

Επεξεργασία Φυσικής Γλώσσας & Μηχανική Μάθηση

Εισαγωγή

Κάτια Κερμανίδου
kerman@ionio.gr

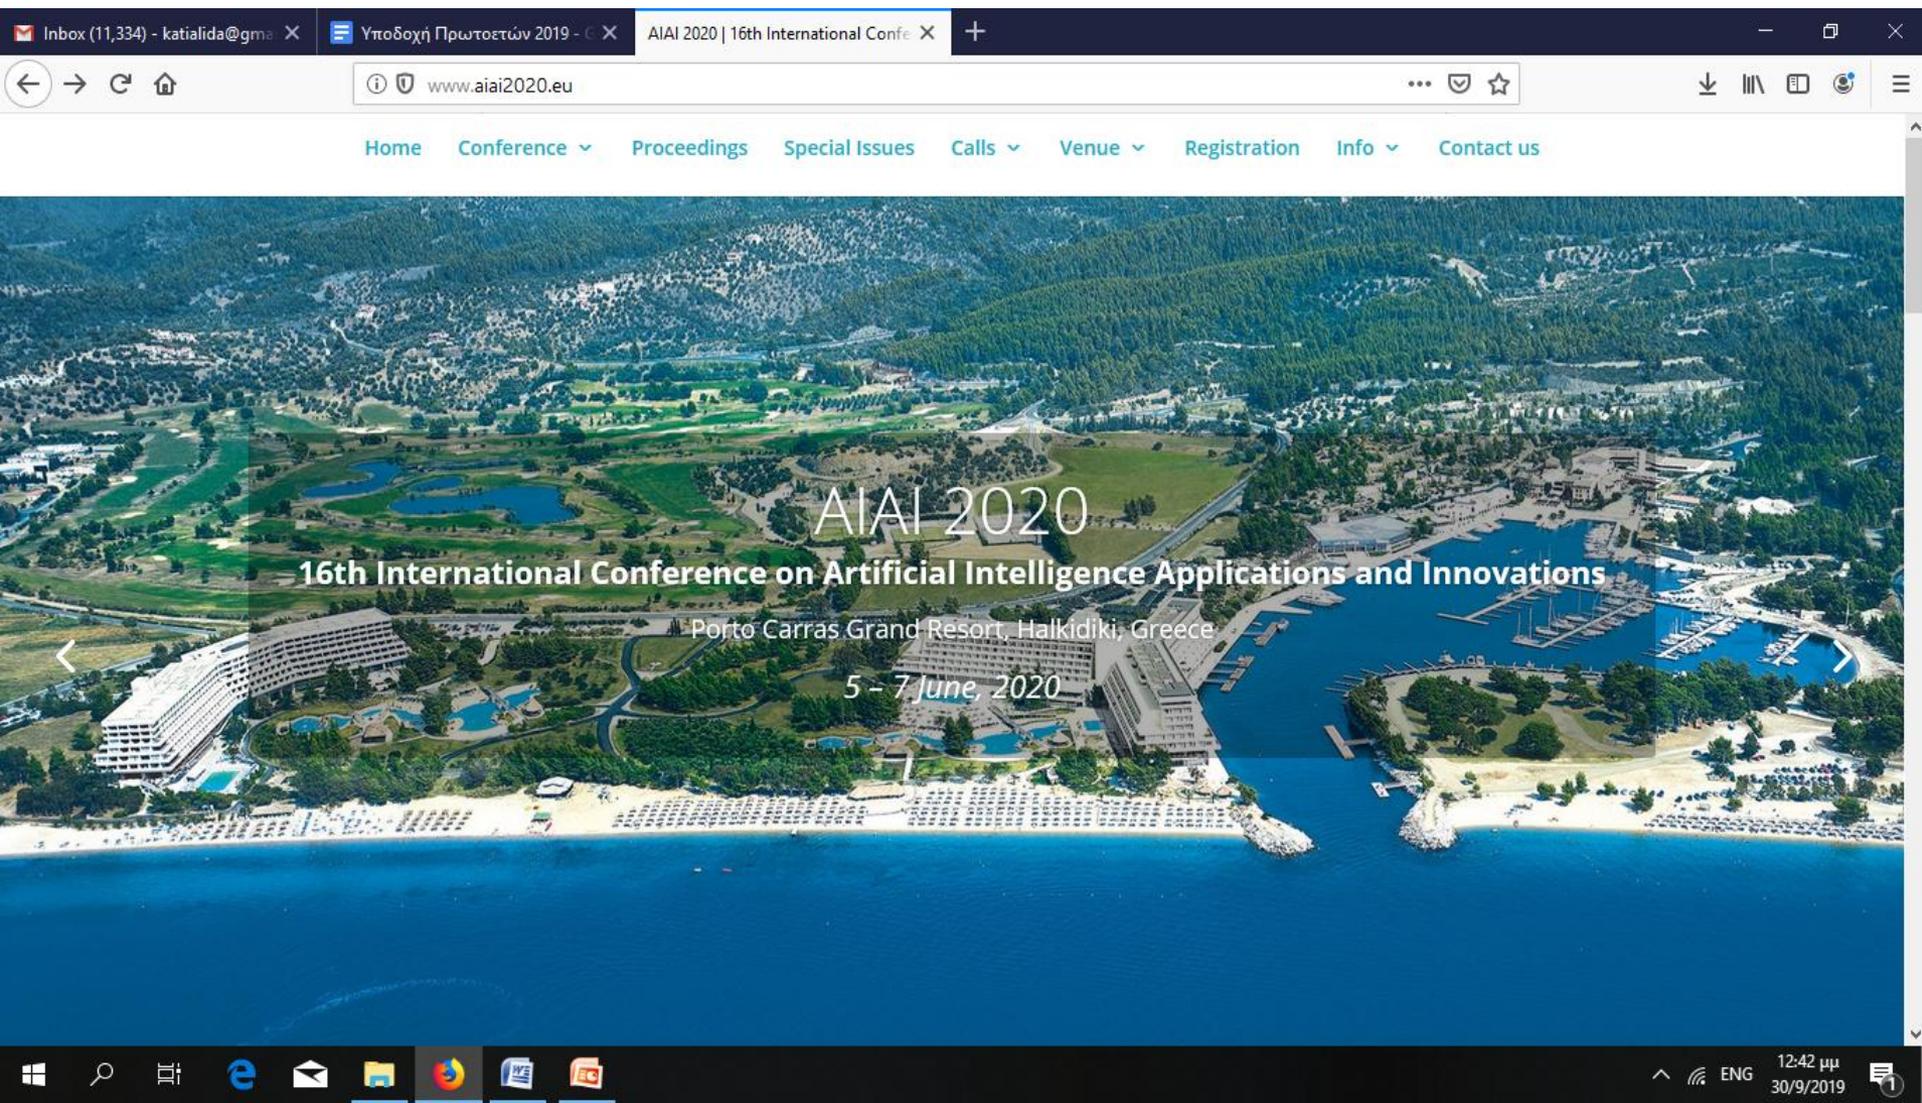
Χρονοδιάγραμμα μαθήματος

A/A	Εβδομάδα	Περιεχόμενο μαθήματος	Διδάσκων
1	23/10/19	Εισαγωγή	Κ. Κερμανίδου
2	30/10/19	Παρουσιάσεις φοιτητών - Βήμα I Πιθανοτικά Μοντέλα στην ΕΦΓ	Κ. Κερμανίδου
3	06/11/19	Reading Week	-
4	13/11/19	Παρουσιάσεις φοιτητών - Βήμα II Δέντρα απόφασης στην ΕΦΓ	Κ. Κερμανίδου
5	20/11/19	Μάθηση Βασισμένη στην Μνήμη στην ΕΦΓ Αναπαραστάσεις Λέξεων	Κ. Κερμανίδου
6	27/11/19	Μηχανική Μετάφραση	Κ. Κερμανίδου
7	04/12/19	RapidMiner και Εξόρυξη Γλωσσικής Πληροφορίας	Μ. Μαραγκουδάκης
8	11/12/19	Reading Week	-
9	18/12/19	Βαθιά Μάθηση στην ΕΦΓ	Κ. Κερμανίδου
10	08/01/20	Παρουσιάσεις φοιτητών - Βήμα III Εργαλεία Pythοn για Βαθιά Μάθηση στην ΕΦΓ I	Κ. Κερμανίδου Δ. Μουρατίδου
11	15/01/20	Εργαλεία Pythοn για Βαθιά Μάθηση στην ΕΦΓ II	Δ. Μουρατίδου

Διαδικαστικά

- Ομαδική εργασία
 - Ομάδες 3-4 ατόμων
 - Ο βαθμός της εργασίας πιάνει το 60% του τελικού βαθμού
 - Η καλύτερη εργασία πάει για δημοσίευση σε διεθνές συνέδριο (ακολουθούν προτάσεις για συνέδρια)
- Γραπτές εξετάσεις
 - Ο βαθμός του γραπτού πιάνει το 40% του τελικού βαθμού.

