

Girona

Modelització de decisions i sistemes de presa de decisions*

Vicenç Torra¹

Maig, 2012

¹ Institut d'Investigació en Intel·ligència Artificial (IIIA-CSIC)

*V. Torra, Y. Narukawa (2007) Modelització de decisions: fusió d'informació i operadors d'agregació.
Edicions UAB

Índex

- Presa de decisions
 - Introducció
 - MCDM i elecció social
 - Preferències
 - Utilitats
 - Agregació: introducció

Introducció

- Presa de decisions:
 - Triar entre diverses alternatives.
- Exemple:
 - Volem comprar un cotxe, i hi ha diversos models.
 - Alternatives: $\{Peugeot308, FordT., \dots\}$

Introducció

- Multicriteria Decision Aid (MCDA) i Multicriteria Decision Making (MCDM)
 - Ofereixen eines per ajudar en la presa de decisions.
 - Dificultat del problema:
 - Hi ha diverses alternatives
 - Cal tenir en compte diversos punts de vista o criteris (sovint contradictoris)

Introducció

- Multicriteria Decision Aid (MCDA) i Multicriteria Decision Making (MCDM)
 - Ofereixen eines per ajudar en la presa de decisions.
 - Dificultat del problema:
 - Hi ha diverses alternatives
 - Cal tenir en compte diversos punts de vista o criteris (sovint contradictoris)
 - MCDA: Es donen eines per capturar, entendre i analitzar les diferències (punt de vista constructivista)
 - MCDM: Es donen eines per descriure el procés de decisió. Es suposa que es pot formalitzar el procés de decisió (punt de vista descriptiu)

Introducció

- L'exemple de la compra del cotxe:
 - Alternatives: $\{Peugeot\text{308}, Ford\text{T.}, \dots\}$
 - Punts de vista/criteris: Preu, Qualitat, Confort
- MCDA: Es donen eines per capturar, entendre i analitzar les diferències
- MCDM: Es donen eines per descriure el procés de decisió.

Introducció: MCDM

- El procés descriptiu es formula en termes matemàtics.
 - Funcions d'utilitat.
 - Cal disposar d'una funció per a cada criteri.
 - La funció s'aplica a cada alternativa.
 - La funció retorna un valor més gran per a les alternatives que satisfan millor el criteri.
 - Relacions de preferències (comparació entre les diverses alternatives)
 - Cal disposar d'una relació binària per a cada criteri.
 - Cada relació ens ordena les alternatives segons el criteri considerat.

Introducció

- L'exemple de la compra del cotxe:
 - Alternatives: $\{Peugeot308, FordT., \dots\}$
 - Punts de vista/criteris: Preu, Qualitat, Confort
- Formalització:
 - Funció d'utilitat (U):
 - Ford T: $U_{preu} = 0.2, U_{qualitat} = 0.8, U_{confort} = 0.3$
 - Peugeot308: $U_{preu} = 0.7, U_{qualitat} = 0.7, U_{confort} = 0.8$
 - Relacions de preferència (R)
 - R_{preu} : $R_{preu}(P308, FordT), \neg R_{preu}(FordT, P308)$
 - $R_{qualitat}$: $\neg R_{qualitat}(P308, FordT), R_{qualitat}(FordT, P308)$
 - $R_{confort}$: $R_{confort}(P308, FordT), \neg R_{confort}(FordT, P308)$

Introducció

- En el marc de MCDA o MCDM es distingueixen dues àrees:
 - MODM (Multi-Objective Decision Making): correspon a la situació amb un **nombre infinit d'alternatives** (espais d'alternatives continu).
 - MADM (Multi-Attribute Decision Making): correspon a la situació en que el **nombre d'alternatives** és petit
 - Sovint s'entén MCDM com a sinònim de MADM.
 - L'exemple de la tria de cotxes: un problema MADM/MCDM

MODM (multi-objective decision making): aquests problemes es formulen normalment mitjançant **problemes d'optimització**, i es resolen amb mètodes de programació matemàtica (tipus SIMPLEX). S'han aplicat també altres tècniques com ara els algorismes genètics.

MCDM i elecció social

MCDM i elecció social

- MCDM (decisió) i l'elecció social.
⇒ són dues àrees relacionades.

MCDM i elecció social

- L'elecció social (social choice)
 - estudia regles de votació, i com les preferències d'un conjunt de gent es poden agregar (combinar) per obtenir la preferència del conjunt.
- Tot i que en l'elecció social estem construint una preferència global a partir d'opinions de persones en lloc de criteris, des d'un punt de vista formal no hi ha gaire diferència entre els dos casos¹.
 - Les persones no *decideixen*, només expressen les seves **preferències**
- Així, (*informalment*)
 - l'elecció social *ignora* les persones
 - l'elecció social *només* estudia com *agregar* les preferències i construir la preferència composta

¹A. Rapoport, Decision Theory and Decision Behaviour, Kluwer Academic Publishers, 1989. p. 5

MCDM i elecció social

- Regla de la majoria (elecció social vs. MCDM):
 - L'alternativa seleccionada és la preferida per la majoria de gent.
 - L'alternativa seleccionada és la que guanya en tots els criteris.

MCDM i elecció social

- Exemple (de MCDM/presa de decisions):
 - El Peugeot 308 és millor en quant a preu i a confort (guanya 2 vegades)
 - El Ford T només és millor en qualitat (guanya 1 vegada)
- Guanya el Peugeot 308
- Exemple (d'elecció social)
 - Una família de 3 membres $\{p, q, c\}$ volen comprar un cotxe
 - * p prefereix el Peugeot 308
 - * q prefereix el Ford T
 - * c prefereix el Peugeot 308
 - Fan una votació (cadascú vota el que prefereix):
 - * guanya l'opció Peugeot 308.

