

# Extraction d'Informations pour la biodiversité microbienne

Robert Bossy - DigitBio 2023-01-12

# Informations extraites sur la biodiversité microbienne

## Evaluation of antibacterial activity of synthetic aliphatic and aromatic monoacylglycerols.

The antibacterial activity of synthetic aliphatic and aromatic monoacylglycerols (MAGs) was studied against two **human pathogens**: **Staphylococcus aureus** and **Escherichia coli**. The active compounds inhibited selectively **S. aureus**. The most active compounds amongst them were those with medium size aliphatic chain and aromatic MAGs with electron withdrawing substituents at the aryl ring. The introduction of one or two-carbon spacer between the aryl ring and the carboxylic function did not influence antibacterial effectiveness.

ncbi:562  
**Escherichia coli**

ncbi:1280  
**S. aureus**

obt:002488 <human> obt:000375 <pathogen> ncbi:1280  
**human pathogens**

ncbi:1280  
**Staphylococcus aureus**

### Entités Nommées (REN)

- Taxons microbiens
- Habitats
- Phénotypes

### Normalisation (NEN)

- Taxonomie
- Ontologie des habitats et phénotypes

### Relations (ER)

- <Vit dans>
- <Présente le phénotype>

# Motivations

- Recherche en microbiologie : taxon singulier → études transversales.
- L'expertise sur tous les taxons et tous les milieux de vie est impossible.
- L'information est accessible exclusivement dans des articles ou des champs de bases de données en texte libre.



Image: NCBI 2023

## Questions

- Spectre d'*espèces* connu dans un milieu donné.
- Éventail d'habitats colonisés par un *taxon*.
- Ensemble d'organismes qui vivent dans des *milieux similaires* à ceux d'une *souche* donnée.

# Contenu de cette présentation

- Cheminement qui *nous* a amené à investir ce sujet.
  - Ressources qui ont été nécessaires pour lever les verrous.
1. Analyse du besoin
  2. Acquisition des ressources
  3. Organisation de challenges
  4. Développement de services
  5. Conclusion

# Analyse du besoin

# Demande initiale

*Corrélation entre les protéines de surface et les conditions environnementales chez les bactéries vivant dans l'intestin de mammifères.*

Marteen van de Guchte (2010)

Constat d'un déficit d'informations disponibles :

- Incapacité à lister et distinguer les milieux liés à l'intestin.
- Absence de lexique et de modèle.
- Aucun recensement des bactéries présentes dans l'intestin.



# Généralisation & délimitation

Levures impliquées dans la *fermentation* de *jus végétaux*.

Évolution de la diversité des *champignons* présents dans un *sol*.

*Symbiotes* de la *rhizosphère*.

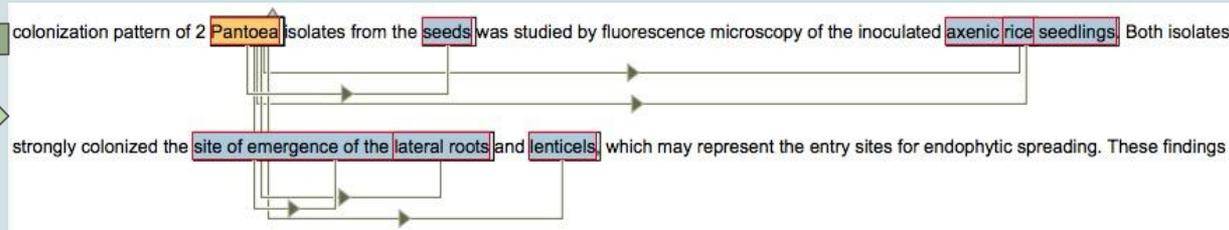
*Insectes* vecteurs de *pathogènes* (*humains* ou *plantes*).

- Intestin → Tous les habitats possibles + phénotypes.
- Bactéries → Tous les microorganismes.
- Protéines de surface → information déjà disponible dans des bases de données.

# Méthodologie

Itérations successives d'analyse partagée de textes.  
Le texte comme objet de frontière (*boundary object*).

Microbiologistes



“Nous”

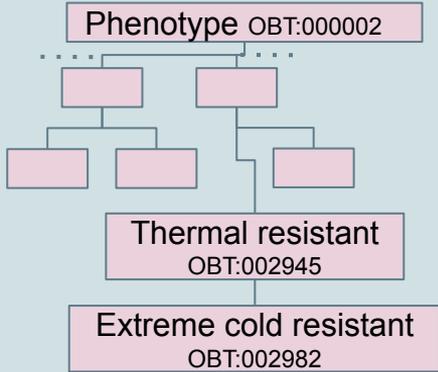
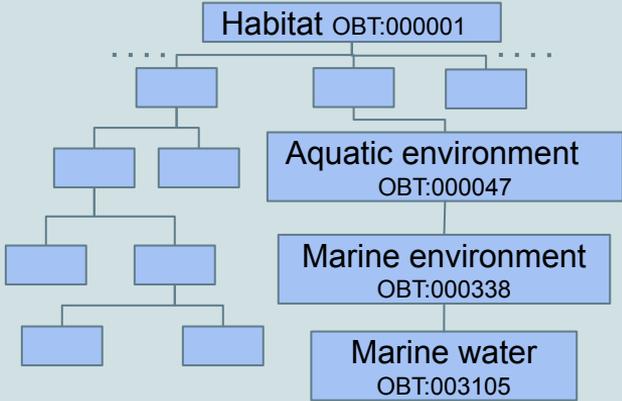
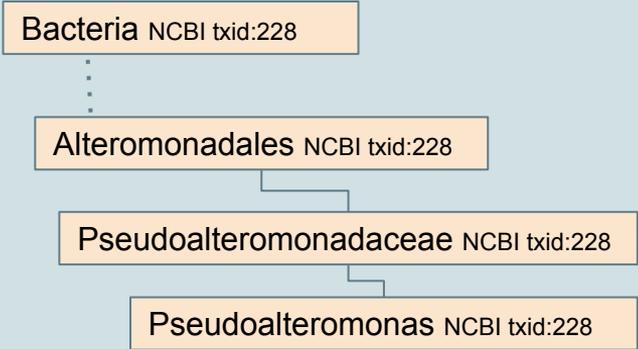
- Formalisation de la définition des entités et relations.
- Affinement de la portée des entités.
- Identifier les verrous en extraction d'information.

