



D1.16. Identificarea metodelor de clasificare automată a stilului de exprimare din surse de date text și audio

Aceste rezultate au fost obținute prin finanțare în cadrul Programului PN-III Proiecte complexe realizate în consorții CDI, derulat cu sprijinul MEN – UEFISCDI,
Cod: PN-III-P1-1.2-PCCDI-2017-0818, Contract Nr. 73 PCCDI/2018:

“SINTERO: Tehnologii de realizare a interfețelor om-mașină pentru sinteza text-vorbire cu expresivitate”

© 2018-2020 – SINTERO

Acest document este proprietatea organizațiilor participante în proiect și nu poate fi reprodus, distribuit sau diseminat către terți, fără acordul prealabil al autorilor.

Denumirea organizației participante în proiect	Acronim organizație	Tip organizație	Rolul organizației în proiect (Coordonator/partener)
Institutul de Cercetări Pentru Inteligență Artificială “Mihai Drăgănescu”	ICIA	UNI	CO
Universitatea Tehnică din Cluj-Napoca	UTCN	UNI	P1
Universitatea Politehnică din București	UPB	UNI	P2
Universitatea "Alexandru Ioan Cuza" din Iași	UAIC	UNI	P3

Date de identificare proiect

Număr contract:	PN-III-P1-1.2-PCCDI-2017-0818, Nr. 73 PCCDI/2018
Acronim / titlu:	„SINTERO: Tehnologii de realizare a interfețelor om-mașină pentru sinteza text-vorbire cu expresivitate”
Titlu livrabil:	D1.16. Identificarea metodelor de clasificare automată a stilului de exprimare din surse de date text și audio
Termen:	Noiembrie 2018
Editor:	Mircea Giurgiu (Universitatea Tehnică din Cluj-Napoca)
Adresa de eMail editor:	Mircea.Giurgiu@com.utcluj.ro
Autori, în ordine alfabetică:	Mircea Giurgiu, Adriana Stan
Ofițer de proiect:	Cristian STROE

Rezumat:

Acest livrabil prezintă atât rezultate de natură teoretică ce au în vedere identificarea unor soluții de clasificare automată a stilului de exprimare din surse de date text și audio, precum și implementarea modulelor software aferente. Evidențierea acestor soluții este importantă pentru realizarea în etapele următoare a sistemului de sinteză text vorbire cu expresivitate.

În primă etapă au fost identificate câteva metode de reprezentare vectorială a textelor. Acestea se referă la reprezentări de tipul Bag of Words, VSM (Vector Space Models) și LSA (Latent Semantic Analysis). Din punct de vedere practic s-au implementat în Python și apoi testat experimental fluxurile de procesări care realizează reprezentările amintite și prin care s-a verificat posibilitatea de clasificare a mai multor stiluri de vorbire similar identificării automate a topicurilor din discursul de tip text. Rezultatele preliminare s-au obținut pe un corpus redus, dar avem în vedere utilizarea corpusurilor (belestristic, științific, jurnalistic, narativ) obținute de la Coordonator.

Similar metodelor de clasificare a textelor s-au identificat paramterii acustici care ar fi relevanți în clasificarea stilului de vorbire numai din date audio. Rezultatele pe surse de date audio arată că prin clasificatori tradiționali se poate obține o foarte bună rată de clasificare. Ramân în studiu atât selectarea potrivită a setului de parametri, precum și testarea pe un volum mult mai mare de date.

Aceste rezultate prezintă fundamentul pentru dezvoltarea în următoarea etapă a unui modul de identificare a nivelului de expresivitate din text, direct interoperabil cu modulul de control al prozodiei.

