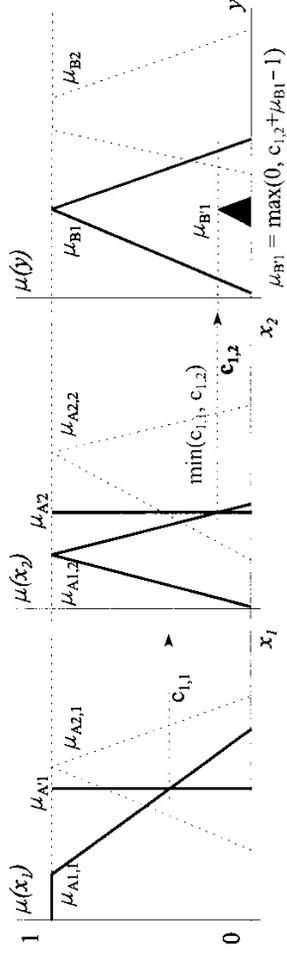
**R<sub>2</sub>:** if  $x_1 = A_{2,1}$  and  $x_2 = A_{2,2}$  then  $y = B_2$



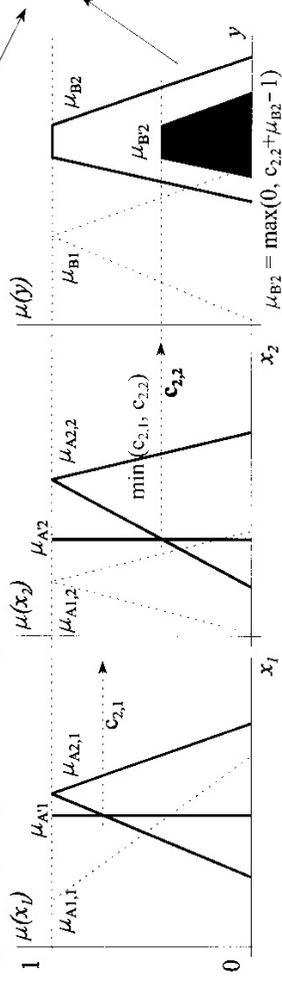
$$\mu_{B_2} = c_{2,1} * c_{2,2} * \mu_{B_2}$$

Inference PROD-MAX

**R<sub>1</sub>:** if  $x_1 = A_{1,1}$  and  $x_2 = A_{1,2}$  then  $y = B_1$

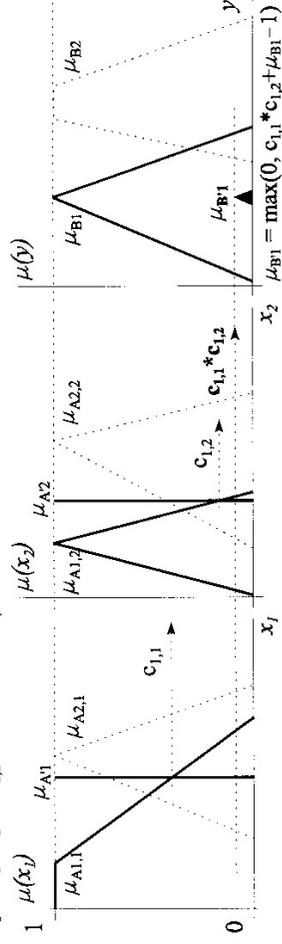


**R<sub>2</sub>:** if  $x_1 = A_{2,1}$  and  $x_2 = A_{2,2}$  then  $y = B_2$

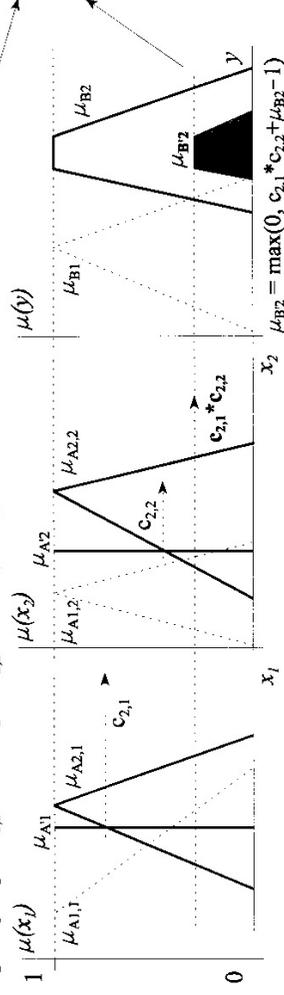


Inference MIN-BOLD

**R<sub>1</sub>:** if  $x_1 = A_{1,1}$  and  $x_2 = A_{1,2}$  then  $y = B_1$

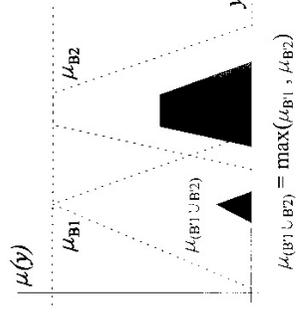


**R<sub>2</sub>:** if  $x_1 = A_{2,1}$  and  $x_2 = A_{2,2}$  then  $y = B_2$

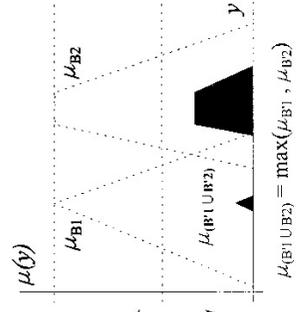


Inference PROD-BOLD

$x_1 = A'_1, x_2 = A'_2$   
 $y = B'_1 \cup B'_2$



$x_1 = A'_1, x_2 = A'_2$   
 $y = B'_1 \cup B'_2$



## Metoda Takagiho a Sugena

1. je ji považovat za modifikaci Mamdaniho přístupu:

Vstupní domény se zpracují stejně jako u Mamdaniho.

