



HAL
open science

Le SARS-CoV-2 : une expérience inédite de surveillance génomique mondiale

Hélène Touzet, Mikaël Salson, Claire Lemaitre, Florence Débarre

► To cite this version:

Hélène Touzet, Mikaël Salson, Claire Lemaitre, Florence Débarre. Le SARS-CoV-2 : une expérience inédite de surveillance génomique mondiale. 2023. hal-04155812

HAL Id: hal-04155812

<https://inria.hal.science/hal-04155812v1>

Submitted on 7 Jul 2023

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.



Distributed under a Creative Commons Attribution 4.0 International License

Le SARS-CoV-2 : une expérience inédite de surveillance génomique mondiale

Hélène Touzet¹, Mikaël Salson¹, Claire Lemaitre², Florence Débarre³

¹ Univ. Lille, CNRS, Centrale Lille, UMR 9189 - CRISTAL, Lille F-59000, France

² Univ Rennes, Inria, CNRS, IRISA, Rennes F-35000, France

³ Institut d'écologie et des sciences de l'environnement de Paris (iEES-Paris, UMR 7618), CNRS, Sorbonne Université, UPEC, IRD, INRAE, Paris, France

Depuis le début de la pandémie de SARS-CoV-2, la surveillance de l'évolution du génome du virus avec son *séquençage en continu* est devenue un élément clé de santé publique. En effet, le génome d'un virus est par nature très dynamique, avec une évolution qui se manifeste par l'accumulation rapide de mutations. Disposer au fil du temps de nombreux génomes d'origines géographiques variées est donc nécessaire pour identifier l'émergence de *variants*, des lignées porteuses de mutations-clés susceptibles d'affecter la pathogénicité et la transmissibilité du virus, voire de mener à un échappement vaccinal. Ce type de surveillance a pu être expérimenté ces dernières années avec la grippe saisonnière, les virus Ebola ou Zika, et a atteint une ampleur inédite avec le suivi du SARS-CoV-2. Une telle tâche requiert des moyens de génération, d'analyse bioinformatique et de partage des données particulièrement optimisés et ambitieux. Comment cela se passe-t-il ?

Séquençage à grande échelle. En janvier 2020, la découverte des premiers génomes du SARS-CoV-2 à Wuhan avait nécessité des techniques de séquençage et d'analyse bioinformatique assez complexes (voir "[Comment la bioinformatique a résolu le puzzle du génome du SARS-CoV-2](#)"). Il avait fallu réaliser le séquençage de l'ensemble du contenu en ARN d'échantillons pulmonaires des patients, même si la fraction virale contenue dans ces prélèvements est extrêmement faible. Ce type de séquençage produit de grandes quantités de données de séquences et nécessite ensuite la mise en œuvre d'analyses bioinformatiques sophistiquées. Tout cela est peu compatible avec un suivi routinier de l'épidémie. Aujourd'hui, maintenant que le génome de référence est connu, il est possible à la fois de réduire les coûts de séquençage en ciblant exclusivement les séquences d'intérêt désormais connues dans l'échantillon, et d'accélérer les traitements bioinformatiques d'assemblage et d'analyse des nouveaux génomes.

Dans le cas du SARS-CoV-2, la stratégie la plus utilisée pour cibler le génome viral est le *séquençage par amplicons*. Dans ce protocole, le matériel génétique du virus présent dans l'échantillon biologique est d'abord amplifié par PCR, puis les fragments d'ADN issus de l'amplification (les amplicons) sont séquencés. La PCR (réaction en chaîne par polymérase) est une technique moléculaire largement utilisée en biologie qui repose notamment sur une première étape bioinformatique cruciale : la conception d'*amorces*, des petites séquences bien choisies sur le génome cible (voir Encadré 1).

