

ANALYSE EXPLORATOIRE SPATIALE DES EFFETS SANITAIRES ET ÉCONOMIQUES DE LA COVID-19 À PARTIR DE DONNÉES MONDIALES

Exploratory spatial analysis of the health and economic effects of COVID-19 using global data

Idrissa Yaya DIANDY¹

Université Cheikh Anta Diop de Dakar, Sénégal
Faculté des Sciences Économiques et de Gestion
Département d'Analyse et Politique Économiques
idrissa.diandy@ucad.edu.sn
<https://orcid.org/0000-0001-8518-7916>

Abstract

Purpose : This article analyses the health and economic effects of the COVID-19 pandemic.

Design/methodology/approach : The sample includes 132 countries, and the methodology is based on Exploratory Spatial Data Analysis. The calculation of the output gap by the Hodrick-Prescott filter allows to highlight the economic impact of the health crisis, through the output gaps in 2020. The health variable, for its part, is measured by the incidence rates of COVID-19.

Findings : The results of the estimations validated the hypothesis of spatial autocorrelation for both the health and economic variables. Examination of the Moran scatter plot confirms the positive local spatial association pattern, i.e. the existence of similarities between neighbouring countries in the manifestation of the pandemic and spatial heterogeneity between groups of countries. More specifically, the results show the existence of clusters with low levels of COVID-19 incidence in Africa and Asia, compared with Europe and North America. In addition, while high-income countries were generally more affected in terms of health, they developed greater economic resilience.

Originality/value : These results show that taking space into account could provide a better understanding of the dynamics of health and economic shocks.

Keywords: growth, output gap, COVID-19, spatial autocorrelation.

¹ BP 5005, Dakar-Fann, Sénégal.

Résumé

L'objectif : L'objectif de cet article est d'analyser les effets sanitaires et économiques de la pandémie de COVID-19.

Conception/méthodologie/approche : L'échantillon est composé de 132 pays et la méthodologie se fonde sur l'analyse exploratoire des données spatiales. Le calcul de l'output gap par la méthode de Hodrick-Prescott a permis de ressortir les conséquences économiques de la crise sanitaire, à travers les écarts de production pour l'année 2020. La variable sanitaire, quant à elle, est mesurée par le taux d'incidence de la COVID-19 et la mortalité.

Résultats : Les résultats des estimations ont permis de valider l'hypothèse d'autocorrélation spatiale aussi bien pour la variable sanitaire que pour la variable économique. L'examen du diagramme de Moran confirme le schéma d'association spatiale local positif, c'est-à-dire l'existence à la fois de similitudes entre pays voisins dans la manifestation de la pandémie et d'hétérogénéité spatiale entre les groupes de pays. De manière plus précise, les résultats montrent l'existence de clusters avec de faibles niveaux d'incidence de la COVID-19 en Afrique et en Asie, comparativement à l'Europe et à l'Amérique du Nord. De plus, si les pays à revenu élevé ont généralement été davantage touchés sur le plan sanitaire, ils ont toutefois développé une plus grande résilience économique.

Originalité/valeur : Ces résultats montrent que la prise en compte de l'espace pourrait permettre de mieux comprendre la dynamique des chocs sanitaires et économiques.

Mots-clés : croissance, écart de production, COVID-19, autocorrélation spatiale.

JEL classification : C21, E32, O49.

Introduction

Le nouveau coronavirus (COVID-19), apparu en Chine à la fin de l'année 2019, a marqué durablement la fin de la décennie. En effet, la pandémie a eu des effets sanitaires et économiques dévastateurs à l'échelle mondiale en 2020, et ses effets se feront sentir probablement au-delà (Maisonnavé & Cabral, 2021). De plus, la maladie a connu une propagation rapide, ce qui fait qu'elle a frappé la quasi-totalité des régions du monde et de manière presque synchrone. À l'échelle mondiale, au total 522 783 196 cas confirmés de COVID-19 ont été répertoriés, dont 6 276 210 décès (OMS, 2022). De même, les effets économiques consécutifs aux mesures de confinement et à l'arrêt de travail ont été tout aussi chaotiques, rappelant la crise de 2008. Avec la mise en place de mesures de confinement pour lutter contre la COVID-19, on a assisté à un ralentissement mondial de l'activité économique et à une perte d'emploi massive, surtout chez les emplois peu qualifiés (Azcona et al., 2020). Le monde a connu une récession de 3,3% (après une croissance de 2,6% en 2019) alors qu'elle n'était que de 1,3% en 2009.

L'impact économique durable de la pandémie de coronavirus se manifeste dans l'évolution des facteurs de production macroéconomiques (Grömling, 2021) et notamment en termes de perte de capacité de production (Coutiño & Zandi, 2021). Goel et al. (2021), en se fondant sur des données de 130, ont conclu que la pandémie a des effets sur la logistique de la chaîne d'approvisionnement et sur la croissance économique. Toutefois, ils constatent que cet effet sur la croissance varie selon les pays. Pour Merow et Urban (2020) et Carleton et al. (2020), la manifestation de la COVID-19 pourrait être liée à des variables spatiales comme la température, l'humidité et la lumière ultraviolette, suggérant ainsi que la position géographique pourrait influencer sur la manifestation spatiale de la maladie.

Malgré la reconnaissance de l'importance de la géographie sur les pandémies, particulièrement mise en évidence par les défis posés par les crises du coronavirus, sa prise en compte dans les analyses économiques est moins répandue. Pourtant, les manifestations sanitaires et économiques de la pandémie peuvent révéler des spécificités selon la localisation géographique. En réalité, les phénomènes (économiques, sociaux, environnementaux, etc.) sont rarement distribués de façon aléatoire dans l'espace. En particulier, les phénomènes de santé comportent bien souvent des facteurs de risques liés à la géographie, à l'environnement, aux relations spatiales entre les individus. Si le vocabulaire de l'analyse spatiale est relativement nouveau en économie, elle est présente depuis longtemps dans d'autres disciplines. Historiquement, le concept d'analyse spatiale est lié à la relation entre la géographie et l'étude des épidémies, qui remonte au moins de l'Antiquité avec des études d'Hippocrate (480 av. J.-C.) mettant en rapport les lieux et l'apparition des maladies. C'est seulement à la fin du XVIIIe siècle que la connaissance géographique sera établie en tant que discipline scientifique et systématique.