MCDM i elecció social

- Regla de la majoria (elecció social vs. MCDM):
 - L'alternativa seleccionada és la preferida per la majoria de gent.
 - L'alternativa seleccionada és la que guanya en tots els criteris.
- En aquesta regla només considerem l'alternativa més preferida (per a cada criteri), però no com estan *ordenades* les altres opcions.

MCDM i elecció social

- Donades les preferències, com construir l'agregació?
 - Formalització de les preferències amb $>_i$ (preferència, indiferència)
 - $F(R_1, R_2, \dots, R_N)$ per denotar la preferència agregada

MCDM i elecció social

- Donades les preferències, com construir l'agregació?
 - Formalització de les preferències amb $>$ i = (preferència, indiferència)
 - $F(R_1, R_2, \dots, R_N)$ per denotar la preferència agregada
 - Dificultats (I): considerem
 - * $R^1 : x > y > z$
 - * $R^4 : y > z > x$
 - * $R^5 : z > x > y$
 - regla de la majoria simple: $u > v$ si la majoria prefereix u a v
 - * $x > y, y > z, z > x$ (rel. intransitiva: $x > y, y > z$ però no $x > z$)
 - Dificultats (II):
 - Teorema d'impossibilitat d'Arrow

MCDM i elecció social

- Donades les preferències, com construir l'agregació?
 - Formalització de les preferències amb $>_i$ (preferència, indiferència)
 - $F(R_1, R_2, \dots, R_N)$ per denotar la preferència agregada

MCDM i elecció social

- Donades les preferències, com construir l'agregació?
 - Formalització de les preferències amb $>_i$ (preferència, indiferència)
 - $F(R_1, R_2, \dots, R_N)$ per denotar la preferència agregada
 - Solucions
 - * Regla de Copeland (variació de Condorcet)²:
 - * Regla de Borda³

²La regla de Condorcet amb el desempat de Copeland va ser definit per Ramon Llull (s. XIII) en diversos treballs. Per exemple, a la novel·la Blanquerna.

³Nicolau de Cusa va introduir la regla de Borda el s. XV.


Utilitats

Utilitats

- Problema MADM/MCDM amb utilitats
 - Dificultat: el tenir en compte els punts de vista contradictoris
 - Solució: Les utilitats ens permeten expressar aquests punts de vista (contradictoris)
 $\Rightarrow U_i(\text{alternativa})$


Utilitats

- Problema MADM/MCDM amb utilitats
 - Dificultat: el tenir en compte els punts de vista contradictoris
 - Dificultat: el que te una alternativa de bo en un criteri, ho te de dolent en un altre; i tenim una alternativa amb comportaments inversos
- Es diu que una situació és **òptim de Pareto** (o Pareto-eficient) quan no és possible que ningú hi obtingui un guany superior sense que hi perdi algú altre.



Utilitats

- Problema MADM/MCDM amb utilitats
 - Dificultat: el tenir en compte els punts de vista contradictoris
 - Dificultat: el que te una alternativa de bo en un criteri, ho te de dolent en un altre; i tenim una alternativa amb comportaments inversos
- com *ordernar* les alternatives òptim de Pareto o Pareto-eficient ?



Utilitats

- Solució d'un problema MADM/MCDM amb utilitats

Opció 1: Construim relacions, i treballem amb preferències
(cas anterior: MCDM i elecció social)

Opció 2:

- **Agreguem** els graus de satisfacció/utilitat
- Ordenem les alternatives segons els graus de satisfacció
→ seleccionem l'alternativa (o el conjunt d'alternatives) millor

| Criteria | | | | Consensus | | Ranking | |
|----------|-------|---------|---------|-----------|-----------|---------|---------|
| alt | Price | Quality | Comfort | alt | Consensus | alt | Ranking |
| FordT | 0.2 | 0.8 | 0.3 | FordT | 0.35 | 206 | 0.72 |
| 206 | 0.7 | 0.7 | 0.8 | 206 | 0.72 | FordT | 0.35 |
| ... | ... | ... | ... | ... | ... | ... | ... |

→ →

Utilitats

Opció 2:


- **Agreguem** els graus de satisfacció/utilitat
- Ordenem les alternatives segons els graus de satisfacció

Agregacions:

- Agregacions diferents, donen ordenacions diferents
- Les agregacions estableixen quins **punts** són *equivalents*
- Agregacions diferents, estableixen corbes de punts diferents

| Criteria Satisfaction on: | | | | Consensus | | Ranking | |
|------------------------------|-------|---------|---------|-----------|-----------|---------|---------|
| alt | Price | Quality | Comfort | alt | Consensus | alt | Ranking |
| FordT | 0.2 | 0.8 | 0.3 | FordT | 0.35 | 206 | 0.72 |
| 206 | 0.7 | 0.7 | 0.8 | 206 | 0.72 | FordT | 0.35 |
| ... | ... | ... | ... | ... | ... | ... | ... |

→ →



Agregació: introducció

Agregació: Introducció

- L'agregació o fusió d'informació:
 - En el nostre cas, com combinar els valors associats als criteris
- En general,
 - tota una àrea de recerca, amb aplicacions molt diverses
- Exemples de funcions d'agregació:
 - $\sum_{i=1}^N a_i/N$ (mitjana aritmètica, AM arithmetic mean)
 - $\sum_{i=1}^N p_i \cdot a_i$ (mitjana ponderada, WM weighted mean)
- Naturalment, funcions diferents donen resultats diferents
 - En el nostre cas, funcions diferents donen ordenacions diferents!

