



Extraction d'information à partir de textes

Robert Bossy & Claire Nédellec
MalAGE, Jouy-en-Josas



ANF 2021, 17 novembre 2021

Des analyses numériques de documents complémentaires

Besoin précis → Extraction d'information,
traitement automatique de la langue (TAL)



On sait modéliser ce que l'on cherche et on peut cibler l'information à extraire

Besoin exploratoire → Fouille et découverte de connaissances

On ne sait pas caractériser a priori les connaissances que l'on va dériver du corpus de textes et de données collecté



Extraction d'information et de
connaissance - partage et réutilisation



Notion de référentiel commun



Extraction automatique d'information : identifier, typer et relier les entités




Texte



Texte annoté par des entités et par des relations

- Les entités de type **microbe**, **habitat** et **lieu géographique**
- Reliés par des relations orientées **vit-dans**, **localisée-à**

Textes de documents




Représentation formelle de l'information

Extraction automatique d'information

Transforme une donnée non structurée, du texte en donnée structurée manipulable par un ordinateur


Schéma d'annotation des informations




Les champs du formulaire correspondent au schéma des données

Schéma des données, entité - relation

- En général, des relations binaires entre deux entités
- Orientées
- Les arguments de la relation sont typés





Extraction automatique d'information et de connaissances *Partage et réutilisation*

L'extraction d'information transforme
des données en information


Partager l'information nécessite
un référentiel de connaissance commun
et de relier l'information aux connaissances connues

Données, informations, connaissances

Données. Eléments discrets, nombres, bases de données, texte


Informations. Données filtrées, contextualisées, interprétées et reliées localement à l'aide de la connaissance de façon à être réutilisables

Connaissances. Informations organisées, synthétisées et reliées à un modèle de connaissance : un système uniifié de définitions formelles et de principes fondamentaux, pour la compréhension partagée et des traitements fiables (*sémantique formelle*)



Référentiels


D'après Sophie Aubin



Termino-ontologie

Chaque concept est
Relié à ses **parents** (concepts plus généraux)
Relié à ses **descendants**
(concepts plus spécifiques)
Relié à d'autres concepts par des **relations spécialisées**

Il est associé à
des informations terminologiques, label, synonyme
Éventuellement, les sens et usages du terme



Extraction d'information pour des bases de connaissance intégrées

Objectif


Centraliser, structurer et standardiser l'information
Pour en faciliter l'accès et l'utilisation

Données en **texte libre nombreuses**


Les structurer pour les combiner à d'autres données

- Déetecter les informations
 - Les associer à une référence partagée (ontologie)
 - Les relier entre elles
 - Les mettre à disposition

Par des méthodes de *text mining*



Formaliser l'association entre données du texte et référentiels





Extraction automatique
d'information basée sur des
ontologies

L'extraction
d'information
contribue aux principes



INRAE
Extraction d'information,
Robert Bossy & Claire Nédellec



[Nédellec et al., EGC 2019]
AgroPortal ONTOBIOTOPE

Méta données des documents

Index MeSH thématique global au document

PMID- 19329624
TI - *Salinivibrio siamensis* sp. nov., from fermented fish (pla-ra) in Thailand.
LID - 10.1099/ijis.0.001768-0 [doi]
AB - A Gram-negative, facultatively anaerobic, moderately halophilic bacterium, strain ND1-1(T), was isolated from fermented fish (pla-ra) in Thailand. The cells were curved rods, motile and non-endospore-forming. The novel strain grew optimally at 37 degrees C, at pH 8 and in the presence of 9-10 % (w/v) NaCl. [...] Comparative 16S rRNA gene sequence analyses indicated that strain ND1-1(T) was closely related to *Salinivibrio costicola*, which comprises three subspecies, and *Salinivibrio proteolyticus* with gene sequence similarities of 98.3-98.6 %. [...] On the basis of the physiological and biochemical characteristics and the molecular data presented, strain ND1-1(T) should be classified as a novel species of the genus *Salinivibrio* for which the name *Salinivibrio siamensis* sp. nov. is proposed. The type strain is ND1-1(T) (=JCM 14472(T)=PCU 301(T)=TISTR 1810(T)).