Výstupní doména však není rozdělena pomocí fuzzy intervalů, nýbrž obsahuje ostré hodnoty (tj. přímo hodnoty řídicí akce). Není tedy zapotřebí defuzzifikace.

Tvar řídicího pravidla:

$R_j$ : IF  $x_1 = A_{1j}$  AND ... AND  $x_m = A_{mj}$   
THEN  $y = f_j(x_1, \dots, x_m)$   $j = 1, 2, \dots, m$

$f_j$  je mapování  $X_1 \times X_2 \times \dots \times X_m \rightarrow Y$

Obecně se předpokládá lineární funkce:

$$f_j(x_1, x_2, \dots, x_m) = a_1^{(j)} x_1 + \dots + a_m^{(j)} x_m + a_0^{(j)}$$

Při aktivaci více pravidel se výsledná hodnota řídicí veličiny určí jako

$$y = \frac{\sum_{j=1}^m c_j \cdot f_j(x_1, \dots, x_m)}{\sum_{j=1}^m c_j}, \quad j = 1, \dots, m$$

## Takagiho-Sugenův model

Takagiho-Sugenův inferenční model se formálně odlišuje od Mamdaniho metody tím, že pravé strany pravidel nejsou tvořeny fuzzy množinami, nýbrž obecně funkcemi vstupních proměnných  $f_j(x_1, x_2, \dots, x_N)$ , které mapují kartézský součin  $X_1 \times X_2 \times \dots \times X_N \rightarrow Y$ :

IF  $x_1 \text{ je } A_{1j}$  AND  $x_2 \text{ je } A_{2j}$  AND ... AND  $x_N \text{ je } A_{Nj}$   
THEN  $y = f_j(x_1, x_2, \dots, x_N)$

Obvykle se používá lineární mapovací funkce vyjádřená následujícím vztahem:

$$f_j(x_1, x_2, \dots, x_N) = q_{0j} + \sum_{i=1}^N q_{ij} x_i, \quad j = 1, 2, \dots, M$$

případně zcela jednoduchá forma, kde je v každém pravidle na pravé straně konstanta:

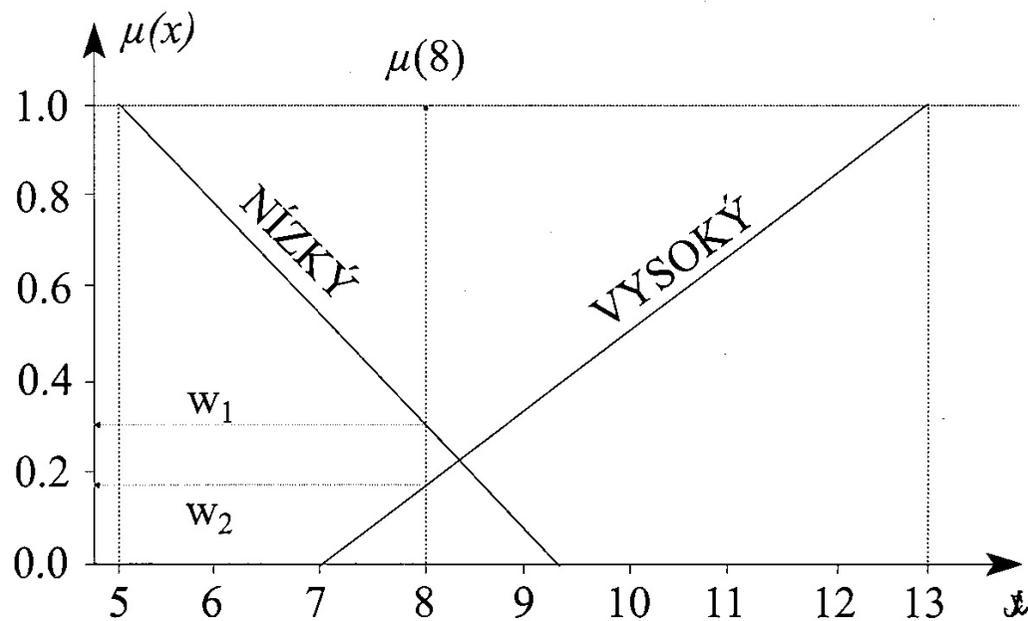
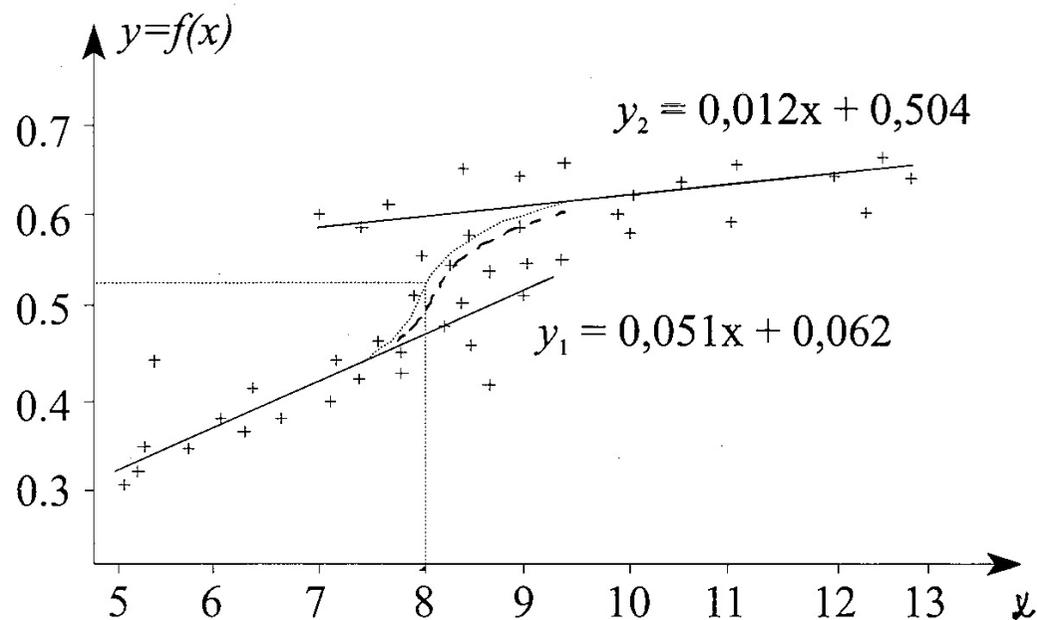
$$f_j(x_1, x_2, \dots, x_N) = k_j, \quad j = 1, 2, \dots, M$$