Agregació: Introducció

- Objectiu de l'agregació (no només per MCDM):
 - Produir una dada específica, i a la vegada exhaustiva, sobre una entitat.
 - Aquesta dada es construeix a partir de les informacions subministrades per diverses fonts d'informació (o per la mateixa font a partir d'informació recollida en diversos instants de temps).
 - Aquestes tècniques s'empren per reduir algun tipus de soroll, incrementar la precisió, resumir la informació, extreure informació, prendre decisions, etc.

Agregació: Introducció

- La fusió d'informació estudia . . .
 . . . tots els aspectes relacionats amb la combinació d'informació:
- Objectius de l'agregació (*objectius de l'àrea*):
 - Formalització del procés d'agregació
 - Definició de noves funcions
 - Selecció de funcions
(mètodes per decidir quina és la funció més apropiada en una situació donada)
 - Determinació dels paràmetres
 - Estudi dels mètodes existents:
 - Caracterització de funcions
 - Determinació de les capacitats de modelització de les funcions
 - Relació entre operadors i paràmetres
(per saber com els paràmetres afecten el resultat: es pot aconseguir la propietat de dictador?, sensibilitat a les dades → índex).

Agregació: Introducció

- Termes:
 - Integració d'informació
 - Fusió d'informació: funcions/tècniques concretes:
 - el procés concret de combinar diverses dades per obtenir-ne una de sola.
 - Operadors d'agregació: $\mathbb{C} : D^N \rightarrow D$ (\mathbb{C} de Consens)
 - i \mathbb{C} amb paràmetres (coneixement de base): \mathbb{C}_P
- Agregació:
 - Unanimitat o idempotència: $\mathbb{C}(a, \dots, a) = a$ per a tot a
 - Monotonia: $\mathbb{C}(a_1, \dots, a_N) \geq \mathbb{C}(a'_1, \dots, a'_N)$ quan $a_i \geq a'_i$
 - Simetria: Per a qualsevol permutació π sobre $\{1, \dots, N\}$
 $\mathbb{C}(a_1, \dots, a_N) = \mathbb{C}(a_{\pi(1)}, \dots, a_{\pi(N)})$
 - Unanimitat + monotonia → internalitat:
 $\min_i a_i \leq \mathbb{C}(a_1, \dots, a_N) \leq \max_i a_i$


Agregació: Introducció

Definició:

- Definició a partir de propietats



- Definició heurística



- Definició a partir d'exemples



Agregació: Introducció

- Definició a partir de propietats



Agregació: Introducció

- Definició a partir de propietats



- Algunes definicions
 - a) Emprant equacions funcionals

Agregació: Introducció

- Definició a partir de propietats



- Algunes definicions

a) Emprant equacions funcionals

b) Agregació de $a_1, a_2, \dots, a_N \in D$, com el c situat a la mínima distància dels a_i :

$$\mathbb{C}(a_1, a_2, \dots, a_N) = \arg \min_c \left\{ \sum_{a_i} d(c, a_i) \right\},$$

d és una distància sobre D .

Aggregació: Introducció

- Exemple (cas (a)): Equacions funcionals

- repartir s euros entre m projectes segons l'opinió de N experts

| | Proj 1 | Proj 2 | ... | Proj j | ... | Proj m |
|-------|---------------------|---------------------|-----|---------------------|-----|---------------------|
| E_1 | x_1^1 | x_2^1 | ... | x_j^1 | ... | x_m^1 |
| E_2 | x_1^2 | x_2^2 | ... | x_j^2 | ... | x_m^2 |
| | \vdots | \vdots | | \vdots | | \vdots |
| E_i | x_1^i | x_2^i | ... | x_j^i | ... | x_m^i |
| | \vdots | \vdots | | \vdots | | \vdots |
| E_N | x_1^N | x_2^N | ... | x_j^N | ... | x_m^N |
| DM | $f_1(\mathbf{x}_1)$ | $f_2(\mathbf{x}_2)$ | ... | $f_j(\mathbf{x}_j)$ | ... | $f_m(\mathbf{x}_m)$ |

Agregació: Introducció

- La solució general del sistema (Proposició 3.11)

$$f_j : [0, s]^N \rightarrow \mathbb{R}^+ \text{ for } j = \{1, \dots, m\} \quad (1)$$

$$\sum_{j=1}^m \mathbf{x}_j = \mathbf{s} \text{ implies that } \sum_{j=1}^m f_j(\mathbf{x}_j) = s \quad (2)$$

$$f_j(\mathbf{0}) = 0 \text{ for } j = 1, \dots, m \quad (3)$$

for a given $m > 2$ is given by

$$f_1(\mathbf{x}) = f_2(\mathbf{x}) = \dots = f_m(\mathbf{x}) = f((x_1, x_2, \dots, x_N)) = \sum_{i=1}^N \alpha_i x_i,$$

where $\alpha_1, \dots, \alpha_N$ are nonnegative constants satisfying $\sum_{i=1}^N \alpha_i = 1$, but are otherwise arbitrary.

Agregació: Introducció

- Exemple (cas (b)): Considerem l'expressió següent:

$$\mathbb{C}(a_1, a_2, \dots, a_N) = \arg \min_c \left\{ \sum_{a_i} d(c, a_i) \right\},$$

on els a_i són nombre de \mathbb{R} i d és una distància sobre D . Aleshores,

1. Quan $d(a, b) = (a - b)^2$, \mathbb{C} és la mitjana aritmètica.

Això és, $\mathbb{C}(a_1, a_2, \dots, a_N) = \sum_{i=1}^N a_i / N$.

2. Quan $d(a, b) = |a - b|$, \mathbb{C} és la mediana.

Això és, la mediana de a_1, a_2, \dots, a_N és l'element que ocupa la posició central quan ordenem els elements a_i .

