Fuzzy rendszerek

A fuzzy halmaz és a fuzzy logika

A hagyományos kétértékű logika, melyet évezredek óta alkalmazunk a tudományban, és amelyet *George Boole* (1815-1864) fogalmazott meg matematikailag, azon a feltételezésen alapszik, hogy valamely elem egy halmaznak vagy eleme, vagy sem. A kettő között átmenet nem létezik.
A világ, amelyben élünk, ettől kissé eltér. Vegyük például az alábbi, mindenki által ismert összetett mondatot: „*Ha végre itt a nyár és meleg az idő, az ember strandra jár*”. Amennyiben ez a mondat a kétértékű logika szerint lenne érvényes, akkor a strandnak nem kellene a nyári napforduló előtt kinyitnia, mert senki nem látogatná őket. Esős nyári napon szintén nem kellene kinyitnia, mert ugye nem szép az idő. A „*nyár van és szép az idő*” csak akkor igaz, ha mindkettő egyidejűleg teljesül. Pedig a valóság ettől merőben eltér. A strandok május elsejére kinyitnak, mert ugyan még nincs nyár, de ha szép idő van, akkor özönlik a tömeg a strandra. Miért is van ez? Mert a „*már nyár van*” és a „*még nincs nyár*” között átmenetek vannak. Mert a „*szép idő van*” nem mindenkinek jelenti pontosan ugyanazt. Apuka felhős időben is szívesen megissza sörét a medence mellett, de anyuka csak akkor viszi szívesen a gyerekeket strandra május elején, ha egyetlen felhőt sem lát az égen. Szóval a strandnak érdemes kinyitni akkor is, ha már eléggé nyár van, és elég esély van jó időre.
Vegyük például a „*nyár van*” állítást. Magyarországon pl. július 15.-én ez teljes mértékben teljesül és december 24.-én egyáltalán nem. De vajon mennyire van nyár május 29.-én? Vagy szeptember 19.-én? Az ilyen mennyiségek leírására hozta létre 1965-ben *Lotfi A. Zadeh* a fuzzy logikát.
A fuzzy logika szerint egy elem egy halmaznak nulla és egy közötti mértékig eleme lehet. Az x elem A halmazhoz való tartozásának mértékét a $_A(x)$ fuzzy tagságfüggvény adja meg, melynek értéke a [0,1] intervallum valamely eleme.
Például, ha egy útikönyv azt írja, hogy Lengyelországban 5 zlotyi egy liter benzin, az nem azt jelenti, hogy mindig és mindenhol pontosan annyi. A lengyel benzin az 5 zlotyis benzinek halmazához bizonyos fuzzy tagságfüggvény által leírt mértékig tartozik hozzá. Ez a tagságfüggvény sokféle lehet. Az 1. ábra ismertet néhány példát a leggyakrabban használt fuzzy tagságfüggvény alakokból.

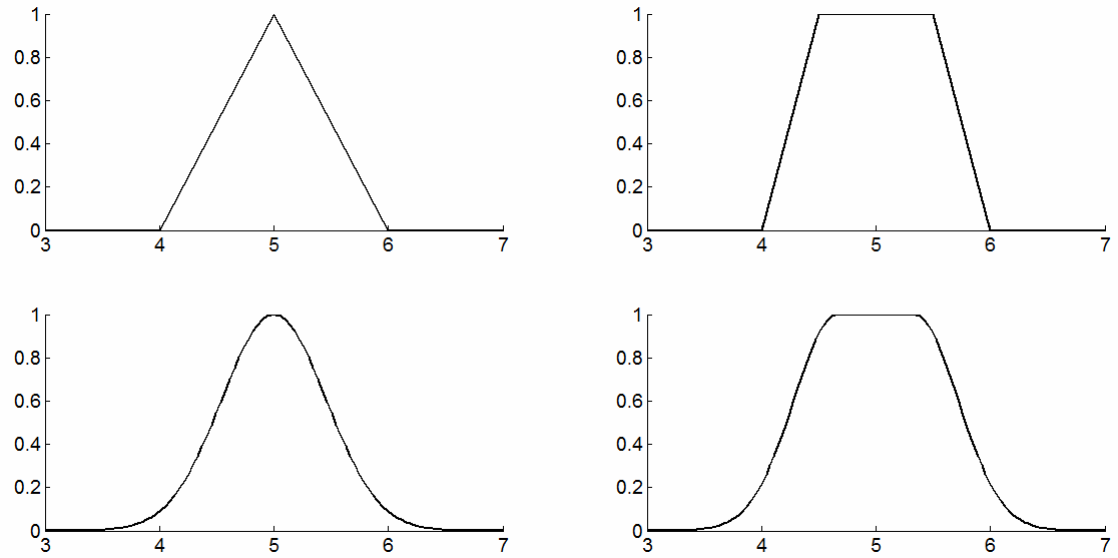

1. ábra. Néhány gyakran alkalmazott fuzzy tagságfüggvény alak. Mindegyik a „körülbelül öt” halmazt írja le

