ΟΙΚΟΝΟΜΙΚΟ ΠΑΝΕΠΙΣΤΗΜΙΟ ΑΘΗΝΩΝ
ATHENS UNIVERSITY OF ECONOMICS AND BUSINESS

Τεχνητή Νοημοσύνη

7η διάλεξη (2026-27)

Ίων Ανδρουτσόπουλος

http://www.aueb.gr/users/ion/

Οι διαφάνειες αυτής της διάλεξης βασίζονται σε ύλη των βιβλίων (α) *Artificial Intelligence – A Modern Approach* των S. Russel και P. Norvig, 2η και 4η έκδοση, Prentice Hall, 2003 και 2020, (β) *Τεχνητή Νοημοσύνη* των Βλαχάβα κ.ά., 3η έκδοση, Β. Γκιούρδας Εκδοτική, 2006 και (γ) *Machine Learning* του T. Mitchell, McGraw-Hill, 1997. Τα περισσότερα σχήματα των διαφανειών βασίζονται σε αντίστοιχα σχήματα των διαφανειών που συνοδεύουν τα πρώτα δύο βιβλία.

Τι θα ακούσετε σήμερα

- Είδη συλλογιστικής
  - Παραγωγική, απαγωγική, επαγωγική συλλογιστική.
- Μηχανική μάθηση
  - Εισαγωγή και είδη μηχανικής μάθησης.
  - Παράσταση δεδομένων και υποθέσεων.
  - Η μηχανική μάθηση ως πρόβλημα αναζήτησης.
- Παράσταση κειμένων: σάκοι λέξεων, TF-IDF.
- Εντροπία και κέρδος πληροφορίας.
- Επιλογή ιδιοτήτων μέσω κέρδους πληροφορίας και μέσω αναζήτησης υποσυνόλων ιδιοτήτων.

Είδη συλλογιστικής

- **Παραγωγική** συλλογιστική (deduction).
  - Παραγωγή ορθών συμπερασμάτων με **κανόνες λογικής**.
  - Π.χ. modus ponens, modus tollens (επόμενες διαλέξεις)
  - Π.χ. $\{\forall x_1\ (Dog(x_1) \Rightarrow Animal(x_1)), Dog(Fido)\} \vdash Animal(Fido)$
- **Απαγωγική** συλλογιστική (abduction).
  - Προσπάθεια εύρεσης **πιθανής** υπόθεσης που να εξηγεί παρατηρήσεις. Η υπόθεση μπορεί να **μην ισχύει**.
  - Π.χ. γνώση: $\forall x_1\ (Has(x_1, Grippe) \Rightarrow Fever(x_1, High))$
  - Παρατήρηση: Fever(John, High)
  - Πιθανή εξήγηση: Has(John, Grippe)
  - Πολύ σημαντικός μηχανισμός σε συστήματα **διάγνωσης**.

Είδη συλλογιστικής (συνέχεια)

- **Επαγωγική** συλλογιστική (induction).
  - Προσπάθεια εύρεσης **γενίκευσης**.
  - *Has(Patient323, Grippe), Fever(Patient323, High),* Has(Patient357, Pneumonia), Fever(Patient357, High), *Has(Patient389, Grippe), Fever(Patient389, High), Has(Patient456, Grippe), Fever(Patient456, High),* Has(Patient498, Grippe), Fever(Patient498, <u>Medium</u>).
  - Γενίκευση (αγνοώντας σπάνιες περιπτώσεις):

$$\forall x_1\ (\mathrm{Has}(x_1, \mathrm{Grippe}) \Rightarrow \mathrm{Fever}(x_1, \mathrm{High}))$$

  - Ιδιαίτερα σημαντική στη **μηχανική μάθηση**.

Μηχανική μάθηση

- Η **χειρωνακτική** εισαγωγή γνώσεων σε ένα σύστημα είναι συχνά **δύσκολη**.
  - Δυσκολία/κόστος εκμαίευσης γνώσης από ειδικούς.
  - Δυσκολία προσδιορισμού των απαιτούμενων γνώσεων.
- **Αλγόριθμοι μηχανικής μάθησης**: εξάγουν αυτόματα **νέες γνώσεις** από **εμπειρικά δεδομένα**, βελτιώνοντας έτσι τη συμπεριφορά ενός συστήματος.
  - Π.χ. πρόγραμμα που μαθαίνει να κάνει **ιατρικές διαγνώσεις** από προηγούμενες διαγνώσεις ιατρών και τα αντίστοιχα αποτελέσματα εργαστηριακών εξετάσεων.
  - Π.χ. πρόγραμμα που μαθαίνει να **κατατάσσει κριτικές προϊόντων** σε θετικές, αρνητικές, μικτές, ουδέτερες.

Μερικές από τις πολλές εφαρμογές της ΜΜ

- Αναγνώριση χαρακτήρων σε **χειρόγραφα**.
  - Προγράμματα οπτικής αναγνώρισης χαρακτήρων (OCR).
  - Προγράμματα αναγνώρισης χαρακτήρων για κινητά.
- Αναγνώριση **ομιλίας**.
  - Αναγνώριση προφορικών εντολών (π.χ. στο αυτοκίνητο).
  - Μετατροπή συνεχούς ομιλίας σε γραπτή μορφή (υπαγόρευση).
- Προγράμματα που παίζουν **τάβλι**, **σκάκι**, **Go**, …
  - TD-GAMMON (Tesauro 1992, 95): εκπαιδεύτηκε παίζοντας πάνω από 1 εκατομμύριο παρτίδες με τον εαυτό του.
  - AlphaGo (Google DeepMind, https://en.wikipedia.org/wiki/AlphaGo).
- **Οδήγηση** αυτοκινήτου.
  - ALVINN (Pomerlau 1989): μετά από εκπαίδευση οδήγησε σε αυτοκινητόδρομο επί 90 μίλια με ταχύτητα 70 μιλίων/ώρα.
  - Self-driving cars (https://waymo.com/).
- **Μεγάλα γλωσσικά μοντέλα (LLMs)**.
  - Π.χ. GPT-x, Claude, Llama, Gemini, Quen, Mixtral, DeepSeek…