Une fois tous les amplicons séquencés, l'assemblage du génome viral est également facilité par l'utilisation de la séquence génomique déjà connue de SARS-CoV-2, qui sert de modèle. L'assemblage *de novo* (voir "[Comment la bioinformatique a résolu le puzzle du génome du SARS-CoV-2](#)") n'est plus nécessaire, et les lectures sont simplement alignées sur le génome de référence. L'alignement d'une lecture sur le génome de référence consiste à la positionner sur ce génome, c'est-à-dire identifier la portion du génome qui présente le plus de similarité avec la lecture, et à lister les caractères identiques et différents entre ces deux séquences.

Une fois toutes les lectures alignées, une séquence consensus peut alors être calculée en sélectionnant, à chaque position, le caractère observé dans la majorité des lectures alignées à la position donnée. Les variations de séquences, telles que les mutations, sont ensuite identifiées entre la souche virale nouvellement séquencée et le génome de référence ou entre différentes souches coexistant dans l'échantillon. La Figure 1 montre les mutations qui ont été identifiées dans le gène de la protéine S dans différentes lignées du SARS-CoV-2.




Figure 1 : prévalence des mutations identifiées dans le gène de la protéine S (positions sur le gène en abscisse) dans les différentes lignées de SARS-CoV-2 (en ordonnée, BA.1, BA.2 et BA.5 sont des sous-variants d'Omicron). Le dégradé de couleur indique la proportion des génomes de la lignée dans lesquels la mutation a été observée (une case est grisée quand la mutation n'a encore jamais été détectée dans la lignée ; la couleur blanc indique que la mutation a été observée dans très peu de génomes de la lignée, la couleur violet foncée indique que la mutation a été observée dans 100% des génomes de la lignée). Figure générée par le site outbreak.info qui utilise les données de la base de données GISAID : <https://outbreak.info/compare-lineages?gene=S&threshold=75>

L'organisation et le partage des informations. En juin 2021, un an et demi après la publication du premier génome de Wuhan, plus de 2 millions de génomes de SARS-CoV-2 ont été séquencés, assemblés et partagés par divers laboratoires et institutions de pays du monde entier. Ce vaste effort de séquençage permet de comprendre comment le virus évolue, de suivre les mutations en temps réel et d'identifier de nouveaux variants. Un aspect important de cette recherche est que plusieurs initiatives nationales et internationales ont rapidement développé des portails web dédiés afin de stocker ces informations et de les rendre librement disponibles sur Internet. Les dépôts de séquences généralistes tels que Genbank, hébergé par le NCBI (Etats-Unis), ou l'ENA, hébergé par l'European Bioinformatics Institute, qui organisent le partage des données de séquences du domaine public depuis plusieurs décennies, ont développé des bases de données et des outils spécifiques pour les données du SARS-CoV-2. Le Consortium GISAID fournit également une ressource essentielle pour les génomes de SARS-CoV-2 (ressource disponible sur inscription). La base de données GISAID comptait 339 génomes du SARS-CoV-2 disponibles à la fin du mois de janvier 2020, et ce nombre a augmenté rapidement, atteignant environ 80 000 en août 2020, 1 million début avril 2021, puis plus de 4 millions six mois plus tard et plus de 14 millions en novembre 2022 (voir

Figure 2). Lorsque l'activité épidémique est importante, 1 million de séquences peuvent être ajoutées en un seul mois.

Ce sont les scientifiques qui soumettent librement des données de séquence à de telles collections. Ces séquences sont vérifiées avant d'être partagées publiquement. Les séquences génomiques disponibles sont également parfois accompagnées d'informations supplémentaires, telles que l'origine géographique et la date de collecte de l'échantillon, les protocoles de séquençage, les informations cliniques du patient, etc. Ces métadonnées sont structurées dans des bases de données pour permettre des requêtes efficaces et des analyses comparatives en aval à partir de cette énorme collection de séquences.




