NOWCASTING DU PIB FRANÇAIS : UN MODELE A FACTEURS DYNAMIQUES

Magali Dauvin

Ombeline Jullien de Pommerol

Raul Sampognaro

SCIENCES PO OFCE WORKING PAPER n° 16/2025

EDITORIAL BOARD

Chair: Xavier Ragot (Sciences Po, OFCE)

Members: Jérôme Creel (Sciences Po, OFCE), **Eric Heyer (**Sciences Po, OFCE), **Sarah Guillou** (Sciences Po, OFCE), **Xavier Timbeau (**Sciences Po, OFCE), **Anne Epaulard** (Sciences Po, OFCE).

CONTACT US

OFCE
10 place de Catalogne | 75014 Paris | France
Tél. +33 1 44 18 54 24
www.ofce.fr

WORKING PAPER CITATION

This Working Paper:
Magali Dauvin, Ombeline Jullien de Pommerol et Raul Sampognaro
Nowcasting du PIB français : un modèle à facteurs dynamiques,
Sciences Po OFCE Working Paper, n° 16/2025.
Downloaded from URL: www.ofce.sciences-po.fr/pdf/dtravail/WP2025-16.pdf
DOI - ISSN

© 2025 OFCE

ABOUT THE AUTHORS

Magali Dauvin, Sciences Po-OFCE, Paris
Email Address: magali.dauvin@sciencespo.fr
Ombeline Jullien de Pommerol, Sciences Po-OFCE, Paris
Email Address: ombeline.julliendepommerol@sciencespo.fr
Raul Sampognaro, Sciences Po-OFCE, Paris
Email Address: raul.sampognaro@sciencespo.fr

ABSTRACT

Dans ce document, nous présentons un modèle de nowcasting du PIB français fondé sur une approche directe mobilisant un large ensemble d'indicateurs à haute fréquence. L'objectif est de fournir des estimations infra-trimestrielles réactives et robustes dans un environnement économique incertain, tel que celui observé depuis la crise de la Covid-19. À partir d'une base de données structurée en huit blocs thématiques regroupant 136 séries macroéconomiques nationales et internationales, nous testons trois méthodes de pré-sélections de variables et estimons un modèle à facteurs dynamiques avec fréquences mixtes. Nous évaluons les performances prédictives en pseudo-temps réel entre 2010 et 2025 sur plusieurs sous-périodes (pré- et post-Covid). Notre meilleur modèle atteint un RMSE compris entre 0,20 et 0,22 sur l'ensemble du trimestre, avec une amélioration progressive au fur et à mesure de la publication des données (RMSE compris entre 0,19 et 0,20 le dernier mois du trimestre en cours). Nous discutons également les stratégies de correction des données liées à la période Covid et la robustesse des spécifications retenues.

KEYWORDS

Nowcasting, modèle à facteurs dynamiques, croissance du PIB.

JEL

C32, C38, E32, E37.

Nowcasting du PIB français : un modèle à facteurs dynamiques

Magali Dauvin, Ombeline Jullien de Pommerol et Raul Sampognaro

2025-09-11

Dans ce document, nous présentons un modèle de nowcasting du PIB français fondé sur une approche directe mobilisant un large ensemble d'indicateurs à haute fréquence. L'objectif est de fournir des estimations infra-trimestrielles réactives et robustes dans un environnement économique incertain, tel que celui observé depuis la crise de la Covid-19. À partir d'une base de données structurée en huit blocs thématiques regroupant 136 séries macroéconomiques nationales et internationales, nous testons trois méthodes de pré-sélections de variables et estimons un modèle à facteurs dynamiques avec fréquences mixtes. Nous évaluons les performances prédictives en pseudo-temps réel entre 2010 et 2025 sur plusieurs sous-périodes (pré- et post-Covid). Notre meilleur modèle atteint un RMSE compris entre 0,20 et 0,22 sur l'ensemble du trimestre, avec une amélioration progressive au fur et à mesure de la publication des données (RMSE compris entre 0,19 et 0,20 le dernier mois du trimestre en cours). Nous discutons également les stratégies de correction des données liées à la période Covid et la robustesse des spécifications retenues.

Classification JEL: C32, C38, E32, E37

Mots-clefs : *nowcasting*, modèle à facteurs dynamiques, croissance du PIB

*Nous remercions l'Insee pour la mise à disposition des séries trimestrielles du PIB. Nous remercions également les participants au séminaire interne de l'OFCE, du workshop « Nowcasting du PIB français » de la Chaire "Mesure de l'économie" à PSE pour leurs remarques. Nous adressons des remerciements particuliers à Catherine Doz et Éric Dubois pour leurs suggestions et commentaires, ainsi qu'à Marie-Julie Biffe pour son appui à la recherche.

1 Introduction

Les modèles de prévision du PIB, à l'instar des économies française et mondiale, ont été profondément bouleversés par la crise liée à la Covid-19. Conçus pour des environnements relativement stables, ces outils traditionnels ont été confrontés à un choc économique sans précédent, qui a non seulement désorganisé l'activité réelle, mais aussi perturbé les calendriers de publication des statistiques officielles. Cette rupture a mis en évidence les limites des approches historiques, en altérant leur capacité à anticiper les évolutions macroéconomiques dans un contexte de forte incertitude. Ce contexte a ainsi révélé la nécessité de disposer d'outils de prévision plus réactifs, capables de s'adapter à des environnements volatils, riches en données et a souligné les insuffisances des méthodes classiques face à des chocs rapides et imprévus.

Dans la littérature comme dans les pratiques institutionnelles, deux grandes approches de nowcasting du PIB se dégagent. La première, dite approche directe, consiste à modéliser le PIB agrégé comme une fonction d'un ensemble d'indicateurs économiques disponibles en temps réel. Elle est utilisée notamment par la Banque de France, la Fed de New York ou la DG Trésor (Banbura et al. (2013), Mogliani, Darné, et Pluyaud (2017), Bok et al. (2018), Chinn, Meunier, et Stumpner (2023), André et Bessec (2024)). La seconde, qualifiée d'approche *bottom-up*, repose sur la modélisation séparée des principales composantes de la demande et de l'offre (consommation, investissement, commerce extérieur, production, etc.), dont les prévisions sont ensuite agrégées pour reconstituer le PIB. Cette méthodologie est illustrée notamment par l'outil *GDPNow* développé par la Réserve Fédérale d'Atlanta (Higgins (2014)).

Chaque approche présente des avantages spécifiques. L'approche directe se distingue par sa simplicité structurelle et sa capacité à intégrer rapidement un grand nombre d'indicateurs hétérogènes, tandis que l'approche *bottom-up* offre une lecture plus désagrégée de la dynamique conjoncturelle, au prix d'un calibrage plus exigeant. Dans les deux cas, le *nowcasting* répond à une exigence croissante de disposer d'estimations rapides et fiables de l'activité économique en cours, dans un contexte marqué par la volatilité accrue des indicateurs macroéconomiques et les délais de publication importants des données de comptabilité nationale (Giannone, Reichlin, et Small (2008)).

Dans ce paysage, l'OFCE disposait historiquement d'un indicateur avancé, fondé essentiellement sur des enquêtes de conjoncture (Hervé Péléraux (2000), Péléraux (2017)), mis en sommeil pendant la crise Covid (Figure 1). La nécessité de réactiver et de moderniser ce type d'outil s'est renforcée avec les chocs récents, qui ont accentué la demande d'indicateurs en temps réel émanant des décideurs publics et des analystes conjoncturels.

Dans ce document, nous adoptons une approche directe du *nowcasting*, en mobilisant un large ensemble d'indicateurs à haute fréquence pour estimer l'évolution du PIB à court terme à l'aide d'un modèle à facteurs dynamiques (MFD). Cette stratégie vise à concilier réactivité, robustesse empirique et cohérence statistique dans un environnement macroéconomique devenu plus instable.

La méthode proposée repose sur deux piliers complémentaires : la construction d'une base de données riche et la mise en œuvre d'un modèle économétrique adapté. La première étape du travail a consisté à élaborer une base aussi exhaustive que possible, réunissant 136 séries issues de sources statistiques variées, couvrant à la fois l'économie française et certains indicateurs internationaux. Ces données sont organisées en huit grands blocs thématiques et font l'objet d'une collecte et d'une mise à jour automatisées, assurant ainsi une intégration rapide et fiable de l'information conjoncturelle disponible.

Afin de tirer parti de cette base tout en limitant la sur-paramétrisation du modèle, une pré-sélection des variables est opérée permettant de ne retenir que les indicateurs les plus informatifs pour la prévision. Le modèle à facteurs dynamiques, *i.e.* le modèle de *nowcasting* retenu est particulièrement adapté à la prévision infra-annuelle dans un contexte de publication échelonnée des statistiques. Il permet de résumer l'information contenue dans les nombreuses séries sélectionnées sous forme de quelques facteurs latents, estimés dans un cadre espace-état à l'aide de l'algorithme EM. Ce cadre flexible permet notamment une prise en compte efficace des données manquantes, tout en maintenant une forte réactivité aux nouvelles données disponibles. L'implémentation repose sur la boîte à outils développée récemment par Linzenich et Meunier (2024) pour la Banque Centrale Européenne.

Enfin, nous évaluons les performances du modèle dans une perspective de prévision en pseudo-temps réel, sur une période récente caractérisée par des chocs conjoncturels majeurs (crise sanitaire, tensions géopolitiques, inflexions de politique monétaire). Cette évaluation permet de discuter les limites actuelles de la méthode ainsi que les pistes d'amélioration à envisager dans la perspective d'un dispositif opérationnel de prévision à haute fréquence.

Le document est organisé comme suit. Dans la section 2, nous présentons le cadre méthodolgique de l'éxercice réalisé. Dans la section 3, nous introduisons les données ainsi que les différents étapes permettant d'arriver à notre modèle de *nowcasting*. La section 4 présente les résultats. Nous proposons des spécifications alternatives pour tester la robustesse de nos résultats dans la section 5.

2 Methodologie

2.1 Modèle à facteurs dynamiques

Les modèles à facteurs dynamiques figurent parmi les outils les plus largement utilisés pour la prévision macroéconomique à court terme (voir *e.g.* la contribution fondatrice de Stock et Watson (2002)). Ces modèles permettent d'exploiter l'information contenue dans de vastes ensembles de données. L'idée centrale consiste à résumer les co-mouvements d'un grand nombre de variables à l'aide d'un petit nombre de facteurs communs latents. Cette approche permet une réduction de dimension tout en conservant un maximum d'informations pertinentes.

Figure 1: Millésimes du PIB

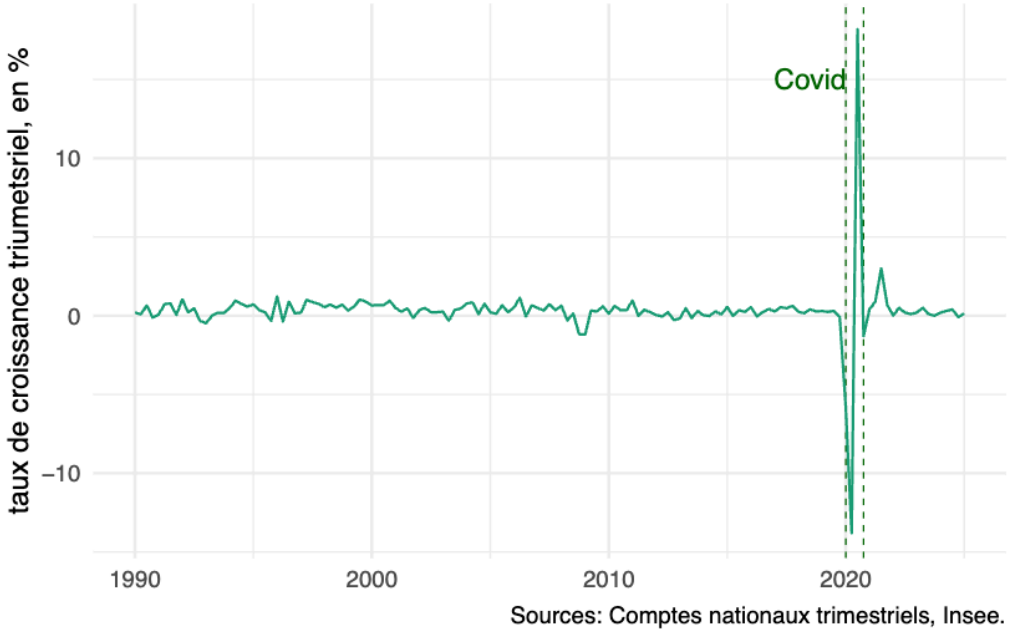

L'utilisation d'une méthodologie tirant parti de l'accès à des données de plus en plus riches et à haute fréquence est particulièrement attrayante. De tels modèles sont employés par les principales institutions publiques en France pour prévoir la croissance du PIB à court terme (Bessec et Doz (2014), Bessec et Doz (2012)).

La représentation en espace-état de cette classe de modèles (Watson et Engle (1983)) a grandement facilité leur mise en œuvre, tant du point de vue de l'estimation que de celui de l'inférence. Plus récemment, l'adaptation de l'algorithme EM (*Expectation Maximisation*) proposée par Bańbura et Modugno (2014) a permis de traiter les données manquantes selon une structure prédéfinie. Cette dernière contribution permet notamment de traiter les délais de publication des différents indicateurs conjoncturels. Il s'agit là d'une contribution majeure à la littérature sur le *nowcasting* en économie.

L'ensemble de ces contributions permet aux MFD d'intégrer deux dimensions essentielles des données conjoncturelles : d'une part, la diversité des fréquences d'observation — quotidienne, hebdomadaire, mensuelle ou trimestrielle — ; d'autre part, l'arrivée décalée des informations, liée à l'hétérogénéité des délais de publication des indicateurs.