Επιβλεπόμενη/μη επιβλεπόμενη μάθηση

- Αλγόριθμοι **επιβλεπόμενης μάθησης**.
  - Προϋποθέτουν ότι υπάρχουν **παραδείγματα εκπαίδευσης** για τα οποία είναι γνωστές (ή μπορούν να αποκτηθούν) οι **ορθές απαντήσεις**.
  - Π.χ. σύστημα που μαθαίνει να κάνει **ιατρικές διαγνώσεις** από προηγούμενες περιπτώσεις ασθενών και διαγνώσεων.
- Αλγόριθμοι **μη επιβλεπόμενης μάθησης**.
  - Προσπαθούν να ανακαλύψουν νέες γνώσεις από δεδομένα που **δεν περιέχουν τις επιθυμητές απαντήσεις**.
  - Π.χ. οργάνωση πελατών ή ειδήσεων σε **ομάδες (clusters)** ή εύρεση συσχετισμών της μορφής «οι πελάτες που αγοράζουν το Χ την Παρασκευή αγοράζουν και ...».
  - Πολλές εφαρμογές στην **εξόρυξη γνώσης** και την **επιστήμη δεδομένων** (παρακολουθήστε το αντίστοιχο μάθημα).

Παραδείγματα εκπαίδευσης

- Τραπεζικό σύστημα που θα αποφασίζει αν πρέπει να δοθεί **δάνειο** σε έναν πελάτη.

ιδιότητες

Πελάτης	**Οφειλές**	**Εισόδημα**	**Παντρεμένος**	**Καλός;**
1	Υψηλές (1)	Υψηλό (1)	Ναι (1)	Καλός (1)
2	Χαμηλές (0)	Υψηλό (1)	Όχι (0)	Κακός (0)
3	Χαμηλές (0)	Υψηλό (1)	Ναι (1)	Καλός (1)
4	Υψηλές (1)	Χαμηλό (0)	Ναι (1)	Κακός (0)
5	Χαμηλές (0)	Χαμηλό (0)	Ναι (1)	Κακός (0)

- **Διανυσματική** παράσταση εμπειρίας:

$\{ <1, 1, 1, \mathbf{1}>, <0, 1, 1, \mathbf{1}>, <0, 1, 0, \mathbf{0}>, <1, 0, 1, \mathbf{0}>, <0, 0, 1, \mathbf{0}> \}$

επιθυμητές απαντήσεις

Η μάθηση ως πρόβλημα αναζήτησης

- Αναζήτηση μιας **συνάρτησης** («**υπόθεσης**»).
  - $h(x, y, z) = ?$
  - $h: \{0, 1\} \times \{0, 1\} \times \{0, 1\} \rightarrow \{0, 1\}$
  - γενικότερα $\mathbf{h: D_1 \times D_2 \times \ldots \times D_n \rightarrow C}$
  - $\mathbf{D_i}$: οι δυνατές τιμές της i-στής **ιδιότητας**.
  - **C**: οι δυνατές **απαντήσεις**.
- Αναζήτηση σε ένα **χώρο συναρτήσεων**.
  - Θεωρούμε ότι τα δεδομένα εκπαίδευσης είναι ένα **δείγμα** από έναν πληθυσμό που παράγεται σύμφωνα με μια **συγκεκριμένη άγνωστη συνάρτηση**.
  - Αναζητούμε αυτή τη συνάρτηση μέσα σε ένα **χώρο συναρτήσεων**.

Χώρος αναζήτησης

- Ο χώρος αναζήτησης εξαρτάται από τις **ιδιότητες**.
  - **Ποιες ιδιότητες** θα χρησιμοποιήσουμε;
  - Αντιστοιχούν στα ορίσματα των υποθέσεων.
  - Π.χ. οικογ. κατάσταση, οφειλές, ηλικία, επάγγελμα, ύψος;
  - **Τιμές** από πεπερασμένο σύνολο, πραγματικοί αριθμοί;
- Και από το **μοντέλο παράστασης** των υποθέσεων.
  - Π.χ. **γραμμική συνάρτηση** των ιδιοτήτων;
  - Περιορίζουμε την αναζήτηση στις (π.χ. γραμμικές) **υποθέσεις που μπορεί να παραστήσει το μοντέλο**.
  - Δεν μπορούμε να μάθουμε μια υπόθεση που δεν μπορεί να παρασταθεί από το μοντέλο που διαλέξαμε.
  - Οι περιορισμοί του μοντέλου, όμως, **μειώνουν το μέγεθος του χώρου αναζήτησης**.
  - Δυστυχώς συχνά δεν ξέρουμε τι περιορισμούς να επιβάλουμε.

Μοντέλο παράστασης υποθέσεων

- Απλοϊκό παράδειγμα για το πρόβλημα των δανείων:
  - Παριστάνουμε κάθε συνάρτηση-υπόθεση με μια **τριάδα** που αντιστοιχεί στις περιπτώσεις που δίνουμε δάνειο.
  - Π.χ. $\mathbf{h_1 = <0, ?, 1>}$, $\mathbf{h_2 = <1, 1, 1>}$
  - «?» σημαίνει για **οποιαδήποτε** τιμή.

Αν χαμηλές οφειλές και παντρεμένος/η, δώσε δάνειο ανεξαρτήτως εισοδήματος. Διαφορετικά μη δώσεις

Αν υψηλές οφειλές και υψηλό εισόδημα και παντρεμένος/η, δώσε δάνειο. Διαφορετικά μη δώσεις.

- Αδύνατον, όμως, να μάθουμε την $(\mathbf{h_1} \vee \mathbf{h_2})$, γιατί δεν περιλαμβάνεται στο χώρο αναζήτησης.

