La certification des entrepôts de données

Françoise Genova, Aude Chambodut, Olivier Rouchon, Gilles Ohanessian

La certification des entrepôts de données

Françoise Genova, CDS/Observatoire Astronomique de Strasbourg, RDA France, GT Certification

Aude Chambodut, EOST, CNRS INSU, Board CTS

Olivier Rouchon, CNRS, FAIR-IMPACT, Board CTS

Gilles Ohanessian, GT Certification

La certification des entrepôts de données

- Pourquoi?
- Les cadres de certification ‘de base’
- Exemple d’auto-évaluation
- Les critères du CoreTrustSeal et leur évolution
- Conclusions

RDA FRANCE

La certification, pourquoi?

Confiance (Trustworthiness)

- La confiance est au cœur de la Science Ouverte
- Les entrepôts sont une source majeure de données
- Il leur faut avoir la confiance
  - de leurs utilisateurs
    - Les personnes qui produisent et déposent les données
    - Les utilisateurs des données
  - de leurs autorités et de leurs financeurs

Qu'est-ce qu'un entrepôt de confiance?

- Mission de fournir un accès fiable, long-terme à des ressources numériques contrôlées pour sa communauté cible, maintenant et dans le futur
- Supervision, planification et maintenance constantes
- Compréhension des menaces et risques dans les sytèmes
- **Cycle d'audit et/ou de certification régulier**

Credits: Ingrid Dillo & Hervé L'Hours

Qu'est-ce qu'un entrepôt de confiance?

- Mission de fournir un accès fiable, long-terme à des ressources numériques contrôlées pour sa communauté cible, maintenant et dans le futur
- Supervision, planification et maintenance constantes
- Compréhension des menaces et risques dans les sytèmes
- **Cycle d'audit et/ou de certification régulier** ?

Credits: Ingrid Dillo & Hervé L'Hours

Pourquoi une certification formelle?

- Assurer que le centre est « de confiance »
- Mais… il a peut-être déjà la confiance de ses utilisateurs…
- L'exemple du CDS
  - Crée en 1972
  - Centre de données de référence pour la communauté astronomique internationale
  - Infrastructure de Recherche sur la Feuille de Route nationale
  - 2 000 000+ requêtes/jour sur les services

Pourquoi une certification formelle?

- Critères établis par des personnes compétentes et applicables quel que soit le cadre disciplinaire
- Au préalable, auto-évaluation selon les critères, qui permet de vérifier l'organisation et les process et d'identifier des améliorations possibles
- Evaluation externe par des personnes compétentes
- Le dépôt dans un centre de données certifié est un point important dans les Plans de Gestion des Données (PGD)

La stratégie Nationale

Plan National pour la Science Ouverte

2018

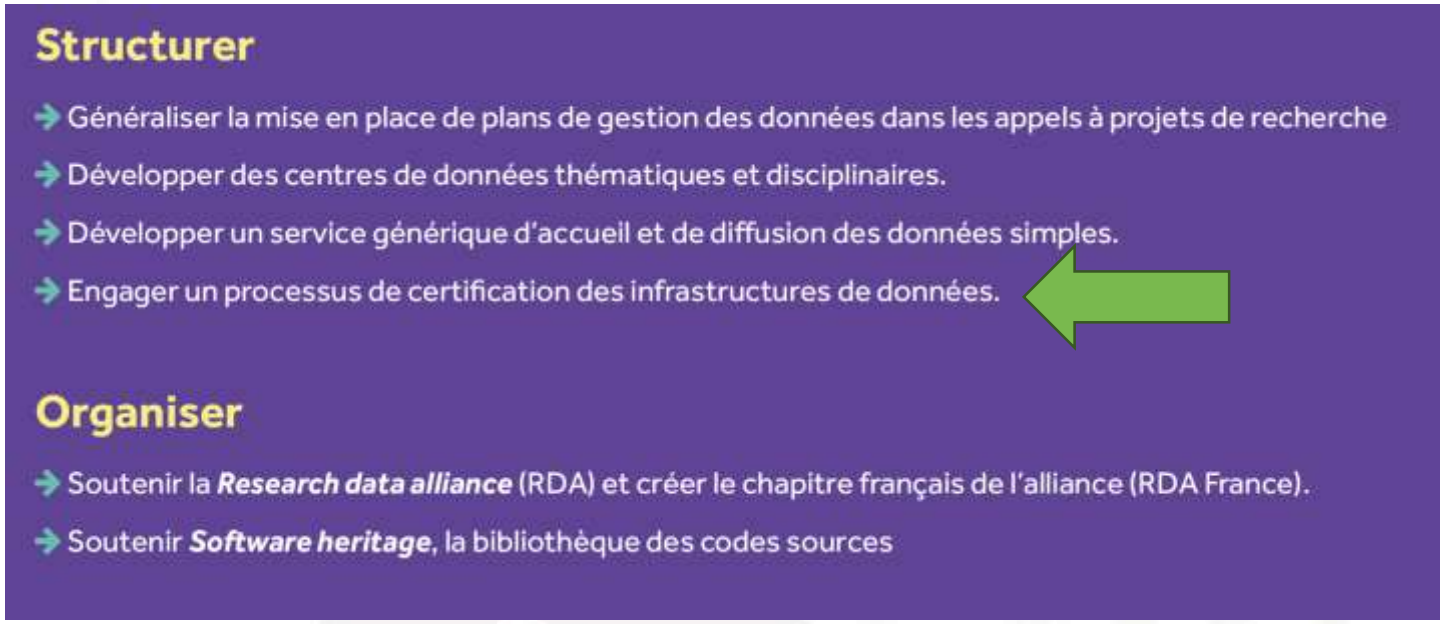

2021

→ Poursuivre le processus de **certification** (*Core trust seal*) des entrepôts de données français.

La stratégie au CNRS

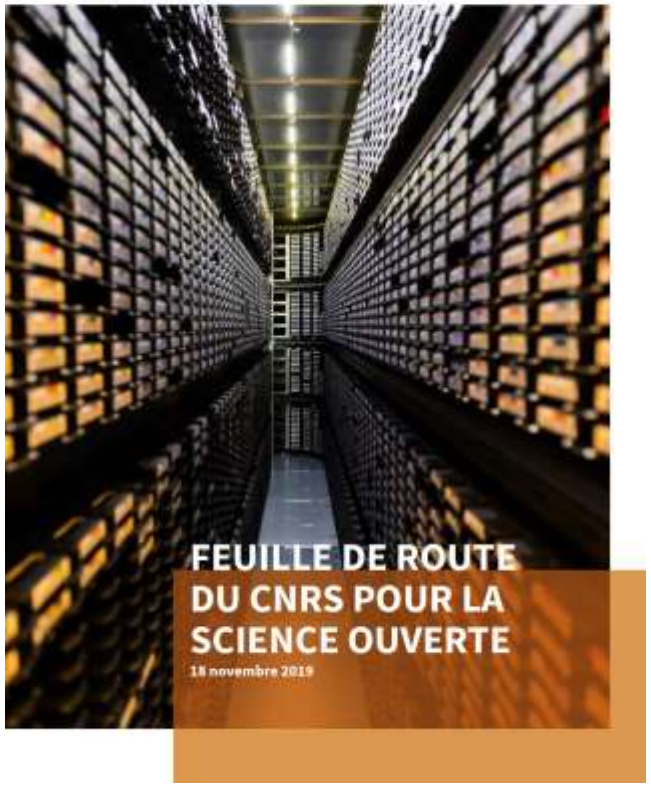

Action 3 : soutenir et accompagner les infrastructures de recherche, productrices de données, dans la définition et la mise en œuvre de politiques de données.

Le CNRS est largement engagé avec ses partenaires dans les Infrastructures de Recherche (IR) nationales et internationales, qui représentent les lieux où se créent et s'analysent les données de la recherche: instruments analytiques, infrastructures de calcul, infrastructures de données, observatoires, etc. Pour généraliser l'application des principes FAIR à toutes les disciplines, le CNRS publiera une charte des infrastructures, engageant celles-ci à respecter les pratiques FAIR et des standards de qualité, en affichant des politiques de données concertées avec les communautés scientifiques utilisatrices des infrastructures concernées. Certaines infrastructures (telles que Progedo et Humanum à l'Institut des SHS (INSHS)) sont déjà bien engagées dans ce processus, d'autres sont en cours d'accompagnement telles que les IR de Chimie. Le synchrotron SOLEIL a également mis en route une politique de gestion des données. Les exemples sont multiples et devraient tendre à être généraliser. Ces développements doivent être corrélés avec les certifications (de type CoreTrustSeal) dans le cas où les infrastructures prennent elles-mêmes en charge la distribution de leurs données.

Action 4 : soutenir et accompagner des Infrastructures de données - Mettre en œuvre un service coordonné avec les instituts pour favoriser le dépôt des données pour tous les personnels des unités du CNRS

Les infrastructures de données thématiques jouent un rôle national ou international. Certaines sont inscrites sur la feuille de route nationale des infrastructures de recherche. Cela s'inscrit dans la mesure de structuration du Plan national pour la Science ouverte qui préconise de « développer des centres de données thématiques et disciplinaires ». Le CNRS continuera à soutenir ces infrastructures, et soutiendra le développement de nouveaux réservoirs et services de données thématiques. Ce soutien sera conditionné à une évaluation de leur impact, de leur adéquation aux besoins scientifiques, et de la qualité de leur gestion. Une certification CoreTrustSeal sera recherchée.

