

Intitulé du stage : Stage de Data engineering pour la surveillance en santé publique (SurSaUD)

Référence de l'offre : DATA-STA-2026-07

■ **Présentation de Santé publique France**

Santé publique France est l'Agence nationale de santé publique française. Etablissement public de l'Etat sous tutelle du ministre chargé de la santé créé par l'ordonnance 2016-246 du 15 avril 2016, elle intervient au service de la santé des populations.

Agence scientifique et d'expertise du champ sanitaire, elle a pour missions :

- 1° L'observation épidémiologique et la surveillance de l'état de santé des populations ;
- 2° La veille sur les risques sanitaires menaçant les populations ;
- 3° La promotion de la santé et la réduction des risques pour la santé ;
- 4° Le développement de la prévention et de l'éducation pour la santé ;
- 5° La préparation et la réponse aux menaces, alertes et crises sanitaires ;
- 6° Le lancement de l'alerte sanitaire.

L'Agence est organisée autour de quatre conseils (Conseil d'Administration, Conseil scientifique, Comité d'Ethique et de Déontologie et Comité d'orientation et de dialogue), de directions scientifiques et transversales, et de directions assurant le support et le soutien à l'activité. L'Agence dispose d'implantations régionales (Cellules régionales) auprès des agences régionales de la santé.

Son programme de travail, arrêté par son Conseil d'administration, s'articule autour de 6 enjeux : Anticipation, préparation et réponse aux menaces de santé publique, dont les épidémies ; Numérique en santé publique ; Santé environnementale, changement climatique et environnement de travail ; Fardeau des maladies et de leurs déterminants, efficacité des interventions et retour sur investissement de la prévention ; Stratégie de prévention, marketing social et approche par populations ; Inégalités sociales, vulnérabilités territoriales.

Son siège est situé à Saint-Maurice (94).

Localisation du stage :

☒ Saint-Maurice

☐ En région, indiquer la région, le département et la ville concernés :

■ **Le stage**

Contexte :

Description de la Direction : Le stage s'inscrit au sein de la Direction Appui, Traitements et Analyses des données (DATA) de Santé publique France, qui assure un appui transversal à l'ensemble de l'agence pour le traitement, l'analyse et la valorisation des données. Forte d'une cinquantaine d'agents, la direction est structurée en trois unités spécialisées (unité « Applications, big data et surveillance syndromique », unité « Appui et méthodes pour les études et investigations dans le domaine de la surveillance », unité « Enquêtes »). Elle intervient sur l'ensemble du cycle de vie des données de santé.

Ses missions couvrent notamment la gestion de données, l'analyse statistique, la géomatique, la métrologie, ainsi que le développement d'outils informatiques d'analyse et de visualisation. Elle pilote ou soutient plusieurs dispositifs structurants, notamment le système de surveillance syndromique SurSaUD, l'enquête Baromètre santé, le site open-DATA Odyssée ainsi que l'exploitation de bases médico-administratives comme le SNDS.

La direction DATA développe une expertise reconnue en modélisation spatio-temporelle, détection automatique de signaux, et intelligence artificielle. Soucieuse de renforcer la qualité scientifique de ses travaux, elle collabore activement avec des partenaires institutionnels et académiques, et accueille régulièrement stagiaires, interne, doctorants et chercheurs, dans une dynamique d'innovation continue au service de la surveillance en santé publique.

Description du projet : Le stage s'inscrit dans les travaux menés autour du système de surveillance syndromique SurSaUD, piloté par Santé publique France. Mis en place en 2004 à la suite de la canicule de 2003, ce dispositif permet de suivre en temps quasi réel l'état de santé de la population, en facilitant la détection précoce d'événements sanitaires, qu'ils soient attendus ou inhabituels. SurSaUD repose sur l'intégration quotidienne et automatisée de données individuelles et anonymisées issues de quatre sources complémentaires :

- Les passages aux urgences hospitalières (réseau OSCOUR),
- Les interventions des associations SOS Médecins,
- Les données de mortalité issues des bulletins d'état civil transmis à l'Insee,
- Les certificats électroniques de décès transmis à l'Inserm-CépiDC.

Ces données permettent de générer un volume important de séries temporelles, décrivant l'évolution d'indicateurs de santé à différentes échelles spatio-temporelles. Leur structuration et leur analyse représentent un enjeu stratégique pour renforcer les capacités de surveillance, de modélisation et d'alerte. Dans ce contexte, la Direction DATA a engagé un projet visant à construire une chaîne de traitement automatisée, fiable et évolutive, permettant de valoriser ces données au moyen de méthodes avancées d'analyse. Le stage proposé contribuera activement à ce projet.

Sujet de stage : Ce stage a pour objectif de contribuer à la mise en place d'une chaîne automatisée, à grande échelle, de traitement et de structuration des données issues du système SurSaUD, adaptée à l'analyse de séries temporelles multivariées en contexte de surveillance sanitaire (détection de signaux faibles, modélisation, prévision). Le ou la stagiaire participera à la fiabilisation, l'enrichissement et l'organisation d'un jeu de données massif, constitué de plusieurs centaines de milliers de séries temporelles, décrivant l'évolution d'indicateurs de santé selon différentes dimensions géographiques, temporelles, syndromiques et démographiques.

