



RÉPUBLIQUE
FRANÇAISE
*Liberté
Égalité
Fraternité*

anr
agence nationale
de la recherche



DATA
TERRA



PNDDB
Pôle National
de Données de Biodiversité

Infrastructure technique intégrée Équipements et Interconnexion des sites



Karim Ramage (CNRS/IPSL)
Coordinateur technique adjoint du projet GAIA DATA

KICK-OFF 12 AVRIL 2022



SOMMAIRE



01

CONTEXTE et ENJEUX

02

OBJECTIFS et MOYENS

03

EVOLUTION DES
CENTRES DE GAIA DATA

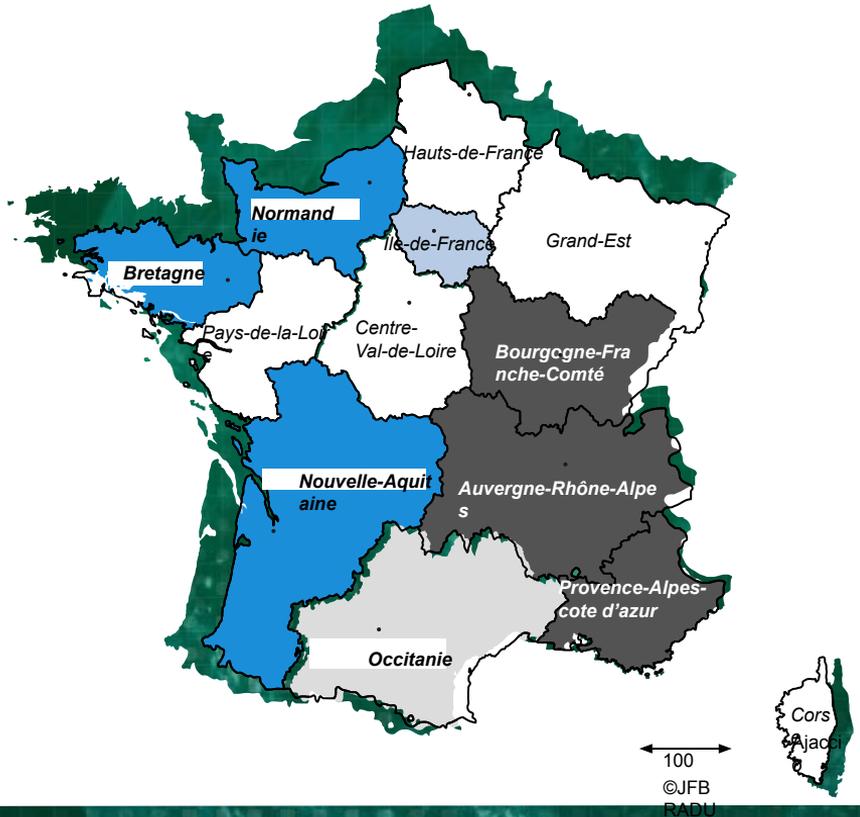
04

ARTICULATION PROJETS
NUMÉRIQUES PIA3/4



01

Contexte et Enjeux



Contexte numérique national ESRI : InfraNum

Rationaliser les infrastructures informatiques de l'ESR

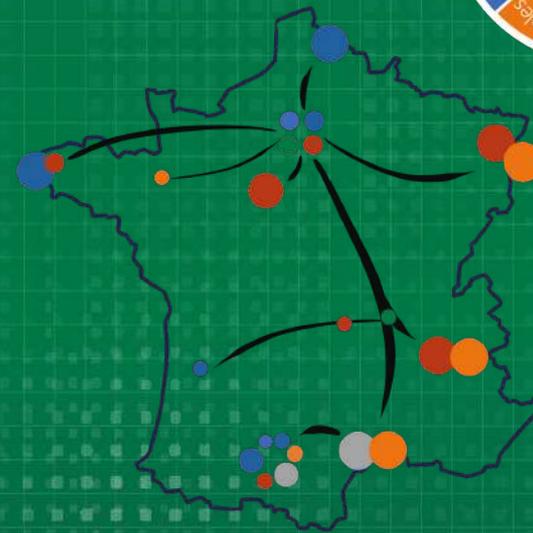
- réduire l'impact écologique des salles informatiques (datacentre)
- regrouper les RH nécessaires pour la gestion des datacentres
- offrir des hébergements à l'état de l'art, sécurisés, résilients et performants énergétiquement
- au-delà de l'hébergement physique : tendre vers une offre de cloud pour l'ESRI
- en s'appuyant sur les grandes infrastructures de calcul et données de l'ESRI : GENCI, Mésocentres régionaux, France-Grilles

