



HAL
open science

Plan de gestion de données Plateau technique Analyses des Acides Nucléiques (ANAN)

Sandrine Balzergue, Julien Jeauffre, Muriel Bahut

► **To cite this version:**

Sandrine Balzergue, Julien Jeauffre, Muriel Bahut. Plan de gestion de données Plateau technique Analyses des Acides Nucléiques (ANAN). Université d'Angers (UA), Angers, FRA. 2024. hal-04599612v2

HAL Id: hal-04599612

<https://hal.science/hal-04599612v2>

Submitted on 6 Jun 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Open licence - etalab

DMP du projet "PTM ANalyses des Acides Nucléiques (ANAN)"

Plan de gestion de données créé à l'aide de DMP OPIDoR, basé sur le modèle "INRA - Trame Structure" fourni par INRAE - Institut national de recherche pour l'agriculture l'alimentation et l'environnement.

Renseignements sur le plan

Titre du plan	DMP du projet "PTM ANalyses des Acides Nucléiques (ANAN)"	
Version	Version intermédiaire	
Domaines de recherche (selon classification de l'OCDE)		
Langue	fra	
Date de création	2019-07-02	
Date de dernière modification	2024-05-27	
Identifiant	hal-04599612v1	
Type d'identifiant	Identifiant local	
Licence	Nom	Etalab Open License 2.0
	URL	http://spdx.org/licenses/etalab-2.0.json

Renseignements sur le projet

Titre du projet

PTM ANalyses des Acides Nucléiques (ANAN)

Acronyme

PDG_ANAN

Résumé

Maison de la Recherche
Campus du Végétal
42 rue Georges Morel - CS 60057
49071 Beaucouzé cedex - France

Site internet

Le plateau technique mutualisé "ANalyses des Acides Nucléiques" (ANAN) est l'un des trois plateaux de la SFR Quasav. Il a pour objectif de mutualiser et de mettre à disposition de la communauté scientifique de la SFR et de ses partenaires, des outils d'analyses en **génomique** (génotypage, transcriptomique...)

Les utilisateurs ont également à leur disposition des appareils dédiés à la **préparation, au dosage et au contrôle qualité** de leurs échantillons d'acides nucléiques.

L'équipe ANAN est présente pour accompagner les utilisateurs dans le montage de leurs projets et le design de leurs expériences.

Partenaires

- ANSES - Laboratoire de la santé des végétaux
- Groupe d'études et de contrôle des variétés et des semences
- Institut de Recherche en Horticulture et Semences
<https://ror.org/02xq0x374>
- Signalisation Fonctionnelle des Canaux Ioniques et Récepteurs
<https://ror.org/000n0fx93>
- SUBSTANCES D'ORIGINE NATURELLE ET ANALOGUES STRUCTURAUX
- Légumineuses, Ecophysiologie Végétale, Agroécologie
- Groupe de Recherche en Agro-alimentaire sur les Produits et les Procédés
- environnement physique de la plante horticole
- Institut de Génétique Environnement et Protection des Plantes
- Unité en sciences biologiques et biotechnologies UMR 6286 (ex Unité de fonctionnalité et Ingénierie des Protéines)
- Biopolymères, Interactions Assemblages <https://ror.org/013vjwn12>

Produits de recherche :

1. Données acquises sur instruments (Jeu de données)
2. Codes informatiques embarqués aux instruments du laboratoire (Logiciel)

Contributeurs

Nom	Affiliation	Rôles
Bahut Muriel	Université d'Angers	<ul style="list-style-type: none"> • Coordinateur du projet • Personne contact pour les données (Données acquises, Codes embarqués)
Jeuffre Julien - julien-jeuffre	INRAE	<ul style="list-style-type: none"> • Responsable du plan de gestion de données

DMP du projet "PTM ANalyses des Acides Nucléiques (ANAN)"

Données acquises sur instruments

Informations sur la structure

Nom de la structure

Plateau technique mutualisé "ANalyses des Acides Nucléiques" (ANAN)

Type de structure

- Plateforme, plateau technique

PTM ANAN
Maison de la Recherche
Campus du Végétal
42 rue Georges Morel - CS 60057
49071 Beaucouzé cedex - France

[Site internet](#)

Le plateau technique mutualisé "ANalyses des Acides Nucléiques" (ANAN) est l'un des trois plateaux de la SFR Quasav. Il a pour objectif de mutualiser et de mettre à disposition de la communauté scientifique de la SFR et de ses partenaires, des outils d'analyses en **génomique** (génotypage, transcriptomique...)

