

UNIVERSIDAD
EAFIT

50
Años

Seminario **quantil**

Autores: Jesús
Botero-García;

Andrés

García-Suaza;

Diego

Montañez-Herrera

2021

Nowcasting economic activity from Google Trends: A Deep Learning approach in post-pandemic

- ¿Qué es el Nowcast? ¿Qué es Google Trends (GT)?
- Proceso de construcción
- Modelos dinámicos de factores
- Inteligencia Artificial (AI) y Teoría de juegos
- AI para series de tiempo
- El Deep Learning (DL) en la macroeconomía
- Resultados del Nowcast_GT_DL
- Conclusiones

Introducción ¿Qué es Nowcasting?

Actualmente contamos con un universo de datos. Las agencias estadísticas, los bancos centrales, los institutos de investigación y las empresas privadas tienen acceso a miles de indicadores económicos y financieros.



¿Qué es Nowcasting? ¿Por qué es importante y quien lo usa?

- Existe un espacio importante para dar mayor aprovechamiento a fuentes de información no tradicional que complementen los datos oficiales y permitan hacer monitoreo en alta frecuencia.
- Los institutos de estadística publican indicadores económicos con retrasos considerables y con estimaciones iniciales que se revisan considerablemente con el tiempo.
- En síntesis, es de vital importancia un diagnóstico de la economía en “tiempo real”, que se ha popularizado como “nowcasting”, siendo esto una combinación entre el presente (now) y el futuro (forecasting) (Banbura, et al. 2013) o simplemente como la “**predicción inmediata**”

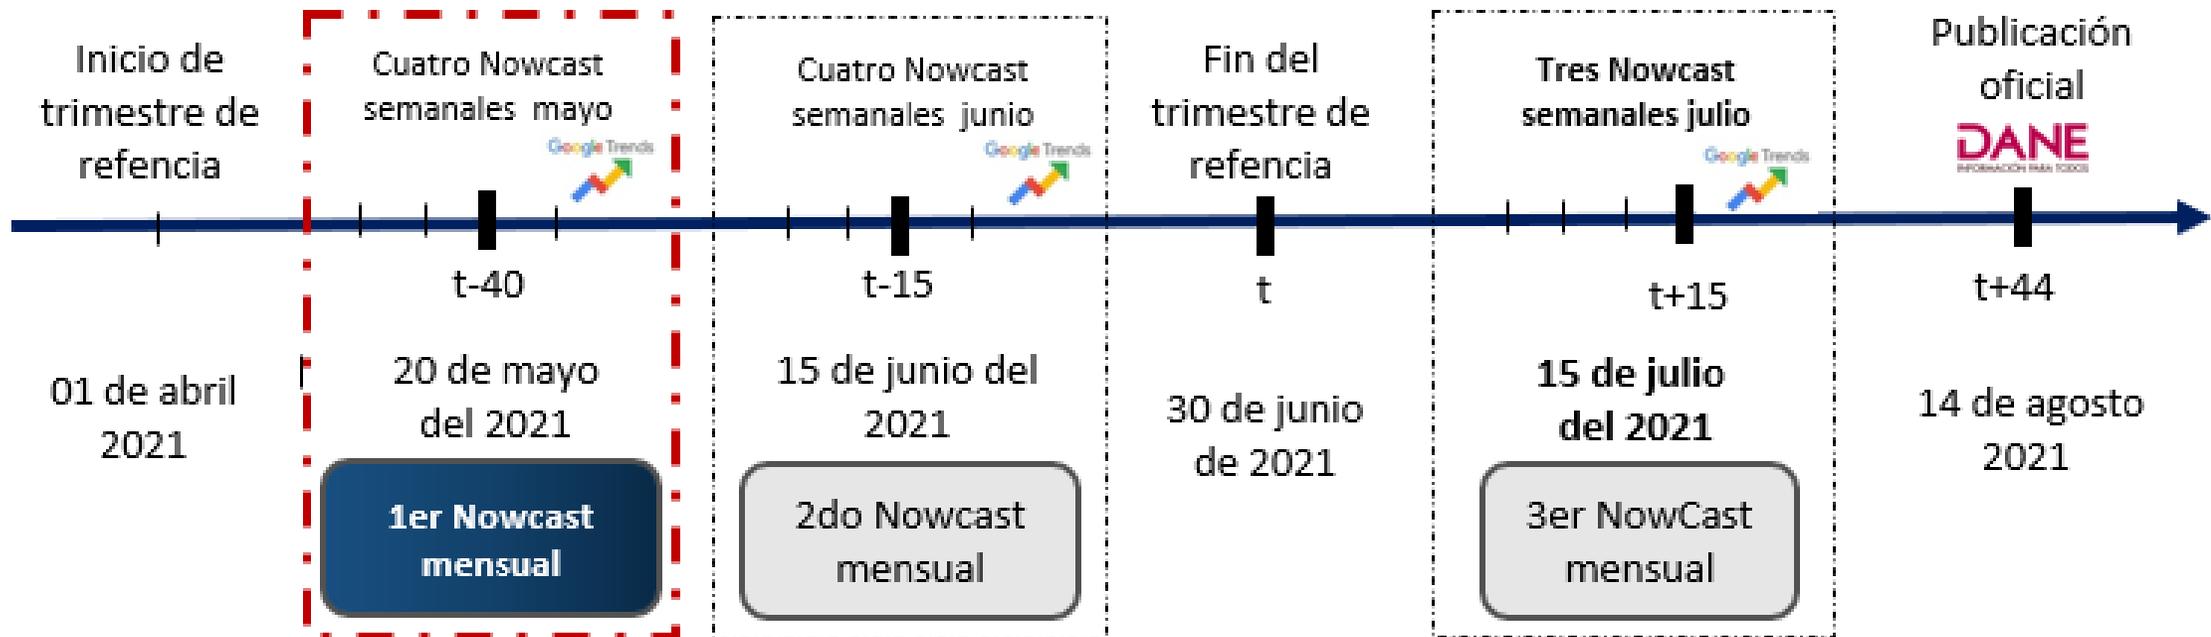
¿Qué es Nowcasting? ¿Por qué es importante y quien lo usa?