Most pedig hasonlítsuk össze a hagyományos kétértékű és a fuzzy logika alapfogalmait. Mindkét esetre tekintsük az A és B halmazokat, melyek az X alaphalmaz részhalmazai. A hagyományos logika szerint az A halmazt leírhatjuk a $\mu_A : X \to \{0,1\}$ karakterisztikus függvénnyel, mely definíció szerint bármely $x \in X$ esetén $\mu_A(x) = 1 \Leftrightarrow x \in A$ és $\mu_A(x) = 0 \Leftrightarrow x \notin A$. A fuzzy logikában a karakterisztikus függvény értéktartománya változik meg: $\mu_A : X \to [0,1]$, és így bármely $x \in X$ esetén az x elem A halmazhoz tartozásának mértékét a karakterisztikus függvény $\mu_A(x)$ értéke fogja meghatározni, melyet az x elem A halmazhoz viszonyított fuzzy tagságfüggvényének nevezünk.
A halmazokon végzett egyszerűbb műveletek összehasonlítására tekintsük meg az alábbi táblázatokat:

Művelet	Hagyományos kétértékű logika szerint
Üres halmaz	$\mu_\Phi(x) = 0 \quad \forall x \in X$
Komplemens halmaz	$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad \forall x \in X$
Egyesítés	$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad \forall x \in X$
Metszet	$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} = \mu_A(x) \cdot \mu_B(x) \quad \forall x \in X$

Művelet	Fuzzy logika szerint
Üres halmaz	$\mu_\Phi(x) = 0 \quad \forall x \in X$
Komplemens halmaz	$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad \forall x \in X$
Egyesítés	Általánosan: $\mu_{A \cup B}(x) \geq \max\{\mu_A(x), \mu_B(x)\} \quad \forall x \in X$ Mamdani szerint: $\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad \forall x \in X$ Larsen szerint: $\mu_{A \cup B}(x) = 1 - (1 - \mu_A(x)) \cdot (1 - \mu_B(x)) \quad \forall x \in X$
Metszet	Általánosan: $\mu_{A \cap B}(x) \leq \min\{\mu_A(x), \mu_B(x)\} \quad \forall x \in X$ Mamdani szerint: $\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad \forall x \in X$ Larsen szerint: $\mu_{A \cap B}(x) = \mu_A(x) \cdot \mu_B(x) \quad \forall x \in X$

A fenti táblázatokban megfigyelhető, hogy vannak olyan műveletek, amelyeket nem csak egyféleképpen lehet értelmezni. A Mamdani és Larsen-féle fuzzy logika csak kettő a sok értelmezés közül. Ezek közötti különbséget látni fogjuk a továbbiakan.

A fuzzy partíció

A fuzzy logika tagságfüggvényei lehetővé teszik, hogy különböző elemeket különböző mértékig soroljunk bele valamely halmazba. Ezt a lehetőséget felismertve, Ruspini [3] 1969-ben bevezette a valószínűségi fuzzy partíció fogalmát, mely szerint ha az X alaphalmaz elemeit A_1, $A_2 \ldots A_c$ halmazokba kívánjuk besorolni, akkor a $\mu_1(x) + \mu_2(x) + \ldots + \mu_c(x) = 1$ lesz. Így azt is mondhatjuk, hogy valamely A_i osztályhoz tartozást leíró $\mu_i(x)$ fuzzy tagságfüggvény megmutatja, hogy az x elem milyen *valószínűség*gel tartozik az A_i osztályhoz.
A fuzzy Ruspini-féle valószínűségi fuzzy partíciót alkalmazásaképpen, 1981-ben Bezdek [4] bevezette az ún. fuzzy c-means (FCM) klaszterező (csoportosító) algoritmust, melynek segítségével az X alaphalmaz vektoriális (vagy sajátos esetben skaláris) adatait optimálisan csoportosíthatjuk egymáshoz hasonló egyedek halmazára. Az FCM algoritmus előre eldönti,

hogy hány osztályba fogja sorolni az adatokat, ezt jelöljük c-vel. Minden osztálynak lesz egy reprezentatív eleme vagy prototípusa (v_i , $i = 1 \ldots c$), amely az adott osztályba tartozó bemeneti adatoknak egy súlyozott átlaga lesz. Az x_k ($k = 1 \ldots n$) bemeneti adat v_i osztály prototípushoz való hasonlóságát vagy különbségét jellemezhetjük a kettő közötti távolsággal, melyet vektoriális környezetben normaként értelmezünk: $d_{ik} = \|x_k - v_i\|$. Euklideszi távolságot használva ezt így is írhatjuk: $d_{ik} = \|x_k - v_i\| = \sqrt{(x_k - v_i)^T (x_k - v_i)}$.
Az FCM algoritmus egy optimális valószínűséget számít ki, egy négyzetes célfüggvény minimumának meghatározásával. A célfüggvény a következő:

$$J_{FCM} = \sum_{i=1}^{c} \sum_{k=1}^{n} \mu_{ik}^m \|x_k - v_i\|^2 = \sum_{i=1}^{c} \sum_{k=1}^{n} \mu_{ik}^m d_{ik}^2 \tag{1}$$