Les utilisateurs ont également à leur disposition des appareils dédiés à la **préparation, au dosage et au contrôle qualité** de leurs échantillons d'acides nucléiques.

L'équipe ANAN est présente pour accompagner les utilisateurs dans le montage de leurs projets et le design de leurs expériences.

Identifiant de la structure

Préciser le fournisseur de l'identifiant (ISNI, VIAF, FundRef, DataCite...).

1088518 AuréHAL

Responsabilités dans la structure

Nom, Prénom	Courriel	Rôle
Balzerque, Sandrine	sandrine.balzerque@inrae.fr	Responsable scientifique
Bahut, Muriel	muriel.bahut@univ-angers.fr	Responsable technique
Jeauffre, Julien	julien.jeauffre@inrae.fr	Responsable Plan de gestion de Données

Etablissement(s) tutelle(s)

Université d'Angers

Département de rattachement Inra

Financier(s) (permettant l'acquisition des jeux de données - hors projet)

- SFR QuaSaV
- Europe
- Région Pays de la Loire
- Angers Loire Métropole
- Etat Français

Informations sur le plan de gestion

DOI (version publiée du plan de gestion)

Pas encore publié

Historique des versions

Date	n° de version	Status	Auteur	Affiliation de l'auteur (se reporter à l' annuaire Inra)	Validé par	Validé le
19/02/2024	0	en cours	Julien JEAUFFRE			

Présentation générale des données

Mode d'obtention des données

- Données générées par la structure
- Données produites par un tiers

Les données expérimentales sont obtenues grâce aux instruments de mesure. Elles peuvent être brutes (sortie de l'instrument), et/ou bien transformées (transformation informatique)

- Les données obtenues grâce aux instruments de contrôle-qualité sont des données brutes.
 - Données chiffrées de dosage de molécule (technologies par absorbance & fluorimétrie)
 - Données de profil électrophorétique

- Les données obtenues grâce aux instruments de séquençage haut débit sont des données brutes et transformées.
 - Données court fragment (technologie Illumina)
 - Données long fragment (technologie Oxford Nanopore)
- Les données obtenues grâce aux instruments d'amplification (thermocycleurs) sont des données brutes.
 - Données de géotypage SNP (technologie KASP)
 - Données d'expression (par sonde et par colorant).

Origine

- Expérimentation

Instruments de préparation des acides nucléiques (manipulation de solutions , extraction d'acides nucléiques, fragmentation, fabrication de banques NGS)

- Robot Perkin-Elmer, Zephyr
- Robot ID-Solutions, IDEAL-32
- Sonicateur Covaris, M220

Instruments de contrôle qualité

- Spectromètre Thermo-Scientific, NanoDropOne
- Lecteur de plaque BMG-Labtech, FluoStar
- Elctrophorese capillaire automatisée Agilent Bioanalyser 2100

Instruments d'amplification

- Thermocycleur T100 (Bio-Rad)
- Thermocycleur en temps réel CFX Touch (Bio-Rad)
- Thermocycleur en temps réel CFX OPUS (Bio-Rad)

Instruments de séquençage haut débit:

- iSeq 100 (Illumina)
- MiSeq (Illumina)
- Minion Mk1B (Oxford Nanopore Technology)

Type de données

- Dataset

Dataset : Fichiers de données expérimentales ou de traitements de données

Nature des données

Données génomiques expérimentales

- Donnée chiffrée quantifiant les solutions d'acides nucléiques
 - Profil électrophorétique qualifiant les solutions d'acides nucléiques
 - Donnée chiffrée post-amplification (Cq) qualifiant les solutions d'acide nucléiques
 - Séquence nucléotidique (ADN/ARN)
-

Format des données

Type de données	Format informatique de sortie (propriétaire / ouvert)	Format informatique transformé (propriétaire / ouvert)
Données chiffrées de quantification des acides nucléiques par mesure d'absorbance ou de fluorimétrie	Comma-separated values (csv)	
Données de qualification des acides nucléiques par profil électrophorétique	.xad	Portable Document Format (pdf)
Données de séquençage massif	lecture courte (Illumina): Binary Base Call (BCL) lecture longue (Oxford Nanopore): Hierarchical Data Format (.fast5)	fastq (fastq; fq) GNU zip (.gz)
Données d'amplification * géotypage SNP chimie KASP * expression par chimie intercalante ou sonde FRET	Data (pcrd) Fichier de pré-données autonome (zpcr)	/

Périmètre thématique des données

- Biodiversity and Ecology
- Microorganisms
- Omics
- Plant Breeding and Plant Products
- Plant Health and Pathology
- Soils and soil sciences
- Animal Breeding and Animal Products
- Human Health and Pathology

Droits de propriété intellectuelle

Qui détiendra les droits sur les données et les autres informations créées ?