L'essor des méthodes spatiales est favorisé par le développement des systèmes d'information géographique qui permettent de disposer simultanément des valeurs prises par les variables d'intérêt et de leur localisation géographique (données spatiales ou géoréférencées). À ce titre, la dépendance (ou autocorrélation) spatiale constitue le concept clé dans toute démarche spatiale. Dans le contexte épidémique, elle suggère qu'il existerait une similitude entre pays ou régions géographiquement proches dans l'apparition ou la manifestation d'une maladie, ou encore de ses conséquences économiques. Utiliser la localisation est donc fondamental dans l'analyse et la compréhension des phénomènes socioéconomiques et de leurs mécanismes. De plus, la plupart des études sur les effets sanitaires et économiques de la COVID-19 ont adopté une approche a-spatiale (Maisonnavé & Cabral, 2021), bien que leur caractère spatial soit souvent postulé.

L'objet de cet article est d'analyser le rôle de l'espace dans la manifestation et les conséquences économiques de la pandémie de COVID-19, à travers une analyse exploratoire spatiale. Le reste de l'article est constitué comme suit : la section 1 revient sur les faits stylisés en relation avec l'évolution de la pandémie ; la section 2

expose les éléments de littérature ; la section 3 décrit la méthodologie de l'analyse exploratoire spatiale et la section 4 donne les résultats de l'analyse.

1. Diffusion spatiale de la COVID-19 et ses conséquences sur l'économie mondiale

La pandémie de la COVID-19 est un phénomène mondial, de grande amplitude. Étant donné son rythme élevé de propagation, ce virus a mis à mal les systèmes de santé les plus performants des pays développés d'Asie orientale, d'Europe et d'Amérique du Nord qui ont, tour à tour, été les principaux foyers de diffusion (OIT, 2020). Le continent africain semble avoir été relativement moins touché, si l'on se fie aux données du tableau 1, qui montre la distribution du nombre de cas pour 1 million d'habitants. Il montre que l'Europe, l'Amérique (Nord et Latine) ainsi que certains pays d'Asie paraissent être les régions les plus durement touchées, alors que l'Afrique et l'Asie du Sud-Ouest semblent être relativement épargnées. Et même au sein d'une même région, on peut percevoir des disparités spatiales : des pays de l'Europe de l'Est (Pologne, Roumanie, etc.) semblent moins impactés que ceux de l'Ouest (Belgique, France, Portugal, etc.).

Tableau 1. Taux d'incidence de la COVID-19 par région en 2022 (nombre de cas pour 1 million d'habitants)

Afrique		Asie		Europe		Amérique	
Algérie	5 863	Afghanistan	4 429	Autriche	465 240	Argentine	198 692
Botswana	125 606	Hong Kong	159 045	Belgique	353 822	Bolivie	75 772
Cameroun	4 310	Inde	30 691	Danemark	510 963	Brésil	142 945
Côte d'Ivoire	2 972	Indonésie	21 697	France	447 922	Canada	100 272
Éthiopie	3 918	Iran	84 055	Allemagne	309 595	Chili	187 763
Ghana	4 996	Israël	442 184	Grèce	331 382	Haïti	2 636
Kenya	5 790	Malaisie	135 496	Italie	286 222	Mexique	43750
Lesotho	15 136	Philippines	32 842	Pologne	159 011	États-Unis	254 119
Maroc	30 919	Thaïlande	62963	Portugal	401 025	Uruguay	258 133
Sénégal	4 898			Roumanie	152 995		

Source : basé sur les données de (OMS, 2022).

Le tableau 1 semble indiquer l'existence d'une certaine régionalisation de la pandémie. Ce constat est renforcé par les statistiques sur la mortalité. La démographie de régions comme l'Afrique, dont 3% seulement de la population sont âgés de plus de 65 ans, pourrait expliquer les taux de mortalité faibles comparés à d'autres régions comme l'Europe, dont 20% des habitants ont plus de 65 ans (Fonds Mondial, 2020).

En plus de ces conséquences sanitaires, la COVID-19 a également fortement impacté l'ensemble des échanges commerciaux et financiers internationaux et provoqué une forte contraction de l'activité économique au niveau mondial (OIT, 2020). Ainsi, en 2020, la plupart des régions du monde ont connu une contraction de leur activité.

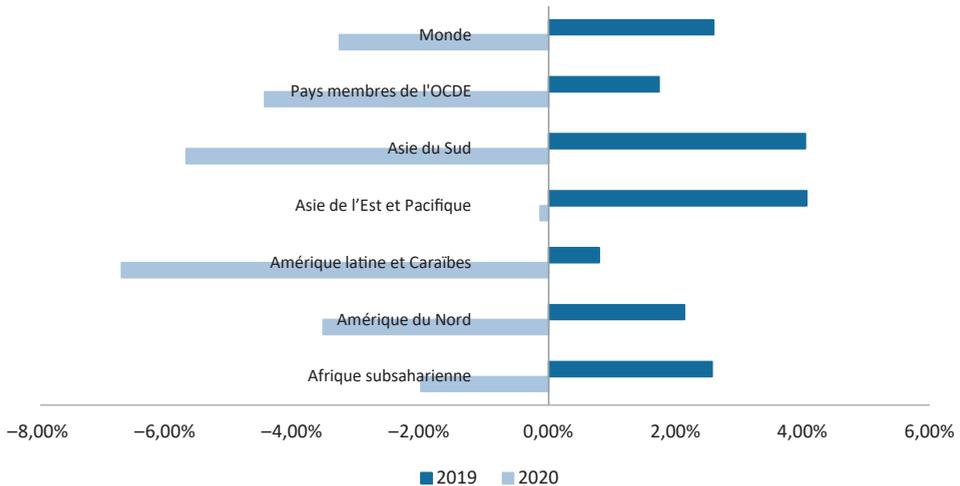


Figure 1. Taux de croissance en 2019 et en 2020

Source : basée sur les données de la Banque mondiale WDI.

La figure 1 montre que les pays d'Amérique latine semblent être les plus touchés par la crise économique, avec une récession de 6,72% en 2020. Il en est de même pour les pays membres de l'OCDE. L'Afrique subsaharienne et l'Asie de l'Est apparaissent comme les régions les moins touchées, avec des taux de croissance respectivement de -2,1% et -0,13%.

2. Fondements théoriques de la dépendance spatiale

L'analyse et la compréhension des phénomènes spatiaux ont comme point de départ le concept de la dépendance spatiale. Cliff et Ord (1973) ont proposé la première analyse formelle traitant de l'autocorrélation spatiale, qui sera complétée plus tard par une deuxième édition (Cliff & Ord, 1981). Par la suite, dans la même période, plusieurs travaux (Cliff et al., 1975 ; Getis & Boots, 1978 ; Haggett et al., 1977 ; Ripley, 1981 ; Upton & Fingleton, 1985) vont ériger les fondements de l'analyse de l'autocorrélation spatiale.