ahol az egyszerűség kedvéért használtuk a $\mu_{ik} = \mu_i(x_k)$ jelölést az x_k adat i-dik osztályhoz való tartozás fuzzy tagságfüggvényéhez, továbbá m jelöli a Bezdek-féle fuzzy kitevőt, melynek értékével ($m > 1$) az algoritmus fuzzy jellegét lehet szabályozni. A célfüggvény minimumának megkeresése során azt várjuk, hogy a v_i osztály prototípusok olyan helyre álljanak be, ahol sok bemeneti adathoz közel lehetnek, továbbá olyan fuzzy partíciót kapjunk, melyben egy osztály prototípushoz közel eső adatok nagy valószínűséggel tartozzanak az adott osztályhoz, míg a távol eső adatok alacsony tagságfüggvény értéket kapjanak. A célfüggvény minimumát a Ruspini-féle valószínűségi megkötés megtartása mellett hajtjuk végre. Bezdek a célfüggvény parciális deriváltjainak zérus átmeneteiből, Lagrange szorzók alkalmazásával határozta meg az iteratív minimumkereső eljárás ismétlődő lépéseit:

$$\mu_{ik} = \frac{d_{ik}^{-2/(m-1)}}{\sum_{j=1}^{c} d_{jk}^{-2/(m-1)}} \qquad \forall i = 1 \ldots c \ \forall k = 1 \ldots n \tag{2}$$

$$v_i = \frac{\sum_{k=1}^{n} \mu_{ik}^m x_k}{\sum_{k=1}^{n} \mu_{ik}^m} \qquad \forall i = 1 \ldots c \tag{3}$$

A (2) és (3) egyenletekben leírt számításokat addig kell ismételni, amíg az osztály prototípusok konvergenciája bekövetkezik. Végül a kialakult partíciót defuzzyfikálhatjuk, azaz meghatározhatjuk, melyik bemeneti adat melyik osztályhoz tartozik leginkább. Ez matematikailag így fogalmazható meg:

$\forall k = 1 \ldots n$ esetén x_k vektort abba a j-dik osztályba soroljuk be, amelyre

$$j = \arg\max_i \{\mu_{ik}, i = 1 \ldots c\} \tag{4}$$

Vizsgáljuk meg egy kicsit a (2)-es formulát: az x_k vektornak az i-dik osztályhoz való tartozását leíró fuzzy tagságfüggvény értékét egy tört formájában számítjuk ki. A tört számlálója a $d_{ik} = \|x_k - v_i\|$ távolságnak egy negatív hatványa, azaz minél közelebb van az x_k vektor a v_i osztály prototípushoz, annál nagyobb fuzzy tagságfüggvénnyel fog az i-dik

osztályhoz tartozni. Amennyiben x_k és v_i egybeesik, a μ_{ik} tagságfüggvény értéke aszimptotikusan tart az 1-es érték felé, míg az összes többi μ_{jk} nulla lesz ($i \neq j$).

A (3)-as formula a bemeneti vektoroknak egy-egy súlyozott átlagaként számítja ki az osztály prototípusok új értékét, ahol a súlyok a legutóbb kiszámított fuzzy tagságfüggvényeknek az m-dik hatványai.

Most pedig egy konkrét példa segítségével figyeljük meg, hogy az FCM algoritmus milyen fuzzy tagságfüggvényeket számít ki különböző m fuzzy kitevők esetén. Egy tanár tesztet íratott a diákjaival, majd az elért pontszámokat FCM algoritmussal csoportosította 5 osztályba, és ezeket minősítette elégtelen, elégséges, közepes, jó és jeles osztályzattal. A 4. ábrán megfigyelhetjük, hogy különböző m értékek esetén hogyan néznek ki az egyes osztályok fuzzy tagságfüggvényei: $m = 2$ esetén a Gauss-féle haranghoz, $m = 3$ esetén háromszöghöz, míg $m < 2$ kitevőnél a trapézhoz hasonló tagságfüggvényeink lesznek. Ugyanakkor megfigyelhetjük, hogy az $m \to 1_+$ fuzzy kitevőnél a kétértékű, hagyományos logikát közelítjük, ahol minden elem egyetlen osztályhoz tartozik hozzá, 1-es tagságfüggvény értékkel. Ha pedig a fuzzy kitevőt nagyon megnöveljük, minden fuzzy tagságfüggvény értéke tart $1/c$ felé. Ez utóbbi eset nem vezet elfogadható osztályozáshoz.