- **Projet en Prestation** : Le PTM ANAN est propriétaire des méthodes et l'utilisateur est propriétaire des résultats. Le PTM ANAN peut donc librement communiquer sur les méthodes, mais ne pourra communiquer sur les résultats qu'après accord écrit de l'utilisateur. En terme de valorisation, l'utilisateur doit systématiquement mentionner le PTM ANAN dans les remerciements de toutes les valorisations scientifiques ; en cas d'une implication significative du PTM ANAN, le co-autorat sera de mise.
- **Projet en R&D/Collaboration** : l'utilisateur et le PTM ANAN définissent la propriété intellectuelle des méthodes et des résultats d'un commun accord dans le cahier des charges. Il en sera de même dans le cas de valorisation scientifique.

Confidentialité

Identification des jeux de données contenant des données confidentielles

De manière générale, les données sont la propriété des utilisateurs et sont considérées comme des informations confidentielles. Les données resteront confidentielles jusqu'à publication par l'auteur.
Dans le cas spécifiques des projets internes, les données ont vocations à être rendues publiques (publications, poster, data.gouv). La liste des clients et données à caractère personnel sont listés en interne à la structure.

Quelles sont les mesures prises et les normes auxquelles il est nécessaire de se conformer pour garantir cette confidentialité ?

Anonymisation des noms de projets.
Transfert des données uniquement à l'utilisateur.

Le cas échéant, comment la confidentialité de données fournies par des personnes sera garantie lorsque les données seront partagées ou rendues disponibles pour une analyse de second niveau ?

Pas concerné

Partage des données

Y a t'il une obligation de partage (ou à l'inverse une interdiction ou une restriction) ?

Les données générées dans le cadre d'une prestation, la donnée (brute et raffinée) appartient à l'utilisateur, donc le choix lui revient.
Les codes informatiques ayant concourus à l'acquisition des données seront rendus publics au travers des forges institutionnelles.
Les données générées dans le cadre d'un projet interne ou en collaboration financé en partie ou en totalité pour un financeur publique suit la politique d'ouverture des données selon le principe "ouvert autant que possible, fermé autant que nécessaire".

Quelles sont les réutilisations potentielles de ces données ?

Dans le cadre d'une prestation de service, l'utilisateur est libre de faire ce qu'il veut des données produites (analyse, publication...)
Dans le cadre d'un projet en interne, ou en collaboration, l'utilisateur et le PTM ANAN définissent les conditions de réutilisation des données, des méthodes et des résultats d'un commun accord.

La lecture des données nécessite-t-elle le recours à un logiciel ou un outil spécifique ? Si oui, lequel ?

La lecture des données acquises grâce aux thermocycleurs ainsi que les programmes d'amplification nécessite l'usage du logiciel propriétaire CFX Maestro 2.3 (Bio-Rad)

La lecture des données aux formats Excel Binary File Format (xls) et Extensions to the Office Open XML SpreadsheetML File Format(xlsx) nécessite l'usage du logiciel propriétaire Microsoft Excel

La lecture des données de qualification des acides nucléiques par profil électrophorétique nécessite l'usage du logiciel propriétaire 2100 Expert (Agilent)

L'usage de ces trois logiciels propriétaires oblige l'utilisateur à acheter une licence commerciale s'il souhaite analyser les données brutes sur son poste informatique

Comment les données seront-elles partagées ?

Les données acquises par les instruments de contrôle-qualité & les instruments de séquençage haut débit sont mises à disposition sur le serveur de stockage NAS du pôle informatique de l'IRHS (partage-bioinfo.angers-nantes.inrae.fr/anan/data), sous condition d'accès.

Les données acquises par les instruments de contrôle-qualité pour/par utilisateurs du laboratoire IRHS sont également accessibles par le serveur de stockage NAS de l'unité (pnas1.stockage.inrae.fr/angersnantes-irhs/irhs), sous condition d'accès.

Les données acquises par les thermocycleurs sont accessibles par support physique portatif (clé USB/Disque Dur)

Cas particulier des données acquises par l'instrument de séquençage haut débit Illumina NextSeq550:

Les données acquises sont accessibles par support physique portatif (Disque Dur) puis mises à disposition sur le serveur de stockage NAS du pôle informatique de l'IRHS (partage-bioinfo.angers-nantes.inrae.fr/anan/data), sous condition d'accès.

Avec qui ?

- Autre

Les données sont uniquement partagées avec l'utilisateur.

Sous quelle licence ?