Si elle n'est apparue que récemment en sciences économiques, la dépendance spatiale se retrouve depuis longtemps dans d'autres disciplines. En effet, si cette méthode s'applique à de nombreux domaines, son usage à l'origine se limitait toutefois à la géographie et à l'épidémiologie, notamment à l'étude de la distribution spatiale des maladies.

L'autocorrélation (ou dépendance) spatiale part du constat suivant lequel les observations spatialisées en coupes transversales ne sont pas indépendantes (Le Gallo, 2002). L'existence d'une certaine dépendance dans l'espace est suggérée par la première loi de la géographie de Tobler (1979) qui stipule que tous les objets sont en relation, mais ceux qui sont plus proches le sont davantage. Cette « loi » définit le concept statistique de l'autocorrélation spatiale, selon lequel deux ou plusieurs entités géographiquement proches ont tendance à présenter plus de similitudes – par rapport à un attribut donné – qu'avec d'autres géographiquement plus éloignées (Pisati, 2012).

Ainsi, l'autocorrélation spatiale peut être interprétée d'une part comme la mesure de la façon dont les choses sont réparties dans l'espace. Dans ce cas, elle se rapporte au degré de similitude entre un objet ou une activité localisée et un autre objet ou activité relativement proche ; cela veut dire que pour un indice de dépendance spatiale, deux variables sont d'autant plus corrélées que la distance qui les sépare est petite.

L'autocorrélation spatiale peut aussi être interprétée d'autre part comme un processus de cause à effet, qui mesure le degré d'influence exercé par un territoire sur ses voisins. Elle indique alors comment la valeur attendue d'une entité est affectée par les caractéristiques d'entités situées dans d'autres zones géographiques relativement proches. Ainsi présentée, l'autocorrélation spatiale traduit l'absence d'indépendance entre les observations géographiques et permet de saisir, dans le contexte des pandémies, les effets de contagion.

D'après Goodchild (1986), l'importance de la mesure de l'autocorrélation spatiale peut être appréciée à deux niveaux. D'un côté, en tant qu'indice, il propose un nouveau type d'information sur un phénomène réparti dans l'espace, qui n'existait pas au niveau de l'analyse statistique « standard », et qui peut être déterminant pour corriger l'interprétation faite sur l'évolution du phénomène. D'autre part, en tant que mesure du processus par lequel un lieu influence un autre, l'analyse de l'autocorrélation spatiale est souvent une étape nécessaire pour effectuer des prévisions correctes. Ainsi, Goodchild (1986) illustre son analyse avec l'exemple suivant : l'incidence d'une maladie infectieuse comme la grippe dans une région est mieux prédite non pas par les mesures antérieures ou les caractéristiques de la région, mais plutôt par la connaissance de l'incidence de la grippe dans les régions voisines d'où elle est susceptible de se propager (Goodchild, 1986).

Sur le plan empirique, un certain nombre d'études ont utilisé l'analyse spatiale pour examiner l'effet des pandémies. Pour ce qui concerne la COVID-19, Xie et

al. (2021) ont procédé à une revue des recherches sur les facteurs influençant la propagation spatiale du COVID-19 du point de vue du contenu et de la méthode de recherche. Ils trouvent que de plus en plus, le modèle à décalage spatial, le modèle d'erreur spatiale et le modèle de régression géographiquement pondéré sont largement utilisés. De plus, l'impact de l'environnement naturel et des facteurs économiques et sociaux sur la propagation de l'épidémie se reflète principalement dans la température, l'humidité, la vitesse du vent, les polluants atmosphériques, les mouvements de population, le niveau de développement économique et les installations médicales et aussi sanitaires.

Naumov et al. (2021) se proposent d'évaluer l'hétérogénéité spatiale de la propagation de l'infection par le coronavirus, et de simuler les effets de l'aggravation de la situation épidémiologique sur la dynamique du développement économique des systèmes régionaux. La particularité de l'approche développée est le regroupement spatial des systèmes régionaux en fonction du niveau d'incidence du COVID-19, réalisé à l'aide d'indices d'autocorrélation spatiale globaux et locaux. L'étude a révélé un groupe spatial caractérisé par des niveaux élevés d'infection, avec une forte zone d'influence et des similitudes interrégionales avec les régions environnantes. Une analyse de régression utilisant des données de panel a aussi confirmé l'impact de l'incidence de la COVID-19 sur le nombre moyen d'employés dans les entreprises et sur le niveau des salaires.

3. Méthodologie de l'Analyse Exploratoire des Données Spatiales (AEDS)

Les données spatiales, tout comme les séries temporelles, sont caractérisées par la dépendance et l'hétérogénéité. La dépendance spatiale est observée lorsqu'une variable est influencée par les valeurs de son environnement immédiat. L'instabilité dans l'espace des relations économiques est appelée hétérogénéité spatiale : les comportements et les phénomènes économiques ne sont pas les mêmes selon la localisation géographique (Le Gallo, 2002).

L'analyse exploratoire des données spatiales (AEDS) est une extension de l'analyse exploratoire des données (AED) au problème de détection des schémas de données spatiales (Haining et al., 1998). Contrairement aux analyses statistiques conventionnelles, l'analyse spatiale traite de deux types d'informations distincts : d'une part les attributs des éléments (le revenu, l'incidence d'une maladie, la religion ou le type de sol) ; et d'autre part, chaque élément bénéficie d'une géolocalisation qui peut être donnée par sa position sur une carte ou par diverses références géographiques ou un ensemble de coordonnées. L'AEDS consiste à rechercher les bonnes descriptions des données spatiales, afin d'aider à développer des hypothèses et modèles mieux adaptés à ce genre de données (Bailey & Gatrell, 1995).

3.1. Mesure du degré de proximité : La matrice de pondération spatiale

La modélisation des interactions spatiales nécessite de spécifier le niveau de connectivité entre les éléments en jeu (districts, villes, régions, pays, etc.). Le degré de proximité spatial entre N objets géographiquement localisés est obtenu généralement grâce à la représentation d'une matrice carrée appelée matrice de poids ou encore matrice de pondération spatiale, notée W . Chaque élément (i, j) de W ou coefficient de pondération (noté w_{ij}) mesure le degré de proximité spatiale entre deux éléments i et j . Les N éléments de la diagonale de la matrice W sont supposés nuls ($w_{ii} = 0$).