Rezago de publicación (días)	País	Zona
70	Estados Unidos 	Norte América
71	Canadá 	
58	Francia 	Euro y Unión Europea
54	Alemania 	
90	Inglaterra 	
123	Unión Europea 	
155	México 	Latinoamérica
96	Chile 	
90	Colombia 	

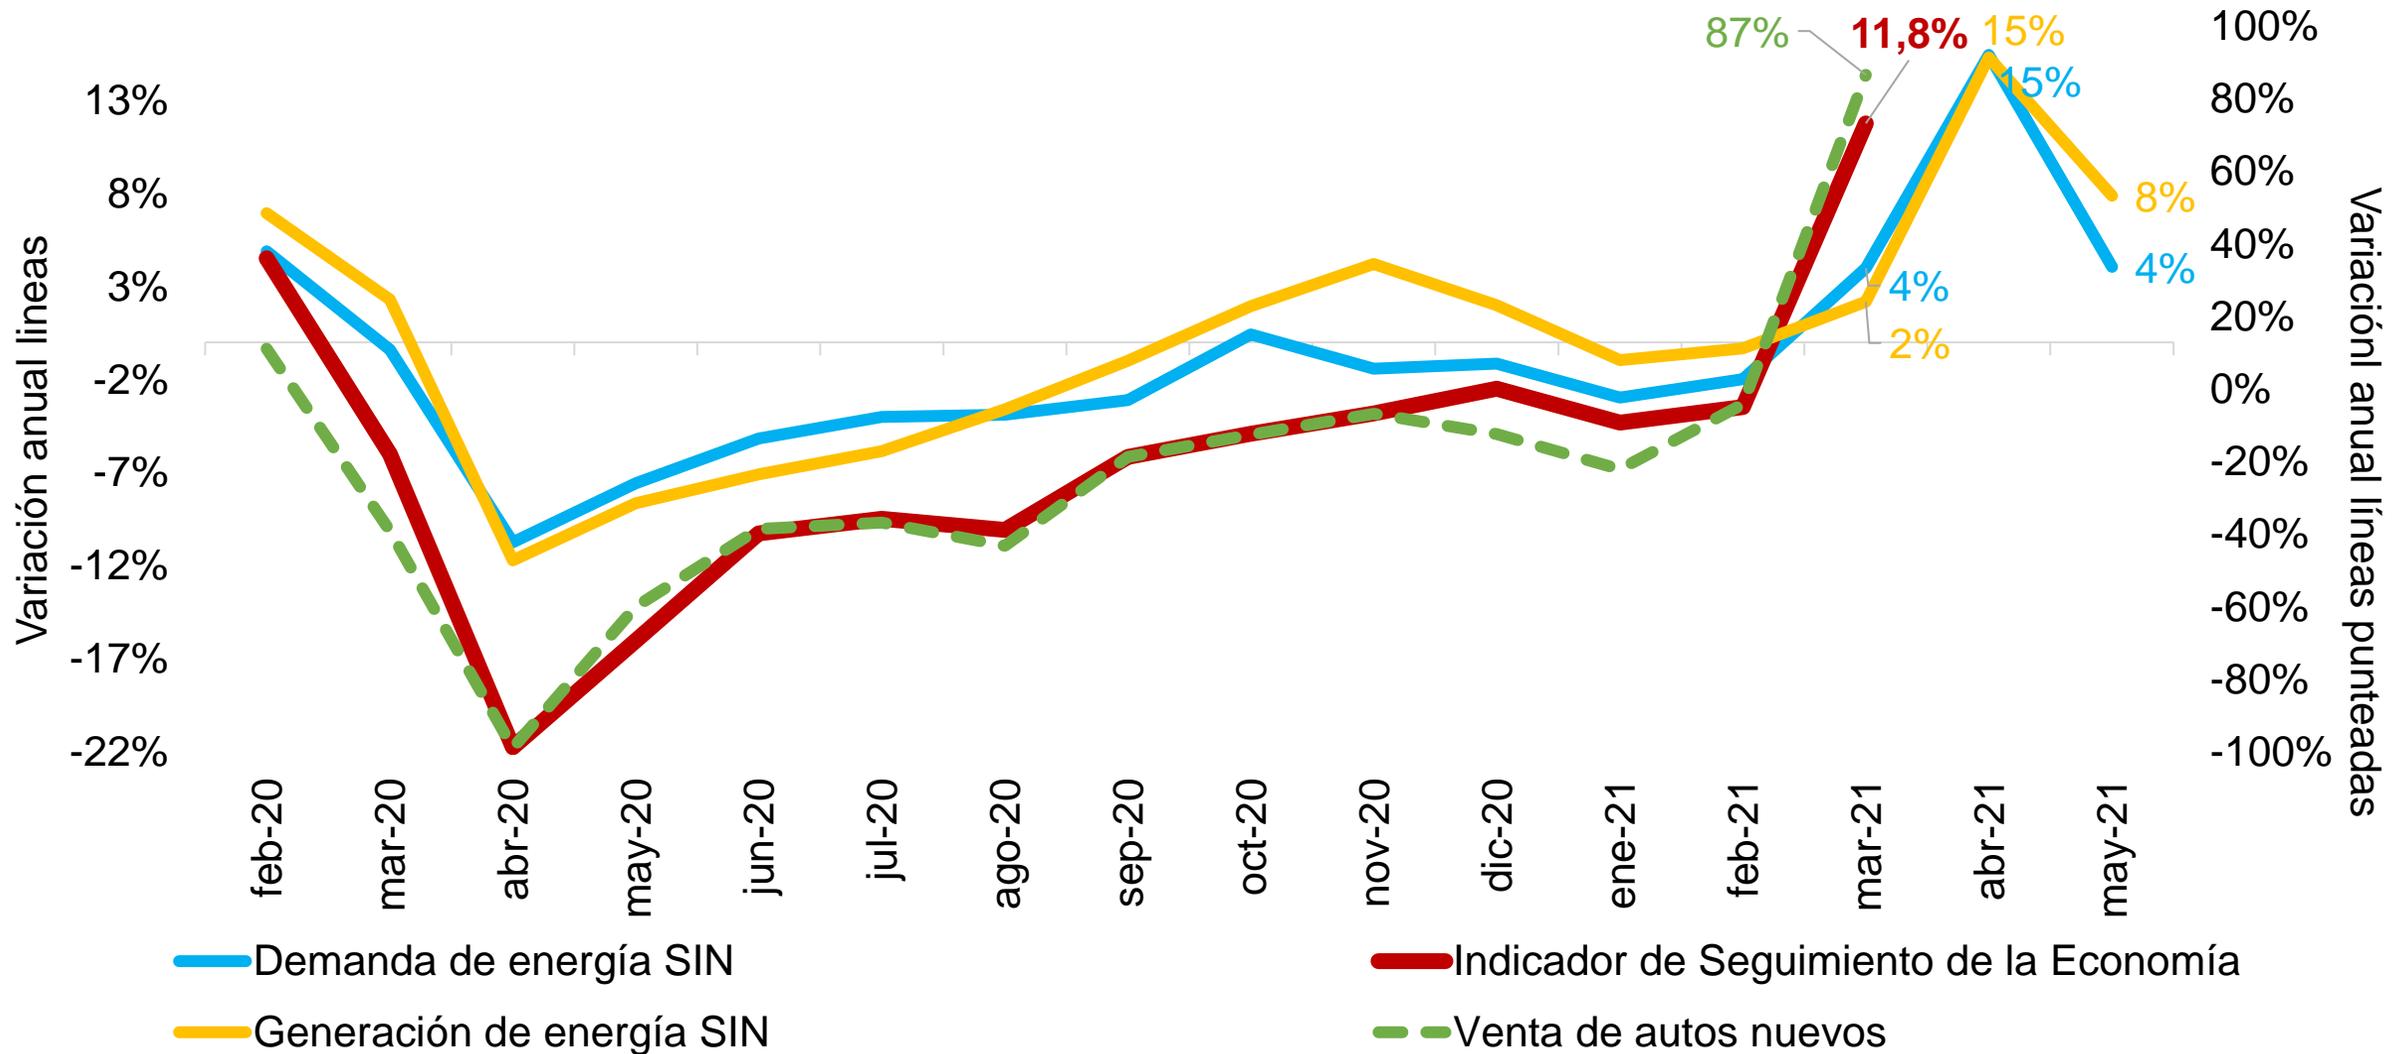
Fuente: Elaboración propia con información de DANE.