Non concerné

Organisation et documentation des données

Quels méthodes et outils sont utilisés pour acquérir et traiter les données, depuis leur acquisition jusqu'à leur mise à disposition, leur archivage ou leur destruction ?

Utiliser éventuellement un lien vers un schéma illustrant les processus

Type de données	Documentation des données	Stockage des données	Archivage
Données chiffrées de quantification des acides nucléiques par mesure d'absorbance ou de fluorimétrie	Modes opératoires et instructions	Sur l'instrument	N/A
Données de qualification des acides nucléiques par profil électrophorétique	Modes opératoires et instructions	Sur l'instrument	N/A
Données de séquençage massif	Modes opératoires et instructions	Sur serveur interne géré par pôle informatique de l'UMR IRHS durant 3 ans	N/A
Données d'amplification * génotypage SNP chimie KASP * expression par chimie intercalante ou sonde FRET	Mode opératoire de l'utilisateur	Sur l'instrument	N/A

Quelles métadonnées seront utilisées pour accompagner le jeu de données ? Quels seront les standards, vocabulaires, taxonomies... utilisés pour décrire et représenter les données et éléments de métadonnées ? Comment les métadonnées seront-elles produites et mises à jour ?

Les métadonnées sont disponibles à travers les modes opératoires, les instructions, les fichiers log des instruments et les cahiers de laboratoires tenus par le PTM ANAN.

Une documentation complémentaire aux métadonnées est-elle nécessaire pour décrire les données et assurer leur réutilisabilité sur le long terme ?

Comment les fichiers de données sont-ils gérés et organisés : contrôle des versions, conventions de nommage des fichiers, organisation des fichiers

Type de données	Convention de nommage des fichiers	Contrôle des versions	Organisation des fichiers
Données chiffrées de quantification des acides nucléiques par mesure d'absorbance ou de fluorimétrie	A la discrétion des utilisateurs	N/A	par date
Données de qualification des acides nucléiques par profil électrophorétique	type de puce_date	N/A	par équipe et par date
Données de séquençage massif	N°Run généré par l'instrument (Illumina) et par le PTM ANAN (Oxford Nanopore)	N/A	Par date
Données d'amplification * génotypage SNP chimie KASP * expression par chimie intercalante ou sonde FRET	A la discrétion des utilisateurs	N/A	par équipe et par date

Quelle est le processus de contrôle qualité des données ?

Type de données

Processus de contrôle qualité

Données chiffrées de quantification des acides nucléiques par mesure d'absorbance ou de fluorimétrie

N/A

Données de qualification des acides nucléiques par profil électrophorétique

Calibrateur interne : marqueur de taille

Données de séquençage massif

Données de qualité générées par Sequencing Analysis Viewer (Illumina)

Données de qualité générées par Minknow (ONT)

Données d'amplification

* géotypage SNP chimie KASP

* expression par chimie intercalante ou sonde FRET

A la discrétion des utilisateurs

Stockage et sécurité des données

Quels sont les types de flux empruntés par les données et les supports utilisés pour les stocker ?
(Faire éventuellement un lien vers un schéma)

Type de données

Support de Stockage des données

Flux

Données chiffrées de quantification des acides nucléiques par mesure d'absorbance ou de fluorimétrie

Sur l'instrument

versement sur clé USB par l'utilisateur

Données de qualification des acides nucléiques par profil électrophorétique

Sur l'instrument

versement sur clé USB par l'utilisateur

Données de séquençage massif

Sur serveur interne géré par pôle informatique de l'UMR IRHS durant 3 ans

versement manuel des données

Données d'amplification

* géotypage SNP chimie KASP

* expression par chimie intercalante ou sonde FRET

Sur l'instrument

versement sur clé USB par l'utilisateur

Quelle est la volumétrie actuelle et prévisionnelle ?

1- La volumétrie de données stockées disponibles pour la partition ANAN est de 4,5 To. A date (22 mai 2024), 87% de la capacité est utilisé soit 3,7 To, et 581 Go utilisables.

L'entité hébergeant physiquement les données a-t-elle une politique de sécurité pour son système d'information ? *politique locale, charte des infrastructures de recherche...*

Repose sur les SI de l'unité (UMR 1345) :

- Portail des données INRAE
- [Charte des infrastructures de recherche à l'Inra](#)

Cela implique une sauvegarde du NAS avec réplication

Sécurité - Confidentialité : les données font-elles l'objet d'échange ou de partage avec de tiers acteurs et selon quelles modalités ? comment sont déterminés les droits d'accès aux données avant leur publication ?

Seuls les coordinateurs ou collaborateurs du projet et le personnel de la plateforme ont accès aux données tant qu'elles ne sont pas publiques.

