


# ➤ Insertion et exploitation de données hétérogènes dans un graphe de connaissance

Confais J, Francillonne N, Semery M, Gonnet I

Paris, 2023-09-15

# Des données hétérogènes, des bases indépendantes et pas de liens



TFBS & TF : PlantRegMap Db (<http://plantfdb.cbi.pku.edu.cn/download.php>) & Heyndrix et al 2014 (Plant Cell):

TAIR V10 repository : [https://www.arabidopsis.org/download/index-auto.jsp?dir=%2Fdownload\\_files%2FGenes%2FTAIR10\\_genome\\_release%2FTAIR10\\_gff3](https://www.arabidopsis.org/download/index-auto.jsp?dir=%2Fdownload_files%2FGenes%2FTAIR10_genome_release%2FTAIR10_gff3)

GWAS: Nordborg study (Genome-wide association study of 107 phenotypes in Arabidopsis thaliana inbred lines; Atwell et al. - Nature 2010)

REPETDB <https://urgi.versailles.inrae.fr/repetdb>

CNS : Van de Velde et al 2014 (Plant Cell)

ReMap2022



JASPAR<sup>2022</sup>

PlantRegMap




Phytozome 12  
THE PLANT GENOMICS RESOURCE

=> Comment articuler ces données pour répondre à notre question ?

# C'est quoi une base graphe

- Modélisation flexible qui s'adapte à l'hétérogénéité des données disponibles
- Création de relation entre entités qui portent un sens biologique

**=> Choix d'un graphe de propriété**




- Création de la base graphe avec Neo4J :
  - Modèle dynamique - CRUD + DML (Data Manipulation Language)
  - Méta-modèle généré à la volée à partir des données
  - Cypher simplifie la prise en main

# ➤ Intérêts de la base graphe

## Reactome graph database : Efficient access to complex pathway data

- Efficace pour les données très connectées (évite les multiples jointures des bases de données relationnelles)
- Type de base plus porté sur l'interrogation que le stockage massif → BDGs pour l'analyse


### Relational Database



```
SELECT r.*, pe.* FROM Reaction r
JOIN Reaction-input ri ON r.dbId = ri.Reaction_dbId
JOIN PhysicalEntity pe ON pe.dbId = ri.PhysicalEntity_dbId
JOIN Reaction-output ro ON r.dbId = ro.Reaction_dbId
JOIN pe ON pe.dbId = ro.PhysicalEntity_dbId
WHERE r.dbId = IDENTIFIER
```

### b SQL query

### Graph Database



```
MATCH (r:Reaction{dbId: IDENTIFIER}) -[:input|output]->(pe)
RETURN r,pe
```

### d Cypher query

Fabregat et al., Plos Computational Biology (2018)

93% de gain sur le temps de requête



# Types de données


Source	Format des données	Données biologiques
Phytozome	gff, txt	annotation de gènes
	txt	homologie gènes intra <i>B.distachyon</i>
	txt	orthologie entre <i>A.thaliana</i> et <i>B.distachyon</i>
PlantRegMap	gff, txt	groupes d'orthologie (17 & 157 espèces) ; TFBS prédit (motif, motifCE, FunTFBS) ; CNS ; TF
URGI	gff3, tsv, classif	TEs pangénomiques
Gordon <i>et al.</i>	pdf, csv	climat, classe de floraison, cluster, accessions

⇒ Données d'*A.thaliana* : Gènes, TEs, CNS, SNPs, TFBS (ChIP-Seq et prédit), TF, Stress, Trait

# La base graphe avec nos données ?

(Entité)-[relation]-(Entité)

- Nœud 
- Relation 
- Propriété 






# Processus d'intégration

Des données et des formats très hétérogènes


données d'entrée




fichiers prêts à être intégrés



# ➤ Cas de relations de distance



Données d'annotation fichiers .gff




relations de distance

# > Volumétrie

## Nœuds



## Relation



Quelques remarques !