La stratégie au CNRS

p.8

- Le CNRS constituera à l'intention des chercheurs et des chercheuses un annuaire des entrepôts et des services de données existants, avec en particulier l'objectif d'aller vers la certification des entrepôts et services de données.

  Un entrepôt doit avoir un rôle de curation et de préservation des données, et les principes FAIR sont un objectif dans le contexte Science Ouverte. La certification de base *CoreTrustSeal* explicite les critères pour un entrepôt « de confiance », ce qui permet de travailler à améliorer les pratiques en se basant sur les critères, sans nécessairement aller jusqu'à soumettre un dossier de certification.

p. 11

Certification des dispositifs de prise en charge des données de la recherche (notamment le *CoreTrustSeal*[5]). La certification des entrepôts et services de données, citée comme un objectif dans le Plan National pour la Science Ouverte, permet d'assurer qu'un centre de données est « de confiance », en examinant la manière dont il met en œuvre l'ensemble de la chaîne liée aux données, de leur ingestion à leur dissémination et à leur préservation. Elle peut aussi s'entendre dans le cadre de réseaux de centres de données, par exemple ceux des Pôles de données thématiques de l'IR Data Terra[6], ou ceux de l'infrastructure européenne CLARIN[7]. Le CNRS pourra s'appuyer sur les activités de soutien à la certification mises en place par le Nœud National RDA France[8].

Entrepôts français actuellement certifiés CTS

- IDOC/IDOC-DATA, Orsay
- IFREMER SISMER, Plouzané
- ORTOLANG, Nancy
- ESRF, Grenoble
- CDSP, Paris
- IPSL, Paris
- CDS, Strasbourg

RDA FRANCE

Les cadres de certification ‘de base’

Un peu d’histoire…

Le paysage de la certification en 2015

- 4 certifications standards disponibles

DIN 31644

ISO 16363

Le World Data System (WDS)

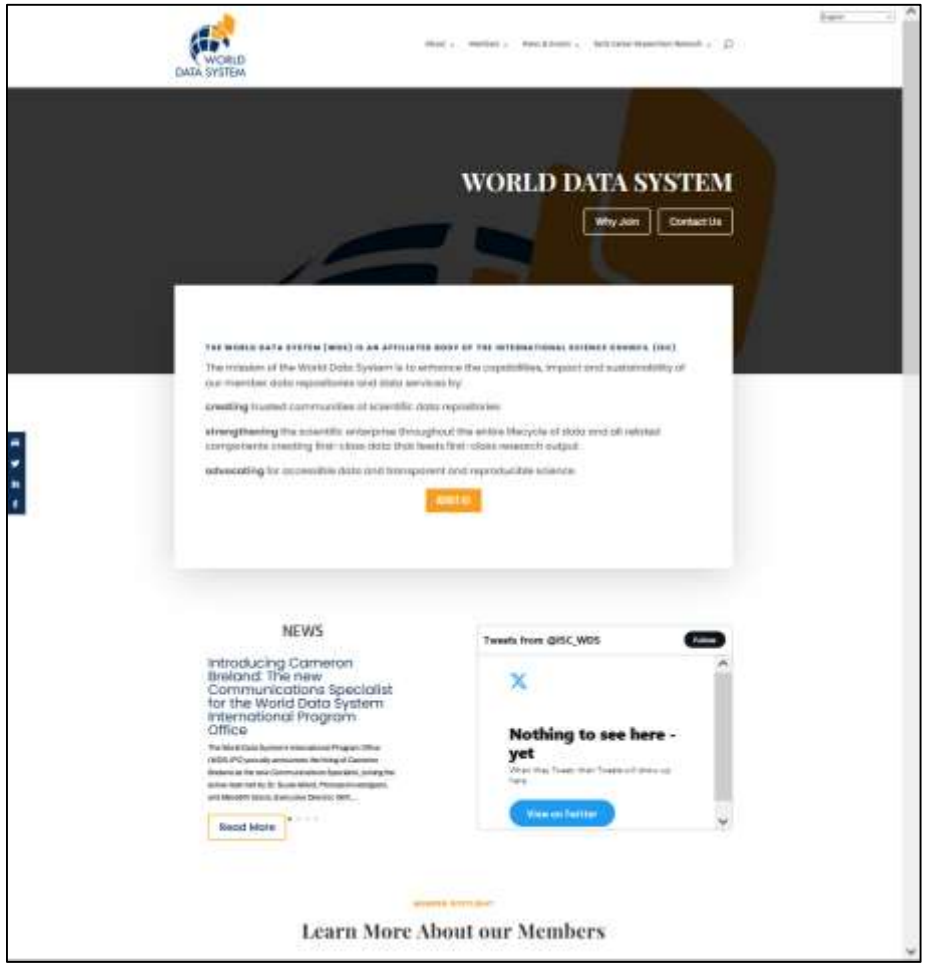

- Créé en 2008 par l'ICSU (=ISC)
- Essentiellement au départ données sur la planète (et astronomie) mais ouvert à tous
- *Promoting universal and equitable access to, and long-term stewardship of, quality-assured scientific data and data services, products, and information covering a broad range of disciplines from the natural and social sciences, and humanities.*
- *Cooordinates trusted scientific data services for the provision, use, and preservation of relevant datasets*
- CDS membre du WDS depuis 2012

Le Data Seal of Approval (DSA)

- Plutôt Humanités
- Plus dépôts de données que services
- Le CINES a été le premier centre français certifié DSA, le CDS a été le second en France et le premier centre certifié du domaine des sciences physiques (en 2014)