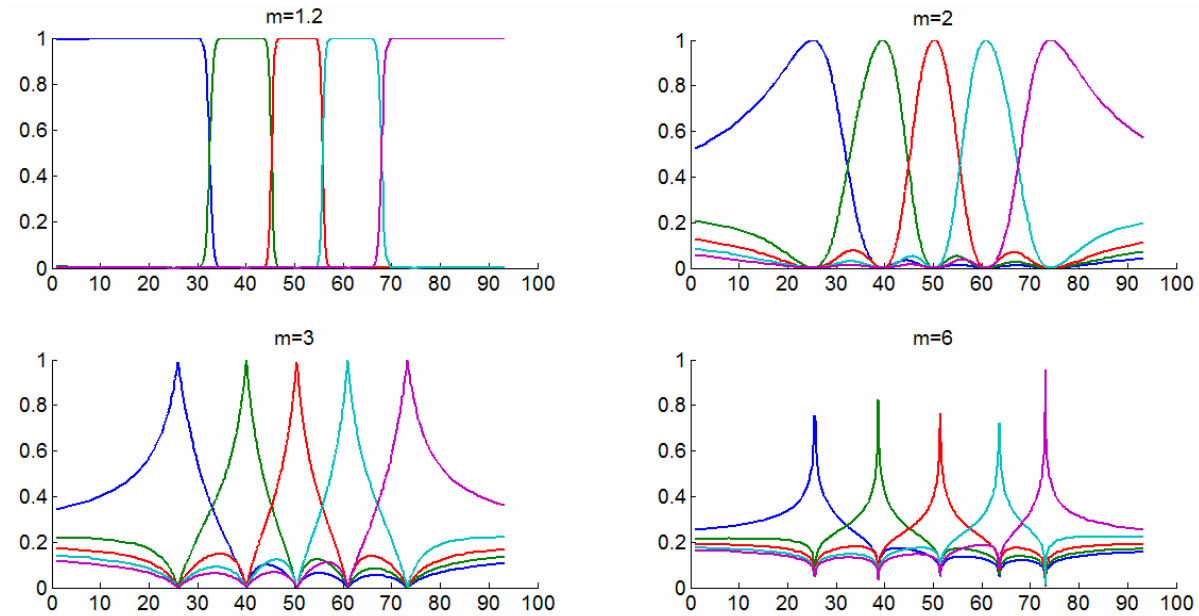

2. ábra. Az FCM algoritmus eredményeként kapott, változatos fuzzy tagságfüggvény alakok

A fuzzy inferencia

Három fuzzy jóbarát mindig a város valamely étteremében találkozik, és egy vacsora elfogyasztása mellett megvitatják legújabb fuzzy felfedezéseiket. Szokás szerint a vacsora után az ételt is és a kiszolgálást is egy-egy 0 és 10 közé eső osztályzattal minősítik, majd ezekből a számokból fuzzy inferenciával számolják ki, hogy hány százalék borravaló jár a személyzetnek az [5,25] intervallumból.

A baráti társaság fuzzy szabályrendszere a következőkből áll:

1. Az ételt négyféle fuzzy tagságfüggvénnyel kategorizálják. A besorolás szerint az étel lehet ehetetlen, ehető, finom és ízletes.
2. A kiszolgálás minőségét három fuzzy halmazba sorolják: a kiszolgálás lehet rossz, közepes és jó.

A 3. ábrán megtekinthetjük a bemeneti adatok kategorizálását leíró fuzzy tagságfüggvényeit.

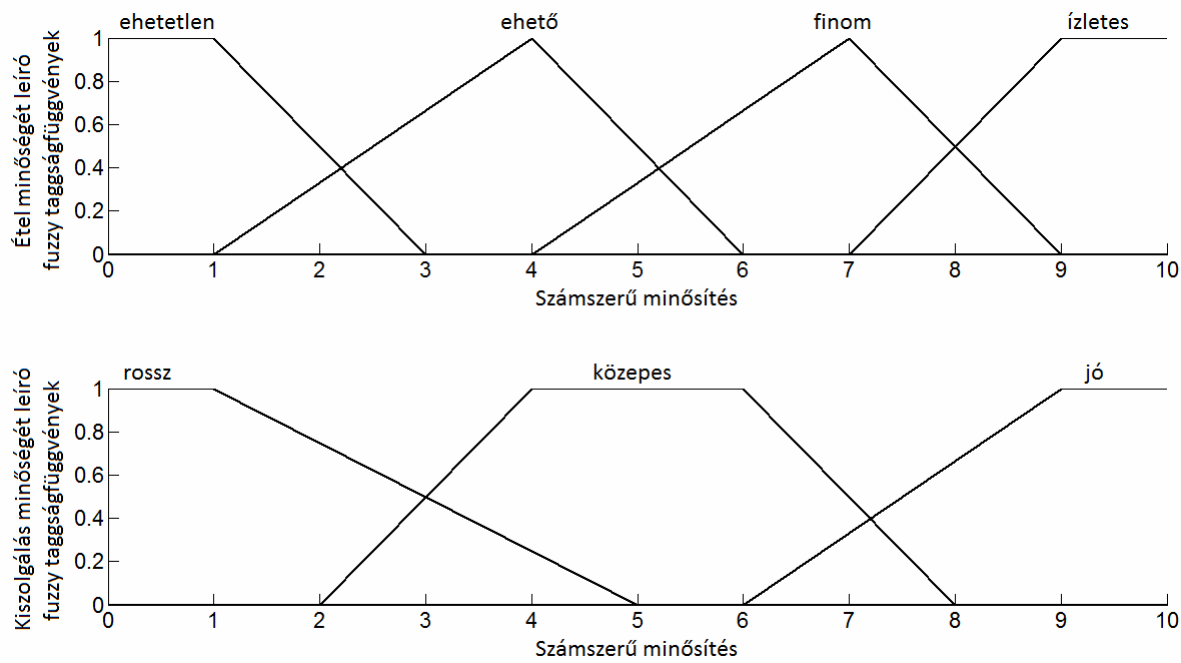

3. ábra. Fent: étel minőségét leíró fuzzy tagságfüggvények. Lent: a kiszolgálás minőségét leíró fuzzy tagságfüggvények