FAU - Chamroensaksri, Nitcha
AD - Department of Microbiology, Faculty of Pharmaceutical Sciences, Chulalongkorn University, Bangkok 10330, Thailand.
FAU - Tanasupawat, Somboon
FAU - Akaracharanya, Ancharith
FAU - Visessanguan, Wonnop
FAU - Kudo, Takuji
FAU - Itoh, Takashi
LA - eng
PT - Journal Article
TA - Int J Syst Evol Microbiol
JT - International journal of systematic and evolutionary microbiology
MH - Fishes/*microbiology
MH - *Food Microbiology
MH - Phylogeny
MH - RNA, Ribosomal, 16S/genetics
MH - Sequence Analysis, DNA
MH - Temperature
MH - Thailand
SO - Int J Syst Evol Microbiol. 2009 Apr;59(Pt 4):880-5. doi: 10.1099/ijis.0.001768-0.

Des entités emboitées, discontinues

Métagdonnées locales des informations extraites du document

| Entités de type Habitat | | Position | Longueur |
|-------------------------|----------------|----------|----------|
| Id | Forme | | |
| 1 | Fermented fish | 73 | 12 |
| 2 | pla-ra | 87 | 6 |
| ... | | | |

| Entités de type Taxon | |
|-----------------------|-------|
| 3 | ND1-1 |

| Entités de type Géo | |
|---------------------|----------|
| 4 | Thailand |

| Type | Argument 1 | Argument 2 |
|------------|------------|------------|
| Located at | 3 | 4 |

Types et classes d'entités en extraction d'information

1. La reconnaissance d'entité nommée associe un type général aux entités reconnues

Date, lieu, personne

Microbe, habitat, maladie, symptôme, organe

Entreprise, fonction

2. La normalisation associe aux entités un nom standard provenant d'un référentiel

Microbe: nom scientifique


Molécule : nom de la molécule dans le référentiel (ex CheBI)

3. L'annotation sémantique associe aux entités une catégorie d'un référentiel, un concept précis de l'ontologie


Microbe: taxon dans la taxinomie (ex NCBI)

Maladie : nom de la maladie dans la classification (ex CIM-10)

2. Normalisation et référentiel : associer un nom standard aux formes « figées »



L'annotation sémantique associe aux entités du texte *une catégorie précise et des relations du référentiel*



Différents référentiels pour différents types d'entités et de relations

Le schéma d'annotation des données du texte peut faire référence à des **référentiels distincts** :

nomenclatures, dictionnaires, thesaurus, ontologies

Dans **l'exemple**


Une taxinomie : *NCBI Taxonomy*

Une nomenclature : *GeoNames*

Une ontologie : *OntoBiotope*

Des relations externes

Différents types de référentiels pour différents niveaux de standardisation et d'expressivité



Exemple de schéma d'annotation entité – relation et référentiels associés

p. 17

Méta données des documents

Index MeSH thématique global au document

PMID- 19329624
TI - *Salinivibrio siamensis* sp. nov., from fermented fish (pla-ra) in Thailand.
LID - 10.1099/ijc.0.001768-0 [doi]
AB - A Gram-negative, facultatively anaerobic, moderately halophilic bacterium, strain ND1-1(T), was isolated from fermented fish (pla-ra) in Thailand. The cells were curved rods, motile and non-endospore-forming. The novel strain grew optimally at 37 degrees C, at pH 8 and in the presence of 9-10 % (w/v) NaCl. [...] Comparative 16S rRNA gene sequence analyses indicated that strain ND1-1(T) was closely related to *Salinivibrio costicola*, which comprises three subspecies, and *Salinivibrio proteolyticus* with gene sequence similarities of 98.3-98.6 %. [...] On the basis of the physiological and biochemical characteristics and the molecular data presented, strain ND1-1(T) should be classified as a novel species of the genus *Salinivibrio* for which the name *Salinivibrio siamensis* sp. nov. is proposed. The type strain is ND1-1(T) (=JCM 14472(T)=PCU 301(T)=TISTR 1810(T)).

FAU - Chamroensaksri, Nitcha
AD - Department of Microbiology, Faculty of Pharmaceutical Sciences, Chulalongkorn University, Bangkok 10330, Thailand.
FAU - Tanasupawat, Somboon
FAU - Akaracharanya, Anchalda
FAU - Visessanguan, Wonnop
FAU - Kudo, Takuji
FAU - Itoh, Takashi
LA - eng
PT - Journal Article
TA - Int J Syst Evol Microbiol
JT - International Journal of systematic and evolutionary microbiology
MH - Fishes/*microbiology
MH - *Food Microbiology
MH - Phylogeny
MH - RNA, Ribosomal, 16S/genetics
MH - Sequence Analysis, DNA
MH - Temperature
MH - Thailand
SO - Int J Syst Evol Microbiol. 2009 Apr;59(Pt 4):880-5. doi: 10.1099/ijc.0.001768-0.

