



Multimedia  
information  
retrieval  
Modeling

# Contrainte de correspondance Document-Document pour la RI

Application à la divergence de Kullback-Leibler



P. Mulhem

J.-P. Chevallet

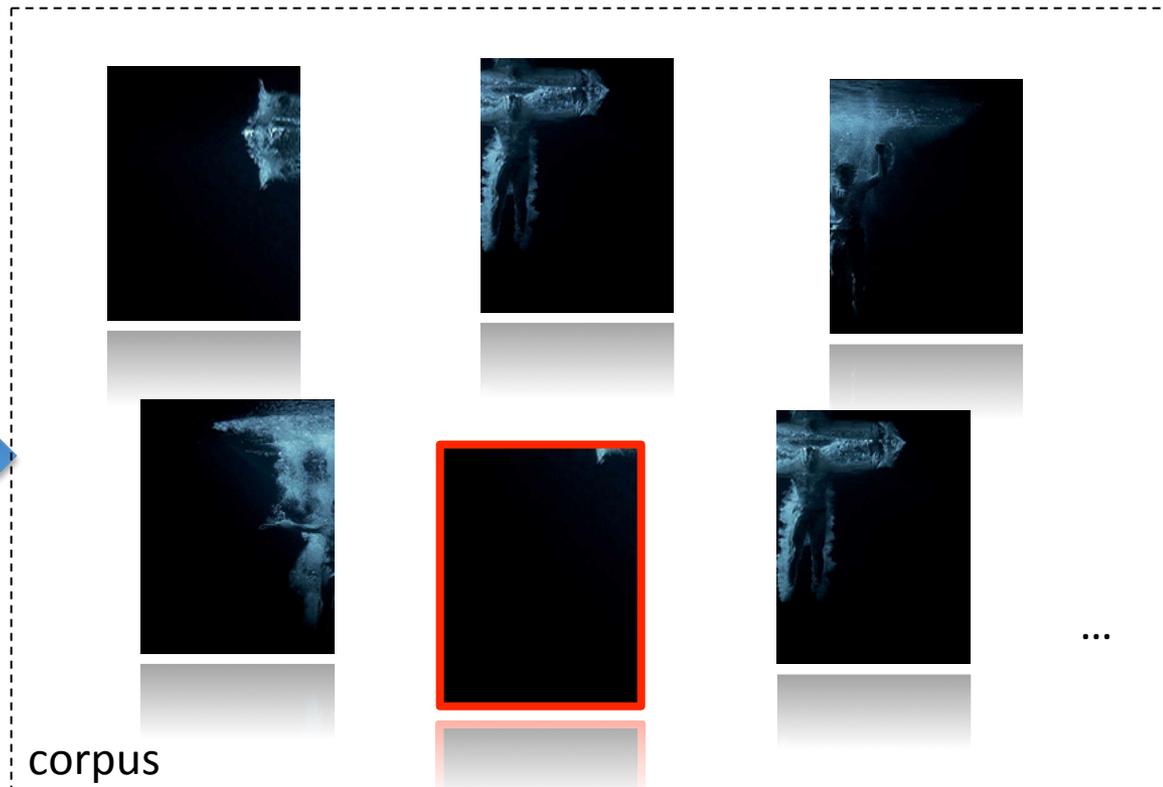
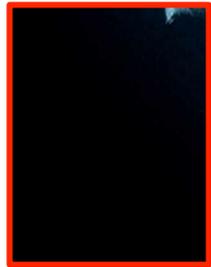


# Prélude...

De tout temps, les hommes ont voulu retrouver de l'information

- Recherche d'image fixe par l'exemple

Requête (dans corpus)



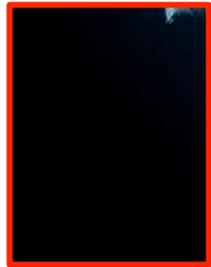
# Plan

1. Point de départ : comportement inattendu
2. Existant : Contraintes axiomatiques pour la RI
3. Comportement attendu : DDMC
4. Modèles de langues utilisant la divergence de Kullback-Leibler  
Modification pour validation de DDMC : nSKL
5. Etude de nSKL  
Théorique  
Expérimentale