Contexte des 3 Infrastructures de Recherche

- 30 Centres de données et Services regroupant les experts :
 - ingénierie de la données
 - ingénierie logicielle
 - ingénierie systèmes et réseau
- 50 Po (2020) ; 100 Po (2023) ; 150 Po (2025)
- 50 000 cœurs de calcul cumulés sur les centres de traitement

Stratégie Gaia Data pour les Equipements

Concentrer les investissements en **équipement de Gaia Data** sur les Centres de Calcul et Données des pôles de **Data-Terra**, de **ClimERI** et du **PNDB** compatibles avec la politique InfraNum, tout en **gardant un ancrage régional** essentiel au fonctionnement et au financement des activités des trois IRs.



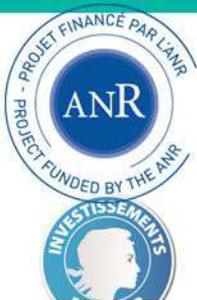
8 sites principaux
30 sites existants

INFRASTRUCTURE GAIA DATA

8 Sites regroupant :

- Centres de Calcul Nationaux (CINES, IDRIS)
- Centres de Calcul et données d'organismes (CNES, Ifremer, BRGM)
- Mésocentres Régionaux (GRICAD, UniStra, Univ Lille, Meso@LR)
- Mésocentres Thématiques (ICARE, ESPRI, IPGP-Dante)

en développant **les liens avec les infrastructures nationales** et en tenant compte des **évolutions du paysage numérique national et européen** au cours du projet : Projets PIA3 FITS et MesoNet, développement du **Cloud et du calcul national** (FG-Cloud, Projet Clusster, PEPR Cloud, GENCI), et **européen** (EOSC, DIAS, Gaia-X, EUROPHPC)



Projets Equipex+ ou PIA4 infra

- FITS
- MesoNet
- Clusster

PEPR thématiques

- PEPR Cloud

Projets H2020 – Horizon Europe

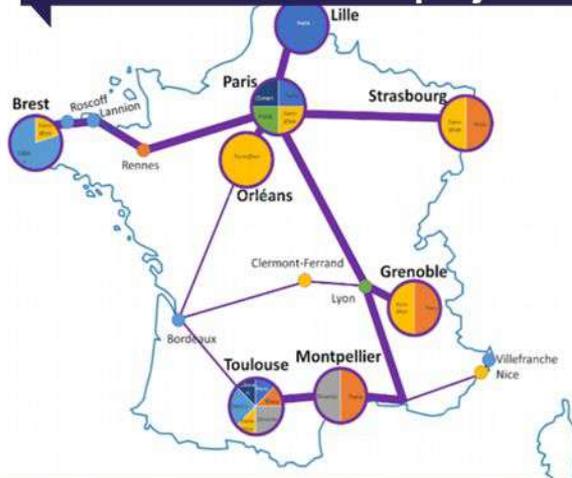
- IS-ENES
- PHIDIAS
- EOSC-Pillar
- FAIR EASE



Projets CPER en région



relation avec des projets connexes



Intégré dans le paysage international / Européen



02

Objectifs et Moyens

Renforcer les moyens dans les Centres de Calcul et Données pour assurer les missions des pôles et IR

- Stockage des données de référence
- Production des données à valeur ajoutée
- Distribution

Développer les infrastructures pour permettre l'interopérabilité des accès aux données