Des entités emboitées, discontinues

Métagdonnées locales des informations extraites du document

| Entités de type Habitat | | Forme |
|-------------------------|----------------------------|------------------------|
| Id | Classe | |
| 1 | OBT:Fermented fish product | Fermented fish product |
| 2 | OBT:Fermented fish product | pla-ra |
| ... | | |
| Entités de type Taxon | | |
| 3 | NCBI tax :ND1-1 | ND1-1 |
| Entités de type Géo | | |
| 4 | Geonames:Thailand | Thailand |
| Relation | | |
| Type | Argument 1 | Argument 2 |
| Located at | 3 | 4 |

Que faire en recherche documentaire en fonction du référentiel

1. La reconnaissance d'entité nommée associe un type général aux entités reconnues

Retrouver tous les documents qui mentionnent un type d'entité

Produire la liste des entités dans un ensemble de documents

Ex. Trouver tous les documents qui mentionnent une maladie,

Ex. Identifier toutes les expressions du texte qui dénotent des maladies

2. La normalisation associe aux entités un nom standard provenant d'un référentiel

Retrouver précisément les données ou documents contenant une entité étant donné son nom,

Indépendamment des variations

Ex. Trouver tous les documents qui mentionnent la bactérie Salinivibrio siamensis

3. L'annotation sémantique associe aux entités une catégorie précise de l'ontologie

Retrouver des données ou documents contenant une entité, à différents niveaux de généralité

Sans connaître son nom

Ex. Trouver tous les documents qui mentionnent des types d'habitat, par exemple, des aliments




Aperçu des méthodes d'extraction d'information



Projection de lexiques

Rechercher dans le texte des fragments identiques à des entrées dans une liste préétablie de formes connues.



- Exploitation de ressources existantes : *gazetteers*, glossaires, annuaires, terminologies, ontologies, etc.
- Approche simple pour la reconnaissance d'entités, voire l'annotation sémantique si les étiquettes sont associées à un identifiant.

Limites

- Silence sur les entités hors-nomenclature.
- Peu robuste aux variations typographiques ou aux variations de langage.
- Entrées ambiguës.

Capture des variations

Saturation automatique des lexiques pour les abréviations.

| | | |
|------------------------|---|------------------|
| Escherichia coli | → | E. coli |
| Klebsiella pneumoniae | → | K. pneumoniae |
| Pseudomonas aeruginosa | → | P. aeruginosa |
| Streptococcus aureus | → | S. aureus |
| Listeria monocytogenes | → | L. monocytogenes |

Recovery of Gram-Negative **Bacteria** from Aerobic Blood Culture Bottles Containing Antibiotic Binding Resins after Exposure to β -Lactam and Fluoroquinolone Concentrations.

1.4142135

Authors: Iris H Chen David P Nicolau Joseph L Kuti

2019 *Journal of clinical microbiology*

Abstract Blood culture bottles containing antibiotic binding resins are routinely used to minimize artificial sterilization in the presence of antibiotics. However, the resin binding kinetics can differ between antibiotics and concentrations. This study assessed the impact of clinically meaningful peak, midpoint, and trough concentrations of meropenem, imipenem, cefepime, cefazolin, levofloxacin, and piperacillin-tazobactam on the recovery of **Pseudomonas aeruginosa**, **Escherichia coli**, and **Klebsiella pneumoniae** from resin-containing BacT/Alert FA Plus and Bactec Aerobic/F blood culture bottles. **P. aeruginosa**-inoculated bottles alarmed positive in 4/20 (20%), 16/20 (80%), and 20/20 (100%) of those with peak, midpoint, and trough concentrations of antipseudomonal agents, respectively ($P \leq 0.001$). **E. coli** was recovered from 8/24 (33%), 11/24 (46%), and 14/24 (58%) of bottles with peak, midpoint, and trough concentrations, respectively ($P = 0.221$). **K. pneumoniae** was recovered from 8/16 (50%) at all concentrations of the studied antibiotics ($P = 1.0$). Bact/Alert and Bactec bottles inoculated with antibiotics and **P. aeruginosa** had similar times to detection (TTD) ($P = 0.352$); however, antibiotic-containing BacT/Alert bottles had a shorter TTD compared with antibiotic-containing Bactec bottles for **E. coli** ($P = 0.026$) and **K. pneumoniae** ($P \leq 0.001$). Pathogen recovery in BacT/Alert FA Plus and Bactec Aerobic/F blood culture bottles containing antibiotic binding resins was greatly reduced in the presence of antibiotics, especially at higher concentrations. These data support the practice of drawing blood cultures immediately before an antibiotic dose to maximize the chances of pathogen recovery.