Odlíšná forma konsekventu ovlivňuje způsob inference. Spojce THEN zde odpovídá algebraický součin, takže úhrnnou míru splnění podmíněné části  $j$ -tého pravidla  $\xi_j$  lze považovat za váhu, modifikující parciální příspěvek pravé strany pravidla. Protože na pravé straně pravidla nevystupuje fuzzy množina, nýbrž ostré číslo, není zapotřebí defuzzifikace. Přesto i zde zůstává problém řešení konfliktu pravidel, a to ze stejné příčiny jako u Mamdaniho metody. Je-li nutno stanovit celkový výsledek, složený z částečných příspěvků jednotlivých pravidel, spočítá se výsledná hodnota  $y'$  jako vážený aritmetický průměr příspěvků jednotlivých pravidel:

$$y' = \frac{\sum_{j=1}^M \xi_j * f_j(x_1, \dots, x_N)}{\sum_{j=1}^M \xi_j}$$

Takagiho-Sugenův model je do jisté míry výpočtově jednodušší, neboť není nutno defuzzifikovat výsledek inference, což je obvykle náročná operace, avšak v praxi nemusí být vždy snadné určit koeficienty  $q_{ij}$  a tak definovat potřebné mapovací funkce. Přestože nejsou konsekventy pravých stran stanoveny formou částečně se překrývajících fuzzy množin, popsána interpolační metoda využívající vážený aritmetický průměr umožňuje spojitou změnu výstupu obdobně jako v případě Mamdaniho modelu.

Sestavení a použití Takagi-Sugenova modelu lze ilustrovat následujícím postupem (hypotetický příklad je z důvodu srozumitelnosti a stručnosti velmi zjednodušen). Předpokládejme, že vztah mezi vstupní veličinou  $x$  a výstupní veličinou  $y$  je znám pouze pomocí řady uskutečněných měření tak, jak je zobrazen v horní části obrázku formou bodů vyznačených křížky. Závislost je nelineární a měření je ovlivněno šumem ve snímaných veličinách. Dále uvažujme, že zpracování naměřených dat umožnilo získat dvě regresní přímky  $y_1=0.045x+0.31$  a  $y_2=0.013x+0.56$ , tj. vztah  $y=f(x)$  je v tomto okamžiku modelován nespojitou lineární aproximací po částech. V oblasti hodnot přibližně  $x \in [7, 9.5]$ , nejvíce zatížených šumem při měření, je čárkovanou křivkou naznačena možnost aproximace neznámého nelineárního spojení obou lineárních funkcí. V popisovaném příkladu lze postupovat např. tak, že obor hodnot  $x$  se rozdělí na dvě části – nízké hodnoty, modelované fuzzy množinou NÍZKÝ, a vysoké hodnoty  $x$ , modelované fuzzy množinou VYSOKÝ (viz spodní část obrázku). Oblast překrytí obou fuzzy množin odpovídá té části universa, kde nebylo možno najít vhodnou lineární aproximaci, která by zároveň tvořila přechod mezi  $y_1$  a  $y_2$ . Nyní již je možné stanovit přibližná fuzzy pravidla:



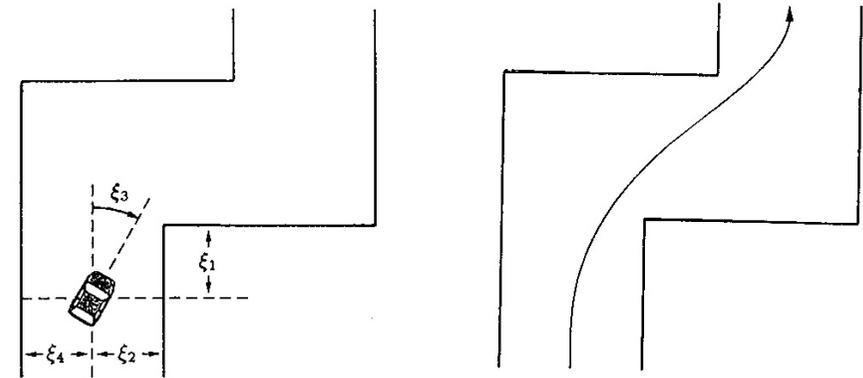
$R_1$ : IF  $x$  is NÍZKÝ THEN  $y=y_1=0,051x+0,062$