3. Quan $d(a, b) = 1$ si $a = b$, \mathbb{C} és la regla de pluralitat (moda o votació).

Això és, $\mathbb{C}(a_1, a_2, \dots, a_N)$ selecciona l'element de \mathbb{R} que trobem més sovint entre els elements de (a_1, a_2, \dots, a_N) .

Agregació: de la mitja ponderada a les integrals difuses

Agregació: exemple de selecció d'alternatives

- Exemple.

Agregació: exemple de selecció d'alternatives

- **Exemple.**

A i B imparteixen un curs (teoria+pràctica) i tenen algunes restriccions:

Agregació: exemple de selecció d'alternatives

- **Exemple.**

A i B imparteixen un curs (teoria+pràctica) i tenen algunes restriccions:

- El nombre total de sessions és sis.

Agregació: exemple de selecció d'alternatives

- **Exemple.**

A i B imparteixen un curs (teoria+pràctica) i tenen algunes restriccions:

- El nombre total de sessions és sis.
- El professor A donarà la part de teoria, que hauria de consistir en unes tres sessions. Tres és el valor òptim, i una diferència entre el nombre de sessions més gran que dues és inacceptable.

Agregació: exemple de selecció d'alternatives

- **Exemple.**

A i *B* imparteixen un curs (teoria+pràctica) i tenen algunes restriccions:

- El nombre total de sessions és sis.
- El professor *A* donarà la part de teoria, que hauria de consistir en unes tres sessions. Tres és el valor òptim, i una diferència entre el nombre de sessions més gran que dues és unacceptable.
- El professor *B* donarà la part de problemes, que consisteix en dues sessions.

Agregació: exemple de selecció d'alternatives

- **Exemple.**

A i B imparteixen un curs (teoria+pràctica) i tenen algunes restriccions:

- El nombre total de sessions és sis.
- El professor A donarà la part de teoria, que hauria de consistir en unes tres sessions. Tres és el valor òptim, i una diferència entre el nombre de sessions més gran que dues és unacceptable.
- El professor B donarà la part de problemes, que consisteix en dues sessions.
- Els dos professors han de donar, més o menys, el mateix nombre de sessions. Una diferència d'una o dues és mitjanament acceptable, però una diferència de tres és unacceptable.

Agregació: exemple de selecció d'alternatives

- **Exemple.** Formalització

- Variables

- * x_A : nombre de sessions impartides pel professor A
 - * x_B : nombre de sessions impartides pel professor B .

- Restriccions

- * C_1 : $x_A + x_B$ ha de ser al voltant de 6
 - * C_2 : x_A ha de ser al voltant de 3
 - * C_3 : x_B ha de ser al voltant de 2
 - * C_4 : $|x_A - x_B|$ ha de ser al voltant de zero.

- Les restriccions es descriuen mitjançant conjunts difusos . . .

Agregació: exemple de selecció d'alternatives


- **Exemple.** Formalització

- si μ_6 expressa “al voltant de 6”, aleshores
avaluem “ $x_A + x_B$ ha de ser al voltant de 6” per $\mu_6(x_A + x_B)$.
→ donats $\mu_6, \mu_3, \mu_2, \mu_0$.
- Aleshores, donat un parell (x_A, x_B) (una solució possible), obtenim els graus de satisfacció següents:
 - * $\mu_6(x_A + x_B)$
 - * $\mu_3(x_A)$
 - * $\mu_2(x_B)$
 - * $\mu_0(|x_A - x_B|)$.

Agregació: exemple de selecció d'alternatives

- **Exemple.** Formalització

- Funcions de pertinença per a les restriccions.



Aggregació: exemple de selecció d'alternatives

- **Exemple.** Formalització

| alternativa | Graus de satisfacció | graus de satisfacció | | | |
|--------------|--|----------------------|-------|-------|-------|
| | | C_1 | C_2 | C_3 | C_4 |
| (x_A, x_B) | $(\mu_6(x_A + x_B), \mu_3(x_A), \mu_2(x_B), \mu_0(x_A - x_B))$ | | | | |
| $(2, 2)$ | $(\mu_6(4), \mu_3(2), \mu_2(2), \mu_0(0))$ | 0 | 0.5 | 1 | 1 |
| $(2, 3)$ | $(\mu_6(5), \mu_3(2), \mu_2(3), \mu_0(1))$ | 0.5 | 0.5 | 0.5 | 0.5 |
| $(2, 4)$ | $(\mu_6(6), \mu_3(2), \mu_2(4), \mu_0(2))$ | 1 | 0.5 | 0 | 0.5 |
| $(3.5, 2.5)$ | $(\mu_6(6), \mu_3(3.5), \mu_2(2.5), \mu_0(1))$ | 1 | 0.5 | 0.5 | 0.5 |
| $(3, 2)$ | $(\mu_6(5), \mu_3(3), \mu_2(2), \mu_0(1))$ | 0.5 | 1 | 1 | 0.5 |
| $(3, 3)$ | $(\mu_6(6), \mu_3(3), \mu_2(3), \mu_0(0))$ | 1 | 1 | 0.5 | 1 |

Aggregació: exemple de selecció d'alternatives

- **Exemple.** Formalització

| alternativa | graus de satisfacció | | | | agregació | | | |
|--------------|----------------------|-------|-------|-------|----------------|----------------|----------------|----------------|
| (x_A, x_B) | C_1 | C_2 | C_3 | C_4 | \mathbb{C}_1 | \mathbb{C}_2 | \mathbb{C}_3 | \mathbb{C}_4 |
| $(2, 2)$ | 0 | 0.5 | 1 | 1 | | | | |
| $(2, 3)$ | 0.5 | 0.5 | 0.5 | 0.5 | | | | |
| $(2, 4)$ | 1 | 0.5 | 0 | 0.5 | | | | |
| $(3.5, 2.5)$ | 1 | 0.5 | 0.5 | 0.5 | | | | |
| $(3, 2)$ | 0.5 | 1 | 1 | 0.5 | | | | |
| $(3, 3)$ | 1 | 1 | 0.5 | 1 | | | | |