1^η Πρόταση για δημοσίευση: ΑΙΑΙ 2020 (Υποβολή: 29/2/2020)



The screenshot displays a web browser window with the URL www.aiai2020.eu. The browser's address bar shows the page title "AIAI 2020 | 16th International Conference on Artificial Intelligence Applications and Innovations". The navigation menu includes links for Home, Conference, Proceedings, Special Issues, Calls, Venue, Registration, Info, and Contact us. The main content area features a large aerial photograph of the Porto Carras Grand Resort, overlaid with the following text:

AIAI 2020
16th International Conference on Artificial Intelligence Applications and Innovations
Porto Carras Grand Resort, Halkidiki, Greece
5 - 7 June, 2020

The Windows taskbar at the bottom shows the system tray with the date 30/9/2019 and time 12:42 μμ, along with various application icons.

2^η Πρόταση για δημοσίευση: SMAP 2020 (Υποβολή: 31/3/2020)



The image shows a screenshot of a PDF document titled "SMAP 2020" displayed in a web browser. The browser's address bar shows the URL: http://hilab.di.ionio.gr/smap2020/wp-content/uploads/2019/07/SMAP_2020_CfP_v01.pdf. The document content includes the following text:

SMAP 20

**15th International Workshop on Semantic and Social Media
Adaptation and Personalization**

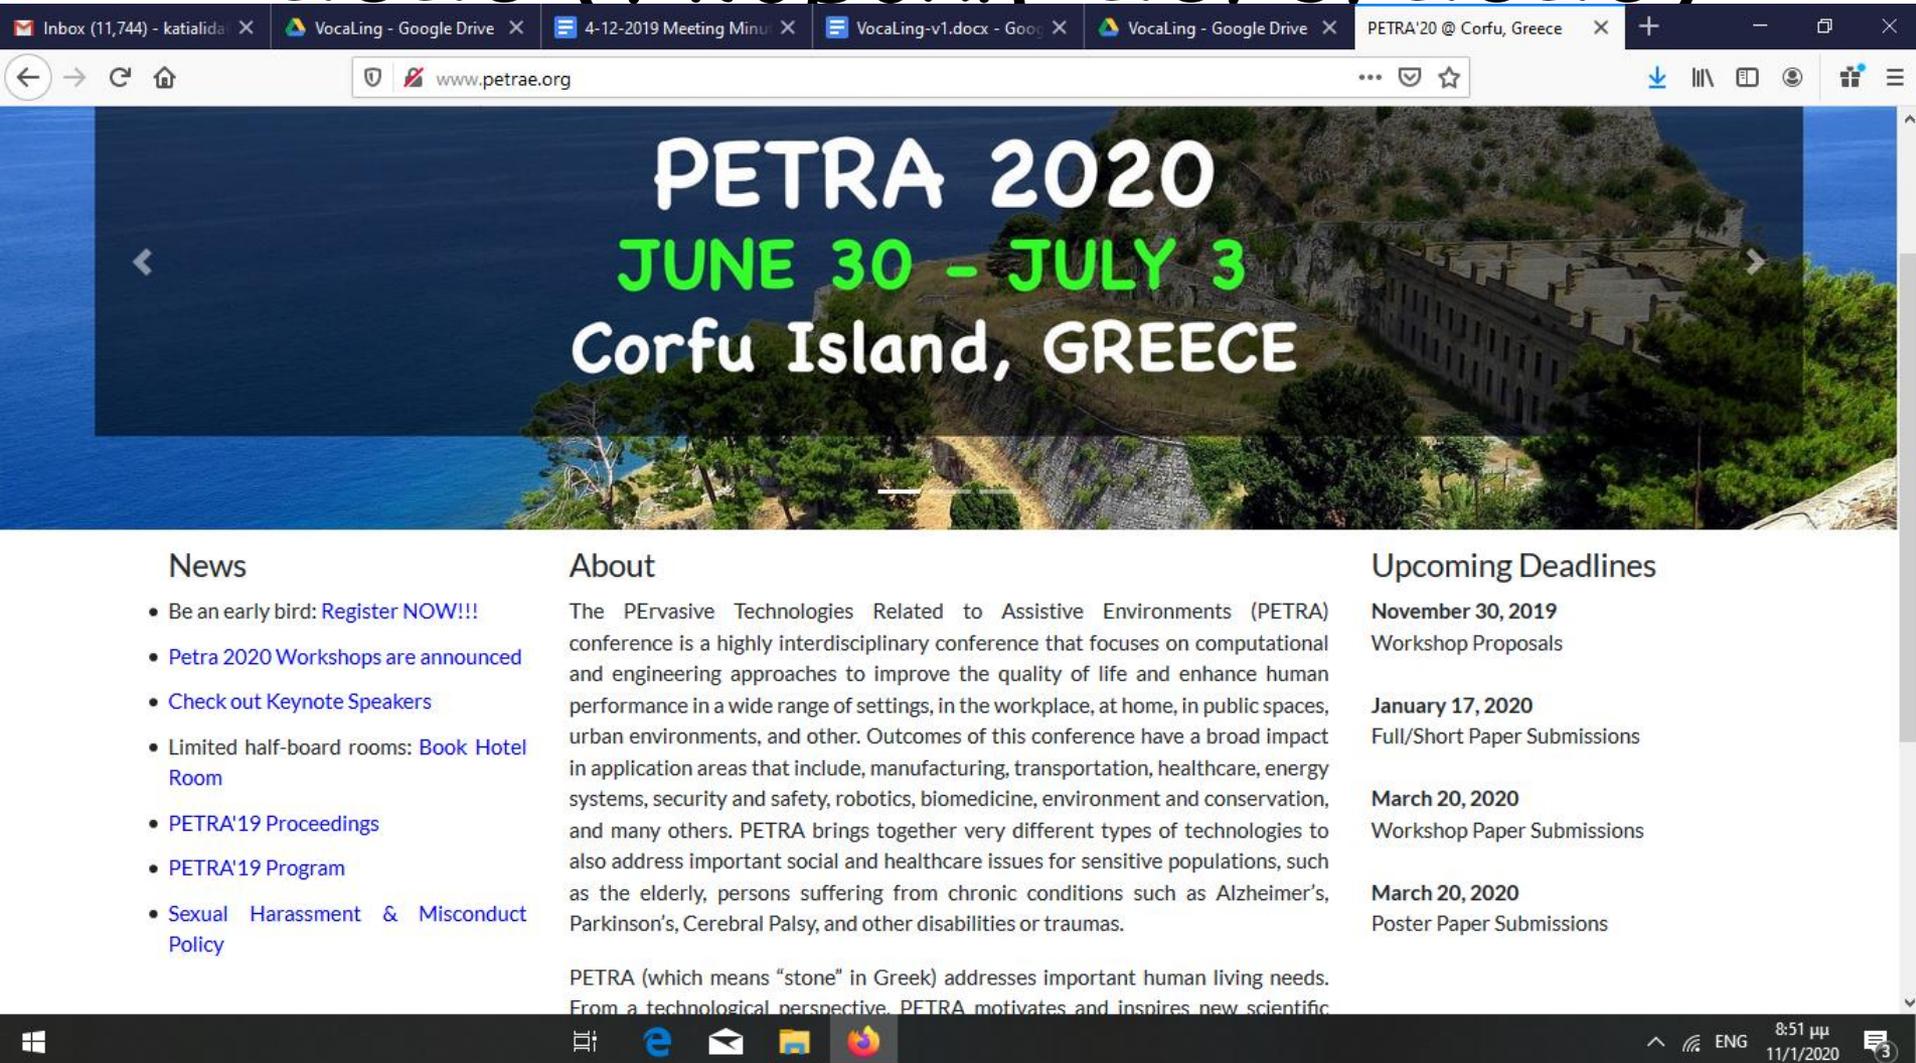
SMAP 2020

July 1-2, 2020, Zakynthos, Greece

<http://www.smap2020.eu>

The **Semantic and Social Media Adaptation and Personalization (SMAP) Initiative** was founded during the summer of 2006 in an effort to discuss the state-of-the-art, recent advances and future perspectives for semantic and social media adaptation. After 14 successful workshops -in Athens, London, Prague, San Sebastian, Limassol, Vigo, Luxembourg, Bayonne, Corfu, Trento, Thessaloniki, Bratislava, Zaragoza, and Larnaca, the SMAP workshop series has consolidated as a reference event in order to discuss about the newest advances in the field, including a 2-days single main track of high-quality scientific papers. The 15th SMAP workshop will be held in **Zakynthos, Greece** at **July 1st and 2nd, 2020** and it will be hosted by the **Ionian University** (<https://ionio.gr/en/>)

3^η Πρόταση για δημοσίευση: PETRA 2020 (Υποβολή: 20/3/2020)



The image shows a browser window displaying the website for the PETRA 2020 conference. The browser's address bar shows the URL www.petrae.org. The main banner features a scenic view of Corfu Island, Greece, with the text: **PETRA 2020**, **JUNE 30 - JULY 3**, and **Corfu Island, GREECE**. Below the banner, there are three columns of content: 'News', 'About', and 'Upcoming Deadlines'. The 'News' column lists several items, including a call to register and announcements for workshops and speakers. The 'About' column provides a detailed description of the conference's focus on assistive environments. The 'Upcoming Deadlines' column lists submission dates for workshop proposals, full/short paper submissions, and poster submissions.