- Plus d'une centaine de propriétés décrivant les nœuds ou relations
- 54 accessions de *B.distachyon* avec 54 annotations en TE et en gènes

## ➤ Metagraph

# ATTENTION!

# ça part dans tous les sens





## ➤ Pleins de données mais pour faire quoi ?

3 cas d'utilisation de la base

- 1<sup>er</sup> cas: Quelles seraient les séquences régulatrices ancestrales impliquées dans la floraison
- 2<sup>e</sup> cas: Visualisation de TEs pouvant avoir un impact sur l'adaptation aux stress de chaleur et de luminosité
- 3<sup>e</sup> cas: Associer les familles de TE à des motifs fonctionnels

# Cas d'utilisation


## Étude du pangénome des éléments transposables (TEs) chez *Arabidopsis thaliana*



- *Arabidopsis thaliana* est une espèce modèle
- 4 accessions séquencées et annotées en éléments transposable
- Absence/Présence d'éléments transposables chez chaque individu
- Définition TE en clique :

TE qui partage une même position  
dans différents génomes :


- core = présente chez toutes les accessions
- dispensable = partagées par certaines accessions



=> Peut-on inférer aux éléments transposables un impact sur certains phénotypes exprimés dans certaines variétés/accessions ?


# Exemple de requête dans la base :

Quels sont les éléments potentiellement régulateurs (TFBS, TE) en amont de gènes impliqués dans la réponse à un stress ?



# Exemple de requête dans la base :

Quels sont les éléments régulateurs (TE, TFBS, marqueur SNP) que l'on peut trouver en amont d'un gène impliqué dans un stress ?




```

match p=(te:ATHA_TE)-[:IS_UPSTREAM_OF]-(g:ATHA_GENE),
tfa=(tf:ATHA_TFBS)-[:IS_UPSTREAM_OF]-(g),
s-(:ATHA_SNP)-[:IS_UPSTREAM_OF]-(g)--(:ATHA_STRESS),
t=(te)-[:INTERSECT_WITH]-(tf)
return p,s,t, tfa

```



# ➤ 1<sup>er</sup> cas: Quelles seraient les séquences régulatrices ancestrales impliquées dans la floraison



## Conditions cumulées

Gènes d'*A.thaliana* impliqués dans la floraison

+ CNS en amont des gènes d'*A.thaliana*

+ CNS qui chevauche un TFBS validé par analyse CHIP-Seq

+ CHIP-Seq TFBS se liant avec un TF

+ Gène d'*A.thaliana* orthologue à un gène de *B.distachyon*

+ CNS en amont des gènes de *B.distachyon*


+CNS de *B.distachyon* chevauche un TFBS prédit se liant à un TF

+TF d'*A.thaliana* et de *B.distachyon* de la même famille

**Puis affichage des TFBS prédits d'*A.thaliana* et des groupes d'homologie et d'orthologie de *B.distachyon***

## ➤ Use case

Quelles seraient les séquences régulatrices ancestrales impliquées dans la floraison ?




Puis affichage des TFBS prédits d'*A.thaliana* et des groupes d'homologie et d'orthologie de *B.distachyon*

```


1 MATCH a=(g1:Gene{specie:"Atha"})--(:Trait{TRAIT_NAME:"Flowering"}),
2 b=(g1)-[:IS_UPSTREAM_OF]-(cns1:CNS),
3 c=(cns1)-[:INTERSECT_WITH]-(tfbs1:ChipSeq_TFBS),
4 d=(tfbs1)--(tf1:TF),
5 e=(tfbs1)-[:INTERSECT_WITH]-(pTFBS1:predicted_TFBS)-[:INTERSECT_WITH]-(cns1),
6 f=(pTFBS1)-[:IS_DOWNSTREAM_OF]-(g1),
7 g=(g1)--(:OG{name_orthogroup:"OG_Bdis_Atha"})--(g2:Gene{specie:"Bdis"}),
8 h=(g2)-[:IS_UPSTREAM_OF]-(cns2:CNS),
9 i=(cns2)-[:INTERSECT_WITH]-(tfbs2:predicted_TFBS),
10 j=(tfbs2)-[:BIND_TO]-(tf2:TF), k=(g2)--(:HG), l=(g1)--(:OG)--(g2)
11 WHERE tf1.family=tf2.family
12 RETURN a,b,c,d,e,f,g,h,i,j,k,l

```


# ➤ Use case



# 2<sup>e</sup> cas: Visualisation de TEs pouvant avoir un impact sur l'adaptation aux stress de chaleur et de luminosité



# 3<sup>e</sup> cas: Associer les familles de TE à des motifs fonctionnels




# 3<sup>e</sup> cas: Associer les familles de TE à des motifs fonctionnels

## PLM (Preferentially Located Motif)



GNet Marie-Laure Martin  
Julien Rozière  
+ Sylvie Coursol



<http://plmview.ips2.universite-paris-saclay.fr/>

→ POTENTIELS MOTIFS CIS-REGULATEURS

Rozière, J., et al. (2022) Frontiers




INRAE

Titre de la présentation

Date / information / nom de l'auteur

# Requêter les motifs associés aux TEs

New enhancers or repressors




Lisch, Damon. *Nat Rev Genet* (2012).