Figure 2 : Évolution du nombre de génomes de SARS-CoV-2 déposés dans la base de données GISAID entre janvier 2020 et novembre 2022 au niveau mondial (en gris), par le Royaume Uni (en jaune) et par la France (en bleu). Figure produite à partir des statistiques fournies par GISAID.

Toutes ces informations (génomes et métadonnées) sont utilisées pour suivre la diversité de la population de SARS-CoV-2 dans le monde. Mais ces données servent également à détecter de manière précoce des variants préoccupants. Alerté par la reprise du nombre d'infections dans le Sud-Est de l'Angleterre à l'automne 2020, le Royaume-Uni a pu expliquer ce phénomène par la propagation d'un nouveau variant, de la lignée B.1.1.7, et suivre la propagation de ce qui a ensuite été appelé le *variant Alpha*. En étudiant rétrospectivement les données de séquençage, on a pu constater que ce variant avait été initialement détecté en septembre 2020. De même, à la fin du printemps 2021, le Royaume-Uni a pu associer une nouvelle reprise épidémique sur son territoire à la propagation du *variant Delta*, initialement détecté en Inde. De manière similaire, l'Afrique du Sud, qui dispose de moyens importants de séquençage et d'analyse bioinformatique pour le suivi de l'épidémie, a détecté le *variant Omicron* à l'automne 2021 (voir par exemple : <https://www.nature.com/articles/d41587-022-00003-3>). Ces découvertes ont été facilitées par une politique volontariste de surveillance

génomique, que [l'Organisation mondiale de la Santé recommande](#) afin de détecter au plus tôt l'émergence de variants préoccupants. À ce titre, le Royaume-Uni figure parmi les pionniers. En 2020, plus de 140 000 génomes avaient été publiés via le consortium COG-UK, contre moins de 3 000 en France, qui n'avait alors pas encore de consortium en place. Un tel consortium a depuis été mis en place en France à partir du début de l'année 2021 et a publié plus de 170 000 séquences cette année-là. L'Institut Français de Bioinformatique (IFB) apporte un soutien technique avec notamment la mise en place et la gestion d'une base de données sécurisée. Le Royaume-Uni a publié 1,5 million de séquences en 2021 (voir Figure 2).

En l'état actuel des connaissances, un génome n'est cependant toujours pas suffisant pour caractériser un phénotype, et il reste indispensable de coupler les jeux de séquences génomiques avec d'autres types de données (nombres de cas, statut vaccinal des patients, informations sur la sévérité de l'infection, une éventuelle hospitalisation, etc.). Toutes ces questions sont au cœur de l'*épidémiologie génomique*, discipline récente rendue possible par les progrès du séquençage et de la bioinformatique. La pandémie de SARS-CoV-2 montre toute l'importance d'une politique de science ouverte ambitieuse et volontaire, avec le stockage, la structuration et le partage des données.

Encadré 1 : Bioinformatique pour la conception d'amorces PCR

La PCR (réaction en chaîne par polymérase) est une technique moléculaire très utilisée qui permet de générer rapidement un nombre élevé de copies d'un brin d'ADN ou d'ARN spécifique, dont la longueur peut atteindre quelques centaines de nucléotides. La PCR a de multiples applications. Pour SARS-CoV-2, la PCR est utilisée à la fois pour les tests de dépistage, le criblage de variants connus et pour le séquençage ciblé du génome (Figure 3 A).