Acquisition de ressources

# Ressource sémantique

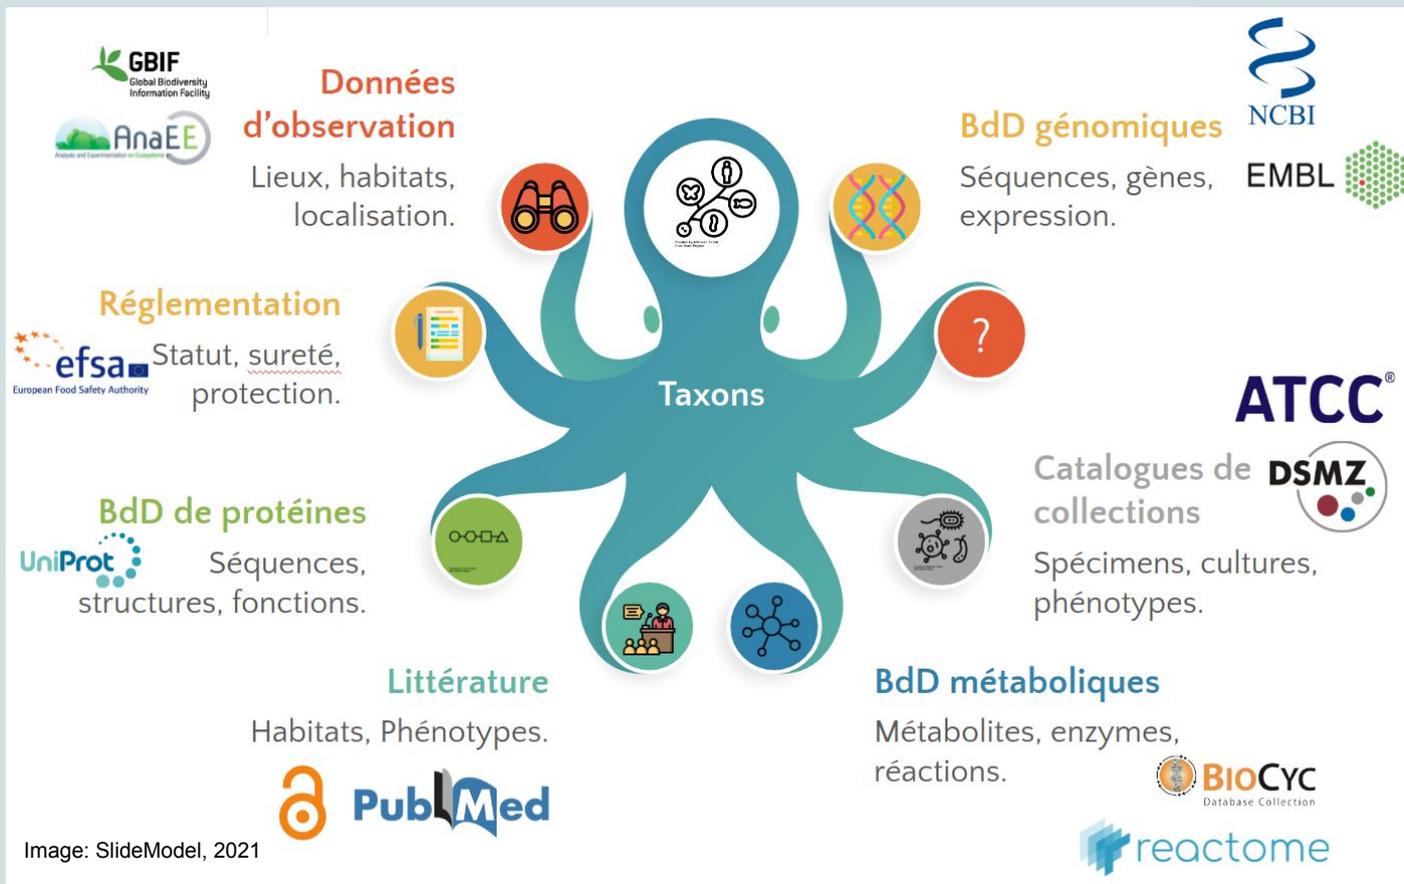


## OntoBiotope Ontology



*Pseudoalteromonas* is known to have many cold-adapted enzymes that function in the polar seawater

# Référentiel partagé



# Critères de réutilisation de ressources existantes

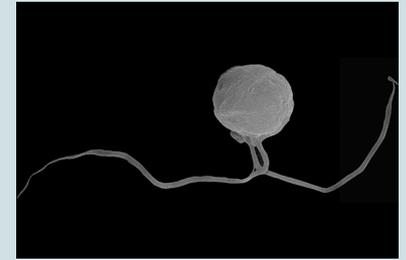
- **Exhaustivité sémantique**
  - Est-ce que toutes les branches taxonomiques sont représentées ?
- **Précision**
  - Quels rangs taxonomiques (espèce, souche) ?
- **Exhaustivité lexicale**
  - Synonymes et noms vernaculaires inclus ?
- **Niveau de formalisme**
  - Présence de lignées taxonomiques ? Distinction des types de synonymie ?
- **Disponibilité technique et légale**
  - Téléchargement ou API ? Licence ?
- **Adoption et autorité**
  - Liens établis avec des BdD ? Fréquence de mise à jour ?

# Taxonomie

- NCBI Taxonomy, taxonomie de référence pour :
  - les bases de données du NCBI (GenBank),
  - mais aussi de l'EBI,
  - et UniProt.
- Alternatives
  - GBIF Taxonomic Backbone : référence taxonomique du GBIF.
  - LPSN : référence taxonomique pour *Bacteria* et *Archaea*.
  - ICTV : référence taxonomique pour les virus.
  - ...

# Réutilisation de NCBI Taxonomy

- Exhaustivité sémantique
  - Toutes les branches microbiennes sont représentées.
- Précision
  - Rangs sub-spécifiques, incluant souches, pathovars, etc. *Exhaustivité limitée.*
- Exhaustivité lexicale
  - Synonymes inclus, avec et sans autorité. Quelques noms vernaculaires.
- Niveau de formalisme
  - Taxons hiérarchisés. Distinction de différents types de synonymes.
- Disponibilité technique et légale
  - Téléchargement. Licence libre.
- Adoption et autorité
  - Source secondaire, politique de curation peu claire. Largement liée dans différentes BdD.



ncbi:3004206 <Provora>

# NCBI Taxonomy : sélection des microorganismes

- Aucune définition intrinsèque satisfaisante de “microorganismes”.
- Approche communautaire
  - Quels chercheurs se reconnaissent dans “microbiologiste” ?
  - OntoBiotope (Réseau métaprogramme MEM).
- Volume
  - ~ 1M taxons
  - ~ 2,5M noms

Taxon	ID
<i>Alveolata</i>	33630
<i>Amoebozoa</i>	554915
<i>Archaea</i>	2157
<i>Bacteria</i>	2
<i>Chlamydomonadales</i>	3042
<i>Chlorella</i>	3071
<i>Choanoflagellida</i>	28009
<i>Cryptophyta</i>	3027
<i>Desmidiiales</i>	131210
<i>Diplomonadida</i>	5738
<i>Euglenozoa</i>	33682
<i>Fungi</i>	4751
<i>Glaucocystophyceae</i>	38254
<i>Haptophyta</i>	2830
<i>Ichthyosporea</i>	127916
<i>Nematoda</i>	6231
<i>Oxymonadida</i>	66288
<i>Parabasalia</i>	5719
<i>Prototheca</i>	3110
<i>Retortamonadidae</i>	193075
<i>Rhizaria</i>	543769
<i>Stramenopiles</i>	33634
<i>Viruses</i>	10239

# Combinaison de ressources

- Souches dans NCBI Taxonomy : complétude très inégale.
- L'information sur les habitats et phénotypes au niveau de la souche est essentielle.
- Aligner le catalogue du DSMZ :
  - Collection de cultures de référence.
  - Catalogue disponible en ligne.
- Incrément
  - 80k taxons
  - 700k synonymes

# Alignement NCBI et DSMZ

```
<strains>
  <list-item>
    <domain>Bacteria</domain>
    <phylum>Proteobacteria</phylum>
    <class>Deltaproteobacteria</class>
    <ordo>Myxococcales</ordo>
    <family>Anaeromyxobacteraceae</family>
    <genus>Anaeromyxobacter</genus>
    <species>Anaeromyxobacter dehalogenans</species>
    <species_epithet>dehalogenans</species_epithet>
    <subspecies_epithet/>
    <full_scientific_name>Anaeromyxobacter
dehalogenans Sanford et al.
2002</full_scientific_name>
    <designation>FRC-D3</designation>
    <variant/>
    <is_type_strain>False</is_type_strain>
    <ID_reference>16578</ID_reference>
  </list-item>
</strains>
```

```
161493 | Anaeromyxobacter dehalogenans Sanford et al. 2002 | authority |
161493 | Anaeromyxobacter dehalogenans | scientific name |
```

- Nouveau noeu d bd:16578
- Parent : ncbi:161493
- Nom : “*Anaeromyxobacter dehalogenans FRC-D3*”

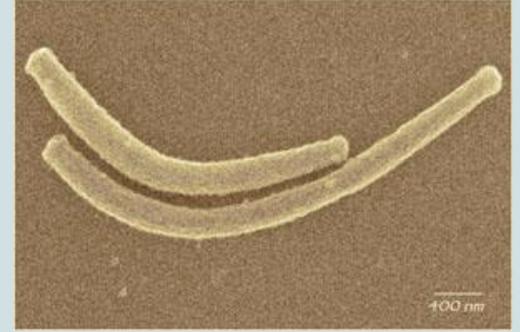


Image: Joint Genome Institute

# Alignement NCBI et DSMZ

```
<strains>
  <list-item>
    <domain>Bacteria</domain>
    <phylum>Actinobacteria</phylum>
    <class>Actinobacteria</class>
    <ordo>Actinomycetales</ordo>
    <family>Corynebacteriaceae</family>
    <genus>Corynebacterium</genus>
    <species>Corynebacterium timonense</species>
    <species_epithet>timonense</species_epithet>
    <subspecies_epithet/>
    <full_scientific_name>Corynebacterium
timonense Merhej et al.
2009</full_scientific_name>
    <designation>5401744, CSUR P20</designation>
    <variant/>
    <is_type_strain>True</is_type_strain>
    <ID_reference>16812</ID_reference>
  </list-item>
</strains>
```