$R_2$ : IF  $x$  is VYSOKÝ THEN  $y=y_2=0,012x+0,504$

Přijde-li na vstup např. hodnota  $x=8$ , která spadá do oblasti, kde nebylo možno stanovit regresní přímku, pak lze spočítat, že pro ilustrovanou situaci platí  $\mu_{NÍZKÝ}(8)=0.31$  a  $\mu_{VYSOKÝ}(8)=0.18$ . Konkrétní hodnoty konsekventů budou tedy po dosazení  $y_1=0.47$  a  $y_2=0.6$ . K výsledku přispívají obě pravidla a tento konflikt řeší váhovaný aritmetický průměr, kde váhami pro  $y_1$  a  $y_2$  jsou získané stupně příslušnosti 0.31 resp. 0.18:

$$y'=(0.31*0.47+0.18*0.6)/(0.31+0.18)=0.52.$$

O této hodnotě je možno říci, že vcelku odpovídá očekávání vzhledem k existující neurčitosti v popisu závislosti  $y=f(x)$ .



rule	$\xi_1$	$\xi_2$	$\xi_3$	$\xi_4$	$p_0$	$p_1$	$p_2$	$p_3$	$p_4$
$R_1$	-	-	outwards	small	3.000	0.000	0.000	-0.045	-0.004
$R_2$	-	-	forward	small	3.000	0.000	0.000	-0.030	-0.090
$R_3$	small	small	outwards	-	3.000	-0.041	0.004	0.000	0.000
$R_4$	small	small	forward	-	0.303	-0.026	0.061	-0.050	0.000
$R_5$	small	small	inwards	-	0.000	-0.025	0.070	-0.075	0.000
$R_6$	small	big	outwards	-	3.000	-0.066	0.000	-0.034	0.000
$R_7$	small	big	forward	-	2.990	-0.017	0.000	-0.021	0.000
$R_8$	small	big	inwards	-	1.500	0.025	0.000	-0.050	0.000
$R_9$	medium	small	outwards	-	3.000	-0.017	0.005	-0.036	0.000
$R_{10}$	medium	small	forward	-	0.053	-0.038	0.080	-0.034	0.000
$R_{11}$	medium	small	inwards	-	-1.220	-0.016	0.047	-0.018	0.000
$R_{12}$	medium	big	outwards	-	3.000	-0.027	0.000	-0.044	0.000
$R_{13}$	medium	big	forward	-	7.000	-0.049	0.000	-0.041	0.000
$R_{14}$	medium	big	inwards	-	4.000	-0.025	0.000	-0.100	0.000
$R_{15}$	big	small	outwards	-	0.370	0.000	0.000	-0.007	0.000
$R_{16}$	big	small	forward	-	-0.900	0.000	0.034	-0.030	0.000
$R_{17}$	big	small	inwards	-	-1.500	0.000	0.005	-0.100	0.000
$R_{18}$	big	big	outwards	-	1.000	0.000	0.000	-0.013	0.000
$R_{19}$	big	big	forward	-	0.000	0.000	0.000	-0.006	0.000
$R_{20}$	big	big	inwards	-	0.000	0.000	0.000	-0.010	0.000

$R_i$ : if  $\xi_1 = A$  and  $\xi_2 = B$  and  $\xi_3 = C$  and  $\xi_4 = D$   
then  $\eta = p_0 + p_1 \xi_1 + p_2 \xi_2 + p_3 \xi_3 + p_4 \xi_4$