La forme la plus répandue est la matrice de contiguïté simple binaire, dont les composantes prennent la valeur 1 lorsque les régions partagent une frontière commune et 0 sinon.

$$\begin{cases} w_{ij} = 1 & \text{si les régions sont frontalières} \\ w_{ij} = 0 & \text{sinon} \end{cases} \quad (1)$$

Lorsque les distances entre les régions sont connues, les coefficients de pondération peuvent être définis par une fonction décroissante de la distance, par exemple grâce à une puissance négative :

$$w_{ij} = |d_{ij}|^{-a} \quad (2)$$

d_{ij} étant la distance entre deux régions i et j ; le coefficient a peut être interprété comme un paramètre qui traduit la vitesse à laquelle la pondération diminue avec la distance : plus le paramètre a est petit, plus la diminution est lente, et inversement. Un cas particulier de matrice fondé sur les distances est le suivant :

$$\begin{cases} w_{ij} = 0 & \text{si } i = j \\ w_{ij} = \frac{1}{d_{ij}} & \text{si } d_{ij} < d_t \\ w_{ij} = 0 & \text{si } d_{ij} > d_t \end{cases} \quad (3)$$

où d_{ij} est la distance sphérique entre les centroïdes des régions i et j , et d_t la distance seuil au-delà de laquelle les interactions entre régions sont supposées négligeables (Bonfond, 2013).

À partir de cette base, il est possible de définir une multitude de matrices de poids en fonction des spécificités de l'espace et de la distribution du phénomène étudié. Un autre cas particulier est la matrice binaire fondée sur les distances. Il

s'agit de la matrice des k -plus proches voisins, $w_{ij}(k)$ représentant la relation de voisinage entre les régions i et j :

$$\begin{cases} w_{ij}(k) = 0 & \text{si } i = j \\ w_{ij}(k) = 1 & \text{si } d_{ij} \leq d_i(k) \\ w_{ij}(k) = 0 & \text{si } d_{ij} > d_i(k) \end{cases} \quad (4)$$

$d_i(k)$ est un seuil de distance défini comme la distance entre la région et son « k -ième » plus proche voisin (k étant le même pour toutes les régions). Ici, les interactions sont considérées comme négligeables au-delà de cette distance. L'avantage de cette spécification de la matrice de poids est qu'elle utilise l'information sur les distances physiques entre régions, tout en réduisant la matrice en une forme binaire. De plus, cette forme matricielle permet le calcul de la plupart des indices, et plus particulièrement l'analyse graphique de Moran sur les associations spatiales.

3.2. Mesure de l'autocorrélation spatiale

Pour les données spatiales, une corrélation peut se produire entre deux ou plusieurs réalisations d'une même variable du fait de leur proximité géographique. Un indice global d'autocorrélation spatiale mesure le degré de ressemblance entre des régions géographiquement proches par rapport à une variable numérique Y (Pfeiffer et al., 2008). Il y a ainsi autocorrélation lorsqu'il s'observe un regroupement spatial de valeurs similaires de cette variable. De façon qualitative, on parle d'autocorrélation positive pour une variable lorsqu'il y a un regroupement géographique de valeurs similaires de la variable. De même, il se produit une autocorrélation négative si des valeurs dissemblables ont tendance à partager le même espace. Et enfin le cas d'autocorrélation zéro se produit lorsque les attributs sont indépendants de l'emplacement géographique.

Les indices d'autocorrélation globale sont destinés à détecter la présence d'une tendance spatiale globale. Plus le nombre de régions géographiquement proches présentant des similitudes par rapport à une variable numérique Y est élevé, plus la valeur de l'indice global d'autocorrélation est grande (Pisati, 2012). Moran (1950) a développé un indice statistique (indice de Moran ou *Ide Moran*) qui permet de mesurer l'autocorrélation spatiale. Ses valeurs s'étendent de -1 (indiquant une dispersion parfaite) à $+1$ (corrélation parfaite). Les valeurs négatives (positives) de l'indice indiquent une autocorrélation spatiale négative (positive). Une valeur nulle est significative d'une répartition spatiale parfaitement aléatoire.

L'indice de Moran capte le degré de similitude ρ_{ij} par le produit des écarts à la moyenne $(y_i - \bar{y})(y_j - \bar{y})$, avec \bar{y} la moyenne de la variable observée Y . Le calcul de l'indice est donné par l'expression suivante :

$$I = \frac{\sum_{i=1}^N \sum_{j=1}^N w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\frac{1}{N} \sum_{i=1}^N w_{ij} (y_i - \bar{y})^2 \sum_{i=1}^N \sum_{j=1}^N w_{ij}} \quad (5)$$

avec $w_{ii} = 0$.

Pour analyser les effets économiques de la pandémie, nous utilisons l'écart de production (output gap). Il s'agit d'appliquer l'analyse spatiale sur l'écart de production de l'année 2020, obtenu à l'aide du filtre de Hodrick-Prescott (HP). Cette méthode se fonde sur le calcul du différentiel entre la valeur potentielle d'une variable et de sa valeur effective. Plus précisément, le filtre HP permet de décomposer une série temporelle (y_t) en une composante stable (τ_t) et une composante cyclique (c_t). Même si le filtre a été spécifié depuis le début des années 1980, il a été popularisé qu'à la fin des années 1990, à la suite des travaux de Hodrick et Prescott (1997). La série y_t est spécifiée ainsi :

$$y_t = \tau_t + c_t \quad (6)$$

La composante cyclique est obtenue en faisant la différence entre le revenu effectif et la tendance :

$$c_t = y_t - \tau_t \quad (7)$$

Le filtre HP calcule la tendance τ_t de y_t en minimisant la variance de y_t autour de τ_t .

$$\min_{\tau_t} \left[\sum_{t=1}^T (y_t - \tau_t)^2 + \lambda \sum_{t=2}^{T-1} \{(\tau_{t+1} - \tau_t) - (\tau_t - \tau_{t-1})\}^2 \right] \quad (8)$$

avec λ un paramètre de lissage.

4. Résultats des estimations de l'analyse exploratoire

Les résultats de l'analyse spatiale seront présentés d'abord pour les données sanitaires et ensuite sur les données économiques. L'analyse porte sur un échantillon de 132 pays (tableau 2).

