

# Présentation d'article par Nathan Galard

**Marion Baranes. Vers la correction automatique de textes bruités:  
Architecture générale et détermination de la langue d'un mot inconnu.  
RECITAL'2012 - Rencontre des Etudiants Chercheurs en Informatique pour le Traitement  
Automatique des Langues, Jun 2012, Grenoble, France. pp.95-108, 2012. <hal-00701400>**

# Sujet/objectif 1

- Correction orthographique et typographique automatisée sur textes de qualité très dégradée
- Multilingue **Prérequis pour nombreux outils**
- Contextuel (id est « s'adaptant »)

/!\ sur-correction versus sous-correction

29 janvier 2008 à 18 h 22 min

#2412



axl

Participant

bien evidement c plus raisonnable. mais c vrai qu'apriori l avantage ( en dehors des papiers) c que tu pars avec 1 job.

tu as ete bosser la bas? est ce que c facil de trouver qqc? les patrone c pas 1 peu l'arnak, est ce qu'il st cool?

merci qd mm pour les conseils de prudence, c pas 1 mal de se moderer 1 peu. 😊

[www.australia-australie.com/sujet/odysse-agri/](http://www.australia-australie.com/sujet/odysse-agri/)  
Consulté le 28/01/19

# Sujet/objectif 2

- Plusieurs modules, un doit déterminer si mot inconnu étranger ou pas :

- Faute d'orthographe

agreement

:’(

- Emprunt

OMG !

- Néologisme

reseter

- Mot étranger

jumper

- Entité nommée

surkiffant

Mâchouillon

Tro klassssss

Jyväskylä

# Objet

- **Textes bruités provenant du web**

- Forums
- Sites d'avis
- Réseaux sociaux
- Blogs
- (Mails)

**Corpus messages clients  
(canaux variés)**

# État de l'art de la correction automatique 1

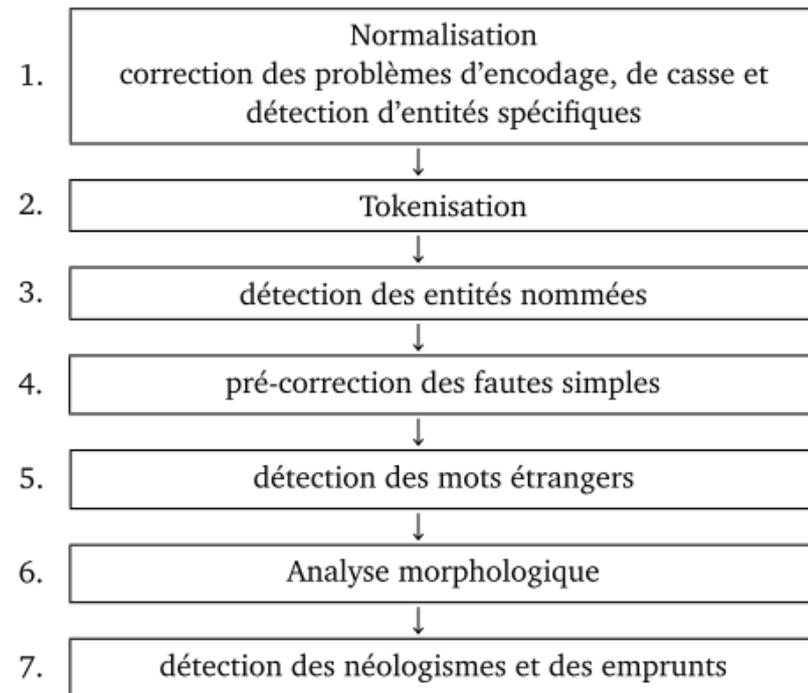
- **Type/provenance de corpus (ex : OCR vs SMS)**
- **Faute lexicale vs faute grammaticale (vert-vers)**
  - Traitées séparément (hors de pri)
  - Modèles de langage n-grammes (tjs hor de pri)
  - n-grammes phonétiques [ou] les deux
- **Phonétisation (sms)**
- **Ressources lexicales spécifiques**
- **Modèles entraînés sur textes bruités + nettoyée**

# État de l'art de la correction automatique 2

- Méthode enrichie par résultats de requêtes
- Mots inconnus
  - Lexiques spécifiques
  - Contexte
- Même logique : détecter > liste candidats > choisir

# Moyens généraux

- Implémentation d'une architecture de correction
  - En plusieurs modules
  - Grammaticale et lexicale
  - Combinaison de plusieurs méthodes très variées
  - Série de prétraitements



# Les prétraitements n°1 ; 2 ; 3 et 4

- **Normalisation** (encodage, casse, entités spécifiques)
- **Tokenisation** (segmentation en unités)
- **Détection des entités nommées**(noms propres, acronymes)
  - « Nettoyage » ; SxPipe (chaîne modulaire et paramétrable qui applique des traitements de surface)
- **Pré-correction des fautes univoques**
  - Noooooooooon ! > Non !

