

Création d'un étiqueteur automatique pour la détection d'expressions polylexicales

Manon Scholivet
Mémoire encadré par Carlos Ramisch

15 janvier 2018

Plan

- 1 Introduction
 - Choix de la méthode
- 2 Les problématiques
- 3 Cadre expérimental
- 4 Contributions
- 5 Conclusions

Détection des expressions polylexicales (MWEs)

Approches existantes

- Dictionnaires
- Analyseur syntaxique
- Apprentissage de modèles de séquence
 - Requier peu d'annotations
 - Peu de contraintes sur la structure
 - Approche indépendante de la langue

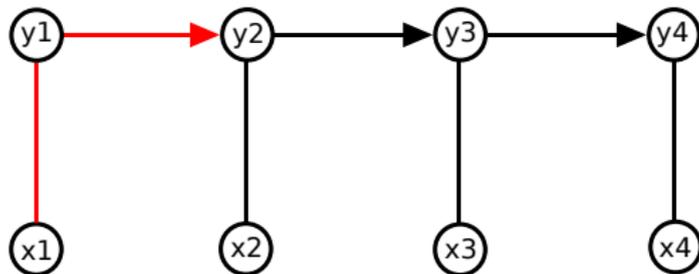
i:	1	2	3	4	5
w _i :	<i>Le</i>	<i>français</i>	<i>défend</i>	<i>ses</i>	<i>couleurs</i>
MWE:	O	O	B1	O	I1

Plan

- 1 Introduction
- 2 Les problématiques**
- 3 Cadre expérimental
- 4 Contributions
- 5 Conclusions

Les *Conditional random fields* (CRF)

- Apprennent une fonction f qui prédit une étiquette y_t en fonction des traits $r(x_t)$ de l'entrée x_t et de l'étiquette précédente y_{t-1}
 - $y_t = f(r(x_t), y_{t-1})$



Obstacles

- Dépendances lointaines pas prises en compte :
*Il fera cet après-midi une belle **présentation***
- Pas de généralisation sur les mots ayant un sens proche :
*Faire un/une **présentation/discours/intervention***

Obstacles/Solutions

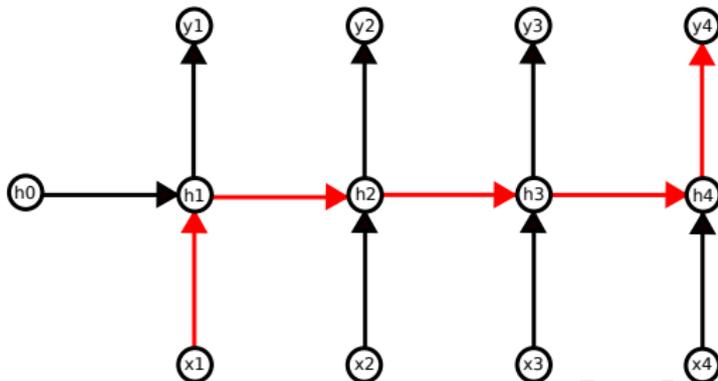
- Dépendances lointaines pas prises en compte :
*Il fera cet après-midi une belle **présentation***
→ Réseaux de neurones récurrents (RNN)
- Pas de généralisation sur les mots ayant un sens proche :
*Faire un/une **présentation/discours/intervention***

Obstacles/Solutions

- Dépendances lointaines pas prises en compte :
*Il fera cet après-midi une belle **présentation***
→ Réseaux de neurones récurrents (RNN)
- Pas de généralisation sur les mots ayant un sens proche :
*Faire un/une **présentation/discours/intervention***
→ Word embeddings

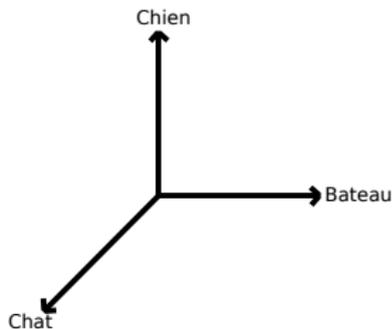
Les réseaux de neurones récurrents (RNN)