News

- Be an early bird: [Register NOW!!!](#)
- [Petra 2020 Workshops are announced](#)
- [Check out Keynote Speakers](#)
- Limited half-board rooms: [Book Hotel Room](#)
- [PETRA'19 Proceedings](#)
- [PETRA'19 Program](#)
- [Sexual Harassment & Misconduct Policy](#)

About

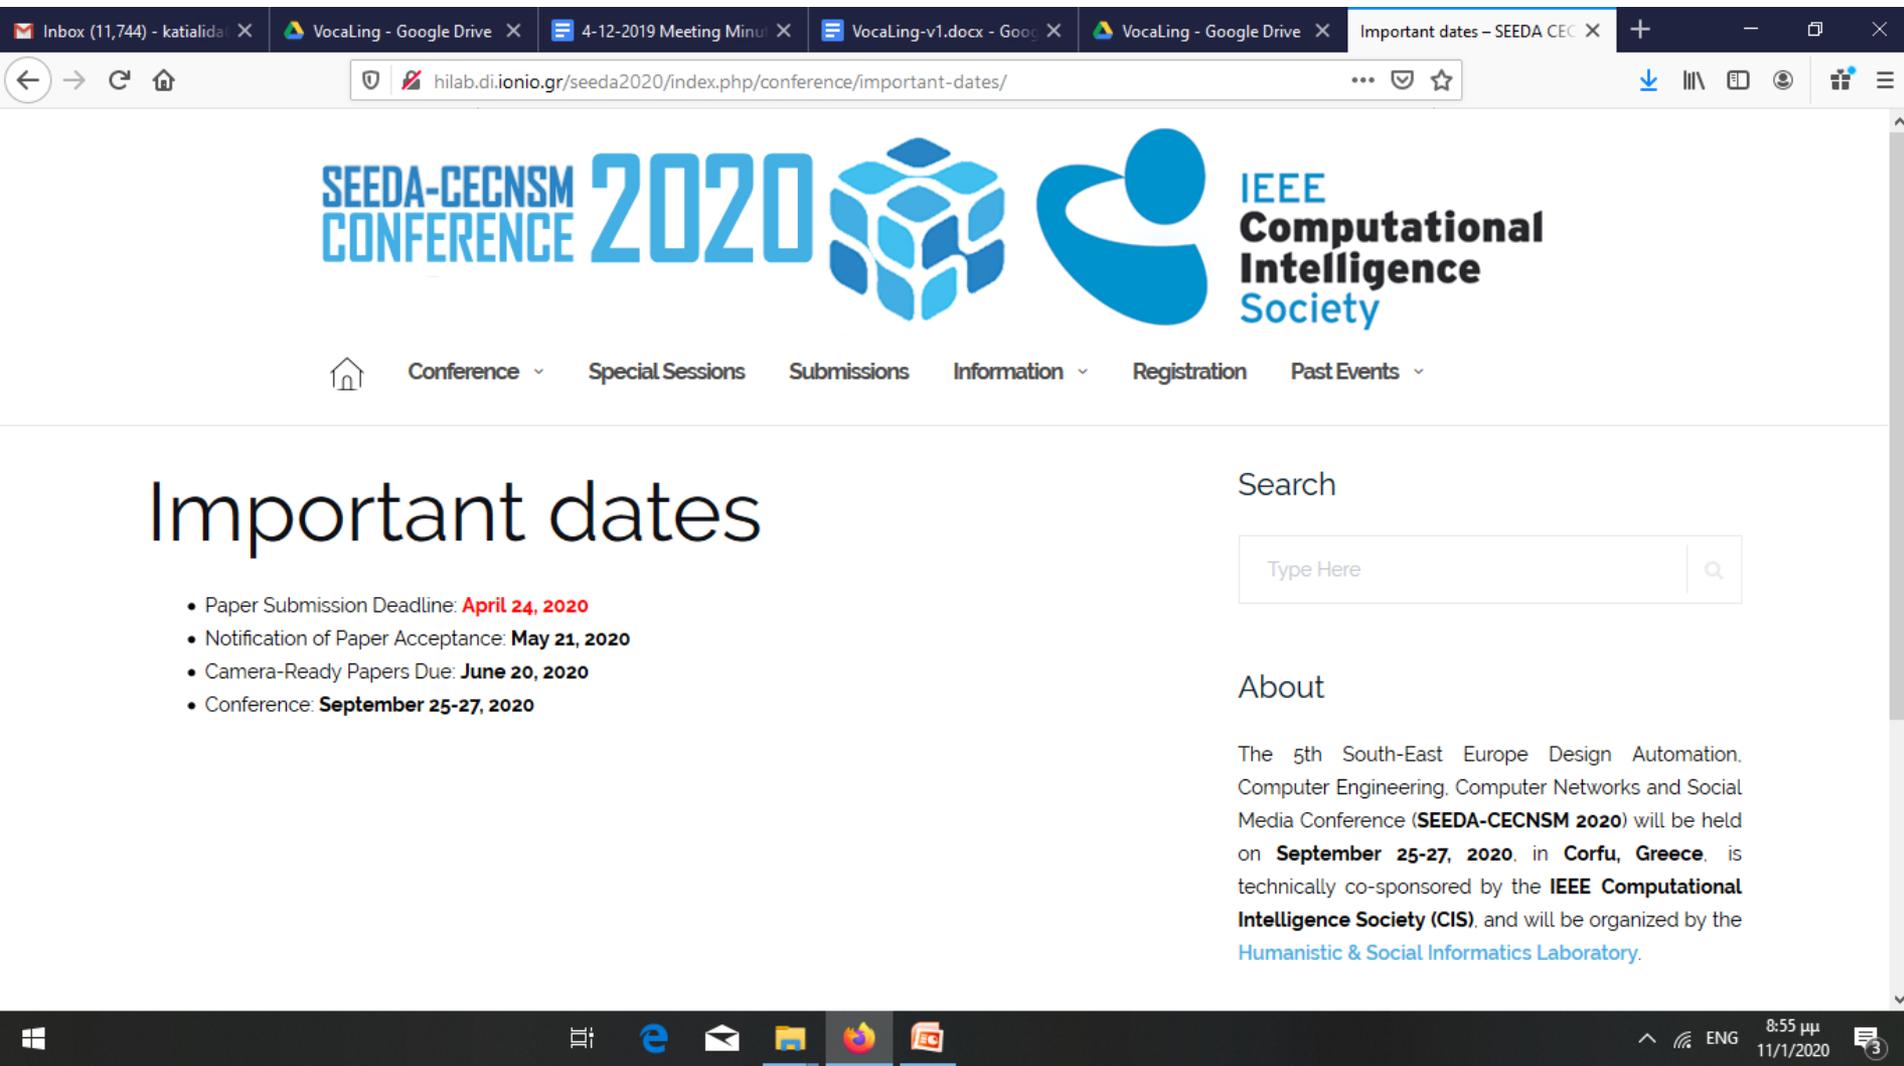
The PErvasive Technologies Related to Assistive Environments (PETRA) conference is a highly interdisciplinary conference that focuses on computational and engineering approaches to improve the quality of life and enhance human performance in a wide range of settings, in the workplace, at home, in public spaces, urban environments, and other. Outcomes of this conference have a broad impact in application areas that include, manufacturing, transportation, healthcare, energy systems, security and safety, robotics, biomedicine, environment and conservation, and many others. PETRA brings together very different types of technologies to also address important social and healthcare issues for sensitive populations, such as the elderly, persons suffering from chronic conditions such as Alzheimer's, Parkinson's, Cerebral Palsy, and other disabilities or traumas.