WM, OWA, i WOWA

- Operadors ben coneguts

(que usen un vector de pesos de dimensió N :

$$v = (v_1 \dots v_N) \text{ on } v_i \in [0, 1] \text{ i } \sum_i v_i = 1$$

- Arithmetic mean (AM: $\mathbb{R}^N \rightarrow \mathbb{R}$): $AM(a_1, \dots, a_N) = (1/N) \sum_{i=1}^N a_i$
- Weighted mean (WM: $\mathbb{R}^N \rightarrow \mathbb{R}$): $WM_p(a_1, \dots, a_N) = \sum_{i=1}^N p_i a_i$
(p vector de pesos de dimensió N)
- Ordered Weighting Averaging operator (OWA: $\mathbb{R}^N \rightarrow \mathbb{R}$):

$$OWA_w(a_1, \dots, a_N) = \sum_{i=1}^N w_i a_{\sigma(i)},$$

on $\{\sigma(1), \dots, \sigma(N)\}$ és una permutació de $\{1, \dots, N\}$ tal que
 $a_{\sigma(i-1)} \geq a_{\sigma(i)}$, i w vector de pesos de dimensió N

WM, OWA, i WOWA

Exemple.

- Considerem la situació següent:
 - El professor A és més important que el professor B
 - La restricció més important (però no un requeriment nítid) és que el nombre de sessions sigui 6.
 - La restricció menys important és la relativa a la diferència entre el nombre de sessions impartides pels dos professors

WM amb $\mathbf{p} = (p_1, p_2, p_3, p_4) = (0.5, 0.3, 0.15, 0.05)$.

WM, OWA, i WOWA

Exemple.

- WM amb $\mathbf{p} = (p_1, p_2, p_3, p_4) = (0.5, 0.3, 0.15, 0.05)$.

| alternative | Aggregation of the Satisfaction degrees | WM |
|--------------|---|-------|
| (x_A, x_B) | $WM_{\mathbf{p}}(C_1, C_2, C_3, C_4)$ | |
| $(2, 2)$ | $WM_{\mathbf{p}}(0, 0.5, 1, 1)$ | 0.35 |
| $(2, 3)$ | $WM_{\mathbf{p}}(0.5, 0.5, 0.5, 0.5)$ | 0.5 |
| $(2, 4)$ | $WM_{\mathbf{p}}(1, 0.5, 0, 0.5)$ | 0.675 |
| $(3.5, 2.5)$ | $WM_{\mathbf{p}}(1, 0.5, 0.5, 0.5)$ | 0.75 |
| $(3, 2)$ | $WM_{\mathbf{p}}(0.5, 1, 1, 0.5)$ | 0.725 |
| $(3, 3)$ | $WM_{\mathbf{p}}(1, 1, 0.5, 1)$ | 0.925 |

WM, OWA, i WOWA

Exemple.

- Compensació: quants criteris poden tenir una valuació negativa/dolenta
- No passa res per tenir un valor negatiu/dolent: OWA amb $w = (1/3, 1/3, 1/3, 0)$ (es descarta el valor més baix)

| alternative | Aggregation of the Satisfaction degrees | OWA |
|--------------|---|--------|
| (x_A, x_B) | $OWA_w(C_1, C_2, C_3, C_4)$ | |
| (2, 2) | $OWA_w(0, 0.5, 1, 1)$ | 0.8333 |
| (2, 3) | $OWA_w(0.5, 0.5, 0.5, 0.5)$ | 0.5 |
| (2, 4) | $OWA_w(1, 0.5, 0, 0.5)$ | 0.6666 |
| (3.5, 2.5) | $OWA_w(1, 0.5, 0.5, 0.5)$ | 0.6666 |
| (3, 2) | $OWA_w(0.5, 1, 1, 0.5)$ | 0.8333 |
| (3, 3) | $OWA_w(1, 1, 0.5, 1)$ | 1.0 |

WM, OWA, i WOWA

A vegades interessa ...

- Importància dels criteris: uns criteris més importants que d'altres
- Compensació: uns certs valors poden no interessar (els extrems, els alts, els baixos)

⇒ Weighted Ordered Weighted Averaging **WOWA** operator

WM, OWA, i WOWA

- Weighted Ordered Weighted Averaging WOWA operator
(WOWA : $\mathbb{R}^N \rightarrow \mathbb{R}$):

$$WOWA_{\mathbf{p}, \mathbf{w}}(a_1, \dots, a_N) = \sum_{i=1}^N \omega_i a_{\sigma(i)}$$

where

$$\omega_i = w^*(\sum_{j \leq i} p_{\sigma(j)}) - w^*(\sum_{j < i} p_{\sigma(j)}),$$


with σ a permutation of $\{1, \dots, N\}$ s. t. $a_{\sigma(i-1)} \geq a_{\sigma(i)}$, and w^* a nondecreasing function that interpolates the points

$$\{(i/N, \sum_{j \leq i} w_j)\}_{i=1, \dots, N} \cup \{(0, 0)\}.$$

w^* is required to be a straight line when the points can be interpolated in this way.

WM, OWA, i WOWA


- Construction of the w^* quantifier




- Rationale for new weights (ω_i , for each value a_i) in terms of \mathbf{p} and \mathbf{w} .
 - If a_i is small, and **small values have more importance than larger ones**, increase p_i for a_i (i.e., $\omega_i \geq p_{\sigma(i)}$).
(the same holds if the value a_i is large and importance is given to large values)
 - If a_i is small, and importance is for large values, $\omega_i < p_{\sigma(i)}$
(the same holds if a_i is large and importance is given to small values).