- Résolvent le problème des dépendances lointaines
- Apprennent une fonction qui prédit une étiquette y_t en fonction d'un état caché h_t , lui-même dépendant des entrées $r(x_t)$ et de h_{t-1}
 - $h_0 = 0$
 - $h_t = f(r(x_t), h_{t-1})$
 - $y_t = g(h_t)$

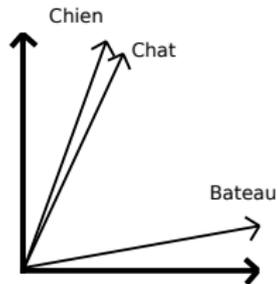


Les *Word Embeddings*

→ Résolvent le problème de la généralisation sur les mots de sens proche



One-hot



Word Embeddings

- Apprentissage par le RNN
- Pré-apprentissage externe

"You shall know a word by the company it keeps" (Firth, 1957)

Plan

- 1 Introduction
- 2 Les problématiques
- 3 Cadre expérimental**
- 4 Contributions
- 5 Conclusions

Description du système proposé

- Chaque phrase standardisée à 128 éléments
 - Deux entrées : les POS et les lemmes
 - Couches d'embeddings, 64 neurones par défaut
 - Concaténation des deux couches d'embeddings
 - 2 couches de GRU bidirectionnelles
 - Couche dense
 - Couche d'activation softmax
- Grande variabilité des modèles produits. Vote majoritaire sur une vingtaine de modèles pour obtenir un unique résultat plus stable.

Corpus

- Corpus PARSEME, Campagne d'évaluation 2017 (français) :

	Train	Test
Nb. phrases	17 880	1 667
Nb. MWEs	4 462	500

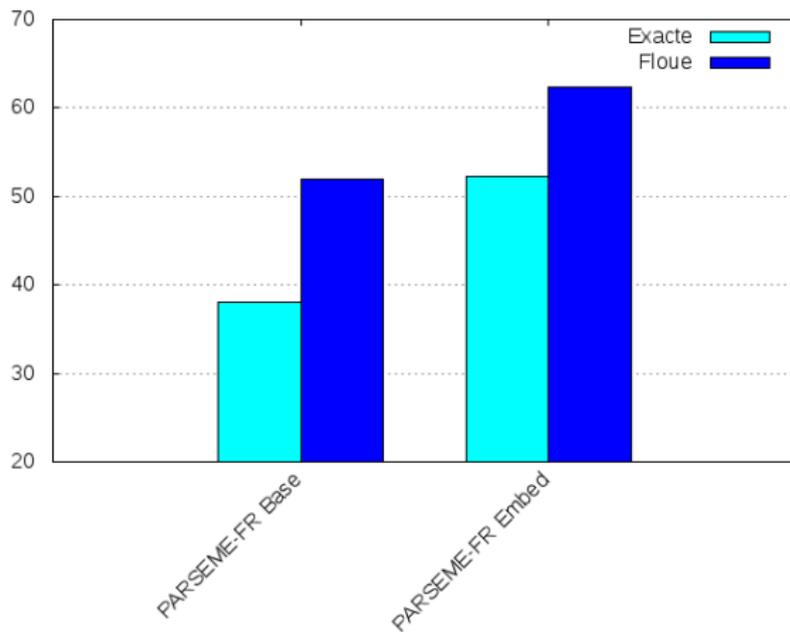
Plan

- 1 Introduction
- 2 Les problématiques
- 3 Cadre expérimental
- 4 Contributions**
 - Hypothèses
 - Résultats
 - Analyse d'erreur
- 5 Conclusions