- Interconnexion réseau
- Grille de données
- Datalakes

Renforcer les équipements et développer les systèmes pour assurer l'interopérabilité des services entre les Centres de Calcul et Données

- Containerisation, cloud et plateforme IaaS/PaaS/IaasC
- Outils de déploiements logiciels
- Authentication and Authorization Infrastructure / Single Sign On

Renforcer les architectures spécialisées pour le service de la données

- Nœuds pour la visualisation, traitements à la demande (Virtual Research Environment, Earth Analytic Labs)
- IA / Machine Learning



Budget WP2 Infrastructure Gaia Data

□ **Equipement : 8 777 445 €**

- Renforcement/Acquisition des équipements réseaux et sécurité..... 758 503 €
- Renforcement des espaces "capacitifs" pour les données de référence..... 2 361 950 €
- Renforcement/Acquisition des espaces de stockage d'échange 1 530 959 €
- Renforcement des espaces de disques "rapide" pour le traitement de données..... 1 384 892 €
- Renforcement des processeurs pour les plateformes d'analyses..... 1 069 191 €
- Renforcement des processeurs graphiques pour la visualisation..... 509 190 €
- Renforcement des plateformes de virtualisation/conteneurisation pour l'hébergement des services... 1 162 760 €

□ **Prestations : 610 768 €**

- Location Stockage/Calcul/Locaux dans les mésocentres régionaux 281 728 €
- Installation / Déploiement des équipements..... 329 040 €

□ **Réduction par rapport au budget initial : 22 % en moyenne pour l'ensemble des sites**

- Changement de la repartition entre phase de développement et phase d'exploitation □ de 60/40 à 70/30, permettant de faire porter la réduction essentiellement sur la phase d'exploitation

□ Recherche de financements complémentaires au niveau national (CPER, PEPR) et Européens (EOSC)

□ Optimisation des marchés en lien avec les autres projets PIA3 (MesoNet) et GENCI (CINES, IDRIS)

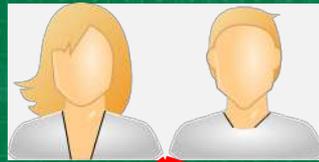
□ **Architecture logicielle** : Contribution du WP3 pour le développement et le déploiement



03

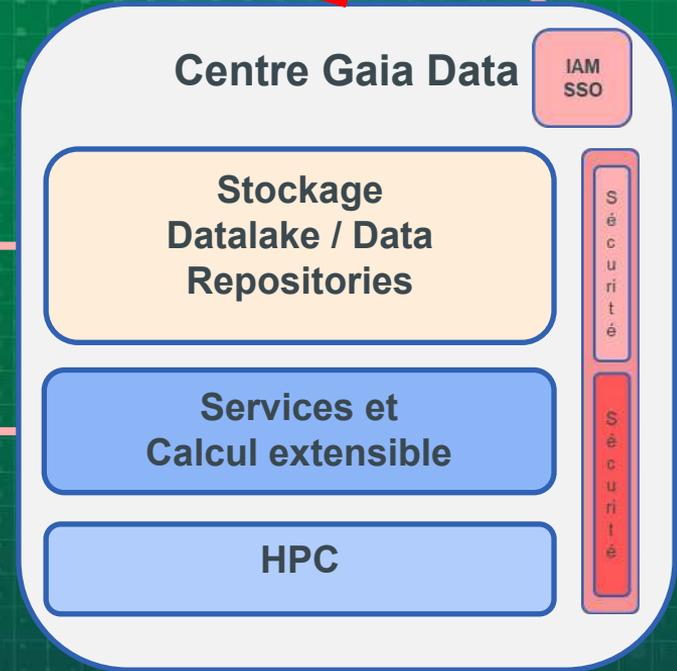
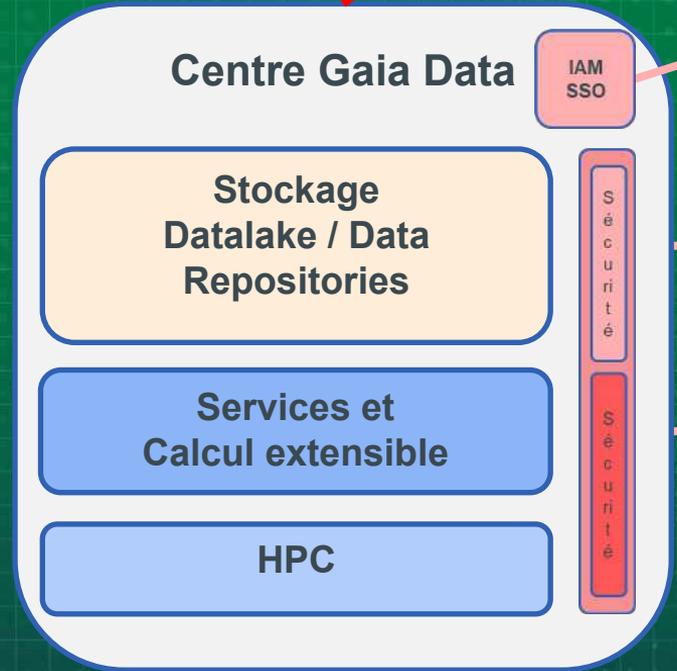
Evolutions des Centres de Gaia Data