1203190		Corynebacterium timonense 5401744		scientific name	
1203190		Corynebacterium timonense str. 5401744		equivalent name	
1203190		Corynebacterium timonense strain 5401744		equivalent name	

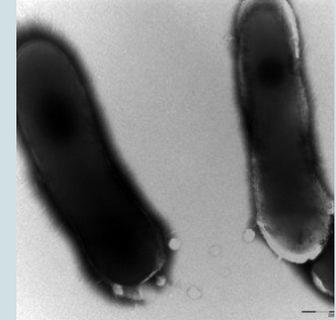


Image: Roux, et al., 2014

- Équivalence entre bd:16812 et ncbi:1203190
- Nouveau synonyme : “*Corynebacterium timonense CSUR P20*”

# Ressource sémantique : habitats et phénotypes

- EnvO : ontologie d'écosystèmes et environnements.
- *“The Environment Ontology (ENVO) is an expressive, machine-actionable knowledge representation of environmental entities.”*

⊖ chemical food component  
⊖ entity  
⊖ continuant  
⊖ generically dependent continuant  
⊖ independent continuant  
⊖ anatomical entity  
⊖ anatomical cluster  
⊖ immaterial anatomical entity  
⊖ anatomical space  
⊖ anatomical cavity  
⊖ coelemic cavity lumen  
⊖ serous cavity  
⊖ anatomical conduit space  
⊖ extraembryonic cavity  
⊖ future coelemic cavity lumen  
⊖ open anatomical space  
⊖ material anatomical entity  
⊖ biological entity  
⊖ immaterial entity  
⊖ material entity  
⊖ specifically dependent continuant  
⊖ occurrent  
⊖ food material  
⊖ food product organismal source  
⊖ food transformation process  
⊖ fruit-producing plant  
⊖ organismal entity  
⊖ collection of organisms  
⊖ biota  
⊖ multi-species collection of organisms  
⊖ single-species collection of organisms  
⊖ plant according to family  
⊖ plant structure development stage  
⊖ plant used for producing extract or concentrate  
⊖ role

# Réutilisation de EnvO

- Exhaustivité sémantique
  - Habitats peu adaptés aux microorganismes. Aucun phénotype.
- Précision
  - Très variable.
- Exhaustivité lexicale
  - Étiquettes auto-suffisantes, mais peu de lexicalisation.
- Niveau de formalisme
  - Ontologie formelle.
- Disponibilité technique et légale
  - Téléchargeable. CC0.
- Adoption et autorité
  - Vocabulaire contrôlé de MIxS du Genomic Standards Consortium (adoption effective limitée).

# Habitats et phénotypes : OntoBiotope

- Ontologie des habitats et phénotypes microbiens.
- Organisation des habitats selon les propriétés physiques, chimiques et physiologiques d'intérêt pour l'adaptation des microorganismes.
- Adoption:
  - Challenge Bacteria Biotopes.
  - Base de données Omnicrobe.
  - Vocabulaire contrôlé pour Open16S (projet pilote MICA).
- Volume:
  -

OntoBiotope root  
microbial habitat  
animal habitat  
animal husbandry and agricultural habitat  
aquaculture habitat  
artificial environment  
experimental medium  
food  
habitat wrt chemico-physical property  
living organism  
medical environment  
microorganism associated habitat  
natural environment habitat  
part of living organism  
planet  
microbial phenotype  
phenotype wrt adhesion  
phenotype wrt community behaviour  
phenotype wrt environment  
antimicrobial activity  
endolithic  
endopelic  
endopsammic  
epilythic  
epipelic  
epipsammic  
epixylic  
phenotype wrt microbial-host interaction  
animal hosted  
commensal  
free-living  
parasite  
pathogen  
plant hosted  
symbiont  
ubiquitous  
phenotype wrt genetic  
phenotype wrt growth  
phenotype wrt metabolic activity  
phenotype wrt morphology  
phenotype wrt motility  
phenotype wrt ploidy  
phenotype wrt stress  
physiological phenotype  
microbial use

# OntoBiotope : méthodologie top-down

- Approche épistémique pour les concepts les plus élevés :
  - Organismes vivants
  - Parties d'organismes vivants
  - Nourriture
  - Habitats liés à l'agriculture (et aquaculture)
  - Environnements médicalisés
  - Environnements naturels
  - ...

# OntoBiotope : methode bottom-up

- Approche ascendante pour les concepts les plus profonds.

## Documents

The antibacterial activity of synthetic aliphatic and aromatic monoacylglycerols (MAGs) was studied against two human pathogens: Staphylococcus aureus and Escherichia coli. The active compounds inhibited selectively S. aureus. The most active compounds amongst them were those with medium size aliphatic chain and aromatic MAGs with electron withdrawing substituents at the aryl ring. The introduction of one or two-carbon spacer between the aryl ring and the carboxylic function did not influence antibacterial effectiveness.



Extraction terminologique

## Groupes nominaux

active compounds x2  
antibacterial activity  
antibacterial effectiveness  
aromatic MAGs  
aromatic monoacylglycerols  
aryl ring x2  
carbon  
carboxylic function  
electron  
electron withdrawing substituents  
human  
human pathogens  
introduction  
MAGs x2  
medium size  
medium size aliphatic chain  
one or two-carbon spacer  
synthetic aliphatic

Tri



## Habitats Phénotypes

human  
human pathogens

Modélisation



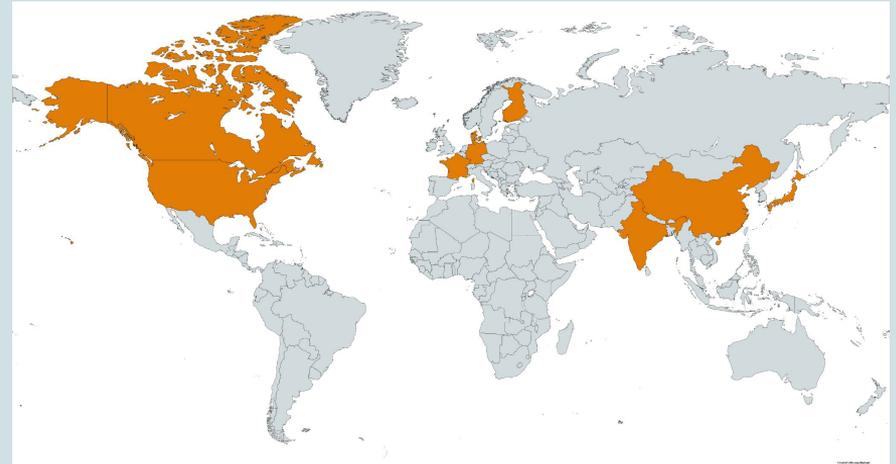
- ▣ OntoBiotope root
  - ▣ microbial habitat
    - ▣ animal habitat
    - ▣ animal husbandry and agricultural habitat
    - ▣ aquaculture habitat
    - ▣ artificial environment
    - ▣ experimental medium
    - ▣ food
    - ▣ habitat wrt chemico-physical property
    - ▣ living organism
    - ▣ medical environment
    - ▣ microorganism associated habitat
    - ▣ natural environment habitat
    - ▣ part of living organism
    - ▣ planet
  - ▣ microbial phenotype
    - ▣ phenotype wrt adhesion
    - ▣ phenotype wrt community behaviour
    - ▣ phenotype wrt environment
      - ▣ antimicrobial activity
      - ▣ endolithic
      - ▣ endopsammic
      - ▣ epilythic
      - ▣ epipelic
      - ▣ epipsammic
      - ▣ epixylic
    - ▣ phenotype wrt microbial-host interaction
      - ▣ animal hosted
      - ▣ commensal
      - ▣ free-living
      - ▣ parasitic
      - ▣ pathogen
      - ▣ plant hosted
      - ▣ symbiont
      - ▣ ubiquitous
    - ▣ phenotype wrt genetic
    - ▣ phenotype wrt growth
    - ▣ phenotype wrt metabolic activity
    - ▣ phenotype wrt morphology
    - ▣ phenotype wrt motility
    - ▣ phenotype wrt ploidy
    - ▣ phenotype wrt stress
    - ▣ physiological phenotype
  - ▣ microbial use

- Exhaustivité sémantique et lexicale.