Cuprins

1. Introducere	4
2. Metode de clasificare a stilului de exprimare din date text	4
2.1. Metode bazate pe frecvențele cuvintelor (Modelul Bag of Words – BOW)	5
2.2. Metode de clasificare bazate pe reprezentarea VSM (Vector Space Models)	6
2.3. Metode bazate pe LSA (Latent Semantic Analysis)	6
3. Teste preliminare privind clasificarea stilului de exprimare din text	7
3.1. Fluxul de procesări	7
3.2. Rezultate preliminare	8
4. Clasificarea stilului de exprimare din date audio	9
4.1. Identificarea parametrilor acustici relevanți	9
4.2. Metode de clasificare din date audio	10
5. Concluzii	11
6. Bibliografie	11

1. Introducere

Acest livrabil (D1.16 „Identificarea metodelor de clasificare automată a stilului de exprimare din surse de date text și audio”) prezintă rezultatele obținute în activitatea A1.16 din planul de realizare a proiectelor componente, în mod specific din cadrul sub-proiectului P4 (SINTERO).

Identificarea și clasificarea stilului de exprimare din text este necesară în modulul de procesare a textului din cadrul unui sistem de sinteză text – vorbire cu scopul de a informa generatorul de semnal vocal despre expresivitatea pe care trebuie să o încorporeze la sinteză. Aceasta expresivitate este determinată de conținutul semantic al textului și de polaritatea acestuia.

Pentru a realiza acest deziderat textul este reprezentat prin intermediul cuvintelor într-o formă abstractă, vectorială, care pune în evidență în mod latent posibile relații semantice între cuvinte, respectiv indica la modul global un anumit stil de vorbire învățat în mod automat dintr-un corpus reprezentativ pentru acel stil.

2. Metode de clasificare a stilului de exprimare din date text

De regulă, înaintea aplicării oricărei metode de analiză sau clasificare automată a textului se procedează la pre-procesări de tipul tokenizare, normalizare sau adnotare.

Tokenizarea unui document text brut înseamnă a decide care sunt cele mai mici entități care ar trebui să fie considerate termeni individuali și extragerea acelor termeni. Deși în multe limbi cuvintele sunt separate numai de spații, adesea se iau în considerare și semnele de punctuație, abrevierile și cuvintele compuse. După preluarea termenilor de formare a unui text se pot filtra cuvintele după frecvența acestora, se pot elimina cuvinte predefinite dintr-o listă de oprire sau alți termeni care nu au semnificație majoră, cum ar fi prepozițiile și conjuncțiile. Procesul de tokenizare este un proces dependent de limbă.

Normalizarea este o altă prelucrare dependentă de limbă și care are în vedere fuziunea termenilor cu diferite forme, dar care reprezintă aceeași informație. Cele mai comune metode de normalizare sunt transformarea în literă mică și păstrarea doar a rădăcinii cuvântului. Uneori, modificarea în literă mică sau eliminarea accentului pot schimba sensul cuvintelor. De asemenea, eliminarea semnelor diacritice specifice limbii ar putea schimba conotația unui cuvânt. Păstrarea rădăcinii cuvântului este un proces similar cu analiza morfologică a cuvintelor și al cărei scop este aducerea cuvintelor la o formă normalizată. Astfel, se vor elimina formele de plural sau timpul verbului. Pentru a reduce și mai mult dimensiunea unui dicționar lingvistic, acesta poate fi filtrat prin numărul minim de apariții de cuvinte. După cum se vede în Figura 1, dimensiunea unui corpus poate fi redusă la jumătate doar prin reținerea rădăcinii cuvintelor, proces cunoscut sub numele de lematizare. Corpusul prezentat conține 3.299 de fișiere text conținând nuvele, articole din literatura beletristică, buletine de știri de la radio și televiziune – text colectat din Internet