Pas d'échanges avec des acteurs tiers par défaut, sauf dans le cas des données de séquençage Illumina qui peuvent être accessibles au support technique lorsqu'un run est problématique (accès sécurisé et individuel).

Sécurité - Intégrité - Tracabilité : Quelles sont les mesures de protection mises en œuvre pour suivre la production et l'analyse des données ?

Sécurité

- Protection des ordinateurs pilotant les instruments de mesure contre les virus et les intrusions assurée par le pare-feu Defender
- Des sauvegardes hebdomadaires sont mises en place pour garantir la préservation des données. La communication est sécurisée par le protocole SSH, qui chiffre les échanges entre le client et le serveur en utilisant un système de clés publiques et privées.

Archivage et conservation des données

Quelles sont les données à conserver sur le moyen ou le long terme et quelles sont les données à détruire ?

Le plateau ANAN est un plateau d'acquisition de données.

Dans le cadre de prestations de service, il n'a pas vocation à conserver les données produites sur le moyen/long terme. La durée choisie pour la mise à disposition des données est de trois années (après la clôture du projet (dernières données envoyées). Possibilité de déroger à cette règle si accord préalable avec l'utilisateur.

Pour les projets collaboratifs, les données sont stockées 3 ans après la date de fin de projets.

A plus long terme toutes les données sont détruites, la plateforme n'a pas vocation à faire de l'archivage de données. La conservation des données appartient à l'utilisateur.

Sur quelle plateforme d'archivage pérenne seront archivées les données à conserver sur le long terme ? Sinon, quelles procédures seront mises en place pour la conservation à long terme ?

Le plateau ANAN est un plateau d'acquisition de données.

il n'a pas vocation à conserver les données produites sur le moyen/long terme.

L'archivage des données appartient à l'utilisateur.

Quelle est la durée de conservation des données ?

Dans le cadre de prestations de service, il n'a pas vocation à conserver les données produites sur le moyen/long terme. La durée choisie pour la mise à disposition des données est de trois années (après la clôture du projet (dernières données envoyées). Possibilité de déroger à cette règle si accord préalable avec l'utilisateur.

Pour les projets collaboratifs, les données de séquençage sont stockées 3 ans après la date de fin de projets.

A plus long terme toutes les données sont détruites, la plateforme n'a pas vocation à faire de l'archivage de données. La conservation des données appartient à l'utilisateur.

Quelles garanties de financements couvriront les coûts associés à la conservation à long terme ?

Les structures porteuses de la SFR Quasav assurent le financement des serveurs.

Codes informatiques embarqués aux instruments du laboratoire

Informations sur la structure

Nom de la structure

Plateau technique mutualisé "ANalyses des Acides Nucléiques" (ANAN)

Type de structure

- Plateforme, plateau technique

PTM ANAN
Maison de la Recherche
Campus du Végétal
42 rue Georges Morel - CS 60057
49071 Beaucouzé cedex - France

[Site internet](#)

Le plateau technique mutualisé "ANalyses des Acides Nucléiques" (ANAN) est l'un des trois plateaux de la SFR Quasav. Il a pour objectif de mutualiser et de mettre à disposition de la communauté scientifique de la SFR et de ses partenaires, des outils d'analyses en **génomique** (génotypage, transcriptomique...)

Les utilisateurs ont également à leur disposition des appareils dédiés à la **préparation, au dosage et au contrôle qualité** de leurs échantillons d'acides nucléiques.

L'équipe ANAN est présente pour accompagner les utilisateurs dans le montage de leurs projets et le design de leurs expériences.

Identifiant de la structure

Préciser le fournisseur de l'identifiant (ISNI, VIAF, FundRef, DataCite...).

1088518 AuréHAL

Responsabilités dans la structure

Nom, Prénom	Courriel	Rôle
Balzerque, Sandrine	sandrine.balzerque@inrae.fr	Responsable scientifique
Bahut, Muriel	muriel.bahut@univ-angers.fr	Responsable technique
Jeauffre, Julien	julien.jeauffre@inrae.fr	Responsable Plan de gestion de Données

Etablissement(s) tutelle(s)

Université d'Angers

Département de rattachement Inra

Financier(s) (*permettant l'acquisition des jeux de données - hors projet*)

- SFR QuaSaV
- Europe
- Région Pays de la Loire
- Angers Loire Métropole
- Etat Français

Informations sur le plan de gestion

DOI (version publiée du plan de gestion)

Pas encore publié

Historique des versions

Date	n° de version	Status	Auteur	Affiliation de l'auteur (se reporter à l' annuaire Inra)	Validé par	Validé le
19/02/2024	0	en cours	Julien JEAUFFRE			

Présentation générale des données

Mode d'obtention des données

- Données générées par la structure
- Données produites par un tiers

Un jeu de codes informatiques pilotant l'instrument de manipulation robotisée ID-Solutions IDEAL32, est fourni par défaut par le fournisseur de l'instrument (Macherey/Nagel).