PETRA (which means "stone" in Greek) addresses important human living needs. From a technological perspective, PETRA motivates and inspires new scientific

Upcoming Deadlines

- November 30, 2019**
Workshop Proposals
- January 17, 2020**
Full/Short Paper Submissions
- March 20, 2020**
Workshop Paper Submissions
- March 20, 2020**
Poster Paper Submissions

4^η Πρόταση για δημοσίευση: SEEDA 2020 (Υποβολή: 24/4/2020)



The screenshot shows a web browser window with several tabs open. The active tab is titled "Important dates - SEEDA CECNSM 2020" and the address bar shows the URL "hilab.di.ionio.gr/seeda2020/index.php/conference/important-dates/". The website header features the "SEEDA-CECNSM CONFERENCE 2020" logo, a blue cube icon, and the "IEEE Computational Intelligence Society" logo. Below the header is a navigation menu with links for "Conference", "Special Sessions", "Submissions", "Information", "Registration", and "Past Events". The main content area is titled "Important dates" and lists four key dates: "Paper Submission Deadline: April 24, 2020", "Notification of Paper Acceptance: May 21, 2020", "Camera-Ready Papers Due: June 20, 2020", and "Conference: September 25-27, 2020". To the right of the main content is a search bar with the placeholder text "Type Here" and a search icon. Below the search bar is an "About" section with the following text: "The 5th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM 2020) will be held on September 25-27, 2020, in Corfu, Greece, is technically co-sponsored by the IEEE Computational Intelligence Society (CIS), and will be organized by the Humanistic & Social Informatics Laboratory." The Windows taskbar is visible at the bottom of the screen, showing the time as 8:55 μμ on 11/1/2020.

Important dates

- Paper Submission Deadline: **April 24, 2020**
- Notification of Paper Acceptance: **May 21, 2020**
- Camera-Ready Papers Due: **June 20, 2020**
- Conference: **September 25-27, 2020**

Search

Type Here

About

The 5th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (**SEEDA-CECNSM 2020**) will be held on **September 25-27, 2020**, in **Corfu, Greece**, is technically co-sponsored by the **IEEE Computational Intelligence Society (CIS)**, and will be organized by the [Humanistic & Social Informatics Laboratory](#).

Υλικό (καλύψτε τυχόν κενά!)

- Το μάθημα προϋποθέτει
 - βασική εξοικείωση με έννοιες, και τεχνικές Επεξεργασίας Φυσικής Γλώσσας
 - <https://e-class.ionio.gr/courses/DCS153/>
 - https://www.cs.vassar.edu/~cs366/docs/Manning_Schuetze_StatisticalNLP.pdf
 - <https://mitpress.mit.edu/books/introduction-natural-language-processing>
 - βασική εξοικείωση με έννοιες και αλγορίθμους Μηχανικής Μάθησης
 - <http://ciml.info/>
 - <http://profsite.um.ac.ir/~monsefi/machine-learning/pdf/Machine-Learning-Tom-Mitchell.pdf>
 - <ftp://ftp.ingv.it/pub/manuela.sbarra/Data%20Mining%20Practical%20Machine%20Learning%20Tools%20and%20Techniques%20-%20WEKA.pdf>
 - http://alex.smola.org/drafts/thebook.pdf?utm_source=twitterfeed&utm_medium=twitter
 - <https://www.amazon.com/Introduction-Deep-Learning-MIT-Press/dp/0262039516>

Περισσότερο υλικό

- https://www.researchgate.net/publication/228686410_Machine_learning_for_natural_language_processing/link/0912f5126527f24567000000/download
- <http://www.ai.mit.edu/courses/6.891-nlp/>
- <https://www.scss.tcd.ie/kevin.koidl/cs4062/>
- <http://u.cs.biu.ac.il/~89-680/>

Μηχανική Μάθηση (Machine Learning)

- Η δημιουργία μοντέλων ή προτύπων από ένα σύνολο δεδομένων, από ένα υπολογιστικό σύστημα, ονομάζεται μηχανική μάθηση.
- Simon (1983)
 - "η μάθηση σηματοδοτεί προσαρμοστικές αλλαγές σε ένα σύστημα με την έννοια ότι αυτές του επιτρέπουν να κάνει την ίδια εργασία, ή εργασίες της ίδιας κατηγορίας, πιο αποδοτικά και αποτελεσματικά την επόμενη φορά".
- Carbonell (1987)
 - "... η μελέτη υπολογιστικών μεθόδων για την απόκτηση νέας γνώσης, νέων δεξιοτήτων και νέων τρόπων οργάνωσης της υπάρχουσας γνώσης".
- Mitchell (1997)
 - "Ένα πρόγραμμα υπολογιστή θεωρείται ότι μαθαίνει από την εμπειρία E σε σχέση με μια κατηγορία εργασιών T και μια μετρική απόδοσης P , αν η απόδοση του σε εργασίες της T , όπως μετριοούνται από την P , βελτιώνονται με την εμπειρία E ".
 - Task T : playing chess
 - Performance measure P : percent of games won against opponents
 - Training Experience E : playing practice games against itself
- Witten & Frank (2000),
 - Κάτι μαθαίνει όταν αλλάζει τη συμπεριφορά του κατά τέτοιο τρόπο ώστε να αποδίδει καλύτερα στο μέλλον"

Γιατί Μηχανική Μάθηση;

- Αλγόριθμοι για την εξαγωγή δομικών περιγραφών (προτύπων) από δεδομένα
- Οι περιγραφές αυτές
 - Μπορούν να χρησιμοποιηθούν για την πρόβλεψη (prediction) ενός αποτελέσματος σε καινούρια (άγνωστα) δεδομένα
 - μπορούν να χρησιμοποιηθούν για την ερμηνεία του τρόπου με τον οποίο επιλέγεται η πρόβλεψη
- Αντί να απαιτείται η συγγραφή κώδικα για να αναγνωριστούν αυτά τα πρότυπα **χειρωνακτικά**, οι αλγόριθμοι μάθησης τρέχουν πάνω στα δεδομένα και εξάγουν τα πρότυπα αυτά **αυτόματα**.

Παραδοσιακός Προγραμματισμός - Μηχανική Μάθηση

Traditional Programming



Machine Learning



Η ΜΜ σήμερα

- Μεγάλη εξέλιξη σε αλγορίθμους
- Διάθεση μεγάλου όγκου δεδομένων
- Μεγάλη διαθέσιμη υπολογιστική ισχύς
- Πληθώρα εφαρμογών

Είδη Μηχανικής Μάθησης

- Επιβλεπόμενη Μάθηση
 - Επαγωγή (induction)
- Μη επιβλεπόμενη Μάθηση

Επιβλεπόμενη Μάθηση:

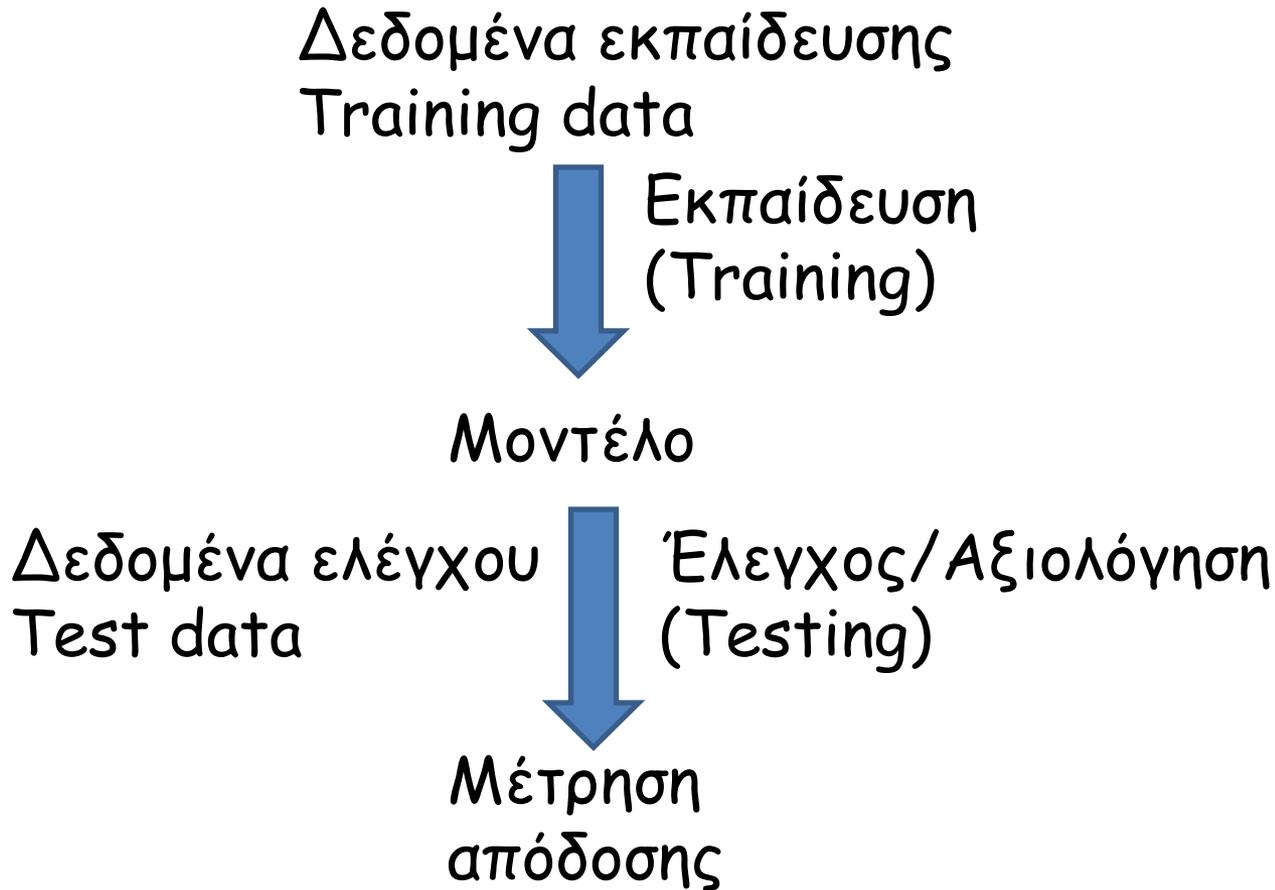
Επαγωγή (Induction)