Γενικότερες/ειδικότερες υποθέσεις

- Υποθέτουμε εδώ πάλι ότι οι **τιμές των υποθέσεων** είναι **0 ή 1** και οι **ιδιότητες** έχουν **διακριτές** τιμές.
- Η **h_2 είναι ειδικότερη της h_1** ανν $h_1 \neq h_2$ (διαφορετικές συναρτήσεις) και:
  - **αν $h_2(x_1, ..., x_n) = 1$, τότε $h_1(x_1, ..., x_n) = 1$.**
  - Π.χ. αν δίνει δάνειο η h_2, τότε δίνει και η h_1.
- Η h_1 είναι **γενικότερη** της h_2 ανν η h_2 είναι ειδικότερη της h_1.

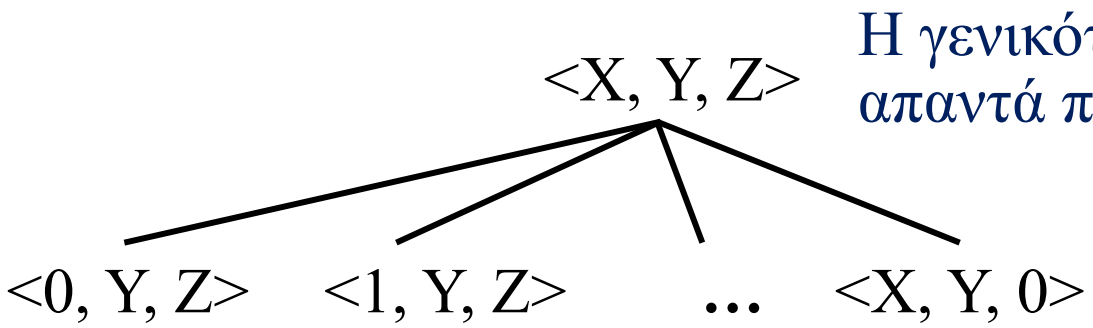

Η γενικότερη υπόθεση: απαντά πάντα «ναι»

Αμέσως ειδικότερες υποθέσεις.

Εδώ χρησιμοποιούμε μεταβλητές αντί για «?».