3. Négyféle fuzzy osztály jellemzi borravalót (lásd 4. ábra), amely lehet skót, magyar, német, és milliomos.

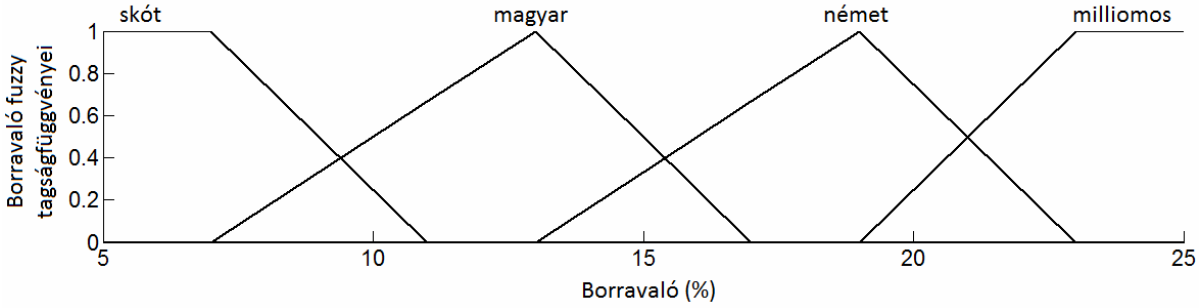

4. ábra. A borravaló fuzzy tagságfüggvényei

4. A bemeneti adatok (étel és szolgáltatás minősége) fuzzy tagságfüggvényei és a kimenő adat (borravaló) fuzzy tagságfüggvényei között fuzzy szabályokkal teremtenek kapcsolatot, az alábbi formában:

HA az étel ehető ÉS a kiszolgálás jó AKKOR a borravaló magyar

5. Ha az egyik bemenő adatnak 4, a másiknak pedig 3 fuzzy osztálya van, akkor elvileg 4×3=12 fuzzy szabályt kell felírnunk ahhoz, hogy mindegyik lehetséges bemenetre megoldást szolgáltassunk. Jelen konkrét feladat 12 fuzzy szabályát az alábbi

táblázatban foglaltuk össze. A táblázat szerint, pl. ízletes étel és közepes kiszolgálás esetén német borravaló jár.

	ehetetlen	Ehető	finom	ízletes
rossz	skót	Skót	magyar	magyar
közepes	skót	magyar	német	német
jó	magyar	magyar	német	milliomos

Most pedig alkalmazzuk a baráti társaság fuzzy inferenciáját három konkrét vacsorájuk esetére. Az 5. ábrán három különböző színnel jelöltük a különböző éttermek osztályzatait. A piros étteremben az étel minőségének 2,5-es osztályzata $\beta_1 = 1/4$ illeszkedési mértékkel bír az ehetetlen fuzzy osztályra, valamint $\beta_2 = 1/2$-del az ehető osztályra nézve. A kiszolgálás minősége viszont 8,5-es osztályzatot kapott, amellyel csak a jó fuzzy osztályhoz illeszkedik, $\beta_1^{/} = 5/6$ mértékig. Hasonló módon leolvashatjuk a zöld és kék étterem osztályzatait és illeszkedési mértékeit a különböző fuzzy halmazokra nézve.

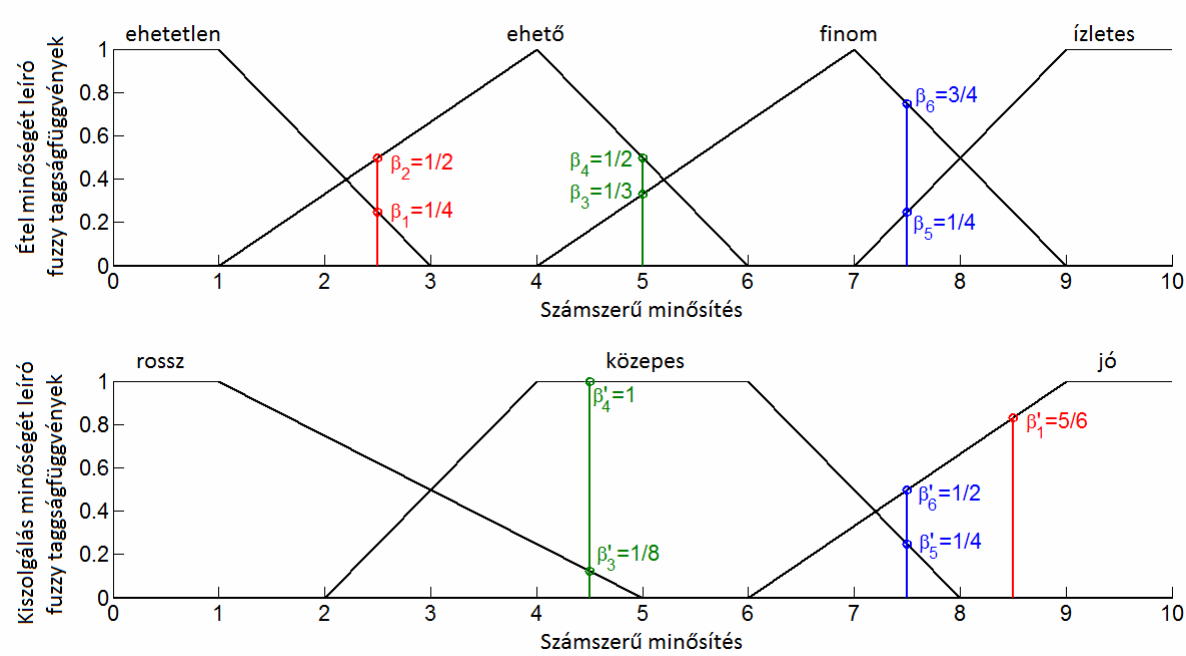

5. ábra. A három étteremnek adott számszerű osztályzatok és azok illeszkedési mértékei a fuzzy tagságfüggvényekhez

Alkalmazzuk a fuzzy szabályokat mindhárom étterem esetében!