Challenge

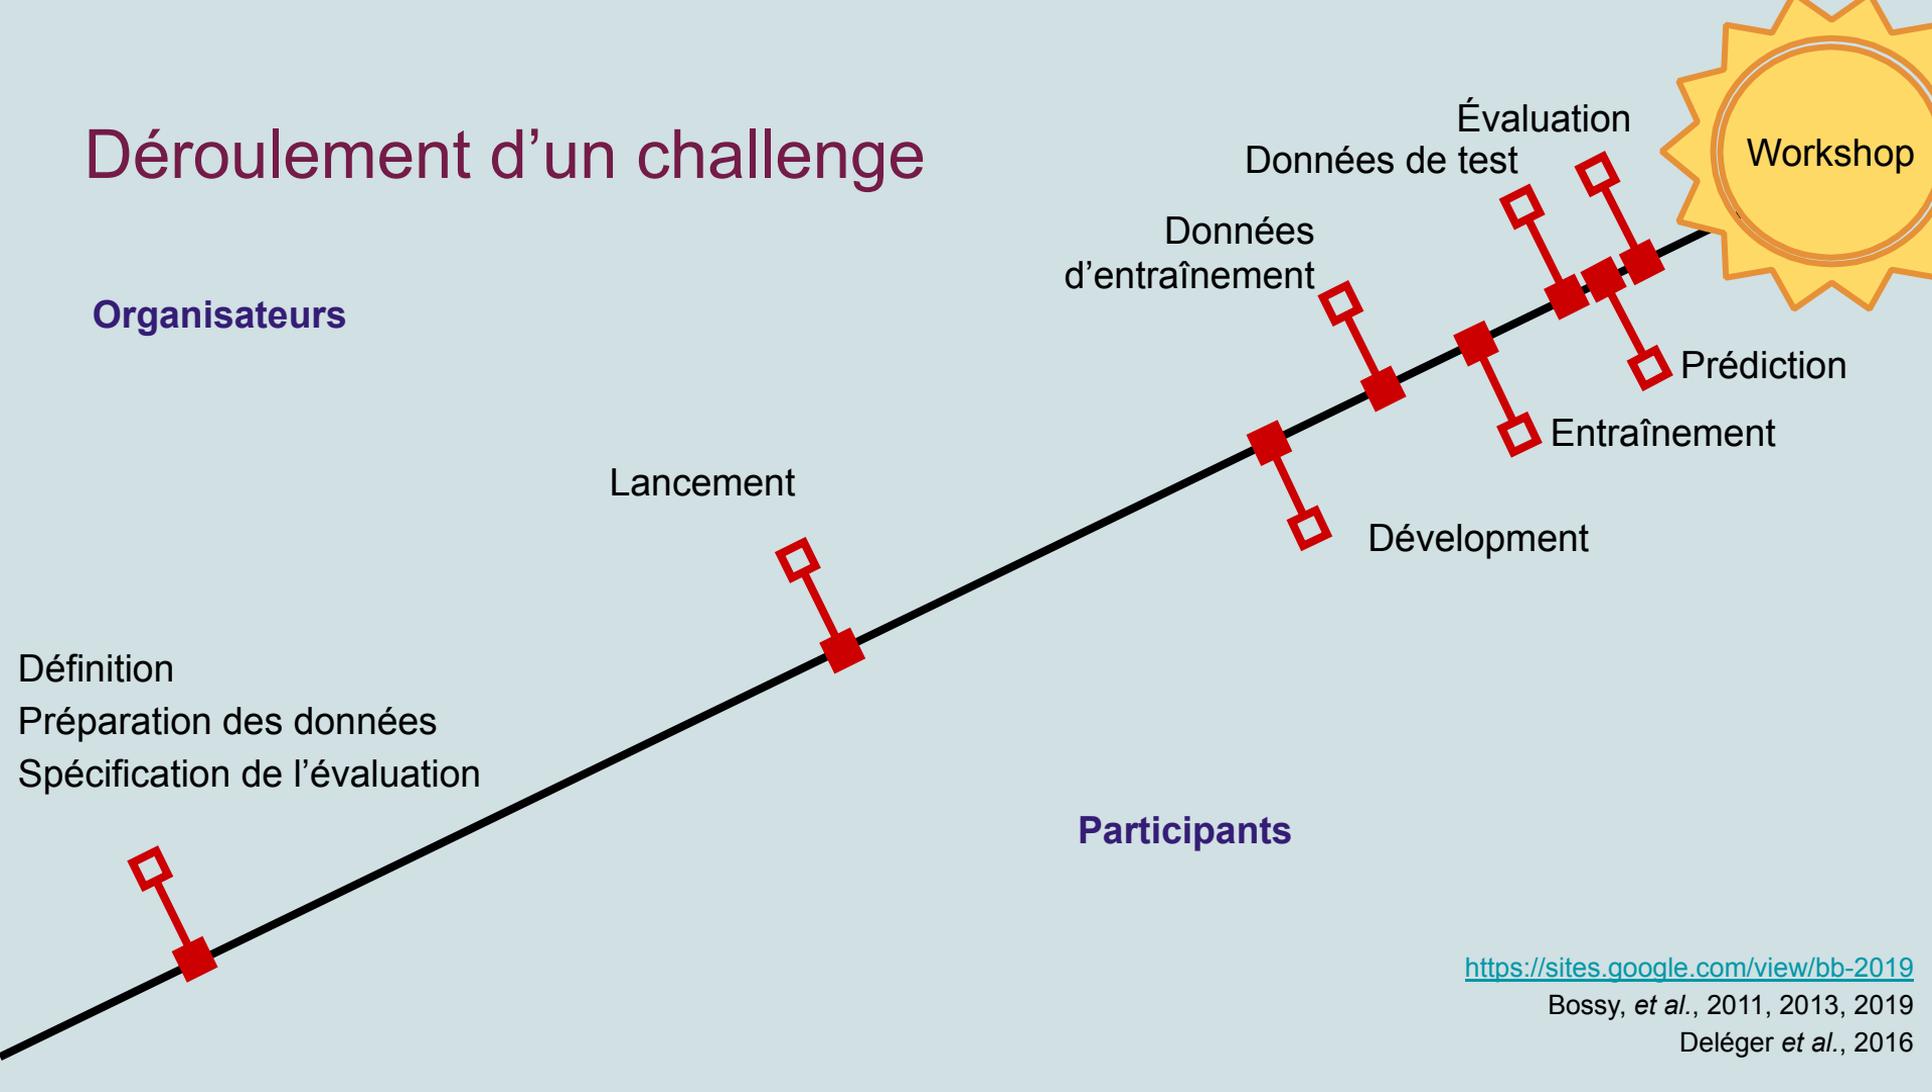
# Bacteria Biotopes

- Motivation
  - Mettre en avant les problématiques de INRAE
    - Biodiversité, Microbiologie, Agronomie et Alimentation
    - Entités nommées désignateurs non-rigides
  - Faire un point sur l'état de l'art méthodologique
- Bilan
  - BioNLP Shared Tasks
  - 4 éditions (2011, 2013, 2016, 2019)
  - 63 soumissions de 24 participants
  - Plus de 500 citations



# Déroulement d'un challenge

Organisateurs



Définition  
Préparation des données  
Spécification de l'évaluation

Lancement

Données d'entraînement  
Données de test  
Évaluation  
Développement  
Entraînement  
Prédiction