Χώρος αναζήτησης

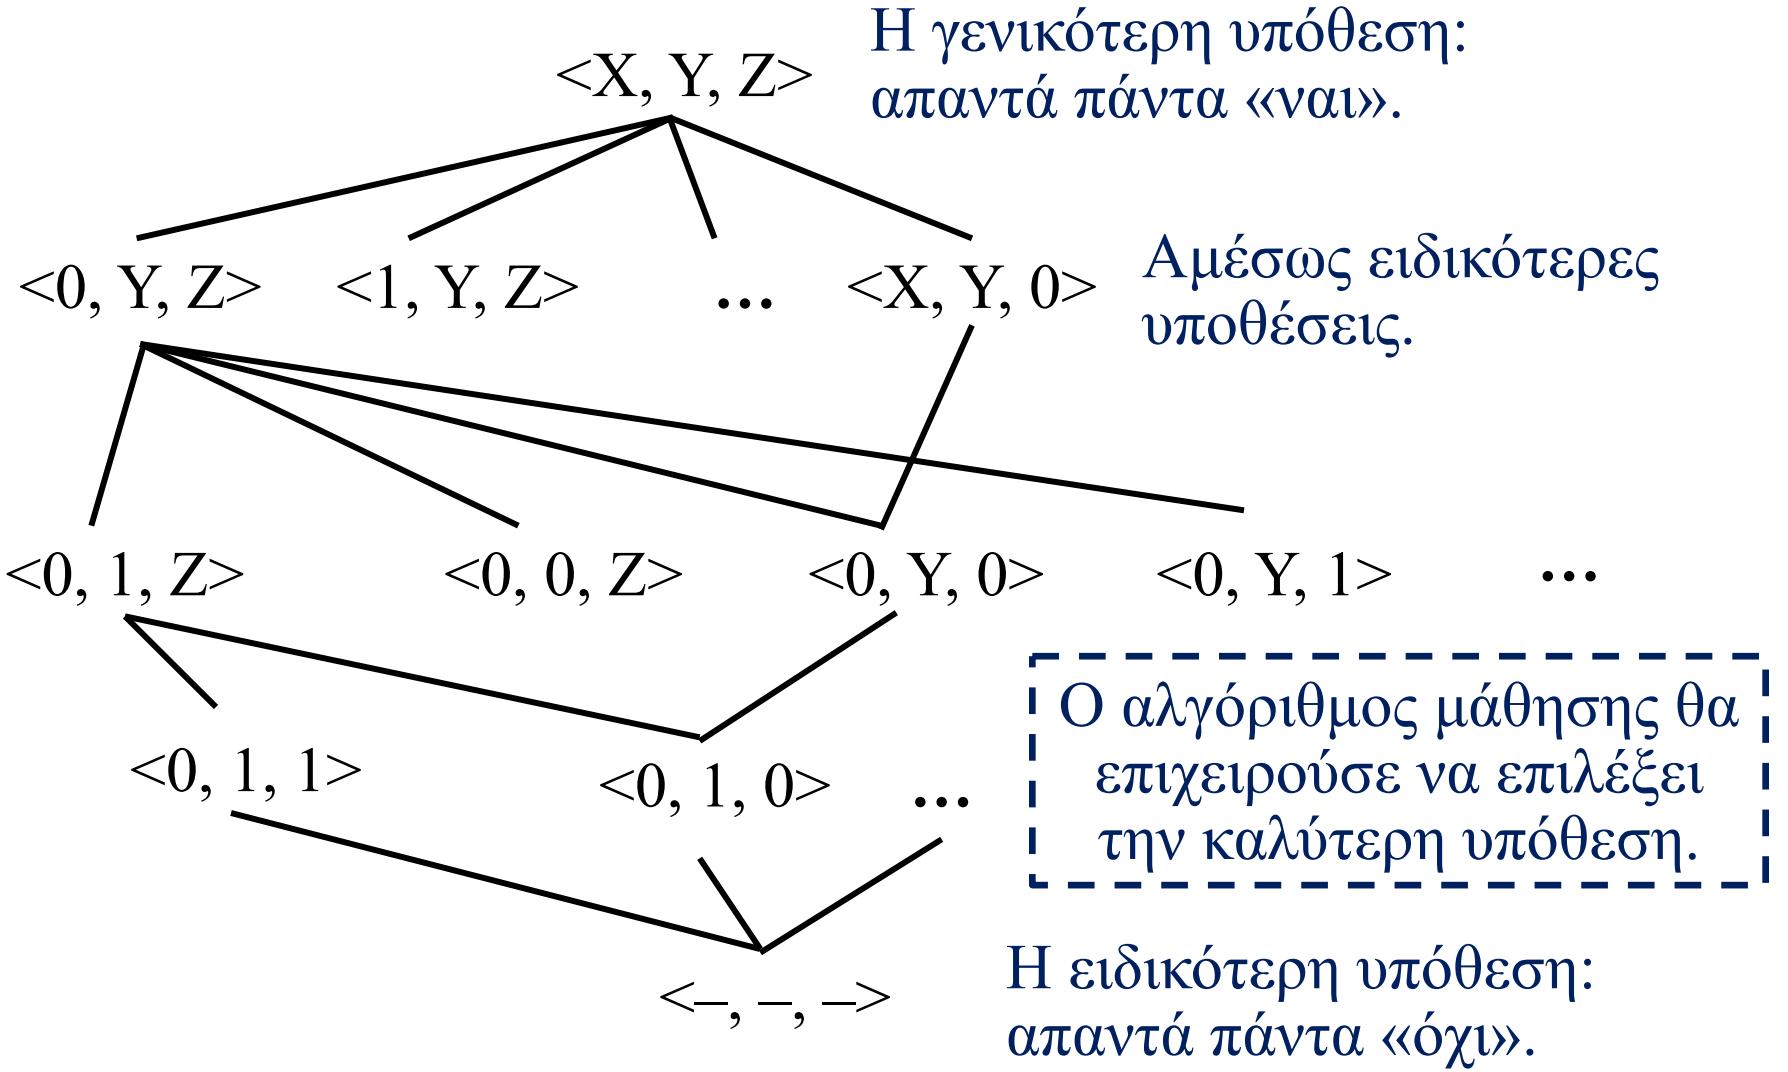

Συνεπείς υποθέσεις και γενίκευση

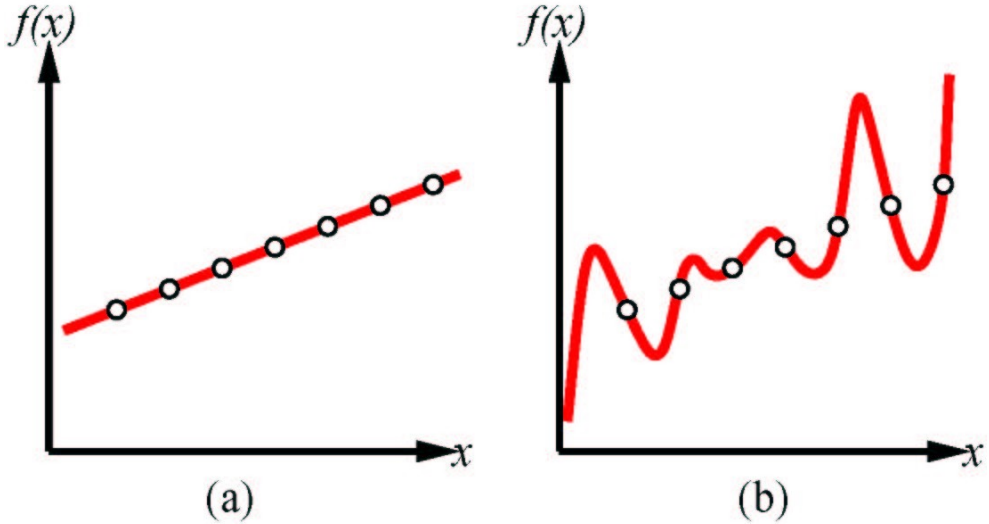

Οι τελείες αντιστοιχούν σε δεδομένα εκπαίδευσης. Εδώ έχουμε μία ιδιότητα και οι τιμές των υποθέσεων είναι πραγματικοί. Έστω ότι αναζητούμε πολυωνυμικές υποθέσεις.

- **Συνεπείς υποθέσεις**: συμφωνούν με τα δεδομένα εκπαίδευσης.
  - (a): πολυώνυμο 1ου βαθμού. (b): πολυώνυμο μεγαλύτερου βαθμού.
- **Ξυράφι του Ockham**: Προτιμότερη είναι η **απλούστερη** συνεπής υπόθεση, εδώ το πολυώνυμο μικρότερου βαθμού.
  - Απλούστερες υποθέσεις είναι ευκολότερο να κατασκευαστούν (π.χ. γραμμική παρεμβολή) και οι αποκρίσεις τους υπολογίζονται ευκολότερα.
- **Ικανότητα γενίκευσης**: Να δίνει σωστές απαντήσεις και για νέες περιπτώσεις που δεν ανήκουν στα παραδείγματα εκπαίδευσης.
  - Απλούστερες υποθέσεις συνήθως γενικεύουν καλύτερα τις παρατηρήσεις.