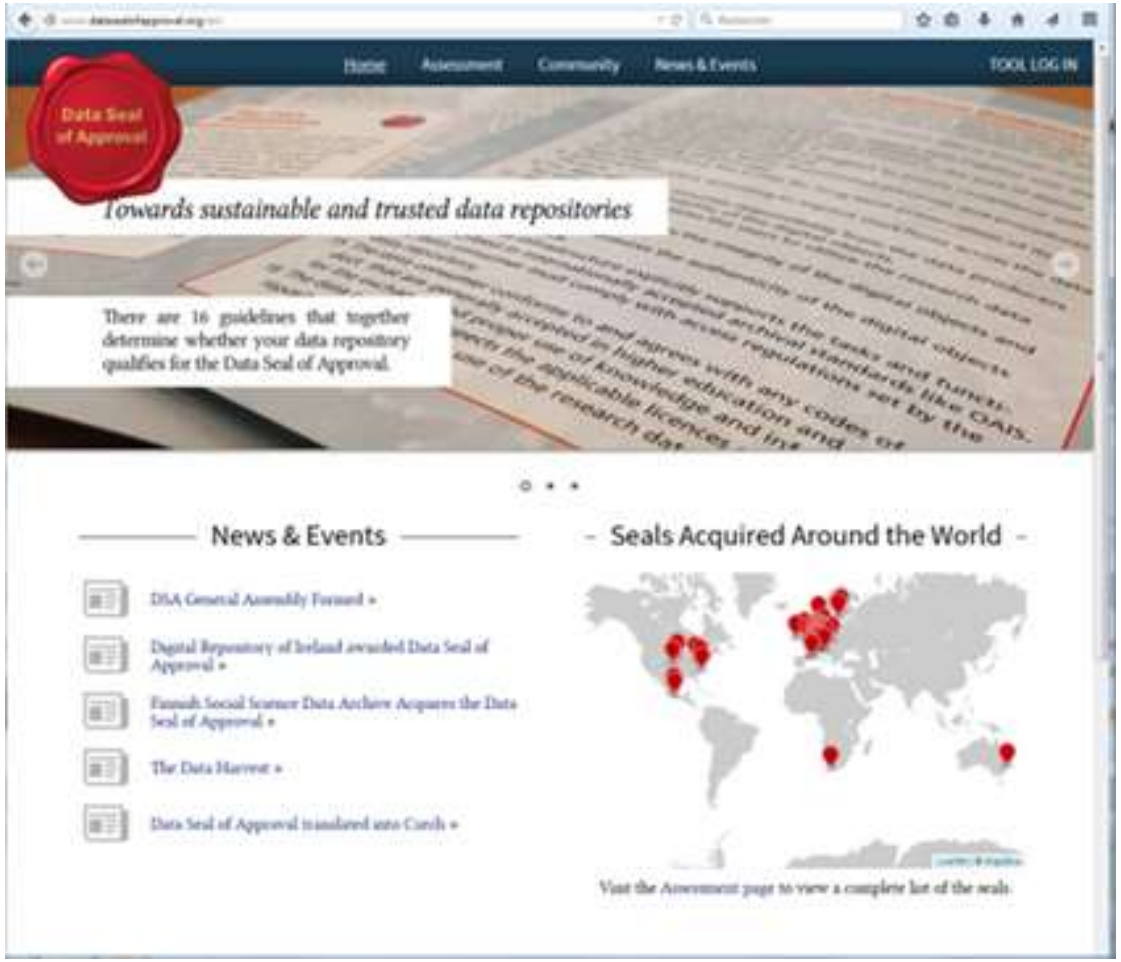

Dans la RDA, dès 2013

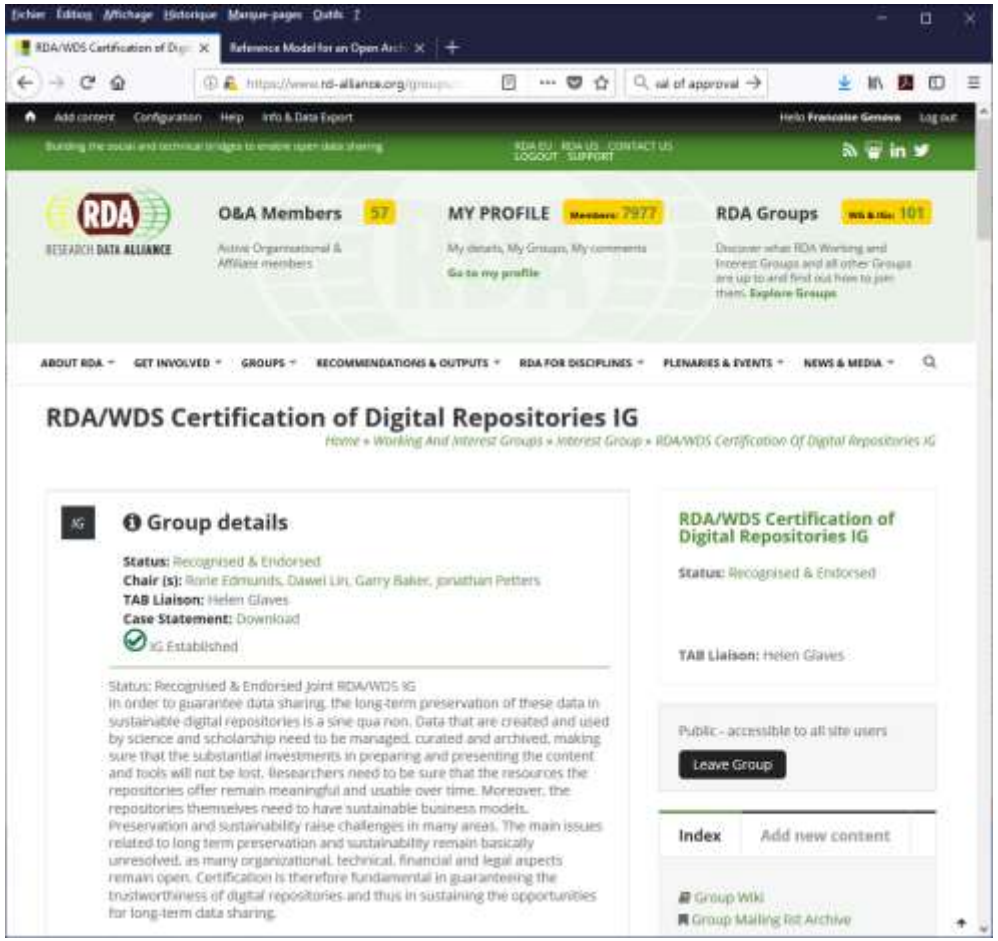

RDA: DSA + WDS (2016)

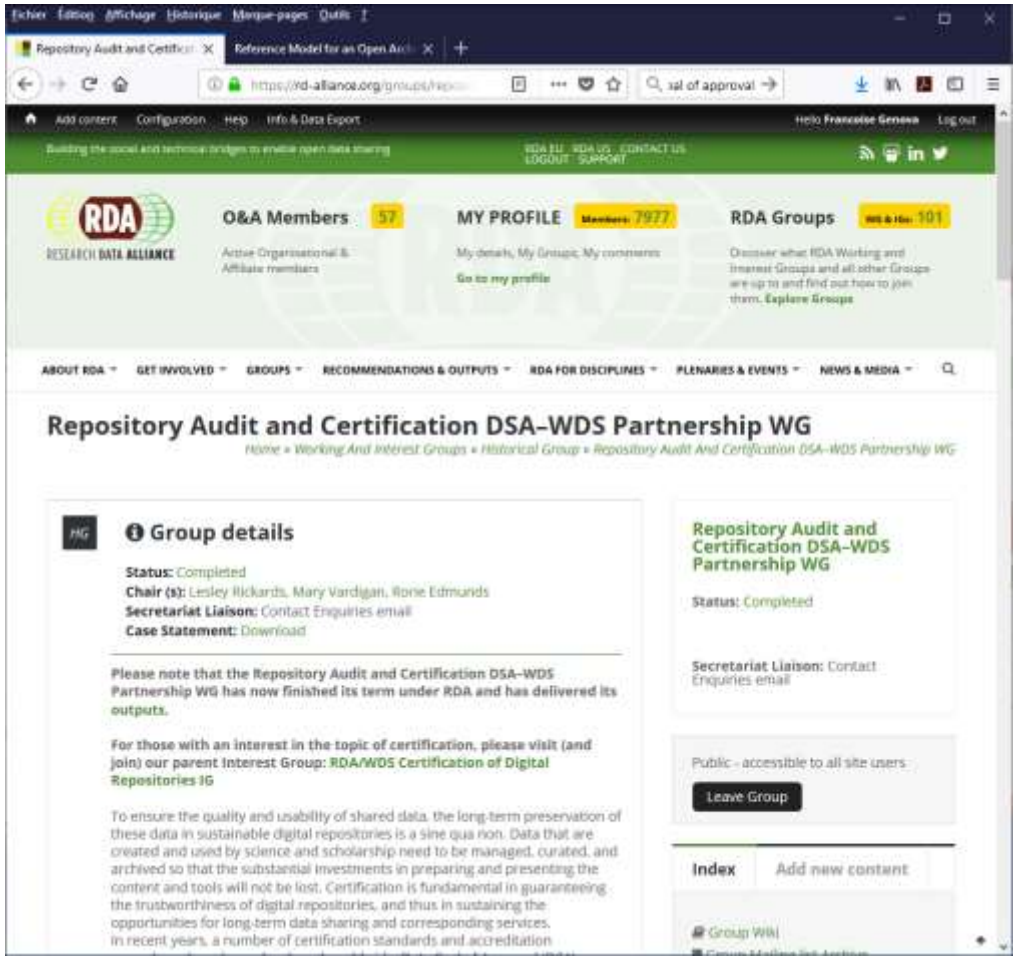

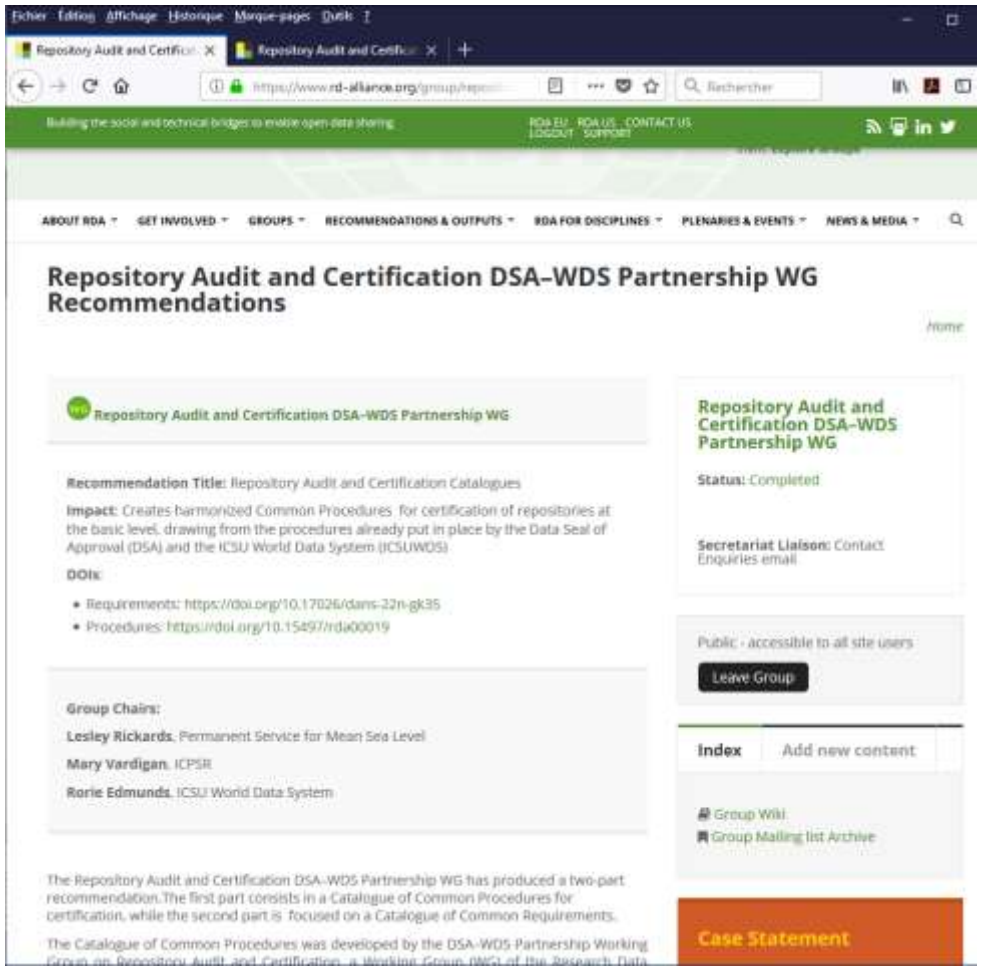

DSA + WDS = CoreTrustSeal (CTS), 2017

RDA FRANCE

Certification formelle ISO 16363:2012
(2 Centres ont été certifiés, 100+ critères)
https://www.iso.org/standard/56510.html/