A zöld étterem esete

1. Ha az étel $\beta_3 = 1/3$ mértékig finom és a kiszolgálás $\beta_3^{/} = 1/8$ mértékig rossz, akkor a borravaló $\min\{\beta_3, \beta_3^{/}\} = 1/8$ mértékig magyar.
2. Ha az étel $\beta_3 = 1/3$ mértékig finom és a kiszolgálás $\beta_4^{/} = 1$ mértékig közepes, akkor a borravaló $\min\{\beta_3, \beta_4^{/}\} = 1/3$ mértékig német.
3. Ha az étel $\beta_4 = 1/2$ mértékig ehető és a kiszolgálás $\beta_3^{/} = 1/8$ mértékig rossz, akkor a borravaló $\min\{\beta_4, \beta_3^{/}\} = 1/8$ mértékig skót.

4. Ha az étel $\beta_4 = 1/2$ mértékig ehető és a kiszolgálás $\beta_4^{/} = 1$ mértékig közepes, akkor a borravaló $\min\{\beta_4, \beta_4^{/}\} = 1/2$ mértékig magyar.

A 6. ábra felső részén látható a zöld étterem osztályzatának mind a négy lehetséges esete: a zöld vonalak behatárolják a kimeneti fuzzy tagságfüggvényeket a kiszámított illeszkedési mértékekig. Ez a grafikus ábrázolás a konkrét feladat fuzzy kimenete. Amennyiben egyetlen skaláris értékkel meg akarjuk nevezni a fizetendő borravaló százalékot, defuzzyfikálni kell a kimenetet. Ehhez meg kell határoznunk, hogy a zöld vonalak alatti terület súlypontja hol helyezkedik el a vízszintes tengely mentén.

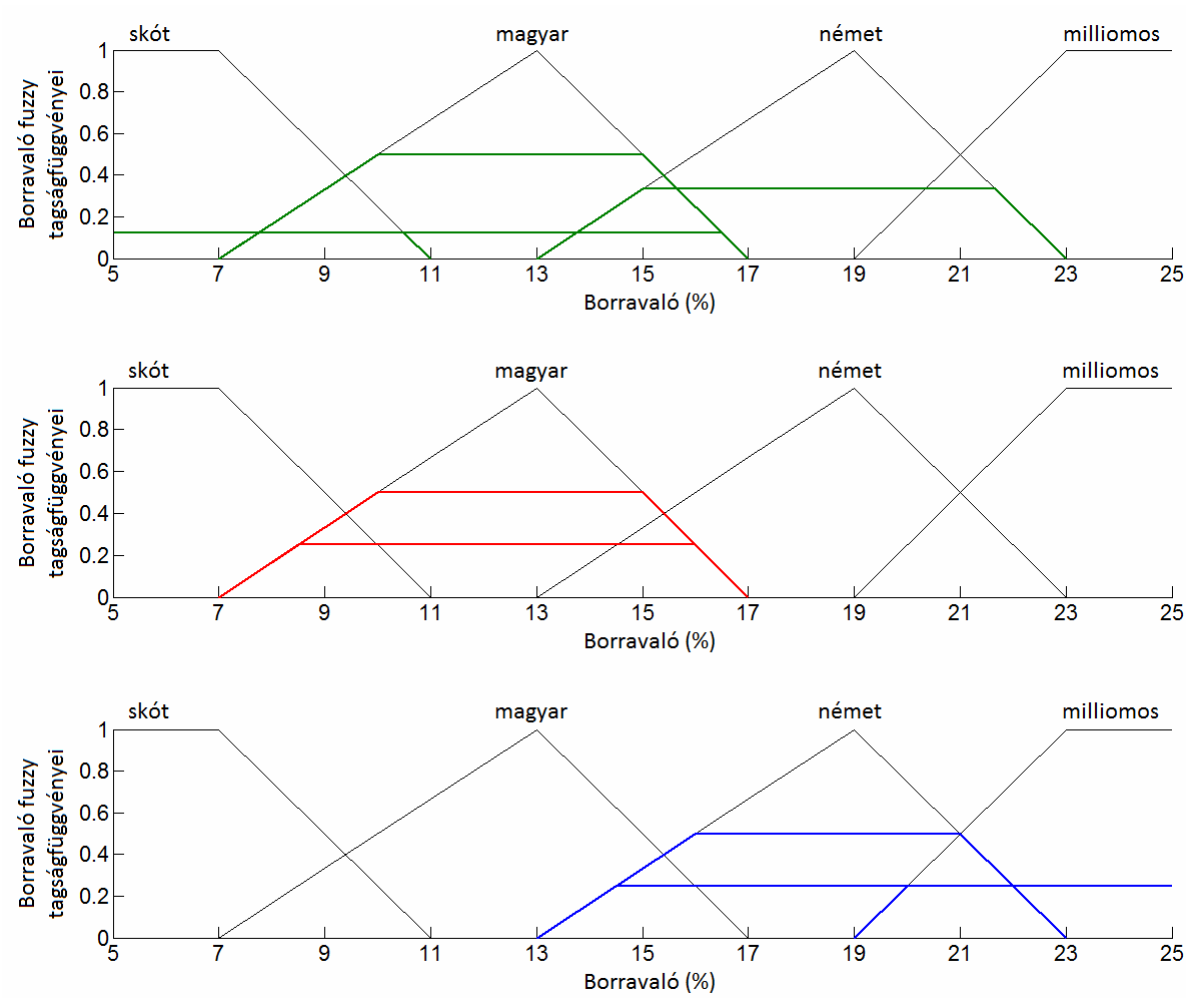

6. ábra. A fuzzy szabályokat alkalmazva mindhárom étterem esetére, az itt látható fuzzy kimeneteket kapjuk