Ασυνεπείς υποθέσεις ίσως είναι προτιμότερες

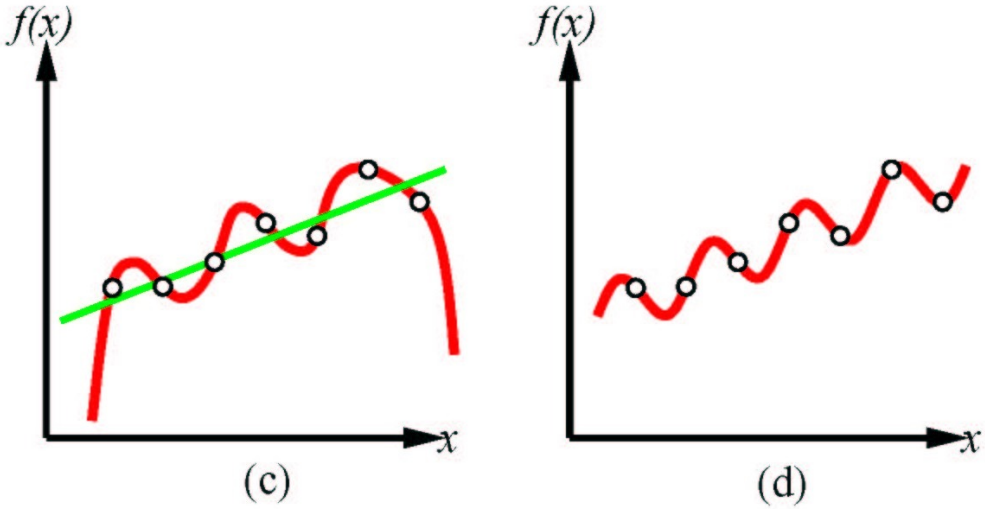

Τα δεδομένα εκπαίδευσης ακολουθούν μια συνάρτηση της μορφής **a·x + b + c·sinx** (διάγραμμα d), που είναι αδύνατον να παρασταθεί ως πολυώνυμο πεπερασμένου βαθμού.

- Αν περιορίσουμε την αναζήτηση σε **πολυώνυμα πεπερασμένου βαθμού** (έστω ≤ k), η συνάρτηση-στόχος του (d) **δεν περιλαμβάνεται** στο χώρο αναζήτησης.
- Αν επιμείνουμε στην εξεύρεση **συνεπούς** υπόθεσης, καταλήγουμε στο **πολυώνυμο 6ου βαθμού** της κόκκινης γραμμής του (c), που **δεν επιτυγχάνει καλή γενίκευση**.
  - Μας ενδιαφέρει οι προβλέψεις να είναι καλές για όλα τα x.
- Οι προβλέψεις της **ευθείας γραμμής** (c) είναι εν γένει **πιο κοντά** στις επιθυμητές τιμές (d), αν και η (c) είναι **ασυνεπής**.

Παράδειγμα: φίλτρα ανεπιθύμητων μηνυμάτων

our highly successful multi – national company gives you an exclusive business that generates an extra weekly income of up to $ 600 or more … anyone can easily make money … if you wish to be removed from our list …

call for papers 9 th european workshop on natural language generation … is a subfield of natural language processing that generates texts in human languages from non-linguistic data or knowledge … for the systems to be successful …

- **Πρόβλημα κατάταξης** με **δύο κατηγορίες.**
  - Spam ($C = 1$), ham ($C = 0$).
- Γενικότερα μπορεί να υπάρχουν ***n* κατηγορίες**.
  - **Πιθανώς επικαλυπτόμενες** (multi-label): π.χ. οικονομικά, πολιτικά, κοινωνικά, αθλητικά νέα.
  - Ή **μη επικαλυπτόμενες** (single-label): π.χ. θετική, αρνητική, ουδέτερη, ανάμικτη κριτική προϊόντος.