Certification étendue DIN 31644
(5 Centres certifiés, 34 critères)
www.langzeitarchivierung.de

Certification CoreTrustSeal
(160+ centres, 16 critères)
www.CoreTrustSeal.org

Centres de données de confiance - Trustworthy Data Repositories

Credits: Mustapha Mokrane

RDA FRANCE

Exemple d'auto-évaluation

Le Centre de Données astronomiques de Strasbourg (CDS)

L'auto-évaluation

- Questionnaire à remplir
- Il faut les compétences
  - De la direction (mission, organisation, …)
  - Des personnes en charge du contenu
  - Des personnes en charge de l'informatique
- Pour le CDS: un travail d'équipe qui a impliqué la direction, les documentalistes, l'informaticien en charge du service et l'ingénieur système

Les conséquences pour le CDS

- Description de bout en bout des process et des rôles
- Pas de modification majeure
- Des améliorations suite aux auto-évaluations pour DSA en 2014
  - Clarification des licences
  - Checksums des fichiers
- Le document soumis à CTS en 2018 a été accepté sans modification majeure
- Soumis en 2022 pour renouvellement en ajoutant l'entrepôt d'un second service
- Réaction très positive de nos autorités

Description des process du CDS

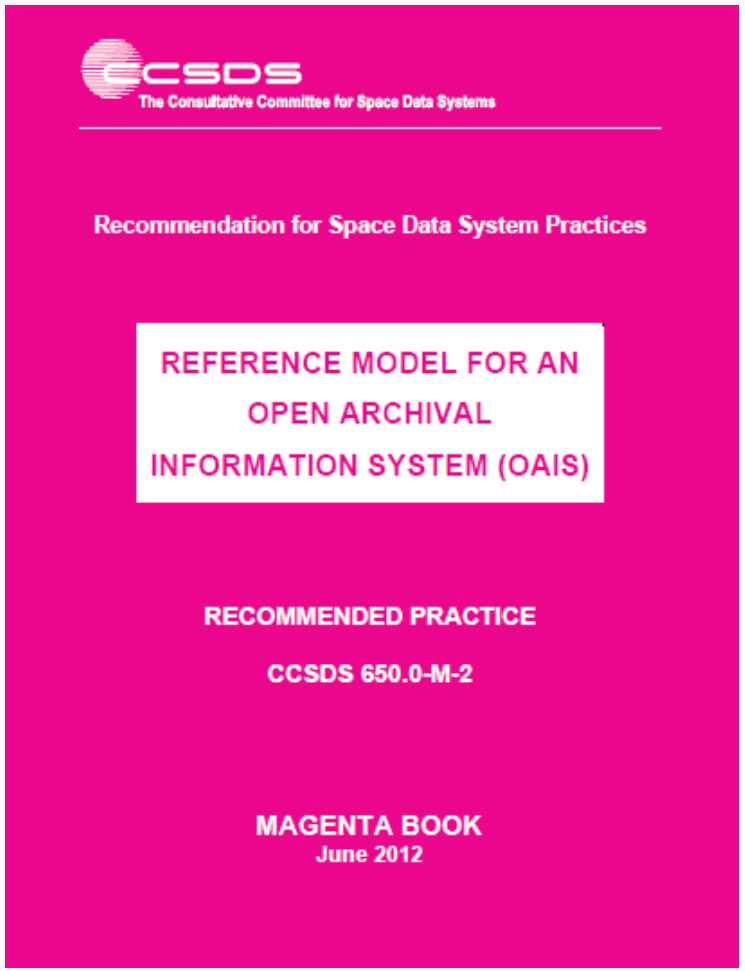

- Basé sur le modèle OAIS – Open Archive Information System

https://public.ccsds.org/Pubs/650x0m2.pdf (Version 2, 2012)

Draft Octobre 2020

- Site en français

https://www.cines.fr/archivage/un-concept-des-problematiques/le-modele-de-reference-loais/

