

Mise en place de serveurs Galaxy dans le cadre du réseau CATI BBRIC

{[Sebastien.Carrere](mailto:Sebastien.Carrere@toulouse.inra.fr), [Ludovic.Legrand](mailto:Ludovic.Legrand@toulouse.inra.fr),[Jerome.Gouzy](mailto:Jerome.Gouzy@toulouse.inra.fr)}@toulouse.inra.fr
{[Fabrice.Legeai](mailto:Fabrice.Legeai@rennes.inra.fr),[Anthony.Bretaudeau](mailto:Anthony.Bretaudeau@rennes.inra.fr)}@rennes.inra.fr

CATI BBRIC



- ▶ 35 bioinformaticiens
- ▶ 15 unités
- ▶ 10 sites

Domaines d'applications

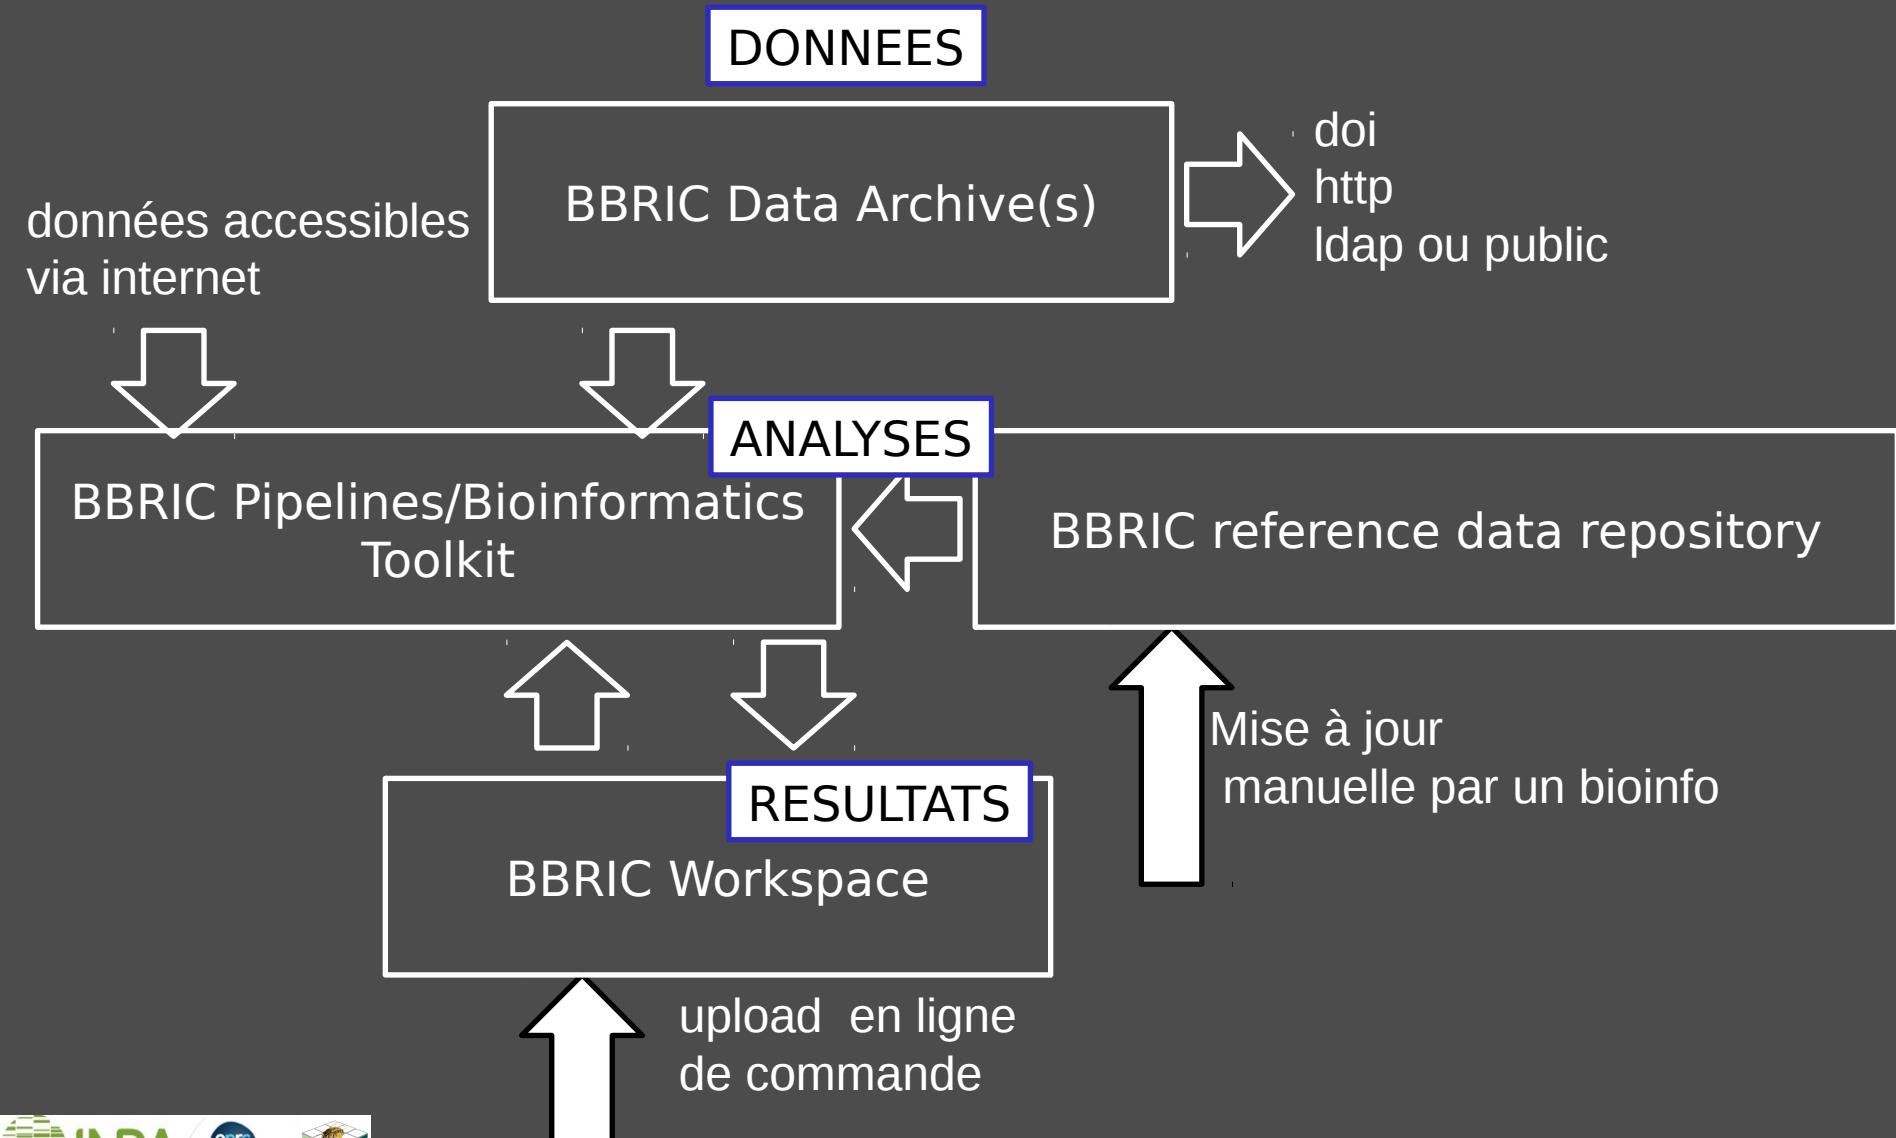
- ▶ Assemblage (genomes/transcriptomes)
- ▶ Annotation structurale des génomes (gènes codants pour des protéines / ncRNA)
- ▶ Annotation fonctionnelle (genomes/transcriptomes)
- ▶ Analyse de l'expression (RNAseq, puces)
- ▶ Détection et analyse du polymorphisme
- ▶ Metagenomique
- ▶ Epigénomique
- ▶ Modélisation des réseaux métaboliques et de régulation.
- ▶ Gestion de collections (bactéries, insectes, etc.)
- ▶ Systématique: identification des espèces de groupes d'espèces d'intérêt
- ▶ Phylogénie, évolution
- ▶ Génomique des populations

