



Πρόγραμμα Μεταπτυχιακών Σπουδών
"Προηγμένες Τεχνολογίες Υπολογιστών
και Πληροφορικής"

Υπολογιστική Νοημοσύνη

Μάθημα 5^ο

Δρ. Βασίλειος Γ. Καμπουρλάζος
Δρ. Ανέστης Γ. Χατζημιχαηλίδης

Τμήμα Μηχανικών Πληροφορικής Τ.Ε.
ΤΕΙ Ανατολικής Μακεδονίας και Θράκης

2016-2017

Περιεχόμενα

Διευρυμένη Υπολογιστική Νοημοσύνη (ΥΝ)

- ◉ Επεκτάσεις της Κλασικής ΥΝ.
- ◉ Μεθοδολογίες Στατιστικές, Πιθανοτήτων, Δυνατοτήτων.
- ◉ Μεθοδολογίες με Γράφους.

Μεθοδολογίες Στατιστικές, Πιθανοτήτων, Δυνατοτήτων

- ο Πολλές μεθοδολογίες της (κλασικής) ΥΝ, συμπεριλαμβανομένων ΤΝΔ, παρουσιάζονται ως στατιστικές μεθοδολογίες.

Στο προαναφερθέν πλαίσιο παρουσιάζουμε ενδεικτικά έναν αριθμό μεθοδολογιών της διευρυμένης ΥΝ.

(Μεθοδολογίες Στατιστικές, Πιθανοτήτων, Δυνατοτήτων)

- Πολλαπλά Μοντέλα.
- Τεχνικές Ομαδοποίησης.
- Τεχνικές της Θεωρίας Τεκμηρίων.

Πολλαπλά Μοντέλα

- ◉ Ασθενής κατηγοριοποιητής:
 - Δίνει τόσες σωστές απαντήσεις όσες θα έδινε μια τυχαία επιλογή των απαντήσεων.
- ◉ Ισχυρός κατηγοριοποιητής:
 - Προσεγγίζει το σύνολο των ορθών απαντήσεων με οποιαδήποτε ακρίβεια.

-
- Η ώθηση (ή σύνολο κατηγοριοποιητών ή επιτροπή εμπειρογνωμόνων) είναι μια μεθοδολογία μηχανικής μάθησης για κατηγοριοποίηση που χρησιμοποιεί έναν πληθυσμό από ασθενείς κατηγοριοποιητές με στόχο έναν ισχυρό κατηγοριοποιητή.

AdaBoost (Adaptive Boosting)

- Είναι ο πλέον γνωστός αλγόριθμος ώθησης.

Στην απλούστερη εκδοχή θεωρούνται δύο μόνον κατηγορίες στο σύνολο $Y=\{0,1\}$. Στόχος είναι η μάθηση της υπόθεσης συνάρτησης $h: X \rightarrow [0,1]$. Η τιμή $h(\mathbf{x})$ ερμηνεύεται ως η πιθανότητα το \mathbf{x} να ανήκει στην κατηγορία 1.

Ο αλγόριθμος *AdaBoost*

- Έστω μια ακολουθία $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)$, όπου $\mathbf{x}_1, \dots, \mathbf{x}_N$ είναι N δεδομένα και y_1, \dots, y_N οι αντίστοιχες κατηγορίες αυτών, μια κατανομή D βαρών πάνω στα N δεδομένα, ένας ασθενής κατηγοριοποιητής **WeakLearn**, και ένας ακέραιος T που καθορίζει το πλήθος των επαναλήψεων.
- Αρχικοποίηση των βαρών $w_i^1 = D(i)$, $i = 1, \dots, N$

(0 αλγόριθμος AdaBoost)

○ Κάνε για $t = 1, 2, \dots, T$

1. Όρισε το διάνυσμα κατανομής

$$\mathbf{p}^t = \frac{\mathbf{w}^t}{\sum_{i=1}^N w_i^t}$$

2. Κάλεσε τον WeakLearn με την

κατανομή \mathbf{p}^t . Κατέγραψε την $h: \mathbf{X} \rightarrow [0, 1]$.