Calendario de un Nowcasting típico: El caso NowCast EAFIT del PIB Colombia

Las ventajas de tener una imagen oportuna del estado de la economía son múltiples.

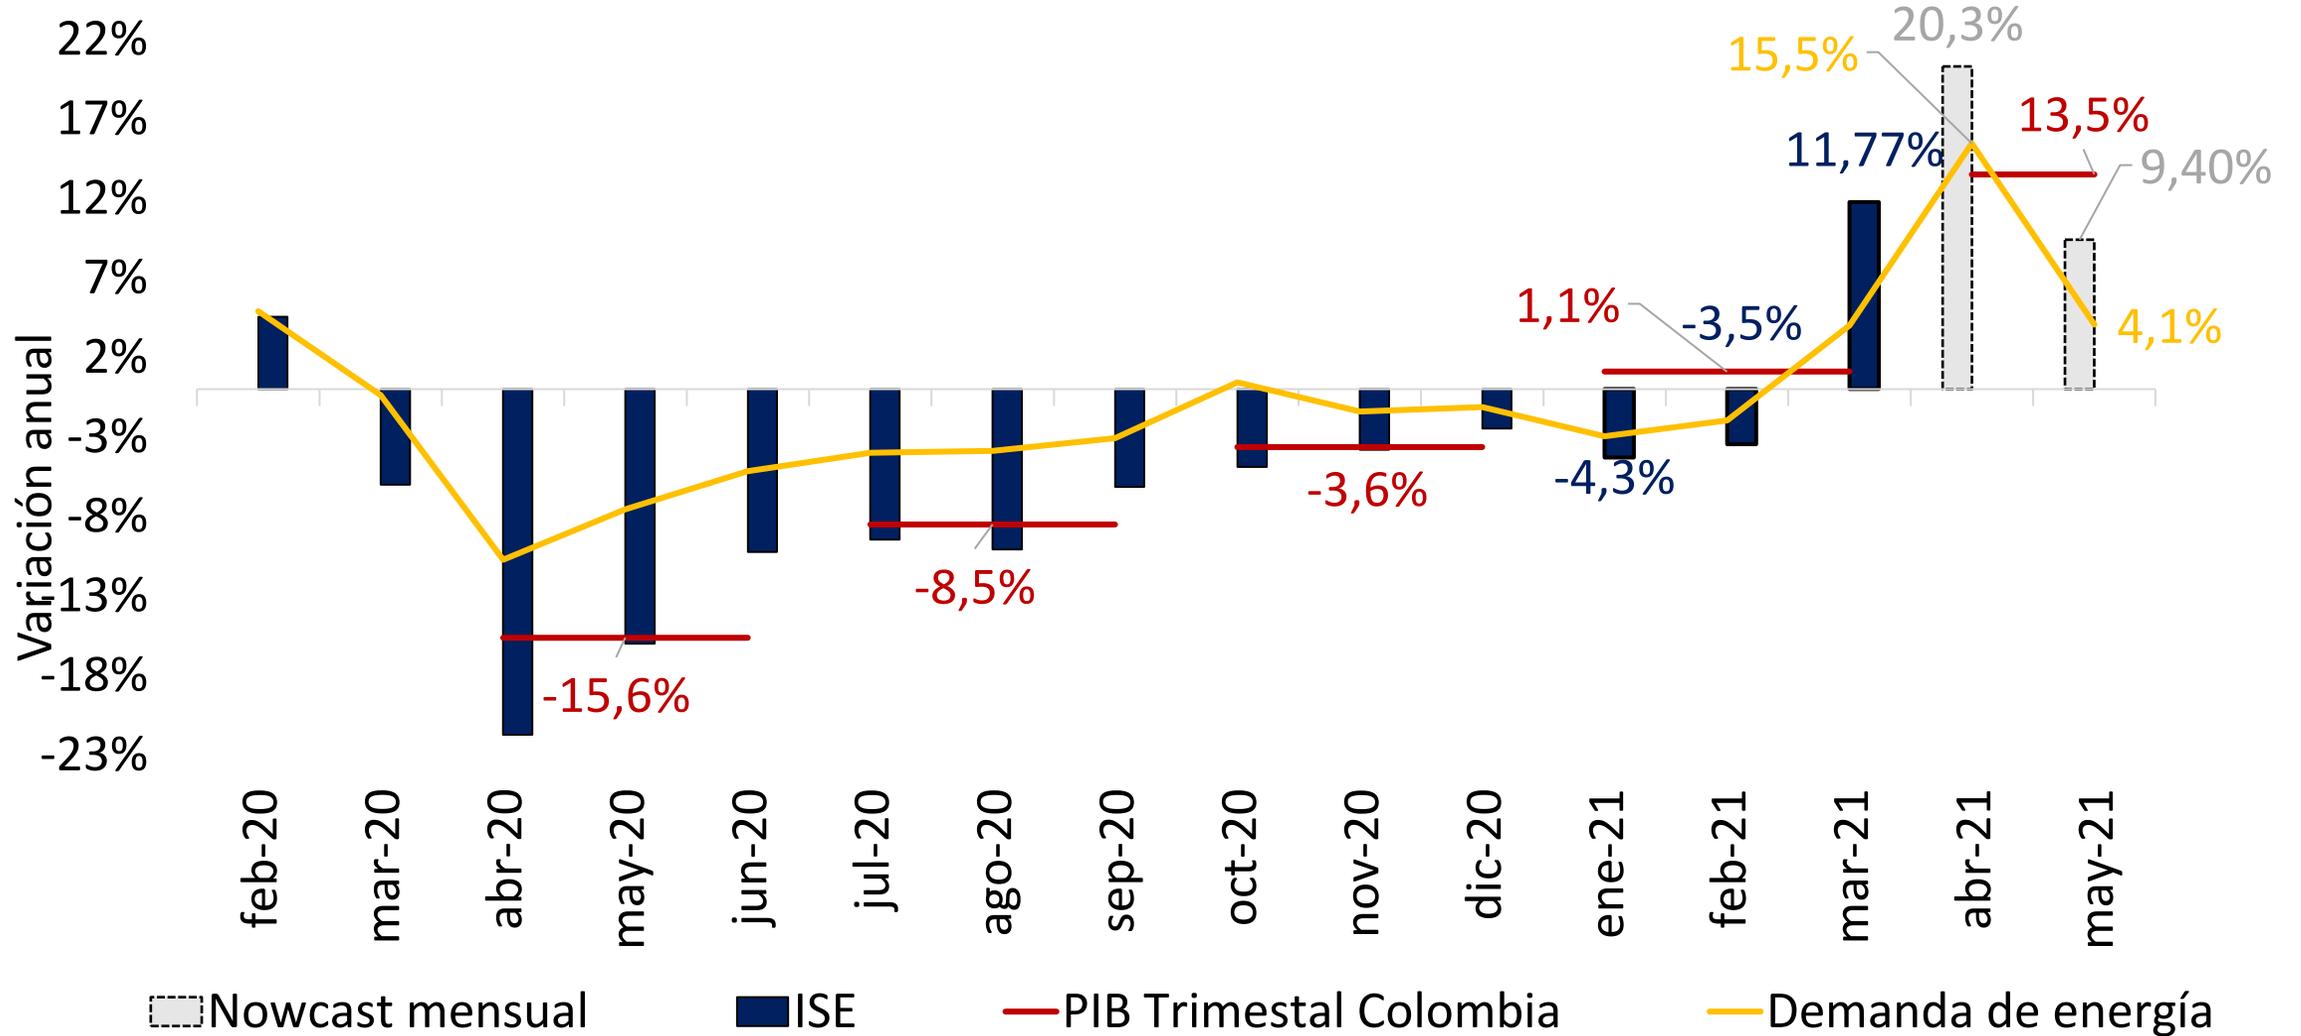