Architecture Gaia Data



Accès aux données :
S3, OpenDAP, GridFTP

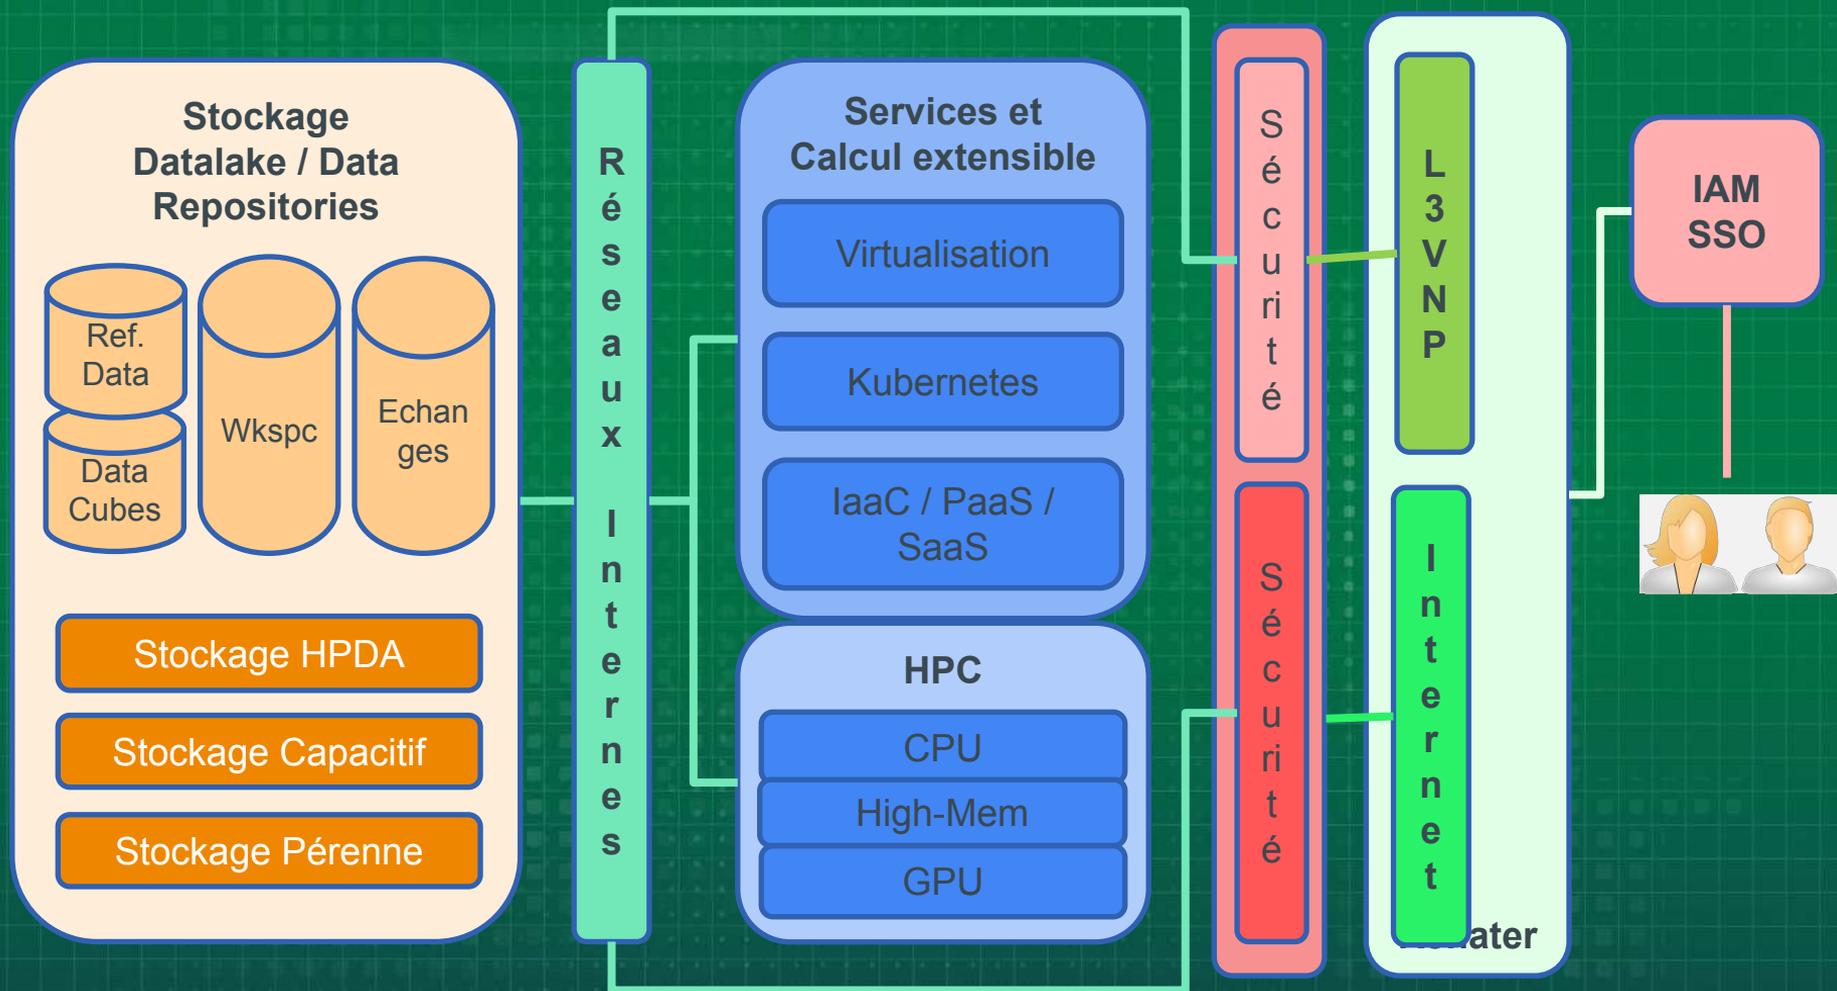
Accès aux Services :
OGC, notebooks, ...



iRods / S3

Docker Singularity

Architecture Cible des Centres de Gaia Data



Extension des systèmes de stockage capacitif des 8 centres pour les données de références

- **Garantir la capacité des pôles et des IR** à assurer leurs missions pour l'acquisition, le traitement, **l'hébergement** et la distribution des données du système Terre et de la biodiversité