2.2 Cadre économétrique

Soit $Y_t = (y_{1t}, y_{2t}, \dots, y_{Nt})$ un vecteur de N indicateurs conjoncturels stationnaires observés au mois t. On suppose que ce vecteur peut être représenté de la manière suivante :

$$Y_t = \Lambda F_t + \varepsilon_t \tag{1}$$

où $F_t = (f_{1t}, f_{2t}, \dots, f_{rt})$ désigne un vecteur de dimension r regroupant les facteurs communs, et $\varepsilon_t = (\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{Nt})$ le vecteur des chocs idiosyncratiques, supposés non corrélés avec les valeurs passées, présentes ou futures de F_t. La matrice Λ, de dimension $N \times r$, contient les charges factorielles associées à chaque variable.

Chaque élément de la composante idiosyncratique est modélisé de la façon suivante :

$$\varepsilon_{it} = \rho_i \varepsilon_{it-1} + e_{it} \tag{2}$$

où e_{it} est un bruit blanc gaussien, indépendant de tout autre élément du modèle. Dans un premier temps, nous considérons tous les éléments du vecteur $\rho = (\rho_1, \dots, \rho_N)$ comme nuls soit $\varepsilon_t \sim iid$. Nous relâcherons cette hypothèse plus tard pour tester la robustesse de nos résultats.

Les facteurs communs F_t sont supposés suivre un processus VAR stationnaire d'ordre p :

$$F_t = A_1 F_{t-1} + A_2 F_{t-2} + \dots + A_p F_{t-p} + u_t$$

avec $u_t \sim N(0, Q)$.

Pour estimer le MDF présenté dans cet article, nous nous appuyons sur le code proposé par Linzenich et Meunier (2024), fondé sur la méthodologie de Bańbura et Modugno (2014).

L'estimation du modèle dynamique factoriel suit l'algorithme d'*Expectation-Maximization* (*EM*) couplé au lisseur de Kalman, comme proposé par Doz, Giannone, et Reichlin (2011). La procédure est initialisée par une analyse en composantes principales statique, qui fournit une première estimation des facteurs et des charges. Les paramètres du modèle sont ensuite mis à jour à chaque itération par moindres carrés, ce qui correspond à une étape de maximisation de la vraisemblance conditionnelle. Les facteurs communs sont reconstitués à l'aide du lisseur de Kalman, et l'algorithme itère jusqu'à convergence vers les estimateurs du maximum de vraisemblance[1].

[1] Pour plus de détails, voir Bańbura et Modugno (2014).

3 Données

Dans cette section, nous présentons les données mobilisées ainsi que les différents traitements qu'elles ont nécessités avant d'aborder l'estimation proprement dite.

La recherche académique en matière de *nowcasting* a tiré profit de la disponibilité croissante de données massives dans un délai de plus en plus court, ainsi que du développement de méthodes adaptées à l'estimation de modèles de grande dimension. Aux États-Unis, cela s'est notamment concrétisé par la construction de la base *Fred-MD* (McCracken et Ng (2015)), qui fait aujourd'hui référence par la diversité de ses sources, la pertinence économique des séries qu'elle contient, et leur mise à disposition régulière auprès de la communauté scientifique. Elle contribue ainsi au développement de modèles de prévision à très court terme pour l'économie américaine. Si tout exercice de *nowcasting* repose en premier lieu sur la constitution d'un ensemble de données, le présent article s'inscrit dans une démarche visant à construire — de manière cumulative — une base de données destinée à améliorer les outils de prévision utilisés par les praticiens en France. Dès que le périmètre final de cette base sera stabilisé, celle-ci sera rendue publique et actualisée de manière récurrente, ouvrant ainsi la voie à des exercices de prévision en temps réel fondés sur un large éventail d'informations.

3.1 La base de données

Nous avons construit notre base de données de manière à reproduire la logique de la base *Fred-MD*, tant dans le type de variables qu'elle contient que dans sa structuration en blocs thématiques. Elle vise également à intégrer le plus grand nombre possible de séries déjà mobilisées dans les modèles de *nowcasting* du PIB trimestriel français, en particulier ceux de Bessec et Doz (2012) et André et Bessec (2024).

La base se compose de 136 séries. L'échantillon s'étend de janvier 1970 à juin 2025. La dernière date de mise à jour de la base de données date du 30 juin 2025. Les séries rassemblées sont de natures variées : certaines proviennent d'enquêtes, d'autres de données brutes (en termes réels ou nominaux), d'indices élaborés par des économistes, ou encore de prévisions de type *nowcast*. Leur couverture géographique inclut la France, mais également les États-Unis, l'Allemagne, et plus largement l'économie mondiale. De ce fait, la base s'appuie sur une diversité de sources, parmi lesquelles figurent la Banque de France, Baker, Bloom, et Davis (2016), Caldara et Iacoviello (2022), le Centraal Planbureau (CPB), la Dares, Eurocontrol, Eurostat, France Travail, FRED, l'Insee, Open Data Réseaux Énergies (ODRE), les Nations Unies, la Réserve Fédérale de New-York, et Yahoo Finance.

Parmi ces séries, 13 sont quotidiennes, 3 hebdomadaires, 114 mensuelles, et 6 trimestrielles. Pour l'analyse réalisé dans ce document, les séries quotidiennes et hebdomadaires sont mensualisées en calculant leur moyenne dans le mois.

Les 136 séries ont été réparties en 8 groupes de variables. Le groupe Activité contient 31 séries. Le groupe Commandes et inventaires en compte 27. Le groupe Construction contient

21 séries. Le groupe Finance en comprend 13. Le groupe Incertitude regroupe 3 séries. Le groupe International en compte 16. Le groupe Marché du travail contient 15 séries. Enfin, le groupe Monnaie, crédit, prix rassemble 10 séries[2].

Tout au long du trimestre en cours et du premier mois du trimestre suivant, le *nowcast* du PIB peut être affiné à mesure que les données sont mises à jour. Prenons l'exemple de la base compilée au 30 juin 2025 et des délais de publication illustrés dans la Figure 2. Plaçons-nous donc au premier jour du 3e trimestre 2025 (ordonnée à l'origine). Les variables quotidiennes sont, par nature, disponibles sans délai. Nous en avons 13. Bien qu'elles ne couvrent pas l'intégralité du mois de juillet 2025, elles fournissent tout de même une information sur cette période et peuvent être mises à jour quotidiennement. Autour du 19 juillet, on observe une première hausse marquée du nombre d'observations disponibles, passant de 12 à 38, liée à la publication des enquêtes de conjoncture de l'Insee. En fin de mois, près de 40 % des variables pour juillet sont accessibles. Une dizaine de jours plus tard, une nouvelle progression nette (de 41 à 70 variables disponibles) résulte cette fois-ci de la publication des enquêtes de la Banque de France. Jusqu'à la mi-août, la disponibilité des données continue d'augmenter progressivement, notamment avec les statistiques de consommation des ménages et de logement de l'Insee. Au-delà de cette période, les publications restantes concernent principalement le mois précédent, c'est-à-dire juin 2025, ou le trimestre 2. Enfin, la quatrième hausse significative — marquée par une barre verticale dans la Figure 2 — correspond à la publication, avec deux mois de délai, des indices de la production industrielle[3].

Avant d'estimer le modèle, nous commençons par ajuster les données. Pour faire cela nous avons suivi les ajustement déjà réalisés dans d'autres travaux similaires (notamment Bessec et Doz (2012) et André et Bessec (2024)). Cette démarche permet notamment de lisser certaines séries très volatiles — telles que les mises en chantier, les permis de construire, les immatriculations de véhicules, les créations d'entreprises ou les faillites — en les exprimant sous forme de moyenne mobile sur trois mois. Par ailleurs, les séries présentant une forte saisonnalité, comme le nombre de vols aériens, sont exprimées en moyenne mobile d'ordre 12. Seules les trois séries de *nowcast* (PIB, commerce mondial de biens, commerce mondial de services) sont testées exclusivement sous leur forme "brute"[4]. Pour toutes les variables dont la fréquence de sortie est infra-mensuelle, nous faisons une moyenne sur le mois.

Bien entendu, toute variable intégrée d'ordre 1 ou supérieur est rendue stationnaire[5]. Le dégré d'intégration est présenté dans Table 7.

[2]Le détail des séries inclues dans chaque groupe se trouve en annexe de ce document.

[3]Les indices de production industrielle sont publiés environ 35 à 40 jours après la fin du mois concerné. Comme nous mesurons les délais à partir du début du mois, nous attribuons ainsi un décalage de deux mois à la publication de la production industrielle. Toutes les données étant soumises à la même contrainte, cela ne pose donc pas de problème pour notre analyse. La variable correspondant à la consommation d'électricité (voir Figure 9) est récupérée, pour l'instant, avec beaucoup de délai (253 jours, soit le dernier point de Figure 2), ce qui ne sera pas le cas dans la base de données stabilisée.

[4]"Brute" au sens où aucune transformation n'est effectuée de notre part.

[5]Les tests ADF, KPSS et PP ont été effectués.

Figure 2: Variables disponibles en fonction du délai de publication

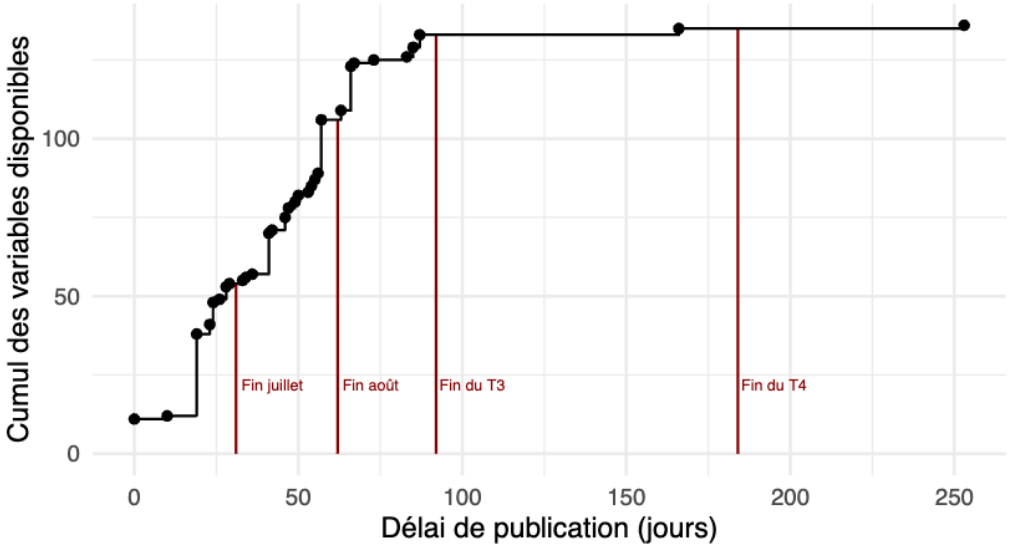

Notes: Délais de publication calculés à partir de la base de données consolidée le 30 juin 2025.
L'ordonné à l'origine correspond au premier jour du 3e trimestre 2025, soit le 01 juillet 2025.
Sources: Calculs des auteurs.

3.2 Pré-selection de variables

Plusieurs travaux ont recommandé de procéder à une présélection des séries utilisées pour l'estimation des facteurs dans un modèle DFM (Boivin et Ng (2006), Bai et Ng (2008), Banbura, Giannone, et Reichlin (2010), Barhoumi et al. (2013)). Cette démarche repose sur des considérations empiriques, mais les implications théoriques de ces choix de sélection sont rarement discutées. Dans la littérature, différentes stratégies ont été adoptées. Boivin et Ng (2006) retiennent 40 séries parmi 147, tandis que Banbura, Giannone, et Reichlin (2010) en choisissent 24 a priori — comme André et Bessec (2024), Antolin-Diaz, Drechsel, et Petrella (2017) et Drechsel, Antolin-Diaz, et Petrella (2024), avec respectivement 60, 24 et 29 séries. Linzenich et Meunier (2024) partent d'un ensemble de 540 séries, qu'ils ramènent à 81 puis 31 à l'aide d'une procédure de présélection structurée[6].

3.2.1 La préselection d'après la corrélation directe entre une variable et la variable cible

Dans cette lignée, et conformément au principe de parcimonie souvent retenu en modélisation économique, nous choisissons de présélectionner les séries afin de limiter le bruit issu de

[6] « Our final preselection consisted of 79 monthly and 2 quarterly series, where industrial activity (31%), retail sales (20%) and surveys (12%) represented the largest shares » (page 32), et l'on dénombre 31 variables dans la figure 7 (page 27) de Linzenich et Meunier (2024).

variables peu informatives. Il n'existe toutefois pas de consensus sur la méthode de présélection à privilégier. La littérature propose à la fois des approches non supervisées, qui exploitent uniquement la structure statistique des séries, et des approches supervisées, qui visent à modéliser explicitement leur lien avec une variable cible. C'est le cas de la méthode introduite par Bair et al. (2006) qui vise à prévoir une variable cible Y (par exemple la première estimation du PIB trimestriel dans notre cas) à partir d'un ensemble élargi d'indicateurs $X_1, X_2, \dots, X_p$ (tels que la production industrielle, les stocks, les prix du pétrole, etc.). Toutes les variables n'étant pas informatives, une étape de présélection s'impose pour améliorer la précision des prévisions. Dans notre cas, le choix entre les différentes méthodes est également guidé par des contraintes techniques, telles que l'existence de données manquantes ou l'hétérogénéité des périodes de disponibilité.

La méthode de Bair et al. (2006) repose sur une étape de filtrage supervisé, consistant à ne retenir que les variables présentant une relation statistiquement significative avec Y. La sélection peut être affinée en fixant un seuil de significativité ou en conservant un nombre déterminé de variables les mieux classées selon leur degré de corrélation avec la variable cible.