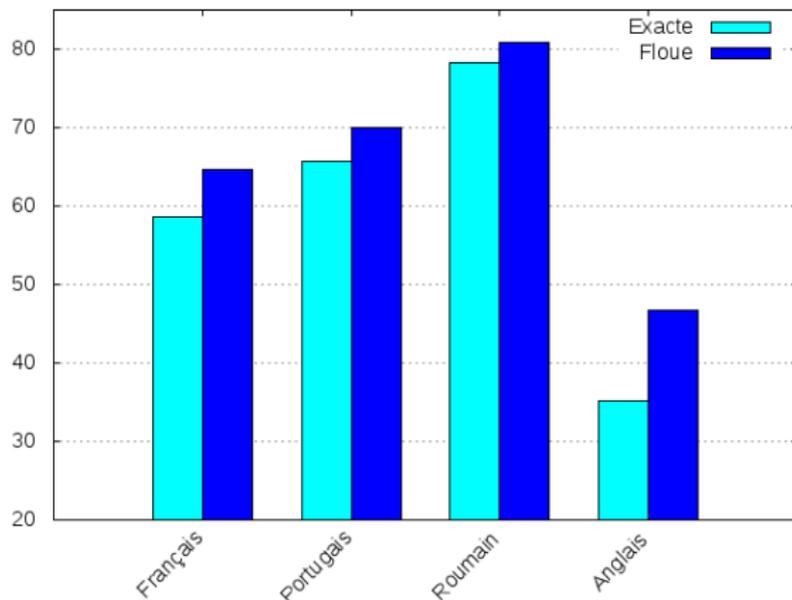
Hypothèses

- Comment la pré-initialisation des embeddings influence les performances ?
- Est-ce que le système est indépendant de la langue ?
- Quelles sont les performances de notre RNN comparées à d'autres systèmes ?
- Le RNN prend t-il mieux en compte :
 - l'historique lointain ? (*gestion des discontinuités*)
 - la variabilité des MWEs ?
 - les nouvelles MWEs ?

Pré-initialisation des embeddings



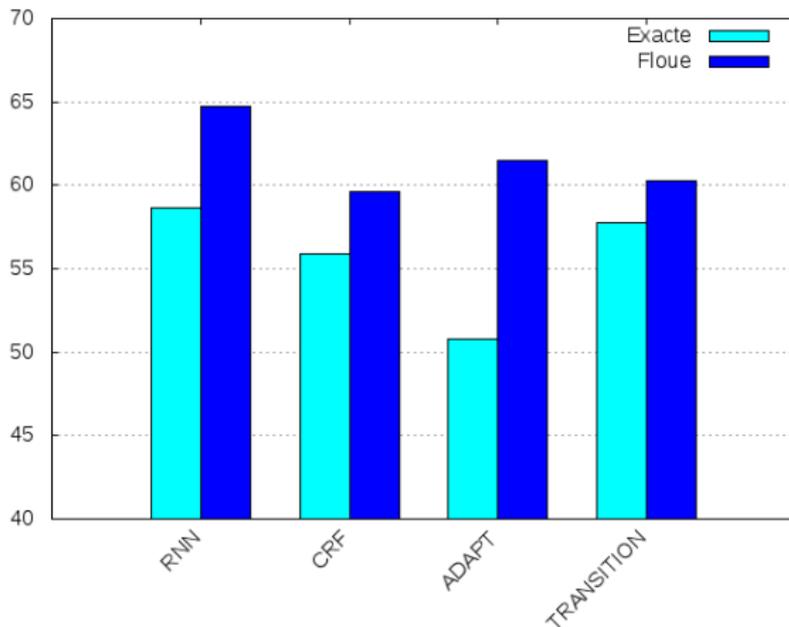
Modèle indépendant de la langue



→ Meilleurs résultats de la campagne d'évaluation :

- Portugais :
67,33% Exacte,
70,94% Floue
- Roumain :
77,21% Exacte,
83,58% Floue
- Anglais :
57,24% Floue

