



spaCy (v2.1.0)

	Outil de traitement automatique du langage naturel	
	Système d'exploitation :	Multiplateforme
	Développé par :	Explosion AI
Open source, MIT	Personne de contact :	katy.fokou@smals.be

Fonctionnalités

spaCy est un outil de traitement automatique du langage naturel (NLP) basé sur le langage de programmation Python. Il est construit pour une application pratique du NLP, notamment pour des tâches telles que l'[étiquetage morpho-syntaxique](#) (POS tag), la [reconnaissance d'entités](#) (NER) ou l'[analyse syntaxique](#) (parser).



spaCy supporte 8 langues (modèles) et pour chaque langue, spaCy propose des modèles statistiques permettant d'exécuter un pipeline comprenant en natif les fonctionnalités linguistiques suivantes : POS tagger, parser et NER. À ce pipeline peut s'ajouter un élément de classification de textes. Chaque élément peut être facilement activé et désactivé selon les besoins. Le module statistique NER standard reconnaît jusqu'à 18 entités pour l'anglais et 4 pour le néerlandais et le français (PER, ORG, MISC, LOC). En plus des modèles statistiques, spaCy propose des fonctionnalités de *matching* similaires aux expressions régulières et une fonction de calcul de similarité sémantique.

Les modèles natifs peuvent être enrichis de plusieurs manières, en modifiant le *tokenizer*, en ré-entraînant le *tagger*, *parser* et *NER* ou en ajoutant de nouvelles entités basées sur des règles prédéfinies. Il est aussi possible de développer un nouveau modèle « from scratch ».

Notons aussi que spaCy dispose d'un outil de visualisation des entités et de dépendances : displaCy. Les résultats sont disponibles via un serveur web ou dans [Jupyter notebook](#) et s'intègrent aussi bien à une application web.


Conclusions & Recommandations

spaCy est une librairie simple d'utilisation pour des utilisateurs familiers avec le langage Python. Une des qualités de cet outil vient de sa modularité ; il est facile d'ajouter et/ou de modifier des composants du pipeline. C'est aussi un outil rapide et performant, orienté vers la production qui s'intègre parfaitement avec d'autres outils de NLP/machine learning, on le recommande donc pour du NLP.

Tests et Résultats

La majorité des tests effectués ci-après portent sur des documents juridiques en néerlandais, une langue pour laquelle les modèles ne sont pas toujours disponibles ou alors sont peu précis.

Parsing et tagging : le *parsing* et le *tagging* se font de façon correcte et peuvent être visualisés avec displaCy.



Customisation du modèle - ajout d'un modèle de NER basé sur des règles prédéfinies : spaCy permet d'ajouter de nouvelles entités au composant NER existant ; de façon relativement simple et complémentaire au NER statistique en utilisant des règles ou *pattern* pour détecter les entités. Dans l'exemple ci-dessous, une entité « KAMER » a été ajoutée au modèle existant. Pour cela on définit une règle qui sera appliquée dans le pipeline après le NER statistique.

gedeeltelijk vernietigde arrest. Houdt de kosten aan en laat de beslissing daaromtrent aan de feitenrechter over. Verwijst de aldus beperkte zaak naar het arbeidshof te **Brussel Loc** . 28 maart 2011 – 3^e kamer **KAMER** – **Voorzitter Loc** en verslaggever: **C. Storck PER** , voorzitter – **Gelijkkluidende PER** conclusie: **M. Palumbo PER** , advocaat-generaal met opdracht – **Advocaat PER** : **J. Oosterbosch PER** .

Customisation du modèle - ajout d'une nouvelle entité au modèle statistique : dans certaines situations, les règles pour l'extraction de nouvelles entités sont difficiles à définir et on préfère utiliser du *machine learning* pour apprendre au modèle à reconnaître l'entité. Dans l'exemple ci-dessous, un modèle NER est entraîné à extraire des articles de lois d'un document juridique à partir de 25 données de *training*.

onderdeel 1. **Artikel 1017, eerste lid, Gerechtelijk Wetboek bepaalt dat, tenzij LAW** bijzondere wetten anders bepalen, ieder eindvonnis, zelfs ambtshalve, de in het ongelijk gestelde partij in de kosten verwijst, onverminderd de overeenkomst tussen partijen, die het eventueel bekrachtigt. Krachtens **artikel 1017, vierde lid, Gerechtelijk Wetboek kunnen de kosten worden omgeslagen zoals de rechter het raadzaam oordeelt, hetzij wanneer de partijen onderscheidenlijk omtrent enig geschilpunt in het ongelijk zijn gesteld, hetzij over echtgenoten, bloedverwanten in de opgaande lijn, broeders en zusters of aanverwanten in dezelfde graad. LAW** Krachtens **artikel 1018, eerste lid, 6°, Gerechtelijk Wetboek omvatten de kosten de rechtsplegingsvergoeding zoals bepaald in artikel 1022 Gerechtelijk Wetboek. LAW** Volgens **artikel 1022, eerste lid, Gerechtelijk Wetboek, is de rechtsplegingsvergoeding een forfaitaire tegemoetkoming in**

Le modèle détecte correctement les articles de loi présents dans le texte mais considère toute la phrase comme entité. Ceci est en parti du à la façon dont sont définies les données de training.

Customisation du modèle - ajout d'un classificateur : le modèle entraîné sur un set de seulement 300 textes avec le composant «TextCategorizer» de spaCy s'est avéré moins performant qu'un modèle SVM entraîné sur les même données. Ceci est probablement dû au fait que spaCy utilise le deep learning.

Calcul de similarité entre documents : le calcul de similarité se fait sur base de la mesure du cosinus entre les vecteurs. Pour certaines langues, spaCy propose des modèles avec vecteurs et sans vecteurs (ou plutôt avec des pseudo vecteurs). Les tests effectués sur des documents en français ont révélé que les mesures de similarité étaient plus cohérentes avec le modèle sans vecteurs qu'avec le modèle avec vecteurs inclus.

Conditions d'utilisation & Budget

spaCy est une librairie gratuite et sous licence MIT, à utiliser dans un environnement Python