Pour chaque variable explicative X_j, on estime la régression linéaire suivante :

$$Y_t = \alpha_0 + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \beta_j X_{jt} + \epsilon_t$$

On teste ensuite l'hypothèse nulle $H_0 : \beta_j = 0$ à l'aide de la statistique t classique associée à $\hat{\beta}_j$:

$$t_j = \frac{\hat{\beta}_t}{SE(\hat{\beta}_t)}$$

La variable X_j est retenue si $|t_j| > t_{\text{threshold}}$, où $t_{\text{threshold}} = 1.96$ pour un seuil de confiance de 5 %.

Nous avons appliqué cette méthode de deux manières distinctes. D'une part, en réalisant l'analyse sur deux sous-périodes : avant le Covid (1995T1–2019T4) et après le Covid (2021T4–2025T2). La force de la corrélation entre la première estimation du PIB et les différentes séries de notre base est illustrée respectivement dans Figure 3 (période pré-Covid) et Figure 4 (période post-Covid).

La comparaison des deux périodes fait apparaître des changements notables dans l'ensemble des variables les plus corrélées au PIB. Avant la crise sanitaire, les indicateurs dominants appartiennent essentiellement aux groupes *Activité* et *Consommation, commandes et stocks*, représentées respectivement en rouge et en bleu clair. La première variable internationale qui se détache est l'indice de production industrielle en Allemagne (STSINPRMALL), suggérant une certaine sensibilité aux conditions extérieures. Le taux de chômage (UNERTMT) et un indicateur d'enquête dans la construction complètent le top 20, reflétant la difficulté des entreprises à accroître leur production face à une demande croissante (001586922).

À l'inverse de la période pré-Covid, la période post-Covid se caractérise par une plus forte présence d'indicateurs internationaux (en bleu foncé) parmi les variables les plus corrélées. Le *nowcast* hebdomadaire du commerce mondial de services (NOWCSERV) arrive en tête, suivi notamment de l'indice de production industrielle manufacturière américaine (IPMAN), de l'indice des prix à la production dans l'industrie manufacturière aux États-Unis (PCUOMFGOMFG), ainsi que du taux d'intérêt américain à 10 ans (IRLTLT01FRM156N).

Figure 3: Preselection: Pre Covid

Notes : La taille des mots reflète l'intensité de la corrélation avec la croissance trimestrielle du PIB. Les 20 variables les plus corrélées apparaissent en couleurs pleines ; les autres en teintes transparentes. Les couleurs correspondent aux différentes catégories de variables. Sources : Calculs des auteurs.

Les tensions sur le marché du travail sont également bien représentées dans les dix premières variables, avec par exemple le taux de chômage des jeunes au sens du BIT (UNERTM25) ou encore les demandeurs d'emploi en fin de mois (catégories A, B et C, DEFM). On retrouve aussi quelques indices boursiers (CAC, DAX). Enfin, parmi les vingt variables les plus corrélées à la première estimation du taux de croissance trimestriel du PIB, ce sont davantage des variables dites "dures" (consommation, chiffres d'affaires, production industrielle, trafic aérien, immatriculations, etc.) qui ressortent, contrairement à la période pré-Covid où les données d'enquêtes étaient davantage représentées. Le faible nombre d'observations disponibles sur la période post-Covid (au maximum 14) rend néanmoins cette présélection fragile et invite à une interprétation prudente.[7]

Dans un second temps, dans la perspective de développer un modèle utilisable sur l'ensemble de la période, nous avons adopté une approche complémentaire de séléction. Une présélection a été réalisée sur l'échantillon complet à l'aide d'une fenêtre glissante de quatre ans, avancée d'un trimestre à la fois, couvrant la période de janvier 1995 à mars 2025. Pour chaque fenêtre, nous avons recensé le nombre de fois où chaque série apparaissait parmi les 40 variables

[7] La stabilité de la pré-sélection fera l'objet d'un travail ultérieur, une fois qu'un plus grand nombre de données sera disponible.

les mieux classées. Nous avons ensuite tenu compte du nombre de fenêtres pour lesquelles chaque série était éligible à la sélection (c'est-à-dire effectivement présente dans la base de données à cette date). Enfin, nous avons calculé un ratio correspondant à la fréquence de sélection conditionnelle à la présence de la série dans l'échantillon. La hiérarchie issue de cette présélection est représentée dans Figure 5.

Figure 4: Preselection : Post Covid

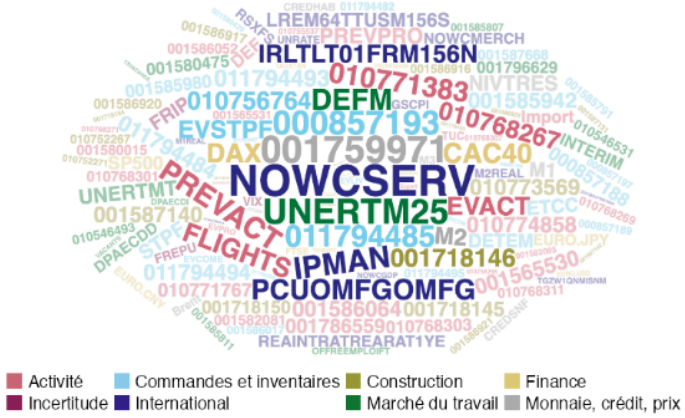

Notes : Variables présélectionnées sur la période post-Covid (2021 T4 – 2025 T1). Voir la note précédente. Sources : Calculs des auteurs.

Figure 5: Présélection avec fenêtres glissantes

Notes : La figure présente les variables les plus fréquemment sélectionnées, conditionnellement à leur disponibilité dans l'échantillon, en moyenne sur la période 1995–2025 à l'aide de fenêtres glissantes de cinq ans. Voir note précédente. Sources : Calculs des auteurs.

3.2.2 La méthode LARS pour éviter l'information redondante

Nous l'avons indiqué précédemment, nous avons utilisé une méthode *t-stat* permettant de passer outre le problème de la méthode LARS (*Least Angle Regressions*, ci-dessous) lorsque le nombre d'observations est plus faible que le nombre de variables. Une des qualités de la méthode LARS est d'éviter la redondance de variables contrairement à la méthode supervisée de Bair et al. (2006) qui ne tient compte que de la corrélation entre une variable X et la variable cible y[8], ici le taux de croissance trimestriel du PIB (première version). La méthode LARS, introduite par Efron et al. (2004), est une technique de sélection de variables qui construit un modèle linéaire en avançant étape par étape vers les variables les plus utiles pour expliquer la variable cible y.

Elle commence par choisir la variable la plus corrélée avec y, puis ajoute progressivement d'autres variables (autrement dit, les variables "s'activent" au fur et à mesure), en ajustant leurs coefficients selon la contribution conditionnelle de chaque variable, c'est-à-dire ce qu'elle ajoute en plus des variables déjà sélectionnées.

Le modèle est de la forme :

$$y = X\beta + \varepsilon, \text{ où } \hat{\varepsilon} = y - X\hat{\beta}$$

LARS utilise la corrélation au début, puis ajuste les coefficients de manière itérative, en analysant à chaque étape les résidus $\hat{\varepsilon}$, c'est-à-dire ce qui reste à expliquer. Cette approche est très efficace quand il y a beaucoup de variables, et permet de construire des modèles parcimonieux tout en étant plus rapide que les approches classiques comme la sélection par pas (*e.g stepwise selection, Hastie, Tibshirani, et Friedman (2009)*) ou le LASSO (*Least Absolute Shrinkage and Selection Operator*, Tibshirani (1996)). C'est ce que nous faisons sur la période 1995 T1 - 2025 T1 en enlevant la période du Covid allant de 2020 T1 à 2021 T3 (inclus). Cette méthode nécessitant un panel cylindré, seules 86 variables sont testées. Les résultats sont illustrés dans Figure 6. Comme test de robustesse, nous réalisons la pré-sélection sur un échantillon plus court (de mars 1995 à mars 2005) et nous réalisons l'exercice ensuite en ajoutant un point à chaque fois. Les résultats sont illustrés dans la Figure 19.

[8] Une variable peut être fortement corrélée directement à y, mais avoir un coefficient proche de zéro si son information est redondante avec une autre variable déjà incluse dans un modèle incluant ces deux variables.

Figure 6: Préselection avec la méthode LARS

Notes : Variables présélectionnées sur toute la période hors Covid (1995 T1 - 2025 T1 hors 2020 T1 – 2021 T3). La taille des mots reflète l'ordre à partir duquel les variables deviennent actives. Voir note précédentes. Sources : Calculs des auteurs.

3.3 Les différents modèles testés

À partir des trois méthodes de pré-sélection de variables envisagées, nous construisons trois modèles distincts (A, B, C), auxquels s'ajoute un modèle hybride *(C+)*:

- le modèle A: il repose sur les variables pré-sélectionnées selon la méthode proposée par Bair et al. (2006) appliquée sur des fenêtres glissantes (cf. Figure 5). Nous en déclinons plusieurs versions, composées respectivement des 10 à 40 premières variables retenues, par incréments de 5.
- le modèle B: il tient compte des éventuels changements structurels entre les périodes pré- et post-Covid. Il est construit à partir des variables les mieux classées dans chaque sous-période selon la méthode de pré-sélection individuelle (cf. Figure 3 et Figure 4). Pour chaque sous-période, nous retenons les 10 (resp. 15, 20, ..., 40) meilleures variables, puis nous prenons leur union. Les modèles ainsi obtenus comprennent entre 20 et 70 variables[9].
- le modèle C: ce modèle est contruit à partir d'une pré-sélection avec la méthode LARS. De même que pour le modèle A, nous en déclinons plusieurs versions, composées respectivement des 10 à 40 premières variables retenues, par incréments de 5.

[9]Nous rappelons que le modèle B noté avec 10 variables correspond en réalité à l'union des 10 premières variables présélectionnées sur la période pré-Covid et des 10 premières variables présélectionnées sur la période post-Covid, soit un total de 20 variables. Cette construction illustre la forte hétérogénéité de la présélection entre les deux périodes.

- le modèle C+: il correspond aux différentes versions du modèle C (comportant entre 10 et 40 variables), enrichies de cinq variables additionnelles. Celles-ci ont été choisies pour leur caractère original : certaines sont récentes (*e.g.* *nowcast*, trafic aérien), d'autres jugées particulièrement pertinentes dans le contexte, comme le nombre de défaillances d'entreprises.

Une fois ces quatre ensembles de modèles définis – chacun décliné en sept versions, totalisant 28 modèles –, nous déterminons, pour chacun, le nombre optimal de retards et de facteurs à retenir.

3.4 Choix des paramètres

Bien que l'estimation et l'utilisation du modèle à facteurs dynamiques (DFM) pour le *nowcasting* soient relativement simples grâce à la boîte à outils proposée par Linzenich et Meunier (2024), le modélisateur doit néanmoins spécifier plusieurs paramètres clés pour le modéliser à l'aide d'un MFD le lien entre les variables pré-sélectionnées et la variable cible:

- r : le nombre de facteurs retenus pour synthétiser l'information utile à la prévision de la variable cible (y_t) ;
- p : le nombre de retards dans le processus VAR régissant la dynamique des facteurs communs ;
- ρ : qui peut être fixée à zéro, auquel cas la composante idiosyncratique ε_t est supposée suivre un bruit blanc i.i.d.

Dans les prochaines sous-sections nous allons détailler la procédure utilisée pour choisir la spécification du MFD retenu pour chaque jeu de variables préselectionnés.

3.4.1 Nombre de facteurs r

Pour déterminer le nombre de facteurs à inclure dans le modèle, nous pourrions nous appuyer sur l'approche fondée sur les critères d'information proposée par Bai et Ng (2002). Toutefois, ces critères reposent sur les propriétés asymptotiques des MFD (tant dans leur dimension temporelle comme en coupe transversale) en posant des hypothèses fortes. Ce type de critère d'information sélectionne dans la pratique à échantillon fini, des modèles avec le maximum de facteurs possibles (les résultats empiriques des trois critères par les auteurs sont présentés dans Table 8). L'ensemble des résultats selon les 3 critères de Bai et Ng (2002) sont présentés en annexe.

Toutefois, les conditions d'application des critères de Bai et Ng (2002) sont trop contraignants et nous avons utilisé un critère *ad hoc* usuellement utilisé dans la littérature pratique du *nowcasting*. Ce critère utilise aussi les propriétés in sample des facteurs et consiste à compter le nombre de facteurs (estimés par une ACP) qui permettent d'expliquer au moins 10 % de la

Table 1: Spécifications sélectionnées pour chaque configuration possible

Configuration	Nombre de variables (N)	Retards (p)	Facteurs (r)
Modèle A			
10	10	2	3
15	15	2	2
20	20	2	3
25	25	2	3
30	30	2	3
35	35	2	3
40	40	2	3
Modèle B			
10	20	3	3
15	29	2	3
20	39	2	3
25	47	2	3
30	55	2	3
35	62	3	3
40	70	3	3
Modèle C			
10	10	2	3
15	15	2	2
20	20	3	2
25	25	4	2
30	30	3	2
35	35	3	3
40	40	3	3
Modèle C+			
10	15	2	3
15	20	2	2
20	25	3	2
25	30	4	2
30	35	3	2
35	40	3	3
40	45	3	3

Source: Calcul des auteurs

variance totale de l'échantillon. Ce critère, moins fondé sur les propriétés asymptotiques du MFD, est facile à rendre opérationnel.