Le principe général de la PCR consiste à amplifier de manière répétée un matériel génétique spécifique. Elle n'amplifie pas la séquence entière, mais seulement une région d'intérêt. Pour cela, une PCR est basée sur deux courtes séquences d'ADN, appelées amorces, délimitant la région à amplifier. Ces amorces, d'une vingtaine de nucléotides, sont complémentaires du génome cible et doivent être spécifiques de la séquence d'intérêt afin que seule celle-ci soit amplifiée. Ainsi, le premier défi consiste à concevoir des amorces PCR appropriées pour cibler la région souhaitée du génome du SARS-CoV-2 sans cibler par inadvertance d'autres régions, ou même d'autres agents pathogènes ou gènes humains présents dans un échantillon donné. Pour ce faire, il faut comparer les amorces potentielles avec les séquences des agents pathogènes et des génomes humains connus afin de s'assurer qu'il n'y a ni hybridation croisée ni similarité avec un autre organisme. Un autre défi consiste à concevoir des amorces robustes qui peuvent se fixer solidement au brin du génome. L'affinité dépend de la composition, de la structure et de la dynamique de la séquence de l'amorce. Après toutes ces étapes *in silico*, les amorces doivent être évaluées sur des échantillons réels montrant l'efficacité des tests d'amplification *in vitro*.

Dans le cas du séquençage ciblé du génome complet du SARS-CoV-2 par amplicons, il ne s'agit pas de concevoir une paire d'amorces mais toute une série de paires d'amorces dans

l'objectif de tuiler, ou de recouvrir, le génome du SARS-CoV-2 par de courtes régions entourées de paires d'amorces. Il s'agit d'un beau problème combinatoire : trouver un ensemble de paires d'amorces dans le génome de référence de telle sorte que 1) celles-ci couvrent l'ensemble du génome, 2) qu'elles soient spécifiques au génome et 3) qu'elles conviennent à l'amplification par PCR. Par exemple, il est possible de tuiler le génome de SARS-CoV-2 avec environ 140 segments PCR, chacun de longueur 400 nucléotides.

Enfin, la conception d'amorces PCR a également été utilisée pour le criblage rapide et peu coûteux de certaines formes du SARS-CoV-2. Des amorces PCR ont été conçues pour amplifier des régions spécifiques du génome viral dans lesquelles des mutations d'intérêt ont déjà été identifiées. Le succès ou non de l'hybridation des produits de PCR à des séquences spécifiques des mutations ciblées permet de déterminer la présence ou l'absence de ces mutations dans l'échantillon. Ces tests PCR dits de criblage, couplés aux tests de diagnostic, permettent de systématiser la recherche de variants connus et répertoriés et de suivre leur abondance dans l'ensemble d'une population au cours du temps. Ils sont plus économiques que le séquençage complet, mais ne concernent que quelques mutations possibles (Figure 3B). Le séquençage reste indispensable pour caractériser toutes les mutations portées par un variant, d'où l'importance de mettre en place ou maintenir une surveillance génomique de qualité partout dans le monde.




Figure 3 : A) Principe de la PCR pour amplifier une séquence d'intérêt avec des paires d'amorces. Le résultat de l'amplification PCR peut être quantifié (pour les tests diagnostics ou le criblage de variants) ou séquencé (pour du séquençage ciblé). B) Impact des mutations sur l'amplification de la PCR en fonction de leur localisation par rapport aux sites des amorces.

Ressources sur le web :

- Centre européen de prévention et de contrôle des maladies, et plus particulièrement des données sur le dépistage du COVID-19 par semaine et par pays : <https://www.ecdc.europa.eu/en/publications-data/covid-19-testing>

- GISAID, <https://www.gisaid.org>, a été créé en 2008 pour assurer le partage rapide des données issues des épidémies de grippe et constitue désormais une ressource clé pour les génomes du SARS-CoV-2. Elle comprend des séquences génétiques et des données cliniques et épidémiologiques associées aux virus humains, ainsi que des données géographiques et spécifiques aux espèces associées aux virus aviaires et à d'autres virus animaux, afin d'aider les chercheurs à comprendre comment les virus évoluent et se propagent pendant les épidémies et les pandémies.
- Portail du NCBI dédié au COVID : <https://www.ncbi.nlm.nih.gov/sars-cov-2>
- Portail de l'EBI dédié au COVID : <https://www.covid19dataportal.org>
- Sites d'exploration des données déposées sur GISAID : <https://outbreak.info> , <https://covariants.org> , <https://cov-spectrum.ethz.ch>