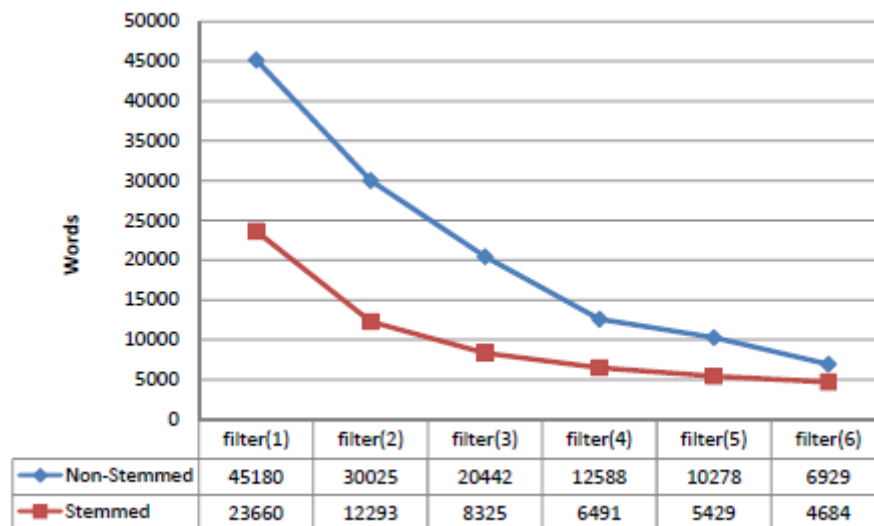


Figura 1. Reducerea dimensiunii corpusului de date text ca urmare a lematizării („stemmed”) și aplicării diferitelor metode de filtrare

Un al treilea proces lingvistic este adnotarea termenilor și prin care se adaugă informație auxiliară despre cuvinte. De exemplu, adnotarea părților de vorbire, marcarea unor cuvinte ambigue sau chiar analiza gramaticală pentru fiecare cuvânt în parte.

Toate studiile converg către ideea că modul de alegere și de calcul a caracteristicilor extrase din text sunt determinante pentru procesul de clasificare. Rezultate foarte bune au fost obținute doar prin calculul frecvențelor de apariție ale cuvintelor. Aceasta modalitate de reprezentare este cunoscută sub denumirea de bag of words (BOW). Alte caracteristici suplimentare pot fi obținute din adnotarea părților de vorbire, din reprezentarea vectorială (VSM – Vector Space Models) a cuvintelor sau a caracterelor, respectiv anumite statistici asupra lungimii cuvintelor, a modului de folosire a caracterelor speciale sau uneori a abrevierilor (eg. pentru domeniul tehnic).

În ce privește metodele de clasificare Naive Bayes reprezintă o metodă extrem de populară, cu bune rezultate chiar și pentru vectori de dimensiuni mari, în ciuda ipotezei de independență a acestor vectori. O altă metodă, mai performantă decât Naive Bayes, o reprezintă clasificatorii SVM (Support Vector Machines), în special prin abilitatea lor de a rezolva probleme cu vectori caracteristici de dimensiune mare și cu date incomplete. La ora actuală, multe metode au în vedere utilizarea rețelelor neuronale multistrat (DNN – Deep Neural Networks).

2.1. Metode bazate pe frecvențele cuvintelor (Modelul Bag of Words – BOW)

În acest model, pentru fiecare document din corpus se calculează un vector unidimensional de mărime egală cu mărimea dicționarului corpusului. Fiecare element din vector reprezintă numărul de apariții a cuvântului din dicționar în documentul de analizat. Prin urmare, toate documentele sunt reprezentate vectorial prin intermediul unui set de cuvinte din dicționar. Din acest motiv, modelul de numește Bag of Words. (Manning 2009)

Aplicațiile de căutare de documente cu aceste modele au arătat că relevanța căutării nu crește proporțional cu frecvența termenului în document. Ca atare s-a propus o metodă de ponderare pe o scală logaritmică a frecvențelor de apariție.

$$w_{t,d} = \begin{cases} 0 & , otherwise \\ 1 + \log_{10}(tf_{t,d}) & if\ tf_{t,d} > 0 \end{cases}$$

Mai mult, pornind de la aceasta modelare s-a propus o metodă similară prin care frecvența de apariție a termenului în document este înlocuită cu inversul acesteia. În consecință, se promovează termeni care apar mai rar în document, termeni care se consideră ca aduc mai multă informație decât termenii comuni.