3.4.2 Nombre de retards dans le procesus des facteurs p

Après avoir calculé le nombre de facteurs par configuration de variables et de les avoir estimés à l'aide d'une anaylse en composantes principales (ACP), nous avons déterminé l'ordre du VAR régissant leur dynamique en utilisant différents critères usités dans ces modèles (AIC, HQ, SC et FPE). Parmi les quatre critères nous avons retenu le minimum des retards p afin d'avoir les modèles les plus simples possibles. Les spécifications finalement retenues sont affichées dans Table 1.

3.5 Nombre de variables N

Une fois les couples (p, r) identifiés pour chacun des modèles, et différenciés selon le nombre de variables sélectionnées, nous procédons à la détermination du nombre optimal de ces dernières. Pour ce faire, nous évaluons la performance prédictive des modèles en pseudo-temps réel, sur l'ensemble de la période hors Covid ainsi que sur deux sous-échantillons distincts : avant et après la période Covid.

Nous évaluons la capacité prédictive hors échantillon à l'aide d'un exercice en pseudo-temps réel. Idéalement, nous aurions souhaité nous placer en situation réelle, c'est-à-dire disposer, à chaque date d'évaluation, exactement des données disponibles à cette date. Au-delà des délais de publication, les données font l'objet de révisions à chaque nouvelle diffusion. Notre exercice ne prend pas en compte ces révisions, mais uniquement une version stylisée des délais de publication. Comme c'est souvent le cas dans la littérature, nous reproduisons pour chaque mois le calendrier de publication observé lors de la dernière mise à jour de notre base de données. Cette approche, réaliste mais approximative, ne tient pas compte des variations mensuelles des délais, liées notamment au calendrier des jours ouvrés. À chaque date t d'évaluation, nous reconstruisons un jeu de données reproduisant la structure des retards de publication observée lors de notre dernière mise à jour (ici le 30 juin 2025). Le modèle est ensuite estimé de manière récursive, avec un jeu de paramètres donné, en utilisant uniquement les données disponibles à la date t. Faute de disposer de données en temps réel pour de nombreuses séries, notre procédure néglige l'effet des révisions sur la qualité prédictive du modèle. La constitution progressive de notre base nous permettra, à l'avenir, de conserver un jeu de données pour chaque millésime et de réaliser des exercices en temps réel plus réalistes.

Les résultats portant sur l'ensemble de la période (hors Covid) sont présentés dans la Figure 7. L'évaluation détaillée de chacun des modèles (A, B, C et C+), en fonction du nombre de variables, pour les périodes pré- et post-Covid, est fournie en Annexe, aux Figure 17 et Figure 18.

Pour le modèle A, l'erreur quadratique moyenne (RMSE) varie peu en fonction du nombre de variables incluses, à l'exception notable du mois 3, pour lequel une sensibilité plus marquée est observée. La spécification qui minimise le RMSE sur la période d'évaluation retient 10 variables. De manière analogue, les résultats suggèrent une préférence pour une spécification parcimonieuse dans le cas du modèle B, le modèle optimal contenant 20 variables[10]. En revanche, pour le modèle C, aucun consensus clair ne se dégage ; nous retenons alors la spécification qui minimise le RMSE sur l'ensemble du trimestre, soit 25 variables. Enfin, le modèle dit *hybride* (C+) se révèle plus performant avec 30 variables, correspondant aux 25 retenues pour le modèle C, auxquelles s'ajoutent 5 variables spécifiques[11].

[10] Nous rappelons que le modèle B noté avec 10 variables correspond en réalité à l'union des 10 premières variables présélectionnées sur la période pré-Covid et des 10 premières variables présélectionnées sur la période post-Covid, soit un total de 20 variables. Cette construction illustre la forte hétérogénéité de la présélection entre les deux périodes.

[11] Soit DEF, FLIGHTS, NOWCMERCH, NOWCSERV, NOWCGDP.

Figure 7: Nombre optimal de variables par modèle et horizon temporel - 2010-2025

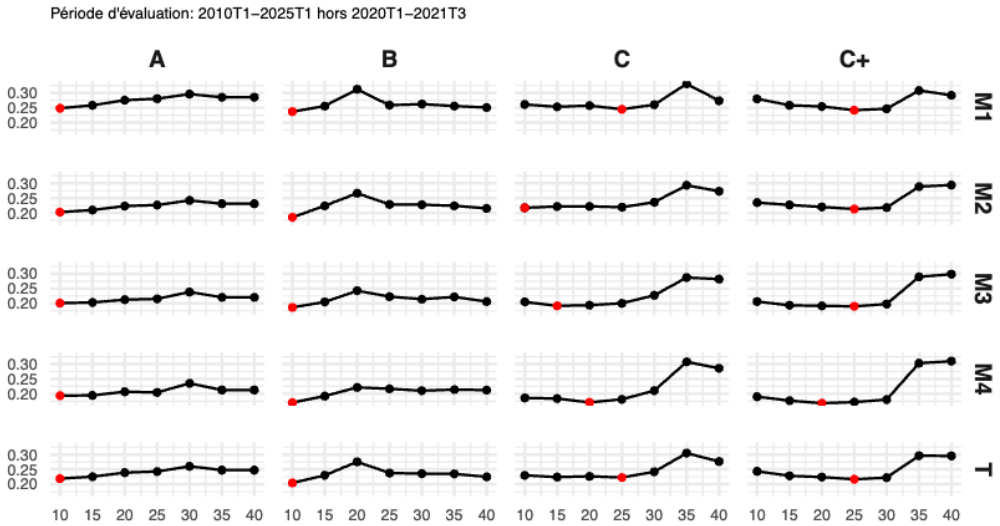

Notes: Le nombre de variables est représenté en abscisse, tandis que le RMSE figure en ordonnée. Pour les modèles B et C, le nombre de variables est plus important que celui affiché en abscisse (section –Les différents modèles testés–). On retrouve en colonnes les différents modèles et en lignes les horizons (Mois 1, 2, 3, 4 et le Trimestre (= M1, M2, M3)). L'évaluation a été réalisée à partir de données arrêtées au 30 juin 2025.
Source : Calculs des auteurs.

Finalement, les caractéristiques des modèles dont nous allons évaluer la performance en pseudo-temps réel sur différentes périodes sont décrites dans le tableau suivant (Table 2). La liste des variables incluses dans chaque modèle est présentée dans le tableau Table 7.

Table 2: Spécifications retenues pour chaque modèle

Modèle	Nombre de variables (N)	Retards (p)	Facteurs (r)
A	10	2	3
B	20	3	3
C	25	4	2
C+	30	4	2

4 Résultats

Afin d'évaluer les propriétés prédictives de nos spécifications retenues, nous analysons leur performance *out-of-sample* à travers un exercice de prévision en pseudo-temps réel (précédemment défini), conformément aux pratiques usuelles dans la littérature. À l'instar de André et Bessec (2024), nous nous concentrons sur la période allant de janvier 2010 à décembre 2024. Dans cet exercice, nous supposons que les observations de l'année 2020 sont manquantes.

Il convient de noter que, pour les spécifications retenues, nous disposons de [12]:

- Mois 1 : 10 % des données du trimestre sont disponibles pour le Modèle A, 5 % pour le Modèle B, 12 % pour le modèle C et 14 % pour le modèle C+ ;
- Mois 2 : 36 % (modèle A), 27 % (B), 35 % (C) et 38 % (C+) ;
- Mois 3 : 70 % (A), 60 % (B),68% (C) et 70 % (C+);
- Mois 4 (*backcasting*) : 93 % (A), 88 % (B), 90% (C) et 91 % (C+).

Compte tenu de la disponibilité croissante des données au fil du trimestre, on observe une amélioration du RMSE en pseudo-temps réel. Sur la période pré-Covid (2010–2019), le RMSE du Modèle A diminue de 0,232 au premier mois à 0,155 au troisième mois. Pour le Modèle B, il passe de 0,236 en début de trimestre à 0,160 au troisième mois. Pour le modèle C, il passe de 0,257 à 0,170 et enfin pour le modèle C+ il passe de 0,256 à 0,160. Dans tous les cas, les modèles offrent des gains de précision par rapport à une prévision fondée sur un modèle autorégressif (noté AR) (Table 3).

Si l'on se focalise sur la période post-Covid (2022–2024), le constat est un peu modifié. Le Modèle A, qui exploite la pré-sélection tenant compte de la corrélation des variables avec la première estimation de la croissance trimestrielle du PIB, affiche une performance proche à celle d'un modèle AR. Nous constatons que la prise en compte spécifique des ruptures suscitées par la crise Covid (ce qu'il est possible de constater avec le peu de recul dont nous disposons) est importante. Ainsi, le modèle B, qui implicitement surpondère l'importance de la préselection faite sur la période post-Covid permet d'améliorer significativement la capacité prédictive par rapport à un modèle naïf (RMSE de 0,214 en moyenne au cours du trimestre contre 0,310 pour l'AR) en gardant ses capacités prédictives par rapport à la période pré-Covid. Les modèles C et C+ gardent eux aussi une bonne capacité prédictive en pseudo temps réel, sur la période post-Covid.

Ce résultat suggère la nécessité de poursuivre le travail de sélection des indicateurs utilisés, car la crise du Covid semble bien avoir constitué une rupture dans la qualité prédictive des modèles traditionnellement mobilisés. Ce constat a d'ailleurs été souligné pour le cas français par Bourassi, Claisse, et Phung (2024), et notre analyse va dans le même sens.

[12] Ces calculs ont été arrêtés au dernier jour du mois concerné.

Table 3: Évaluation en pseudo-temps réel (RMSE)

Modèle	Trimestre	Mois 1	Mois 2	Mois 3	Mois 4
Post-Covid					
AR	0.310	0.263	0.230	0.401	0.407
A	0.284	0.297	0.260	0.294	0.312
B	0.214	0.238	0.189	0.211	0.203
C	0.210	0.207	0.211	0.211	0.216
C+	0.208	0.200	0.210	0.212	0.209
Pré-Covid					
AR	0.278	0.276	0.279	0.279	0.273
A	0.197	0.232	0.184	0.169	0.155
B	0.201	0.236	0.184	0.178	0.160
C	0.227	0.257	0.222	0.197	0.170
C+	0.219	0.256	0.214	0.182	0.160
Toute la période (hors Covid)					
AR	0.286	0.272	0.267	0.311	0.306
A	0.219	0.248	0.203	0.201	0.194
B	0.204	0.237	0.185	0.187	0.170
C	0.222	0.245	0.220	0.200	0.181
C+	0.217	0.242	0.213	0.190	0.172

Notes: Les RSME reportés sont le résultat d'une analyse en pseudo-temps réel réalisée avec une base de données compilée le 30 juin 2025, sur la période 2010 T1 -2025 T1. Nous considérons la période Covid comme allant de 2020 T1 à 2021 T3 inclus. Source: Calculs des auteurs.

Table 4: Évaluation en pseudo-temps réel (FDA)

Modèle	Trimestre	Mois 1	Mois 2	Mois 3	Mois 4
Post-Covid					
AR	0.700	0.385	0.846	0.857	0.846
A	0.575	0.385	0.769	0.571	0.615
B	0.650	0.615	0.615	0.714	0.615
C	0.700	0.692	0.692	0.714	0.846
C+	0.650	0.692	0.615	0.643	0.692
Pré-Covid					
AR	0.558	0.325	0.675	0.675	0.700
A	0.808	0.700	0.825	0.900	0.900
B	0.792	0.675	0.800	0.900	0.900
C	0.767	0.650	0.825	0.825	0.875
C+	0.758	0.650	0.825	0.800	0.875
Toute la période (hors Covid)					
AR	0.594	0.340	0.717	0.722	0.736
A	0.750	0.623	0.811	0.815	0.830
B	0.756	0.660	0.755	0.852	0.830
C	0.750	0.660	0.792	0.796	0.868
C+	0.731	0.660	0.774	0.759	0.830

Notes: Les FDA reportés sont le résultat d'une analyse en pseudo-temps réel réalisée avec une base de données compilée le 30 juin 2025, sur la période 2010 T1 -2025 T1. Nous considérons la période Covid comme allant de 2020 T1 à 2021 T3 inclus. Source: Calculs des auteurs.

En se concentrant sur la capacité des différents modèles à anticiper le sens de l'évolution du PIB trimestriel (hausse ou baisse par rapport au trimestre précédent), on observe que les modèles A, B et C prédisent correctement cette direction (notée FDA, *Forecast Directional Accuracy*) dans plus de 75 % des trimestres sur l'ensemble de la période d'analyse hors Covid (Table 4). Tous les modèles font mieux que l'AR sur l'ensemble de la période selon cette métrique. Sur la période post-Covid, le FDA diminue pour tous les modèles et seul le modèle C arrive à capturer le sens des mouvements du PIB aussi bien que le modèle AR.

Pour la suite de l'analyse, nous allons nous concentrer sur les deux modèles qui ont les capacités prédictives qui nous semblent plus adéquates: les modèles B et C+ (Figure 8). Ces modèles se distinguent à la fois par leur faible RMSE sur l'ensemble de la période et la résilience de leurs performances sur la période post-Covid.