3. Υπολόγισε το σφάλμα $\varepsilon_t = \sum_{i=1}^N p_i^t |h_t(x_i) - y_i|$

4. Όρισε $\beta_t = \varepsilon_t / (1 - \varepsilon_t)$

5. Όρισε τα νέα βάρη ως $w_i^{t+1} = w_i^t \beta_t^{1 - |h_t(x_i) - y_i|}$

Τελική υπόθεση $h_f(x) = 1$, αν και μόνον αν

$$\sum_{t=1}^T (\log 1 / \beta_t) h_t(x) \geq \frac{1}{2} \sum_{t=1}^T (\log 1 / \beta_t)$$

(Ο αλγόριθμος *AdaBoost*)

- Μετά την εισαγωγή ενός ασθενούς κατηγοριοποιητή, επανα-υπολογίζεται η κατανομή πιθανότητας πάνω στο υποσύνολο εκπαίδευσης έτσι ώστε για κάθε δεδομένο το οποίο κατηγοριοποιείται λανθασμένα (ορθά) αυξάνεται (μειώνεται) η βαρύτητα. Έτσι, οι κατηγοριοποιητές επικεντρώνονται στο να μάθουν δεδομένα που κατηγοριοποιούν λανθασμένα.

Εναλλακτικοί Αλγόριθμοι Ώθησης

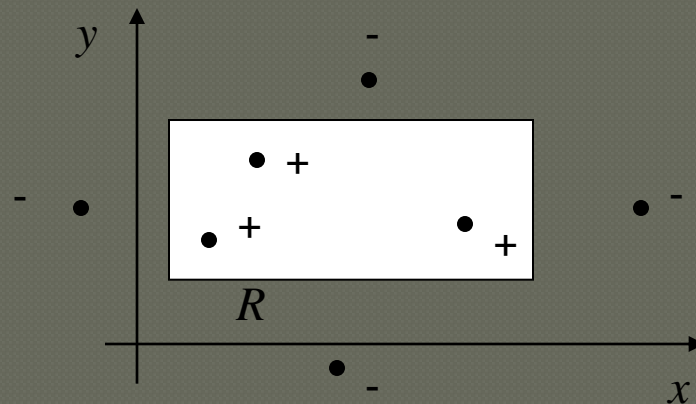
- Ο αλγόριθμος ενεργής μάθησης ορίζει ένα βέλτιστο υποσύνολο εκπαίδευσης X^e στοχεύοντας στην μεγιστοποίηση της ικανότητας γενίκευσης, τυπικά σε προβλήματα κατηγοριοποίησης.

- Ο αλγ. πολλαπλής δειγματοποίησης (bagging) παράγει, m νέα υποσύνολα εκπαίδευσης D_i , $i \in \{1, \dots, m\}$ ιδίου μεγέθους n' έκαστο. Εάν $n' = n$ τότε, για μεγάλες τιμές του n , ένα υποσύνολο D_i , $i \in \{1, \dots, m\}$ αναμένεται να έχει ένα ποσοστό $1 - (1/e)$ (περίπου) 63.2% των δεδομένων του διαφορετικά μεταξύ τους.

- Στη συνέχεια χρησιμοποιούνται m διαφορετικά μοντέλα κάθε ένα από τα οποία εκπαιδεύεται με ένα διαφορετικό υποσύνολο $D_i, i \in \{1, \dots, m\}$. Οι έξοδοι των m μοντέλων συνδυάζονται είτε υπολογίζοντας τον μέσο όρο αυτών (για εφαρμογές παλινδρόμησης) είτε με ψηφοφορία (για εφαρμογές κατηγοριοποίησης).

Πιθανώς Ορθό κατά Προσέγγιση

- ◉ Παράδειγμα
Επιλέγουμε σημεία στο επίπεδο σύμφωνα με μια κατανομή πιθανότητας D .