$$idf_t = \log_{10} \frac{N}{df_t}$$

Pentru a balansa aceste două reprezentări s-a propus combinarea lor prin produs, obținând TF-IDF (Term frequency - Inverse Document Frequency).

$$tf \circ idf_{t,d} = \left(1 + \log_{10}(tf_{t,d}) \right) * \left(\log_{10} \frac{N}{df_t} \right)$$

2.2. Metode de clasificare bazate pe reprezentarea VSM (Vector Space Models)

În această abordare, fiecare document text este reprezentat sub forma vectorială în spațiul multidimensional a cuvintelor din dicționar. Principala problemă cu aceasta reprezentare este ca foarte multe dintre elementele vectorului sunt nule. Această problema se rezolva prin reducerea dimensionalității prin metoda SVD (Singular Value Decomposition). Ce este interesant în această metodă este faptul că documentele fiind reprezentate prin vectori se poate calcula ușor similaritatea între documente, respectiv se pot extrage informații de natură semantică doar din operații cu vectori. (Manning 2009)




Figura 2. Reprezentarea documentelor text sub formă de vectori și calculul similarității (Euclidian, cosinus)

2.3. Metode bazate pe LSA (Latent Semantic Analysis)

Latent Semantic Analysis (LSA) este o metodă prin care se explorează contextul în care se găsesc cuvintele într-un anumit document, pornind de la premiza că anumite cuvinte care sunt apropiate ca înțeles semantic vor fi regăsite în texte cu conținut semantic similar. Deoarece nu sunt folosite nici un fel de cunoștințe preliminare metoda este foarte puternică pentru că încearcă să descopere legături latente, semantice, în spațiul multidimensional al reprezentării cuvintelor.

3. Teste preliminare privind clasificarea stilului de exprimare din text

Această secțiune prezintă rezultate preliminare privind implementarea unui flux de procesări ale textului, în vederea identificării stilului de exprimare. S-a considerat un corpus de test în care sunt prezente două stiluri de exprimare, stilul beletristic (documentele 0 – 4), respectiv știri meteo (documentele 5-7).

Document ID	Text
0	<i>Cu două degete muiate în apă poți să stingi o lumânare. Închizând pleoapele, poți stinge o rază de soare. Dar noapte nu se face.</i>
1	<i>Căci noapte nici nu poate fi. Nici noaptea pamântului, noaptea cea mare, nu e noapte, ci doar o umbră într-un univers de lumină.</i>
2	<i>Ușor nu e nici cântecul. Zi și noapte nimic nu e ușor pe pamânt; căci roua este sudoarea privighetorilor ce s-au ostenit toată noaptea cântând.</i>
3	<i>Și dacă se întâmplă pe tine să te văz, Desigur că la noapte un tei am să visez.</i>
4	<i>Și dacă se întâmplă să întâlnesc un tei, Desigur toată noaptea visez la ochii tăi.</i>
5	<i>Vremea va fi în general închisă și se va răci iar noaptea va fi geroasă. Cerul va fi mai mult noros.</i>
6	<i>Cerul va fi noros și va ninge pe arii extinse. Vântul va sufla slab la moderat.</i>
7	<i>Vremea se menține închisă. Cerul va fi mai mult noros și va ninge pe arii relativ extinse în cursul zilei; noaptea va mai ninge la munte.</i>

3.1. Fluxul de procesări

Preprocesarea textului

- eliminarea caracterelor speciale (în exemplul de mai sus nu apar)
- eliminarea semnelor de punctuație
- tokenizare
- eliminare valori numerice
- eliminare cuvinte cu lungimea mai mică decât un prag pre-stabilit (eg.3)
- eliminare cuvinte cu frecvența de apariție mai mică decât un anumit prag (eg.2, cazul prepozițiilor sau conjuncțiilor)
- eliminare cuvinte din lista stop-list
- lematizare / opțional