Figure 8: Prévision en pseudo temps réel à la fin de chaque mois du trimestre

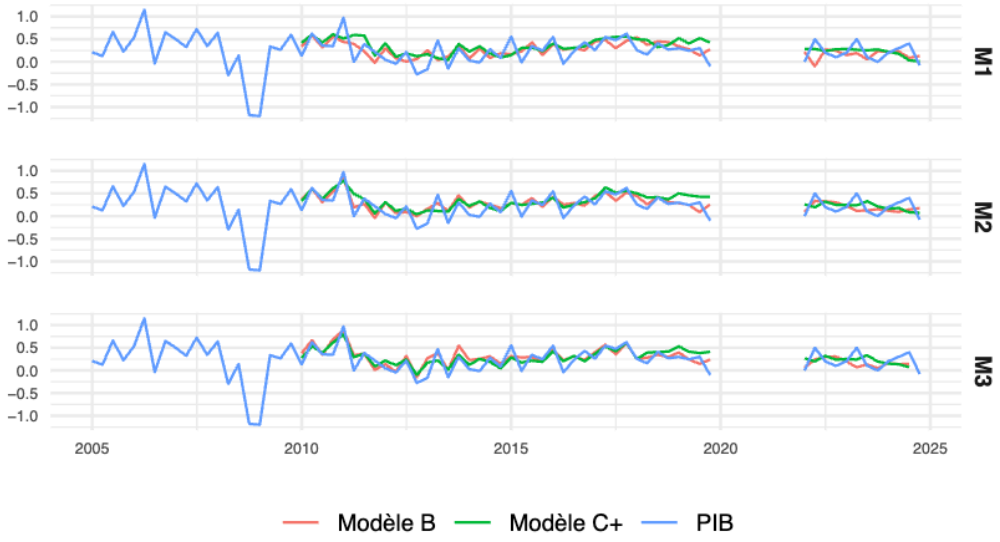

Notes: PIB correspond au taux de croissance trimestriel du PIB (première estimation)
L'évaluation a été réalisée à partir des données arrêtées au 30 juin 2025, sur la période 2020 T1–2025 T1.
Source : Insee, Calculs des auteurs.

Dans la section suivante, nous évaluons la robustesse des résultats en modifiant successivement certaines hypothèses structurelles des modèles. Des exercices de robustesse sont menés, avec une attention particulière portée à la période Covid, afin d'examiner la stabilité des résultats et la nécessité d'ajustements sur les données de 2020–2021.[13].

[13]Par exemple, dans les exercices présentés ici, l'année 2021 est considérée comme une année « normale », alors même qu'elle a également été affectée par la dynamique des mesures sanitaires.

5 Robustesse

5.1 Corrections liées à la période Covid

Une décision de modélisation importante concerne le traitement de la période de crise liée au Covid-19 (2020–2021), durant laquelle les séries macroéconomiques ont connu des dynamiques particulièrement erratiques, du fait du caractère exceptionnel des mesures de confinement et d'endiguement — à commencer par le PIB lui-même (voir Figure 1). Dans cette analyse, nous retenons l'approche de André et Bessec (2024), qui consiste à traiter les données de l'année 2020 comme manquantes.

Lenza et Primiceri (2022) montrent que la stratégie *ad hoc* consistant à supprimer les observations extrêmes peut être satisfaisante pour l'estimation des paramètres mais qu'ignorer ces données dans le processus de prévision peut sous-estimer l'incertitude associée aux prévisions. C'est pourquoi, l'évaluation de stratégies alternatives constitue une piste essentielle pour tester la robustesse des résultats. C'est l'objet de l'exercice présenté ci-après.

Nous évaluons la sensibilité de la qualité prédictive en comparant six approches distinctes à un scénario de référence. Plus précisément, nous calculons le ratio entre le RMSE obtenu pour chaque stratégie, relativement à celui obtenu dans la spécification de base, sur la période allant de janvier 2010 à mars 2025.

Les cinq approches testées sont les suivantes :

1. Ne rien faire.
2. Deux variables muettes sont introduites (pour juin 2020 et septembre 2020).
3. Deux variables muettes sont ajoutées (pour mars 2020 et juin 2020).
4. Une variable muette par trimestre est ajoutée entre mars 2020 et décembre 2021.
5. Une variable muette par trimestre est ajoutée entre février 2020 et décembre 2020.

Les résultats correspondants sont présentés dans Table 5. Ce tableau présente l'erreur quadratique moyenne (RMSE) de notre modèle de référence sur l'ensemble de la période, pour les modèles B et C+, dans la ligne *Baseline: mettre des NaN (de février à septembre 2020 inclus)*. Les autres lignes reportent, pour chaque horizon et chaque modèle, le rapport entre le RMSE d'une correction alternative et celui de cette spécification de référence. Un résultat constant ressort: la suppression des observations liées au Covid permet d'obtenir les meilleures performances prédictives. Aucune autre stratégie de correction ne parvient à améliorer le RMSE par rapport à cette configuration. À l'inverse, laisser le modèle tourner sans correction ou introduire des variables muettes tend à doubler, voire tripler le RMSE. La correction des valeurs extrêmes donne des résultats proches de la baseline dans le modèle B pour les premiers mois du trimestre, mais sa performance se dégrade nettement en *backcast*

Table 5: Corrections liées au Covid

	Correction Covid	Trimestre entier	Mois 1	Mois 2	Mois 3	Mois 4
	Baseline: mettre des NaN (de fev. 2020 à sept. 2020 inclus)	*0.20*	*0.24*	*0.19*	*0.19*	*0.17*
	Ne rien faire	2.56	2.64	2.46	2.53	2.95
	Ajouter dummies (juin 2020 & septembre 2020)	2.37	2.60	2.44	1.86	3.04
B	Correction des valeurs aberrantes (remplacées par NaN)	1.04	1.00	1.11	1.05	2.42
	Ajouter dummies (mars 2020 & juin 2020)	2.17	2.31	2.33	1.75	3.00
	Ajouter dummies (de mars 2020 à déc. 2021)	2.26	2.44	2.43	1.73	3.08
	Ajouter dummies (2020)	2.16	2.29	2.32	1.74	2.98
	Baseline: mettre des NaN (de fev. 2020 à sept. 2020 inclus)	*0.22*	*0.24*	*0.21*	*0.19*	*0.17*
	Ne rien faire	2.24	2.58	2.13	1.75	2.92
	Ajouter dummies (juin 2020 & septembre 2020)	1.74	1.77	1.55	1.93	2.69
C+	Correction des valeurs aberrantes (remplacées par NaN)	-	-	-	-	-
	Ajouter dummies (mars 2020 & juin 2020)	1.73	1.76	1.53	1.92	2.70
	Ajouter dummies (de mars 2020 à déc. 2021)	1.84	1.81	1.61	2.15	2.44
	Ajouter dummies (2020)	1.83	1.80	1.60	2.13	2.70

Note de lecture: Dans le Modèle B, la qualité prédictive sur le trimestre s'élève à 0,20 lorsque les observations de la période Covid sont supprimées (*baseline*). En revanche, ne procéder à aucun ajustement conduit à plus que doubler l'erreur quadratique moyenne (RMSE), avec un ratio de 2,56. Autrement dit, la RMSE passe de 0,204 à 0,522, soulignant la dégradation importante de la performance du modèle en l'absence de correction spécifique.
Note: À l'exception de la ligne *Baseline: mettre des NaN (de février 2020 à septembre 2020 inclus)*, les valeurs reportées correspondent au rapport entre le RMSE de la spécification de référence (*baseline*) et celui d'une spécification alternative, pour chaque modèle et chaque horizon. Un ratio supérieur à 1 signale une dégradation de la performance prédictive du modèle, tandis qu'un ratio inférieur à 1 indique qu'une correction liée au Covid améliore le RMSE. Les tests de robustesse ont été effectués via une évaluation en pseudo-temps réel avec une base de données compilée le 30 juin 2025 et sur la période 2010 T1-2025 T1 (hors Covid). Le résultat *baseline* pour chaque modèle est le même que celui dans la Table 3 pour toute la période (hors Covid) et pour chaque modèle.
Sources: Calculs des auteurs.

(mois 4), avec un RMSE plus que doublé (2,42). En définitive, la stratégie consistant à exclure les données Covid apparaît comme la plus robuste.

5.2 Différentes spécifications

Outre la période exceptionnelle qu'a constituée la crise du Covid, et dans un souci de tester la robustesse de nos modèles — et donc la stabilité de nos résultats — nous proposons trois modifications des spécifications de base :

- nous relâchons l'hypothèse selon laquelle les composantes idiosyncratiques suivent un bruit blanc. Dans le cadre de base, ces composantes sont supposées i.i.d., autrement dit $\rho_i = 0$ pour tout i. Nous considérons ici qu'elles suivent un processus autorégressif d'ordre 1, avec $\rho_i \neq 0$ pour tout $i = 1, \dots, N$.
- nous ajoutons un facteur supplémentaire à chaque spécification.
- nous retirons un retard dans la dynamique des facteurs de chaque modèle.

La Table 6 présente, pour chaque horizon de prévision, un indicateur de performance relative : le ratio entre le RMSE du modèle baseline (voir Table 3) et celui obtenu avec chaque

spécification alternative[14]. Une valeur supérieure à 1 indique que le modèle alternatif est plus performant que le modèle baseline, car il affiche un RMSE plus faible. À l'inverse, une valeur inférieure à 1 signifie que le modèle baseline donne de meilleurs résultats. Une valeur égale à 1 traduit une performance équivalente entre les deux modèles.

Concentrons-nous uniquement sur l'ensemble de la période hors Covid.

Modifier la dynamique des composantes idiosyncratiques n'améliore pas les performances des modèles, à l'exception du modèle C. Cette amélioration reste toutefois marginale sur l'ensemble du trimestre, le RMSE diminuant de moins de 0,01.

L'ajout d'un facteur supplémentaire n'a qu'un effet limité sur les modèles A et C. Le modèle C affiche même un *backcast* légèrement meilleur que son *baseline*, principalement en raison des résultats obtenus sur la période post-Covid. En revanche, cette modification dégrade plus nettement les performances des modèles B et C+, avec une hausse du RMSE comprise entre 0,02 et 0,04.

Enfin, lorsqu'un retard est retiré dans la dynamique autorégressive des facteurs, les résultats restent quasi identiques pour l'ensemble des modèles et horizons. Une exception concerne le modèle B, pour lequel la prévision en début de trimestre (notamment au Mois 1, et dans une moindre mesure au Mois 2) est légèrement améliorée avec cette spécification.

Dans l'ensemble, les résultats confirment la robustesse des spécifications retenues. Les modifications apportées — qu'il s'agisse d'ajouter un facteur, de retirer un retard ou de modifier la dynamique des composantes idiosyncratiques — n'améliorent que marginalement les performances des modèles, voire les dégradent.

[14] Il s'agit donc du ratio suivant : $\frac{\text{RMSE}_{baseline}}{\text{RMSE}_{alternatif}}$

Table 6: Tests de différentes spécifications

			Trimestre	M1	M2	M3	M4
Les composantes idiosyncratiques suivent un AR(1)							
	Post Covid						
		A	0.96	0.93	0.97	0.97	0.99
		B	0.70	0.74	0.66	0.68	0.64
		C	0.76	0.77	0.76	0.75	0.79
		C+	0.74	0.71	0.76	0.74	0.74
	Pré Covid						
		A	0.99	0.99	1.00	0.99	1.00
		B	0.95	0.94	0.95	0.99	0.99
		C	1.16	1.15	1.17	1.15	1.14
		C+	1.12	1.13	1.14	1.07	1.07
	Toute la période						
		A	0.98	0.98	0.99	0.99	0.99
		B	0.86	0.88	0.84	0.86	0.84
		C	1.06	1.08	1.06	1.03	1.06
		C+	0.93	0.94	0.93	0.90	0.92
Un facteur en plus							
	Post Covid						
		A	0.97	0.96	0.97	0.99	0.99
		B	0.68	0.74	0.64	0.66	0.62
		C	0.84	0.89	0.81	0.82	0.90
		C+	0.60	0.56	0.60	0.66	0.68
	Pré Covid						
		A	0.97	0.96	0.98	0.97	0.98
		B	0.96	0.99	0.91	0.99	1.00
		C	1.02	0.98	1.03	1.09	1.15
		C+	1.05	1.07	1.04	1.04	1.02
	Toute la période						
		A	0.97	0.96	0.97	0.98	0.98
		B	0.87	0.91	0.82	0.86	0.85
		C	0.97	0.96	0.97	1.00	1.06
		C+	0.90	0.91	0.88	0.89	0.89
Un lag en moins							
	Post Covid						
		A	0.99	1.02	0.97	0.97	0.99
		B	1.08	1.25	1.01	0.99	0.69
		C	0.97	1.01	0.95	0.95	1.01
		C+	1.00	1.00	1.00	1.00	1.00
	Pré Covid						
		A	0.97	0.98	0.95	0.99	0.98
		B	1.01	1.01	1.01	0.99	0.99
		C	0.99	0.99	0.99	0.99	1.00
		C+	0.99	0.99	0.99	0.99	1.00
	Toute la période						
		A	0.98	0.99	0.96	0.98	0.98
		B	1.03	1.06	1.01	0.99	0.88
		C	0.99	0.99	0.98	0.98	1.00
		C+	0.99	0.99	0.99	0.99	1.00

Note de lecture: Lorsque l'on relâche l'hypothèse de composantes idiosyncratiques i.i.d., les performances des modèles se dégradent sur la période pré-Covid. En revanche, les modèles C et C+ présentent une meilleure qualité prédictive après la crise sanitaire. Sur l'ensemble de la période (hors Covid), seul le modèle C parvient à améliorer son RMSE par rapport à une spécification dans laquelle les composantes idiosyncratiques suivent un bruit blanc.
Notes: Les valeurs présentées dans ce tableau correspondent au ratio entre le RMSE du modèle baseline (voir Table 3) et le RMSE obtenu pour chaque spécification alternative, à chaque horizon. Dans le premier test de robustesse, la dynamique autorégressive des composantes idiosyncratiques revient à considérer que ho_i est non nul dans l'équation (2). Enfin, les différentes spécifications testées dans les deux autres exercices de robustesse correspondent respectivement au retrait d'un retard ou à l'ajout d'un facteur, par rapport aux spécifications présentées dans la Table 2.
Sources: Calculs des auteurs.