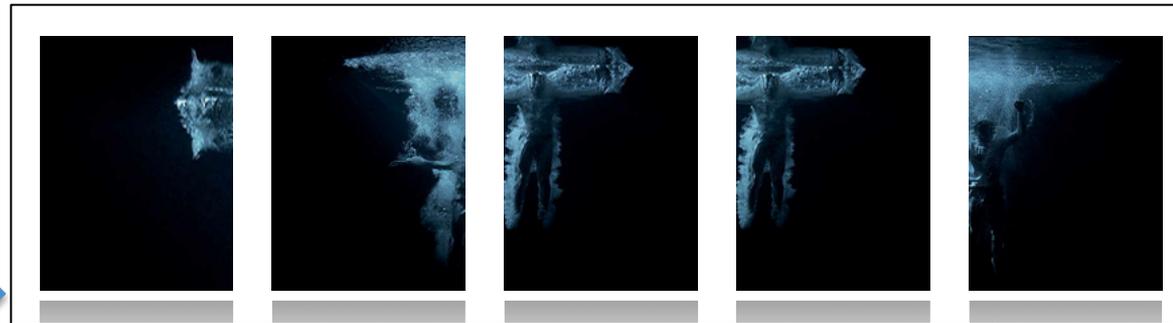
# 1. Point de départ - Comportement «inattendu»

- Recherche d'image fixe
  - sacs de mots, modèle de langue par divergence de Kullback-Leibler, lissage Jelinek-Mercer

Requête (dans corpus)



Résultat



– La requête n'est pas la première réponse...



## 2. Existant : contraintes axiomatiques pour la RI

- En 2004, révolution par [Fang, Tao & Zhai 2004]
  - Analyse des formules : comportements attendus
  - Exemple :
    - TFC1 (Term Frequency Constraint One) :

*Soit :  $Q = \{w\}$  une requête avec un terme  $w$ .  
Posons :  $|D_1| = |D_2|$ .  
si  $c(w, D_1) > c(w, D_2)$ , alors  $f(D_1, Q) > f(D_2, Q)$ .*

Forme analytique [Clinchant Gaussier 2010] :  $\frac{\partial f}{\partial c} \geq 0$

## 2. Existant : contraintes axiomatiques pour la RI

- Fang, Tao et Zhai ont défini 6 contraintes « classiques » en 2004 :
  - Tf : TFC1, TFC2
  - Idf : Term Discrimination Constraint (TDC)
  - |D| : Length Normalization Constraint (LNC1, LNC2)
  - Tf-Length Constraint (TF-LNC)
- Evolutions ultérieures [Clinchant & Gaussier, Lv & Zhai, Rahimi, Shakery & Zhai, Cummins & O’Riordan]

 On s’inspire de ses travaux, selon un point de vue global par rapport au corpus.

# 3. Comportement attendu : DDMC

- Proposition :

## Document-Document Matching Constraint

La valeur de correspondance entre

- un document  $D$  du corpus utilisé comme requête, et
- ce même document dans le corpus  $C$

est supérieure ou égale à celle entre  $D$  utilisé comme requête et chacun des autres documents du corpus.

$$\forall D \in C, \nexists D' \in C, D' \neq D, f(D, D') > f(D, D)$$

- On espère que cette contrainte peut induire un comportement intéressant pour la RI

NOTE : BM25, et modèle de langue classique ne valident pas DDMC.

# Cadre général

1. Etudier un modèle « simple » mais reconnu pour sa qualité, pour voir se qui se passe...

Modèle de langues avec négative de Kullbak-Leibler,  
Lissage de Jelinek-Mercer

2. Tenter de trouver une modification simple qui valide DDMC, pour l'étudier...

Lissage de  
requête

3. Etudier ce modèle modifié
  - DDMC, contraintes « classiques », fichier inverse

# 4. Modèles de langues utilisant la divergence de Kullback-Leibler

- Modèle de référence (nKL)
  - Négative de la divergence de Kullback-Leibler

$$nKL(Q||D) = - \sum_{t \in Q} P_{ML}(t|Q) \cdot \log\left(\frac{P_{ML}(t|Q)}{P_{\lambda}(t|D)}\right)$$

- Modèle de requête Q : maximisation de vraisemblance

$$P_{ML}(t|Q) = \frac{c(t, Q)}{|Q|}$$

- Modèle d'un document D : Lissage de Jelinek-Mercer (adapté aux requêtes longues [Zhai & Lafferty 2001])

$$P_{\lambda}(t|D) = (1 - \lambda) \cdot P_{ML}(t|D) + \lambda \cdot P_{ML}(t|C)$$