Les pays insulaires ont été retirés de l'échantillon, compte tenu des difficultés à définir des critères de proximité. Les données sur la COVID-19 viennent de l'OMS (2022) : WHO Coronavirus Dashboard 2022. Les données sur le PIB viennent

Tableau 2. Pays de l'échantillon et codes ISO

Afghanistan	AFG	Croatie	HRV	Liban	LBN	Portugal	PRT
Albanie	ALB	République Tchèque	CZE	Lesotho	LSO	Qatar	QAT
Algérie	DZA	Danemark	DNK	Libéria	LBR	Roumanie	ROU
Andorre	AND	Équateur	ECU	Libye	LYB	Russie	RUS
Angola	AGO	El Salvador	SLV	Lituanie	LTU	Rwanda	RWA
Argentine	ARG	Guinée Équatoriale	GNQ	Luxembourg	LUX	Arabie Saoudite	SAU
Arménie	ARM	Estonie	EST	Malawi	MWI	Sénégal	SEN
Australie	AUS	Eswatini	SWZ	Malaisie	MYS	Sierra Leone	SLE
Autriche	AUT	Éthiopie	ETH	Mali	MLI	Singapour	SGP
Azerbaïdjan	AZE	Finlande	FIN	Mauritanie	MRT	Slovaquie	SVK
Bangladesh	BGD	France	FRA	Mexique	MEX	Slovénie	SVN
Biélorussie	BLR	Gabon	GAB	Moldavie	MDA	Afrique du Sud	ZAF
Belgique	BEL	Gambie	GMB	Mongolie	MNG	Espagne	ESP
Belize	BLZ	Géorgie	GEO	Monténégro	MNE	Sri Lanka	LKA
Bhoutan	BTN	Allemagne	DEU	Maroc	MAR	Soudan	SDN
Bolivie	BOL	Ghana	GHA	Mozambique	MOZ	Suriname	SUR
Bosnie-Herzégovine	BIH	Grèce	GRC	Birmanie	MMR	Suède	SWE
Botswana	BWA	Guatemala	GTM	Namibie	NAM	Suisse	CHE
Brésil	BRA	Guinée-Bissau	GNB	Nepal	NPL	Tadjikistan	TJK
Bulgarie	BGR	Haïti	HTI	Pays-Bas	NLD	Tanzanie	TZA
Burkina Faso	BFA	Honduras	HND	Nouvelle Zélande	NZL	Thaïlande	THA
Burundi	BDI	Hong Kong	HKG	Nicaragua	NIC	Togo	TGO
Cambodge	KHM	Hongrie	HUN	Niger	NER	Tunisie	TUN
Cameroun	CMR	Inde	IND	Nigeria	NGA	Turquie	TUR
Canada	CAN	Indonésie	IDN	Macédoine du Nord	MKD	Ouganda	UGA
Tchad	TCD	Iran	IRN	Norvège	NOR	Émirats Arabes Unis	ARE
Chilie	CHL	Iraq	IRQ	Oman	OMN	Royaume-Uni	GBR
Chine	CHN	Israël	ISR	Pakistan	PAK	États-Unis	USA
Colombie	COL	Italie	ITA	Papouasie Nouvelle-Guinée	PNG	Uruguay	URY
Congo. Rep. Dem.	COD	Jordanie	JOR	Paraguay	PRY	Ouzbékistan	UZB
Congo. Rep.	COG	Kazakhstan	KAZ	Pérou	PER	Vietnam	VNM
Costa Rica	CRI	Kenya	KEN	Philippines	PHL	Zambie	ZMB
Côte d'Ivoire	CIV	Koweït	KWT	Pologne	POL	Zimbabwe	ZWE

Source : élaboration propre.

de la Banque mondiale, les indicateurs du développement dans le monde (World Bank, 2022). Enfin, les données sur les distances physiques entre pays, qui sont à la base l'élaboration de la matrice spatiale, proviennent de la base de la CEPII, GeoDist Database.

Le tableau 3 fournit une description des variables utilisées dans cette analyse. Les données sur la COVID-19 sont actualisées en mai 2022.

Tableau 3. Description des variables

Variable	Description	Mesure	Source
<i>Incid</i>	Taux d'incidence	Nombre de cas pour 100 000 habitants	OMS
<i>Mortal</i>	Mortalité	Nombre de décès pour 100 000 habitants	OMS
<i>PIB</i>	Produit intérieur brut	Produit intérieur brut réel (en dollar constant de 2015)	Banque Mondiale, WDI 2022
<i>OG</i>	Écart de production	Écart de production en pourcentage	Nos propres calculs, à partir du filtre HP

Source : élaboration propre.

4.1. Sur les données sanitaires

Le tableau 4 fournit les résultats des tests d'autocorrélation spatiale globale effectués sur les taux d'incidence de la COVID-19 (*Incid*), en logarithme.

Tableau 4. Test d'autocorrélation spatiale globale des taux d'incidence

	Valeur	Espérance	Écart type	<i>z</i>	<i>p</i> -value
I de Moran	0,622***	-0,008	0,071	8,820	0,000
c de Geary	0,458***	1,000	0,081	-6,655	0,000

Source : calculs de l'auteur.

La statistique I de Moran est positive et significative. Ce résultat est confirmé par le test de Geary. Ceci démontre l'existence d'une autocorrélation spatiale positive des niveaux d'infection. En d'autres termes, les pays présentant des niveaux d'exposition similaires à la COVID-19 ont tendance à être proches plus souvent que cela ne relèverait du simple fait du hasard. Le même résultat est obtenu avec le nombre relatif de décès (tableau 5).

Si la statistique I de Moran offre une mesure globale de l'autocorrélation spatiale, elle ne permet cependant pas d'analyser la structure locale de celle-ci. Pour cela il existe des mesures d'autocorrélation spatiale locale, mais aussi le diagramme de Moran qui permet de visualiser plus précisément la situation des pays. Le diagramme de Moran est proposé par Anselin (1996). Il permet de déterminer les formes d'associations spatiales. Pour chaque point, il met en relation la valeur

ces cas de figure constituent les cas atypiques de localisations qui dévient du schéma global d'autocorrélation spatiale positive.

Les pays se trouvent majoritairement dans le schéma d'association positif. Dans la partie haute, qui représente les regroupements des pays avec un niveau élevé d'infection, on retrouve majoritairement les pays d'Europe de Ouest et d'Europe centrale (France, Allemagne, la Grande-Bretagne notamment), d'Asie de l'Ouest (Israël, Liban) d'Amérique du Nord et d'Amérique latine (États-Unis, Canada, Mexique, Chili, etc.). Par contre, dans le schéma d'association positif bas (regroupement de pays avec un niveau relativement faible d'infection), on retrouve principalement les pays du continent africain et d'Asie centrale et du Sud. Ce résultat confirme pour ces régions l'existence de cluster avec de faibles niveaux d'infection. Pour l'Afrique en particulier, l'autocorrélation positive basse indique que les faibles taux d'incidence concernent essentiellement des pays localisés sur ce continent.