L'environnement d'une archive OAIS

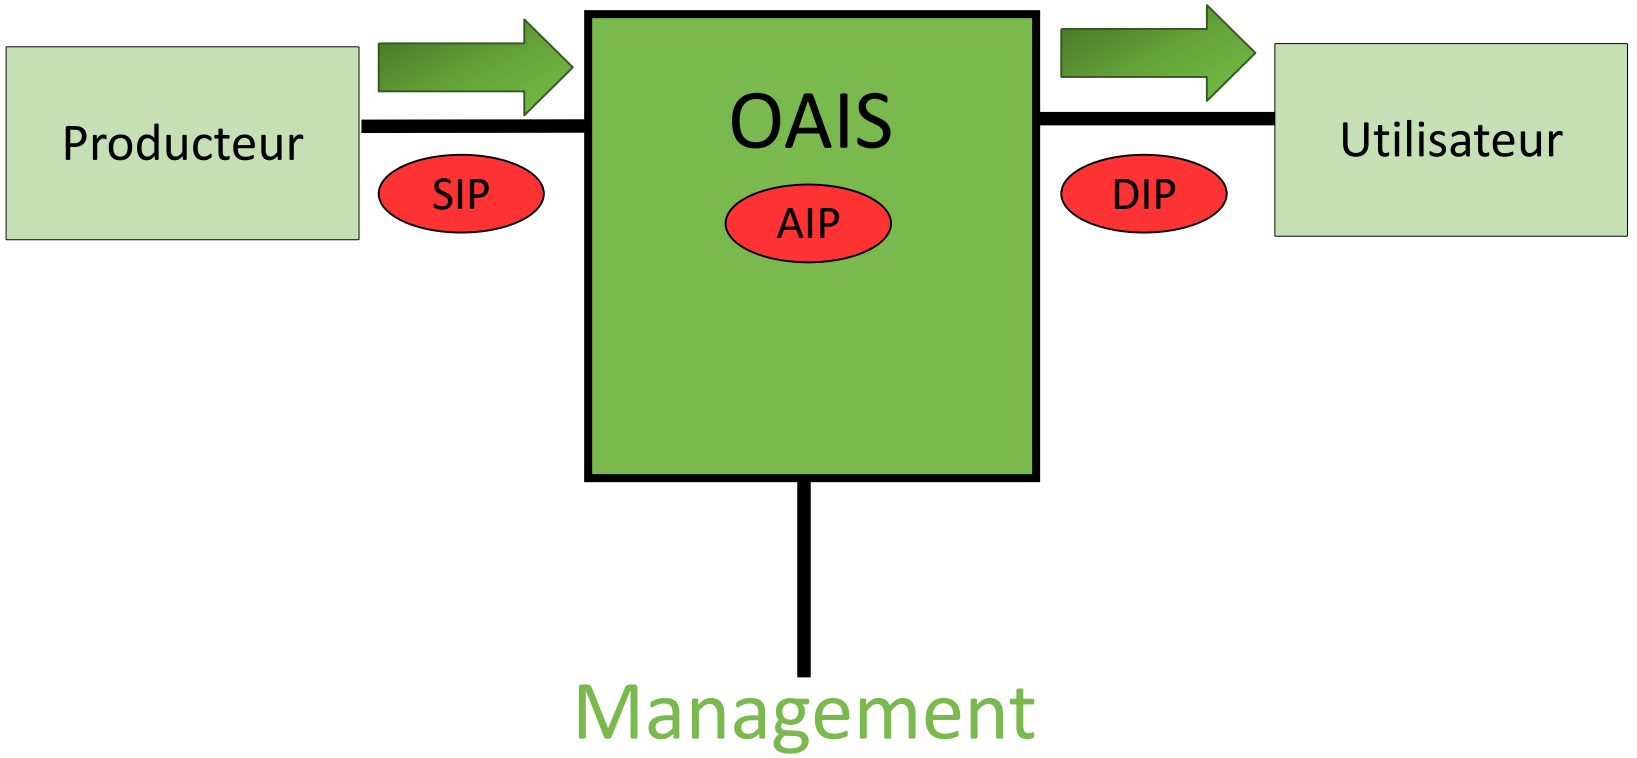

Les entités fonctionnelles de l'OAIS

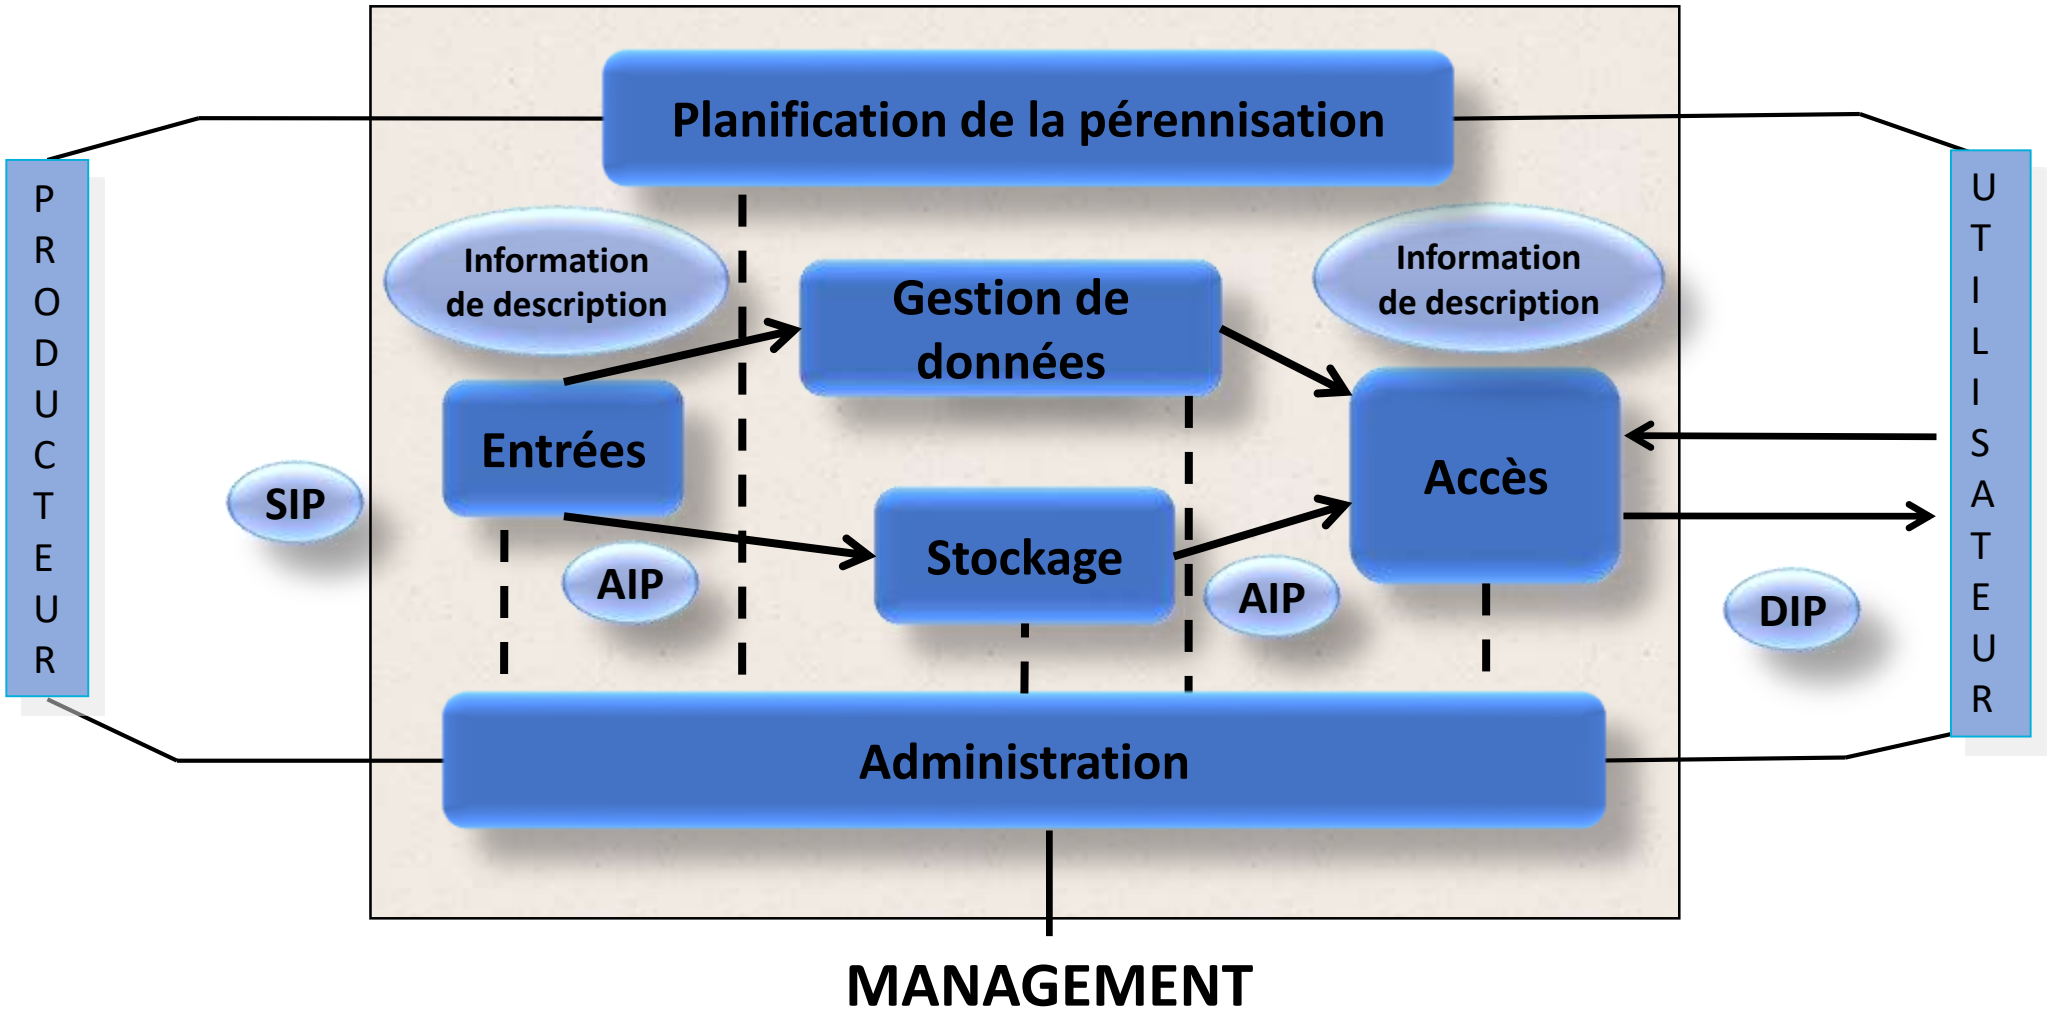

Le pipeline de données pour Aladin/CDS

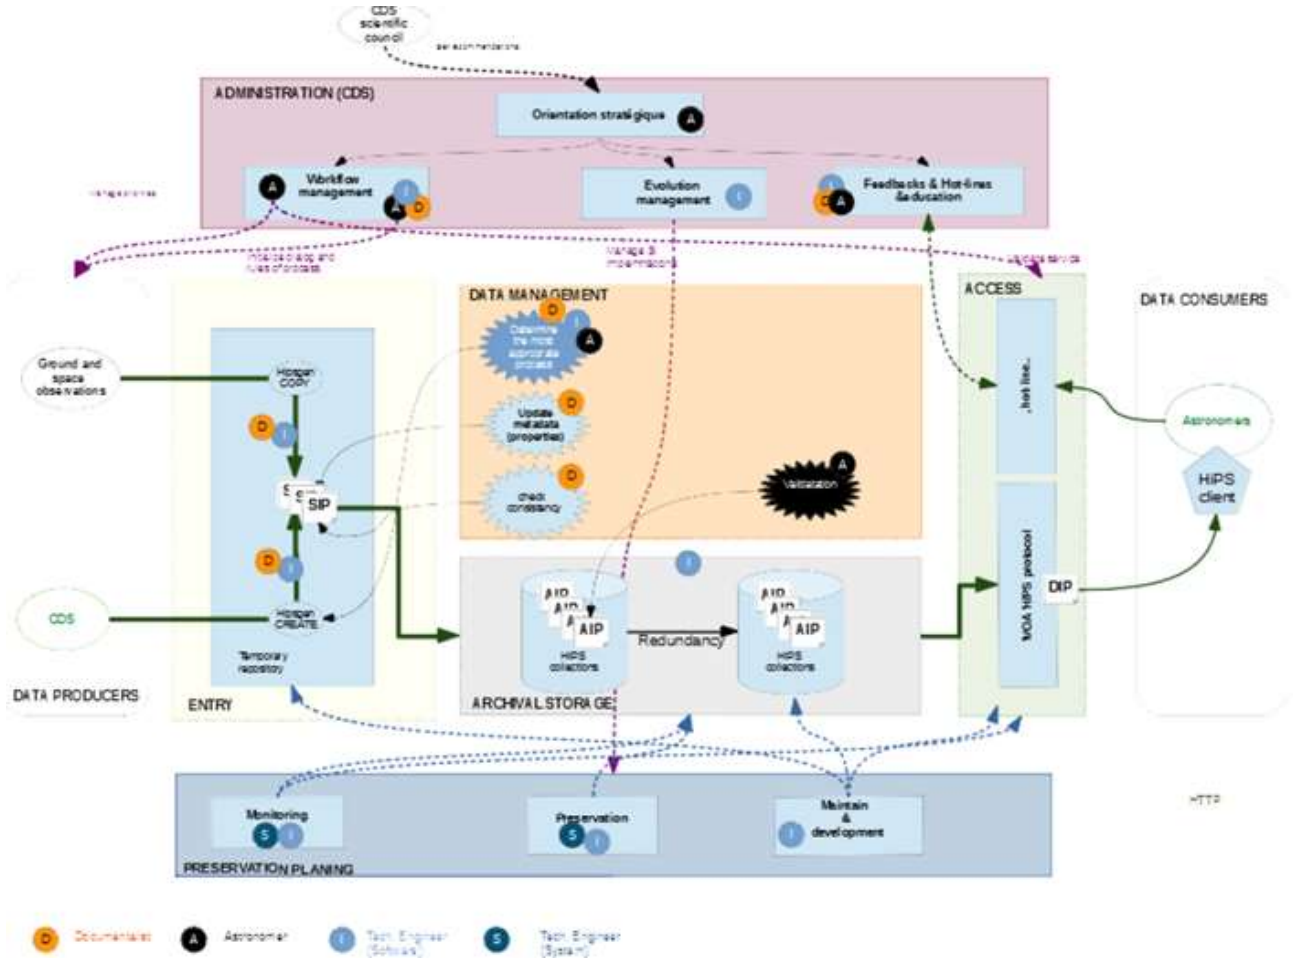

Le pipeline de données pour VizieR/CDS

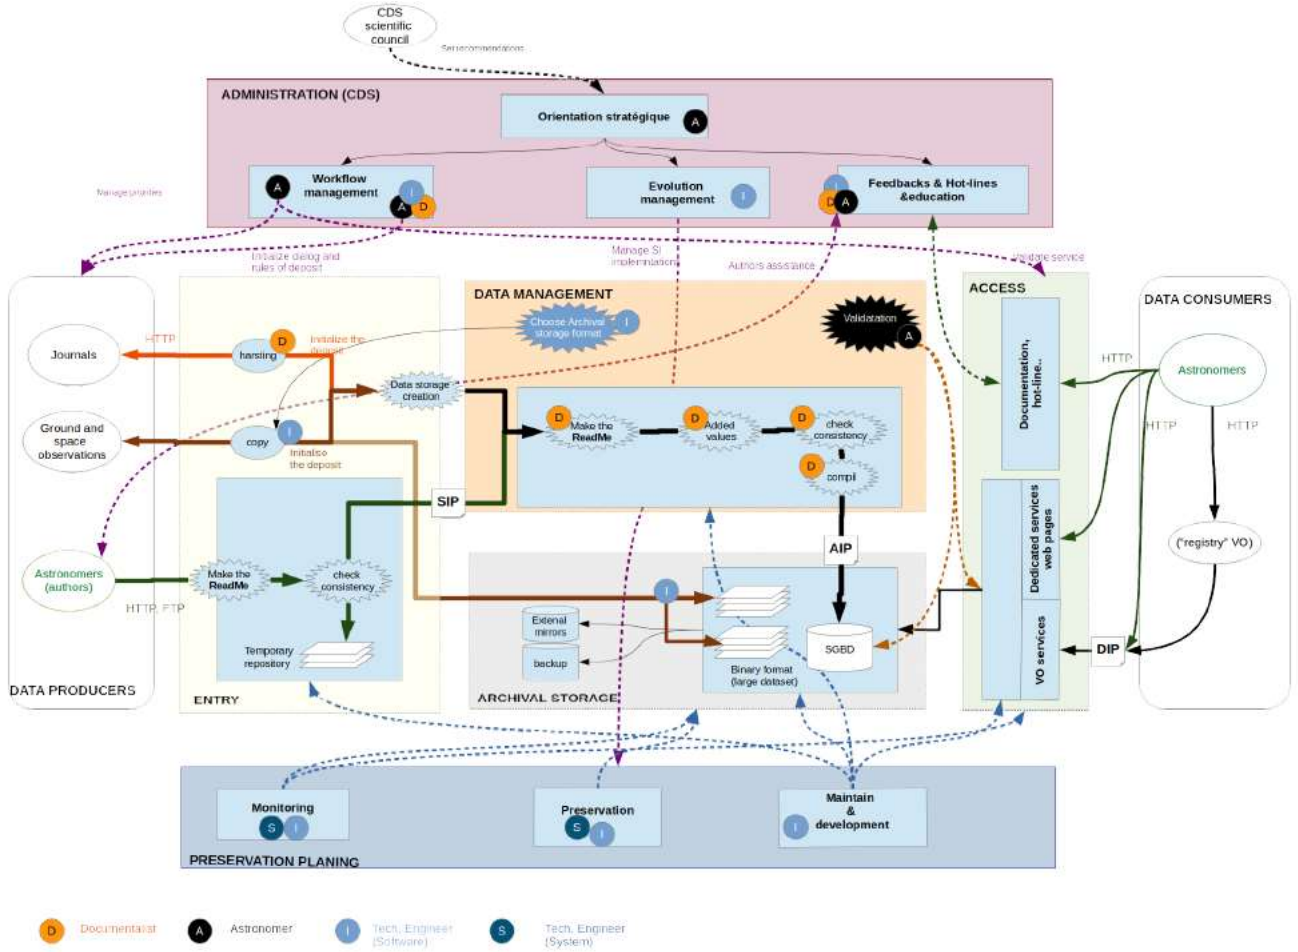

RDA FRANCE

La procédure de certification

La procédure d'évaluation (1)

- Soumission d'un formulaire en ligne
- Examen par deux évaluateurs
- Examen des évaluations par le Board
  - Renvoi des évaluations des évaluateurs et des commentaires du Board aux candidats
  - Acceptation du dossier

La procédure d'évaluation (2)

- Les éléments du dossiers sont publics (sauf exception légitime)
- Les évaluateurs sont membres de la communauté CoreTrustSeal « Assemblée des évaluateurs »

- Pour devenir membre du WDS
  - Il faut obtenir la certification CTS…
  - et remplir quelques conditions supplémentaires
- Renouvellement de la certification tous les 3 ans

RDA FRANCE

Les critères du CoreTrustSeal

La certification CTS

- Toute l'information est sur le site de CoreTrustSeal
  - https://www.coretrustseal.org/
- Contexte + 16 critères
  - https://www.coretrustseal.org/why-certification/requirements/
- Document pour guider les évaluateurs et les candidats
  - Extended Guidance 2020-2022 > 2023-2025
    https://doi.org/10.5281/zenodo.7051096
  - Glossaire
    https://doi.org/10.5281/zenodo.7051125
  - Changements V2.0 > V3.0
    https://doi.org/10.5281/zenodo.7051237
- Les entrepôts qui ont soumis un dossier selon les anciens critères restent dans ce cadre
- « Administrative fee » 3000€