Principales variables del NowCast-EAFIT Colombia



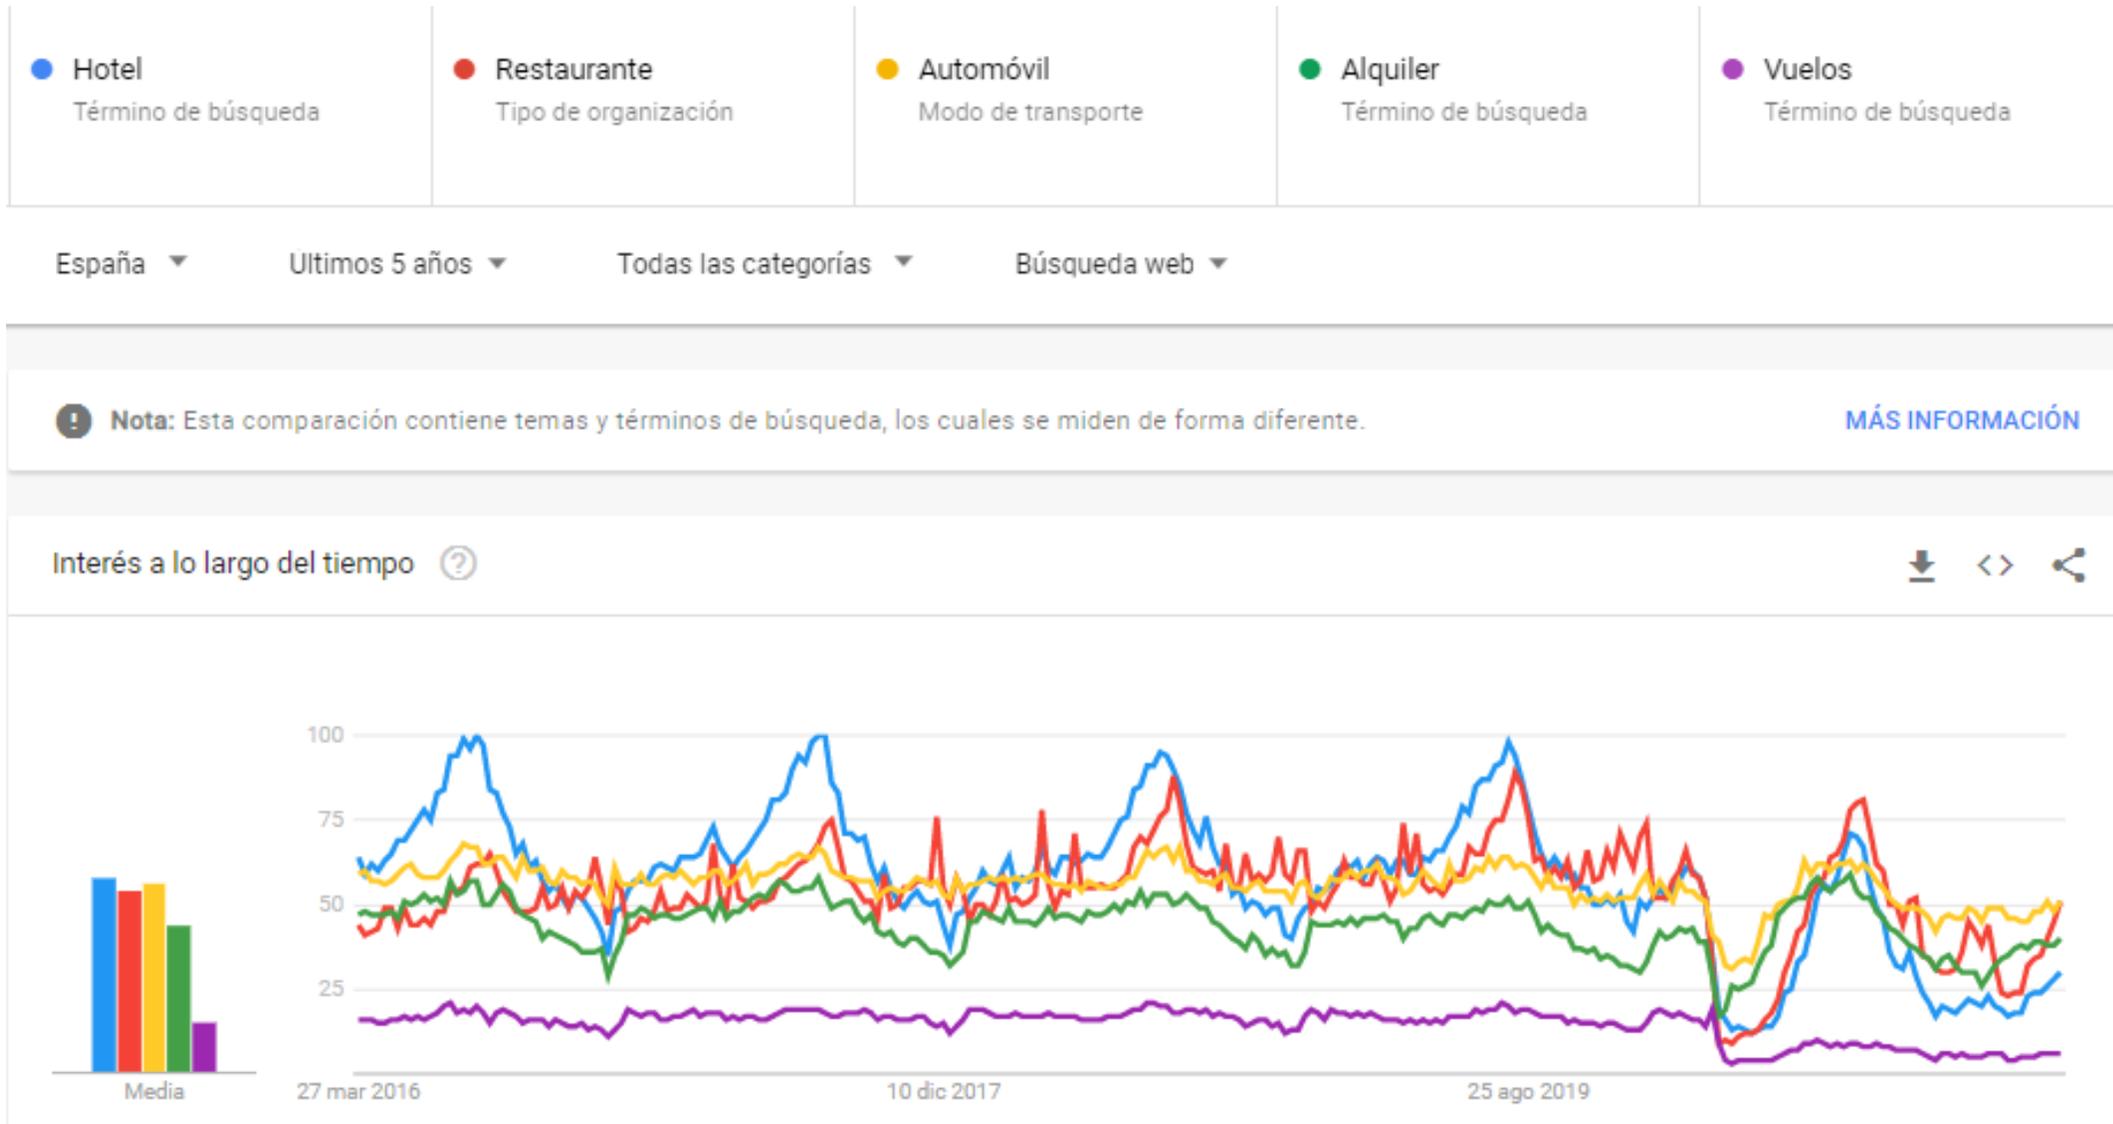
Fuente: Elaboración propia con datos DANE, Andemos, Portal BI de XM (con datos a 19 de mayo 2021)