(Πιθανώς Ορθό κατά Προσέγγιση)

- Θεωρούμε την συνάρτηση $R(\cdot)$ έτσι ώστε $R(p) = 1$ αν και μόνο αν το σημείο p είναι εντός του R , διαφορετικά $R(p) = 0$. Ο σκοπός είναι να επιλέξουμε ικανό αριθμό δειγμάτων $(p, R(p))$ προκειμένου να υπολογίσουμε ένα ορθογώνιο R' το οποίο να είναι μια αποδεκτή προσέγγιση του R .

(Πιθανώς Ορθό κατά Προσέγγιση)

- Συγκεκριμένα, το R' ορίζεται ως το ελάχιστο ορθογώνιο το οποίο περιέχει όλα τα θετικά δείγματα (+).



(Πιθανώς Ορθό κατά Προσέγγιση)


- Ορίζουμε ως **σφάλμα** της προσέγγισης του R με το R' την πιθανότητα ένα σημείο p του επιπέδου που επιλέχθηκε σύμφωνα με την κατανομή D να ανήκει στην περιοχή $R-R'$.

(Πιθανώς Ορθό κατά Προσέγγιση)

- Θα δείξουμε ότι για οποιοδήποτε R και για οποιοδήποτε μικρές τιμές $0 < \varepsilon$ και $0 < \delta < 1/2$ μπορούμε να υπολογίσουμε έναν ελάχιστο αριθμό m δειγμάτων ζευγών $(p, R(p))$ ώστε με πιθανότητα τουλάχιστον $1 - \delta$, το σφάλμα προσέγγισης του R με το R' να είναι μικρότερο από ε .

(Πιθανώς Ορθό κατά Προσέγγιση)

- Θεωρούμε την λωρίδα T' εντός του R η οποία ορίζεται από τις άνω πλευρές των ορθογώνιων R και R' .



(Πιθανώς Ορθό κατά Προσέγγιση)

- Υποθέτουμε ότι υπάρχει ένας ελάχιστος αριθμός m δειγμάτων ζευγών $(p, R(p))$ τέτοιος ώστε το σφάλμα το οποίο αντιστοιχεί στην λωρίδα T' να είναι λιγότερο από $\varepsilon/4$.
- Έστω η λωρίδα $T \supseteq T'$ η οποία αντιστοιχεί ακριβώς σε σφάλμα $\varepsilon/4$. Υπάρχουν τέσσερα ζεύγη από λωρίδες T και T' .

(Πιθανώς Ορθό κατά Προσέγγιση)

- Η πιθανότητα ότι ένα σημείο p δεν θα είναι πάνω στη λωρίδα T είναι $1-\varepsilon/4$. Άρα, η πιθανότητα ότι m ανεξάρτητες επιλογές δεν θα είναι πάνω στην T είναι $(1-\varepsilon/4)^m$. Συνεπώς, η πιθανότητα ότι δεν θα είναι πάνω στην T' είναι το πολύ $(1-\varepsilon/4)^m$. Τελικά, η πιθανότητα ότι m ανεξάρτητες επιλογές δεν θα είναι πάνω σε κάποια από τις 4 λωρίδες T' είναι το πολύ $4(1-\varepsilon/4)^m$.

(Πιθανώς Ορθό κατά Προσέγγιση)

- Επιλέγουμε έναν αριθμό m δειγμάτων που να ικανοποιεί την σχέση $4(1-\varepsilon/4)^m \leq \delta$.
- Προκύπτει $m \geq (4/\varepsilon)\ln(4/\delta)$, όπως υπολογίζεται στη συνέχεια.

(Πιθανώς Ορθό κατά Προσέγγιση)

- Συγκεκριμένα, επιλέγουμε τον m έτσι ώστε να ισχύει $4\exp(-\varepsilon m/4) \leq \delta \Leftrightarrow m \geq (4/\varepsilon)\ln(4/\delta)$.
- Λόγω της γνωστής ανισότητας $(1-x) \leq e^{-x}$ έπεται

$$4(1-\varepsilon/4)^m \leq 4\exp(-\varepsilon m/4)$$

- Συνεπώς, για $m \geq (4/\varepsilon)\ln(4/\delta)$ προκύπτει

$$4(1-\varepsilon/4)^m \leq 4\exp(-\varepsilon m/4) \leq \delta$$

Πιθανώς Ορθό κατά Προσέγγιση

- Έστω X ένα σύνολο δεδομένων (π.χ. στο προηγούμενο παράδειγμα, X ήταν το σύνολο όλων των σημείων στο επίπεδο).
- Μία έννοια c πάνω στο X ορίζεται ως ένα υποσύνολο του X , δηλ. $c \subseteq X$ (π.χ. στο προηγούμενο παράδειγμα, μία έννοια c ήταν ένα ορθογώνιο παραλληλόγραμμο).