Modèles d'intérêt

- ▶ Plantes
- ▶ Bactéries
- ▶ Insectes
- ▶ Nématodes
- ▶ Champignons
- ▶ Oomycetes
- ▶ Virus

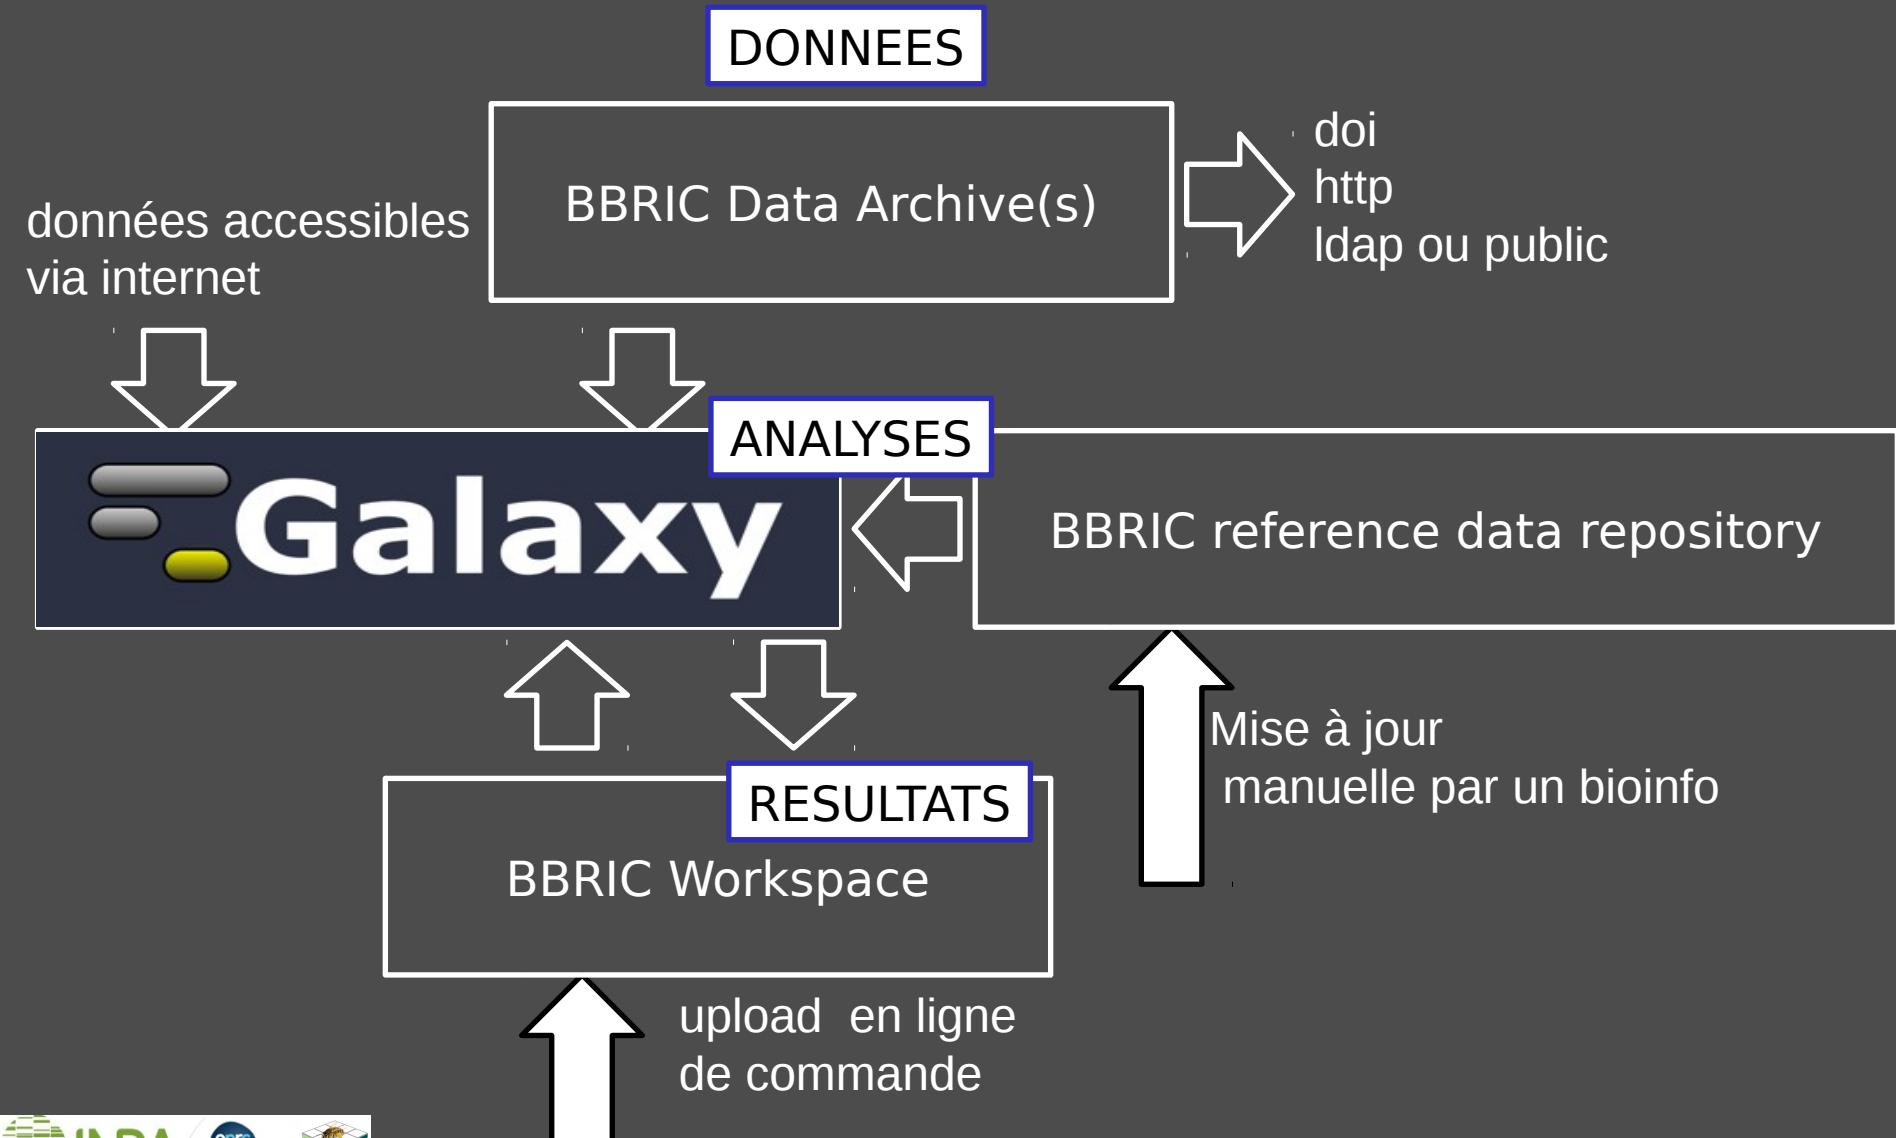
Architecture bioinformatique BBRIC

4 composants interopérables



Architecture bioinformatique BBRIC

4 composants interopérables



Galaxy @ BBRIC

S'adapter au réseau

- ▶ Des instances au plus proche des données
 - @Rennes
 - Accès contrôlé
 - ▶ annuaire LDAP
 - @Toulouse
 - Accès contrôlé
 - ▶ Fédération Education Recherche (Shibboleth)
 - @Ailleurs ?
-
- ▶ Un toolshed pour partager les outils
 - ▶ Un système pour maintenir les données de référence