$A \in \{small, medium, big\}$

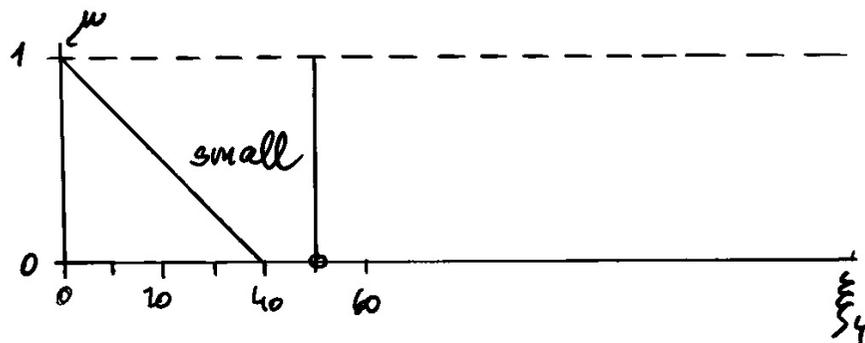
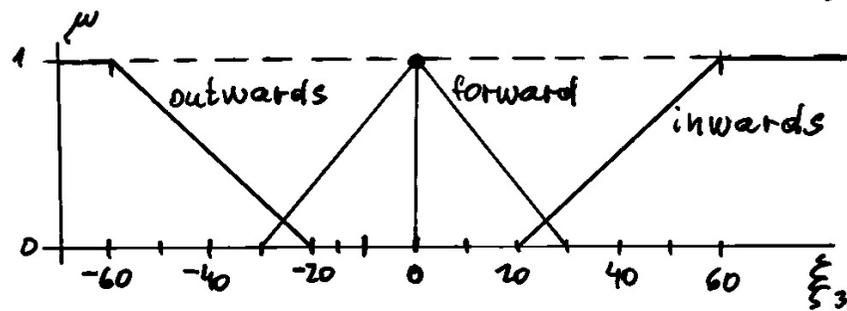
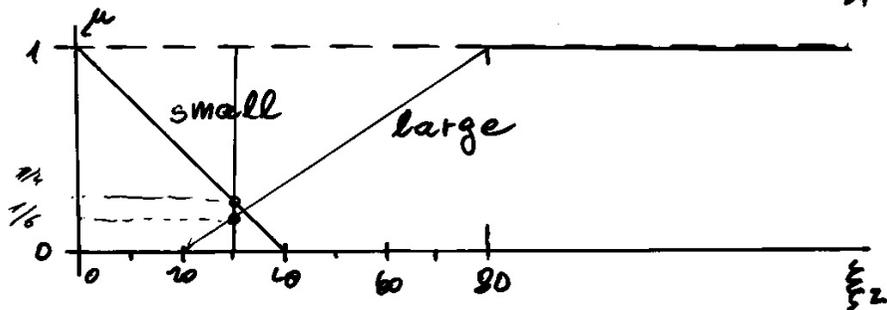
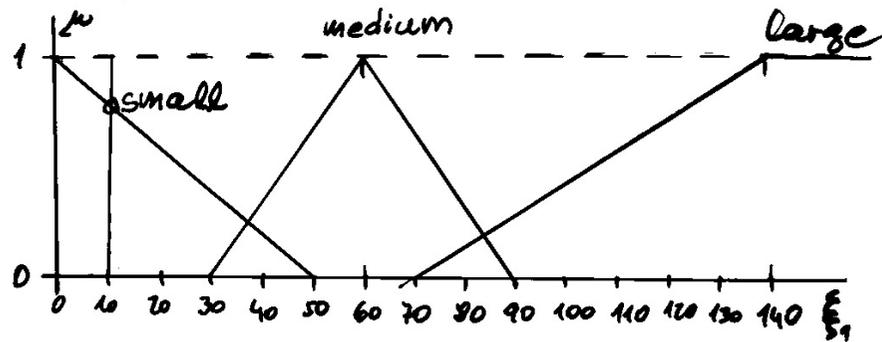
$B \in \{small, big\}$

$C \in \{outwards, forward, inwards\}$

$D \in \{small\}$

$p_i \in R, i = 1, 2, 3, 4$

aktuální hodnoty



Příklad určité situace

Předp., že  $\xi_1 = 10 \text{ cm}$ ,  $\xi_2 = 30 \text{ cm}$ ,  $\xi_3 = 0^\circ$  ("vpřed!"),  
 $\xi_4 = 50 \text{ cm}$ .

Z pravidel  $R_1$  až  $R_7$  se uplatní pouze pravidla  $R_4$  a  $R_7$ :

$$c_4 = 1/4, \quad c_7 = 1/6$$

$$\mu_4^j = 0.303 - 0.026 \cdot 10 + 0.061 \cdot 30 - 0.050 \cdot 0 + 0.50 = 1.873$$

$$\mu_7^j = 2.99 - 0.017 \cdot 10 + 0.30 - 0.021 \cdot 0 + 0.50 = 2.82$$

$$\mu_j = \underbrace{\frac{3}{5}}_{w_4} \cdot 1.873 + \underbrace{\frac{2}{5}}_{w_7} \cdot 2.82 = 2.2518$$

$$w_4 = \frac{\frac{1}{4}}{\frac{1}{4} + \frac{1}{6}} = \frac{3}{5} \quad w_7 = \frac{\frac{1}{6}}{\frac{1}{4} + \frac{1}{6}} = \frac{2}{5}$$

## Řízení cementárenské vypalovací pece pomocí fuzzy logiky u společnosti ENCI v Maastrichtu (Nizozemí)

Cílem optimálního procesu bylo:

- maximální produkce cementu
- konstantně vysoká kvalita
- co nejnižší výrobní náklady

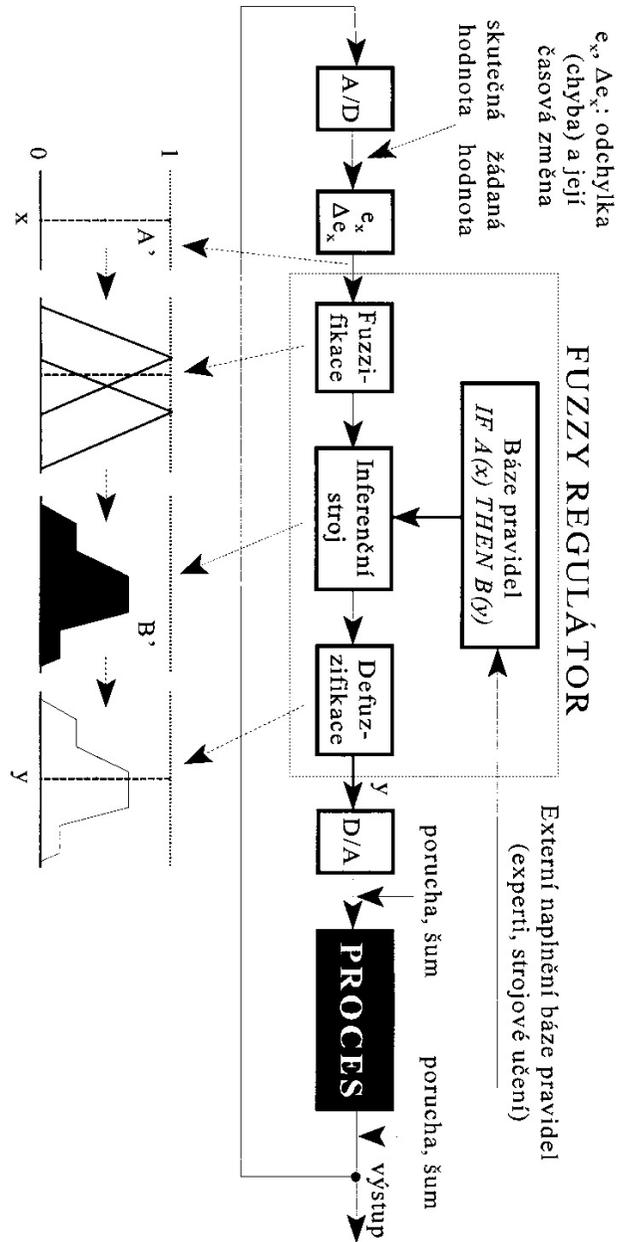
Sekundární cíle:

- produkce nejméně po dobu 85% celkového času
- redukce odstávek o 25%
- vzrůst produkce nejméně o 3%
- úspory energie
- redukce emisí
- redukce spotřeby ohnivzdorných materiálů
- zvýšení využití vypalovací pece
- zvýšení kvality cementu

Fyzikálně-chemický model, potřebný pro vývoj klasického řídicího systému, nebylo možné v rozumné době vyvinout (jedná se o směsi, nikoliv o chemikálie; existuje mnoho proměnných s nejasnou vzájemnou korelací, apod.).

Řídicí model systému rovněž nebylo možné vyvinout v době, kdy by se dal prakticky využít.

Bylo zvoleno řešení využít fuzzy modelování chování zkušených operátorů (Zadehova teorie fuzzy logiky a fuzzy množin). Fuzzy logika umožňuje počítačům pracovat s přibližnými hodnotami (*nadměrná spotřeba paliva, nedostatečný obsah kyslíku, malá změna veličiny...*). Udávaná cena projektu byla zhruba 600 000 HfI.

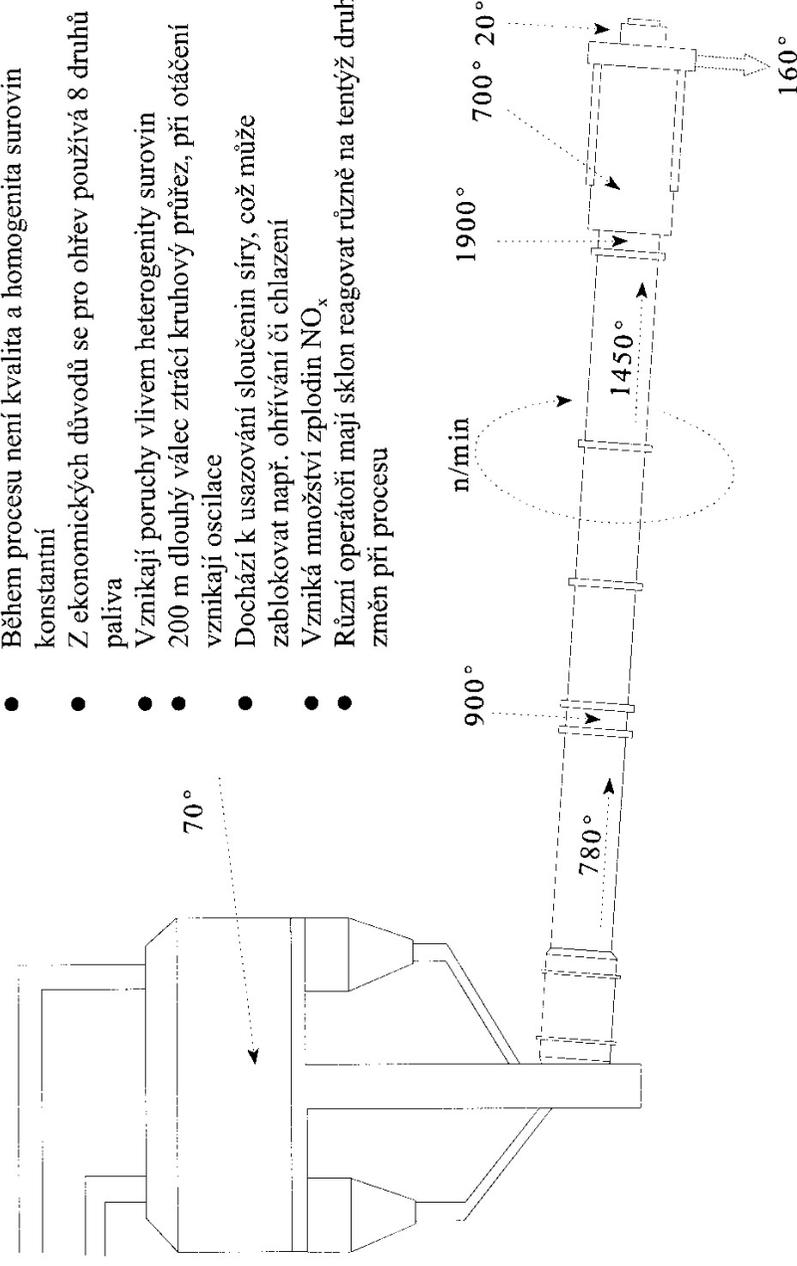


Cementárna v St.Pietersberg u Maastrichtu (Nizozemí) společnosti ENCI (Eerste Nederlandse Cement Industrie). Výroba cementu je řízena fuzzy logikou v kombinaci s klasickým řízením. Fuzzylogický řídicí systém pochází od dánské firmy FLS Automation v Kodani.