- Έστω \mathbf{C} το σύνολο όλων των εννοιών τις οποίες μπορεί να μάθει μια συγκεκριμένη μηχανή μάθησης (π.χ. στο προηγούμενο παράδειγμα, \mathbf{C} είναι το σύνολο όλων των ορθογώνιων παραλληλόγραμμων).
- Έστω $E\mathbf{X}(c, D)$ μια διαδικασία η οποία κάθε φορά επιστρέφει ένα ζεύγος $(\mathbf{x}, c(\mathbf{x}))$, όπου το $\mathbf{x} \in \mathbf{X}$ επιλέγεται σύμφωνα με την D .

Πιθανώς Ορθό κατά Προσέγγιση (ΠΟΠ)


- Ένας αλγόριθμος L μπορεί να μάθει την συλλογή \mathbf{C} κατά ΠΟΠ εάν ο L έχει την ακόλουθη ιδιότητα: Για κάθε έννοια $c \in \mathbf{C}$, για κάθε κατανομή D πάνω στο X , για κάθε $\varepsilon \in (0, 0.5)$ και $\delta \in (0, 0.5)$, εάν ο αλγόριθμος L μπορεί λαμβάνει δεδομένα $EX(c, D)$ τότε με πιθανότητα τουλάχιστον $1 - \delta$ μπορεί να υπολογίζει μια έννοια $h \in \mathbf{C}$ της οποίας το σφάλμα θα είναι μικρότερο από ε .

Τεχνικές Ομαδοποίησης

- Ένα σύνολο δεδομένων για τα οποία δεν είναι γνωστή η κατηγορία στην οποία ανήκουν, επιδιώκεται να χωριστούν σε ομάδες δεδομένων. Με όρους ΥΝ αυτό καλείται μάθηση χωρίς επίβλεψη.

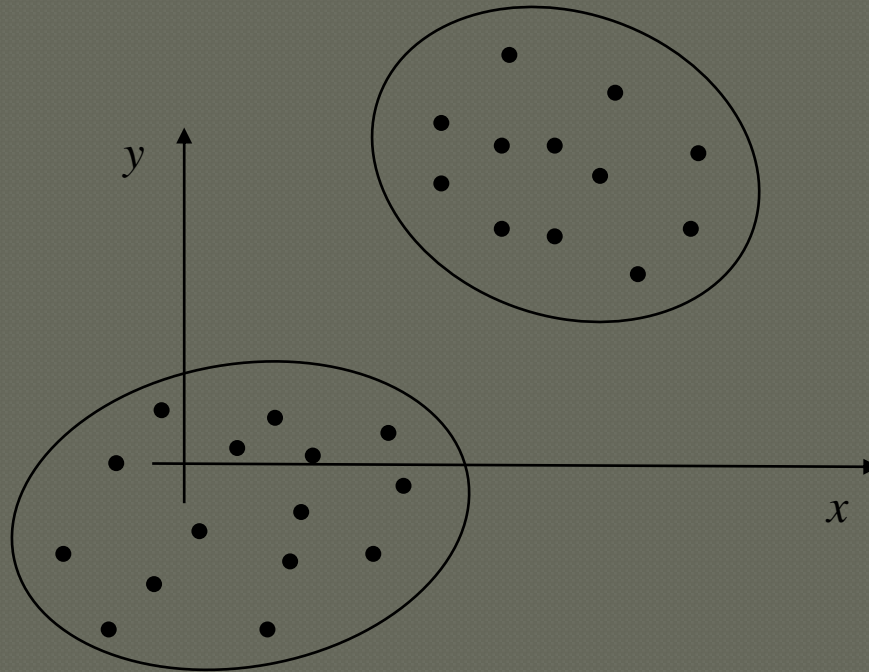
Παραδείγματα Ομαδοποίησης

- Πόσες ομάδες υπάρχουν στο σχήμα;




Παραδείγματα Ομαδοποίησης

- Δύο ευδιάκριτες ομάδες.