- Έννοια (concept) είναι αυτό που καλείται ο αλγόριθμος μάθησης να μάθει
- Επαγωγή είναι η διαδικασία δημιουργίας ενός **γενικευμένου** μοντέλου περιγραφής ή ορισμού μιας έννοιας από ένα σύνολο **ειδικών** παραδειγμάτων της έννοιας
- Προτάθηκε από τον Αριστοτέλη σαν την αντίστροφη διαδικασία από τον συλλογισμό
- Το παράδειγμα του Αρειανού
- Πιο μαθηματικοποιημένα
 - Ένα παράδειγμα-example (στιγμιότυπο-instance ή παρατήρηση-observation ή δεδομένο-data) είναι μια δυάδα $(x, f(x))$, όπου f είναι μια συνάρτηση, το x είναι η είσοδος, και το $f(x)$ η έξοδος της συνάρτησης όταν εφαρμόζεται στο x
 - Επαγωγή: Δοθέντος ενός συνόλου παραδειγμάτων μιας συνάρτησης f , βρες μια συνάρτηση h που προσεγγίζει την f
 - Η συνάρτηση h ονομάζεται υπόθεση και αποτελεί το γενικευμένο μοντέλο που περιγράφει τα παραδείγματα.

Επιβλεπόμενη Μάθηση: Έννοιες & Είδη

- Το σύστημα μάθησης καλείται να μάθει επαγωγικά την **συνάρτηση στόχο** (target function) που περιγράφει τα δεδομένα
- Η τιμή της συνάρτησης-στόχου ονομάζεται και **εξαρτημένη μεταβλητή** ενώ οι υπόλοιπες μεταβλητές που αναπαριστούν το παράδειγμα ονομάζονται **ανεξάρτητες μεταβλητές**.
- Κατά την εκπαίδευση η τιμή της συνάρτησης στόχου των παραδειγμάτων εκπαίδευσης είναι γνωστή, και καθοδηγεί τη διαδικασία μάθησης
- Κατά τον έλεγχο, η απόδοση μετράται σε καινούρια άγνωστα παραδείγματα (ελέγχου), για τα οποία ο αλγόριθμος δεν γνωρίζει την τιμή της συνάρτησης στόχου
- Δύο μορφές επιβλεπόμενης μάθησης
 - Ταξινόμηση (ή Κατηγοριοποίηση - Classification)
 - Η συνάρτηση-στόχος παίρνει διακριτές τιμές
 - Παλινδρόμηση (ή Παρεμβολή - Regression)
 - Η συνάρτηση-στόχος παίρνει αριθμητικές τιμές

Επιβλεπόμενη Μάθηση: Φάσεις



Επιβλεπόμενη Μάθηση: Εκπαίδευση, Επικύρωση και Αξιολόγηση

- Ένας αλγόριθμος ταξινόμησης (classifier) επάγει ένα πρώτο μοντέλο από τα δεδομένα εκπαίδευσης
- Οι παράμετροι του αλγορίθμου συντονίζονται με επαναληπτικά πειράματα πάνω σε ένα σώμα επικύρωσης (validation set)
- Η απόδοση του αλγορίθμου αξιολογείται με εφαρμογή του πάνω στο σετ αξιολόγησης (test set)
- Τα σετ εκπαίδευσης και αξιολόγησης πρέπει να είναι τελείως διαφορετικά

Επιβλεπόμενη Μάθηση: Μέτρα Αξιολόγησης

- Πίνακας σύγχυσης (confusion matrix)

		Predicted class	
		Yes	No
Actual class	Yes	True positive	False negative
	No	False positive	True negative

- True Positive (TP): Ένα παράδειγμα ελέγχου ταξινομείται σωστά ως θετικό
- True Negative (TN): Ένα παράδειγμα ελέγχου ταξινομείται σωστά ως αρνητικό
- False Positive (FP): Ένα παράδειγμα ελέγχου ταξινομείται λάθος ως θετικό
- False Negative (FN): Ένα παράδειγμα ελέγχου ταξινομείται λάθος ως αρνητικό

Επιβλεπόμενη Μάθηση: Μέτρα αξιολόγησης

- Ορθότητα (Accuracy)
 - $Accuracy = (TP+TN) / (TP+TN+FP+FN)$
- Ακρίβεια (Precision)
 - $Precision = TP / (TP+FP)$
- Ανάκληση (Recall)
 - $Recall = TP / (TP+FN)$
- Μέτρο f (f-measure)
 - $F = (1+\beta^2) \times (Precision \times Recall) / (\beta^2 \times Precision + Recall)$
 - Το β είναι θετικός πραγματικός αριθμός
 - Στην ανάκληση αποδίδεται β φορές περισσότερη σημασία από ότι στην ακρίβεια)
 - Αν $\beta=1$, τότε $F = 2 \times Precision \times Recall / (Precision + Recall)$

Επιβλεπόμενη Μάθηση: Αξιολόγηση σε περισσότερες από δυο τιμές εξόδου

System	A	B	C	D	
	32	1	1	6	A
	3	25	10	2	B
	0	5	30	5	C
	4	10	6	20	D
					Expert

System	A	B	C	D	
	32	1	1	6	A
	3	25	10	2	B
	0	5	30	5	C
	4	10	6	20	D
					Expert

E.g: for class A → TP FP FN TN

Επιβλεπόμενη Μάθηση: Αξιολόγηση με μέσες τιμές

- Micro-averaging

$$\pi^{\mu} = \frac{\sum_{i=1}^{|\mathcal{C}|} TP_i}{\sum_{i=1}^{|\mathcal{C}|} (TP_i + FP_i)}$$

$$\rho^{\mu} = \frac{\sum_{i=1}^{|\mathcal{C}|} TP_i}{\sum_{i=1}^{|\mathcal{C}|} (TP_i + FN_i)}$$

- Macro-averaging

$$\pi^M = \frac{\sum_{i=1}^{|\mathcal{C}|} \pi_i}{|\mathcal{C}|}$$

$$\rho^M = \frac{\sum_{i=1}^{|\mathcal{C}|} \rho_i}{|\mathcal{C}|}$$

- όπου τα π_i και ρ_i είναι τα σκορ ανα τιμή εξόδου

Επιβλεπόμενη Μάθηση: Αξιολόγηση με μέσες τιμές

Category	Sport		Politics		World	
Judgment: Expert and System	E	S	E	S	E	S
"Brazil beat Venezuela"	T	F	F	F	F	T
"US defeated Afghanistan"	F	T	T	T	T	F
"Elections in Wicklow"	F	F	T	T	F	F
"Elections in Peru"	F	F	F	T	T	T
Precision (local):	$\pi = 0$		$\pi = 0.67$		$\pi = 0.5$	
Recall (local):	$\rho = 0$		$\rho = 1$		$\rho = 0.5$	
$\pi^M =$			$\frac{0+2+1}{0+2+1+1+1+1} = .5$			
$\pi^M =$			$\frac{0+.67+.5}{3} = .39$			