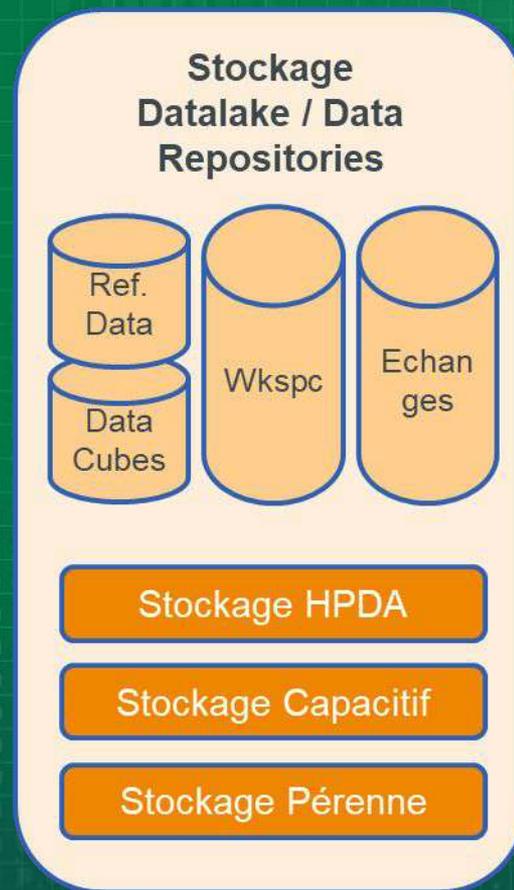
Renforcement des espaces de disques rapides :

- **Stockage au plus près des ressources de calcul** : espaces tampons pour héberger des copies des données du format d'origine, proche de l'observation ou de la simulation, vers des formats de type « **DataCubes** » pour l'analyse (algorithmes parallèles de type IA, par exemple) ou pour la visualisation : images tuilées, facettes 3D, ...

Acquisition d'espaces de stockage « tampon » pour les échanges inter-centres

- Hébergement de **données de références communes** et utiles à plusieurs centres
- **Transfert de données** d'un hébergeur vers un centre de calcul (GENCI par exemple) pour des (re-)traitements massifs
- **Regroupement de jeux de données** multi-centres pour les traitements à la demande de Earth Analytics Labs

Evolution des infrastructures Ressources de Stockage



- **Renforcement des ressources HPC pour la production régulière**
- **Acquisition de nœuds à large mémoire pour:**
 - les traitements rapides à la demande
 - sélections immédiates des données d'intérêt parmi des données extrêmement nombreuses (moteurs d'indexation, TripleStore et bases NoSQL)
- **Nœuds pour la visualisation des données**
 - Processeurs graphiques pour générer des images à la volée
- **Développement des plateformes de virtualisation / containerisation pour l'hébergement des services**
- **Interopérabilité des traitements entre les centres de Gaia Data**
 - environnements logiciels reproductibles, standardisés et paramétrables
 - Packaging des applications et environnements (Guix, Spack, ...)
 - Conteneurisation des codes et applications (docker, singularity)
 - Orchestrateurs d'infrastructure (Terraform, Openstack, K8S) pour faciliter les déploiements de services
- **Développements en lien avec France-Grilles, Clusster, EOSC-Association TF, ESA Cloud**

Evolution des infrastructures Ressources de Calcul



Déploiement d'une Infrastructure d'Authentification et Autorisation interoperable pour l'accès aux données et services de Gaia Data

- Solution basée sur les travaux menés par AERIS : **Keycloak**

Création d'un annuaire des acteurs et des utilisateurs

- Annuaire centralisé des acteurs et des utilisateurs
- Mise en place d'un mécanisme d'authentification unique
- Proposer un service de gestion des autorisations centralisé

Gestion des niveaux de confiance

- Non authentifié
- Authentification déléguée (Fédération Renater, ORCID, réseaux sociaux, ...)
- Utilisateur authentifié d'un organisme (annuaires existants)