Παραδείγματα Ομαδοποίησης

- Πόσες ομάδες υπάρχουν στο σχήμα;



Κίνητρα Ομαδοποίησης

1. Όταν η συλλογή δεδομένων είναι “φθηνή”, αλλά ο προσδιορισμός της κατηγορίας είναι “ακριβός”, π.χ. σε αναγνώρισης φωνής. Οπότε, σχεδιάζονται κατηγοριοποιητές με λίγα (κατηγοριοποιημένα) δεδομένα και ρυθμίζονται με πολλά δεδομένα.

-
2. Για την εύρεση ομάδων δεδομένων και, στη συνέχεια, επικόλληση ετικετών.
 3. Για την εύρεση *χαρακτηριστικών* που θα χρησιμοποιηθούν για κατηγοριοποίηση.

Αλγόριθμοι Ομαδοποίησης

Μίξεις πυκνοτήτων (Pearson, 1894).

1. Τα δείγματα προέρχονται από γνωστό αριθμό c κατηγοριών.
2. Οι προγενέστερες πιθανότητες $P(w_j)$ για κάθε κατηγορία, $j=1, \dots, c$, είναι γνωστές.
3. Οι μορφές των δεσμευμένων ππ $p(\mathbf{x}|w_j, \theta_j)$ για κάθε κατηγορία, $j=1, \dots, c$, είναι γνωστές.
4. Οι τιμές των $\theta_1, \dots, \theta_c$ είναι άγνωστες.
5. Η κατηγορία κάθε δείγματος είναι άγνωστη.

(μίξεις πυκνοτήτων)

- Υποθέτουμε ότι ένα δείγμα \mathbf{x} επιλέγεται τυχαία με την παρακάτω διαδικασία:
 1. Επιλέγεται μια κατηγορία w_j με πιθανότητα $P(w_j)$, και
 2. Επιλέγεται ένα \mathbf{x} με πιθανότητα $p(\mathbf{x}/w_j, \theta_j)$.

Συνεπώς, η ολική πυκνότητα πιθανότητας είναι

$$p(\mathbf{x} | \theta) = \sum_{j=1}^c p(\mathbf{x} / w_j, \theta_j) P(w_j)$$

(μίξεις πυκνοτήτων)

- Στόχος είναι μια εκτίμηση του διανύσματος παραμέτρων $\theta = (\theta_1, \dots, \theta_c)^t$ από δείγματα \mathbf{x} .
- Αφού υπολογίσουμε το θ τότε μπορούμε να χρησιμοποιήσουμε έναν κατηγοριοποιητή ο οποίος ενσωματώνει εμπειρία.

Εκτίμηση μέγιστης πιθανοφάνειας

- Έστω ότι δίδεται ένα σύνολο $D = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ δειγμάτων (χωρίς-ετικέτα) που επιλέχθηκαν τυχαία και ανεξάρτητα από την μίξη πυκνότητας $p(\mathbf{x} | \theta) = \sum_{j=1}^c p(\mathbf{x} / w_j, \theta_j) P(w_j)$

- Η συνάρτηση πιθανοφάνειας ορίζεται ως

$$p(D | \theta) = \prod_{k=1}^n p(\mathbf{x}_k / \theta)$$

(Εκτίμηση μέγιστης πιθανοφάνειας)

- Η εκτίμηση μέγιστης πιθανοφάνειας είναι εκείνη η τιμή του θ η οποία μεγιστοποιεί την συνάρτηση πιθανοφάνειας

$$p(\mathbf{D} | \theta) = \prod_{k=1}^n p(\mathbf{x}_k / \theta)$$

(Εκτίμηση μέγιστης πιθανοφάνειας)