Φίλτρο ανεπιθύμητων μηνυμάτων με επιβλεπόμενη ΜΜ

παραδείγματα επιθυμητών και ανεπιθύμητων μηνυμάτων + σωστές απαντήσεις

εκπαίδευση

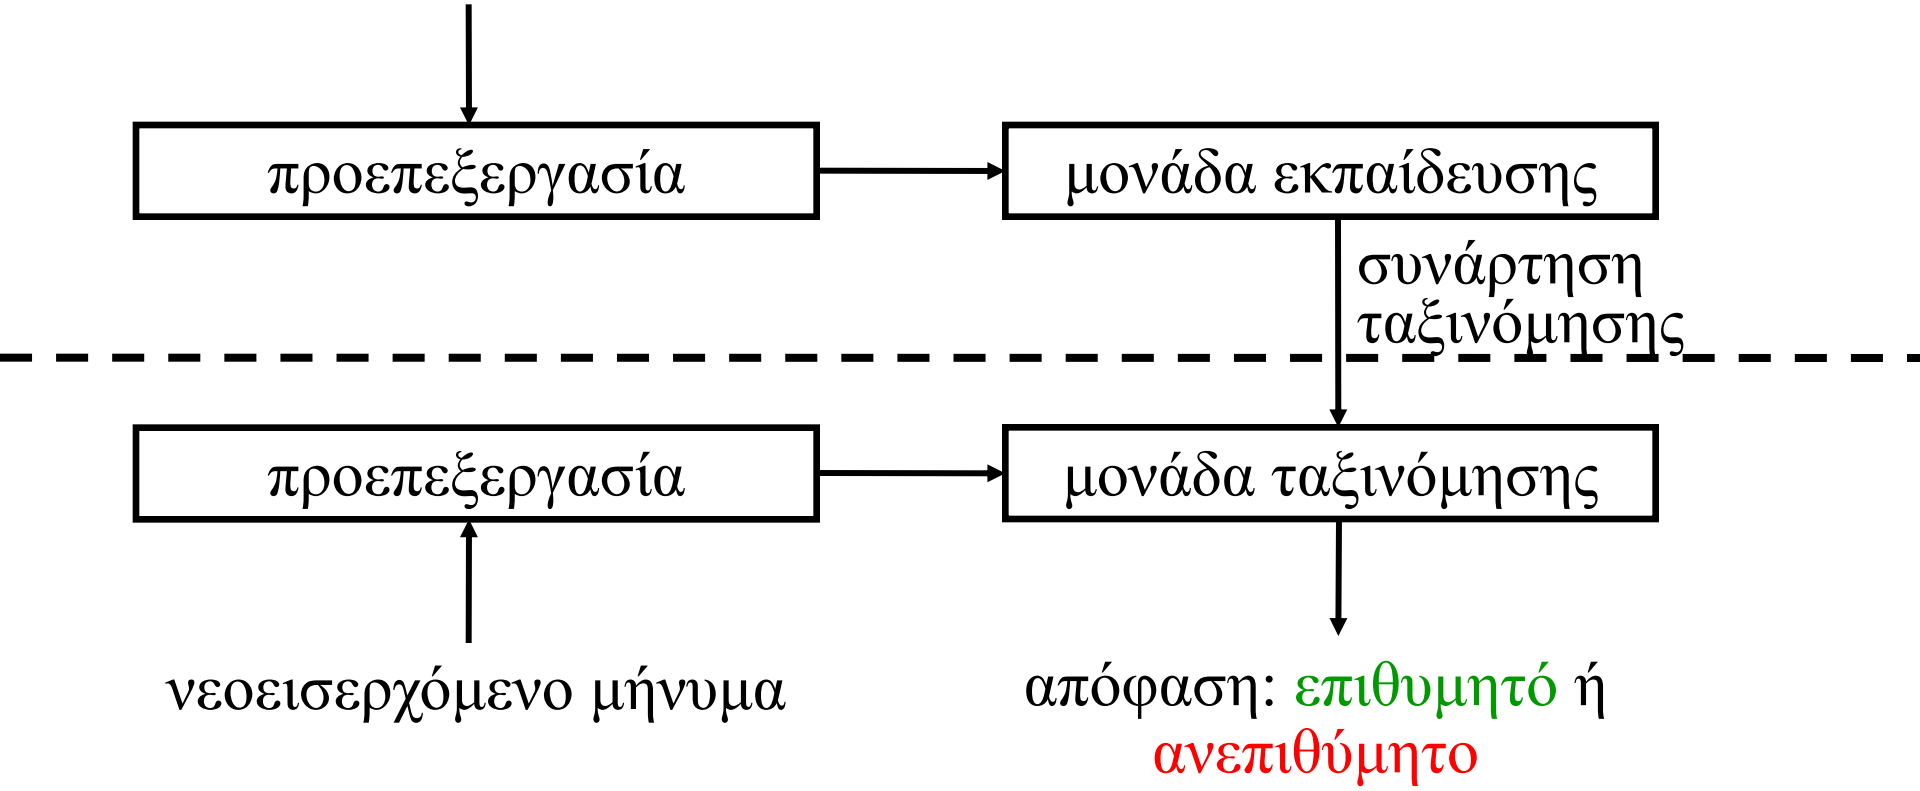

χρήση

Προεπεξεργασία κειμένων

our highly successful multi – national company gives you an exclusive business that generates an extra weekly income of up to $ 600 or more … anyone can easily make money … if you wish to be removed from our list …

call for papers 9 th european workshop on natural language generation … is a subfield of natural language processing that generates texts in human languages from non-linguistic data or knowledge … for the systems to be successful …

< money:1, language:0, natural:0, $:1, adult:0, call:0, exclusive:1, **successful:1**, removed:1, **generates:1**, …>

< money:0, language:1, natural:1, $:0, adult:0, call:1, exclusive:0, **successful:1**, removed:0, **generates:1**, …>

- Εναλλακτικά οι **ιδιότητες** μπορεί να παριστάνουν **συχνότητες** εμφάνισης λέξεων στο μήνυμα και/ή να αντιστοιχούν σε **φράσεις** (π.χ. «to be removed»), **χαρακτηριστικά εικόνων** κλπ.

Απλές διανυσματικές παραστάσεις κειμένων

- **Δυαδικά διανύσματα** (τιμές 0, 1): **ποιες λέξεις** ενός λεξιλογίου **εμφανίζονται ή όχι** στο κείμενο;
- **Διανύσματα συχνοτήτων** λέξεων (term frequencies, ***TF***): **πόσες φορές** εμφανίζεται κάθε λέξη στο κείμενο;
  - Συχνά **διαιρούμε με το μήκος** (σε λέξεις) **του κειμένου**.
- **Διανύσματα *TF-IDF***: **για κάθε λέξη** w_i του λεξιλογίου το διάνυσμα περιέχει ένα σκορ $TF_i \cdot IDF_i$:
  - Θέλουμε **μεγάλα σκορ** για λέξεις που είναι **συχνές στο συγκεκριμένο κείμενο** αλλά **όχι κοινές στη γλώσσα**.

$$IDF_i = \log\left(\frac{Ndoc}{DF_i}\right)$$

Πλήθος εγγράφων σε μια μεγάλη συλλογή.

Πλήθος εγγράφων που **περιέχουν την** w_i.

  - IDF_i (inverse document frequency): δείχνει πόσο σπάνια είναι η w_i σε μια γλώσσα.

Επιλογή ιδιοτήτων

- Για **ποιες λέξεις** (ή φράσεις ή ...) θα υπάρχουν **ιδιότητες** στα διανύσματα;
  - 1ο βήμα: μόνο λέξεις που εμφανίζονται **τουλάχιστον** k φορές στα παραδείγματα εκπαίδευσης (π.χ. $k = 3$).
  - Συνήθως παραμένουν αρκετές **χιλιάδες** λέξεις (και πολύ περισσότερες φράσεις).
  - Με χιλιάδες ιδιότητες: προβλήματα **ταχύτητας**, **ορθότητας** και **υπερεφαρμογής** με πολλούς αλγορίθμους μηχανικής μάθησης.
- Πόσο **αξίζει** κάθε υποψήφια ιδιότητα X;
  - Αν ξέρουμε την τιμή της X, **πόση πληροφορία** κερδίζουμε;
  - Πόσο μειώνεται η **αβεβαιότητά** μας για τη σωστή απάντηση;
  - $C = 1$ (ανεπιθύμητο) ή $C = 0$ (επιθυμητό).
  - Πόσο μειώνεται η **αβεβαιότητά** μας για την τιμή της **τυχαίας μεταβλητής** C, αν ξέρουμε την τιμή της X;

