



Πρόγραμμα Μεταπτυχιακών Σπουδών  
"Προηγμένες Τεχνολογίες Υπολογιστών  
και Πληροφορικής"

# Υπολογιστική Νοημοσύνη

Μάθημα 5<sup>ο</sup>

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

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

2017-2018

# 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  $(\mathbf{x}_1, \mathbf{y}_1), \dots, (\mathbf{x}_N, \mathbf{y}_N)$ , όπου  $\mathbf{x}_1, \dots, \mathbf{x}_N$  είναι  $N$  δεδομένα και  $\mathbf{y}_1, \dots, \mathbf{y}_N$  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  $X^ε$  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  $\varepsilon$ .

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

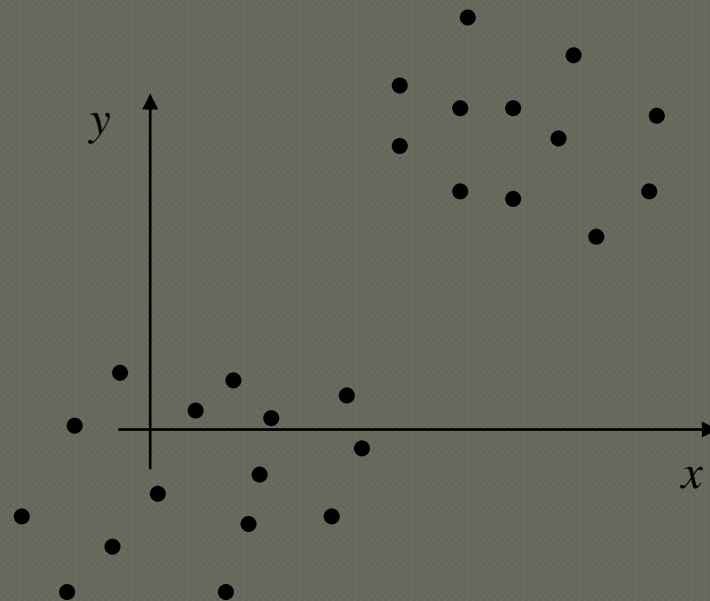
# Τεχνικές Ομαδοποίησης

---

- 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  $\theta$  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  $\theta$  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  $\nabla_{\boldsymbol{\theta}_i} l$  ο ρυθμός μεταβολής του  $l$  ως προς το  $\boldsymbol{\theta}_i$ . Τελικά συνεπάγεται

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

## (Εκτίμηση μέγιστης πιθανοφάνειας)

- Η εκτίμηση μέγιστης πιθανοφάνειας είναι εκείνη η τιμή του  $\theta$  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  $\mu_i$ .
2. Ξανα-υπολόγισε τα  $\mu_i$ .
3. Μέχρι να μην αλλάζουν τα  $\mu_i$ .

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
{Μ}	0.05	0.05
{K, Π}	0.15	0.05
{K, Μ}	0.10	0.20
{Π, Μ}	0.05	0.05
{K, Π, Μ}	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](mailto:vgkabs@teiemt.gr)

Τηλ. 6945224802

Γραφείο B122 (Κτήριο βιβλιοθήκης)

---

ΕΥΧΑΡΙΣΤΩ