Word ID	Word
0	tei
1	arii
2	visez
3	întâmplă
4	noaptea
5	cerul
6	noapte
7	desigur
8	vremea
9	ninge
10	extinse
11	noros

Creare BOW

Se creează un BOW prin care fiecare document din cele 8 este reprezentat prin succesiunea de cuvinte din dicționar. Se obține o matrice de 8 linii (documentele) și 12 coloane (cuvintele din BOW) și care este de tip sparse, deoarece doar 31 de elemente sunt ne-nule din totalul de 96. Se poate aplica și transformarea TF-IFD pe matricea BOW.

Reducere la 2 dimensiuni prin aplicarea VSM și LSA (sunt două stiluri de exprimare in corpus)

3.2. Rezultate preliminare

Prin această reducere de dimensionalitate se poate observa ponderea cu care cuvintele din BOW contribuie în mod latent la definirea unui stil sau altul. Stilul liric este caracterizat de coloana din stânga, iar stilul știri meteo este caracterizat de coloana din dreapta. Astfel, se observă că termenii cuvinte specifice pentru știri meteo, apar în coloana din dreapta cu ponderi pozitive. Ponderile puternic negative din coloana din stânga reflectă contribuția termenilor specifici stilului liric.

```
[[-0.13238691 -0.0490403 ]
[-0.04024498 0.35788882]
[-0.13238691 -0.0490403 ]
[-0.13238691 -0.0490403 ]
[-0.40220745 0.06777064]
[-0.06169143 0.39856061]
[-0.86543053 -0.15549137]
[-0.13238691 -0.0490403 ]
[-0.06769691 0.35742993]
[-0.06099282 0.50988595]
[-0.04024498 0.35788882]
[-0.06169143 0.39856061]]
```

Analiza LSA pune în evidență măsura în care fiecare document din cele 8 aparține de unul din cele două stiluri.

```
[<0, -0.86543053405895032>, <1, -0.15549137130458751>]
[<0, -0.94201518733130518>, <1, -0.090661079026033209>]
[<0, -0.94201518733130518>, <1, -0.090661079026033209>]
[<0, -0.46676607011119936>, <1, -0.13286434841965786>]
[<0, -0.32827195124496605>, <1, -0.085374266273189836>]
[<0, -0.20028749946269681>, <1, 0.64920190022130186>]
[<0, -0.11437257743090597>, <1, 0.8946905553340474>]
[<0, -0.17334222316982797>, <1, 0.94069789171678897>]
```


Cele mai semnificative cuvinte care definesc stilul respectiv

$0.865 * \text{"noapte"} + 0.402 * \text{"noaptea"} + 0.132 * \text{"întâmplă"} + 0.132 * \text{"desigur"} + 0.132 * \text{"visez"} - 0.510 * \text{"ninge"} - 0.399 * \text{"noros"} - 0.399 * \text{"cerul"} - 0.358 * \text{"extinse"} - 0.358 * \text{"arii"}$

4. Clasificarea stilului de exprimare din date audio

Similar clasificării stilului de exprimare din date text, ne punem problema recunoașterii stilului de exprimare din date audio. Recunoașterea stilului de exprimare este o problemă similară recunoașterii emoțiilor din vorbire. Tonul din voce, aparte de mesajul lingvistic, este un bun indicator. Stilul de vorbire și expresivitatea vorbitorului sunt determinate în mod sistematic de către mediul în care acesta comunică, de către situațiile comunicaționale, de tipul de informație care este comunicat. Este posibil însă, ca diferiți vorbitori să exprime un anumit stil de vorbire (de exemplu o poveste) prin modalități care se manifestă acustic în mod diferit. Parametrii care definesc un anumit stil pot fi de natură segmentală (modul de articulare) sau suprasedgmentală (intensitatea, frecvența fundamentală, rata vorbirii).