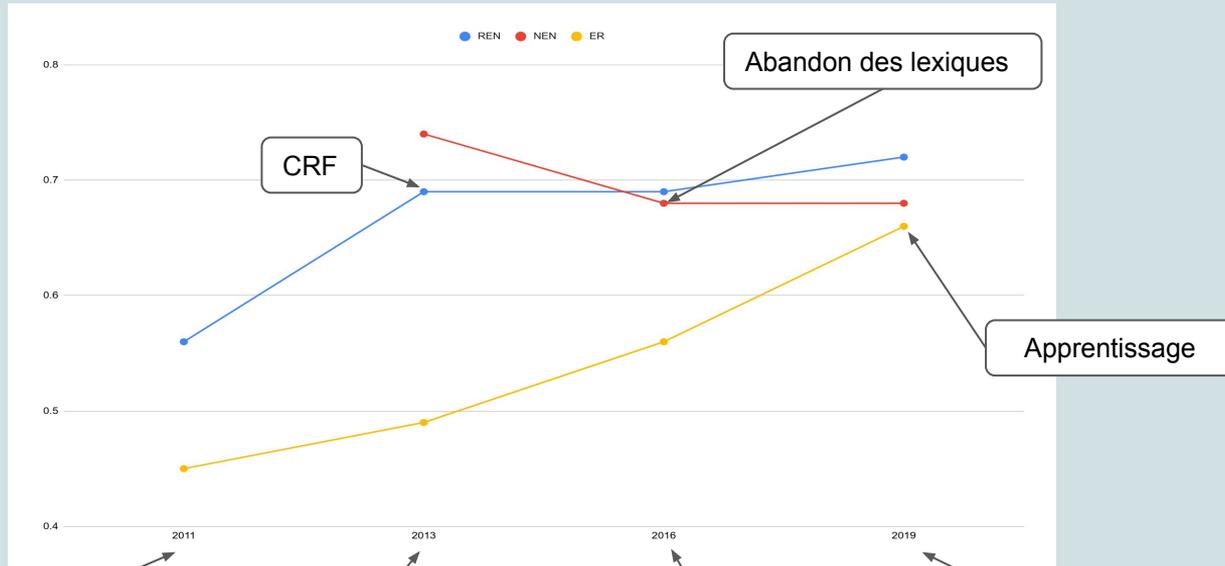
Participants

<https://sites.google.com/view/bb-2019>

Bossy, *et al.*, 2011, 2013, 2019

Deléger *et al.*, 2016

# Évolution des méthodes et performances



Lexiques et patrons  
Peu de ML (SVM, MEMM)

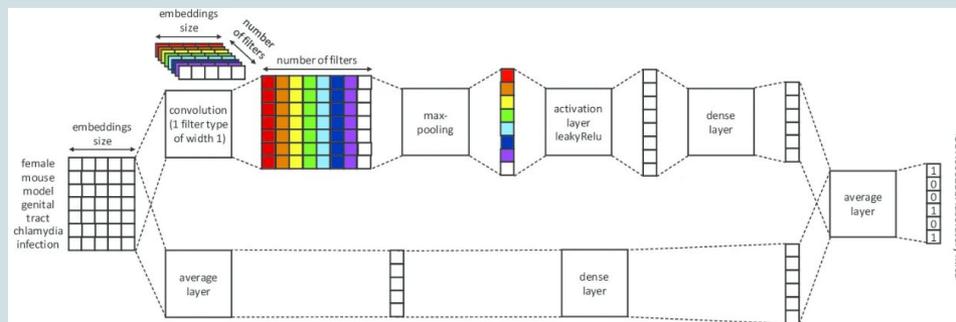
Analyse grammaticale  
kNN, CRF, SVM

Abandon des lexiques  
CRF, **SVM**, NN

SVM+LR, biLSTM, CNN,  
Transformers

# C-Norm

Méthode de normalisation qui combine supervision standard et faible.



Similarité  
(Habitats)

PADIA (meilleur 2019)

0.68

C-Norm

0.78

# Préparation des données

- *Gold standard* : annotation manuelle de documents.
- La “réalité du terrain” du texte est difficile à obtenir :
  - Le langage est sujet à interprétation.
  - Sa compréhension mobilise des connaissances extérieures.
  - La langue écrite est très dense en information.
  - Une annotation manuelle peut varier d’une personne à l’autre.

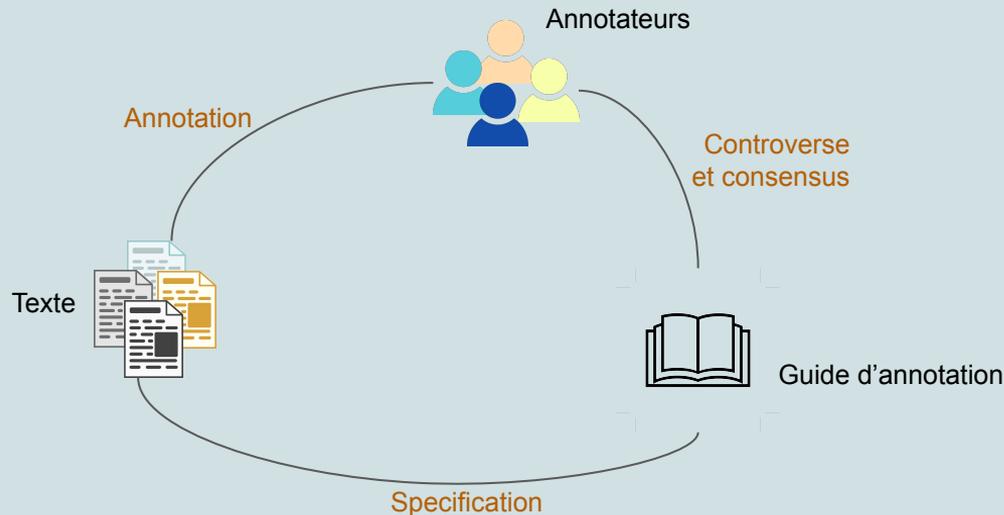
*Differences in the in vitro adhesion of Staphylococcus strains on rabbit tissues were evaluated by viable unit counts and radio-labeling.*

*Vit dans ?*

- “*in vitro*” disqualifie-t-elle la relation ?
- Ne s’agit-il pas d’une hypothèse ?
- Voudrait-on retrouver cette relation dans une base de données ?

# Méthodologie d'annotation

- Chaque texte doit être annoté plusieurs fois.
- Les annotateurs partagent les interprétations lors de l'annotation.
- Les décisions sont enregistrées dans le **guide d'annotation** (“guidelines”, “consignes”).



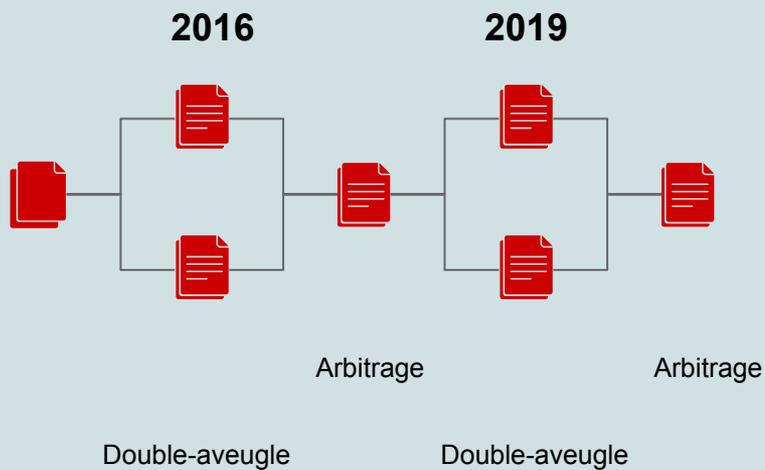
# Extraits du guide Bacteria Biotopes

<b>2 Microbial taxon names</b>	<b>4</b>
2.1 Entity domain	4
2.1.0 Microorganism definition	4
2.1.1 Gram staining	4
2.1.2 Abbreviations	5
2.1.3 Lactic acid bacteria	5
2.1.4 Too general	5
2.2 Boundaries	6
2.2.1 Phenotype acronyms designating microorganisms	7
2.2.2 Strain specification	7
2.2.3 Nomenclatural suffixes: sp., spp., gen. nov., sp.nov.	8
2.3 Taxon ID	9
2.3.1 Unknown taxon identifier	9
2.3.2 Partial coreference	9

<b>6 Lives_In relation</b>	<b>25</b>
6.1 Topological constraints	25
6.2 Partial localization	26
6.3 Effect of microorganisms on the environment	26
6.3.1 Diseases and symptoms	26
6.3.2 Symbioses	27
6.4 Experimental settings	28
6.5 Vaccines	28
6.6 Hypothesis sentence	28
6.7 Relation transitivity	28
6.8 Selection media	29

Le guide d'annotation est le seul élément de reproductibilité d'un texte annoté.