Lemmatisation pour les flexions.

| | | |
|--------|---|-------|
| plants | → | plant |
| plant | → | plant |
| Plant | → | plant |
| PLANT | → | plant |

Comparison of microbial and transient expression (tobacco plants and **plant-cell packs**) for the production and purification of the anticancer mistletoe lectin viscumin.

1.4142135

Authors: Benjamin B Gengenbach Linda L Keil Patrick Opdensteinen Catherine R Müschen Georg Melmer Hans Lentzen Jens Bührmann Johannes F Buyel

2019 *Biotechnology and bioengineering*

Abstract Cancer is the leading cause of death in industrialized countries. Cancer therapy often involves monoclonal antibodies or small-molecule drugs, but carbohydrate-binding lectins such as mistletoe (*Viscum album*) viscumin offer a potential alternative treatment strategy. Viscumin is toxic in mammalian cells, ruling them out as an efficient production system, and it forms inclusion bodies in *Escherichia coli* such that purification requires complex and lengthy refolding steps. We therefore investigated the transient expression of viscumin in intact *Nicotiana benthamiana* **plants** and *Nicotiana tabacum* Bright Yellow 2 **plant-cell packs** (PCPs), comparing a full-length viscumin gene construct to separate constructs for the A and B chains. As determined by capillary electrophoresis the maximum yield of purified heterodimeric viscumin in *N. benthamiana* was ~ 7 mg/kg fresh biomass with the full-length construct. The yield was about 50% higher in PCPs but reduced 10-fold when coexpressing A and B chains as individual polypeptides. Using a single-step lactosyl-Sepharose affinity resin, we purified viscumin to $\sim 54\%$. The absence of refolding steps resulted in estimated cost savings of more than 80% when transient expression in tobacco was compared with *E. coli*. Furthermore, the **plant**-derived product was ~ 3 -fold more toxic than the bacterially produced counterpart. We conclude that **plants** offer a suitable alternative for the production of complex biopharmaceutical proteins that are toxic to mammalian cells and that form inclusion bodies in bacteria.

INRAE

Extraction d'information, ANF nov 2021


Robert Bossy & Claire Nédellec

p. 22

Formes ambiguës

Sources d'ambiguïté

- homonymie
- métonymie
- polysémie



Désambiguïsation par le contexte

Identifier des mots dans le contexte qui permettront de discriminer entre plusieurs sens.

Par exemple : *plant/factory* et *plant/organisme* ?

| | |
|---|-------------------------------------|
| new strains can be rapidly implemented into existing infrastructures such as <u>bioethanol production</u> | plants |
| Evaluation of methanogenic activity of <u>biogas</u> | plant slurry |
| two reference points (indoor and outdoor) that are assumed not to be <u>contaminated</u> by the | plant 's activities |
| a phage can survive in a <u>cheese</u> | plant for more than a year |
| The first large-scale <u>biogas</u> | plant was put into operation |

| | |
|---|---|
| a problem that is present in the transformation of all | plant <u>species</u> |
| The tendency of closely related | plant <u>species</u> to share natural enemies |
| Rhizosphere is the complex place of numerous interactions between | plant <u>roots</u> , microbes and soil fauna |
| an appropriate method of transgene introduction into a | plant <u>cell</u> |
| common mechanisms for | plant <u>cell</u> reprogramming during endosymbiosis |

Exploitation du contexte par des règles d'extraction

Il existe des outils qui permettent d'exprimer des règles de désambiguïsation selon les mots du contexte.

("biogas" ou <nourriture>) "plant" → étiqueter "plant" comme une usine.

"plant" ("species" ou "cell") → étiqueter "plant" comme une plante.

Les mêmes types de règles peuvent servir aussi à extraire des relations.

<microorganism> "isolated from" <NOM>

... mycobacteria isolated from seals ...

<microorganism> "isolated from" <DET> <ADJ> <NOM>

... *Mycobacterium malmoense* isolated from soil ...


... *Nocardia africana* isolated from a feline mycetoma ...