- Τυπικά υποθέτουμε ότι η $p(\mathbf{D}|\boldsymbol{\theta})$ είναι παραγωγίσιμη συνάρτηση του $\boldsymbol{\theta}$.
- Έστω l ο λογάριθμος της $p(\mathbf{D}|\boldsymbol{\theta})$ και έστω $\nabla_{\theta_i} l$ ο ρυθμός μεταβολής του l ως προς το θ_i . Τελικά συνεπάγεται

$$\nabla_{\theta_i} l = \sum_{k=1}^n P(w_i | \mathbf{x}_k, \boldsymbol{\theta}) \nabla_{\theta_i} \ln p(\mathbf{x}_k | \boldsymbol{\theta}_i)$$

(Εκτίμηση μέγιστης πιθανοφάνειας)

- Η εκτίμηση μέγιστης πιθανοφάνειας είναι εκείνη η τιμή του θ η οποία μηδενίζει την συνάρτηση $\nabla_{\theta_i} l$, δηλ.

$$\sum_{k=1}^n P(w_i | \mathbf{x}_k, \theta) \nabla_{\theta_i} \ln p(\mathbf{x}_k | \theta_i) = 0$$

Παράδειγμα

- Έστω μια (κανονική) μίξη με δύο συνιστώσες

$$p(x | \mu_1, \mu_2) = \underbrace{\frac{1}{3\sqrt{2\pi}} e^{-\frac{1}{2}(x-\mu_1)^2}}_{w_1} + \underbrace{\frac{2}{3\sqrt{2\pi}} e^{-\frac{1}{2}(x-\mu_2)^2}}_{w_2}$$

- Χρησιμοποιώντας $\mu_1=-2$, $\mu_2=2$ επιλέχθησαν τα ακόλουθα 25 δείγματα

(Παράδειγμα)

δείγμα (w_1/w_2)

k	x_k	k	x_k	k	x_k
1	0.608 (2)	9	0.262 (2)	17	-3.458 (1)
2	-1.590 (1)	10	1.072 (2)	18	0.257 (2)
3	0.235 (2)	11	-1.773 (1)	19	2.569 (2)
4	3.949 (2)	12	0.537 (2)	20	1.415 (2)
5	-2.249 (1)	13	3.240 (2)	21	1.410 (2)
6	2.704 (2)	14	2.400 (2)	22	-2.653 (1)
7	-2.473 (1)	15	-2.499 (1)	23	1.396 (2)
8	0.672 (2)	16	2.608 (2)	24	3.286 (2)
				25	-0.712 (1)

(Παράδειγμα)

- Χρησιμοποιήσαμε τα δείγματα του πίνακα για να υπολογίσουμε την παρακάτω λογαριθμική συνάρτηση πιθανοφάνειας

$$l(\mu_1, \mu_2) = \sum_{k=1}^n \ln p(x_k | \mu_1, \mu_2)$$

- Τελικά υπολογίστηκε $\mu_1 = -2.130$ και $\mu_2 = 1.668$.

Αλγόριθμος κ-μέσων Ομαδοποίηση

Αρχικοποίησε τα n , c , $\mu_1, \mu_2, \dots, \mu_c$.

1. Επανάλαβε κατηγοριοποίησε τα n δείγματα χρησιμοποιώντας το πλησιέστερο μ_i .
2. Ξανα-υπολόγισε τα μ_i .
3. Μέχρι να μην αλλάζουν τα μ_i .

επέστρεψε τα $\mu_1, \mu_2, \dots, \mu_c$.

Τεχνικές της Θεωρίας Τεκμηρίων

Ασθενής λαμβάνει δύο γνώμες γιατρών:

1. Πάσχει μόνο από την ασθένεια Α με πιθανότητα 60% ή μόνο από την Β (30%) ή μόνο από την Γ (10%).
2. Πάσχει μόνο από την ασθένεια Α με πιθανότητα 30% ή μόνο από την Β (20%) ή μόνο από την Γ (50%).