6 Conclusion

Ce travail constitue une première étape dans la relance d'un dispositif de *nowcasting* du PIB français au sein de l'OFCE. Nous avons, dans un premier temps, construit une base de données inédite, composée de 136 séries économiques, conçue pour être librement diffusée. Cette base vise à alimenter l'effort collectif des chercheurs et des institutions impliqués dans la prévision économique à court terme.

Sur le plan empirique, les modèles à facteurs dynamiques que nous avons estimés à partir d'un sous-ensemble de variables (20 variables pour le Modèle B et 30 variables pour le modèle C+) affichent des performances de prévision comparables à celles documentées dans la littérature, du moins sur la période antérieure à la crise sanitaire. Ce résultat constitue un socle robuste pour la poursuite de nos développements.

Plusieurs axes d'amélioration restent néanmoins à explorer. La période récente appelle des ajustements méthodologiques, qu'il s'agisse de l'enrichissement de la base par de nouvelles séries, du traitement plus rigoureux des valeurs extrêmes, ou encore de la structuration des variables en blocs homogènes. Ces évolutions sont indispensables pour garantir la robustesse du dispositif dans un environnement macroéconomique devenu plus incertain.

À court terme, ces avancées permettront de relancer la publication régulière de prévisions infra-annuelles sur le site de l'OFCE, avec une première diffusion envisagée à l'automne 2025. À moyen terme, la structuration de la base et son actualisation automatisée ouvriront la voie à l'exploration de nouvelles approches méthodologiques. Celles-ci pourront s'appuyer sur des outils économétriques plus avancés largement mobilisés dans la littérature comparable — tels que les modèles BVAR de grande dimension ou les combinaisons de modèles bridge — ou mobiliser des méthodes issues de l'apprentissage automatique, comme les forêts aléatoires ou d'autres techniques de la science des données, censées mieux prendre en compte les relations non linéaires entre les variables.

7 Annexes

7.1 Décomposition des news

Cette section décrit la procédure mise en œuvre dans la boîte à outils pour calculer l'impact des nouvelles données. Il est essentiel de noter que, dans le cadre défini par Bańbura et Modugno (2014), une news désigne la composante inattendue d'une nouvelle publication, au regard des anticipations du modèle. Formellement, cela signifie que la prévision de y_t fondée sur une nouvelle version des données Ω_{v+1} s'écrit $E[y_t|\Omega_{v+1}]$. Ces nouvelles prévisions peuvent être décomposées en une combinaison de l'ancienne prévision $E[y_t|\Omega_v]$ et de la composante inattendue associée à la nouvelle information, notée I_{v+1}. Il est important de souligner qu'une publication conforme aux prévisions du modèle construit sur Ω_v ne constitue pas une news au sens de notre approche, telle que définie dans Linzenich et Meunier (2024) et Bańbura et Modugno (2014).

7.1.1 L'approche analytique

Lorsqu'une nouvelle information devient disponible, la prévision du PIB réel trimestriel produite par un modèle à facteurs dynamiques est mise à jour. Comprendre l'origine de cette révision est essentiel pour interpréter correctement le signal économique véhiculé par les données entrantes. Nous décomposons la variation de la prévision en trois composantes distinctes, selon le cadre proposé par Bańbura et Modugno (2014) : i) l'effet des révisions de données, ii) l'effet des news, iii) l'effet de la ré-estimation du modèle.

Formellement, notons :

- $\hat{y}_t^{\text{old}}$: la prévision du PIB au temps t, obtenue à partir de la version précédente des données ;
- $\hat{y}_t^{\text{rev}}$: la prévision obtenue à partir des données révisées (intégrant les corrections, mais sans nouvelles observations), en maintenant les paramètres du modèle constants ;
- $\hat{y}_t^{\text{new}}$: la prévision produite à partir du nouvel ensemble de données (comprenant les révisions et les nouvelles observations), avec des paramètres ré-estimés.

La révision totale de la prévision du PIB peut alors être décomposée comme suit :

$$\hat{y}_t^{\text{new}} - \hat{y}_t^{\text{old}} = \underbrace{(\hat{y}_t^{\text{rev}} - \hat{y}_t^{\text{old}})}_{\text{Data revision effect}} + \underbrace{\sum_{i \in \mathcal{N}} w_i \cdot (x_i^{\text{new}} - \hat{x}_i^{\text{old}})}_{\text{News effect}} + \underbrace{(\hat{y}_t^{\text{new}} - \hat{y}_t^{\text{rev+news}})}_{\text{Re-estimation effect}}$$

où :

- $\mathcal{N}$ désigne l'ensemble des séries pour lesquelles de nouvelles données ont été publiées ;

- $\hat{x}_i^{\text{old}}$ est l'estimation lissée de Kalman de la nouvelle observation x_i dans l'ancienne base de données ;
- w_i représente le poids (ou impact marginal) de l'observation x_i sur la prévision du PIB, tel qu'il découle de l'étape d'extraction du signal dans le modèle ;
- $\hat{y}_t^{\text{rev+news}}$ est la prévision obtenue en intégrant toutes les nouvelles données, mais en conservant les anciens paramètres du modèle.

Dans ce cadre, l'impact de chaque nouvelle donnée sur la variable cible est calculé en comparant la prévision issue du modèle initial avec celle obtenue après avoir incorporé, isolément, chaque source d'information nouvelle.

$$\sum_{i \in \mathcal{N}} w_i \cdot \left(x_i^{\text{new}} - \hat{x}_i^{\text{old}}\right)$$

représente une contribution totale, cohérente avec le modèle, de l'ensemble des news prises conjointement, mais ne permet pas une décomposition analytique précise par série. En effet, cette contribution est estimée globalement dans la structure du lisseur de Kalman. Cela motive le recours à une méthode d'attribution approximative, présentée ci-après, qui permet une interprétation au niveau individuel de chaque série.

7.1.2 En pratique

En pratique, la procédure se déroule comme suit.

La prévision précédente, $\hat{y}_t^{\text{old}}$, est calculée à partir de la base de données initiale et des paramètres du modèle estimés antérieurement. La prévision révisée, $\hat{y}_t^{\text{rev}}$, est obtenue en mettant à jour uniquement les données révisées (sans ajout de nouvelles observations), tout en conservant les mêmes paramètres. La contribution des news est ensuite déterminée en comparant les valeurs effectivement observées des nouvelles données aux prédictions issues de l'ancienne version du modèle (estimations lissées de Kalman). Chaque écart est pondéré par son impact marginal sur la prévision du PIB, dérivé analytiquement du filtre de Kalman. On obtient ainsi une mesure exacte et cohérente avec le modèle de l'effet total des *news*. Enfin, l'effet de la ré-estimation est calculé comme la différence résiduelle entre la prévision obtenue avec le modèle entièrement ré-estimé et celle obtenue à partir des nouvelles données, mais avec les anciens paramètres.

7.1.3 Contribution par variable / groupe

Afin de faciliter l'interprétation et la communication des résultats, la boîte à outils propose également une décomposition approximative de l'impact de l'information nouvelle, à la fois par série individuelle et par groupe (par exemple : *Activité*, *Consommation et inventaires*, etc.). Cette décomposition repose sur une approche simplifiée.

Concrètement, elle consiste à calculer une prévision contrefactuelle à l'aide d'une base de données modifiée dans laquelle toutes les observations des deux dernières années (précédant la date cible de prévision) sont supprimées — autrement dit, rendues manquantes. La différence entre cette prévision « de référence » et la prévision complète (intégrant toutes les données disponibles) fournit une approximation de l'effet agrégé des données récentes. Cette différence est ensuite répartie entre les séries individuelles en fonction des poids marginaux estimés et des surprises observées.

Bien que cette décomposition soit parlante et intuitive, il convient de souligner qu'elle ne correspond pas à la contribution exacte des news décrite précédemment. Cette dernière est calculée de manière analytique à partir du modèle, en utilisant les paramètres estimés à la date précédente et les versions successives des données ; elle constitue le cœur de la décomposition principale. En revanche, les contributions approximatives par série reposent sur le modèle ré-estimé et s'appuient sur une comparaison avec un scénario de référence sans données récentes. Par conséquent, les deux approches ne sont ni directement additives ni équivalentes. Les contributions individuelles doivent donc être interprétées avec prudence, comme un outil diagnostique et non comme une décomposition formelle.

7.2 La base de données

7.3 Caractéristiques des modèles

Figure 9: Activité

IDBANK	Secteur	Secteur/Produit	Variable	Frequence	Pays/Zone	Source	Delai de publication (en jours)
010758298	Industrie	Industrie manufacturière (CZ)	Activité limitée par l'insuffisance de personnel	M	France	Insee	19
001565531	Ensemble		Indicateur de retournement conjoncturel	M	France	Insee	19
001565530	Ensemble		Indicateur du climat des affaires	M	France	Insee	19
001786559	Services		Indicateur synthétique du climat des affaires	M	France	Insee	19
001586052	Industrie	Industrie manufacturière (CZ)	Perspectives générales - Tendance probable du volume de la production industrielle	M	France	Insee	19
001582081	Services		Tendance passée de l'activité	M	France	Insee	19
001586064	Industrie	Industrie manufacturière (CZ)	Tendance passée de la production	M	France	Insee	19
001582085	Services		Tendance prévue de l'activité	M	France	Insee	19
001580015	Services		Évolution des affaires (ventes) - 3 derniers mois	M	France	Insee	19
EVACT	Services		Evolution de l'activité	M	France	Banque de France	41
EVPRO	Industrie		Evolution de la production	M	France	Banque de France	41
PREVACT	Services		Prévision de l'activité	M	France	Banque de France	41
PREVPRO	Industrie		Prévision de production	M	France	Banque de France	41
TUC	Industrie		Taux moyen d'utilisation des capacités de production	M	France	Banque de France	41
010755537	Ensemble		Nombre de créations d'entreprises	M	France	Insee	49
DEF	Ensemble		Défaillances d'entreprises	M	France	Banque de France	66
Export	Ensemble		Exportations de marchandises	M	France	Douanes françaises	66
Import	Ensemble		Importations de marchandises	M	France	Douanes françaises	66
010768307	Industrie	Industrie manufacturière (CZ)	Indice de la production industrielle	M	France	Insee	66
010768267	Industrie	Fab. aliments, boiss. & prdts base tabac (C1)	Indice de la production industrielle	M	France	Insee	66
010768269	Industrie	Coléfaction et raffinage (C2)	Indice de la production industrielle	M	France	Insee	66
010768271	Industrie	Fab. éq. élec., électr., inf. & machines (C3)	Indice de la production industrielle	M	France	Insee	66
010768301	Industrie	Industrie automobile (CL1)	Indice de la production industrielle	M	France	Insee	66
010768303	Industrie	Fab. d'autres matériels de transport (CL2)	Indice de la production industrielle	M	France	Insee	66
010768275	Industrie	Fab. d'autres produits industriels (C5)	Indice de la production industrielle	M	France	Insee	66
010768311	Industrie	Extr., énerg., eau, gestn déch. & dépol. (DE)	Indice de la production industrielle	M	France	Insee	66
010774858	Services	Services (HZ-JZ, LZ-NZ, RZ & SZ)	Indice de chiffre d'affaires - Ensemble des services	M	France	Insee	87
010771383	Industrie	Industrie manufacturière (CZ)	Indice de chiffre d'affaires - Export	M	France	Insee	87
010771767	Industrie	Industrie manufacturière (CZ)	Indice de chiffre d'affaires - Marché intérieur	M	France	Insee	87
CONSONRJ	Industrie	Electricité, gaz et autres (DZ)	Consommation brute d'électricité et de gaz	M	France	ODRE	253
FLIGHTS	Ensemble		Trafic arérien (Départs/Arrivées)	Q	France	Eurocontrol	46

Figure 10: Commandes et inventaires

IDBANK	Secteur	Secteur/Produit	Variable	Frequence	Pays/Zone	Source	Delai de publication (en jours)
001580429	Services		Intentions de commandes - 3 prochains mois	M	France	Insee	19
001585942	Industrie	Industrie manufacturière (CZ)	Niveau des carnets de commandes globaux	M	France	Insee	19
001585980	Industrie	Industrie manufacturière (CZ)	Niveau des carnets de commandes étrangers	M	France	Insee	19
001586017	Industrie	Industrie manufacturière (CZ)	Niveau des stocks de produits finis	M	France	Insee	19
001585791	Services		Tendance prévue de la demande	M	France	Insee	19
001587668	Ménages		Indicateur synthétique de confiance des ménages	M	France	Insee	24
000857193	Ménages		Opinion sur l'opportunité de faire des achats importants	M	France	Insee	24
000857189	Ménages		Opinion sur le niveau de vie futur en France	M	France	Insee	24
000857188	Ménages		Opinion sur le niveau de vie passé en France	M	France	Insee	24
000857197	Ménages		Opinion sur leur situation financière future	M	France	Insee	24
000857196	Ménages		Opinion sur leur situation financière passée	M	France	Insee	24
010756764	Ménages	Industrie automobile (CL1)	Immatriculations de voitures particulières neuves	M	France	Insee	33
ETCC	Industrie		Etat du carnet de commandes	M	France	Banque de France	41
DETEM	Services		Evolution de la demande globale	M	France	Banque de France	41
EVCOM	Industrie		Evolution des commandes	M	France	Banque de France	41
EVCOME	Industrie		Evolution des commandes reçues de l'étranger	M	France	Banque de France	41
EVLIV	Industrie		Evolution des livraisons	M	France	Banque de France	41
EVSTPF	Industrie		Evolution du stock de produits finis	M	France	Banque de France	41
STPF	Industrie		Situation des stocks de produits finis	M	France	Banque de France	41
011794489	Ménages	Biens manufacturés	Consommation mensuelle des ménages en biens	M	France	Insee	57
011794493	Ménages	Biens durables	Consommation mensuelle des ménages en biens	M	France	Insee	57
011794484	Ménages	Matériels de transport	Consommation mensuelle des ménages en biens	M	France	Insee	57
011794497	Ménages	Équipement du logement	Consommation mensuelle des ménages en biens	M	France	Insee	57
011794494	Ménages	Textile	Consommation mensuelle des ménages en biens	M	France	Insee	57
011794495	Ménages	Autres biens fabriqués	Consommation mensuelle des ménages en biens	M	France	Insee	57
011794482	Ménages	Alimentaire hors tabac	Consommation mensuelle des ménages en biens	M	France	Insee	57
011794485	Ménages	Énergie, eau et déchets	Consommation mensuelle des ménages en biens	M	France	Insee	57