WM, OWA, i WOWA


- La forma de la funció w^* dóna importància
 - (a) als valors grans
 - (b) als valors mitjans
 - (c) als valors petits
 - (d) o dóna la mateixa importància a tots els valors




(a)



(b)



(c)



(d)

WM, OWA, i WOWA

Exemple.

- Importància de les restriccions: $\mathbf{p} = (0.5, 0.3, 0.15, 0.05)$
- Compensació: $\mathbf{w} = (1/3, 1/3, 1/3, 0)$ (es descarta el valor més baix)
→ WOWA amb \mathbf{p} i \mathbf{w} .

| alternative | Aggregation of the Satisfaction degrees | WOWA |
|--------------|---|--------|
| (x_A, x_B) | $WOWA_{\mathbf{p}, \mathbf{w}}(C_1, C_2, C_3, C_4)$ | |
| (2, 2) | $WOWA_{\mathbf{p}, \mathbf{w}}(0, 0.5, 1, 1)$ | 0.4666 |
| (2, 3) | $WOWA_{\mathbf{p}, \mathbf{w}}(0.5, 0.5, 0.5, 0.5)$ | 0.5 |
| (2, 4) | $WOWA_{\mathbf{p}, \mathbf{w}}(1, 0.5, 0, 0.5)$ | 0.8333 |
| (3.5, 2.5) | $WOWA_{\mathbf{p}, \mathbf{w}}(1, 0.5, 0.5, 0.5)$ | 0.8333 |
| (3, 2) | $WOWA_{\mathbf{p}, \mathbf{w}}(0.5, 1, 1, 0.5)$ | 0.8 |
| (3, 3) | $WOWA_{\mathbf{p}, \mathbf{w}}(1, 1, 0.5, 1)$ | 1.0 |

WM, OWA, i WOWA

- Propietats

- El WOWA generalitza la WM i l'OWA

- When $\mathbf{p} = (1/N \dots 1/N)$, OWA

$$WOWA_{\mathbf{p}, \mathbf{w}}(a_1, \dots, a_N) = OWA_{\mathbf{w}}(a_1, \dots, a_N) \text{ for all } \mathbf{w} \text{ and } a_i.$$

- When $\mathbf{w} = (1/N \dots 1/N)$, WM

$$WOWA_{\mathbf{p}, \mathbf{w}}(a_1, \dots, a_N) = WM_{\mathbf{p}}(a_1, \dots, a_N) \text{ for all } \mathbf{p} \text{ and } a_i.$$

- When $\mathbf{w} = \mathbf{p} = (1/N \dots 1/N)$, AM

$$WOWA_{\mathbf{p}, \mathbf{w}}(a_1, \dots, a_N) = AM(a_1, \dots, a_N)$$

Choquet integrals

- In WM, we combine a_i w.r.t. weights p_i .
→ a_i is the value supplied by information source x_i .

Formally

Choquet integrals

- In WM, we combine a_i w.r.t. weights p_i .
→ a_i is the value supplied by information source x_i .

Formally

- $X = \{x_1, \dots, x_N\}$ is the set of information sources
- $f : X \rightarrow \mathbb{R}^+$ the values supplied by the sources
→ then $a_i = f(x_i)$

Thus,

$$WM_{\mathbf{p}}(a_1, \dots, a_N) = \sum_{i=1}^N p_i a_i = \sum_{i=1}^N p_i f(x_i) = WM_{\mathbf{p}}(f(x_1), \dots, f(x_N))$$

Choquet integrals

- A la WM, un únic pes per a cada element
Això és, $p_i = p(x_i)$ (on, x_i és la font d'informació que subministra a_i)
→ quan considerem un conjunt $A \subset X$, *pes* de A ???

Choquet integrals

- A la WM, un únic pes per a cada element

Això és, $p_i = p(x_i)$ (on, x_i és la font d'informació que subministra a_i)
→ quan considerem un conjunt $A \subset X$, *pes* de A ???

... mesures difuses (fuzzy measures) $\mu(A)$

Formalment,

- Fuzzy measure ($\mu : \wp(X) \rightarrow [0, 1]$), a set function satisfying
 - (i) $\mu(\emptyset) = 0$, $\mu(X) = 1$ (boundary conditions)
 - (ii) $A \subseteq B$ implies $\mu(A) \leq \mu(B)$ (monotonicity)

Choquet integrals

- Ara tenim una mesura difusa $\mu(A)$
i, aleshores, com agreguem?
 \Rightarrow integrals difuses com ara la integral de Choquet

Choquet integrals

- Choquet integral of f w.r.t. μ (alternative notation, $CI_\mu(a_1, \dots, a_N)/CI_\mu(f)$)

$$(C) \int f d\mu = \sum_{i=1}^N [f(x_{s(i)}) - f(x_{s(i-1)})] \mu(A_{s(i)}),$$

where s in $f(x_{s(i)})$ is a permutation so that $f(x_{s(i-1)}) \leq f(x_{s(i)})$ for $i \geq 1$, $f(x_{s(0)}) = 0$, and $A_{s(k)} = \{x_{s(j)} | j \geq k\}$ and $A_{s(N+1)} = \emptyset$.