# 4. Modèles de langues utilisant la divergence de Kullback-Leibler

- Explication de DDMC non validée par nKL :

modèles de documents

$$P_{\lambda}(t|D) = (1 - \lambda) \cdot P_{ML}(t|Q) + \lambda \cdot P_{ML}(t|C)$$

≠

modèles de requêtes

$$P_{ML}(t|Q) = \frac{c(t, Q)}{|Q|}$$

- Proposition:

– utilisation de nKL avec les requêtes lissées, nSKL

(idem [Louis & Nenkova 2009])

$$nSKL(Q||D) = - \sum_{t \in T} P_{\lambda}(t|Q) \cdot \log\left(\frac{P_{\lambda}(t|Q)}{P_{\lambda}(t|D)}\right)$$

# 5. Etude de nSKL - Théorique

✓ nSKL valide DDMC

$nSKL(D||D) = 0$  : valeur maximale .

✓ Validation des contraintes « classiques »

[Fang, Tao & Zhai 2004, Clinchant & Gaussier 2011]

Contraintes	TFC1	TFC2	speTDC	LNC1	LNC2	TF-LNC
nKL	OK	OK	OK	OK	OK	Cond : $c(w,d) <  D  \cdot p_{ML}(t C)$
nSKL	OK*	OK*	OK*	OK*	OK*	numérique

\* Via approximation (cf. papier)

# 5. Etude de nSKL - Théorique



Compatible avec fichiers inverses [Mulhem & Chevallet 2014]

$$nSKL(Q||D) \propto_Q \sum_{t \in Q \cap D} (1 - \lambda) \cdot P_{ML}(t|Q) \cdot \log\left(\frac{P_\lambda(t|D)}{\lambda \cdot P_{ML}(t|C)}\right) + \sum_{t \in D} P_{ML}(t|C) \cdot \log\left(\frac{P_\lambda(t|D)}{\lambda \cdot P_{ML}(t|C)}\right)$$

fichier inverse

$K_D$

# 5. Etude de nSKL - Expérimentale

- Images : requêtes par l'exemple
  - ZuBud [Shao et al 2004]
    - 1005 images de 201 bâtiments / 115 requêtes
    - modèle de langue sur mots-clés visuels (2k), SIFT [Lowe 2004, VandeSande et al 2010]

divergence (paramètre)	MAP	MRR	P@10	Taux de Reco.
nKL ( $\lambda = 0, 2$ )	0.6988	0.9072	0.3826	0.8782
nSKLD ( $\lambda = 0, 1$ )	0.6949 (-0,6 %)	0.9029 (-0,5 %)	0.3783 (-1,1 %)	0.8696 (-1,0 %)

✓ – Pas de différence de MAP statistiquement significative (test de Student pairé bilatéral  $p \leq 5\%$ )

# 5. Etude de nSKL - Expérimentale

- Textes
  - TREC-6 ad-hoc [Voorhes & Harman, 2000]
    - 550 000 documents, 50 requêtes
    - Requêtes « longues » : *topic+description+narrative*

divergence (paramètre)	MAP	P@10	P@30
nKL ( $\lambda = 0, 7$ )	0.2646	0.4400	0.3307
nSKLD ( $\lambda = 0, 4$ )	0.2477 (-6,4 %)	0.4360 (-0,9 %)	0.3247 (-1,8 %)

✓  – Pas de différence de MAP statistiquement significative (test de Student pairé bilatéral  $p \leq 5\%$ )

# Conclusion

- Proposition d'une contrainte basée sur le corpus, pour des requêtes « documents » : DDMC
- Modification de modèle de langue à base de négative de Divergence de Kullback-Leibler : nSKL
  - Compatibilité avec fichiers inverses
  - Validation partielle des contraintes « classiques »
- Validation expérimentale préliminaire
  - Résultats très proches de nKL