Figure 11: Incertitude

IDBANK	Secteur	Secteur/Produit	Variable	Frequence	Pays/Zone	Source	Delai de publication (en jours)
FREPU	Ensemble		Incertitude de politique économique - FREPU	M	France	Baker, Bloom, Davis (2016)	29
FRIP	Ensemble		Risque politique - FRIP	M	France	Caldara, Dario, and Matteo Iacoviello (2021)	53
VIX	Finance		VIX	Q	International	Yahoo Finance	0

Figure 12: Construction

IDBANK	Secteur	Secteur/Produit	Variable	Frequence	Pays/Zone	Source	Delai de publication (en jours)
001586922	Bâtiment	Construction (FZ)	Impossibilité d'accroître la production en cas d'augmentation des commandes	M	France	Insee	19
001586919	Bâtiment	Construction (FZ)	Niveau du carnet de commande en mois de travail	M	France	Insee	19
001586921	Bâtiment	Construction (FZ)	Tendance d'évolution passée des effectifs	M	France	Insee	19
001586920	Bâtiment	Construction (FZ)	Tendance d'évolution prévue des effectifs	M	France	Insee	19
001586917	Bâtiment	Construction (FZ)	Tendance de l'activité passée	M	France	Insee	19
001586916	Bâtiment	Construction (FZ)	Tendance de l'activité prévue	M	France	Insee	19
010752267	Bâtiment	Construction (FZ)	Nombre de logements autorisés - Coll. ou en résidence	M	France	Insee	57
001718146	Bâtiment	Construction (FZ)	Nombre de logements autorisés - Ind. groupés	M	France	Insee	57
001718145	Bâtiment	Construction (FZ)	Nombre de logements autorisés - Ind. purs	M	France	Insee	57
010752271	Bâtiment	Construction (FZ)	Nombre de logements autorisés - Total	M	France	Insee	57
001718152	Bâtiment	Construction (FZ)	Nombre de logements commencés - Coll. hors résidence	M	France	Insee	57
001718153	Bâtiment	Construction (FZ)	Nombre de logements commencés - En résidence	M	France	Insee	57
001718151	Bâtiment	Construction (FZ)	Nombre de logements commencés - Ind. groupés	M	France	Insee	57
001718150	Bâtiment	Construction (FZ)	Nombre de logements commencés - Ind. purs	M	France	Insee	57
001718154	Bâtiment	Construction (FZ)	Nombre de logements commencés - Total	M	France	Insee	57
010768320	Bâtiment	Construction (FZ)	Indice de la production industrielle	M	France	Insee	66
010773569	Bâtiment	Construction (FZ)	Indice de chiffre d'affaires - Marché intérieur et export	M	France	Insee	87
001587142	Bâtiment	Construction (FZ)	Activité prévue de l'entreprise	T	France	Insee	28
001587131	Bâtiment	Construction (FZ)	Activité récente de l'entreprise	T	France	Insee	28
001587140	Bâtiment	Construction (FZ)	Opinions sur le carnet de commandes	T	France	Insee	28
001587148	Bâtiment	Construction (FZ)	Évolution prévue des effectifs	T	France	Insee	28

Figure 13: Finance

IDBANK	Secteur	Secteur/Produit	Variable	Frequence	Pays/Zone	Source	Delai de publication (en jours)
RBFRBIS	Finance		Taux de change effectif EUR	M	France	FRED	49
TXCREDHAB	Ménages		Taux d'intérêt à l'habitat	M	France	Banque de France	66
TCNEURO	Finance		Taux de change effectif - Euro	M	France	Eurostat	67
DAX	Finance		DAX	Q	Allemagne	Yahoo Finance	0
SP500	Finance		SP500	Q	Etats-Unis	Yahoo Finance	0
CAC40	Finance		CAC40	Q	France	Yahoo Finance	0
EURO.CNY	Finance		Taux de change EUR-CNY	Q	France	Yahoo Finance	0
EURO.GBP	Finance		Taux de change EUR-GBP	Q	France	Yahoo Finance	0
EURO.JPY	Finance		Taux de change EUR-JPY	Q	France	Yahoo Finance	0
EURO.USD	Finance		Taux de change EUR-USD	Q	France	Yahoo Finance	0
NIKKEI	Finance		NIKKEI	Q	Japon	Yahoo Finance	0
FTSE	Finance		FTSE	Q	Royaume-Uni	Yahoo Finance	0
TAUX1AN	Ensemble		Taux d'intérêt à l'échéance constante - 1 an	Q	France	Banque de France	24

Figure 14: International

IDBANK	Secteur	Secteur/Produit	Variable	Frequence	Pays/Zone	Source	Delai de publication (en jours)
NOWCGDP	Ensemble		Nowcast du PIB mondial	H	International	UNCTAD	23
NOWCMERCH	Services		Nowcast du commerce mondial de marchandises	H	International	UNCTAD	23
NOWCSERV	Services		Nowcast du commerce mondial de services	H	International	UNCTAD	23
REAINTRATREARAT1YE			Taux d'intérêt à 1 an - Etats-Unis	M	Etats-Unis	FRED	10
GSCPI	Ensemble		Difficultés d'approvisionnement - GSCPI	M	International	NYFed	34
UNRATE	Ménages		Taux de chômage - Etats-Unis	M	Etats-Unis	FRED	36
PCUOMFGOMFG	Industrie	Industrie manufacturière (CZ)	Indice des prix à la production - Etats-Unis	M	Etats-Unis	FRED	42
LREM64TTUSM156S	Ménages		Taux d'emploi - Etats-Unis	M	Etats-Unis	FRED	46
IRLTLT01FRM156N			Taux d'intérêt à 10 ans - Etats-Unis	M	France	FRED	46
IR3TIB01FRM156N			Taux d'intérêt à 3 mois - Etats-Unis	M	France	FRED	46
IPMAN	Industrie	Industrie manufacturière (CZ)	Indice de production industrielle - Etats-Unis	M	Etats-Unis	FRED	47
RSXFS	Services	Commerce de détail (GZ-47)	Ventes - Etats-Unis	M	Etats-Unis	FRED	47
M1REAL	Ensemble		Masse monétaire M1 - Etats-Unis	M	Etats-Unis	FRED	54
M2REAL	Ensemble		Masse monétaire M2 - Etats-Unis	M	Etats-Unis	FRED	54
TGZW1QNMISNM	Ensemble		Volume du commerce mondial de marchandises	M	International	CBP	83
STSINPRMALL	Industrie	Industrie manufacturière (CZ)	Indice de production industrielle - Allemagne	M	Allemagne	Eurostat	85

Figure 15: Marché du travail

IDBANK	Secteur	Secteur/Produit	Variable	Frequence	Pays/Zone	Source	Delai de publication (en jours)
001796629	Ensemble		Indicateur du climat de l'emploi	M	France	Insee	19
010546531	Industrie	Industrie manufacturière (CZ)	Tendance d'évolution passée des effectifs	M	France	Insee	19
010546493	Industrie	Industrie manufacturière (CZ)	Tendance d'évolution prévue des effectifs	M	France	Insee	19
001585807	Services		Tendance passée des effectifs	M	France	Insee	19
001585811	Services		Tendance prévue des effectifs	M	France	Insee	19
001580475	Services		Évolution des effectifs - 3 prochains mois	M	France	Insee	19
DPAECDD	Ensemble		Déclarations d'embauches - CDD + de 1 mois	M	France	France Travail	50
DPAECDI	Ensemble		Déclarations d'embauches - CDI	M	France	France Travail	50
DEFM	Ensemble		Demandeurs d'emplois en fin de mois	M	France	Dares/FT	55
OFFREEMPLOIFT	Ensemble		Offres d'emplois collectées par France Travail	M	France	France Travail	55
INTERIM	Ensemble		Emplois intérimaires	M	France	Dares	56
UNERTM25	Ménages		Taux de chômage - Moins de 25 ans	M	France	Eurostat	85
UNERTMT	Ménages		Taux de chômage - Population totale	M	France	Eurostat	85
VACANTS	Ensemble		Emplois vacants	T	France	Dares	166
TXVACANCE	Ensemble		Taux d'emplois vacants	T	France	Dares	166

Figure 16: Monnaie, crédit, prix

IDBANK	Secteur	Secteur/Produit	Variable	Frequence	Pays/Zone	Source	Delai de publication (en jours)
001759971	Ménages		Indice des prix à la consommation harmonisé	M	France	Insee	26
NIVTRES	Services		Situation de trésorerie	M	France	Banque de France	41
IQ12260			Prix de l'or	M		FRED	47
PRAWMINDEXM			Prix des matières premières	M		FRED	56
M1	Ensemble		Masse monétaire - M1	M	France	Banque de France	63
M2	Ensemble		Masse monétaire - M2	M	France	Banque de France	63
M3	Ensemble		Masse monétaire - M3	M	France	Banque de France	63
CREDHAB	Ménages		Volume de crédits distribués - Particuliers	M	France	Banque de France	66
CREDSNF	Ensemble		Volume de crédits distribués - SNF résidentes	M	France	Banque de France	73
Brent	Finance		Prix du Brent - USD	Q	International	Yahoo Finance	0

7.4 Choix du nombre de variables

Table 7: Niveau d'intégration des variables chacun des modèles "préférés"

IDBANK	Variable	Intégration
Modèle B		
EVCOM	Evolution des commandes	I(0)
EVCOME	Evolution des commandes reçues de l'étranger	I(0)
EVLIV	Evolution des livraisons	I(0)
PREVACT	Prévision de l'activité	I(0)
010771383	Indice de chiffre d'affaires - Export	I(0)
011794485	Consommation mensuelle des ménages en biens	I(0)
IPMAN	Indice de production industrielle - Etats-Unis	I(1)
PCUOMFGOMFG	Indice des prix à la production - Etats-Unis	I(1)
DEFM	Demandeurs d'emplois en fin de mois	I(1)
001759971	Indice des prix à la consommation harmonisé	I(1)
UNERTM25	Taux de chômage - Moins de 25 ans	I(1)
Modèle C+		
001586917	Tendance de l'activité passée	I(0)
001796629	Indicateur du climat de l'emploi	I(0)
STPF	Situation des stocks de produits finis	I(0)
000857196	Opinion sur leur situation financière passée	I(0)
FREPU	Incertitude de politique économique - FREPU	I(0)
NOWCGDP	Nowcast du PIB mondial	I(0)
FRIP	Risque politique - FRIP	I(0)
NOWCMERCH	Nowcast du commerce mondial de marchandises	I(0)
REAINTRATREARAT1YE	Taux d'intérêt à 1 an - Etats-Unis	I(0)
DEF	Défaillances d'entreprises	I(0)
FLIGHTS	Trafic arérien (Départs/Arrivées)	I(0)
010768269	Indice de la production industrielle	I(0)
001586920	Tendance d'évolution prévue des effectifs	I(1)
001587148	Évolution prévue des effectifs	I(1)
010758298	Activité limitée par l'insuffisance de personnel	I(1)
CAC40	CAC40	I(1)
LREM64TTUSM156S	Taux d'emploi - Etats-Unis	I(1)
M2	Masse monétaire - M2	I(1)
RBFRBIS	Taux de change effectif EUR	I(1)
IR3TIB01FRM156N	Taux d'intérêt à 3 mois - Etats-Unis	I(1)
011794497	Consommation mensuelle des ménages en biens	I(1)
Commun aux modèles B et C+		
EVPRO	Evolution de la production	I(0)
PREVPRO	Prévision de production	I(0)
NOWCSERV	Nowcast du commerce mondial de services	I(0)
000857193	Opinion sur l'opportunité de faire des achats importants	I(1)
STSINPRMALL	Indice de production industrielle - Allemagne	I(1)
010768307	Indice de la production industrielle	I(1)
010768271	Indice de la production industrielle	I(1)
010768301	Indice de la production industrielle	I(1)
010768275	Indice de la production industrielle	I(1)

Figure 17: Nombre optimal de variables par modèle et horizon - Période pré-Covid 2010-2019

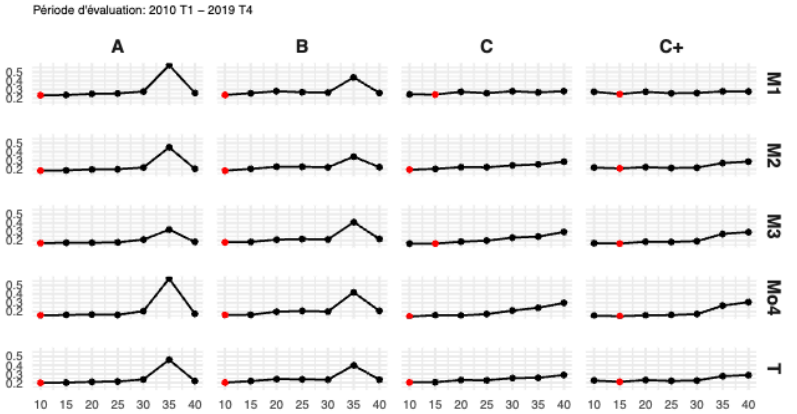

Notes: Le nombre de variables est représenté en abscisse, tandis que le RMSE figure en ordonnée. Pour les modèles B et C, le nombre de variables est plus important que celui affiché en abscisse (section –Les différents modèles testés–). On retrouve en colonnes les différents modèles et en lignes les horizons (Mois 1, 2, 3, 4 et le Trimestre (= M1, M2, M3)). L'évaluation a été réalisée à partir de données arrêtées au 30 juin 2025.
Source : Calculs des auteurs.