En ce qui concerne le nombre de décès, il ressort plusieurs clusters hauts, en Amérique latine principalement, mais aussi en Afrique subsaharienne (figure 3). En réalité, la mortalité est moins homogène en termes de regroupement spatial des taux.

Ainsi, on observe une autocorrélation spatiale moins forte (le I de Moran est de 0,170 contre 0,622 pour l'incidence). En effet, plusieurs pays ont dévié du schéma

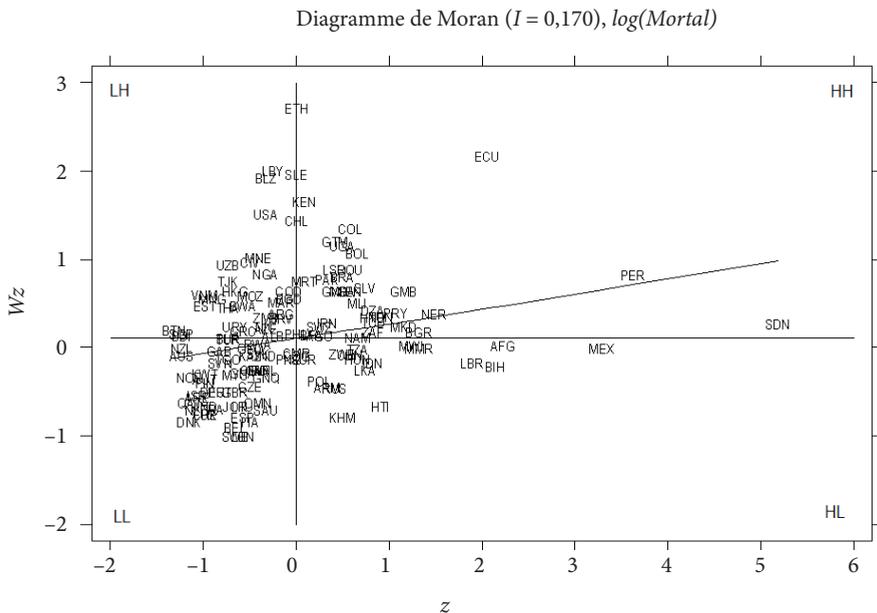


Figure 3. Visualisation de l'autocorrélation spatiale locale du nombre de décès pour 100 000 habitants

Source : élaboration propre.

dominant d'autocorrélation spatiale positive, ce qui fait qu'il est courant de voir des pays avec des taux de mortalité faibles avoir une proximité géographique avec des pays à faible taux de mortalité et vice versa. Il est remarquable aussi de relever qu'alors que les clusters de pays à taux d'incidences élevés étaient situés majoritairement en Europe et en Amérique et se présentaient plutôt de façon homogène, les clusters à forte mortalité sont plus clairsemés et concernent quasiment tous les continents.

4.2. Sur les données économiques

L'écart de production (*OG*), calculé sur le PIB (mesuré par le PIB réel) de chaque pays et donné en pourcentage, est utilisé comme mesure de l'effet de la COVID-19 sur le plan économique. Les calculs sont effectués sur des séries longues de 60 ans (1960 à 2020). Pour l'année 2020, l'écart entre le niveau effectif de la production et celui atteint si l'économie était à son potentiel peut être obtenu.

Ainsi, la figure 4 confirme que toutes les régions du monde ont dévié de leur sentier de croissance de long terme en 2020, comme le démontre les outputs gap négatifs. Toutefois, les effets varient considérablement entre pays et selon l'appartenance spatiale. L'AEDS sur les conséquences économiques est effectuée sur l'écart de production pour l'année 2020.

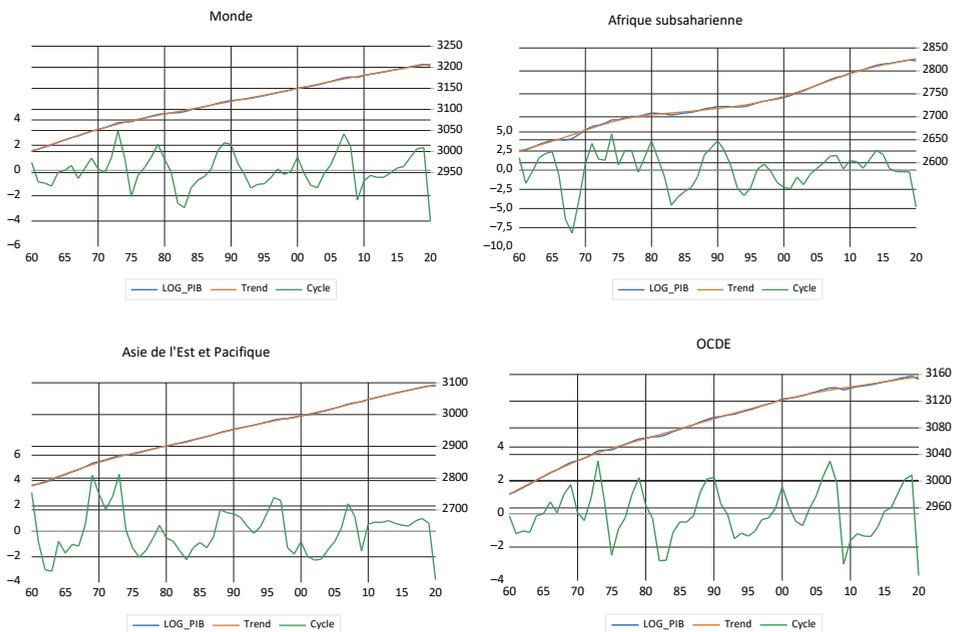


Figure 4. Écart de production de différentes régions du monde en 2020

Source : élaboration propre.

Tableau 6. Test d'autocorrélation spatiale globale des écarts de production (OG) en 2020

	Valeur	Espérance	Écart type	z	p-value
I de Moran	0,183***	-0,008	0,070	2,710	0,003
c de Geary	0,738***	1,000	0,101	-2,581	0,005

Source : calculs de l'auteur.