A piros és kék étterem esetén kapott fuzzy kimenetet is megtaláljuk a 8. ábrán. Most határozzuk meg, melyik étteremben mekkora borravalót fizetett a baráti társaság. A színes vonalak és a vízszintes tengely által közrezárt terület súlypontja a piros étterem esetében határozható meg a legkönnyebben. Egyszerű geometriai műveletekkel belátható, hogy a vízszintes tengely mentén a súlypont $12\frac{2}{9}$ -nél, azaz 12.22-nél helyezkedik el. Ennek megfelelően a vacsoravendégek 12.22% borravalót fizettek a piros étteremben. A másik két esetben a fuzzy kimenetet egy sokkal összetettebb alakzat ír le, melynek súlypontját sokkal nehezebb geometriai műveletekkel meghatározni. Sokkal könnyebb ilyen esetben numerikus megközelítést alkalmazni. A defuzzyfikált eredmény azt mutatja, hogy a zöld étteremben 13.85%, míg a kék étteremben 19.01% borravalót fizettek a fuzzy vendégek.

A fentiekben ismertetett teljes eljárást, ahogyan a numerikus bemenetekből a bemeneti fuzzy tagságfüggvények és a fuzzy szabályok segítségével eljutunk a fuzzy kimenethez, és azt a súlypont módszerével defuzzyfikáljuk, Mamdani-féle inferenciának nevezzük.

Létezik egy nagyon hasonló, a Mamdani-féle inferenciától csupán apró részleteiben eltérő inferencia eljárás is, amelyet Larsen vezetett be. A Larsen-féle inferencia sajátossága az, hogy a fuzzy szabály alkalmazásakor a következőképpen jár el. Ha az egyik bemenet β mértékig illeszkedik egy bizonyos fuzzy tagságfüggvényhez és a másik bemenet $\beta^{/}$ mértékig egy másik fuzzy tagságfüggvényhez, akkor a kimenet nem $\min\{\beta, \beta^{/}\}$, hanem $\beta\beta^{/}$ mértékig fog az adott fuzzy szabály által előírt kimeneti fuzzy tagságfüggvényhez illeszkedni. Tehát a Larsen-féle inferenciánál a bemeneti illeszkedési mértékek összeszorzódnak. Hogy ez mekkora különbséget jelent? Konkrétan, a piros étterem esetében a kimeneti diagramon a piros trapéz magassága 1/2 helyett 5/12 lenne, és így a borravaló analitikus pontossággal $12\frac{65}{342}$ %, numerikus megközelítéssel 12.19% lenne.

A fuzzy rendszernek kettőnél sokkal több bemenete is lehet. Ha mindegyik bemenethez hozzárendelünk 3-4 fuzzy tagságfüggvényt, akkor hat bemenet esetén már ezres nagyságrandű fuzzy szabályra lesz szükség, és ez rendkívül körülményessé teheti mind a fuzzy kimenet kiszámítását, mind pedig a defuzzyfikálás folyamatát. Ezt a problémát kívánja leküzdeni a Takagi-Sugeno-Kang-féle (TSK) inferencia. Egy TSK rendszer ugyanúgy megvizsgálja a bemenetek illeszkedését a különböző fuzzy osztályokhoz, mint a Mamdani-féle rendszer, viszont a fuzzy szabályokat és a defuzzyfikálást egy egyszrűsített eljárással valósítja meg. A TSK rendszer működésének megértésére vegyük megint a zöld étterem esetét.

A bemeneti, számszerű minősítés az étel esetében $x = 5$, míg a kiszolgálásé $x^{/} = 4.5$ volt. Most lássuk a fuzzy szabályokat:

1. Ha az étel $\beta_3 = 1/3$ mértékig finom és a kiszolgálás $\beta_3^{/} = 1/8$ mértékig rossz, akkor a borravaló $\gamma_1 = \min\{\beta_3, \beta_3^{/}\} = 1/8$ mértékig $y_1 = f_{magyar}(x, x^{/})$ lesz.
2. Ha az étel $\beta_3 = 1/3$ mértékig finom és a kiszolgálás $\beta_4^{/} = 1$ mértékig közepes, akkor a borravaló $\gamma_2 = \min\{\beta_3, \beta_4^{/}\} = 1/3$ mértékig $y_2 = f_{német}(x, x^{/})$ lesz.
3. Ha az étel $\beta_4 = 1/2$ mértékig ehető és a kiszolgálás $\beta_3^{/} = 1/8$ mértékig rossz, akkor a borravaló $\gamma_3 = \min\{\beta_4, \beta_3^{/}\} = 1/8$ mértékig $y_3 = f_{skót}(x, x^{/})$ lesz.
4. Ha az étel $\beta_4 = 1/2$ mértékig ehető és a kiszolgálás $\beta_4^{/} = 1$ mértékig közepes, akkor a borravaló $\gamma_4 = \min\{\beta_4, \beta_4^{/}\} = 1/2$ mértékig $y_4 = f_{magyar}(x, x^{/})$ lesz.