Figure 18: Nombre optimal de variables par modèle et horizon - Période post-Covid 2021-2025

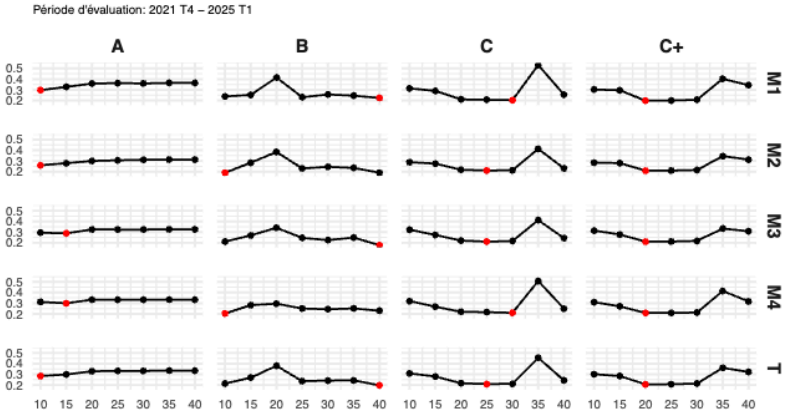

Notes: Le nombre de variables est représenté en abscisse, tandis que le RMSE figure en ordonnée. Pour les modèles B et C, le nombre de variables est plus important que celui affiché en abscisse (section –Les différents modèles testés–). On retrouve en colonnes les différents modèles et en lignes les horizons (Mois 1, 2, 3, 4 et le Trimestre (= M1, M2, M3)). L'évaluation a été réalisée à partir de données arrêtées au 30 juin 2025.
Source : Calculs des auteurs.

7.5 Stabilité de la présélection

Figure 19: Stabilité de la pré-sélection avec la méthode LARS

Table 8: Nombre optimal de facteurs selon les critères de Bai et Ng (2002)

	Modèle A			Modèle B			Modèle C			Modèle C+		
Configuration	CI_1	CI_2	CI_3	CI_1	CI_2	CI_3	CI_1	CI_2	CI_3	CI_1	CI_2	CI_3
10	9	9	9	15	15	15	9	9	9	9	9	9
15	14	14	14	15	15	15	14	14	14	14	14	14
20	15	15	15	15	15	15	15	15	15	15	15	15
25	15	15	15	15	15	15	15	15	15	15	15	15
30	15	15	15	15	15	15	15	15	15	15	15	15
35	15	15	15	15	15	15	15	15	15	15	15	15
40	15	15	15	15	15	15	15	15	15	15	15	15

Source: Calcul des auteurs

7.6 Critères d'information de Bai et Ng (2002)

Pour rappel les trois critères d'information de Bai et Ng (2002) sont:

$$CI_1(r) = \log Vr(\hat{F}, \hat{\lambda}) + r\left(\frac{N+T}{NT}\right)\log\left(\frac{NT}{N+T}\right)$$

$$CI_2(r) = \log Vr(\hat{F}, \hat{\lambda}) + r\left(\frac{N+T}{NT}\right)\log\left(\min\{N,T\}\right)$$

$$CI_3(r) = \log Vr(\hat{F}, \hat{\lambda}) + r\frac{\log\left(\min\{N,T\}\right)}{\min\{N,T\}}$$

où $V_r(\hat{F}, \hat{\lambda})$ désigne la somme des carrés des résidus pour un nombre de facteurs r, et s'écrit : $V_r(\hat{F}, \hat{\lambda}) = \sum_{i=1}^{p}\sum_{t=1}^{n}\mathbb{E}[\hat{\varepsilon}_t^2]$, with $\hat{\varepsilon}_{it} = X_{it} - \hat{F}\hat{\Lambda}$. Les facteurs $\hat{F}$ sont estimés à partir d'une analyse en composantes principales appliquée à la base standardisée X. Les facteurs estimés correspondent aux composantes principales, tandis que les charges factorielles estimées $\hat{\Lambda}$ correspondent aux vecteurs propres associés.

Traditionnellement, le critère $CI_2(r)$ est généralement privilégiée dans le cas d'échantillons de taille finie, en raison de son bon compromis entre ajustement du modèle et complexité. Toutefois, dans notre cas les différents critères donnent des réponses quasiment identiques.

8 References

André, Julien, et Marie Bessec. 2024. « A Mixed-Frequency Factor Model for Nowcasting French GDP ». *Banque de France WP*, n 975. https://www.banque-france.fr/system/files/2024-12/WP975_1.pdf.

Antolin-Diaz, Juan, Thomas Drechsel, et Ivan Petrella. 2017. « Tracking the Slowdown in Long-Run GDP Growth ». *Review of Economics and Statistics* 99 (2): 343-56.

Bai, Jushan, et Serena Ng. 2002. « Determining the number of factors in approximate factor models ». *Econometrica* 70 (1): 191-221.

———. 2008. « Forecasting economic time series using targeted predictors ». *Journal of Econometrics* 146 (2): 304-17.

Bair, E., T. Hastie, D. Paul, et R. Tibshirani. 2006. « Prediction by supervised principal components ». *Journal of the American Statistical Association* 101 (473): 119-37.

Baker, Scott R., Nicholas Bloom, et Steven J. Davis. 2016. « Measuring Economic Policy Uncertainty ». *The Quarterly Journal of Economics* 131 (4): 1593-1636. https://ideas.repec.org/a/oup/qjecon/v131y2016i4p1593-1636..html.

Banbura, Marta, Domenico Giannone, Michele Modugno, et Lucrezia Reichlin. 2013. « Now-Casting and the Real-Time Data Flow ». In *Handbook of Economic Forecasting*, édité par Graham Elliott et Allan Timmermann, 2A:195-237. Elsevier. https://doi.org/10.1016/B978-0-444-53683-9.00004-9.

Banbura, Marta, Domenico Giannone, et Lucrezia Reichlin. 2010. « Nowcasting ». In *The Oxford Handbook of Economic Forecasting*, édité par Michael P. Clements et David F. Hendry, 193-224. Oxford: Oxford University Press.

Bańbura, Marta, et Michele Modugno. 2014. « Maximum Likelihood Estimation Of Factor Models On Datasets With Arbitrary Pattern Of Missing Data ». *Journal of Applied Econometrics* 29 (1): 133-60. https://ideas.repec.org/a/wly/japmet/v29y2014i1p133-160.html.

Barhoumi, Karim, Olivier Darne, Laurent Ferrara, et Benjamin Pluyaud. 2013. « Monthly GDP forecasting using bridge models: Application for the French economy ». *Bulletin of Economic Research* 65 (s1): S53-70.

Bessec, Marie, et Catherine Doz. 2012. « Prévision à court terme de la croissance du PIB français à l'aide de modèles à facteurs dynamiques ». *Économie et Prévision* 199 (1): 1-30. https://doi.org/10.3406/ecop.2012.8096.

———. 2014. « Short-term forecasting of French GDP growth using dynamic factor models ». *OECD Journal: Journal of Business Cycle Measurement and Analysis* 2013 (2): 11-50. https://doi.org/10.1787/jbcma-2013-5jz742l0pt8s.

Boivin, J., et S. Ng. 2006. « Are more data always better for factor analysis? » *Journal of Econometrics* 132 (1): 169-94.

Bok, B., D. Caratelli, D. Giannone, A. M. Sbordone, et A. Tambalotti. 2018. « Macroeconomic nowcasting and forecasting with big data ». *Annual Review of Economics* 10 (1): 615-43.

Bourassi, Lina, Antoine Claisse, et Louise Phung. 2024. « Prévoir la croissance française à court terme en période exceptionnelle ». 348. *Trésor-Eco*. Vol. 2013.

https://www.tresor.economie.gouv.fr/Articles/6621f06c-f940-40e1-b5a3-3d4f46f681fa/files/1ee939f0-a90c-42b4-bc33-eda4d30d940b.

Caldara, Dario, et Matteo Iacoviello. 2022. « Measuring Geopolitical Risk ». *American Economic Review* 112 (4): 1194-1225. https://doi.org/10.1257/aer.20191823.

Chinn, Menzie D., Baptiste Meunier, et Sebastian Stumpner. 2023. « Nowcasting World Trade with Machine Learning: a Three-Step Approach ». Working Paper 917. Paris, France: Banque de France. https://doi.org/10.2139/ssrn.4513741.

Doz, Catherine, Domenico Giannone, et Lucrezia Reichlin. 2011. « A two-step estimator for large approximate dynamic factor models based on Kalman filtering ». *Journal of Econometrics* 164 (1): 188-205.

Drechsel, Thomas, Juan Antolin-Diaz, et Ivan Petrella. 2024. « Advances in Nowcasting Economic Activity: The Role of Heterogeneous Dynamics and Fat Tails ». *Journal of Econometrics* 238 (2). https://doi.org/10.1016/j.jeconom.2024.03.006.

Efron, Bradley, Trevor Hastie, Iain Johnstone, et Robert Tibshirani. 2004. « Least Angle Regression ». *The Annals of Statistics* 32 (2): 407-99. https://doi.org/10.1214/009053604000000067.

Giannone, D., L. Reichlin, et D. Small. 2008. « Nowcasting: The real-time informational content of macroeconomic data ». *Journal of Monetary Economics* 55 (4): 665-76.

Hastie, Trevor, Robert Tibshirani, et Jerome Friedman. 2009. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction.* 2nd éd. Springer.

Hervé Péléraux, Françoise Charpin &. 2000. « L'indicateur avancé de l'OFCE ». Revue de l'OFCE 72 (1): 133-55. https://shs.cairn.info/revue-de-l-ofce-2000-1-page-133?lang=fr&ref=doi.

Higgins, Patrick C. 2014. « GDPNow: A Model for GDP "Nowcasting" ». Working Paper 2014-7. Atlanta, GA: Federal Reserve Bank of Atlanta. https://fraser.stlouisfed.org/title/8586/item/657082.

Lenza, Michele, et Giorgio E. Primiceri. 2022. « How to estimate a vector autoregression after March 2020 ». *Journal of Applied Econometrics* 37 (4): 688-99. https://doi.org/10.1002/jae.2895.

Linzenich, Jan, et Baptiste Meunier. 2024. « Nowcasting Made Easier: a toolbox for economists ». Working Paper Series 3004. European Central Bank. https://ideas.repec.org/p/ecb/ecbwps/20243004.html.

McCracken, Michael W., et Serena Ng. 2015. « FRED-MD: A Monthly Database for Macroeconomic Research ». Working Papers 2015-12. Federal Reserve Bank of St. Louis. https://doi.org/10.20955/wp.2015.012.

Mogliani, Matteo, Olivier Darné, et Bertrand Pluyaud. 2017. « The new MIBA model: Real-time nowcasting of French GDP using the Banque de France's monthly business survey ». *Economic Modelling* 64: 26-39. https://doi.org/10.1016/j.econmod.2017.03.003.

Péléraux, Hervé. 2017. « L'indicateur avancé : croissance du PIB de 0,6 % au tournant de 2017 et de 2018 ». SciencePo Working papers Main hal-03455338. HAL. https://ideas.repec.org/p/hal/spmain/hal-03455338.html.

Stock, J. H., et M. W. Watson. 2002. « Forecasting Using Principal Components From a Large Number of Predictors ». *Journal of the American Statistical Association* 97: 1167-79.

https://ideas.repec.org/a/bes/jnlasa/v97y2002mdecemberp1167-1179.html.
Tibshirani, Robert. 1996. « Regression shrinkage and selection via the lasso ». *Journal of the Royal Statistical Society: Series B (Methodological)* 58 (1): 267-88.
Watson, Mark W., et Robert F. Engle. 1983. « Alternative algorithms for the estimation of dynamic factor, mimic and varying coefficient regression models ». *Journal of Econometrics* 23 (3): 385-400. https://ideas.repec.org/a/eee/econom/v23y1983i3p385-400.html.

ABOUT OFCE

The Paris-based Observatoire français des conjonctures économiques (OFCE), or French Economic Observatory is an independent and publicly-funded centre whose activities focus on economic research, forecasting and the evaluation of public policy.

Its 1981 founding charter established it as part of the French Fondation nationale des sciences politiques (Sciences Po) and gave it the mission is to "ensure that the fruits of scientific rigour and academic independence serve the public debate about the economy". The OFCE fulfils this mission by conducting theoretical and empirical studies, taking part in international scientific networks, and assuring a regular presence in the media through close cooperation with the French and European public authorities. The work of the OFCE covers most fields of economic analysis, from macroeconomics, growth, social welfare programmes, taxation and employment policy to sustainable development, competition, innovation and regulatory affairs.

ABOUT SCIENCES PO

Sciences Po is an institution of higher education and research in the humanities and social sciences. Its work in law, economics, history, political science and sociology is pursued through ten research units and several crosscutting programmes.
Its research community includes over two hundred twenty members and three hundred fifty PhD candidates. Recognized internationally, their work covers a wide range of topics including education, democracies, urban development, globalization and public health.
One of Sciences Po's key objectives is to make a significant contribution to methodological, epistemological and theoretical advances in the humanities and social sciences. Sciences Po's mission is also to share the results of its research with the international research community, students, and more broadly, society as a whole.

PARTNERSHIP