Un jeu de codes informatiques pilotant l'instrument de mesure automatisée BMGLabtech-FluoSTAR, et des scripts d'automatisation de ces codes sont fournis par défaut par le fabricant de l'instrument .

Ces codes de pilotage et scripts d'automatisation font l'objet de modifications pour les adapter aux spécificités des échantillons biologiques et/ou questions de recherche. Ces modifications sont tracées et versionnées.

Des codes informatiques pilotant l'instrument de manipulation robotisé Perkin-Elmer Zephyr sont conçus en interne. Ils font l'objet de modifications pour les adapter aux spécificités des échantillons biologiques et/ou questions de recherche. Ces modifications sont tracées et versionnées.

Origine

- Code

Logiciels commerciaux

Type_instruments	Nom_fabricant_instrument	Nom_logiciel
Séquenceurs	Oxford Nanopore	MinKnow
Séquenceurs	Illumina	Illumina Control Software, Illumina Sequencing Viewer
Lecteur de plaque	BMG-LabTech	BMG-LabTech OMEGA, BMG-LabTech MARS
Thermocycleurs	Bio-Rad	Bio-Rad CFX Maestro
Spectromètre	Thermo scientific	NanodropOne software
Fluorimètre	Thermo scientific	Qubit : Qubit software
Electrophorèse capillaire	Agilent	2100 expert software
Robot	Perkin-Elmer	Maestro Software
Robot	ID-Solutions	IDEAL-32 software
Sonicateur	Covaris	SonoLab

Type de données

- Software

Nature des données

Codes informatiques

Format des données

Type de données	Format informatique de sortie (propriétaire / ouvert)	Format informatique transformé (propriétaire / ouvert)
Programme de mesure automatisée * Quantification des acides nucléiques * Quantification des activités enzymatiques * Quantifications des métabolites primaires et secondaires	code (.tsc) script (.btc)	Excel Binary File Format (xls) Extensions to the Office Open XML SpreadsheetML File Format(xlsx) Comma-separated values (csv)
Programme d'amplification * génotypage SNP chimie KASP * expression par chimie intercalante ou sonde FRET * Fabrication de banque destinée au séquençage massif	Protocol (prcl) Plate (.pltd)	
Programmes de manipulation robotisée * Extraction des acides nucléiques * Manipulation de solutions	Robot Perkins-Elmer Zephyr: csd / Robot ID-solutions IDEAL32: .txt	
Programmes de fragmentation physique des acides nucléiques par sonication	Sonicateur Covaris M220 Focused-ultrasonicator: .PRO ; .txt	

Périmètre thématique des données

- Animal Breeding and Animal Products
- Biodiversity and Ecology
- Food and food processing
- Human Health and Pathology
- Material Science and Engineering
- Microorganisms
- Omics
- Plant Breeding and Plant Products
- Plant Health and Pathology
- Rural and Agricultural Sociology
- Soils and soil sciences
- Water resources

Droits de propriété intellectuelle

Qui détiendra les droits sur les données et les autres informations créées ?

- **Projet en Prestation** : Le PTM ANAN est propriétaire des méthodes et l'utilisateur est propriétaire des résultats. Le PTM ANAN peut donc librement communiquer sur les méthodes, mais ne pourra communiquer sur les résultats qu'après accord écrit de l'utilisateur. En terme de valorisation, l'utilisateur doit systématiquement mentionner le PTM ANAN dans les remerciements de toutes les valorisations scientifiques ; en cas d'une implication significative du PTM ANAN, le co-autorat sera de mise.
- **Projet en R&D/Collaboration** : l'utilisateur et le PTM ANAN définissent la propriété intellectuelle des méthodes et des résultats d'un commun accord dans le cahier des charges. Il en sera de même dans le cas de valorisation scientifique.

Confidentialité

Identification des jeux de données contenant des données confidentielles

De manière générale, les données sont la propriété des utilisateurs et sont considérées comme des informations confidentielles. Les données resteront confidentielles jusqu'à publication par l'auteur.
Dans le cas spécifiques des projets internes, les données ont vocations à être rendues publiques (publications, poster, data.gouv). La liste des clients et données à caractère personnel sont listés en interne à la structure.

Quelles sont les mesures prises et les normes auxquelles il est nécessaire de se conformer pour garantir cette confidentialité ?