# Travaux futurs

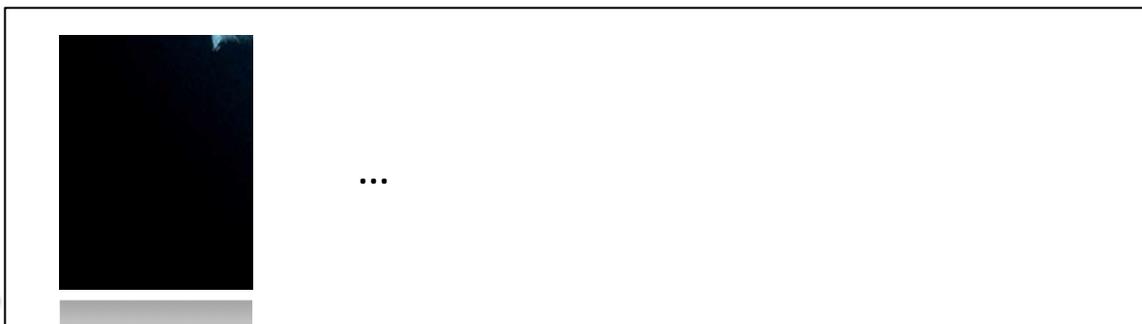
- Etude de nSKL plus poussée
  - Validation des contraintes classiques
  - Expérimentations (requêtes/documents longs/courts)
- Vers une démarche scientifique pour modifier des formules existantes pour les rendre compatibles avec DDMC

- Sur notre exemple initial :

Requête (dans corpus)



Résultat



# 5. ~~Etude de nSKL - Théorique~~

✓ TFC1 validée par calcul de dérivée partielle sur les occurrences des termes [Clinchant et Gaussier 2010]

- En notant la variable  $c$  pour  $c(w,D)$

$$nSKL(Q||D) = (1-\lambda) \cdot \log\left(\frac{1-\lambda}{\lambda} \cdot \frac{c(w,D)}{|D| \cdot P_{ML}(w|C)} + 1\right) + \dots$$

$$\frac{\partial nSKL(Q||D)}{\partial c} = \frac{(1-\lambda)^2}{\lambda \cdot |D| \cdot P_{ML}(w|C) + c - \lambda \cdot c} > 0 \quad \text{si } \lambda \in ]0,1[$$

✓ Suivant les mêmes idées, TFC2, TFC3, LNC1, LNC2, speTDC validées partiellement

✓ TF-LNC validée partiellement numériquement

# ~~5. Etude de nSKL - Théorique~~

- Validation des contraintes de [Fang, Tao & Zhai 2004]
  - Pour les contraintes avec un terme (TFC1, TFC2)

$$\begin{aligned} nSKL(Q||D) = & (1-\lambda) \cdot \log\left(\frac{1-\lambda}{\lambda} \cdot \frac{c(w,D)}{|D| \cdot P_{ML}(w|C)} + 1\right) \\ & + \lambda \cdot P_{ML}(w,C) \cdot \log\left(\frac{1-\lambda}{\lambda} \cdot \frac{c(w,D)}{|D| \cdot P_{ML}(w|C)} + 1\right) \\ & + \lambda \cdot P_{ML}(w',C) \cdot \log\left(\frac{1-\lambda}{\lambda} \cdot \frac{c(w',D)}{|D| \cdot P_{ML}(w'|C)} + 1\right) \\ & + \sum_{t \in D \setminus \{w, w'\}} \lambda \cdot P_{ML}(t,C) \cdot \log\left(\frac{1-\lambda}{\lambda} \cdot \frac{c(t,D)}{|D| \cdot P_{ML}(t|C)} + 1\right) \end{aligned}$$

# DDMC pour modèles classiques

- Modèle vectoriel : tf.idf pour D et Q, cosinus

➤ DDMC validé :  $\text{cosinus}(D, D) = 1$

- BM25 :  $f_{BM25}(Q, D) = \sum_{t \in D \cap Q} \ln \frac{N - df_t + 0.5}{df_t + 0.5} \cdot \frac{(k_1 + 1) \cdot \#t, D}{k_1 \cdot ((1 - b) + b \cdot \frac{|D|}{avdl}) + \#t, D} \cdot \frac{(k_3 + 1) \cdot \#t, Q}{k_3 + \#t, Q}$
- DDMC non validée sur un exemple

- Modèle de langue

- Nég. de div. de Kullback-Leibler :  $nKL(Q||D) = - \sum_{t \in Q \cap D} P_{ML}(t|Q) \cdot \log\left(\frac{P_{ML}(t|Q)}{P_\lambda(t|D)}\right)$

- Lissage de Jelinek-Mercer de D :  $P_\lambda(t|D) = (1 - \lambda) \cdot P_{ML}(t|Q) + \lambda \cdot P_{ML}(t|C)$

- Maximisation de vraisemblance de Q :  $P_{ML}(t|Q) = \frac{c(t, Q)}{|Q|}$

➤ DDMC non validée sur un exemple (confirmation du cas des images)