# Module de détection des mots étrangers

(Mots inconnus entités nommées > correction ?)

- ≠ détection langue (contexte)

---

- Étranger = emprunt non-adapté morphologiquement
  - ≠ inconnu français ni néologisme
- Étranger ≈ anglais → distinguer inconnus fra. / anglais

---

- Classifieur : 2 classes
  - Corpus d'entraînement
  - Syst. de clas. pouvant apprendre modèle probabiliste
  - Corpus d'évaluation représentatif

# Les corpus d'entraînement et système de classification

- **Ressources lexicales** (*Lefff* et *EnLex*)
- **Corpus de textes propres** (journaux, Wiki, livres)
- **Corpus bruités produits par l'utilisateur** (*WaCKy* > *frWaC* et *ukWaC*)
  - Contiennent mots étrangers > approximation peu dérangement
- **Baseline, class. naïve** > fréquence brute tokens
- **Système proposé**
  - N-grammes
  - Fréquence-ratio
  - t-test

# Évaluation

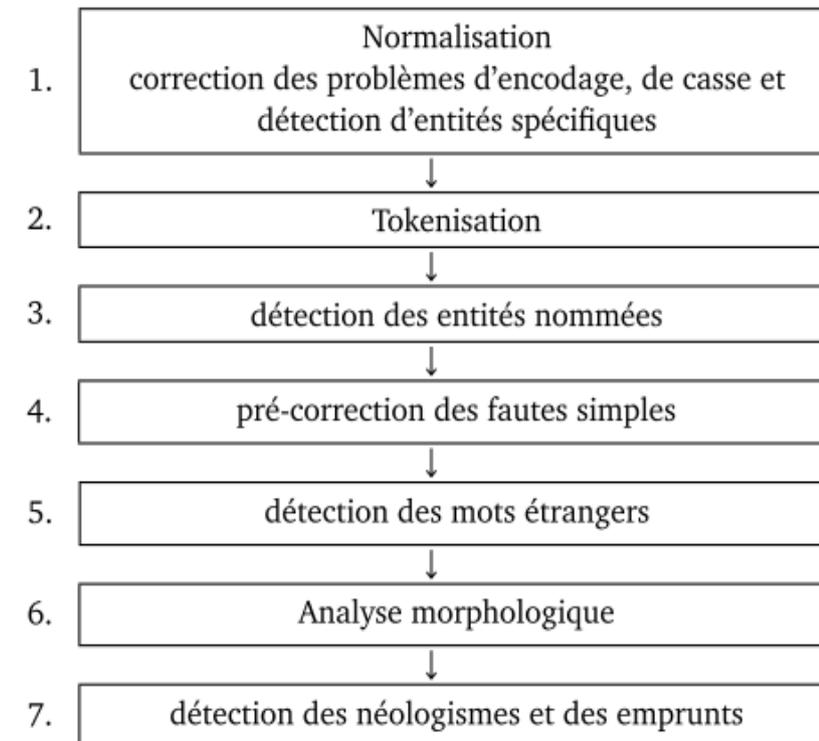
- Données de réf. récoltées et annotées manuellement 564 x2
- Évaluation isolée
- Taux d'erreur :
  - 0,136 Baseline
  - 90 % de bonnes classifications → « satisfaisant »  
(2-grammes et t-test)

# Recontextualisation, modules 6 et 7

- **Module 5 : dois-je corriger ?**

- Oui : analyse morphologique 6 → détection 7 (faute, emprunt, néologisme)
- Si encore inconnu → « étranger »

- **Prétraitements → correction**



# Conclusion

- **User-Generated Content et TAL : outils mal adaptés**
- **Besoin de normalisation et correction**
- **Danger : sur-correction**
- **Module détection mots absents dictionnaire de réf.**
- **Résultat satisfaisants : >90% bonne classification**
  - Sans contexte !

# Perspectives

- **Autres modules de prétraitement**
  - Analyseur morphologique
    - Déterminer nature de ces termes



**Merci de votre  
attention !**