



SIESTA : Cloud confidentiel pour la recherche

Vincent Legoll

vincent.legoll@iphc.cnrs.fr

JCAD – septembre 2025



Funded by
the European Union





Cloud confidentiel pour la recherche

SIESTA :
Secure Interactive Environments for SensiTive data Analytics

<https://eosc-siesta.eu>

Traduction :
Environnements Hyper-sécurisés et interactifs Pour l'Analyse de Données sensibles

Projet Européen EOSC: European Open Science Cloud

- Budget total : ~5M€
- Durée : 36 mois

```
0111011101101000011010010 01100
01100101001000000011000100111010
0010000001110011011100101110011
0010111001 01101101010100100
0110111111010101110 000101110
01110111011000010101110100
01100101001010111001101110100
0111001000100001000101100001
01101110 00100011 1101101101
00 110011100100110000101101110
011001000110100101101100110100
0010100000110000001011000 0000
00110001001010010010100100101001
```

Partenaires

12 partenaires :

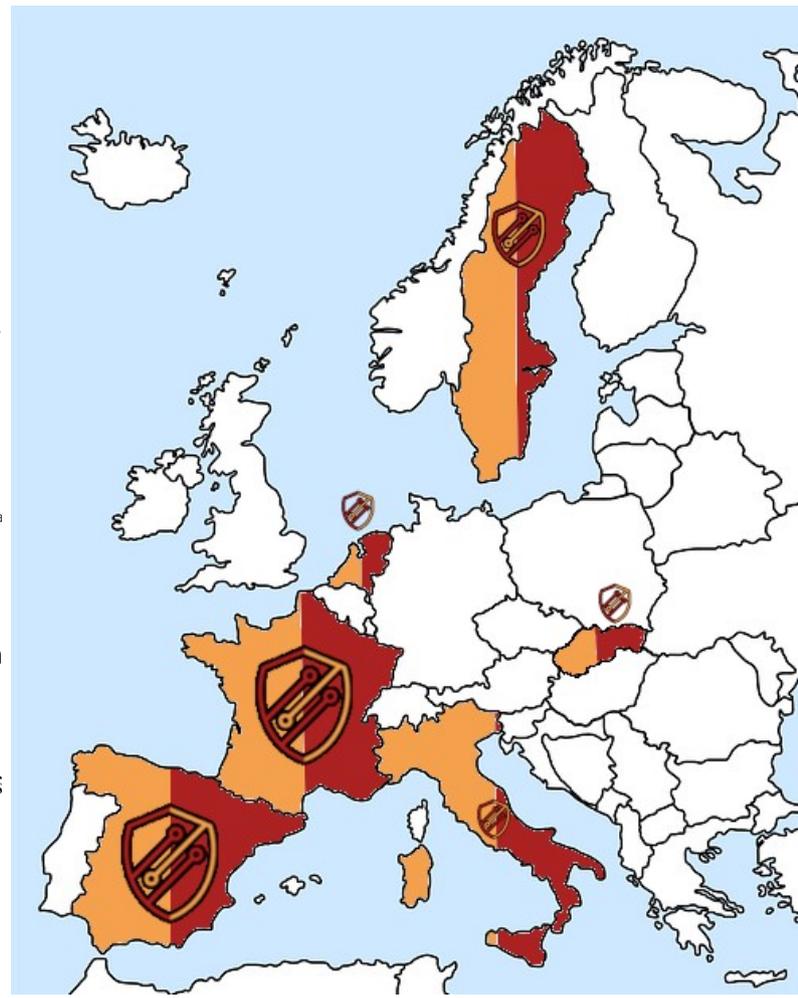
- Institutions de recherche
- Entreprises (service, logiciel, avocats)

6 pays :

- **Espagne**
 - CSIC – IFCA – IFISC - UIB
 - INE - Instituto Nacional de Estadística
 - JdCA – Javier de la Cueva (cabinet d'avocats)
 - Predictia – Société de R&D (spinoff University of Cantabria)
 - ULE - Universidad de León
- **France**
 - CNRS
 - INSERM
- **Hollande**
 - NRU/SRU - Donders Institute for Brain, Cognition, and Behaviour - Radboud University
- **Italie**
 - ISI - International Statistical Institute
- **Slovaquie**
 - IISAS - Institute of Informatics Slovak Academy of Sciences
 - IWAY - Interway (Société de Services)
- **Suède**
 - CEN - Cendio (ThinLinc, services et FOSS)