Mai jos este ilustrată variația anumitor parametri acustici în funcție de starea emoțională exprimată în vorbire.

Emoție	F0	Intensitate	Rata vorbirii
<i>Nervozitate</i>	<i>Valori medii înalte Domeniu larg de variație Schimbări abrupte</i>	<i>Mărită</i>	<i>Mult crescută</i>
<i>Fericire</i>	<i>Valori medii înalte Domeniu larg de variație</i>	<i>Mărită</i>	<i>Crescută sau Scăzută</i>
<i>Tristețe</i>	<i>Valori medii reduse Domeniu redus de variație</i>	<i>Scăzută</i>	<i>Redusă</i>
<i>Frică</i>	<i>Valori medii înalte Domeniu larg de variație</i>	<i>Normal</i>	<i>Crescută</i>
<i>Dezgust</i>	<i>Valori medii înalte Domeniu larg de variație</i>	<i>Scăzută</i>	<i>Redusă</i>

4.1. Identificarea parametrilor acustici relevanți

Pe baza studiilor realizate se prezintă mai jos un tabel sintetic cu parametrii acustici relevanți pentru recunoașterea emoțiilor și pentru identificarea expresivității din vorbire.

Parametri	Utilizare
Parametri spectrali pe termen lung	Media spectrului, spectral flatness measure, centroidul spectral
Parametri spectrali pe termen scurt	MFCC, LSF, LPC-PLP
Pitch	Media, deviația standard, skewness, kurtosis, maximum, minimum, quartiles, diferențe între quartile, coeficienții de regresie liniară și quadratică

Rata vorbirii	Media si deviația standrad pentru durata silabelor, raportul dintre durata segmentelor sonore și nesonore
Parametri in domeniul timp	Intensitatea, RMS/logaritm, numarul de treceri prin zero, TEO
Parametri tonali	Coeficientii CHROMA, CENS
Calitatea vocii	HNR, Jitter, Schimmer

Ca exemplu, ilustrăm modul de variație a 2 dintre acești parametri (frecvența fundamentală, respectiv parametrul LSF1) pentru 2 voci cu emotivități diferite. Prin urmare, acești parametri au un potențial înalt de discriminare între diferitele stiluri de vorbire.




Figura 3. Variația F0 pentru starea fericit (stânga), respectiv trist (dreapta).




Figura 4. Histograma parametrului LSF1 pentru starea fericit (stânga), respectiv trist (dreapta).

4.2. Metode de clasificare din date audio

Cele mai frecvente metode de clasificare aplicate pentru recunoașterea stilului de vorbire și a expresivității (inclusiv pentru recunoașterea emoțiilor) sunt arborii de decizie, clasificatorii SVM sau rețelele neuronale.

În aplicația prototip s-a utilizat un corpus cu 5 stiluri de expresivitate, corespunzând la 5 clase de emoții. În total s-au folosit 500 de fișiere audio pentru fiecare emoție, în total un set de 2500 de fișiere. Întreg setul a fost împărțit în două, un set pentru antrenare și unul pentru testare.

Parametrii acustici au fost extrași cu aplicația GlottHMM și printr-o procedură de selecție a parametrilor bazată pe information gain, s-au generat vectorii specifici fiecărui stil. Rezultate se prezintă pentru setul de parametri (F0, NAQ, LSF1, LSF2, LSF3, LSF4, HNR1, HNR2, HNR3, HNR4, HNR5) pentru care s-au inclus în vector media și deviația standard.

Prezentăm doar rezultatele globale de clasificare obținute prin 3 metode standard,

J48-arbori de decizie	83,67%
Logistic Model Tree	95,40%
MLP	97,95%

Pe baza acestei metodologii, în următoarea etapă vom considera colectarea unui set de date audio și text relevante pentru aplicația finală, iar pe baza acestor vom desfășura experimente extensive pentru testare în condiții mult mai complexe.