Missions du stage : Le stage portera notamment sur les missions suivantes :

- **Collecte et structuration des données :** mobiliser les différentes sources du système SurSaUD et leurs référentiels associés pour constituer un jeu de données cohérent et structuré.
- **Contrôle qualité :** mettre en place des procédures d'évaluation de la qualité des données incluant la détection et, si nécessaire, l'imputation des valeurs manquantes, l'identification des anomalies, ainsi que la définition d'indicateurs synthétiques de fiabilité.
- **Construction d'un référentiel de séries temporelles :** organiser les données en un corpus structuré selon plusieurs dimensions (géographiques, temporelles, syndromiques et démographiques), adapté aux analyses statistiques et exploratoires.
- **Extraction de descripteurs temporels :** compiler des indicateurs décrivant le comportement des séries (statistiques globales, saisonnalité, tendance, variabilité...) en vue d'une typologie des dynamiques observées.
- **Analyse exploratoire et classification non supervisée :** regrouper les séries selon leurs profils temporels afin d'identifier des tendances récurrentes ou atypiques et de mieux caractériser la diversité des comportements.
- **Enrichissement contextuel :** intégrer des données externes (caractéristiques sociodémographiques, calendrier scolaire, jours fériés, conditions météorologiques...) pour affiner l'analyse des séries et orienter les choix méthodologiques futurs (pré-sélection de variables explicatives).
- **Constitution d'un jeu de données de référence annoté :** participer à l'élaboration d'un corpus structuré et documenté, destiné à l'évaluation comparative de méthodes de détection de signaux et de prévision.
- **Documentation des traitements :** produire une documentation technique complète (guides, scripts, structuration des jeux de données) et mettre en œuvre des pratiques garantissant la reproductibilité et la généralisation des travaux à d'autres sources de données (versioning, modularité des scripts).
- **Automatisation des traitements :** concevoir et implémenter une chaîne de traitement automatisée, garantissant la traçabilité, l'horodatage et la reproductibilité des processus.
- **Optimisation des performances :** adapter les traitements aux infrastructures de calcul haute performance de Santé publique France, en tenant compte des contraintes liées aux volumes importants de données manipulées.

Environnement de travail : Le stage s'intègre dans un environnement technique dynamique et collaboratif, mobilisant des outils de développement modernes, des langages adaptés à la science des données, et des infrastructures de calcul performantes. Le-la stagiaire évoluera au sein d'une équipe pluridisciplinaire, en interaction étroite avec des épidémiologistes, data scientists, statisticiens, ingénieurs et membres de la DSI ainsi que le RSSI.

Les principaux outils et technologies mobilisés incluent :

- Langages : Python
- Environnement collaboratif : GitLab (versioning, intégration continue, gestion des issues)

- Automatisation et orchestration : Apache Airflow (déploiement, supervision des workflows), Docker
- Formats et bases de données : PostgreSQL, fichiers Parquet, CSV
- Environnements de développement : VS Code, IA Mistral
- Traitement intensif : Apache Spark, via les serveurs de calcul internes de Santé publique France

Profil recherché : Nous recherchons un·e stagiaire de niveau Master 2, idéalement en informatique, data science, statistique, mathématiques appliquées ou disciplines connexes. Le·la candidat·e doit avoir une bonne connaissance du langage Python et avoir des connaissances en développement logiciel, notamment sur les bonnes pratiques telles que les tests unitaires, le versionning et l'intégration continue. Une expérience avec des outils comme GitLab, Airflow ou PostgreSQL serait un plus.

Le·la candidat·e devra faire preuve de bonnes capacités d'analyse, d'adaptation et d'organisation, ainsi que d'un réel esprit d'équipe pour évoluer au sein d'un environnement pluridisciplinaire. Ce stage offre l'opportunité de participer à des projets techniques innovants, au service de la surveillance de la santé publique, en étroite collaboration avec des experts en épidémiologie, data science et ingénierie, dans un cadre de travail stimulant, bienveillant et collaboratif.

Description : Pour tout renseignement complémentaire, consulter le portail sur le site <http://www.santepubliquefrance.fr>

▪ Type de stage proposé

- ☐ Licence
- ☐ Master 1 ☐ Master 1 + sujet tutoré ☐ Master 1 « observation »
- ☒ Master 2 Professionnel ☐ Master 2 Recherche

Gratification du stage : selon la réglementation en vigueur dans les établissements publics

▪ Date proposée pour le stage et durée :

- ☒ Sans contrainte de date
- ☐ A partir de : (indiquer une date)
- Durée minimum : 6 mois
- Extension possible au-delà de la période obligatoire ☒ Oui ☐ Non

▪ Prérequis :

- ☐ Aucun
- ☒ Compétences spécifiques (préciser) : Connaissance de l'ingénierie de données et du langage Python
- ☒ Maîtrise d'un logiciel spécifique (préciser) : Langage Python
- ☒ Autre (préciser) : Connaissance sur les outils de versionning de code tels que Git/GitHub/GitLab

▪ Stage proposé par :

Direction : DATA

Unité : ABISS

Maître(s) de stage / personne contact :

Nom : HANF

Prénom : MATTHIEU

Fonction : Directeur DATA

Téléphone : 01 71 80 16 86

Adresse email : matthieu.hanf@santepubliquefrance.fr

Co-encadrement

Nom : FOUILLET

Prénom : Anne

Fonction : Coordinatrice SURSAUD

Téléphone :

Adresse email : anne.fouillet@santepubliquefrance.fr

Co-encadrement

Nom : PELAT

Prénom : Camille

Fonction : Data Scientist Senior

Téléphone : 01 41 79 57 38

Adresse email : camille.pelat@santepubliquefrance.fr

- **Pour postuler**

Adresser les candidatures (lettre de motivation + cv) en indiquant la référence de l'annonce par courriel : recrut@santepubliquefrance.fr