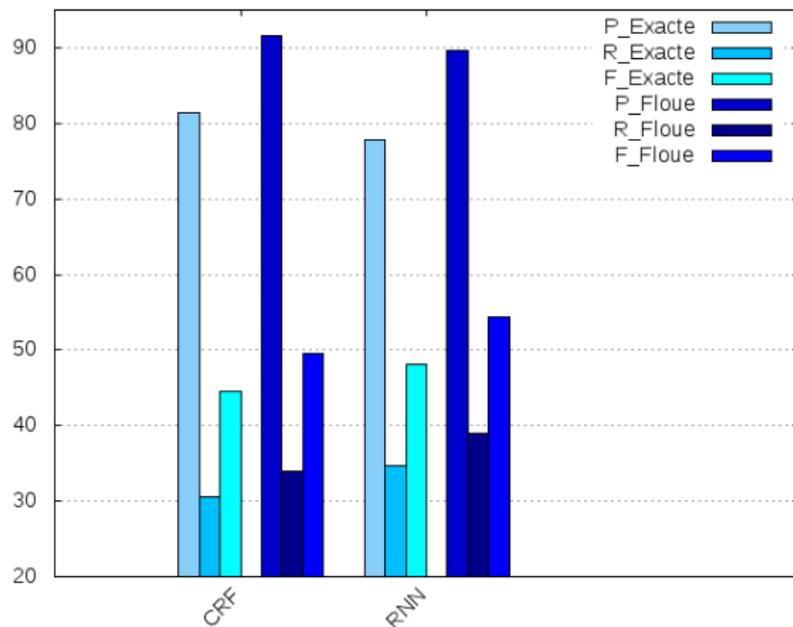
Comparaison avec d'autres systèmes sur PARSEME-FR



Études de phénomènes spécifiques

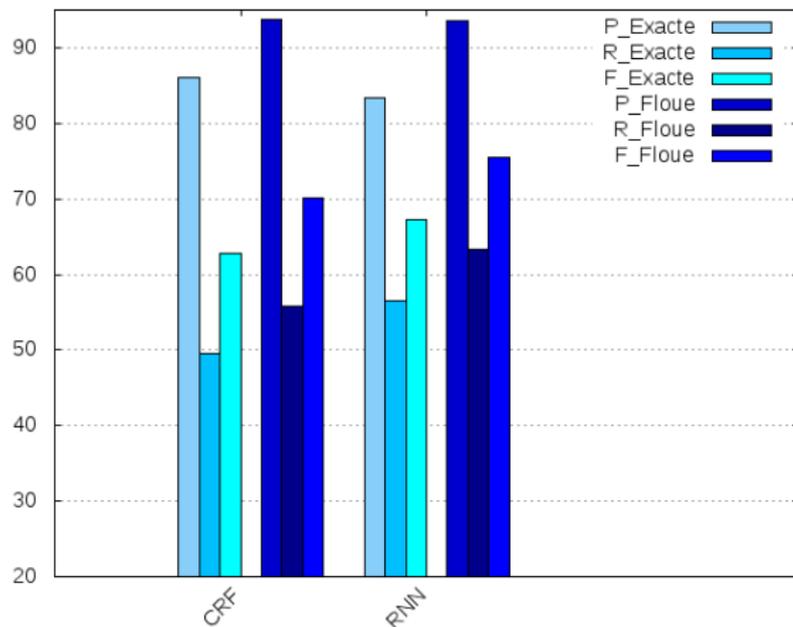
- Création de sous-corpus avec forte densité de :
 - MWEs discontinues (89.81%)
 - MWEs variables (82.80%)
 - MWEs jamais vues (88.00%)