Kromě celkového zvýšení produkce o cca 3% byly sníženy náklady na spotřebu energie, na údržbu (prodloužením jednoho výrobního cyklu), a sníženy emise  $\text{NO}_x$  a  $\text{SO}_2$ . Návratnost nákladů byla 1 rok.



- Během procesu není kvalita a homogenita surovin konstantní
- Z ekonomických důvodů se pro ohřev používá 8 druhů paliva
- Vznikají poruchy vlivem heterogenity surovin
- 200 m dlouhý válec zirácí kruhový průřez, při otáčení vznikají oscilace
- Dochází k usazování sloučenin síry, což může zablokovat např. ohřívání či chlazení
- Vzniká množství zplodin  $\text{NO}_x$
- Různí operátoři mají sklon reagovat různě na tenýž druh změn při procesu



## PRINCIP ROZŠÍŘENÍ

Princip rozšíření poskytuje obecnou metodu, jak rozšířit doménu dané ostré funkce tak, aby zahrnovala i fuzzy množiny. Tím je umožněno rozšíření klasických výpočtů na výpočty s fuzzy množinami modelujícími přibližné hodnoty proměnných. Použití principu rozšíření zpřístupňuje využití fuzzy množin ve všech oblastech.

Nechť jsou dány fuzzy množiny  $A_i \subseteq X_i$  definované na příslušných univezech ( $i=1, 2, \dots, n$ ). Dále necht'  $f(x_1, x_2, \dots, x_n)$  je nefuzzy (ostrá) mapovací funkce  $f: X_1 \times X_2 \times \dots \times X_n \rightarrow Y$ . Cílem je rozšířit  $f$  tak, aby operovala i s  $A_i$  a jako výsledek vracela fuzzy množinu  $F \subseteq Y$ .

**Definice (rozšíření):** Výsledná funkce příslušnosti  $\mu_F(y), y \in Y$ , se po aplikaci ostré funkce  $f$  na fuzzy argumenty  $A_i$  stanoví následovně:

$$\mu_F(y) = \sup_{\substack{x_1, x_2, \dots, x_n \\ y=f(x_1, x_2, \dots, x_n)}} \min(\mu_{A_1}(x_1), \dots, \mu_{A_n}(x_n))$$

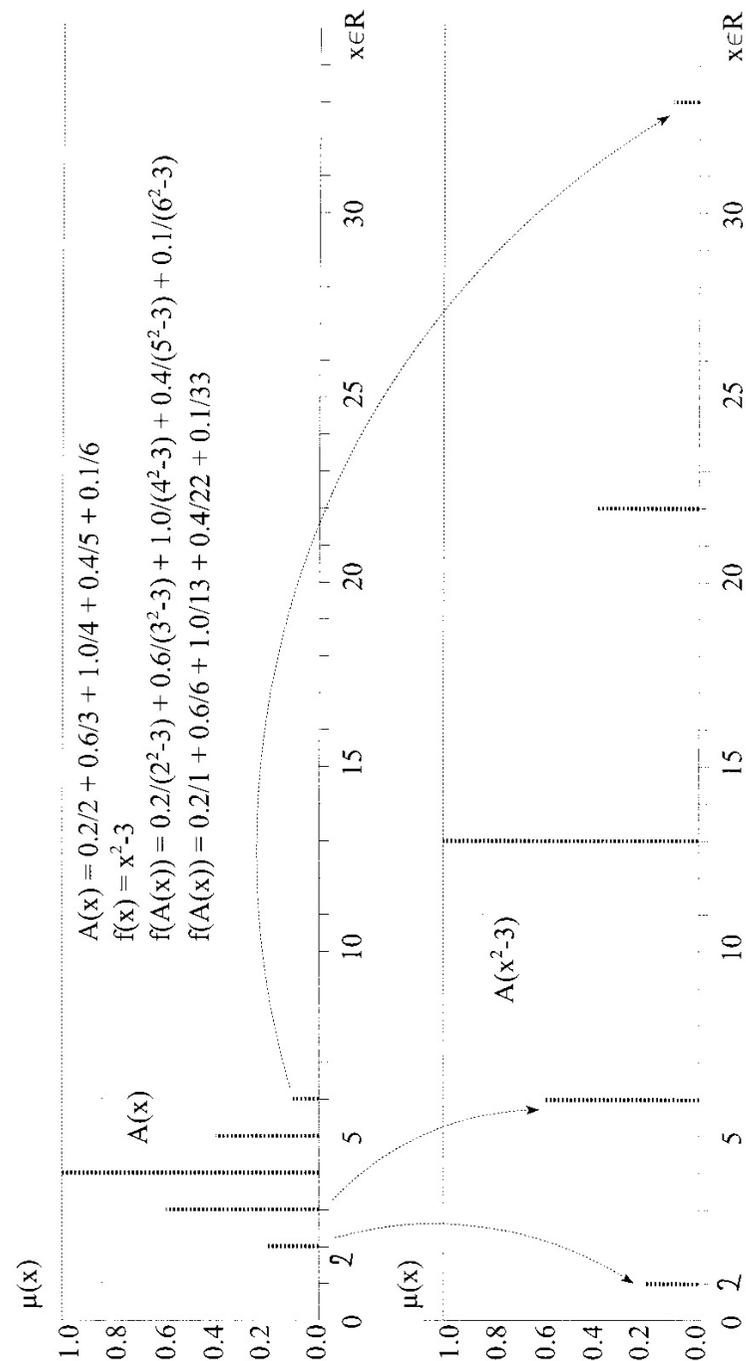
*( $\sup \emptyset \stackrel{\text{def}}{=} 0$  ... předpoklad)*

za předpokladu, že existuje  $f^{-1}(y)$ , jinak  $\mu_F(y)=0$ .