Anonymisation des noms de projets.
Transfert des données uniquement à l'utilisateur.

Le cas échéant, comment la confidentialité de données fournies par des personnes sera garantie lorsque les données seront partagées ou rendues disponibles pour une analyse de second niveau ?

Pas concerné

Partage des données

Y a t'il une obligation de partage (ou à l'inverse une interdiction ou une restriction) ?

Les données générées dans le cadre d'une prestation, la donnée (brute et raffinée) appartient à l'utilisateur, donc le choix lui revient.

Les codes informatiques ayant concourus à l'acquisition des données seront rendus publiques au travers des forges institutionnelles.

Les données générées dans le cadre d'un projet interne ou en collaboration financé en partie ou en totalité pour un financeur publique suit la politique d'ouverture des données selon le principe "ouvert autant que possible, fermé autant que nécessaire".

Quelles sont les réutilisations potentielles de ces données ?

Dans le cadre d'une prestation de service, l'utilisateur est libre de faire ce qu'il veut des données produites (analyse, publication...)
Dans le cadre d'un projet en interne, ou en collaboration, l'utilisateur et le PTM ANAN définissent les conditions de réutilisation des données , des méthodes et des résultats d'un commun accord.

La lecture des données nécessite-t-elle le recours à un logiciel ou un outil spécifique ? Si oui, lequel ?

La lecture des données acquises grâce aux thermocycleurs ainsi que les programmes d'amplification nécessite l'usage du logiciel propriétaire CFX Maestro 2.3 (Bio-Rad)

La lecture des données aux formats Excel Binary File Format (xls) et Extensions to the Office Open XML SpreadsheetML File Format(xlsx) nécessite l'usage du logiciel propriétaire Microsoft Excel

La lecture des données de qualification des acides nucléiques par profil électrophorétique nécessite l'usage du logiciel propriétaire 2100 Expert (Agilent)

L'usage de ces trois logiciels propriétaires oblige l'utilisateur à acheter une licence commerciale s'il souhaite analyser les données brutes sur son poste informatique

Comment les données seront-elles partagées ?

Les données acquises par les instruments de contrôle-qualité & les instruments de séquençage haut débit sont mises à disposition sur le serveur de stockage NAS du pôle informatique de l'IRHS (partage-bioinfo.angers-nantes.inrae.fr/anandata), sous condition d'accès.

Les données acquises par les instruments de contrôle-qualité pour/par utilisateurs du laboratoire IRHS sont également accessibles par le serveur de stockage NAS de l'unité (pnas1.stockage.inrae.fr/angersnantes-irhs/irhs), sous condition d'accès.

Les données acquises par les thermocycleurs sont accessibles par support physique portatif (clé USB/Disque Dur)

Cas particulier des données acquises par l'instrument de séquençage haut débit Illumina NextSeq550:

Les données acquises sont accessibles par support physique portatif (Disque Dur) puis mises à disposition sur le serveur de stockage NAS du pôle informatique de l'IRHS (partage-bioinfo.angers-nantes.inrae.fr/anandata), sous condition d'accès.

Avec qui ?

- Autre

Les données sont uniquement partagées avec l'utilisateur.

Sous quelle licence ?

Non concerné

Organisation et documentation des données

Quels méthodes et outils sont utilisés pour acquérir et traiter les données, depuis leur acquisition jusqu'à leur mise à disposition, leur archivage ou leur destruction ?

Utiliser éventuellement un lien vers un schéma illustrant les processus

Type de données	Documentation des données	Stockage des données	Archivage
Programme de mesure automatisée * Quantification des acides nucléiques * Quantification des activités enzymatiques * Quantifications des métabolites primaires et secondaires	Instructions	Sur l'instrument	sur Disque Dur Externe
Programme d'amplification * génotypage SNP chimie KASP * expression par chimie intercalante ou sonde FRET * Fabrication de banque destinée au séquençage massif	Mode opératoire de l'utilisateur	Sur l'instrument	N/A
Programmes de manipulation robotisée * Extraction des acides nucléiques * Manipulation de solutions	Instructions	Sur l'instrument	sur Disque Dur Externe
Programmes de fragmentation physique des acides nucléiques par sonication	Mode opératoire de l'utilisateur	Sur l'instrument	N/A

Quelles métadonnées seront utilisées pour accompagner le jeu de données ? Quels seront les standards, vocabulaires, taxonomies... utilisés pour décrire et représenter les données et éléments de métadonnées ? Comment les métadonnées seront-elles produites et mises à jour ?