Principales variables del NowCast 2021 Colombia

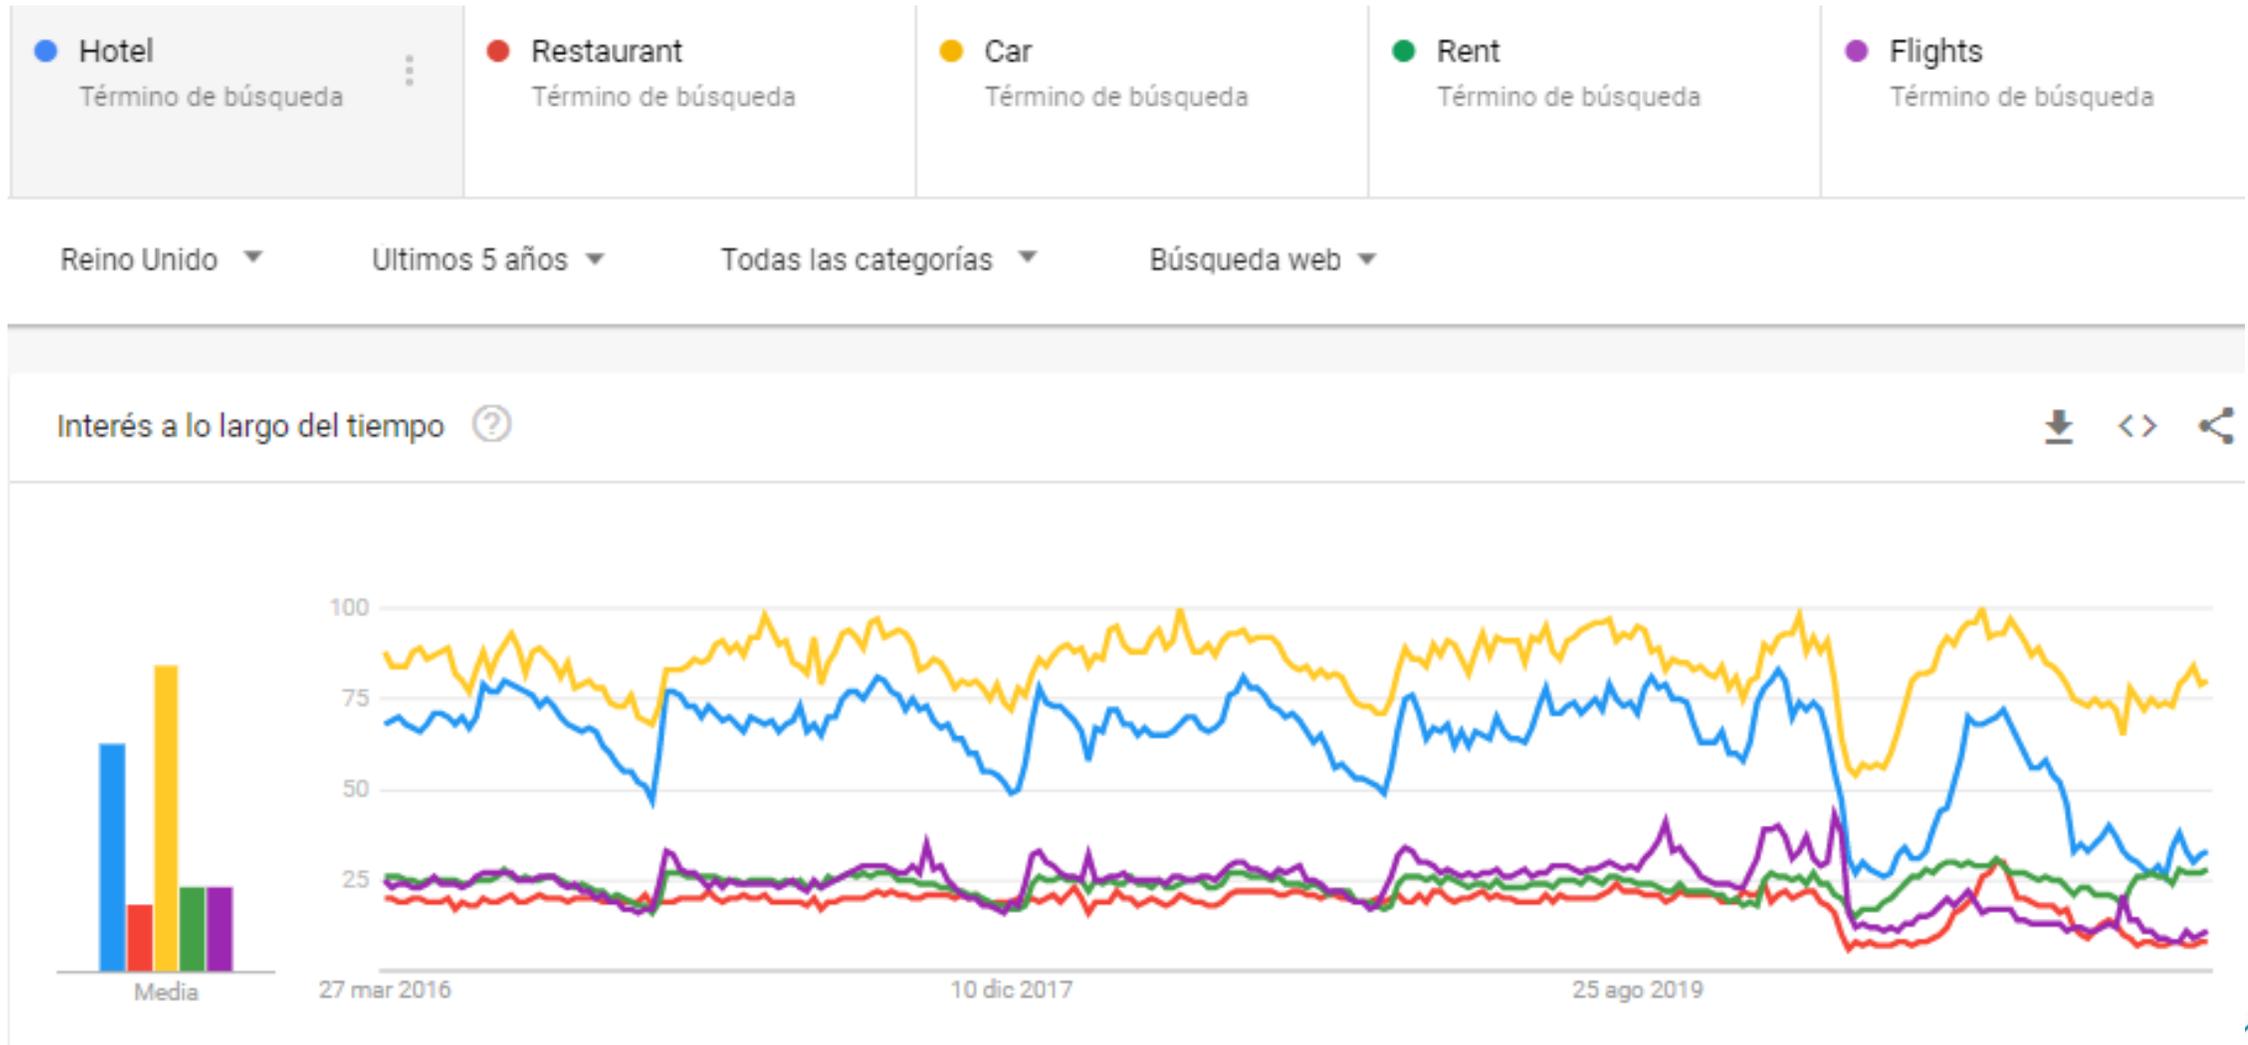


Fuente: Estimación con Tensorflow 2 (Python)