Les critères sur le site CTS

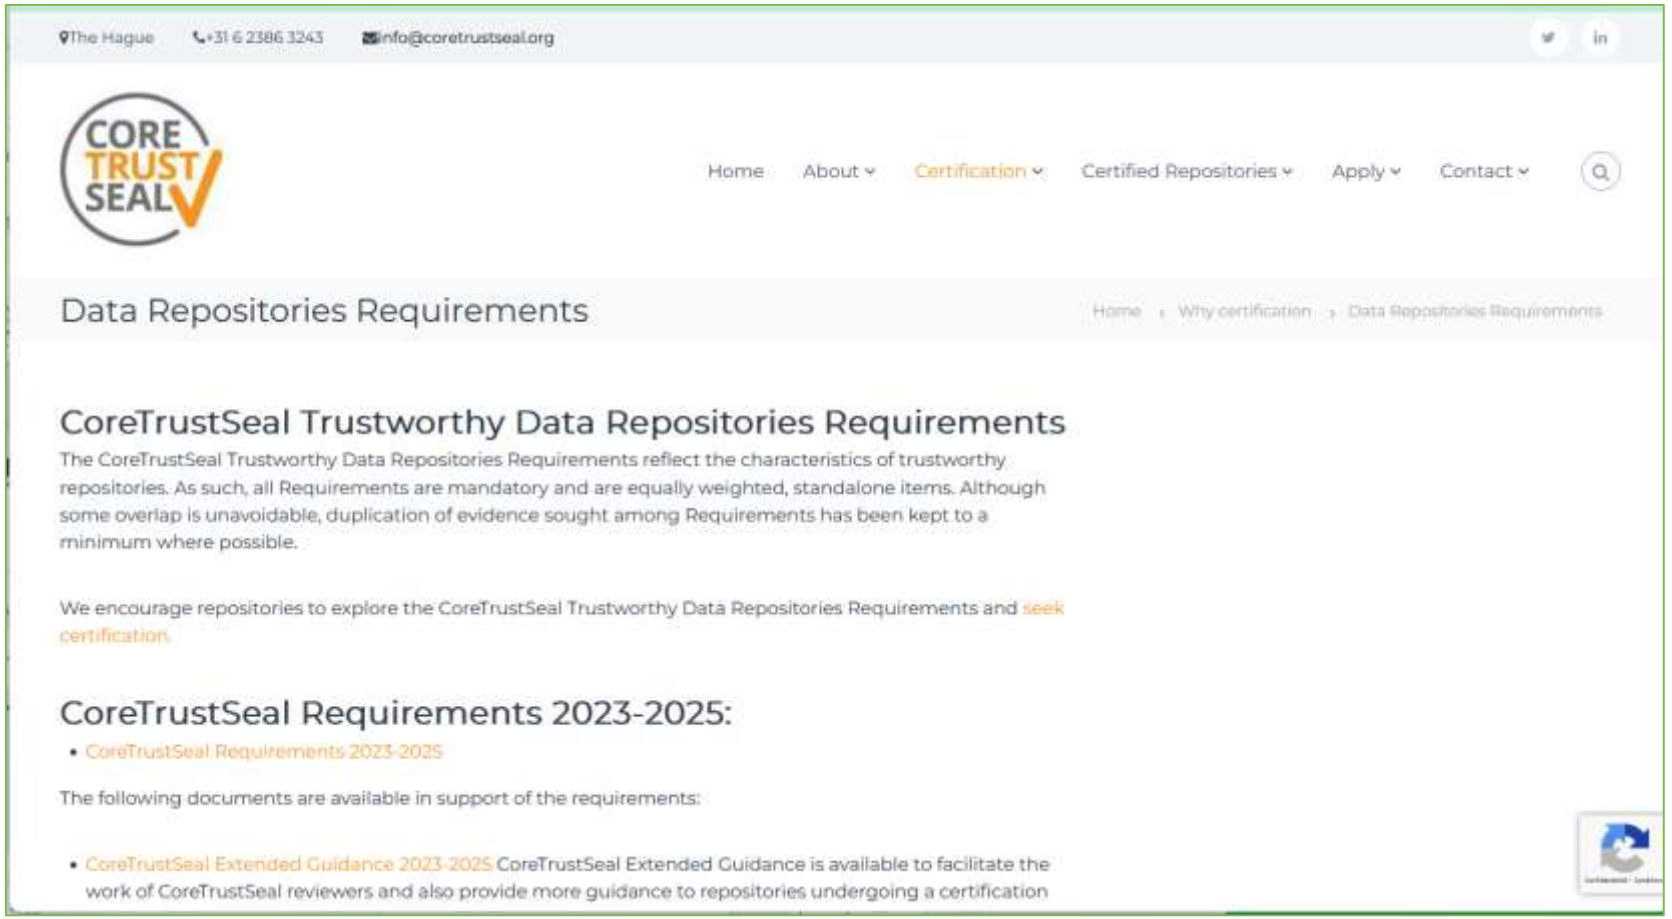

Les critères de certification CTS

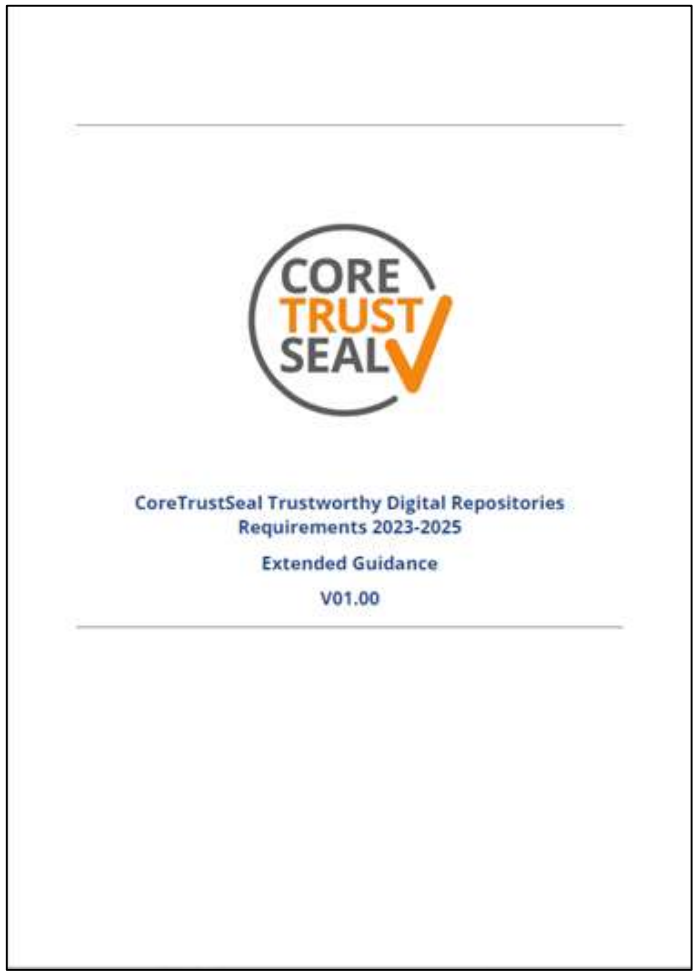

- R0 - Le contexte
- 16 critères, 3 thèmes:
  - Infrastructure organisationnelle
  - Gestion des objets numériques (données et métadonnées)
  - Technologie de l'information et sécurité

Le contexte

- Identifiant Re3data
- Type d'entrepôt
- Brève description de l'entrepôt
- Brève description de la communauté concernée
- Niveau de curation
  - Contenu en accès tel que déposé
  - Curation de base (p. ex. vérification rapide, ajout de métadonnées de base ou de documentation)
  - Curation avancée (p. ex. conversion vers de nouveaux formats, amélioration de la qualité de la documentation)
  - Curation au niveau des données
- Partenaires
- *Résumé des modifications depuis la candidature précédente (s'il y a lieu)*
- Autres informations pertinentes

Infrastructure organisationnelle

- R1 – Mission/périmètre
- R2 – Gestion des droits
- R3 – Continuité de service
- R4 – Légalité/éthique
- R5 – Gouvernance et ressources
- R6 – Conseils d’experts

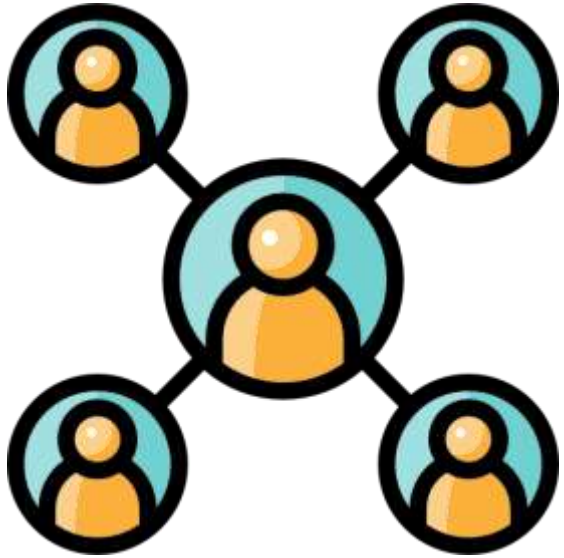

Gestion des objets numériques

- R7 – Provenance et authenticité des données
- R8 – Appréciation et sélection des données
- R9 – Assurance qualité
- R10 – Plan de préservation
- R11 – Processus de traitement (Workflows)
- R12 – Découverte et identification des données
- R13 – Réutilisation des données

Technologie

- R14 – Stockage et intégrité
- R15 – Infrastructure technique
- R16 – Sécurité

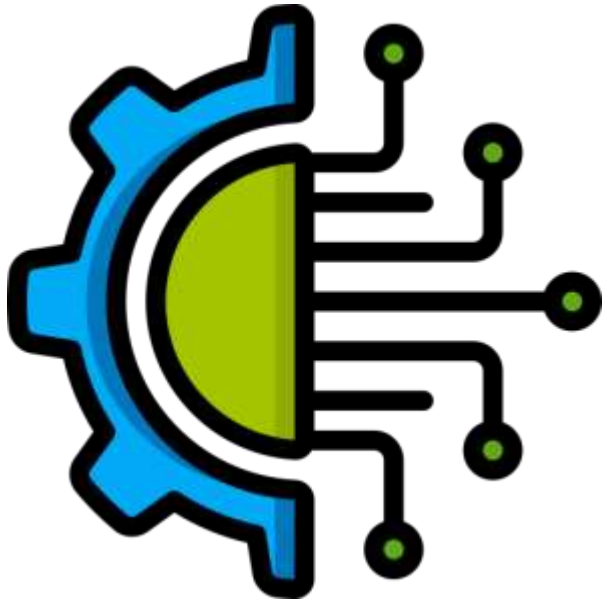

Les changements

- Pas de révolution!
- Modifications
  - Du texte
  - Des critères
  - Deux niveaux de conformité
    - In Progress
    - Implemented