- Alternative expressions (Proposition 6.18):

$$(C) \int f d\mu = \sum_{i=1}^N f(x_{\sigma(i)}) [\mu(A_{\sigma(i)}) - \mu(A_{\sigma(i-1)})],$$


$$(C) \int f d\mu = \sum_{i=1}^N f(x_{s(i)}) [\mu(A_{s(i)}) - \mu(A_{s(i+1)})],$$

where σ is a permutation of $\{1, \dots, N\}$ s.t. $f(x_{\sigma(i-1)}) \geq f(x_{\sigma(i)})$, where $A_{\sigma(k)} = \{x_{\sigma(j)} | j \leq k\}$ for $k \geq 1$ and $A_{\sigma(0)} = \emptyset$

Choquet integrals

- Different equations point out different aspects of the CI

$$(6.1) \quad (C) \int f d\mu = \sum_{i=1}^N [f(x_{s(i)}) - f(x_{s(i-1)})] \mu(A_{s(i)}),$$



$$(6.2) \quad (C) \int f d\mu = \sum_{i=1}^N f(x_{\sigma(i)}) [\mu(A_{\sigma(i)}) - \mu(A_{\sigma(i-1)})],$$

Choquet integrals


- $\int f d\mu =$ (for additive measures)

$$(6.5) \sum_{x \in X} f(x) \mu(\{x\})$$

$$(6.6) \sum_{i=1}^R b_i \mu(\{x | f(x) = b_i\})$$

$$(6.7) \sum_{i=1}^N (a_i - a_{i-1}) \mu(\{x | f(x) \geq a_i\})$$

$$(6.8) \sum_{i=1}^N (a_i - a_{i-1}) (1 - \mu(\{x | f(x) \leq a_{i-1}\}))$$




- Among (6.5), (6.6) and (6.7), only (6.7) satisfies internality.

Choquet integrals

- Properties of CI

- Horizontal additive because $CI_\mu(f) = CI_\mu(f \wedge c) + CI_\mu(f_c^+)$
($f = (f \wedge c) + f_c^+$ is a horizontal additive decomposition of f)
where, f_c^+ is defined by (for $c \in [0, 1]$)

$$f_c^+ = \begin{cases} 0 & \text{if } f(x) \leq c \\ f(x) - c & \text{if } f(x) > c. \end{cases}$$



Choquet integrals

- Definitions (X a reference set, f, g functions $f, g : X \rightarrow [0, 1]$)
 - $f < g$ when, for all x_i ,
$$f(x_i) < g(x_i)$$
 - f and g are comonotonic if, for all $x_i, x_j \in X$,
$$f(x_i) < f(x_j) \text{ imply that } g(x_i) \leq g(x_j)$$
 - \mathbb{C} is comonotonic monotone if and only if, for comonotonic f and g ,
$$f \leq g \text{ imply that } \mathbb{C}(f) \leq \mathbb{C}(g)$$
 - \mathbb{C} is comonotonic additive if and only if, for comonotonic f and g ,
$$\mathbb{C}(f + g) = \mathbb{C}(f) + \mathbb{C}(g)$$
- Characterization. Let \mathbb{C} satisfy the following properties
 - \mathbb{C} is comonotonic monotone
 - \mathbb{C} is comonotonic additive
 - $\mathbb{C}(1, \dots, 1) = 1$

Then, there exists μ s.t. $\mathbb{C}(f)$ is the CI of f w.r.t. μ .


Choquet integrals

- Properties
 - WM, OWA and WOWA are particular cases of CI.
 - * WM with weighting vector \mathbf{p} is a CI w.r.t. $\mu_{\mathbf{p}}(B) = \sum_{x_i \in B} p_i$
 - * OWA with weighting vector \mathbf{w} is a CI w.r.t. $\mu_{\mathbf{w}}(B) = \sum_{i=1}^{|B|} w_i$
 - * WOWA with w.v. \mathbf{p} and \mathbf{w} is a CI w.r.t. $\mu_{\mathbf{p},\mathbf{w}}(B) = w^*(\sum_{x_i \in B} p_i)$
 - Any symmetric CI is an OWA operator.
 - Any CI with a distorted probability is a WOWA operator.
 - Let A be a crisp subset of X ; then, the Choquet integral of A with respect to μ is $\mu(A)$.

Here, the integral of A corresponds to the integral of its characteristic function, or, in other words, to the integral of the function f_A defined as $f_A(x) = 1$ if and only if $x \in A$.

Choquet integrals

- Properties: punts *iguals*



Weighted Minimum and Weighted Maximum

- Possibilistic weighting vector (dimension N): $\mathbf{v} = (v_1 \dots v_N)$ iff $v_i \in [0, 1]$ and $\max_i v_i = 1$.
- Weighted minimum (WMin: $[0, 1]^N \rightarrow [0, 1]$):
 $WMin_{\mathbf{u}}(a_1, \dots, a_N) = \min_i \max(neg(u_i), a_i)$
(alternative definition can be given with $\mathbf{v} = (v_1, \dots, v_N)$ where $v_i = neg(u_i)$)
- Weighted maximum (WMax: $[0, 1]^N \rightarrow [0, 1]$):
 $WMax_{\mathbf{u}}(a_1, \dots, a_N) = \max_i \min(u_i, a_i)$

Weighted Minimum and Weighted Maximum

- **Exemple 6.34.** Avaluació de les alternatives del curs.

