
-LSVMA : au plus deux composants
pour apparier des résumés à des articles

Yves Bestgen

F.R.S-FNRS et UCL / IPSY / CECL
Louvain-la-Neuve - Belgique

Plan

- Le problème
- L'approche
- Analyses et résultats
- Utilité des composants
- Conclusion

L'approche

LSVMA : Trois composants


LSVMA : L'analyse sémantique latente

LSVMA : L'analyse sémantique latente

- Pourquoi?
 - Foltz, Britt et Perfetti (in Foltz, 1996)
 - Quels textes ont le plus influencé un résumé?
 - Appariement des phrases du résumé et celles des textes
 - Evaluation automatique de résumés
 - Comparer les résumés à un document de référence
 - Le plus similaire est le meilleur
- (Kintsch et al., 2000 ; Olmos et al., 2009)

LSVMA : L'analyse sémantique latente

- Comment?
 - Corpus




LSVMA : L'analyse sémantique latente

- Comment?

- Corpus \rightarrow Tableau lexical

- Décomposition en valeurs singulières et réduction


- Espace sémantique



LSVMA : L'analyse sémantique latente

- Comment?

- Corpus → Tableau lexical
- Décomposition en valeurs singulières et réduction
- Proximité entre "résumé" et "document de référence"




LSVMA : Machine à support vectoriel

LSVMA : Machine à support vectoriel

- Pourquoi?

- Un problème de catégorisation de textes



- Classifieur SVM très efficace, y compris à partir de LSA


LSVMA : Machine à support vectoriel

- Comment?
 - Classer chaque résumé dans le texte correspondant sur la base des vecteurs de LSA
 - Mais sur quelle base apprendre?

LSVMA : Machine à support vectoriel

- Comment?

- Classifier chaque résumé dans le texte correspondant sur la base des vecteurs de LSA
- Mais sur quelle base apprendre?
 - Classifier les paragraphes dans les textes



- Multicatégorielle : $SVM^{multiclass}$ (Joachims et al., 2009)

LSVMA : Affectation au Meilleur d'Abord

LSVMA : Affectation au Meilleur d'Abord

- Pourquoi?
 - Un cas particulier de catégorisation de textes
 - Relation biunivoque entre résumés et textes
 - Non prise en compte par la SVM

LSVMA : Affectation au Meilleur d'Abord

- Comment?

- Un problème d'affectation ou d'appariement

	T1	T2	T3	T4	T5	...	Tn
Ra	Orange	Red	Green	Red	Red	Yellow	Orange
Rb	Red	Yellow	Red	Orange	Green	Red	Red
Rc	Green	Red	Red	Red	Red	Orange	Red
Rd	Red	Red	Orange	Red	Yellow	Green	Red
Re	Orange	Green	Red	Yellow	Red	Red	Yellow
	Red	Orange	Red	Red	Orange	Red	Green
Rn	Yellow	Red	Green	Yellow	Red	Yellow	Red

(Rubin, 1973 ; Rosenbaum, 2010)

- Solution simple

- Technique du plus proche disponible en commençant par le meilleur couple Résumé-Texte

LSVMA : Implémentation

- Prétraitements (principaux)
 - Lemmatisation (Treetagger : Schmid, 1994)
 - Textes segmentés en paragraphes de minimum 75 mots
 - Une matrice par revue : Termes x [paragraphes+résumés]

LSVMA : Implémentation


- Prétraitements (principaux)
 - Lemmatisation (Treetagger : Schmid, 1994)
 - Textes segmentés en paragraphes de minimum 75 mots
 - Une matrice par revue : Termes x [paragraphes+résumés]



LSVMA : Implémentation

- Prétraitements (principaux)

- Lemmatisation (Treetagger : Schmid, 1994)
- Textes segmentés en paragraphes de minimum 75 mots
- Une matrice par revue : Termes x [paragraphes+résumés]



- Paramètre pour l'optimisation

- Nombre de vecteurs de l'espace sémantique
 - 300, 200 et 100

Analyses et résultats

Apprentissage : Classifications des paragraphes

Piste	Nvec	ANT	MET	SCI	INT	LIT
1	100					
	200					
	300					
2	100					
	200					
	300					

Classifications correctes (%)

Apprentissage : Classifications des paragraphes

Piste	Nvec	ANT	MET	SCI	INT	LIT
1	100	93	80	94	95	95
	200	97	90	97	97	98
	300	98	94	98	98	99
2	100	93	81	93	94	94
	200	98	91	96	97	98
	300	99	94	98	98	99

Classifications correctes (%)

Apprentissage : Classifications des paragraphes

Piste	Nvec	ANT	MET	SCI	INT	LIT
1	100	93	80	94	95	95
	200	97	90	97	97	98
	300	98	94	98	98	99
2	100	93	81	93	94	94
	200	98	91	96	97	98
	300	99	94	98	98	99

Classifications correctes (%)

Appariement : Classifications des résumés

Piste	Nvec	ANT	MET	SCI	INT	LIT
1	100	100	90	100	100	100
	200	100	100	100	100	100
	300	100	100	100	100	100
2	100	100	90	100	100	100
	200	100	97	100	100	100
	300	100	100	100	100	100

Classifications correctes (%)

Appariement : phase de test

- Les 3 valeurs de Nvec ont donné lieu au même appariement
 - Une seule soumission par piste : 100%

LSVMA : Utilité des trois composants?