# Annotation en double aveugle



	REN ( $F_1$ )	NEN (S)	ER ( $F_1$ )
<b>Accord inter-annotateur</b>	.89	.97	.79
<b>Meilleur système</b>	.72	.68	.66

# Volume de Bacteria Biotopes

Documents	392	Abstracts PubMed + extraits full-text
Tokens	60.402	
Entités	7.232	
Relations	3.578	
<b>Annotateurs</b>	<b>18</b>	

Entraînement 133  $\frac{1}{3}$

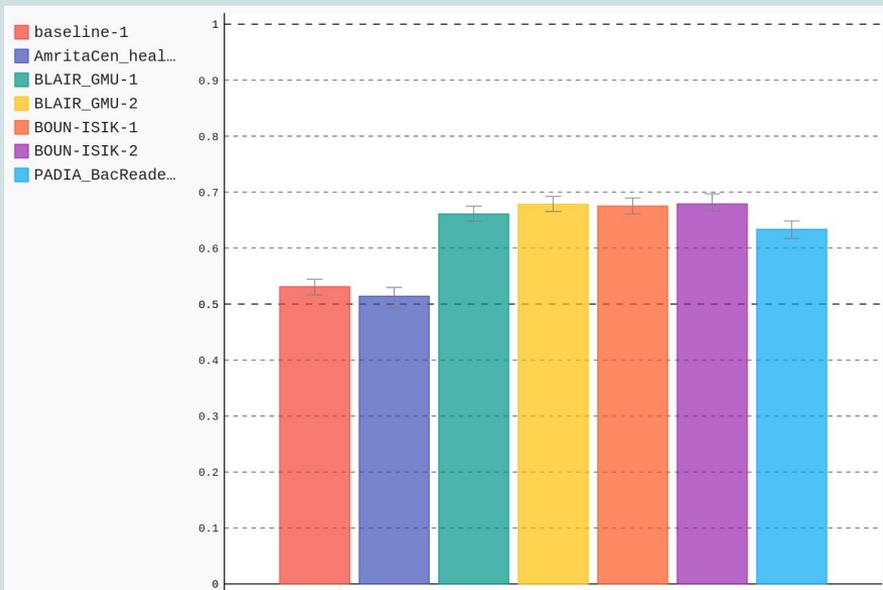
Développement 66  $\frac{1}{6}$

Test 193  $\frac{1}{2}$

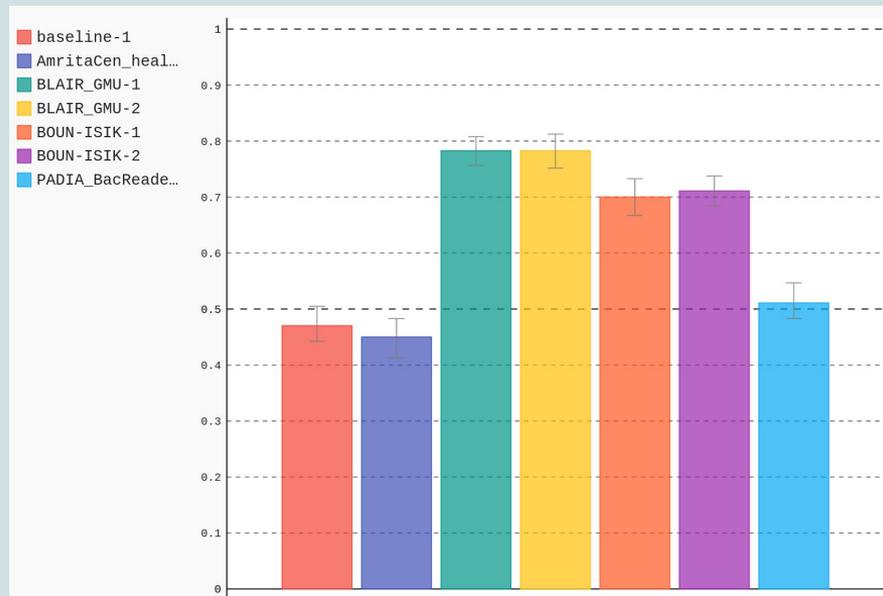
# Métriques

- Métriques classiques de classification : Rappel, Précision, F-score
- Inconvénients
  - Information pauvre sur les forces et les faiblesses de chaque méthode.
  - Couverture partiellement les besoins.
  - Biais métriques.
- Solutions
  - Scores multiples : différencier les types d'annotations, ou des phénomènes linguistiques.
  - Métriques spécialisées : s'approcher des besoins ou pallier les biais.

# Scores multiples (Normalisation)



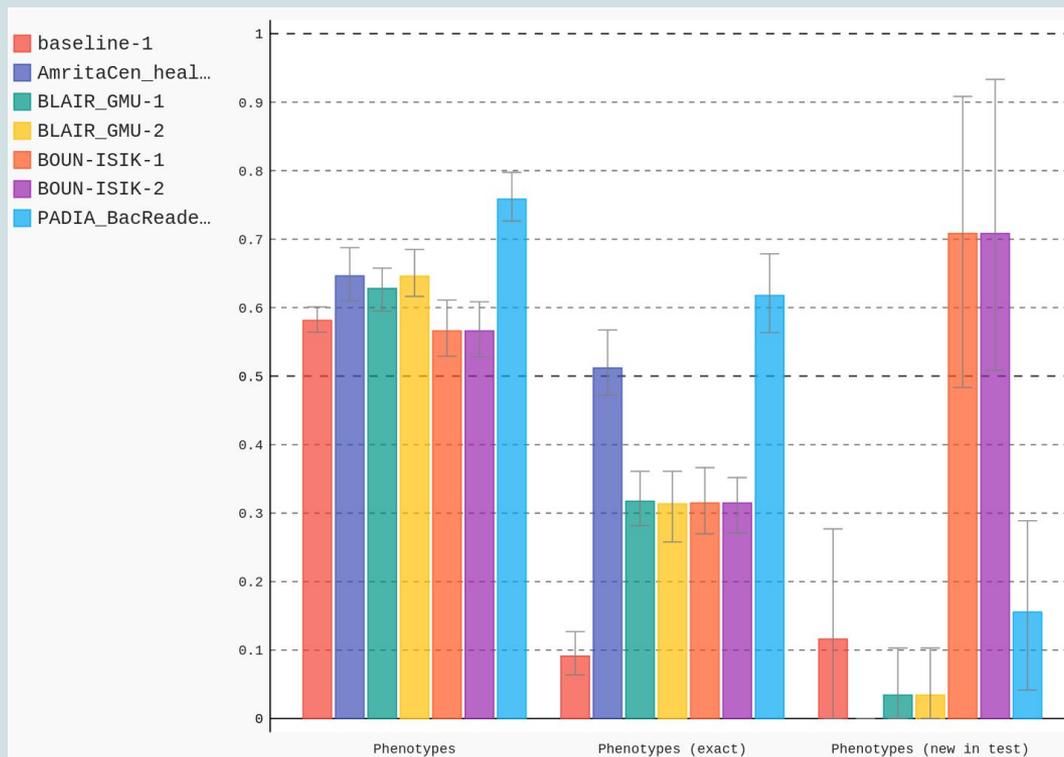
Score global



Microorganismes

Métrie : similarité.