Galaxy @ BBRIC

Pré-requis avant un passage en production

- ▶ Utilisation de fichiers compressés
 - fastq.gz
- ▶ Interopérabilité avec les instances d'Archive
 - Les utilisateurs doivent pouvoir analyser leurs données
- ▶ Interopérabilité avec les instances Workspace
 - Les utilisateurs doivent pouvoir être autonomes dans le post-processing des résultats intermédiaires

Utilisation de fichiers compressés

- ▶ De nombreux outils le permettent, pourquoi s'en priver ?
- ▶ Pourquoi Galaxy décomprime automatiquement ?
- ▶ Extension des datatypes
 - `datatypes_conf.xml`
 - `lib/galaxy/datatypes/data.py`
- ▶ Modification du code de l'upload
 - `tools/data_source/upload.py`
- ▶ Modification des fiches des outils pour ajout du nouveau type accepté

Interopérabilité avec Archive

Qu'est-ce que l'Archive ?

- ▶ Un système de conservation des données brutes
 - générique
 - sans limite de taille de fichier
- ▶ Un système ouvert
 - accès programmatique (API, client)
 - conversion vers les formats standards (SRA, GEO pour les séquences)
 - publication des données/métadonnées (DOI, lien permanent)
- ▶ Un accès sécurisé et authentifié
 - droits d'accès par fichier
 - authentification par la fédération Education Recherche
- ▶ Un outil accessible aux producteurs de données (les biologistes)
 - interface web (consultation, gestion)
 - moteur de recherche