Παράδειγμα κωδικοποίησης τιμών

- Έστω οι ακόλουθες **δυνατές τιμές** της **C**:
  - c_1 με $P(c_1) = 1/4$, c_2 με $P(c_2) = 1/4$, c_3 με $P(c_3) = 1/2$.
- **Παράδειγμα** κωδικοποίησης:
  - Χρησιμοποιούμε **λιγότερα δυφία** (bits) **για τις πιο πιθανές** τιμές.
  - c1 → 10, c2 → 11. Χρησιμοποιούμε $-\log_2(1/4) = 2$ δυφία.
  - c3 → 0. Χρησιμοποιούμε $-\log_2(1/2) = 1$ δυφίο.
  - Αν ο παραλήπτης λάβει «1», ξέρει ότι ακολουθεί και δεύτερο δυφίο.
  - Αναμενόμενος αριθμός δυφίων: $1/4 \cdot 2 + 1/4 \cdot 2 + 1/2 \cdot 1 = 1.5$
- Γενικότερα, στην **ιδανική κωδικοποίηση** (ελάχιστος αναμενόμενος αριθμός μεταδιδόμενων δυφίων) χρησιμοποιούμε **$-\log_2(P(c_i))$ δυφία για κάθε τιμή c_i**.
  - Αν οι πιθανότητες $P(c_i)$ **δεν είναι δυνάμεις του 2**, **ίσως είναι αδύνατον** να χρησιμοποιήσουμε ακριβώς **$-\log_2(P(c_i))$ δυφία** για κάποια c_i στην πράξη. Αλλά δεν μας πειράζει αυτό, η ιδανική κωδικοποίηση είναι θεωρητική.
  - **Στην πράξη**, ο **αναμενόμενος αριθμός μεταδιδόμενων δυφίων** θα είναι γενικά **μεγαλύτερος ή ίσος αυτού της ιδανικής κωδικοποίησης**, τόσο μεγαλύτερος **όσο απέχει η κωδικοποίηση από την ιδανική**.

Εντροπία

Εδώ η **ορθή** απόκριση.

- **Εντροπία** της τυχαίας μεταβλητής *C*.
  - Δείχνει **πόσο αβέβαιοι** είμαστε για την **τιμή της *C***.
  - Πόση είναι η **ελάχιστη ποσότητα πληροφορίας** που πρέπει να μας δοθεί για να γνωρίζουμε με βεβαιότητα την τιμή της *C*.
  - Ποιος είναι στην **καλύτερη περίπτωση** (με την ιδανική κωδικοποίηση) ο **αναμενόμενος αριθμός δυφίων** που πρέπει να μας μεταδοθεί για να καθοριστεί η τιμή της *C*;

αναμενόμενη τιμή

$$H(C) = -\sum_{c} P(C=c) \cdot \log_2 P(C=c)$$

Δυφία που χρησιμοποιούμε στην ιδανική κωδικοποίηση για την παράσταση κάθε τιμής.

- Στην περίπτωση δύο κατηγοριών:

$$H(C) = -P(C=1) \cdot \log_2 P(C=1) - P(C=0) \cdot \log_2 P(C=0)$$

Εκτίμηση πιθανοτήτων από τα παραδείγματα εκπαίδευσης.

Παράδειγμα

- Συλλογή **800 μηνυμάτων** e-mail εκπαίδευσης.
  - Προηγούμενα μηνύματα που έχω λάβει.
  - **200 ανεπιθύμητα** διαφημιστικά μηνύματα (spam).
  - **600 επιθυμητά** μηνύματα.
- Εκτιμήστε την **εντροπία της *C*** (κατηγορία νέου μηνύματος) με βάση τα μηνύματα εκπαίδευσης.
  - ***C* = 1** (ανεπιθύμητο) ή ***C* = 0** (επιθυμητό).
  - $\log_2 3 = 1.585$
- **Πόση γίνεται** η εντροπία της *C* αν **όλα** τα μηνύματα εκπαίδευσης είναι **επιθυμητά** (ή ανεπιθύμητα);
- Αν είναι **400 επιθυμητά** και **400 ανεπιθύμητα**;

$$H(C) = -P(C=1)\cdot\log_2 P(C=1) - P(C=0)\cdot\log_2 P(C=0)$$

Κέρδος πληροφορίας

- Εντροπία της C **αν μάθουμε ότι η τιμή της X είναι 1**:

$$H(C \mid X=1) = -\sum_{c} P(C=c \mid X=1) \cdot \log_2 P(C=c \mid X=1)$$

- Εντροπία της C **αν μάθουμε ότι η τιμή της X είναι 0**:

$$H(C \mid X=0) = -\sum_{c} P(C=c \mid X=0) \cdot \log_2 P(C=c \mid X=0)$$

- **Κέρδος πληροφορίας *IG*** (information gain):

Αναμενόμενη μείωση της $H(C)$, αν μάθουμε την τιμή της X.

$$IG(C,X) = IG(X,C) = H(C) - \sum_{x} P(X=x) \cdot H(C \mid X=x)$$

αναμενόμενη τιμή

x για κάθε δυνατή τιμή του X

Επιλογή ιδιοτήτων με IG

- Υπολογίζουμε το κέρδος πληροφορίας ***IG*(*C*, *X*)** που παρέχει κάθε **υποψήφια ιδιότητα** *X*.
  - Π.χ. η *X* μπορεί να παριστάνει την ύπαρξη ($X = 1$) ή μη ($X = 0$) της λέξης «money» στο μήνυμα.
  - Οι πιθανότητες εκτιμούνται χρησιμοποιώντας τα παραδείγματα εκπαίδευσης.
- Επιλέγουμε τις ιδιότητες με τα **m υψηλότερα** $IG(C,X)$.
  - Π.χ. $m = 500$. Συχνά αφού παραλείψουμε πολύ συχνές λέξεις (stop-words, π.χ. άρθρα, συνδέσμους) και πολύ σπάνιες λέξεις.
- Παριστάνουμε τα παραδείγματα εκπαίδευσης και τα νεοεισερχόμενα μηνύματα ως **διανύσματα *m* διαστάσεων**.
  - Π.χ. $<X_1, X_2, X_3, \ldots, X_m> = <0, 1, 1, \ldots, 0>$