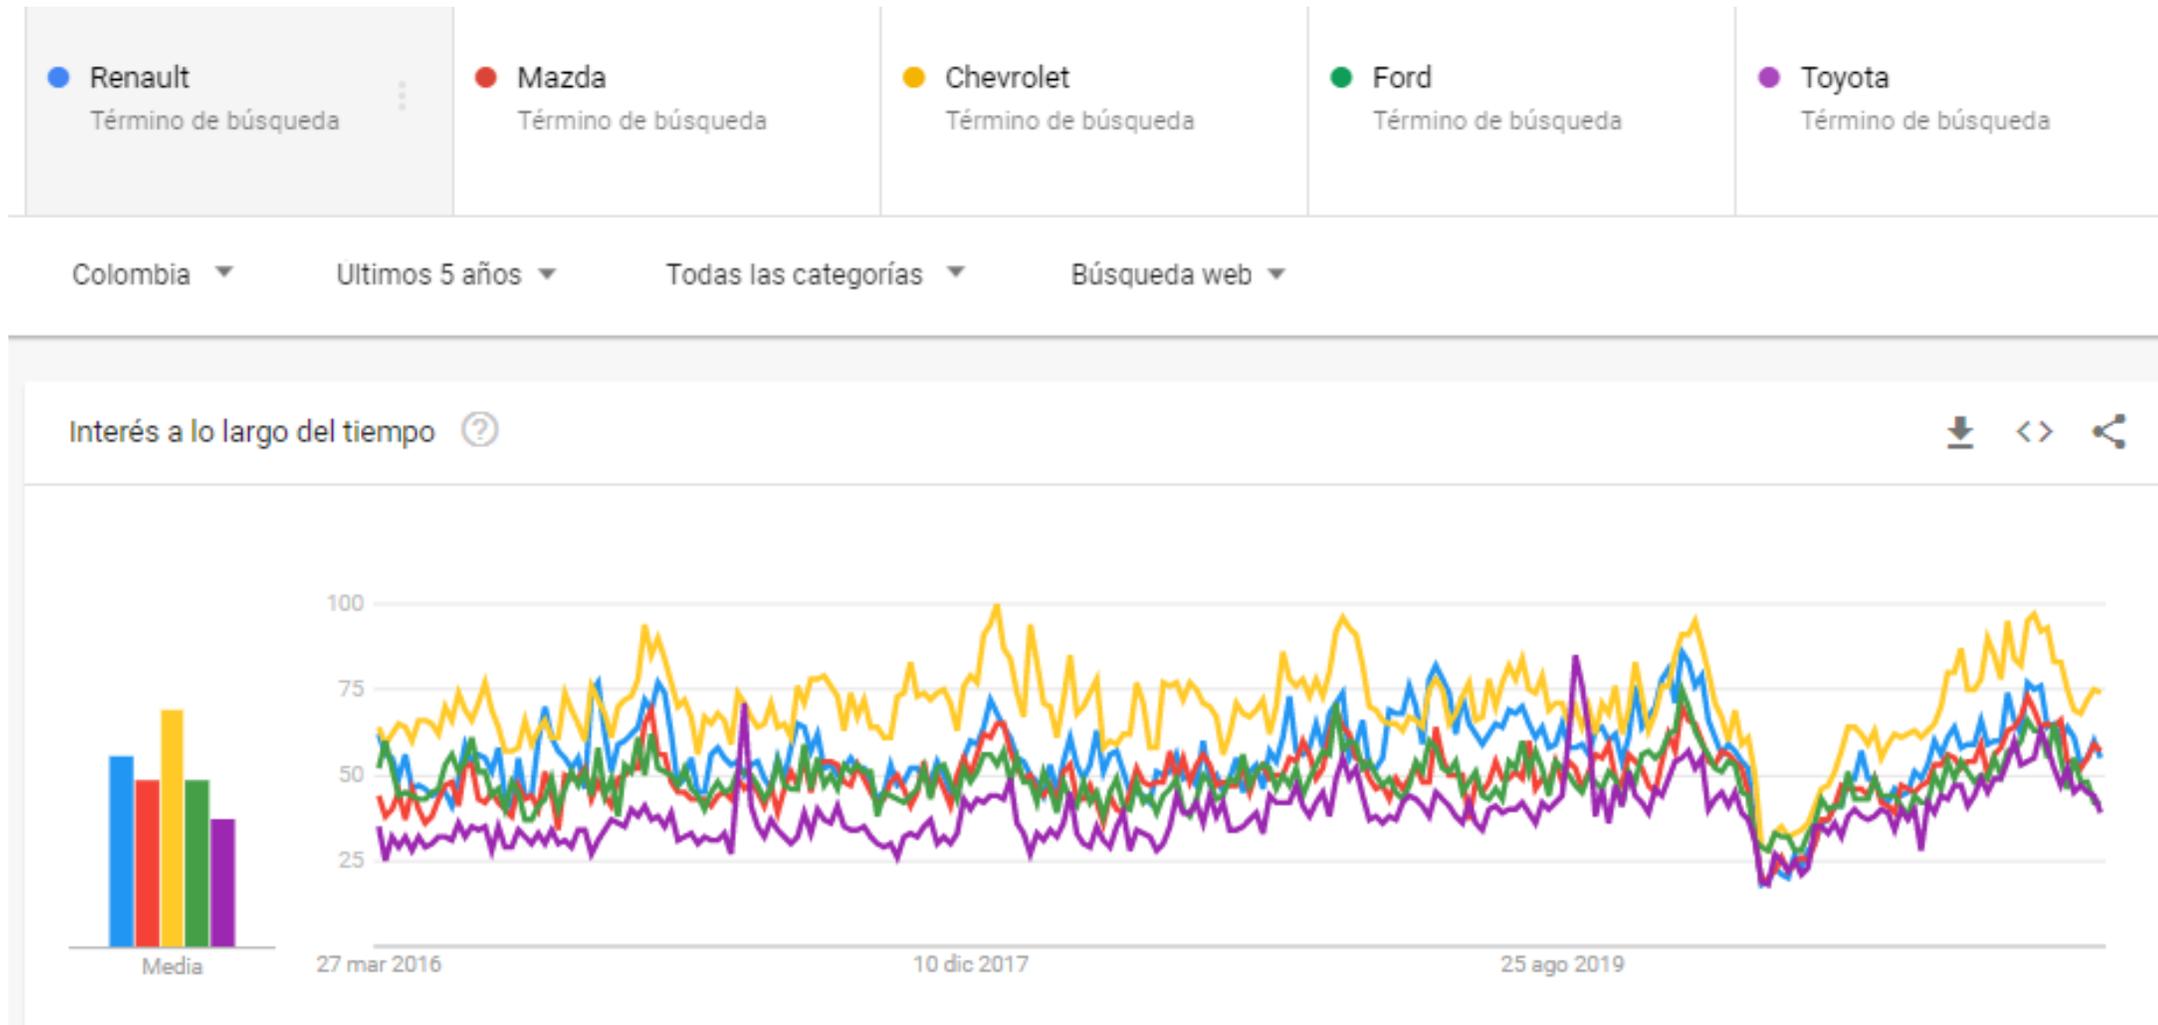
¿Qué es Google Trends? ¿Por qué es importante?



¿Qué es Google Trends? ¿Por qué es importante?



¿Qué es Google Trends? ¿Por qué es importante?