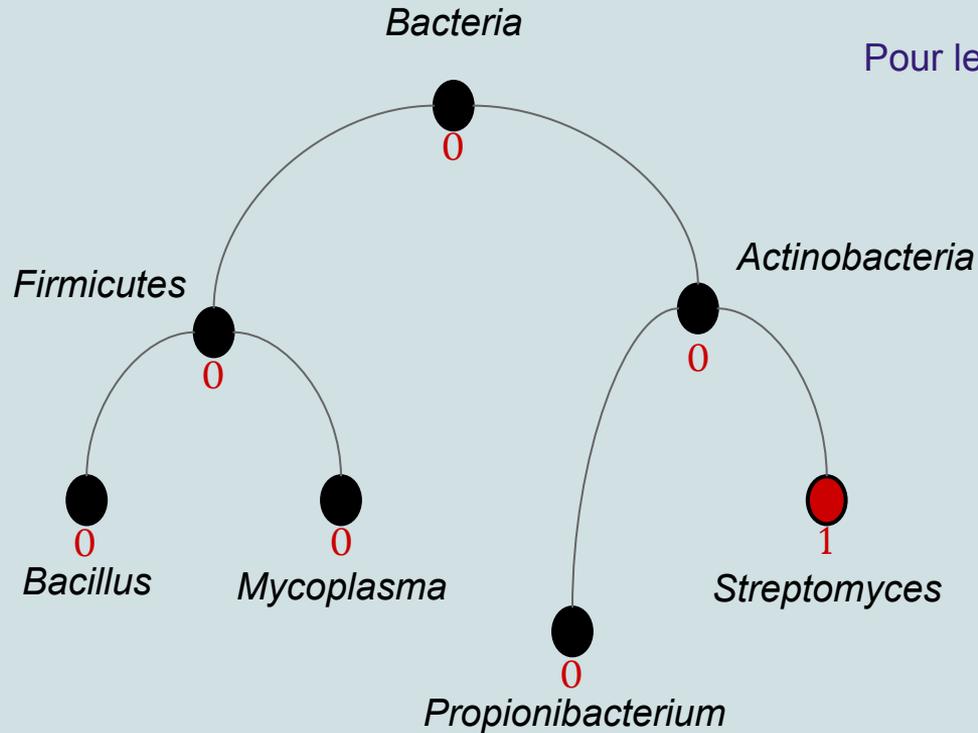
# Scores multiples (Normalisation)



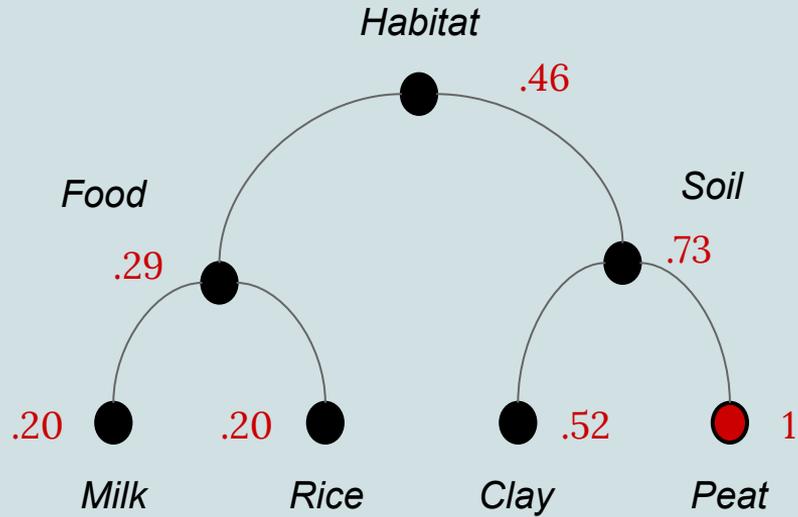
Phénotypes

# Métriques spécialisées (Normalisation)

Pour les taxons, la normalisation doit être stricte.



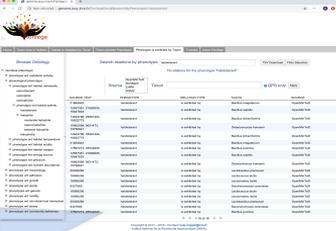
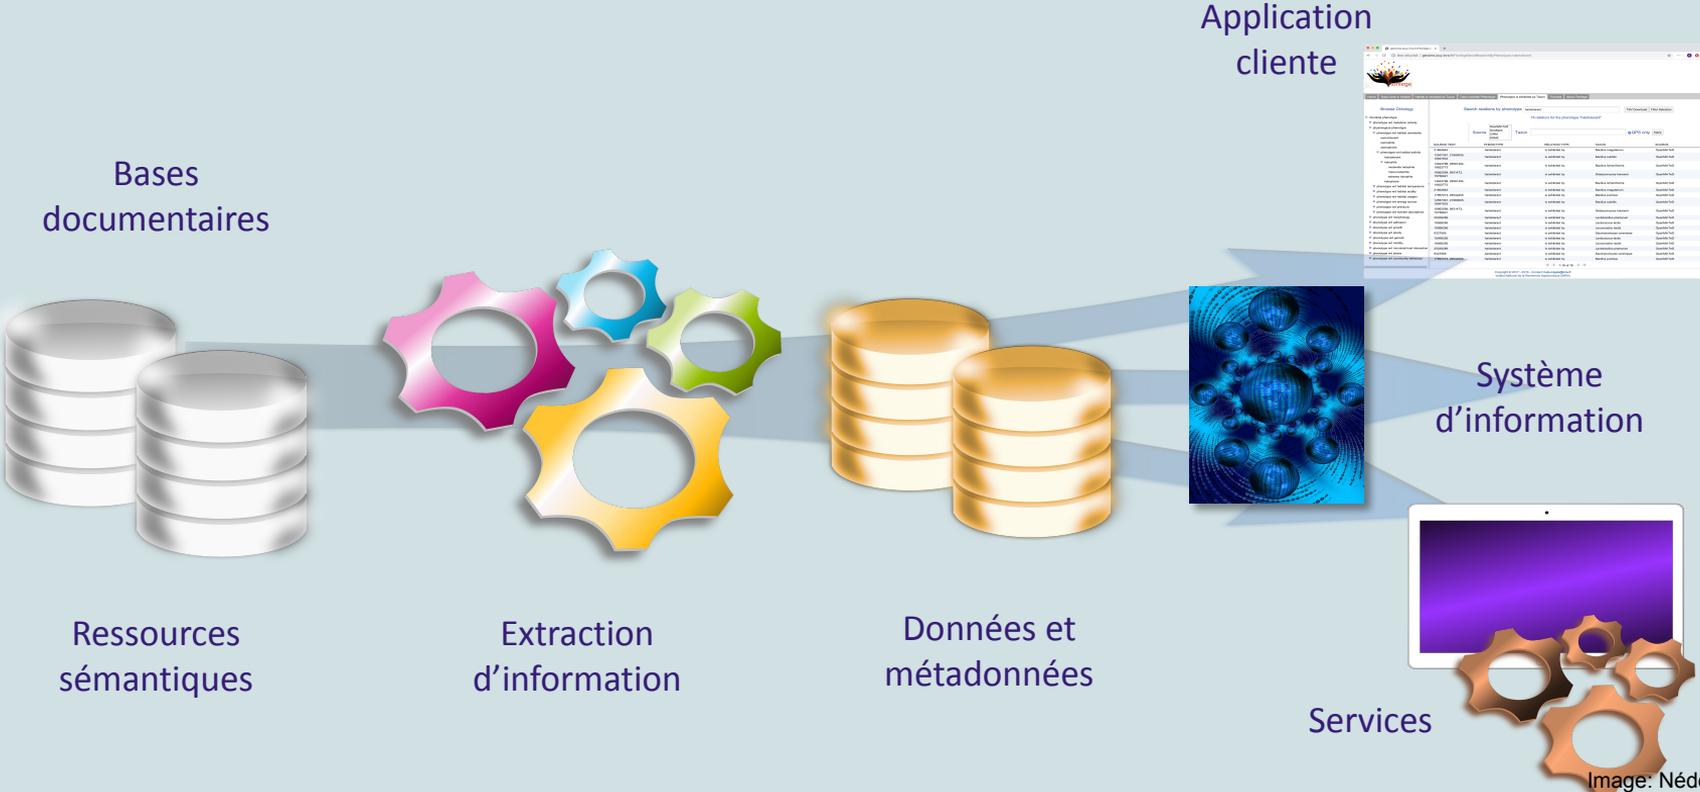
# Métriques spécialisées (Normalisation)



Pour les habitats et phénotypes une normalisation proche est acceptable.