PLM ?

site de  
régulation ?

validation  
expérimentale ?



# ➤ Famille de TE associé à des motifs




JASPAR 2022

ReMap 2022

regulates flavonoid biosynthesis under **high light**

# ➤ Associer les évidences



## Node labels

- \* (11)
- STRESS (1)
- PLM\_POSITION (1)
- TE (1)
- TFBS (7)
- predicted\_TFBS (6)
- GENE (1)
- ChIPSeq\_TFBS (1)

## Relationship types


- \* (25)
- GENE\_STRESS (1)
- INTERSECT\_WITH (23)
- IS\_UPSTREAM\_OF (1)

Displaying 11 nodes, 25 relationships.




# Questions ?

```
$ match p=(te:TE)-[]-(g:GENE)-[]-(tr:TRAIT), q=(te)-[]-(tfbs:TFBS)-[]-(tf:TF)-[]-(z:GENE) return p,q limit 20
```



# Bilan données intégrées

- Échelle **multi-omique** (annotations de gènes, d'éléments transposables, marqueurs génomiques/génétiques, fonctions, phénotypes/traits, etc.)
- Encore énormément de données à moissonner dans des articles



# Quelques remarques


- Ontologies **utilisées** :
  - de référence (GO, SO)
  - ou spécifiques (PTO)
- Ontologies « **à réfléchir** » :
  - relation de distance entre entités génomiques
  - Description phénotypique : gènes impliqués dans des stresses
  - Nouveau concept (lié à la pangénomique comme clique)
- **Modélisation** très liée aux entités manipulées, mais aussi et surtout aux questions envisagées
- **Gestion de la provenance** perfectible. Pistes :
  - PAV (Provenance, Authoring and Versioning) : <https://pav-ontology.github.io/pav/> (plutôt léger)
  - Provenance DCTerms : <https://www.dublincore.org/specifications/dublin-core/dcmi-terms/terms/provenance/>
  - PROV-O : <https://www.w3.org/TR/2013/REC-prov-o-20130430/> (overkill)
  - DublinCore/PROV : <https://www.w3.org/TR/prov-dc/>

# Pré-compilation (2)

Matrice de conversion entre version d'annotation



Certaines données ne sont disponibles que pour certaines versions d'assemblage  
Nécessité de lier les éléments génomiques sur la même version




# Pré-compilation (2)

Matrice de conversion entre version d'annotation




Certaines données ne sont disponibles que pour certaines versions d'assemblage  
Nécessité de lier les éléments génomiques sur la même version



# Cas d'utilisation

## Brachypodium & Arabidopsis



# Recherche du motif conservé d'*A.thaliana* chez *B.distachyon*

---

- Recherche du motif\_CE TFBS d'*A.thaliana* en amont du gène Bradi5g19320 (v3.2)
- ⇒ séquence similaire sur *B.distachyon* entre 22 490 239 - 22 490 251 (- 4 003 avant le gène)
- Recherche de CNS correspondant à ces positions : Bdis\_Bd21\_CNS\_409825 (Bd5 : 22 490 141 - 22 490 306)
- Pas de TFBS prédit sur ces coordonnées
- Récupération et alignement du CNS de *B.distachyon* sur *A.thaliana*

- Pas de lien spécifique entre la classification de climat et la présence de la clique de TE observée
- Beaucoup de cas à explorer même si pas de corrélations observées dans le papier de Gordon

# Recherches complémentaires

---

## **Fonctions du TF bHLH** (Guo *et al.*, 2021)

- Réponse au stress abiotique
- Régulation de la floraison

## **Fonctions du gène** (Zhang *et al.*, 2020 ; Saha *et al.*, 2007)

- Protéine de la superfamille des Pentatricopeptide Repeat (PPR-like)
- Adaptation aux stress et processus développementaux (pollen)
- Famille de protéines retrouvée dans de nombreux organismes