Interopérabilité avec Archive

Galaxy / BBRIC

Analyze Data Workflow Shared Data Visualization Admin Help User

Tools

search tools

LIPM RNaseq LIPM RNaseq
egnpp Annotation on bacterial genome with RNaseq

Get Data

BBRIC Workspace server
BBRIC Archive server
Upload File from your computer

UCSC Main table browser
UCSC Archaea table browser

BX table browser

EBI SRA ENA SRA

BioMart Central server

GrameneMart Central server

Flymine server

modENCODE fly server

modENCODE modMine server

MouseMine server

Ratmine server

YeastMine server

modENCODE worm server

WormBase server

EuPathDB server

EncodeDB at NHGRI

EpiGRAPH server

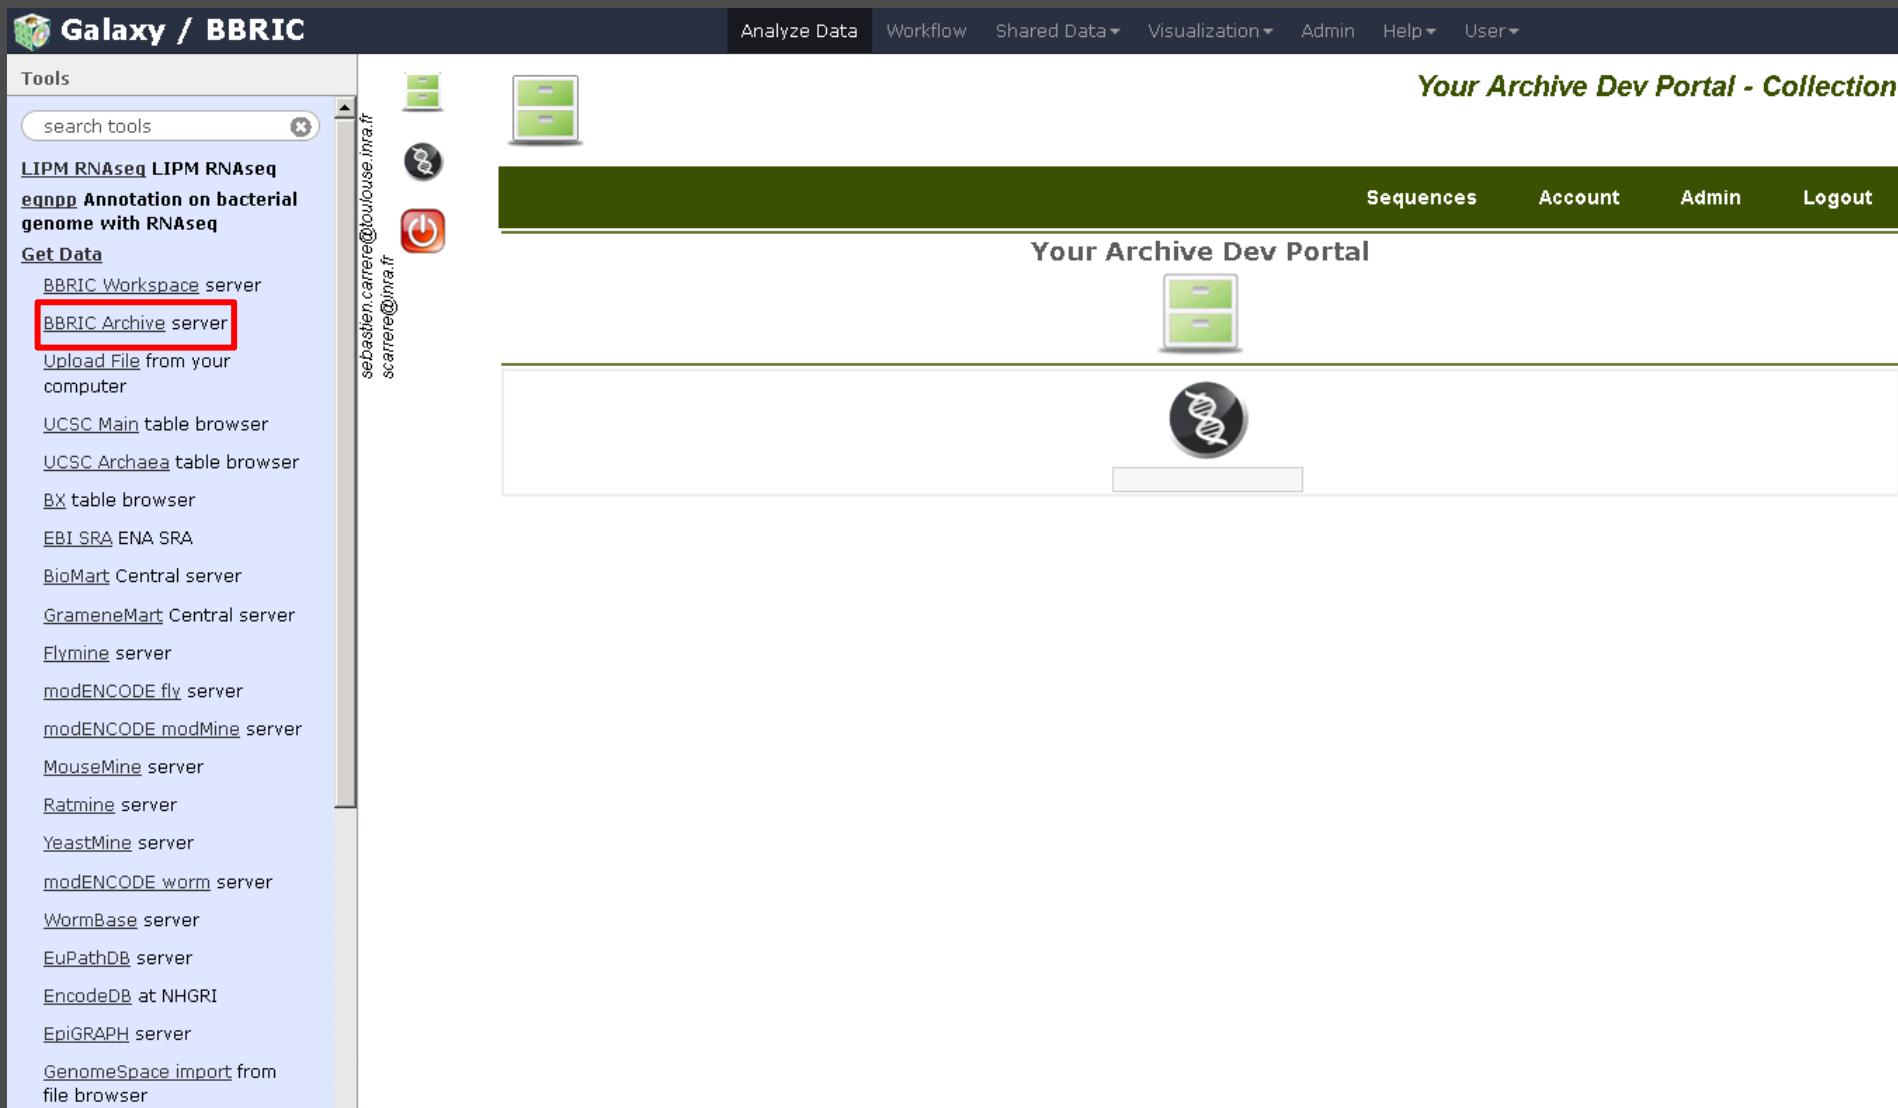
GenomeSpace import from file browser

Your Archive Dev Portal - Collection

Sequences Account Admin Logout

Your Archive Dev Portal

Sebastien.Carrere@toulouse.inra.fr
Scarrere@inra.fr



Interopérabilité avec Archive

Galaxy / BBRIC

Analyze Data Workflow Shared Data Visualization Admin Help User

Tools

LIPM RNaseq LIPM RNaseq
egnpp Annotation on bacterial genome with RNaseq
Get Data
BBRIC Workspace server
BBRIC Archive server
Upload File from your computer
UCSC Main table browser
UCSC Archaea table browser
BX table browser
EBI SRA ENA SRA
BioMart Central server
GrameneMart Central server
Flymine server
modENCODE fly server
modENCODE modMine server
MouseMine server
Ratmine server
YeastMine server
modENCODE worm server
WormBase server
EuPathDB server
EncodeDB at NHGRI
EpiGRAPH server
GenomeSpace import from file browser

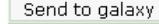
Sebastien.Carrere@toulouse.inra.fr
scarrere@inra.fr