Services

# Extraction d'information et applications



# Zoom sur l'extraction d'information

Les différentes tâches doivent être enchaînées et combinées.

- **Passage à l'échelle** → Robustesse.
- **Mises à jour** → Reproductibilité et infrastructure de calcul.
- **Collaboration** → Pérennité des outils et documentation.

**AlvisNLP** : moteur de workflows spécialisé dans l'extraction d'information **modulaire et paramétrable**.

- Workflow déclaratif → **reproductibilité**.
- Bibliothèque étendue et extensible → **capitalisation**, continuité entre **recherche et service**.



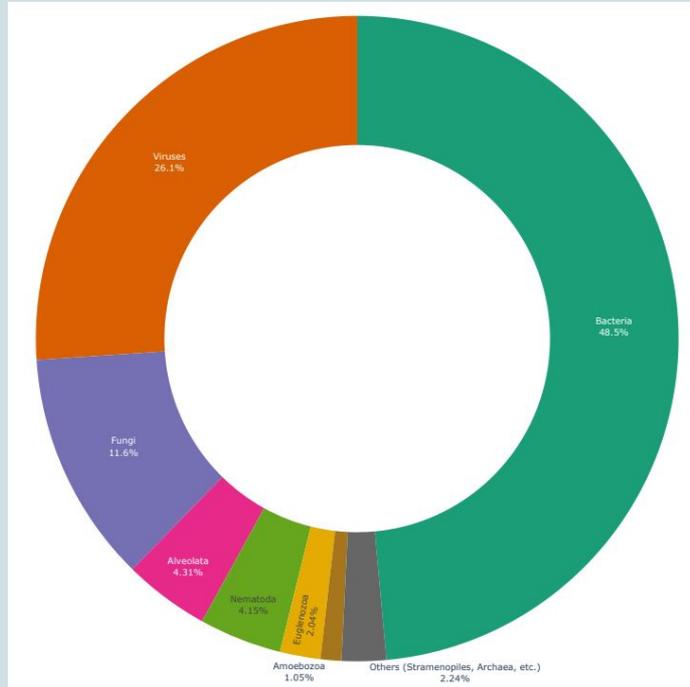
# Exemples d'applications

- Recherche d'information
  - Recherche sémantique de documents.
  - Intégration de données de sources diverses : bibliographie, données expérimentales, données de référence...
- Aide à la décision
  - Cartographie thématique (synthèse de corpus, tendances).
  - Profilage (par exemple, sélection de relecteurs).
- Extension de référentiels
  - Recherche de nouveaux concepts ou synonymes.

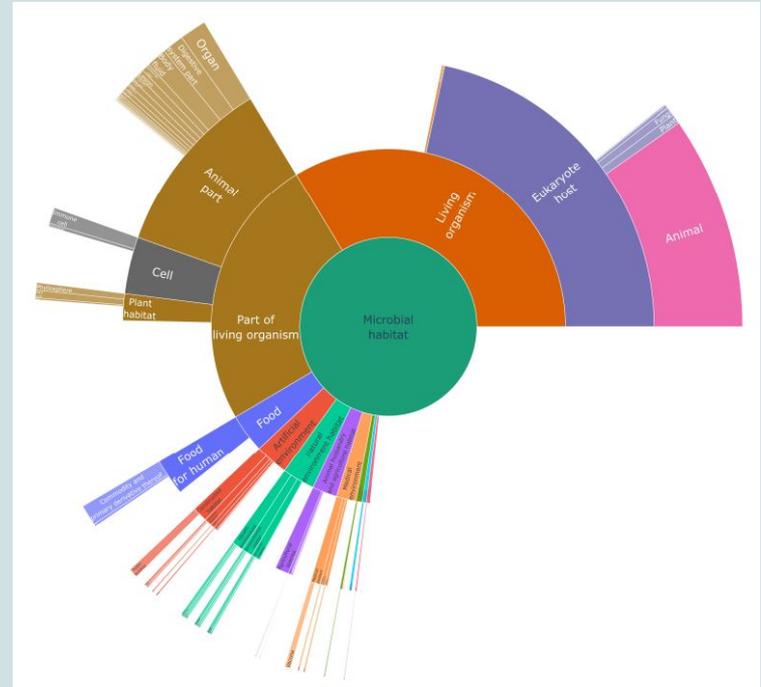
# Omnicrobe

- Base de données de référence sur la biodiversité microbienne
  - Relations entre taxons, habitats et phénotypes.
  - Concepts normalisés par NCBI Taxonomy et OntoBiotope.
- Intégration de données de sources
  - Résumés PubMed.
  - GenBank (champs *organism*, *host*, *isolation\_site*).
  - Entrées du catalogue DSMZ (champs *taxonomy*, *denomination*, *environment*).
  - Entrée de catalogues de CIRM.

# Omnicrobe : contenu



10<sup>6</sup> Relations





# Omnicrobe : les technologies



# Omnicrobe : utilisateurs

- Florilège (Métaprogramme MEM)
  - Conception d'un ferment pour réaliser des yaourts à base de jus de soja.
- Food Microbiome Transfert (Micalis, MaIAGE, Migale, CNIEL)
  - Sélection de souches de référence pour la métagénomique du fromage.
- Open16S (projet pilote MICA)
  - Curation de métadonnées de projets métagénomiques.

L'équipe ("nous")



Bedis Dridi

Marteen van de Guchte

Pierre Renault

H  l  ne Falentin



# OBT

R  seau OntoBiotope



Projet Floril  ge

## Besoin

## Omnicrobe



Sandra Derozier

## Logiciels



Fr  d  ric Papazian



Mouhamadou Ba



Robert Bossy

## Infrastructure

## Projet



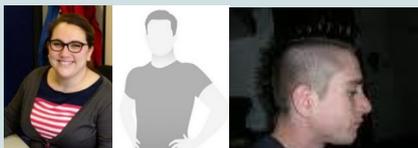
Philippe Bessi  res



Claire N  dellec

## OntoBiotope

## Annotation



Dialekti Valsamou

L  onard Zweigenbaum

Julien Jourde

## ER



Anfu Tang

## REN/NEN



Louise Del  ger

Arnaud Ferr  

Zorana Ratkovic

Wiktorija Golik



Estelle Chaix

Conclusion

# L'application de l'extraction d'information nécessite

## 1. Analyse du besoin

- Co-construction entre spécialistes de l'extraction d'information et les porteurs du besoin.
- Préciser les contours des informations désirées et la faisabilité.

## 2. Identification et construction de ressources sémantiques

- Activité à l'interface de l'ingénierie des connaissances et du domaine d'application.
- Les ressources sémantiques permettent à la fois d'opérer l'extraction d'information et d'en exploiter le résultat.

## 3. Évaluer et développer des méthodes

- La communauté d'extraction d'information est structurée autour de challenges.

## 4. Infrastructure de calcul et de développement logiciel

- Porter les résultats aux utilisateurs.

# Omnicrobe et la biodiversité microbienne

- Base de données de référence
  - Le service expose des résultats de l'extraction d'information.
  - Le développement et la maintenance mobilise trois équipes de l'unité MaIAGE.
- Perspectives
  - Emploi de méthodes à l'état de l'art (thèses Anfu Tang et Mariya Borovikova).
  - Agrégation de sources supplémentaires (convention avec l'ANSES).
- Ré-emploi dans le domaine de l'épidémiosurveillance végétale
  - Entités : organismes nuisibles, plantes, vecteurs, voies de dissémination.
  - Projets : TIERS-ESV (BioSP), Beyond (ANR).

**Merci!**