- Vector de pesos (vector possiblístic): $\mathbf{u} = (1, 0, 5, 0, 3, 0, 1)$.
- WMin:
 - * $sat(2, 2) = WMin_{\mathbf{u}}(0, 0, 5, 1, 1) = 0$
 - * $sat(2, 3) = WMin_{\mathbf{u}}(0, 5, 0, 5, 0, 5, 0, 5) = 0, 5$
 - * $sat(2, 4) = WMin_{\mathbf{u}}(1, 0, 5, 0, 0, 5) = 0, 5$
 - * $sat(3, 5, 2, 5) = WMin_{\mathbf{u}}(1, 0, 5, 0, 5, 0, 5) = 0, 5$
 - * $sat(3, 2) = WMin_{\mathbf{u}}(0, 5, 1, 1, 0, 5) = 0, 5$
 - * $sat(3, 3) = WMin_{\mathbf{u}}(1, 1, 0, 5, 1) = 0, 7$.
- WMax: (amb $neg(\mathbf{u}) = (0, 0, 5, 0, 7, 0, 9)$, segons $neg(x) = 1 - x$)
 - * $sat(2, 2) = WMax_{\mathbf{u}}(0, 0, 5, 1, 1) = 0, 5$
 - * $sat(2, 3) = WMax_{\mathbf{u}}(0, 5, 0, 5, 0, 5, 0, 5) = 0, 5$
 - * $sat(2, 4) = WMax_{\mathbf{u}}(1, 0, 5, 0, 0, 5) = 1$
 - * $sat(3, 5, 2, 5) = WMax_{\mathbf{u}}(1, 0, 5, 0, 5, 0, 5) = 1$
 - * $sat(3, 2) = WMax_{\mathbf{u}}(0, 5, 1, 1, 0, 5) = 0, 5$
 - * $sat(3, 3) = WMax_{\mathbf{u}}(1, 1, 0, 5, 1) = 1$.
- mínim ponderat, el millor parell és el (3, 3), però que, quan utilitzem el màxim ponderat, són indistingibles els parells (2, 4) i (3, 5, 2, 5)

Weighted Minimum and Weighted Maximum

- **Exemple 6.35.** Sistema d'inferència difús

R_i : **IF** x is A_i **THEN** y is B_i .

- with disjunctive rules, the (fuzzy) output for a particular y_0 is a WMax

$$\tilde{B}(y_0) = \vee_{i=1}^N (B_i(y_0) \wedge A_i(x_0)).$$

- with conjunctive rules, and Kleene-Dienes implication ($\mathcal{I}(x, y) = \max(1 - x, y)$)
the (fuzzy) output of the system for a particular y_0 is a WMin

$$\tilde{B}(y_0) = \wedge_{i=1}^N (\mathcal{I}(A_i(x_0), B_i(y_0))) = \wedge_{i=1}^N \max(1 - A_i(x_0), B_i(y_0)).$$

that with $\mathbf{u} = (A_1(x_0), \dots, A_N(x_0))$

$$\tilde{B}(y_0) = WMin_{\mathbf{u}}(B_1(y_0), \dots, B_N(y_0)).$$

Weighted Minimum and Weighted Maximum

- Only operators in ordinal scales (\max , \min , neg) are used in $WMax$ and $WMin$.
- neg is completely determined in an ordinal scale

Proposition 6.36. Let $L = \{l_0, \dots, l_r\}$ with $l_0 <_L l_1 <_L \dots <_L l_r$; then, there exists only one function, $\text{neg} : L \rightarrow L$, satisfying

- (N1) if $x <_L x'$ then $\text{neg}(x) >_L \text{neg}(x')$ for all x, x' in L .
- (N2) $\text{neg}(\text{neg}(x)) = x$ for all x in L .

This function is defined by $\text{neg}(x_i) = x_{r-i}$ for all x_i in L

- Properties. For $\mathbf{u} = (1, \dots, 1)$
 - $WMIN_{\mathbf{u}} = \min$
 - $WMAX_{\mathbf{u}} = \max$

Sugeno integral

- Sugeno integral of f w.r.t. μ (alternative notation, $SI_\mu(a_1, \dots, a_N)/SI_\mu(f)$)

$$(S) \int f d\mu = \max_{i=1,N} \min(f(x_{s(i)}), \mu(A_{s(i)})),$$

where s in $f(x_{s(i)})$ is a permutation so that $f(x_{s(i-1)}) \leq f(x_{s(i)})$ for $i \geq 2$, and $A_{s(k)} = \{x_{s(j)} | j \geq k\}$.


- Alternative expression (Proposition 6.38):

$$\max_i \min(f(x_{\sigma(i)}), \mu(A_{\sigma(i)})),$$

where σ is a permutation of $\{1, \dots, N\}$ s.t. $f(x_{\sigma(i-1)}) \geq f(x_{\sigma(i)})$,
where $A_{\sigma(k)} = \{x_{\sigma(j)} | j \leq k\}$ for $k \geq 1$

Sugeno integral

- Graphical interpretation of Sugeno integrals



Sugeno integral

- Properties
 - WMin and WMax are particular cases of SI
 - * WMax with weighting vector \mathbf{u} is a SI w.r.t.
$$\mu_{\mathbf{u}}^{wmax}(A) = \max_{a_i \in A} u_i.$$
 - * WMin with weighting vector \mathbf{u} is a SI w.r.t.
$$\mu_{\mathbf{u}}^{wmin}(A) = 1 - \max_{a_i \notin A} u_i.$$

Sugeno integral

Example. Citation indices

- Number of citations: CI
- h -index: SI

In both cases,

- X the set of papers
- $f(x)$ the number of citations of paper x
- $\mu(A) \subseteq X$ the cardinality of the set


Fuzzy integrals

- Fuzzy integrals that generalize Choquet and Sugeno integrals
 - The fuzzy t-conorm integral
 - The twofold integral

Models jeràrquics

Hierarchical Models for Aggregation

- Hierarchical model



- Properties. The following conditions hold

- (i) Every multistep Choquet integral is a monotone increasing, positively homogeneous, piecewise linear function.
- (ii) Every monotone increasing, positively homogeneous, piecewise linear function on a full-dimensional convex set in \mathbb{R}^N is representable as a two-step Choquet integral such that the fuzzy measures of the first step are additive and the fuzzy measure of the second step is a 0-1 fuzzy measure.

Índex

Índex

- Equacions funcions i síntesis de judicis
- De la mitjana ponderada a les integrals difuses
- Mesures difuses
- Índexs i mètodes d'avaluació
- Selecció del model