Gestion des MWEs discontinues



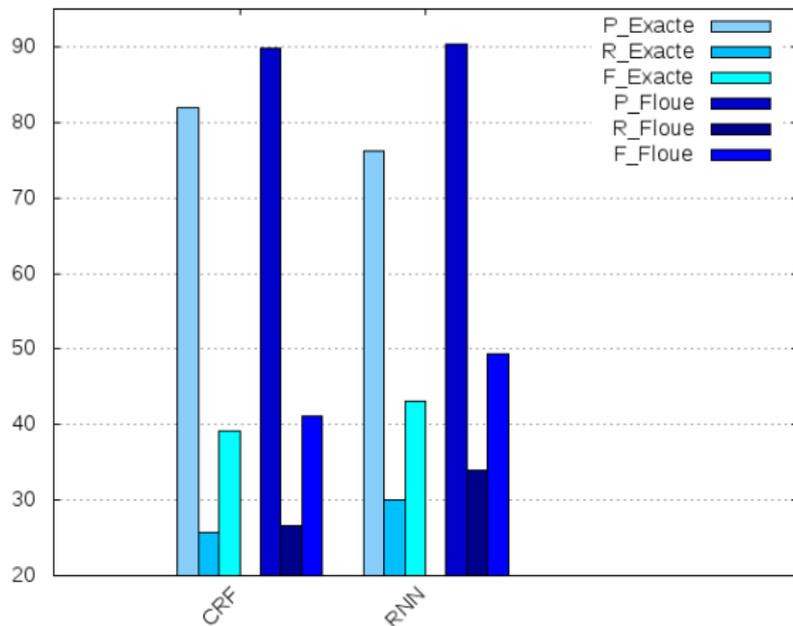
		CRF	RNN
Ex	P	81.36	77.86
	R	30.57	34.71
	F	44.44	48.02
Fl	P	91.67	89.56
	R	33.92	39.06
	F	49.52	54.40

Gestion de la variabilité des MWEs



		CRF	RNN
Ex	P	85.98	83.33
	R	49.46	62.80
	F	56.45	67.31
Fl	P	93.83	93.48
	R	55.88	63.24
	F	70.05	75.44

Gestion des nouvelles MWEs



		CRF	RNN
Ex	P	81.91	76.27
	R	25.67	30.00
	F	39.09	43.06
Fl	P	89.85	90.36
	R	26.70	33.94
	F	41.16	49.34

Les MWEs jamais vues

- *"La musique n'adoucit pas toujours les moeurs."*
 - Aucun de nos systèmes ne détecte cette MWE
- *"... M. Soyer a **fait l'historique** de l'école maternelle ..."*
 - Le RNN le détecte, le CRF non
- *"... chacun ne rêvait que de **remettre la main à la pâte** avec Sylvie et Daniel."*
 - Le RNN détecte une partie de la MWE, le CRF aucune

Les MWEs déjà vues

- "*Une **réflexion** commune est **menée** avec les enseignants ...*"
 - Corpus d'entraînement : "*Nous n'avons **mené** aucune **réflexion** sur le sujet*"
 - Le RNN détecte la MWE, le CRF non
- "*... elle descendait seule **faire** ses **courses** en centre ville, et **prenait** alors **plaisir** à **faire** un brin de **causette** avec ses copines ...*"
 - 1^{ère} MWE détectée par le CRF, mais mal détectée par le RNN
 - 2^{ème} MWE détectée par les deux systèmes
 - 3^{ème} MWE n'est détectée par aucun système

Plan

- 1 Introduction
- 2 Les problématiques
- 3 Cadre expérimental
- 4 Contributions
- 5 Conclusions**

Perspectives

- Gestion des chevauchements
 - Elle **fera un discours et un hommage** aux bénévoles
 - Utiliser un nouveau système d'étiquettes (ex. *pointer networks*)
- Rareté des données annotées, traitement de nouvelles langues
 - Projet de thèse sur des modèles profondément multilingues

Merci pour votre écoute !

Table – Détails des résultats des analyses d'erreurs

		Exacte			Floue		
		P	R	F	P	R	F
CRF	Complet	80.45	42.80	55.87	86.45	45.49	59.61
	Disc	81.36	30.57	44.44	91.67	33.92	49.52
	Variab	85.98	49.46	62.80	93.83	55.88	70.05
	US	81.91	25.67	39.09	89.85	26.70	41.16
RNN	Complet	75.24	48.00	58.61	84.67	52.35	64.70
	Disc	77.86	34.71	48.02	89.56	39.06	54.40
	Variab	83.33	56.45	67.31	93.48	63.24	75.44
	US	76.27	30.00	43.06	90.36	33.94	49.34

Table – Détails de la construction des sous corpus

	Disc		Variab		Unseen	
	Nb	% ss-corpus	Nb	% ss-corpus	Nb	% ss-corpus
FR	280	89.81	154	82.80	264	88.00
RO	170	88.08	62	73.81	41	73.21
PT	225	88.93	201	87.39	165	91.67