Jiný způsob získání výsledné fuzzy množiny  $F$  je pomocí sjednocení:

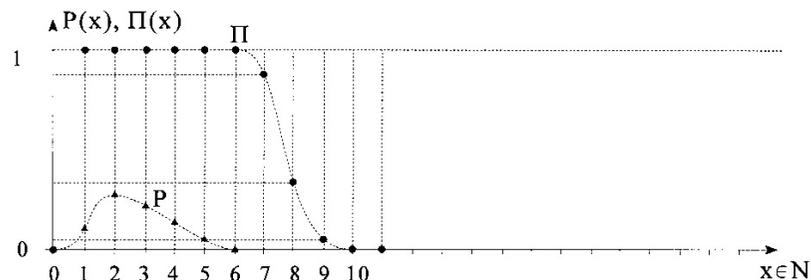
$$F = \int_{X_1 \times \dots \times X_n} \min(\mu_{A_1}(x_1), \dots, \mu_{A_n}(x_n)) / f(x_1, \dots, x_n)$$

*zde symbolizuje sjednocení!*





Lze si ovšem docela dobře představit, že by se 9 lidí nějakým (nepříliš pohodlným způsobem) do auta naskládalo, tedy že takový jev není nemožný, i když se nám ho nepodařilo zaznamenat. V takovém případě (možného jevu – i třeba zcela subjektivně možného, protože názory se mohou lišit) lze přiřadit jevu  $E=(9 \text{ osob})$  nějakou numerickou hodnotu, vyjadřující stupeň uskutečnitelnosti (tj. míru možnosti)  $\in [0, 1]$ . Proto platí, že vztah mezi pravděpodobností  $P(x)$  a možností  $\Pi(x)$  je:  $0 \leq P(x) \leq \Pi(x) \leq 1$ , tedy možnost je vždy větší nebo rovna pravděpodobnosti. Nulovou hodnotu možnosti přiřazujeme pouze nemožným jevům.



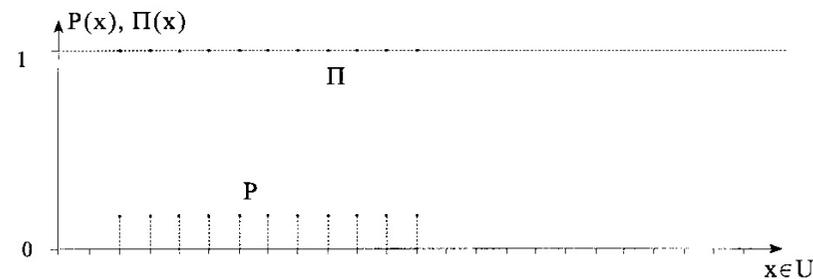
Distribuce pravděpodobnosti  $P$  a možnosti  $\Pi$  téhož diskrétního jevu, že v pětimístném osobním autě pojedou určitý počet osob

**Poznámka:** existuje rozšíření pojmu pravděpodobnosti také do fuzzy domény, takže dostáváme obecnější nástroj *fuzzy pravděpodobnost*. Fuzzy pravděpodobnost popisuje pravděpodobnosti, jejichž hodnota je známa nepřesně, vágně, přibližně.

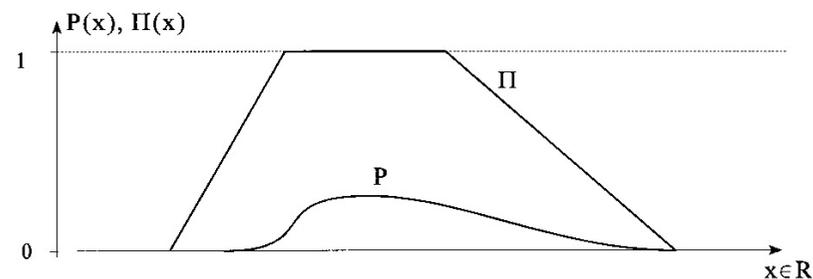
Pravděpodobnost je reálné číslo, které (je-li vágní) lze modelovat pomocí fuzzy čísla:

- pravděpodobnost nákazy touto nemocí je přibližně 0.015
- pravděpodobnost havárie je *nepatrná*
- pravděpodobnost, že akumulátor je vybitý, je *značně vysoká*

Možnost má charakter *nestatistický*, zatímco pravděpodobnost naopak *statistický*. I když je možné, že pan X. Y. sní na snídani 5 vajec, dlouhodobá pozorování indikují, že nikdy zatím nesnědl víc než 3.



Distribuce pravděpodobnosti  $P$  a možnosti  $\Pi$  téhož diskrétního jevu



Distribuce pravděpodobnosti  $P$  a možnosti  $\Pi$  téhož spojitého jevu

Distribuce možnosti indukovaná  $p$  je rovna fuzzy množině  $F$  a je definována následujícím přiřazením:

$$\Pi_x = F$$

což znamená, že pro všechny hodnoty  $x \in U$ ,  $\text{Poss}(X=x) = \mu_F(x)$ ,  $x \in U$ .