Παράδειγμα επιλεγμένων ιδιοτήτων

Λέξη του X_i	$P(X_i=1)$	$P(X_i=1\|C=0)$	$P(X_i=1\|C=1)$
!	0.484105	0.216129	0.828157
$	0.257947	0.040322	0.538302
language	0.247956	0.440322	0.002070
money	0.163487	0.001612	0.372670
remove	0.146230	0.001612	0.333333
free	0.309718	0.104838	0.573498
university	0.219800	0.374193	0.022774

Αναζήτηση υπο-συνόλων ιδιοτήτων

- Ως τώρα θεωρούσαμε ότι **κάθε υποψήφια ιδιότητα** αξιολογείται **ξεχωριστά**.
  - Με *IG*, υπάρχουν και άλλα μέτρα (π.χ. χ^2).
- Μπορεί, όμως, μια ιδιότητα ουσιαστικά να παρέχει περίπου τις **ίδιες πληροφορίες με μια άλλη**.
  - Π.χ. αν οι λέξεις «money» και «rich» εμφανίζονται (ή όχι) σχεδόν πάντα μαζί.
  - Οπότε μπορεί **και οι δύο** να έχουν υψηλό **IG**, αλλά **η μία να περιττεύει**.
- Μπορεί, επίσης, δύο (ή περισσότερες) ιδιότητες **από μόνες τους να μην είναι πολύ χρήσιμες**, αλλά και οι δύο (ή περισσότερες) **μαζί να προβλέπουν καλά** την κατηγορία.
  - Π.χ. υψηλός πυρετός ΚΑΙ δύσπνοια...

Αναζήτηση υπο-συνόλων ιδιοτήτων – συνέχεια

- Μπορούμε να θεωρήσουμε το πρόβλημα **επιλογής** του **καλύτερου υποσυνόλου ιδιοτήτων** (μεταξύ των διαθέσιμων) ως ένα **πρόβλημα αναζήτησης**.
  - Π.χ. **αρχική κατάσταση**: όλες οι υποψήφιες ιδιότητες.
  - **Τελεστής μετάβασης**: αφαίρεση μιας υποψήφιας ιδιότητας.
  - **Συνάρτηση αξιολόγησης κατάστασης**: ποσοστό ορθότητας που επιτυγχάνουμε με το υπο-σύνολο ιδιοτήτων της κατάστασης εκπαιδεύοντας στα δεδομένα εκπαίδευσης και αξιολογώντας σε διαφορετικά δεδομένα ανάπτυξης (ή «επικύρωσης»).
  - Αναζήτηση π.χ. με **αναρρίχηση λόφου**, **beam search**…
- Εναλλακτικά μπορούμε να χρησιμοποιήσουμε **μείωση διαστάσεων** μέσω **Singular Value Decomposition (SVD)**.
  - Βλ. μάθημα «Αριθμητική Γραμμική Άλγεβρα» (6ο εξάμηνο).
  - Απεικονίζει τα διανύσματα σε νέο χώρο λιγότερων διαστάσεων.
  - **Δεν επιλέγουμε** απλά ιδιότητες, **κατασκευάζουμε νέες** (λιγότερες) που **συνδυάζουν πληροφορίες** των αρχικών.

Θα **πρέπει να μελετήσετε τις διαφάνειες** αυτής της διάλεξης **και τις ασκήσεις μελέτης** της (βλ. έγγραφα μαθήματος στο e-class) **πριν από την επόμενη διάλεξη και πριν από το αντίστοιχο εργαστήριο**. **Γράψτε μόνοι σας** τις **λύσεις των ασκήσεων μελέτης** (ακόμα και αν δίνονται οι λύσεις). Επίσης, γράψτε μόνοι σας τους **ορισμούς**, **αλγορίθμους**, **παραδείγματα** εκτέλεσης των αλγορίθμων και λοιπούς **υπολογισμούς** των διαφανειών. Ανατρέξτε στη **βιβλιογραφία** για πρόσθετες εξηγήσεις και γνώσεις (ιδιαίτερα όσοι ενδιαφέρεστε ιδιαίτερα για την ΤΝ).

Βιβλιογραφία

- Russel & Norvig (4η έκδοση): ενότητες 19.1, 19.2, 19.3.3.
  - Θα καλύψουμε αρκετές άλλες ενότητες του κεφαλαίου 19 στις επόμενες διαλέξεις.
- Βλαχάβας κ.ά: ενότητα 8.2, κεφάλαιο 18 ως και ενότητα 18.2, υπο-ενότητα «Κριτήριο διαχωρισμού με βάση την εντροπία» της ενότητας 18.5.1.
- Aggarwal: σχετική ύλη υπάρχει στο κεφάλαιο 6.
- Poole & Mackworth: σχετική ύλη υπάρχει στο κεφάλαιο 7.

Βιβλιογραφία – συνέχεια
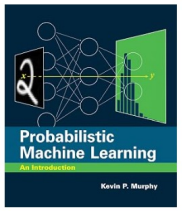
- Περισσότερα για το SVD θα βρείτε στην ενότητα 7.5 του βιβλίου «Probabilistic Machine Learning – An Introduction», του K.P. Murphy, MIT Press, 2022.
  - Υπάρχει στη βιβλιοθήκη του ΟΠΑ η προηγούμενη μορφή του βιβλίου, «Machine Learning – A Probabilistic Perspective», του ιδίου συγγραφέα, MIT Press, 2012 (βλ. ενότητα 12.2).