Neurobiology Research Unit
Rigshospitalet
Copenhagen University Hospital





Introduction

- Les données sensibles sont partout
- Ces données intéressent la recherche
- Protégées par des législations diverses
- Sécurité : stockage, transferts, et pendant l'utilisation ?
- Cloud => Machines partagées => risques de fuites
- Accès par les opérateurs de l'infrastructure
- Cloud Confidentiel => les données restent cryptées en mémoire
- Système d'enclaves sécurisées inaccessibles aux tiers
- Technologies jeunes => matériel récent => logiciel récent



Législations & réglementations

- Globales (EU GDPR)
- Locales (par pays, par détenteur de jeux de données)
- Différences
- Peu permissives (interdictions)
- Bureaucratie

SIESTA : Centralisation, simplification

- Tiers de confiance reconnu et éprouvé
- Signataire interposé
- Procédures allégées

Objectif données sensibles

- 1) Fournir des environnements cloud de confiance
- 2) Étudier la faisabilité des principes FAIR
- 3) Fournir des outils d'anonymisation
- 4) Accompagner les utilisateurs pour appliquer les principes FAIR
- 5) Intégrer la plateforme à « EOSC EU node »

Cas d'usage

- Épidémiologie (population, déplacements)
- Imagerie médical
- Énergie (population, consommation, habitat)
- Anonymisation de données textuelles (documents d'investigation criminelle, type CERT)
- Démographie (population, habitat, données financières)

```
011011101101000011010010 01100
0110010100100000001100010111010
00100000011001101110011110011
00101110011 01101110101100100
01101110111010101110 000101110
01101110111000010100101110100
01100101001011 11001101110100
01110010001010000100010110001
01101110 00100011 1101101101
0110011001010110000101110110
0110010001101001011011100110100
0010100000110000001011000 00000
00110001001010010010100100101001
```

La SIEST'Tech

- AAI : Authentification et Autorisation Infrastructure



- Intégration EOSC (Keycloak)

- Traitement, pipelines de calcul



- VMs (OpenStack)
- Conteneurs (Kubernetes)

- Stockage, transferts



- Frontend : NextCloud, iRods, ...
- Backend : Volumes + cryptage **logiciel** (dans l'enclave sécurisée)
(OpenStack cinder + LUKS)

- Sécurité logicielle : provenance, signatures, attestation, SBOM (Harbor, Trivy)

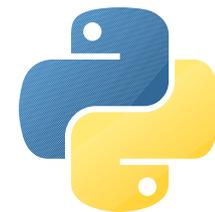


- Développement et suivi : IaC, tickets (Gitlab, ansible, kubespray, confluence)

```
011011101101000011010010 01100
01100101001000000011000100111010
001000000110011011100101110011
0010111001 0110111010101100100
01101110111010101110 000101110
01101110110000100101110100
01100101001010 11001101110100
0111001000101000100001100001
01101110 00100011 1101101101
01 110011100100110000101101110
0110010001101001011011100110100
0010100000110000001011000 00000
001100010010100100101001001001
```

La SIEST'Tech - suite

- (pseudo-)anonymisation (ANJANA, pyCANON, BIDScramble)
- Sécurité et observation réseau (Cilium)
- Monitoring et audit, journaux inaltérables (Wazuh, Trilian)
- Gestion & distribution de secrets (OpenStack Barbican)
- Expérience & interfaces utilisateur
 - Diversité : API REST, CLI, portail web, interactive (ThinLinc)
 - non-experts (compétences techniques requises => délégation)



3 Clouds :

- IFCA – CSIC – Espagne
 - IISAS – Slovaquie
 - IPHC – France
-
- Problèmes rencontrés
 - Pile logicielle très récente requise (Noyau Linux, QEmu, OpenStack, K8s)
 - Difficile à mettre en place sur nos infrastructures cloud de production => PoCs séparés
 - Manque de compétences techniques => besoin de simplicité :
 - CLI (quasi) impossible
 - Compromis : délégation de responsabilité

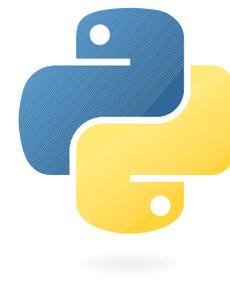
Note : le projet n'est qu'à mi-parcours

```
011011101101000011010010 01100
0110010100100000001100010111010
001000000110011011100101110011
00101110011 010111010101100100
01101110111010101110 000101110
0110111011100100100101110100
01100101001011 11001101110100
011100100010100100001100001
01101110 00100011 1101101101
00 11001100100110000101101110
011001000110100101101100110100
001010000011000000111000 00000
00110001001010010010100101001
```

Réalisations - suite

Développements logiciels :

- pyCANON : outils python d'analyse d'anonymat de jeux de données tabulaires
 - <https://github.com/IFCA-Advanced-Computing/pycanon>
- anjana : outils d'anonymisation/pseudonymisation
 - <https://github.com/IFCA-Advanced-Computing/anjana>
- BidScramble : outils d'anonymisation de données en neuro-imagerie au format BIDS
 - <https://github.com/Donders-Institute/bidschramble>
- 100 % Python
- FOSS (Apache 2 & GPL3)



```
011011101101000011010010 01100
0110010100100000001100010111010
00100000011001101110011110011
00101110011 01101110101100100
011011101110101110 000101110
0110111011100010100101110100
01100101001011 11001101110100
011100100010100100001100001
01101110 00100011 1101101101
00 1100110010011000101101110
011001000110100101101110110100
0010100000110000001011000 00000
00110001001010010010100100101001
```

Comment faire le FAIR ?