Your Archive Dev Portal - Sequence Collection

Sequences Account Admin Logout

Submit Search Browse Manage

Quick search Envoyer (use * for partial search, ex:'phospho*' will match with for 'phosphorylase', 'phosphokinase')

Contributor	Date	Title	Species	Molecule	Project	Metadata
BBRIC Demo	20131024	GSM1185104	Arabidopsis thaliana	total_RNA	INRA	    
		Send to galaxy	111.94 Mo	bbric.demo@gmail.com, LIPM		

All files are public All files are shared or belong to you Some files are shared All files are private

The screenshot shows the Galaxy web interface integrated with the BBRIC Archive Dev Portal. On the left, a sidebar lists various external data sources like EBI SRA, BioMart, and Flymine. The main area displays a table of sequence collection details, with the 'Send to galaxy' button highlighted by a red box. The table includes columns for Contributor, Date, Title, Species, Molecule, Project, and Metadata. The 'Metadata' column contains icons for creating a new item, editing, viewing, and sharing.

Interopérabilité avec Archive

Galaxy / BBRIC

Analyze Data Workflow Shared Data Visualization Admin Help User

Tools

search tools

LIPM eqnp geno Get D BB BB Up co

The following job has been successfully added to the queue:
2: SRR932114.fastq.gz

You can check the status of queued jobs and view the resulting data by refreshing the **History** pane. When the job has been run the status will change from 'running' to 'finished' if completed successfully or 'error' if problems were encountered.

You are now being redirected back to [Galaxy](#)

History

Unnamed history 111.3 MB
2: SRR932114.fastq.gz
1: SRR932114.fastq.gz

Send to galaxy 111.94 Mo bbric.demo@gmail.com, LIPM

All files are public All files are shared or belong to you Some files are shared All files are private

UCSC Main table browser
UCSC Archaea table browser
BX table browser
EBI SRA ENA SRA
BioMart Central server
GrameneMart Central server
Flymine server
modENCODE fly server
modENCODE modMine server
MouseMine server
Ratmine server
YeastMine server
modENCODE worm server
WormBase server
EuPathDB server
EncodeDB at NHGRI
EpiGRAPH server
GenomeSpace import from file browser

Interopérabilité avec Archive

Galaxy / BBRIC

Analyze Data Workflow Shared Data Visualization Admin Help User

Your Archive Dev Portal - Sequence Collection

Tools search tools

LIPM eqnp geno Get D BB BB Up co UCSC Main table UCSC Archaea t BX table browse EBI SRA ENA SR BioMart Central GrameneMart C Flymine server modENCODE fly modENCODE mo MouseMine serv Ratmine server YeastMine serv modENCODE wo WormBase serv EuPathDB serv EncodeDB at NHGRI EpiGRAPH server GenomeSpace import from file browser

The following job has been successfully added to the queue:
2: SRR932114.fastq.gz

You can check the status of queued jobs and view the resulting data by refreshing the History pane. When the job has been run the status will change from

Tool: BBRIC Archive

Name: SRR932114.fastq.gz
Created: Wed Nov 27 15:58:49 2013 (UTC)
Filesize: 111.3 MB
Dbkey: ?
Format: fastq.gz
Galaxy Tool Version: 1.0.0
Tool Version:
Tool Standard Output: stdout
Tool Standard Error: stderr
Tool Exit Code: 0
API ID: 22c94bd07149de56
Full Path: /www-galaxy/database/files/000/dataset_214.dat
Job Command-Line: python /www-galaxy/shed_tools/toolshed.genouest.org/repos/abreraud/bbric_archive/e4b9c92213f0/bbric_archive/bbric_archive.py /www-galaxy/database/files/000/dataset_214.dat Sebastien.Carrere@toulouse.inra.fr 2 0

Input Parameter	Value	Note for rerun
user_email	not used (parameter was added after this job was run)	
user_id	not used (parameter was added after this job was run)	
GALAXY_URL	not used (parameter was added after this job was run)	

Inheritance Chain

SRR932114.fastq.gz

History

Unnamed history 111.3 MB

History

Unnamed history 222.7 MB

done format: fastq.gz, database: ?

gzipped file

1: SRR932114.fastq.gz

Interopérabilité avec Workspace

Galaxy / BBRIC

Analyze Data Workflow Shared Data Visualization Admin Help User

Tools

search tools

LIPM RNaseq LIPM RNaseq
eqnpp Annotation on bacterial genome with RNaseq

Get Data

BBRIC Workspace server (highlighted with red box)

BBRIC Archive server

Upload File from your computer

UCSC Main table browser

UCSC Archaea table browser

BX table browser

EBI SRA ENA SRA

BioMart Central server

GrameneMart Central server

Flymine server

modENCODE fly server

modENCODE modMine server

MouseMine server

Ratmine server

YeastMine server

modENCODE worm server

WormBase server

EuPathDB server

EncodeDB at NHGRI

EpiGRAPH server

GenomeSpace import from file browser

Sebastien.Carrere@toulouse.inra.fr
scarrere@inra.fr

Bioinformatique
Bioinformatique
Représentation
Intégration
des
Connaissances

Analyses Search Manage Admin Logout

Last 10 Analyses All Analyses

Quick search Envoyer

List of the 10 last analyses

	Date	Title	Description	Context
	20131106	BRADI_data	Donnees FATAL	service

Interopérabilité avec Workspace

Galaxy / BBRIC

Analyze Data Workflow Shared Data Visualization Admin Help User

Tools

search tools

LIPM RNaseq LIPM RNaseq
eqnpp Annotation on bacterial genome with RNaseq

Get Data

BBRIC Workspace server (highlighted with red box)