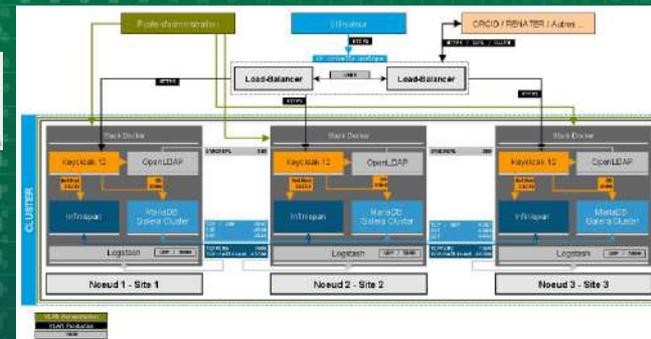
Mise en place de workflow de validation de compte

- Sécurisation fine des jeux de données des catalogues
- Statistique et traçabilité des téléchargements

Possibilité de synchroniser une fédération d'identité déjà en place dans les pôles et IR

Evolution des infrastructures Authentification / Autorisations - SSO

IAM
SSO



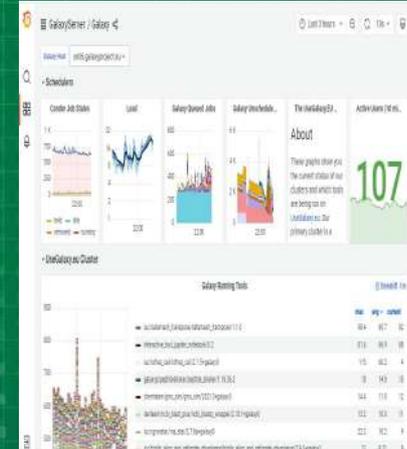
Développement d'un système de supervision et d'accounting mutualisé pour:

- répondre à un niveau de service (SLA) défini,
- faciliter l'exploitation de l'infrastructure,
- piloter les déploiements de ressources,
- mesurer l'empreinte carbone des systèmes

- Supervision des infrastructures systèmes et des Services
- Système de détection et d'alerte d'indisponibilité des services, de surcharge des ressources
- Métriques sur l'utilisation des ressources calcul, stockage
- Métriques sur l'utilisation de la donnée

Dashboards communs Gaia Data

Evolution des infrastructures Supervision et Métriques





04

Articulation avec les Projets PIA3/PIA4

Articulation avec les Projets PIA3/PIA4 : MESONET

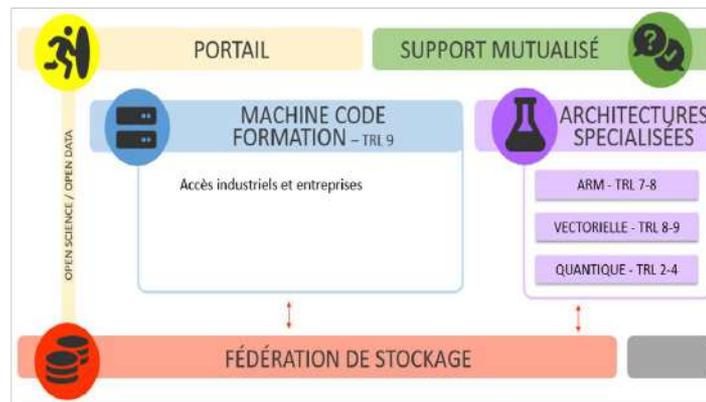


Infrastructure nationale distribuée de type *mésocentre*

- Renforcer la structuration de l'offre régionale
- Disposer d'infrastructures calcul / IA au meilleur niveau technologique
- Intégrer les nouvelles communautés
- Encourager les échanges Tiers1-Tiers2
- Fournir une Infrastructure agile pour le développement des codes et la formation
- S'intégrer à la vision nationale et européenne

➤ Créer une Infrastructure de Recherche

14,2 M€ financés sur un budget total de 30,4 M€
début du projet au 01/10/2021 pour une durée de 6 ans



- Mésocentres régionaux participant aux deux projets
- Problématiques communes :
 - Fédération du stockage : 20 Po distribués iRods (workdir / staging)
 - Interconnexions réseau
 - Authentification fédérée
 - Sécurité (12 sites démarche d'audit sécurité)
- Participation croisée aux GT des différents projets
- Co-financements pour certains équipements