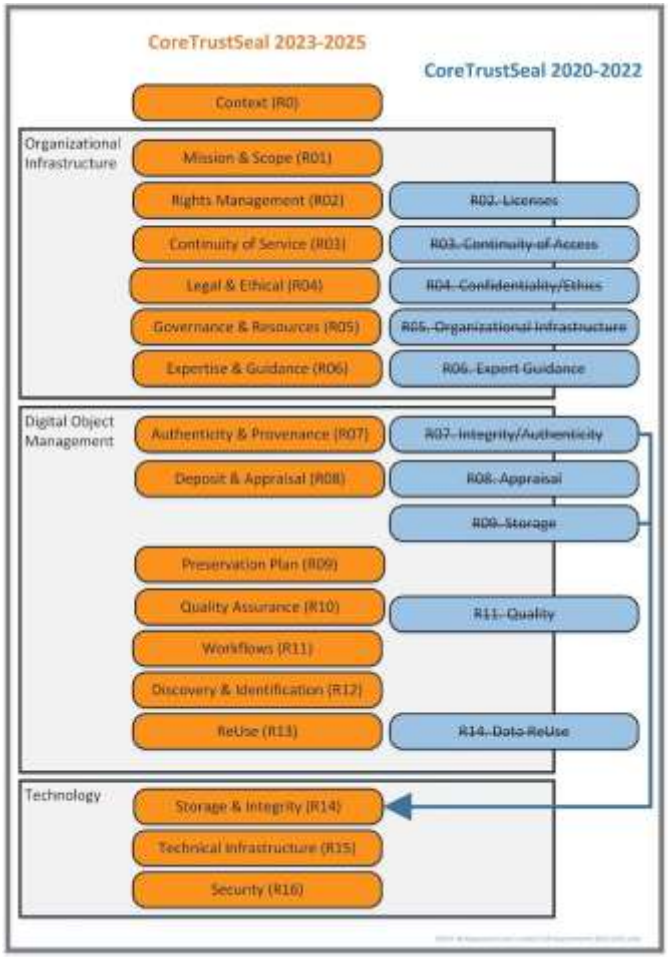

Credits: Mari Kleemola & Hervé L'Hours

Les nouveaux critères 2023-2025

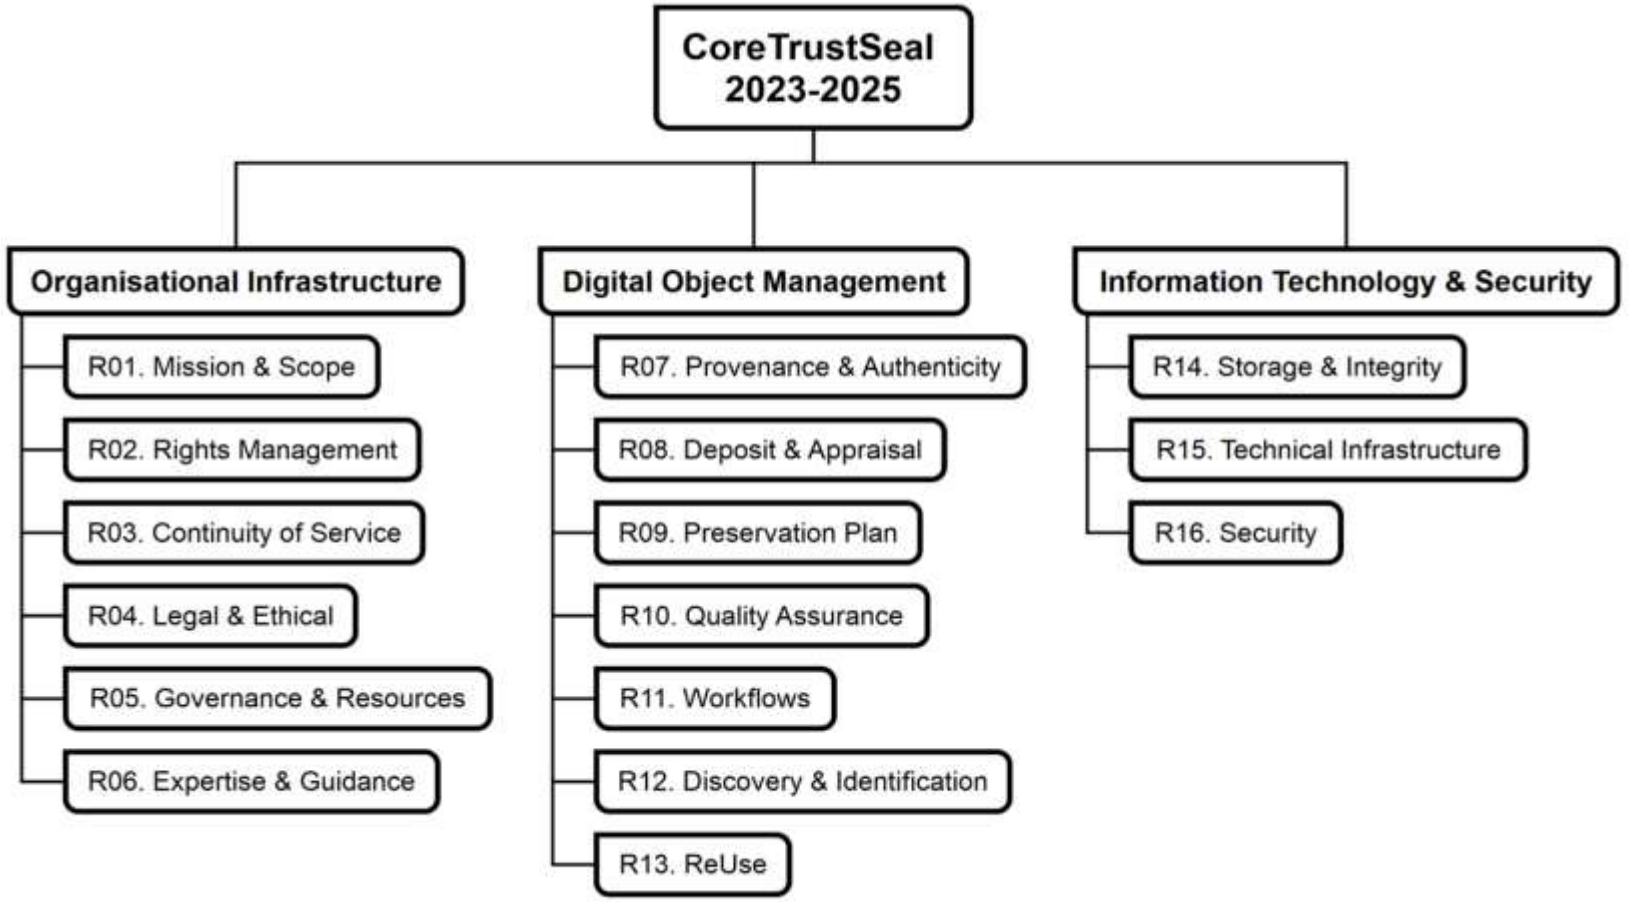

Parmi les changements (1)

- Une évolution du contenu du critère R0
- R2 Licences >> **R02 Gestion des Droits**

  The repository maintains all applicable licenses covering data access and use and monitors compliance

  >> **The repository maintains all applicable rights and monitors compliance.**
- R3 Continuité d'accès >> **R03 Continuité de service**

  The repository has a continuity plan to ensure ongoing access to and preservation of its holdings.

  >> **The Repository has a plan to ensure ongoing access to and preservation of its data and metadata.**

Parmi les changements (2)

- R4 Confidentialité/Ethique > **R04 Aspects Légaux et Ethiques**

  The repository ensures, to the extent possible, that data are created, curated, accessed, and used in compliance with disciplinary and ethical norms.

  >> **The repository ensures to the extent possible that data and metadata are created, curated, preserved, accessed and used in compliance with legal and ethical norms.**

- R10 Qualité des données > **R10 Assurance Qualité**

  The repository has appropriate expertise to address technical data and metadata quality and ensures that sufficient information is available for end users to make quality related evaluations.

  >> **The repository addresses technical quality and standards compliance, and ensures that sufficient information is available for end users to make quality-related evaluations.**

Parmi les changements (3)

- R11 Workflows > **R11 Workflows**

  Archiving takes place according to defined workflows from ingest to dissemination.

  >> **Digital object management takes place according to defined workflows from deposit to access.**

- R9 Procédures de stockages documentées +dans R7 Intégrité> **R14 Stockage & Intégrité**

  The repository applies documented processes and procedures in managing archival storage of the data.

  >> **The repository applies documented processes to ensure data and metadata storage and integrity.**

RDA FRANCE

Conclusions

Pourquoi la certification?

- Quelques semaines de travail d'équipe dans la plupart des cas (tout compris)
  - Beaucoup plus pour d'autres mais ça continue à valoir le coup!
- Evaluation – amélioration des process
  - Auto-évaluation
  - Evaluation externe
- Importance croissante pour les financeurs des centres de données et des projets (PGD)
- Priorité au niveau politique en France, intérêt des organismes (CNRS, Universités)

L’impact de la RDA

- Fusion des deux cadres de certification ‘de base’
- Clarification du paysage pour les centres de données et les agences de financement
- Deux cadres complémentaires au départ: le résultat est meilleur que chacun des originaux!
- Création de CoreTrustSeal
- Nombreux nouveaux candidats à la certification

Le rôle de RDA France

- La certification est une priorité
- Groupe de Travail commun avec le collège Données du Comité pour la Science Ouverte depuis juillet 2021
  - Prise en charge des frais administratifs de certification
  - Outil de visualisation et de partage des dossiers de certification
    https://crusoe.ouvrirlascience.fr/
- Ateliers, présentations à la demande, etc.
  - Plus de 300 personnes ont suivi les ateliers
- Démarrage de la mise en réseau des entrepôts certifiés et « sur le chemin de la certification »
  - Première réunion le 13 octobre 2023, pendant les Journées RDA France 2023
- Liste de diffusion
  https://listes.services.cnrs.fr/wws/subscribe/rda-france-certification

RDA FRANCE

RDA Global

Email - enquiries@rd-alliance.org

Web - www.rd-alliance.org

Twitter - @resdatall

LinkedIn - www.linkedin.com/in/ResearchDataAlliance

Slideshare - http://www.slideshare.net/ResearchDataAlliance

RDA FRANCE

https://rd-alliance.org/groups/rda-france

Email - contact-rdafrance@services.cnrs.fr