Μέτρα απεικόνισης - ROC curve

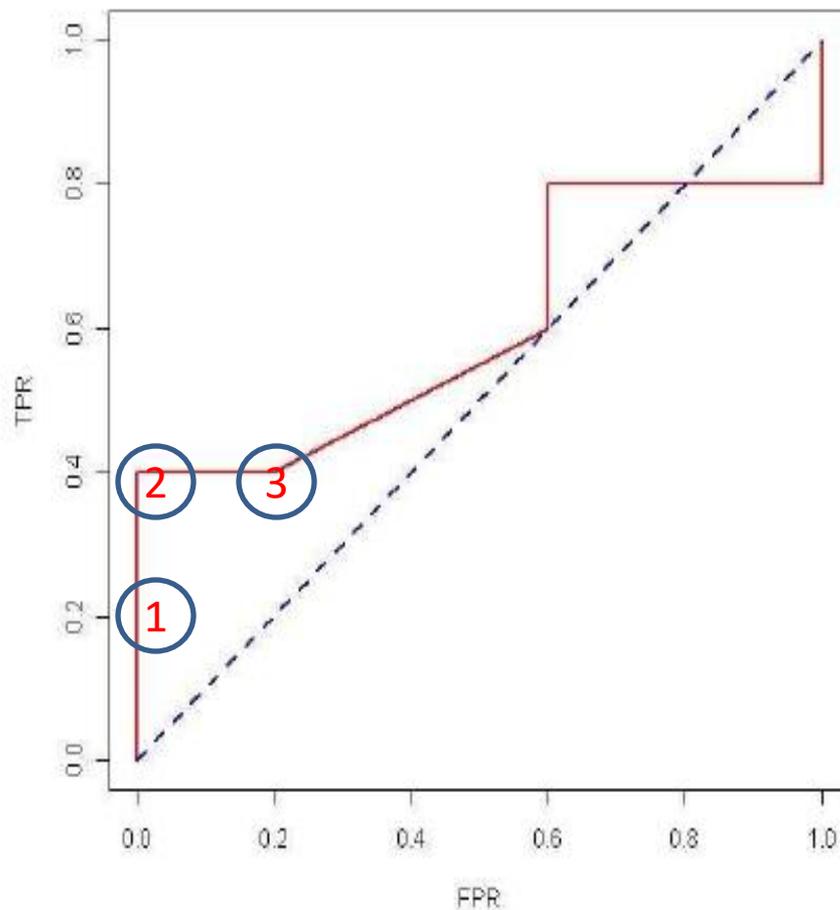
- Εφαρμόζω έναν αλγόριθμο ταξινόμησης που να υπολογίζει τη εκ των υστέρων πιθανότητα (posterior probability) κάθε παραδείγματος ελέγχου να είναι θετικό ($P(+|\text{παραδείγμα})$), όπως ο Naïve Bayes. Ταξινομώ αυτές τις πιθανότητες από την μεγαλύτερη στην μικρότερη.

Instance	$P(+ A)$	True Class
1	0.95	+
2	0.93	+
3	0.87	-
4	0.85	-
5	0.85	-
6	0.85	+
7	0.76	-
8	0.53	+
9	0.43	-
10	0.25	+

- Θέτω κατώφλι σε κάθε μοναδική τιμή του $P(+|\text{παραδείγμα})$.
- Υπολογίζω TP, FP, TN, FN σε κάθε κατώφλι.
- Αξονας x: FP rate ($FPR = FP/(FP+TN)$)
- Αξονας y: TP rate ($TPR = TP/(TP+FN)$)

ROC curve - Παράδειγμα

Instance	P(+)	True class	FPR	TPR
1	0.95	+	0	1/5
2	0.93	+	0	2/5
3	0.87	-	1/5	2/5
4	0.85	-		
5	0.85	-		
6	0.85	+	3/5	3/5
7	0.76	-	4/5	3/5
8	0.53	+	4/5	4/5
9	0.43	-	1	4/5
10	0.25	+	1	1



Σημείο 1: TP=1, TN=5, FP=0, FN=4

$$FPR = FP / (FP + TN) = 0 / (0 + 5)$$

$$TPR = TP / (TP + FN) = 1 / (1 + 4)$$

Σημείο 2: TP=2, TN=5, FP=0, FN=3

$$FPR = FP / (FP + TN) = 0 / (0 + 5)$$

$$TPR = TP / (TP + FN) = 2 / (2 + 3)$$

Σημείο 3: TP=2, TN=4, FP=1, FN=3

$$FPR = FP / (FP + TN) = 1 / (1 + 4)$$

$$TPR = TP / (TP + FN) = 2 / (2 + 3)$$

Γιατί Επεξεργασία Φυσικής Γλώσσας;

- Η ψηφιακή πληροφορία κυρίως εμφανίζεται σε μορφή κειμένου
 - Διαδίκτυο: Wikipedia, κοινωνικά δίκτυα
 - Νέα, έρευνα, νομικά κείμενα, πατέντες
 - Αναφορές επιχειρήσεων
 - Δημόσια έγγραφα
 - ...
- Ο υπολογιστής δεν μπορεί να αντιμετωπίσει το αδόμητο κείμενο
 - Πρέπει να μετατραπεί το κείμενο σε ονοματικά/αριθμητικά χαρακτηριστικά

Επιβλεπόμενη Μάθηση: Σχεδίαση συστήματος

- Εμπειρία (Δεδομένα εκπαίδευσης)
 - Πώς θα έχει το σύστημα πρόσβαση σε παραδείγματα εκπαίδευσης;
 - Σώματα κειμένων
- Συνάρτηση-στόχος
 - Ποια είναι η έννοια που θέλω το σύστημα να μάθει;
 - Στην ΕΦΓ η συν/ση στόχος καθορίζεται από την επισημείωση των παραδειγμάτων εκπαίδευσης
- Αναπαράσταση
 - Πώς θα αναπαρασταθούν οι έννοιες προς μάθηση;
 - Πρέπει να είναι ενιαία η αναπαράσταση
 - Πχ δυαδικά διανύσματα; Μοντέλο bag-of-words;
- Επαγωγή
 - Ποιος αλγόριθμος θα χρησιμοποιηθεί για την μάθηση των επιθυμητών εννοιών;
 - Παραδοχή: Μια προσέγγιση της συνάρτησης στόχου που αποδίδει καλά πάνω σε ένα επαρκώς μεγάλο σετ παραδειγμάτων θα αποδίδει καλά και σε καινούρια παραδείγματα

Μοντέλο Bag of words

- Ένα κείμενο είναι μια σακούλα από λέξεις
- Δεν ενδιαφέρει η διάταξη των λέξεων
- Συνήθως δεν ενδιαφέρει η συχνότητα εμφάνισης των λέξεων
- Δεν υπάρχει καμία μορφοσυντακτική πληροφορία σχετικά με την δομή των προτάσεων του κειμένου
- Δεν υπάρχει καμία σημασιολογική πληροφορία σχετικά με τις λέξεις και τις προτάσεις του κειμένου
- Αν τα διανύσματα αναπαράστασης δυο κειμένων είναι κοντά, τότε τα κείμενα είναι όμοια. Όσο μεγαλύτερη απόσταση έχουν, τόσο πιο ανόμοια είναι.
- Οπότε το «I love the film» έχει ίδια απόσταση με το «I hate the film» και με το «I like the film»

Επιβλεπόμενη Μάθηση και ΕΦΓ: Υπερπροσαρμογή

- Υπερπροσαρμογή (Overfitting)
 - Ανικανότητα του ταξινομητή να γενικεύσει σε καινούρια δεδομένα
 - Ο ταξινομητής αποδίδει καλά στα δεδομένα εκπαίδευσης, αλλά όχι καλά σε άγνωστα παραδείγματα
 - Απαιτείται μεγάλη ποσότητα δεδομένων εκπαίδευσης για να αντιμετωπιστεί
 - ΕΦΓ: σε πολλές εφαρμογές υπάρχει ανεπάρκεια επισημειωμένων δεδομένων
 - K-fold cross validation
 - όσο πιο λεπτομερής η αναπαράσταση των δεδομένων, τόσο περισσότερα δεδομένα χρειάζονται για αποδοτική μάθηση της συνάρτησης στόχου
 - Όσο πιο λεπτομερής η αναπαράσταση, τόσο μεγαλύτερος ο κίνδυνος υπερπροσαρμογής
 - Όσο λιγότερο λεπτομερής η αναπαράσταση, τόσο μεγαλύτερος ο κίνδυνος να χαθούν κριτήρια που είναι σημαντικά για την ταξινόμηση

Το πρόβλημα της διαστατικότητας

- Ο χώρος του μικρόκοσμου που θέλω να κάνω εξόρυξη είναι τόσων διαστάσεων όσο είναι και το πλήθος των ανεξάρτητων μεταβλητών μου
- Όσο αυξάνουν οι διαστάσεις, τα δεδομένα γίνονται ολοένα και πιο αραιά στον πολυδιάστατο χώρο
- Η απόσταση και η πυκνότητα μεταξύ των σημείων που είναι κρίσιμες για την ομαδοποίηση ή την ανίχνευση εξαιρέσεων χάνουν τη σημασία τους

Μείωση της διαστατικότητας

- Μείωση χρόνου και χώρου για τους αλγόριθμους εξόρυξης δεδομένων
- Επιτρέπει την οπτικοποίηση των δεδομένων
- Βοηθάει στην αφαίρεση άσχετων χαρακτηριστικών ή στη μείωση του θορύβου
- Εμπειρικός κανόνας: η υπερπροσαρμογή αποφεύγεται εάν ο αριθμός των παραδειγμάτων εκπαίδευσης είναι 50-100 φορές μεγαλύτερος του αριθμού των χαρακτηριστικών
- Τεχνικές
 - Principle Component Analysis (PCA)
 - Singular Value Decomposition (SVD)
 - Άλλες

Text Mining

- Μη δομημένα δεδομένα (unstructured data) είναι αυτά που δεν ακολουθούν κάποιο προκαθορισμένο μοντέλο
 - Βάση δεδομένων - δομημένα δεδομένα
 - Κείμενο - μη δομημένα δεδομένα
- Εξόρυξη δεδομένων (Data Mining)
 - Η εξαγωγή πληροφορίας από δομημένα δεδομένα
 - Επισκέψεις χρηστών σε ιστοσελίδα
 - Δείκτες χρηματιστηριακών τιμών
- Εξόρυξη κειμενικών δεδομένων (Text Mining)
 - Η εξαγωγή πληροφορίας από κειμενικά δεδομένα
 - Συνήθως με στόχο την εξαγωγή πληροφορίας υψηλού επιπέδου (θέμα, συναίσθημα, προφίλ συγγραφέα κλπ)

ΕΦΓ: Βασικές έννοιες

- Type
 - Κάθε διαφορετική «λέξη»
 - Στην ΜΜ συχνά χρησιμοποιούνται σαν χαρακτηριστικά μάθησης
- Token
 - Κάθε «λέξη»
 - Λέξεις, σύμβολα, ακρωνύμια, συντομογραφίες, σημεία στίξης
- Στην παρακάτω πρόταση πόσα types και πόσα tokens υπάρχουν;
 - "One could, for instance, use a set to store all types in a document, and a list to store all tokens."