Articulation avec les Projets PIA3/PIA4 : FITS

Ambition

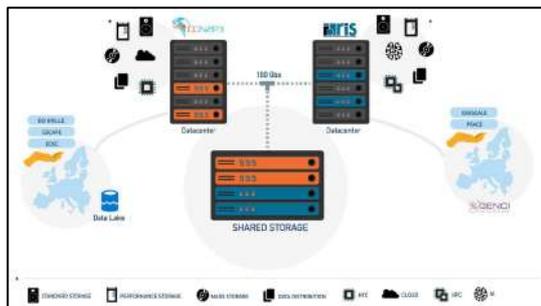
Fédérer les services et savoir-faire de l'IDRIS et du CC-IN2P3, dans le respect de leurs missions spécifiques, à travers la mise en oeuvre d'une infrastructure répartie de stockage, de traitement et de mise à disposition, diffusion et valorisation des données, hébergées dans des conditions environnementales à faible empreinte carbone.

Objectifs

- Permettre aux IR, disposant d'un modèle de calcul établi et nécessitant l'accès à des technologies variées d'y accéder de manière simple et facile
- Leur proposer des moyens d'accès et de distributions à leurs données ouvertes
- Permettre aux IR disposant de leur infrastructure de les héberger et opérer dans un environnement à l'état de l'art

Acteurs

- Acteurs du calcul au CNRS
- Communautés de recherche



Convergences possibles entre les projets :

- Authentification fédérée
- Portail d'accès aux ressources
- Débordement vers les mésocentres et cloud via France-Grille
- Hébergement des infrastructures informatiques de Gaia Data

Articulation avec les Projets PIA3/PIA4 : CLUSSTER



CLUSSTER

Cloud Unifié Souverain de Services, de Technologies et d'infrastructures

Réponse à AMI de Bpifrance relatif à la stratégie d'accélération cloud

Développement et renforcement de la filière française et européenne du Cloud

WHAT?



Un portail unifié et souverain

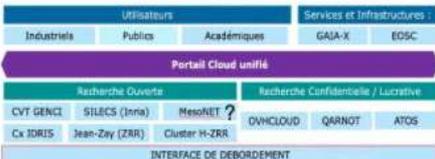
- Fédérer l'ensemble des infrastructures existantes des acteurs privés et publics et des offres de services à valeur ajoutée
- Recherche ouverte, confidentielle et activités lucratives
- Secteur Académique, Industrielle, public
- Intégration écosystème européen; GAIA-X et EOSC



- Faciliter la lisibilité de l'écosystème pour les utilisateurs et l'usage de toutes les ressources/services existantes en France
- Accompagner: Formation, Veille techno, expertise métier

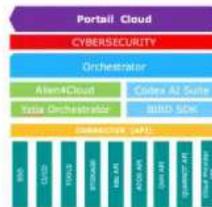
Perspective

- Evolution des services : support à l'adhésion pour couvrir de nouveaux verticaux métiers
- Evolution des domaines: Extension au quantique et à la simulation numérique



Contexte

- AI For humanity (2018)
- Recherche ouverte: Jean Zay (GENCI/IDRIS)
- Recherche confidentielle : OVH, Atos, Activeeon, Qarnot, etc.
- Des expertises académiques
- Des expertises industrielles métiers
- *Aucune offre unique adressant Recherche ouverte et confidentielle et offrant des services d'expertise*



Convergence possibles entre les projets :

- Gaia Data : Use Case de Clusster
- Authentification fédérée
- Portail d'accès unifié
- Interopérabilité des traitements
- Capacité de débordement
- Hébergement des services Gaia Data pour les utilisateurs du secteur aval
- Portail vers les infrastructures européennes (EOSC, Gaia-X)



DATA
TERRA



*Ce travail a bénéficié d'une aide de l'Etat
gérée par l'Agence Nationale de la Recherche
au titre du programme Investissements
d'Avenir Equipex+.*



contact@gaia-data.org

www.gaia-data.org