- FAIR n'est pas incompatible avec données sensibles
- Les métadonnées ouvertes permettent :
 - **F**indable
 - Catalogue des jeux de (méta-)données
 - Moteur de recherche
 - **A**ccessible
 - Ne veut pas dire « ouvert à tout public »
 - Les règles et procédures doivent être documentées, accessibles
 - **I**nteroperable
 - Formats ouverts
 - Standards
 - Taxonomies
 - **R**eusable
 - durée de vie gérée, connue
 - Stockage pérenne

```
011011101101000011010010 01100
01100101001000000011000100111010
001000000110011011100101110011
0010111001 01101110101100100
011011101110101110 000101110
01101110111000100100101110100
01100101001010 11001101110100
0111001000101000100001100001
01101110 00100011 1101101101
00 1100110010011000101101110
011001000110100101101110110100
0010100000110000001011000 00000
00110001001010010010100101001
```

Ouverture



European Network of Trusted Research Environments

EGI / EOSC : d'autres projets

- EOSC ENTRUST & TITAN: des projets concurrents
- EUCAIM : EU Cancer Image (thématique)



- Et dans le privé ?

Tous (quasi) les fournisseurs majeurs de ressources cloud ont une offre CC, mais on en connaît le(s) problème(s) : Coût, souveraineté, etc.



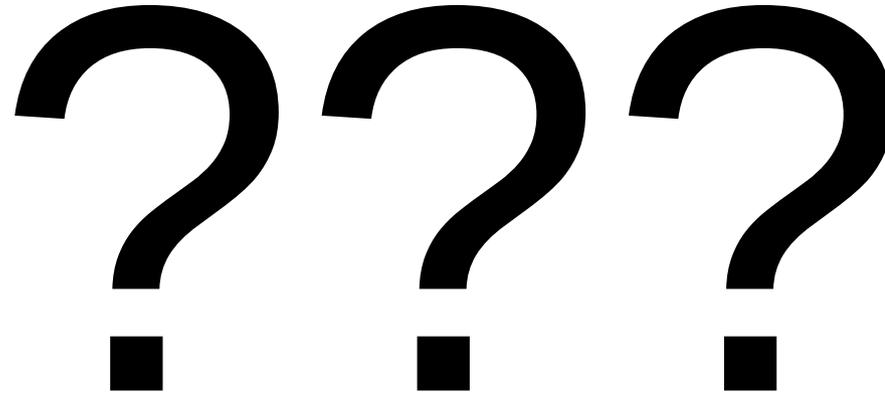
```
011011101101000011010010 01100
01100101001000000011000100111010
001000000110011011100101110011
00101110011 0101110101100100
0110111011100101110 000101110
01101110111000100100101110100
01100101001011 11001101110100
0111001000100100100001100001
01101110 00100011 1101101101
00 11001100100110000101101110
0110010001101001011011100110100
0010100000110000001011000 00000
00110001001010010010100100101001
```

Conclusions

- Le besoin est important
- Les principes FAIR ne sont pas un obstacle
- Encore du travail à fournir
- Simplicité d'utilisation : un enjeu majeur

0111011101101000011010010 01100
0110010100100000001100010111010
00100000011001101110011110011
00101110011 011011101011100100
01101111110101110 000101110
0111011101100010100101110100
01100101001011 11001101110100
0111001000101001000101100001
01101110 00100011 1101101101
00 11001100100110000101101110
011001000110100101101100110100
0010100000110000001011000 00000
00110001001010010010100100101001

Questions



P.S. : L'équipe SCIGNE est à votre disposition jusqu'à mercredi...

011011101101000011010010
0110010100100000001100010111010
00100000011001101110011110011
0010111001110111010101100100
0110111011101010111000101110
01101110111000100100101110100
011001010010111001101110100
011100100010100100010110001
0110111000100011110110101
001100110010011000101101110
01100100011010010110110110100
0010100000110000001011000000
00110001001010010010100101001

Voilà, c'est fini...

Il ne reste plus qu'une
chose à **FAIR** :

une petite **SIESTA** !