Το κείμενο ως διάνυσμα χαρακτηριστικών-τιμών (feature value vectors)

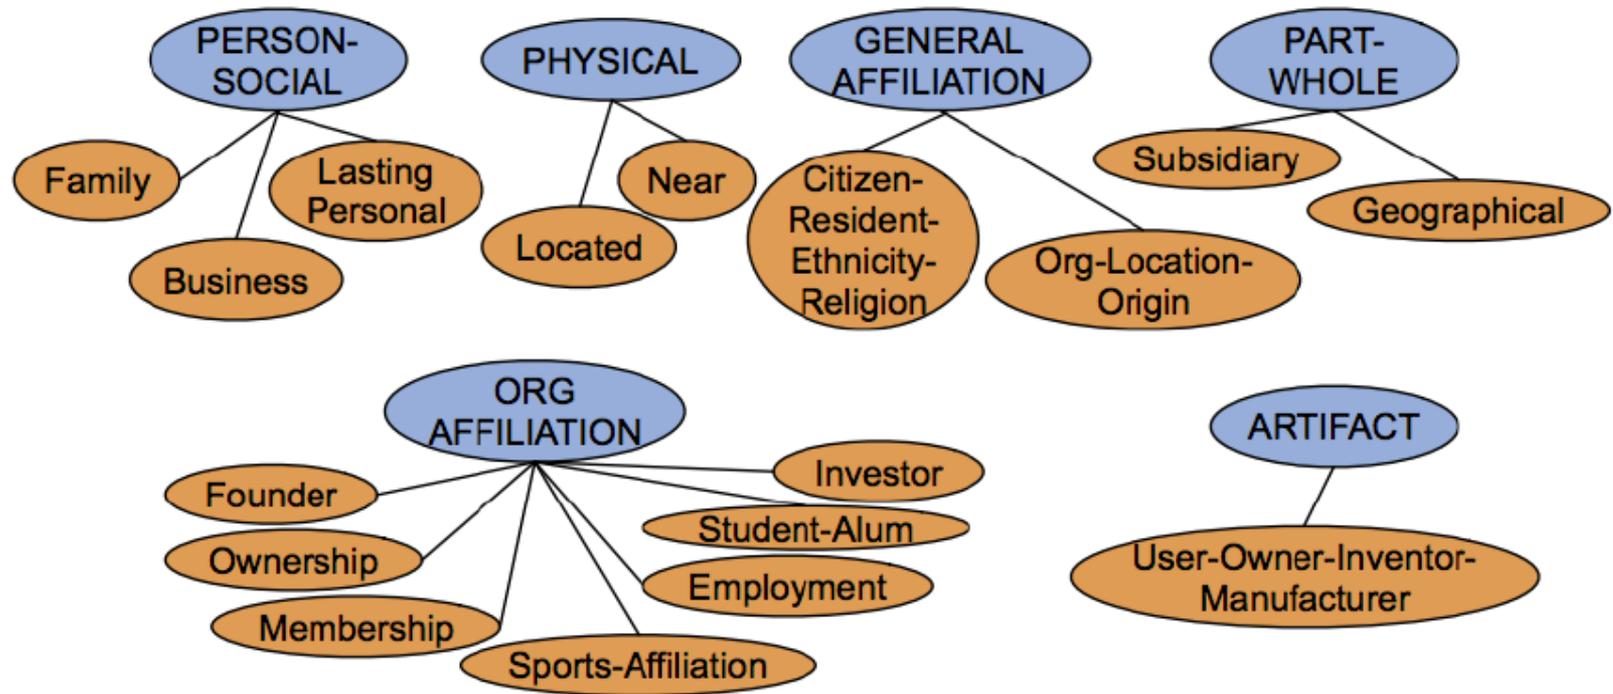
- Επιλέγεται ένα σετ από types του κειμένου σαν σετ χαρακτηριστικών
 - Τα χαρακτηριστικά μπορεί να είναι
 - καταλήξεις
 - ν-γραμμα (βάσει γραμματικών ή βάσει συχνότητας εμφάνισης)
 - φράσεις ('White House', 'Barack Obama')
 - μεταδεδομένα των types
 - αποστάσεις μεταξύ types
 - συντακτικές συσχετίσεις μεταξύ types
 - σημασιολογικές συσχετίσεις μεταξύ types
- Κάθε κείμενο αναπαρίσταται σαν διάνυσμα με τιμές (βάρη) σε αυτά τα χαρακτηριστικά
- Τα βάρη καθορίζουν πόσο το συγκεκριμένο χαρακτηριστικό συνεισφέρει στην σημασιολογική αναπαράσταση του κειμένου
 - δυαδικά (παρουσία/απουσία του type στο κείμενο)
 - συχνότητα εμφάνισης
 - tfidf

Το κείμενο ως διάνυσμα χαρακτηριστικών-τιμών: Παράδειγμα σε Relation Extraction

- Στόχος η ανεύρεση σχέσεων ανάμεσα σε οντότητες σε μια πρόταση
- Οντότητες
 - Κύρια ονόματα
 - Ονοματικές φράσεις
- Παράδειγμα
 - Κάθε παράδειγμα είναι ένα ζευγάρι οντοτήτων
- Έξοδος
 - Είδος σχέσης ανάμεσα στις οντότητες
- Αρχιτεκτονική ταξινόμησης
 - Δυναμική έξοδος για κάθε είδος σχέσης
 - Το είδος που θα αποδοθεί με μεγαλύτερο σκορ στο παράδειγμα κερδίζει
 - Ονοματική έξοδος με διαφορετική τιμή για κάθε είδος σχέσης