BBRIC Archive server

Upload File from your computer

UCSC Main table browser

UCSC Archaea table browser

BX table browser

EBI SRA ENA SRA

BioMart Central server

GrameneMart Central server

Flymine server

modENCODE fly server

modENCODE modMine server

MouseMine server

Ratmine server

YeastMine server

modENCODE worm server

WormBase server

EuPathDB server

EncodeDB at NHGRI

EpiGRAPH server

GenomeSpace import from file browser

Sebastien.Carrere@toulouse.inra.fr
scarrere@inra.fr

Bioinformatique
Bioinformatique
Représentation
Intégration
des
Connaissances

Analyses Search Manage Admin Logout

Last 10 Analyses All Analyses

Quick search Envoyer

List of the 10 last analyses

	Date	Title	Description	Context
	20131106	BRADI_data	Donnees FATAL	service

The screenshot shows the Galaxy web interface for the BBRIC workspace. The top navigation bar includes links for Analyze Data, Workflow, Shared Data, Visualization, Admin, Help, and User. The main header "Workspace DEV" is displayed. On the left, a sidebar lists various external data sources and servers, with "BBRIC Workspace server" highlighted by a red box. Below this, a user's email address "Sebastien.Carrere@toulouse.inra.fr" and "scarrere@inra.fr" are shown. A logo for "Bioinformatique Bioinformatique Représentation Intégration des Connaissances" is present. The main content area displays a table titled "List of the 10 last analyses". The first row of the table is highlighted with a red box around the folder icon, indicating the most recent analysis. The table columns are Date, Title, Description, and Context.

Interopérabilité avec Workspace

Galaxy / BBRIC

Analyze Data Workflow Shared Data Visualization Admin Help User

Tools

- [search tools](#)
- [LIPM RNAseq LIPM RNAseq](#)
- [egnpp Annotation on bacterial genome with RNAseq](#)
- [Get Data](#)
 - [BBRIC Workspace server](#)
 - [BBRIC Archive server](#)
 - [Upload File from your computer](#)
- [UCSC Main table browser](#)
- [UCSC Archaea table browser](#)
- [BX table browser](#)
- [EBI SRA ENA SRA](#)
- [BioMart Central server](#)
- [GrameneMart Central server](#)
- [Flymine server](#)
- [modENCODE fly server](#)
- [modENCODE modMine server](#)
- [MouseMine server](#)
- [Ratmine server](#)
- [YeastMine server](#)
- [modENCODE worm server](#)
- [WormBase server](#)
- [EuPathDB server](#)
- [EncodeDB at NHGRI](#)
- [EpiGRAPH server](#)
- [GenomeSpace import from file browser](#)

sebastien.carrere@toulouse.inra.fr
scarrere@inra.fr

Workspace DEV

Analyses Search Manage Admin Logout

Last 10 Analyses All Analyses

BRADI_data - 20131106

Summary

Owner	sebastien.carrere@toulouse.inra.fr
Title	BRADI_data
Date	20131106
Context	service
Description	Donnees FATAL
Provider	sebastien.carrere@toulouse.inra.fr
Share	

Files

Send to galaxy

e566972ed31b8ae67b1a96e32147e7db_20131106.BRADI_data.zip

- BRADI_data
 - BRADI.clusters
 - BRADI.cfg.mask
 - tair
 - BRADI.peptides
 - BRADI.reads
 - BRADI.pep.iprs...
 - BRADI.report
 - BRADI.FrameD

Expand this branche
Display info
galaxy Link
Save as...