Pour l'output gap de 2020, aussi bien le test de Moran que le test de Geary montrent une autocorrélation spatiale positive (tableau 6). En d'autres termes, les pays proches ont été impactés de manière plus ou moins similaire, suivant les écarts de production. Ce résultat peut être expliqué par le fait que les pays étant interconnectés par les échanges internationaux, les pays proches le seraient davantage. L'arrêt de la production, même si elle a mis en mal la chaîne de production mondiale, a davantage impacté les échanges et les mobilités régionales. De même, les structures économiques similaires des pays proches pourraient être relativement similaires, ce qui explique le fait d'observer les mêmes conséquences économiques face à un même choc.

Le diagramme de Moran (figure 5) permet à la suite de visualiser l'autocorrélation locale. Ici aussi, comme le laissait présager le I de Moran, les schémas d'association positifs sont majoritaires. Les schémas hauts sont composés principalement

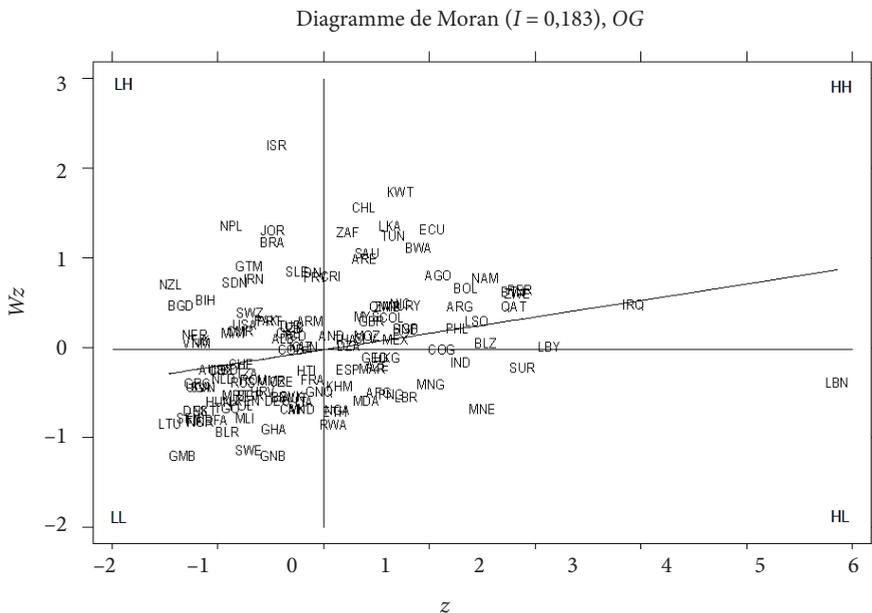


Figure 5. Visualisation de l'autocorrélation spatiale locale de l'écart de production (OG)

Source : élaboration propre.

de pays d'Amérique latine, qui constituent le cluster de pays durement touchés sur le plan économique par la pandémie.

Ainsi, s'agissant des économies relativement impactées sur le plan économique, on distingue un cluster de pays d'Afrique, autour de l'Afrique du Sud (Lesotho, Botswana, Namibie, Angola, etc.) et en Afrique du Nord (Algérie, Tunisie) et un autre au Moyen-Orient, composé principalement de pays producteurs de pétrole (Koweït, Qatar, Arabie Saoudite). Il existe aussi un cluster en Amérique latine, autour du Mexique (Argentine, Bolivie, Colombie, Équateur, Chili). Le point commun entre ces économies pourrait être leur fragilité économique avant la COVID-19, la plupart de ces pays sortant de difficultés économiques ou sociopolitiques. De plus, une grande partie étant dépendante des ressources pétrolières, la chute historique du baril de pétrole en pleine pandémie a précipité à son tour la chute de la production nationale. Il faut souligner aussi que si les pays à revenu élevé (Europe de l'Ouest et du Centre, Amérique du Nord notamment) ont généralement été davantage touchés sur le plan sanitaire, ils ont développé une plus grande résilience économique, au vu des résultats issus du diagramme de Moran portant sur l'output gap (figure 5).

Au total, l'analyse exploratoire spatiale a permis de valider l'hypothèse d'autocorrélation spatiale aussi bien pour les effets sanitaires que pour les effets économiques de la COVID-19. Ce résultat peut être le fait d'interdépendances géographiques issues des effets de voisinage entre pays. L'examen des diagrammes de Moran confirme ces schémas géographiques particuliers des économies et renseigne sur l'importance du rôle de la localisation géographique sur la dynamique des épidémies et de leurs conséquences sanitaires et économiques. Ce résultat justifierait notamment la prise en compte de la dimension régionale dans la prise de décision dans le cadre de la lutte contre la propagation de la pandémie et les mesures de résiliences économiques.

Ces résultats sont similaires avec ceux obtenus par Naumov et al. (2021). Ils sont aussi conformes à la synthèse des résultats empirique faite par Xie et al. (2021) sur l'importance de l'environnement naturel et du niveau de développement économique dans la propagation de la pandémie. L'activité économique s'accompagnant souvent de fortes concentrations dans les villes et métropole est propice à la propagation du nouveau coronavirus. En réalité, il semble avoir une convergence au niveau de la recherche sur le rôle déterminant de la localisation géographique dans la manifestation de la pandémie.

Conclusion

Dans cet article, nous avons analysé les effets sanitaires et économiques de la pandémie de COVID-19 sur un échantillon de 132 pays. La méthodologie utilisée est l'analyse exploratoire des données spatiales. L'avantage de cette méthode est

qu'elle utilise des données en coupe transversale. De même, le calcul de l'output gap par la méthode de Hodrick-Prescott a permis de ressortir les écarts de production pour l'année 2020, consécutifs à la crise sanitaire. Ce dernier suggère déjà une certaine spatialisation des intensités de l'écart de production, la crise économique semblant avoir frappé plus durement certaines régions que d'autres. Le même constat est observé au niveau des taux d'incidence et des taux de mortalité liés à la COVID-19.

Par la suite, l'AEDS, à travers les tests d'autocorrélation spatiale, conclut à l'existence de similitudes régionales dans la manifestation de la pandémie et d'hétérogénéité spatiale entre les régions. En d'autres termes, les pays proches ont tendance à manifester les mêmes intensités en termes d'incidence de la COVID-19 et en termes d'output gap, tandis qu'on observe des dissemblances entre régions. Toutefois, les résultats montrent l'existence de cluster avec de faibles niveaux d'incidence en Afrique et en Asie, comparativement à l'Europe et à l'Amérique du Nord. De plus, si les pays à revenu élevé ont généralement été davantage touchés sur le plan sanitaire, ils ont toutefois développé une plus grande résilience économique.