Παραδείγματα σχέσεων

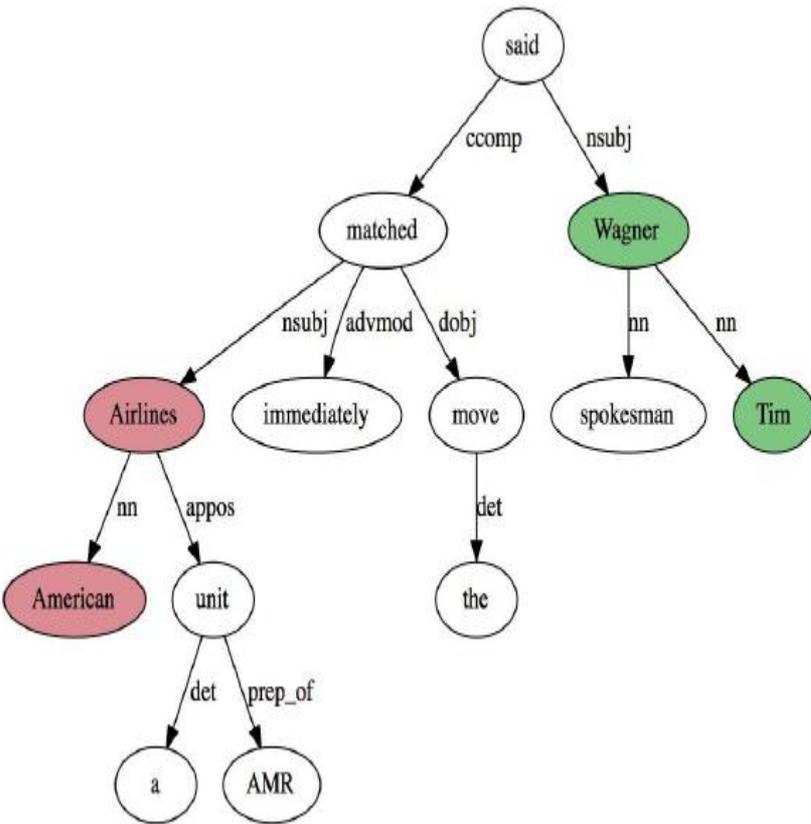
Relations in ACE dataset



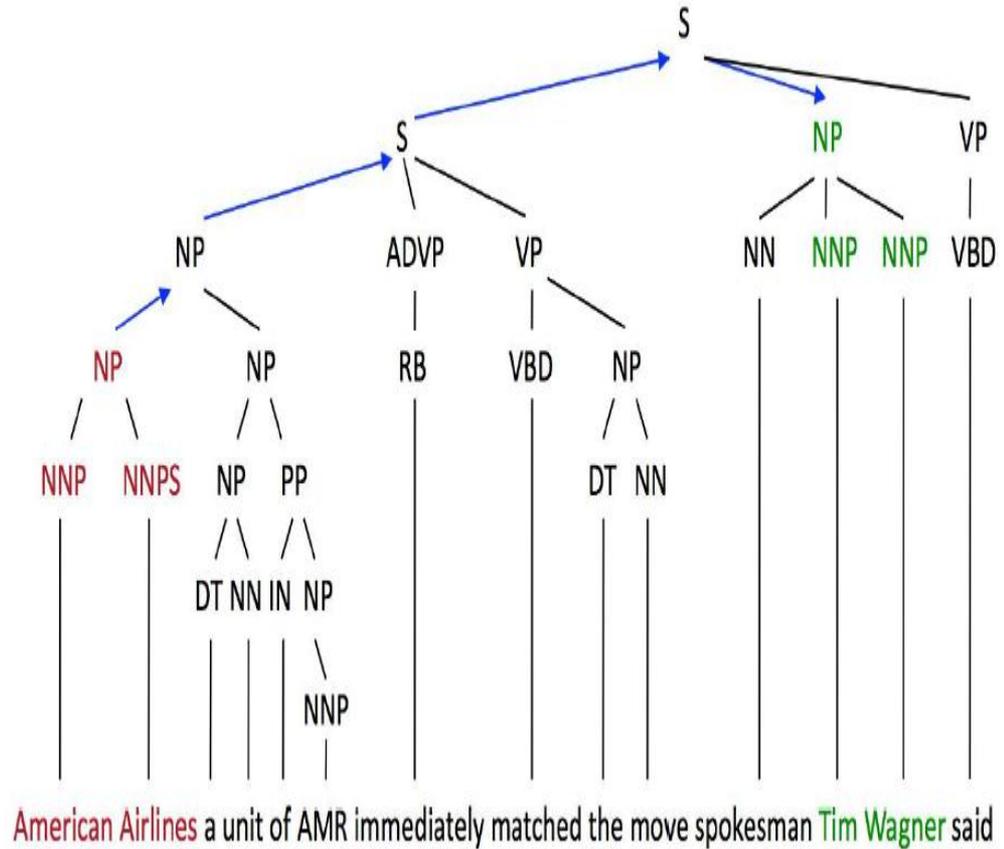
Το κείμενο ως διάνυσμα χαρακτηριστικών-τιμών:
Παράδειγμα σε Relation Extraction
(Exploring Various Knowledge in Relation Extraction,
Zhou et al., ACL 2005)

- Χαρακτηριστικά
 - Των δυο οντοτήτων
 - κατηγορίες
 - Κύριοι όροι
 - Των λέξεων που περιβάλλουν τις δυο οντότητες
 - Παράθυρο συμφραζομένων
 - Της συντακτικής δομής που κυβερνά τις δυο οντότητες
 - Συντακτική συσχέτιση
 - Μονοπάτι συντακτικού δέντρου ανάμεσα στις δυο οντότητες
 - Μήκος μονοπατιού δέντρου

Οι συντακτικές δομές



Δέντρο γραμματικής εξαρτήσεων
Dependency Grammar



Συντακτικό δέντρο

Το κείμενο ως διανύσμα χαρακτηριστικών-τιμών: Παράδειγμα σε Relation Extraction (Zhou et al., 2005)

American Airlines, a unit of AMR, immediately matched the move, spokesman **Tim Wagner** said

Template	Features
Headwords of M1 and M2	Airlines, Wagner, Airlines-Wagner
Unigrams, Bigrams	American, Airlines, Tim, Wagner, American Airlines, Tim Wagner
Words in particular positions	M1-1: NONE, M1+1: a, M2-1: spokesman, M2+1: said
Unigrams between M1 and M2	a, unit, of, AMR, immediately, matched, the, move, spokesman
Named entity types	M1: ORG, M2: PER, ORG-PER
Entity Level (NAME, NOMINAL, PRONOUN)	M1: NAME, M2: NAME
Number of entities between arguments	1 (AMR)
Syntactic chunk sequence from M1 to M2	NP NP PP ADVP VP NP NP
Constituency paths between M1 and M2	NP _{UP} NP _{UP} S _{UP} VP _{DOWN} S _{DOWN} NP _{DOWN}
Dependency tree paths	Airlines <--(nsubj) matched -->(ccomp) said <--(nsubj) Wagner

Μείωση της διαστατικότητας

- Stemming
 - αποκοπή της κατάληξης με στόχο την ομαδοποίηση των types που μοιράζονται κοινή μορφολογική ρίζα
 - cluster, clustering, clustered,... -> cluster
- Lemmatization
 - Λαμβάνει υπόψη της την μορφολογική ανάλυση των λέξεων προς ομαδοποίηση ώστε να βρει κοινό λήμμα
- Διαγραφή λειτουργικών λέξεων (function words)
 - προθέσεις, άρθρα, σύνδεσμοι, ...
- Διαγραφή λέξεων βάσει της συχνότητας εμφάνισης
- Επιλογή χαρακτηριστικών (feature selection)
- Latent Semantic Indexing
- Μπορεί να γίνει
 - για κάθε τιμή της εξόδου ξεχωριστά (local)
 - για όλες τις τιμές μαζί (global)

Latent Semantic Indexing

- Η τεχνική LSI χρησιμοποιεί Singular Value Decomposition για να διασπάσει τον αρχικό term-document matrix.
- Εύρωστη (δεν ενοχλείται από ανορθογραφίες κλπ)
- Υπολογιστικά ακριβή
- Καλή αν κάθε όρος συνεισφέρει από λίγο στην σωστή ταξινόμηση
- Όχι καλή αν ένας μεμονωμένος όρος είναι ιδιαίτερα σημαντικός για την ταξινόμηση

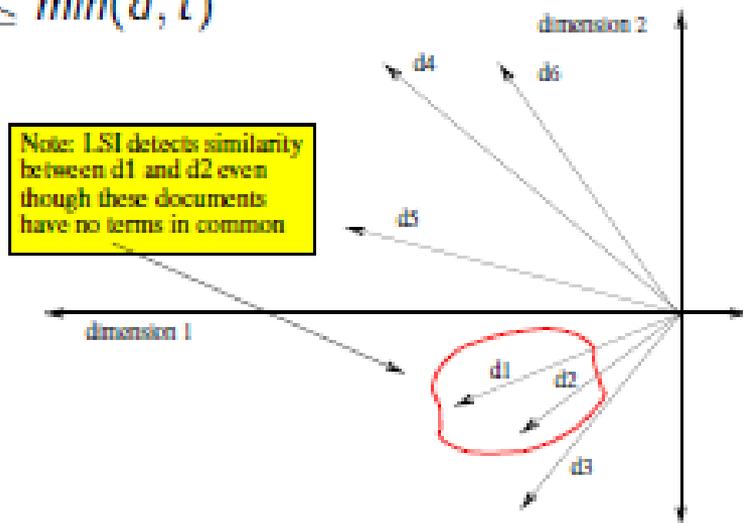
$$A =$$

	d_1	d_2	d_3	d_4	d_5	d_6
cosmonaut	1	0	1	0	0	0
astronaut	0	1	0	0	0	0
moon	1	1	0	0	0	0
car	1	0	0	1	1	0
truck	0	0	0	1	0	1

Table: Sample term-document incidence matrix

$$A_{t \times d} = T_{t \times n} S_{n \times n} (D_{d \times n})^T$$

where $n \leq \min(d, t)$



Για την επόμενη φορά

- Μελετάτε το άρθρο
 - «*A Survey on Natural Language Processing for Fake News Detection*» των Oshikawa, Qian και Wang
- Ετοιμάζετε σε ppt διαφάνειες για να παρουσιάσετε το περιεχόμενο του άρθρου
 - Το πρόβλημα της αναγνώρισης ψευδών ειδήσεων (1)
 - Τα datasets μιας ή λίγων προτάσεων (2.1.1)
 - Τα datasets αναρτήσεων σε κοινωνικά δίκτυα (2.1.2)
 - Τα datasets ολόκληρων άρθρων (2.2)
 - Τις μορφές εξόδου των εργασιών μάθησης (3.2)
 - Τις τεχνικές προεπεξεργασίας των κειμένων (4.1)
 - Τις τεχνικές μηχανικής μάθησης (4.4)
 - Τα αποτελέσματα (5)
 - Τα συμπεράσματα για την είσοδο (6.1)
 - Τα συμπεράσματα για τα μοντέλα (6.2)
 - Τις σχετικές προκλήσεις (7)