5. Concluzii

Rezultatele prezentate în acest livrabil corespund activității A1.16 din planul de implementare și se referă la identificarea metodelor de recunoaștere și clasificare automată a stilului de exprimare în surse de date text. În plus, am considerat util să realizăm un studiu pilot și pentru clasificarea stilului de vorbire doar din date audio. Aceasta s-a realizat pe un corpus rostit în 5 stări emoționale, astfel că recunoașterea emoțiilor poate fi mapată cu recunoașterea stilului de vorbire, până la colectarea unui corpus corespunzător pentru stilurile de vorbire.

Rezultatele preliminare pe sursele de date text arată că prin intermediul unor descriptori simpli, cum ar fi Bag of Words sau Vector Space Models se poate modela cu succes stilul de exprimare. Principala dificultate pe care am avut-o a fost lipsa unui modul de lematizare, dar acesta va fi furnizat în viitor de către partenerii din consoțiu. De asemenea, este necesară creșterea dimensiunii corpusurilor pentru a valida întreaga soluție la o scară mult mai amplă. Odată cu aceasta, este posibil să extindem și modalitatea de caracterizare a cuvintelor prin funcția lor morfologică, iar dacă va fi disponibil și anumite caracteristici din SentiWordNet.

Rezultatele pe surse de date audio arată că prin clasificatori tradiționali se poate obține o foarte bună rată de clasificare. Rămân în studiu atât selectarea potrivită a setului de parametri, precum și testarea pe un volum mult mai mare de date.

Aceste rezultate prezintă fundamentul pentru dezvoltarea în următoarea etapă a unui modul de identificare a nivelului de expresivitate din text, direct interoperabil cu modulul de control al prozodiei.

6. Bibliografie

- [Manning 2009] Christopher D. Manning, Prabhakar Raghavan, Hinrich Schütze, An Introduction to Information Retrieval, Cambridge University Press, 2009.
- [Turney 2010] Turney, Peter D., and Patrick Pantel. "From frequency to meaning: Vector space models of semantics." *Journal of artificial intelligence research* 37.1 (2010): 141-188.
- [Rehurek 2010] Rehurek, Radim, and Petr Sojka. "Software framework for topic modelling with large corpora." *Proceedings of LREC 2010 workshop New Challenges for NLP Frameworks*. 2010.

- [Landauer 1998] Landauer, Thomas K., Peter W. Foltz, and Darrell Laham. "An introduction to latent semantic analysis." *Discourse processes* 25.2-3 (1998): 259-284.
- [Sanderson 2012] Mark Sanderson, W. Bruce Croft, *The History of Information Retrieval*, Proceedings of IEEE, 2012
- [Rud94] Rudnick, A., Hauptmann, A., Lee, K., "Survey of Current Speech Technology", *Communications of the ACM*, Vol.37, No.3, March 1994.
- [Watts 2012] Oliver Watts, "Unsupervised Learning for Text-to-Speech Synthesis", Thesis submitted for the degree of Doctor of Philosophy, The University of Edinburgh, 2012
- [Scordillis 2011] Michael S. Scordillis, "Current progress and challenges in spoken emotion recognition", April 2011, Department of Electrical and Computer Engineering University of Miami
- [Eskenazi] Maxine Eskenazi, "Trends in Speaking Styles Research", LIMSI-CNRS, BP 133, 91403-ORSAY CEDEX, FRANCE
- [Serdar2004] Serdar Yildirim, Murtaza Bulut, Chul Min Lee, Abe Kazemzadeh, Carlos Busso, Zhigang Deng, Sungbok Lee, Shrikanth Narayanan, "An acoustic study of emotions expressed in speech", 2004
- [Gibbs2001] R. W. Gibbs, J. S. Leggitt, and E. A. Turner, "What's special about figurative language in emotional communication?" in *The Verbal Communication of Emotions: Interdisciplinary Perspectives*, S. R. Fussell, Ed. Mahwah, NJ, USA: Lawrence Erlbaum Associates, Inc., June 2002, pp. 125–149