Ainsi, les mesures de riposte doivent être élaborées non pas seulement à l'échelle nationale, mais aussi à l'échelle régionale, pour atténuer les effets de contagion. Les mécanismes de gestion publique et de stabilisation de la situation épidémiologique doivent tenir compte de l'hétérogénéité spatiale de la propagation du COVID-19, qui s'accompagne d'une concentration de l'infection dans certaines parties du monde. Dans ce sens, il est important de coordonner la riposte sanitaire au niveau régional, mais aussi identifier les facteurs à risque spécifiques en termes de développement et de propagation de la maladie.

De même, les mesures de résilience économiques doivent aussi être coordonnées au niveau régional. Il serait aussi important d'identifier les déterminants de la résilience économique face à des chocs exogènes comme celui de la COVID-19. À ce niveau, des recherches futures pourraient déterminer les facteurs (caractéristiques structurelles) qui expliquent l'homogénéité régionale et l'hétérogénéité interrégionale de l'output gap. Pour cela, il faudra nécessairement identifier les mesures et comportements économiques qui aggravent le cycle et celles qui contribuent à l'atténuer dans le court et le long terme. En somme, cette recherche suggère une analyse plus approfondie sur les déterminants de l'hétérogénéité spatiale régionale aussi bien sur le plan sanitaire qu'économique.

References

- Anselin, L. (1996). The Moran scatterplot as an ESDA tool to assess local instability in spatial association. In I. Masser & F. Salge (Eds.), *Spatial analytical perspectives on GIS* (pp. 111–125). Taylor & Francis.

- Azcona, G., Bhatt, A., Encarnacion, J., Plazaola-Castaño, J., Seck, P., Staab, S., & Turquet, L. (2020). *From insights to action: Gender equality in the wake of COVID-19*. UN Women Headquarters.
- Bailey, T. C., & Gatrell, A. C. (1995). *Interactive spatial data analysis*. Longman.
- Bonnefond, C. (2013). *L'analyse des inégalités sociales et spatiales dans le processus d'émergence de la Chine*. [Thèse de doctorat]. Université Montesquieu – Bordeaux IV.
- Carleton, T., Cornetet, J., Huybers, P., Meng, K., & Proctor, J. (2020). Global evidence for ultraviolet radiation decreasing COVID-19 growth rates: Global Estimates and Seasonal Implications. <https://ssrn.com/abstract=3588601>
- Cliff, A. D., & Ord, J. K. (1973). *Spatial autocorrelation*. Pion.
- Cliff, A. D., & Ord, J. K. (1981). *Spatial processes: Models and applications*. Pion.
- Cliff, A. D., Haggett, P., Ord, J. K., Bassett, K. A., & Davies, R. B. (1975). *Elements of spatial structure*. Cambridge University Press.
- Coutiño, A., and Zandi, M. (2021). Global loss of production capacity caused by the COVID-19 pandemic. *Journal of Policy Modeling*, 43(3), 493–502.
- Fonds Mondial. (2020). *Atténuer l'impact du COVID-19 dans les pays touchés par le VIH, la tuberculose et le paludisme*. Le Fonds mondial de lutte contre le sida, la tuberculose et le paludisme Campus de la Santé Mondiale.
- Getis, A., & Boots, B. (1978). *Models of spatial processes*. Cambridge University Press.
- Goel, R. K., Saunoris, J. W., & Goel, S. S. (2021). Supply chain performance and economic growth: The impact of COVID-19 disruptions. *Journal of Policy Modeling*, 43(2), 298–316.
- Goodchild, M. F. (1986). *Spatial autocorrelation*. Geo Books.
- Grömling, M. (2021). COVID-19 and the growth potential. *Intereconomics*, 56, 45–49. <https://doi.org/10.1007/s10272-021-0950-4>
- Haggett, P., Cliff, A. D., & Frey, A. (1977). *Locational analysis in human geography* (2nd ed., 2 vol.). Arnold.
- Haining, R., Wise, AS., & Ma, J. (1998). Exploratory spatial data analysis in a geographic information system environment. *The Statistician*, 47, 457–469.
- Hodrick, R., & Prescott, E. (1997). Postwar U.S. business cycles: An empirical investigation. *Journal of Money, Credit and Banking*, 29(1), 1–16.
- Le Gallo, J. (2002). *Disparités géographiques et convergence des régions européennes: Une approche par l'économétrie spatiale*. [Thèse de doctorat]. Université de Bourgogne.
- Maisonnavé, H., & Cabral, F. (2021). *L'impact du COVID-19 sur l'économie Sénégalaise: Une perspective de genre*. Partnership for Economic Policy Working Paper, 2.
- Merow, C., & Urban, M. C. (2020). *Seasonality and uncertainty in global COVID-19 growth rates*. Nils Chr. Stenseth, University of Oslo.
- Moran, P. A. P. (1950). Notes on continuous stochastic phenomena. *Biometrika*, 37(1/2), 17–23.
- Naumov, I. V., Otmakhova, Y. S., & Krasnykh, S. S. (2021). Methodological approach to modeling and forecasting the impact of the spatial heterogeneity of the COVID-19 spread on the economic development of Russian regions. *Computer Research and Modeling*, 13(3), 629–648.
- OIT. (2020). *Étude de l'impact de la COVID-19 sur les entreprises et travailleurs de l'économie informelle au Sénégal*. Genève. Bureau International du Travail. <https://www.ilo.org/>

- wcmsp5/groups/public/---africa/---ro-abidjan/---sro-dakar/documents/publication/wcms_763402.pdf
- OMS. (2022). *COVID-19 Dashboard*. World Health Organization. <https://covid19.who.int/>
- Pfeiffer, D., Robinson, T., Stevenson, M., Stevens, K., Rogers, D., & Clements, A. (2008). *Spatial analysis in epidemiology*. Oxford University Press.
- Pisati, M. (2012). *Exploratory spatial data analysis using Stata*. German Stata Users Group meeting, WZB Social Science Research Center, Berlin.
- Ripley, B. D. (1981). *Spatial statistics*. John Wiley & Sons.
- Tobler, W. (1979). Cellular geography. In S. Gale & G. Olsson (Eds.), *Philosophy in geography* (pp. 379–386). Reidel.
- Upton, G. J. G., & Fingleton, B. (1985). *Spatial data analysis by example*. Vol. 1: *Point pattern and quantitative data*. John Wiley & Sons.
- World Bank. (2022). *World development indicators*. The World Bank.
- Xie, Z., Zhao, R., Ding, M., & Zhang, Z. (2021). A review of influencing factors on spatial spread of COVID-19 based on geographical perspective. *International Journal of Environmental Research and Public Health*, 18(22), 12182.