Τώρα πρέπει ο ίδιος ο ασθενής να αποφασίσει ποια θεραπευτική αγωγή θα ακολουθήσει.

Συνάρτηση μάζας (ορισμός)

Έστω X ένα σύνολο αναφοράς, και 2^X το δυναμοσύνολό του. Ορίζουμε συνάρτηση $m: 2^X \rightarrow [0,1]$ με το όνομα **συνάρτηση μάζας** με τις ακόλουθες δύο ιδιότητες:

1. $m(\emptyset) = 0$.
2. $\sum_{A \subseteq X} m(A) = 1$.

Διαφορά μάζας από πιθανότητα

- Ένας αυτόπτης μάρτυρας καταθέτει ότι το χρώμα ενός αυτοκινήτου ήταν είτε πράσινο είτε μπλέ ως ακολούθως

	τιμή συνάρτησης μάζας $m(\cdot)$
κανένα χρώμα	0
πράσινο	0.2
μπλε	0.5
πράσινο ή μπλε	0.3

- Παρατηρείστε ότι $m(\pi \text{ ή } \mu) \neq m(\pi) + m(\mu)$.

Συνδυαστικός κανόνας Dempster

• Έστω $m_1: 2^X \rightarrow [0,1]$ και $m_2: 2^X \rightarrow [0,1]$ δύο συναρτήσεις μαζών. Ο συνδυαστικός κανόνας του Dempster υπολογίζει την από κοινού συνάρτηση μάζας $m_{1,2} = m_1 \oplus m_2: 2^X \rightarrow [0,1]$ έτσι ώστε

1. $m_{1,2}(\emptyset) = 0$, και

2. $m_{1,2}(A) = (m_1 \oplus m_2)(A) = \frac{1}{1-K} \sum_{B \cap C = A \neq \{\}} m_1(B)m_2(C)$,

όπου $K = \sum_{B \cap C = \{\}} m_1(B)m_2(C)$.

Παράδειγμα 1

- Η Ελένη εκφράζει την επιθυμία να παρακολουθήσει την ταινία X με βεβαιότητα 99% και την ταινία Y με βεβαιότητα 1%, ενώ ο Πάρις εκφράζει την επιθυμία να παρακολουθήσει την ταινία Z με βεβαιότητα 99% και την ταινία Y με βεβαιότητα 1%.
- Τελικά προκύπτει $(m_1 \oplus m_2)(\{Y\}) = 1$ (Αυτό το αποτέλεσμα θεωρείται «διαισθητικό»).

Παράδειγμα 2

- Ένας γιατρός εκτιμά ότι ο ασθενής είτε έχει κακοήθη όγκο στον εγκέφαλο (99%) είτε πάσχει από μηνιγγίτιδα (1%). Ενώ, ένας άλλος γιατρός εκτιμά ότι ο ασθενής είτε έχει πάθει εγκεφαλική διάσειση (99%) είτε πάσχει από μηνιγγίτιδα (1%).
- Προκύπτει $(m_1 \oplus m_2)(\{\text{μηνιγγίτιδα}\}) = 1$ (Αυτό το αποτέλεσμα θεωρείται «μη-διαισθητικό»).

Άσκηση

- Το χρώμα αυτοκίνητου ανήκει στο σύνολο $\{(K)όκκινο, (Π)ράσινο, (Μ)πλε\}$. Δύο μάρτυρες καταθέτουν

	μάζα m_1	μάζα m_2
{}	0	0
{K}	0.05	0.15
{Π}	0	0
{M}	0.05	0.05
{K, Π}	0.15	0.05
{K, M}	0.10	0.20
{Π, M}	0.05	0.05
{K, Π, M}	0.60	0.50

Ποια είναι η πιθανότερη εκδοχή χρώματος του αυτοκινήτου σύμφωνα με την συνάρτηση μάζας $m_{1,2}$;

Στοιχεία Επικοινωνίας

Δρ. Βασίλειος Γ. Καμπουράζος

vgkabs@teiemt.gr

Τηλ. 6945224802

Γραφείο B122 (Κτήριο βιβλιοθήκης)

ΕΥΧΑΡΙΣΤΩ