Interopérabilité avec Workspace

Galaxy / BBRIC

Analyze Data Workflow Shared Data Visualization Admin Help User

Tools search tools

LIPM RNAseq LIPM RNAseq egnp Annotation on bacterial genome with RNAseq Get Data

enrc@toulouse.inra.fr

Bioinformatique Biodiversité Représentation & Intégration des Connaissances

Workspace DEV

Analyses Search Manage Admin Logout

Last 10 Analyses All Analyses

Analyze Data Workflow Shared Data Visualization Admin Help User

Using 224.2 MB

Brad000371_132_566_3	044996DE9E52498F	144	HMMPfam	PF00234	Tryp_alpha_amyl	62	139	0.00109999999999999999
Brad000371_132_566_3	044996DE9E52498F	144	superfamily	SSF47699	Bifunc_inhib/LTP/seed_store	64	143	1.700002955900538E-2
Brad000371_132_566_3	044996DE9E52498F	144	HMMSmart	SM00499	AAI	62	143	6.400000387884858E-2
Brad000371_132_566_3	044996DE9E52498F	144	Gene3D	G3DSA:1.10.110.10	LPT_helical	59	143	1.3999989204987804E-2
Brad000001_211_1497_1	A82E34902D6AF5CA	428	HMMPfam	PF00004	AAA	154	295	6.6e-1
Brad000004_76_852_1	09578AC44C4B89C2	258	HMMPfam	PF00504	Chloroa_b-bind	58	224	1.4e-5
Brad000005_1_1274_3	0CCC384FD028407E	423	HMMPfam	PF00274	Glycolytic	79	423	2.3e-16
Brad000006_91_1104_1	9203040545794FB7	337	HMMPfam	PF02800	Gp_dh_C	159	316	5.6e-7
Brad000006_91_1104_1	9203040545794FB7	337	HMMPfam	PF00044	Gp_dh_N	4	154	3.3e-5
Brad000007_630_1309_3	20098A0D4B7AB60E	226	HMMPfam	PF01536	SAM_decarbox	12	226	1e-8
Brad000008_1_1262_3	145AD88C77835C39	419	HMMPfam	PF00240	ubiquitin	44	112	1.2e-3
Brad000008_1_1262_3	145AD88C77835C39	419	HMMPfam	PF00240	ubiquitin	120	188	1.2e-3
Brad000008_1_1262_3	145AD88C77835C39	419	HMMPfam	PF00240	ubiquitin	196	264	1.2e-3
Brad000008_1_1262_3	145AD88C77835C39	419	HMMPfam	PF00240	ubiquitin	272	340	1.2e-3
Brad000008_1_1262_3	145AD88C77835C39	419	HMMPfam	PF00240	ubiquitin	348	416	1.2e-3
Brad000009_109_1599_1	E8AED979303DE70D	496	HMMPfam	PF00199	Catalase	18	399	2.3e-17

History

Unnamed history 222.8 MB

4: BRADI.pep.iprscan

done format: tabular, database: 2

BRADI.clusters

BRADI.cfg.mask

tair

BRADI.peptides

BRADI.reads

BRADI.pep.iprscan

BRADI.report

BRADI.FrameD

Expand this branche

Display info

galaxy Link

Save as...

Atelier 29-30/10/2013

- ▶ Quinzaine de bioinformaticiens du CATI BBRIC
- ▶ 1/3 connaît les aspects techniques de Galaxy
- ▶ Etape 1: déployer un outil simple dans Galaxy from scratch
 - Démystifier Galaxy
- ▶ Etape 2: utiliser Appli.pm
 - Se faciliter la vie
- ▶ Etape 3: Déployer un outil complexe (pipeline)
 - Se rendre utile

Atelier 29-30/10/2013

- ▶ Etape 1: déployer un outil simple dans Galaxy from scratch
 - Predotar, tmhmm, signalpHMM
 - Bilan des difficultés rencontrées
 - Gestion dynamique des formats de sortie
 - ▶ Paramètres conditionnels
 - ▶ Itérateurs / collection
 - ▶ Sélection des *datatypes*
 - ▶ Gestion des paths
 - ▶ Débogage

Mais tout le monde peut y arriver et tout le monde y est arrivé !

Atelier 29-30/10/2013

► Etape 2: Appli.pm

► Qu'est-ce ?

- Un module Perl de la « lipmutils » permettant de décrire un programme.
- Développé pour déployer des services Mobyle & BioMOBY étendu à Galaxy

► Pourquoi faire?

- décrire une et une seule fois son programme
- générer autant d'usage que d'outils (CLI, Mobyle, Galaxy, JSON, **next ?**)

► Sous quelles contraintes?

- Perl
- Connaitre les datatypes des interfaces (mobyle ≠ biomoby ≠ galaxy ≠ GetOptLong ≠ EDAM)

Atelier 29-30/10/2013

- ▶ Etape 2: Appli.pm
- ▶ Quel cas d'utilisation ?
 - un programme à ajouter dans Galaxy
 - ce programme a une interface en ligne de commande
 - j'écris un wrapper Perl utilisant Appli pour générer son usage Galaxy
- ▶ Résultat
 - Permet d'obtenir rapidement un outil fonctionnel
 - Permet de générer facilement une trame du XML Galaxy
 - *Gère les collections, mais pas les paramètres conditionnels*

Atelier 29-30/10/2013

- ▶ Etape3: Déployer un outil complexe (pipeline)
- ▶ EuGène-P
 - Pipeline d'annotation de génomes procaryotes
 - ▶ Intègre des données de similarité (Blastx)
 - ▶ Intègre des données de transcriptomique (RNA-seq)
 - ▶ Intègre des résultats de prédicteurs *ab-initio* (Prodigal, tRNAScan-SE,...)
 - Le wrapper devait
 - ▶ prendre en entrée X banques de RNA-seq, un génome nu
 - ▶ générer l'environnement (fichiers de conf, arborescence pour l'exécution du pipeline)
 - ▶ produire un fichier d'annotation au format GFF3

OK pour la majorité des binômes, quelque soit le langage et la méthode utilisée

Bilan de l'atelier

- + Montée en compétence commune
- + Prise en main de l'outil
- Crash des *handlers*
En cause: l'écriture de caractères spéciaux sur stderr !
- Difficultés logs
Comment trouver les commandes exécutées ?
- ~ Les types de données, les ontologies
- ~ Nécessité de redémarrer régulièrement
Problèmes de cache

Bonnes pratiques

- ▶ Toolshed
 - Partager les outils
- ▶ Appli.pm (ou autre ?)
 - Si demain, l'outil à la mode n'est plus Galaxy
- ▶ Déployer des outils de haut niveau
 - Utilisables
 - Utiles
- ▶ Fichiers compressés
 - Obligatoire dans un environnement de production

Merci