Miután az összes nem nulla illeszkedési mérték esetét végigvettük, a végső kimenetet egy egyszerű átlagolással határozzuk meg:

$$y = \frac{\sum_i \gamma_i y_i}{\sum_i \gamma_i},$$

ahol i bejárja az összes fennebb tárgyalt fuzzy szabály esetét, jelen konkrét példánál $i = 1 \ldots 4$. A fuzzy szabályok alkalmazásakor felhasznált függvények ($f_{skót}$, f_{magyar}, $f_{német}$, és $f_{milliomos}$) előre meghatározott, legtöbbször lineáris függvények szoktak lenni.

Tehát a Mamdani-féle és a TSK inferencia modell a számszerű adatok fuzzyfikálását, valamint a fuzzy szabályok alkalmazását teljesen azonos módon végzik. A különbség a fuzzy kimenet meghatározásnál és a defuzzyfikálásnál van: a TSK modell fuzzy kimenetet nem állít elő, hanem egyből számszerű kimenetet ad.

Egy másik, gyakran alkalmazott megoldás a komplikált fuzzy kimenet kiszámításának és defuzzyfikálásának elkerülésére, hogy a teljes fuzzy rendszer viselkedését megtanítják egy neurális hálózatnak. A neurális hálózat tanításához tanulási adatok kellenek. Ezeket úgy hozzák létre, hogy sok különféle bemenetre megállapítják a komplikált fuzzy rendszer milyen kimenetet ad. Ezek a kimenetek lesznek az elvárt értékek a neurális hálózat tanítása során, amikor ugyanazokat a bemenetet kapja a neurális hálózat, mint előzőleg a fuzzy rendszer. Amikor a neurális hálózat képes a tanulási adatokra megfelelő, a fuzzy rendszerével megközelítőleg azonos kimenetet adni, akkor további tesztadatokra is képes lesz modellezni a fuzzy rendszer működését. A kimenet csak megközelítőleg lesz ugyanaz, mint a fuzzy rendszer esetében, de ezt a kimenetet sokkal gyorsabban ki lehet számítani. Az ilyen, neurális hálózattal modellezett fuzzy rendszereket neuro-fuzzy rendszereknek nevezzük.

A fuzzy szabályozó

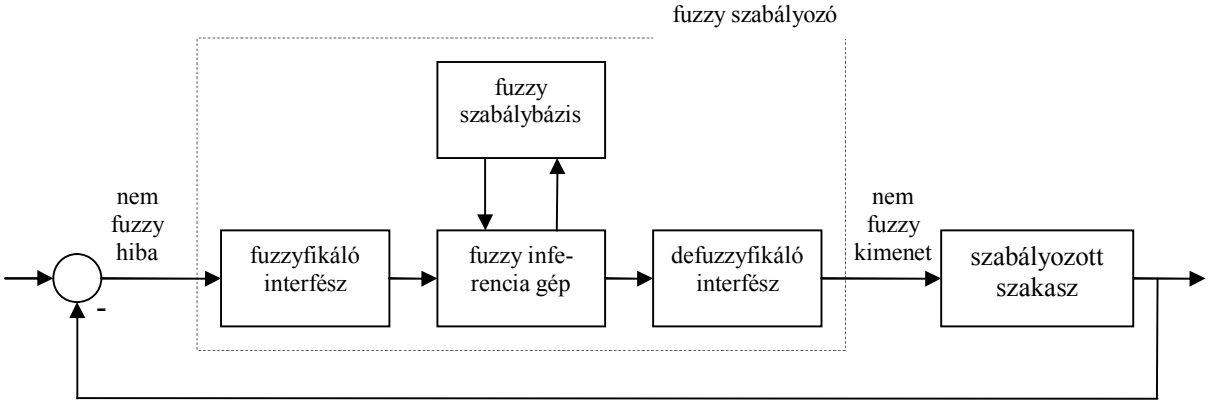

7. ábra. Szabályozó kör fuzzy szabályozóval

A fuzzy szabályozó funkcionálisan egy fekete doboz, melynek bemenete az elvárt referencia jel és a kimeneti jel különbsége, kimenete pedig a szabályozott szakasznak adott szabályozási parancs. Mind a bemenet, mind pedig a kimenet egy-egy nem fuzzy mennyiség. A szabályozó belsejében viszont megtalálható a nem fuzzy bemenetet fuzzyfikáló interfész, egy fuzzy inferencia gép, mely –a fuzzy szabálybázis alapján– előállítja a fuzzy kimenetet, és a defuzzyfikáló interfész, amelyik a fuzzy kimenetből nem fuzzy kimenetet állít elő. Az inferencia gép bármely ismertetett inferencia típust tartalmazhatja.

Irodalom

[1] Zadeh LA: Fuzzy sets. *Inform. Control* 8:338-353, 1965
[2] Mamdani EH: Advances in the linguistic synthesis of fuzzy controllers. *Int. J Man-Mach. Stud.* 7:1-13, 1974
[3] Ruspini EH: A new approach to clustering. *Inform. Control* 15:22-32, 1969
[4] Bezdek JC: *Pattern recognition with fuzzy objective function algorithms.* Plenum, New York, 1981