LSVMA : Utilité des trois composants?



Adapté de <http://reviews.goldenagecartoons.com/2010/mighty/>

LSVMA : Utilité des trois composants?

- SVM est le noyau de l'approche
- LSA ?
 - Raison d'être : synonymie (au sens large), mais ici?
 - SVM sur matrice Termes x Documents
 - Performances aussi bonnes qu'avec LSA
 - LSA non nécessaire
- MA ?

LSVMA : Utilité des trois composants?

- SVM est le noyau de l'approche
- LSA ?
 - Raison d'être : synonymie (au sens large), mais ici?
 - SVM sur matrice Termes x Documents
 - Performances aussi bonnes qu'avec LSA
 - LSA non nécessaire
- MA ?
 - Sans MA, performances moins bonnes
 - Semble nécessaire...

Conclusion

- **LSVMA** : LSA + SVM + MA
- Pour la tâche, LSA n'est pas nécessaire
 - Conclusion généralisable à l'évaluation d'*hétéro-résumé*?
(Schneidecker, 2001)

Conclusion

- **LSVMA** : LSA + SVM + MA
- Pour la tâche, LSA n'est pas nécessaire
 - Conclusion généralisable à l'évaluation d'*hétéro-résumé*?
(Schneidecker, 2001)
- Limitation de l'approche
 - Pourquoi de "moins bonnes" performances pour *Meta*?
 - Pour l'appariement, mais aussi pour l'apprentissage

Apprentissage : Classifications des paragraphes

Piste	Nvec	ANT	MET	SCI	INT	LIT
1	100	93	80	94	95	95
	200	97	90	97	97	98
	300	98	94	98	98	99
2	100	93	81	93	94	94
	200	98	91	96	97	98
	300	99	94	98	98	99

Classifications correctes (%)

Conclusion

- **LSVMA** : LSA + SVM + MA
- Pour la tâche, LSA n'est pas nécessaire
 - Conclusion généralisable à l'évaluation d'*hétéro-résumé*?
(Schneidecker, 2001)
- Limitation de l'approche
 - Pourquoi de "moins bonnes" performances pour *Meta*?
 - Pour l'appariement, mais aussi pour l'apprentissage
 - La revue ou le format ?

Différence de format entre les revues

Revue des sciences de l'éducation

<titre>Introduction</titre>

<p>En 1983, Viviane Isambert-Jamati, qui retraçait l'histoire des rapports entre les sciences sociales et « le ministère » dans le domaine de l'éducation, concluait à une ignorance réciproque (Berthelot, Forquin, Isambert-Jamati et Tanguy, 1984). En 2003, Franck Poupeau dénonce une [...]

Meta

<p>Le modèle présenté ici [...] : il modélise l'activité</p>

<p>professionnelle standard [...] « traducteur ». Il est</p>

<p>centré sur l'ensemble [...] matériau traduit autonome</p>

<p>GENESE</p>

Merci de votre attention

Références


- Foltz (1996). Latent Semantic Analysis for text-based research. *Behavior Research Methods* 28, 197–202.
- Joachims et al. (2009). Cutting-Plane training of structural SVMs, *Machine Learning* 77, 27–59.
- Kintsch et al. (2000). Developing summarization skills through the use of LSA-based feedback. *Interactive Learning Environments* 8, 87–109.
- Olmos et al. (2009). New algorithms assessing short summaries in expository texts using Latent Semantic Analysis. *Behavior Research Methods* 41, 944–950
- Rosenbaum (2010). *Design of Observational Studies*. Springer.
- Rubin (1973). Matching to remove bias in observational studies, *Biometrics* 29, 159–183.
- Schmid (1994). Probabilistic part-of-speech tagging using decision trees. *1st NMLP Conf.*, 44–49.
- Schnedecker (2001). *Lire, comprendre, rédiger des textes théoriques*. De Boeck.

Analyses et résultats

- Matériel pour le développement
 - 5 revues
 - \pm 8 000 termes différents par revue
 - En moyenne, de 22 à 44 paragraphes par texte
- Matériel pour le test
 - 6 revues

LSA : Pondération log-entropie

- Pondération locale
 - Réduit l'impact des mots très fréquents dans un document

$$f_{ij}' = \frac{\log(f_{ij} + 1)}{-\sum_j \frac{f_{ij}}{\sum_j f_{ij}} \log\left(\frac{f_{ij}}{\sum_j f_{ij}}\right)}$$
The diagram shows the formula for local weighting. The numerator, $\log(f_{ij} + 1)$, is circled in red. The denominator, $-\sum_j \frac{f_{ij}}{\sum_j f_{ij}} \log\left(\frac{f_{ij}}{\sum_j f_{ij}}\right)$, is also circled in red. Two red arrows point from the circles to the text above: one from the numerator circle to 'Réduit l'impact des mots très fréquents dans un document' and one from the denominator circle to 'Réduit l'impact des mots peu informatifs (Fréquence similaire dans tous les documents)'. The entire formula is enclosed in a grey rectangular box.

- Pondération globale
 - Réduit l'impact des mots peu informatifs
(Fréquence similaire dans tous les documents)