Limites

- La performance des règles dépend des types d'entités ou de relation, des domaines, et du genre des documents.
- La qualité dépend de la variabilité d'expression dans les documents.
- La maintenance d'un système basé sur des règles écrites à la main peut être coûteuse à maintenir.

Apprentissage supervisé

Les algorithmes d'apprentissage supervisé induisent des règles à partir d'exemples étiquetés.




1. Phase d'apprentissage

- Lors de la phase d'apprentissage, l'algorithme induit un modèle à partir d'exemples annotés par des experts.
- La nature du modèle dépend de l'algorithme utilisé. Ce peuvent être des droites de régression, des arbres de décision, etc.

Apprentissage supervisé

Les algorithmes d'apprentissage supervisé induisent des règles à partir d'exemples étiquetés.

Abstract The cyanobacterium Planktothrix rubescens Anagnostidis & Komarek (previously Oscillatoria rubescens DC ex Gomont) is present in several Italian lakes and it is known to produce cyanotoxins. The dynamics and toxin production of *P. rubescens* population in Lake Albano, a volcanic crater lake in Central Italy, has been studied for 5 years (January 2001-April 2005). Winter-



Abstract The cyanobacterium **Planktothrix rubescens** Anagnostidis & Komarek (previously **Oscillatoria rubescens** DC ex Gomont) is present in **several Italian lakes** and it is known to produce cyanotoxins. The dynamics and toxin production of **P. rubescens** population in **Lake Albano**, a **volcanic crater lake** in **Central Italy** has been studied for 5 years (January 2001-April 2005). Winter-

Corpus non-annoté

Phase de production

- Lors de la phase d'étiquetage, le modèle sert à annoter automatiquement de nouveaux documents.
- Les erreurs peuvent être quantifiées en appliquant le modèle sur le corpus d'apprentissage.

Modèle

À savoir

- L'élaboration du corpus d'apprentissage représente un effort initial considérable.
- Il existe des corpus d'apprentissage et même des modèles pré-appris pour un certain nombre de types d'annotation.

Corpus annoté automatiquement



Exercice d'annotation



Création d'un corpus d'apprentissage

“Gold Standard”

- Échantillon de documents annotés par des experts afin de représenter formellement le sens du texte.
- Quantité suffisante pour que l'algorithme d'apprentissage opère l'induction et produise des modèles stables.
- La qualité dépend de la conformité de l'annotation au besoin exprimé.

Valorisation

- Un corpus annoté est un jeu de données recherché en TAL (recherche et industrie) car il permet de mettre au point les systèmes d'annotation automatique.
- Communication académique :
 - o organisation d'un “challenge” porté par une conférence ou un workshop (ACL, EMNLP, CLEF, CoNLL, BioNLP),
 - o *Data paper* (Scientific Data, Pensoft, BMC Research Notes),
 - o archives ouvertes (CodaLab, Papers With Code, LREC),
 - o dépôts de code (GitHub, GitLab).



Création d'un corpus d'apprentissage : méthodologie

Intérêts de suivre une méthodologie d'annotation

- Garantir la conformité de l'annotation aux besoins.
- Contrôler l'homogénéité de l'annotation.
- Assurer la reproductibilité du “Gold Standard”.

Éléments de

- Outils d'annotations spécialisés.
- Partage d'un document de spécifications, exemples et arbitrages : “guide d'annotation” (“annotation guidelines”).
- Double annotation de chaque document, éventuellement en double-aveugle.
- Accord Inter-Annotateur : mesure de la variabilité de l'annotation.

Conclusion

Les différentes méthodes ont différentes qualités.

Projection de
lexiques

Application de
règles

Apprentissage
supervisé



INRAE

Extraction d'information, ANF nov 2021

Robert Bossy & Claire Nédellec


Conclusion

Les différentes méthodes ont différentes qualités.




Conclusion

Les différentes méthodes ont différents rôles.



Extraction d'information et applications



Exemples d'applications

Recherche d'information

- Recherche sémantique de documents
- Intégration de données de sources diverses : bibliographie, données expérimentales, données de référence, etc.

Aide à la décision

- Cartographie thématique (synthèse de corpus, tendances)
- Profilage d'experts (par ex. sélection de relecteurs)

Extension de référentiel


- Recherche de nouveaux synonymes ou concepts



Extraction d'information, ANF nov 2021

Robert Bossy & Claire Nédellec

Enrichir une ontologie par de nouvelles classes





Un moteur de recherche sémantique,
AlvisIR





Exercice de recherche d'information



INRAe