Les métadonnées sont disponibles à travers les modes opératoires, les instructions, les fichiers log des instruments et les cahiers de laboratoires tenus par le PTM ANAN.

Une documentation complémentaire aux métadonnées est-elle nécessaire pour décrire les données et assurer leur réutilisabilité sur le long terme ?

Comment les fichiers de données sont-ils gérés et organisés : contrôle des versions, conventions de nommage des fichiers, organisation des fichiers

Type de données	Convention de nommage des fichiers	Contrôle des versions	Organisation des fichiers
Programme de mesure automatisée * Quantification des acides nucléiques * Quantification des activités enzymatiques * Quantifications des métabolites primaires et secondaires	A la discrétion des utilisateurs	N/A	par équipe
Programme d'amplification * génotypage SNP chimie KASP * expression par chimie intercalante ou sonde FRET * Fabrication de banque destinée au séquençage massif	A la discrétion des utilisateurs	N/A	par équipe
Programmes de manipulation robotisée * Extraction des acides nucléiques * Manipulation de solutions	par numéro interne	par numéro interne	par équipe
Programmes de fragmentation physique des acides nucléiques par sonication	A la discrétion des utilisateurs	N/A	par équipe

Quelle est le processus de contrôle qualité des données ?

Stockage et sécurité des données

Quels sont les types de flux empruntés par les données et les supports utilisés pour les stocker ?
(Faire éventuellement un lien vers un schéma)

Type de données	Support de Stockage des données	Flux
Programme de mesure automatisée * Quantification des acides nucléiques * Quantification des activités enzymatiques * Quantifications des métabolites primaires et secondaires	Sur l'instrument	Manuellement sur Disque Dur Externe par la responsable technique
Programme d'amplification * génotypage SNP chimie KASP * expression par chimie intercalante ou sonde FRET * Fabrication de banque destinée au séquençage massif	Sur l'instrument	N/A
Programmes de manipulation robotisée * Extraction des acides nucléiques * Manipulation de solutions	Sur l'instrument	Manuellement sur Disque Dur Externe par la responsable technique
Programmes de fragmentation physique des acides nucléiques par sonication	Sur l'instrument	N/A

Quelle est la volumétrie actuelle et prévisionnelle ?

Volume des codes de programmes des appareils : 1,5 Go

L'entité hébergeant physiquement les données a-t-elle une politique de sécurité pour son système d'information ?
politique locale, charte des infrastructures de recherche...

N/A

Sécurité - Confidentialité : les données font-elles l'objet d'échange ou de partage avec de tiers acteurs et selon quelles modalités ? comment sont déterminés les droits d'accès aux données avant leur publication ?

Sécurité - Intégrité - Tracabilité : Quelles sont les mesures de protection mises en œuvre pour suivre la production et l'analyse des données ?

Sécurité

- Protection contre les virus et les intrusions géré par le pare-feu Defender

Archivage et conservation des données

Quelles sont les données à conserver sur le moyen ou le long terme et quelles sont les données à détruire ?

Le plateau ANAN est un plateau d'acquisition de données.

Dans le cadre de prestations de service, il n'a pas vocation à conserver les données produites sur le moyen/long terme. La durée choisie pour la mise à disposition des données est de trois années (après la clôture du projet (dernières données envoyées). Possibilité de déroger à cette règle si accord préalable avec l'utilisateur.

Pour les projets collaboratifs, les données sont stockées 3 ans après la date de fin de projets.

A plus long terme toutes les données sont détruites, la plateforme n'a pas vocation à faire de l'archivage de données. La conservation des données appartient à l'utilisateur.

Sur quelle plateforme d'archivage pérenne seront archivées les données à conserver sur le long terme ? Sinon, quelles procédures seront mises en place pour la conservation à long terme ?

Le plateau ANAN est un plateau d'acquisition de données.

il n'a pas vocation à conserver les données produites sur le moyen/long terme.

L'archivage des données appartient à l'utilisateur.

Quelle est la durée de conservation des données ?

Dans le cadre de prestations de service, il n'a pas vocation à conserver les données produites sur le moyen/long terme. La durée choisie pour la mise à disposition des données est de trois années (après la clôture du projet (dernières données envoyées). Possibilité de déroger à cette règle si accord préalable avec l'utilisateur.

Pour les projets collaboratifs, les données de séquençage sont stockées 3 ans après la date de fin de projets.

A plus long terme toutes les données sont détruites, la plateforme n'a pas vocation à faire de l'archivage de données. La conservation des données appartient à l'utilisateur.

Quelles garanties de financements couvriront les coûts associés à la conservation à long terme ?

Les structures porteuses de la SFR Quasav assurent le financement des serveurs.