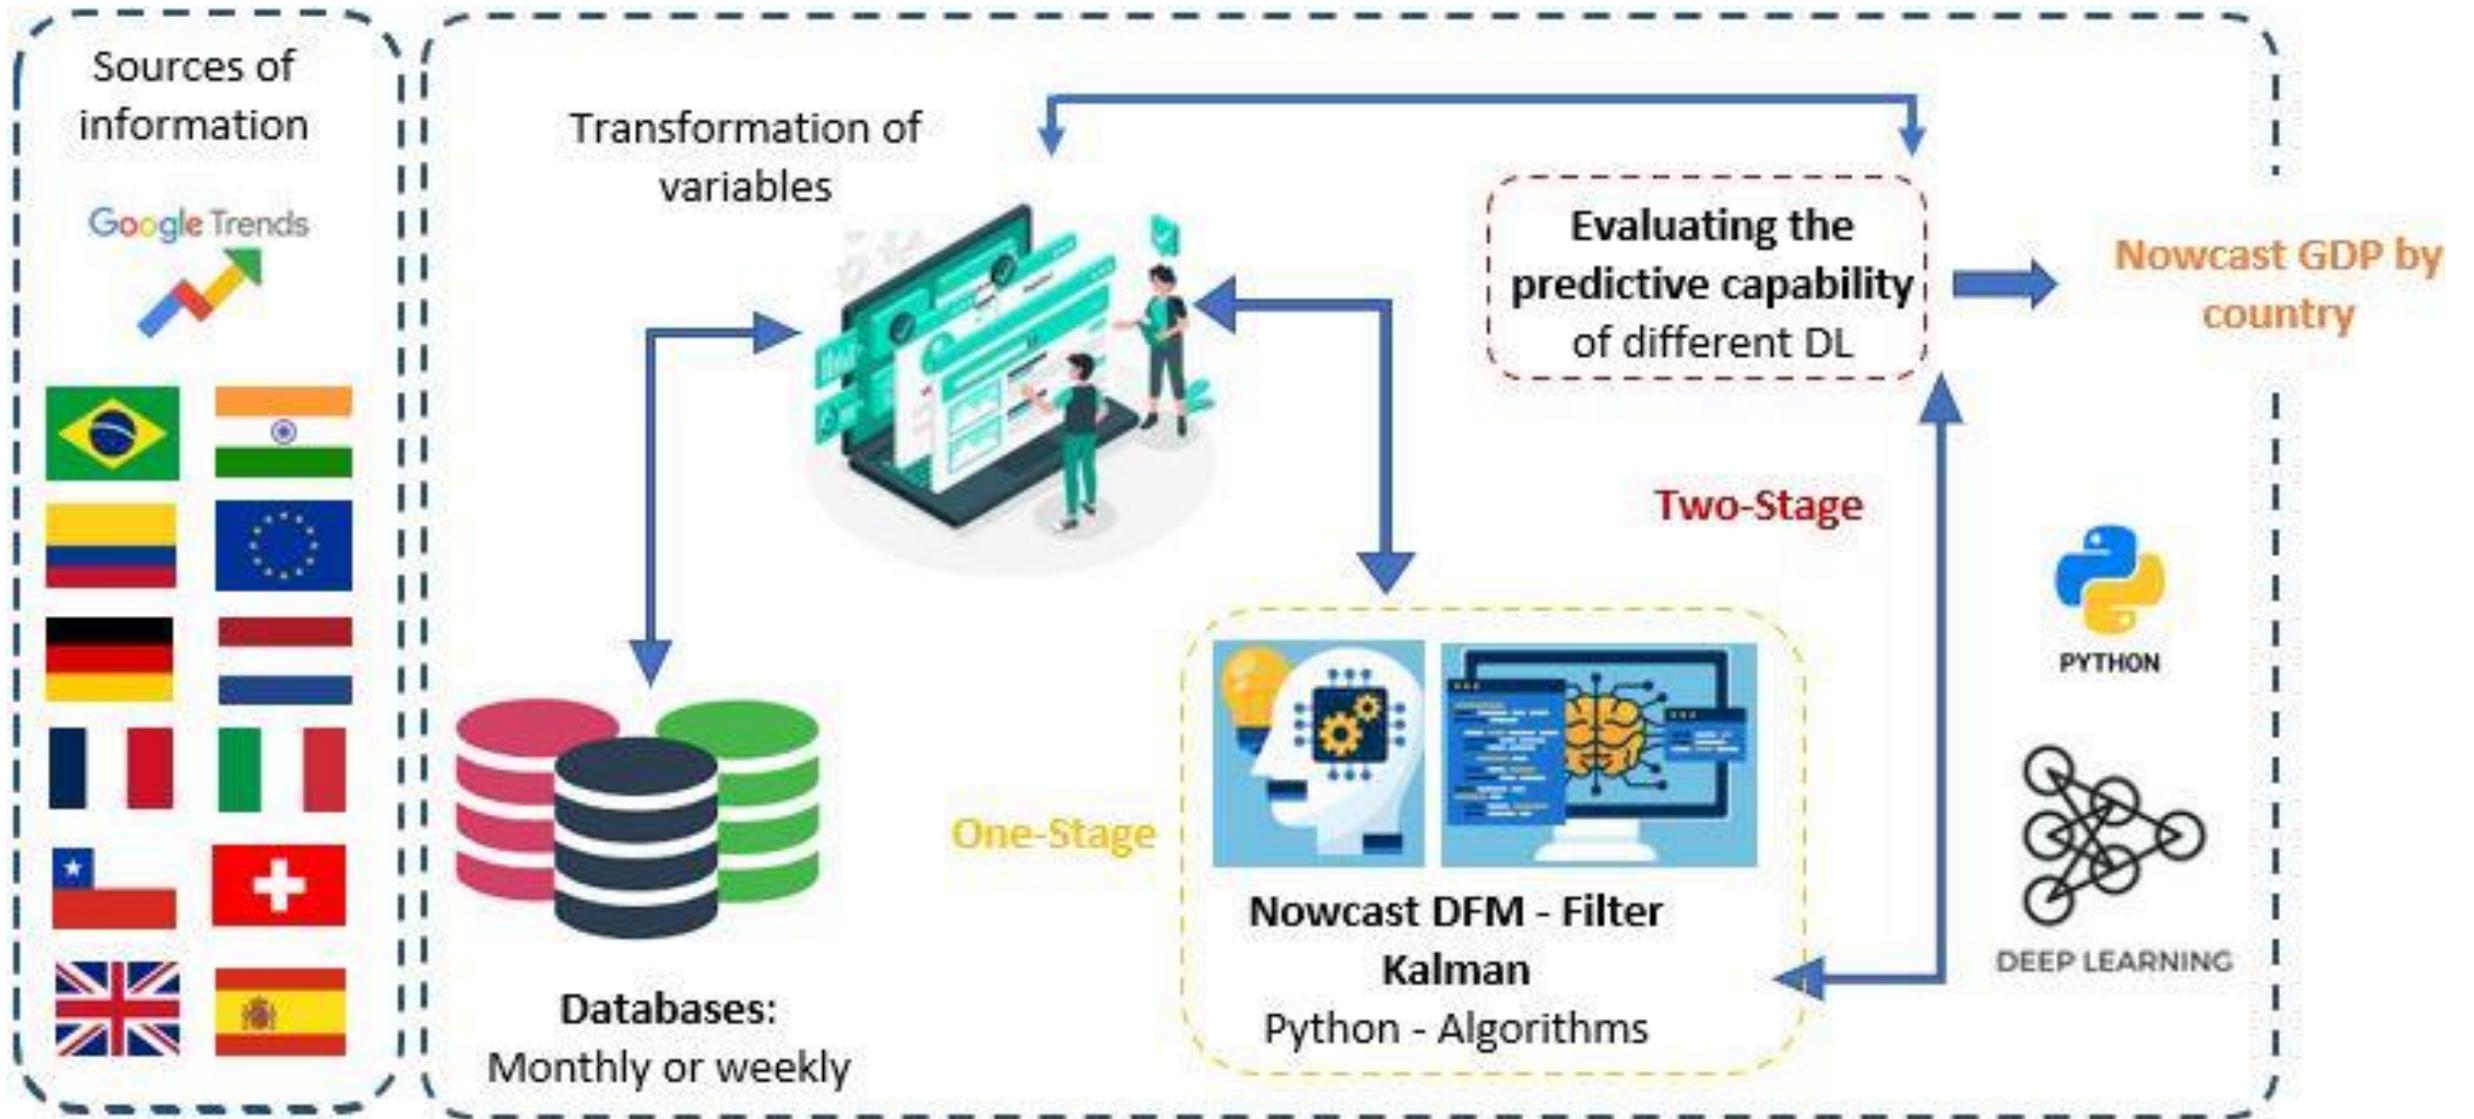
- Trabajos de referencia nowcasting PIB: Stock & Watson (2006), y Giannone et al., (2008).

Aplicaciones para varios países usando modelos de factores dinámicos, ecuaciones puente o vectores autoregresivos Bayesianos.

- Banbura (2013) y Bok (2018) para Estados Unidos
- D'Amato (2015) para Argentina
- Cepni (2019) para varios LACs
- Galvez-Mariano (2019) para México

- Google econometrics: Askitas and Zimmermann (2009), Choi y Varian (2009), Jun et al. (2018).
- GT y mejora de desempeño de nowcasting?: Combes y Bortoli (2016), Corona (2021), Medeiros y Pires (2021)
- GT y nowcasting de mayor frecuencia
A nivel de estado: Larson Sinclair (2021)
Nowcasting semanal: Woloszko (2020), Eraslan (2020), Delle Monache et al. (2021)

Proceso de construcción Nowcast_GT_DL



Correlaciones Nowcast_GT_DL. (1/2)

Correlaciones dinámicas más altas del conjunto de información respecto al ISE 2006-2021

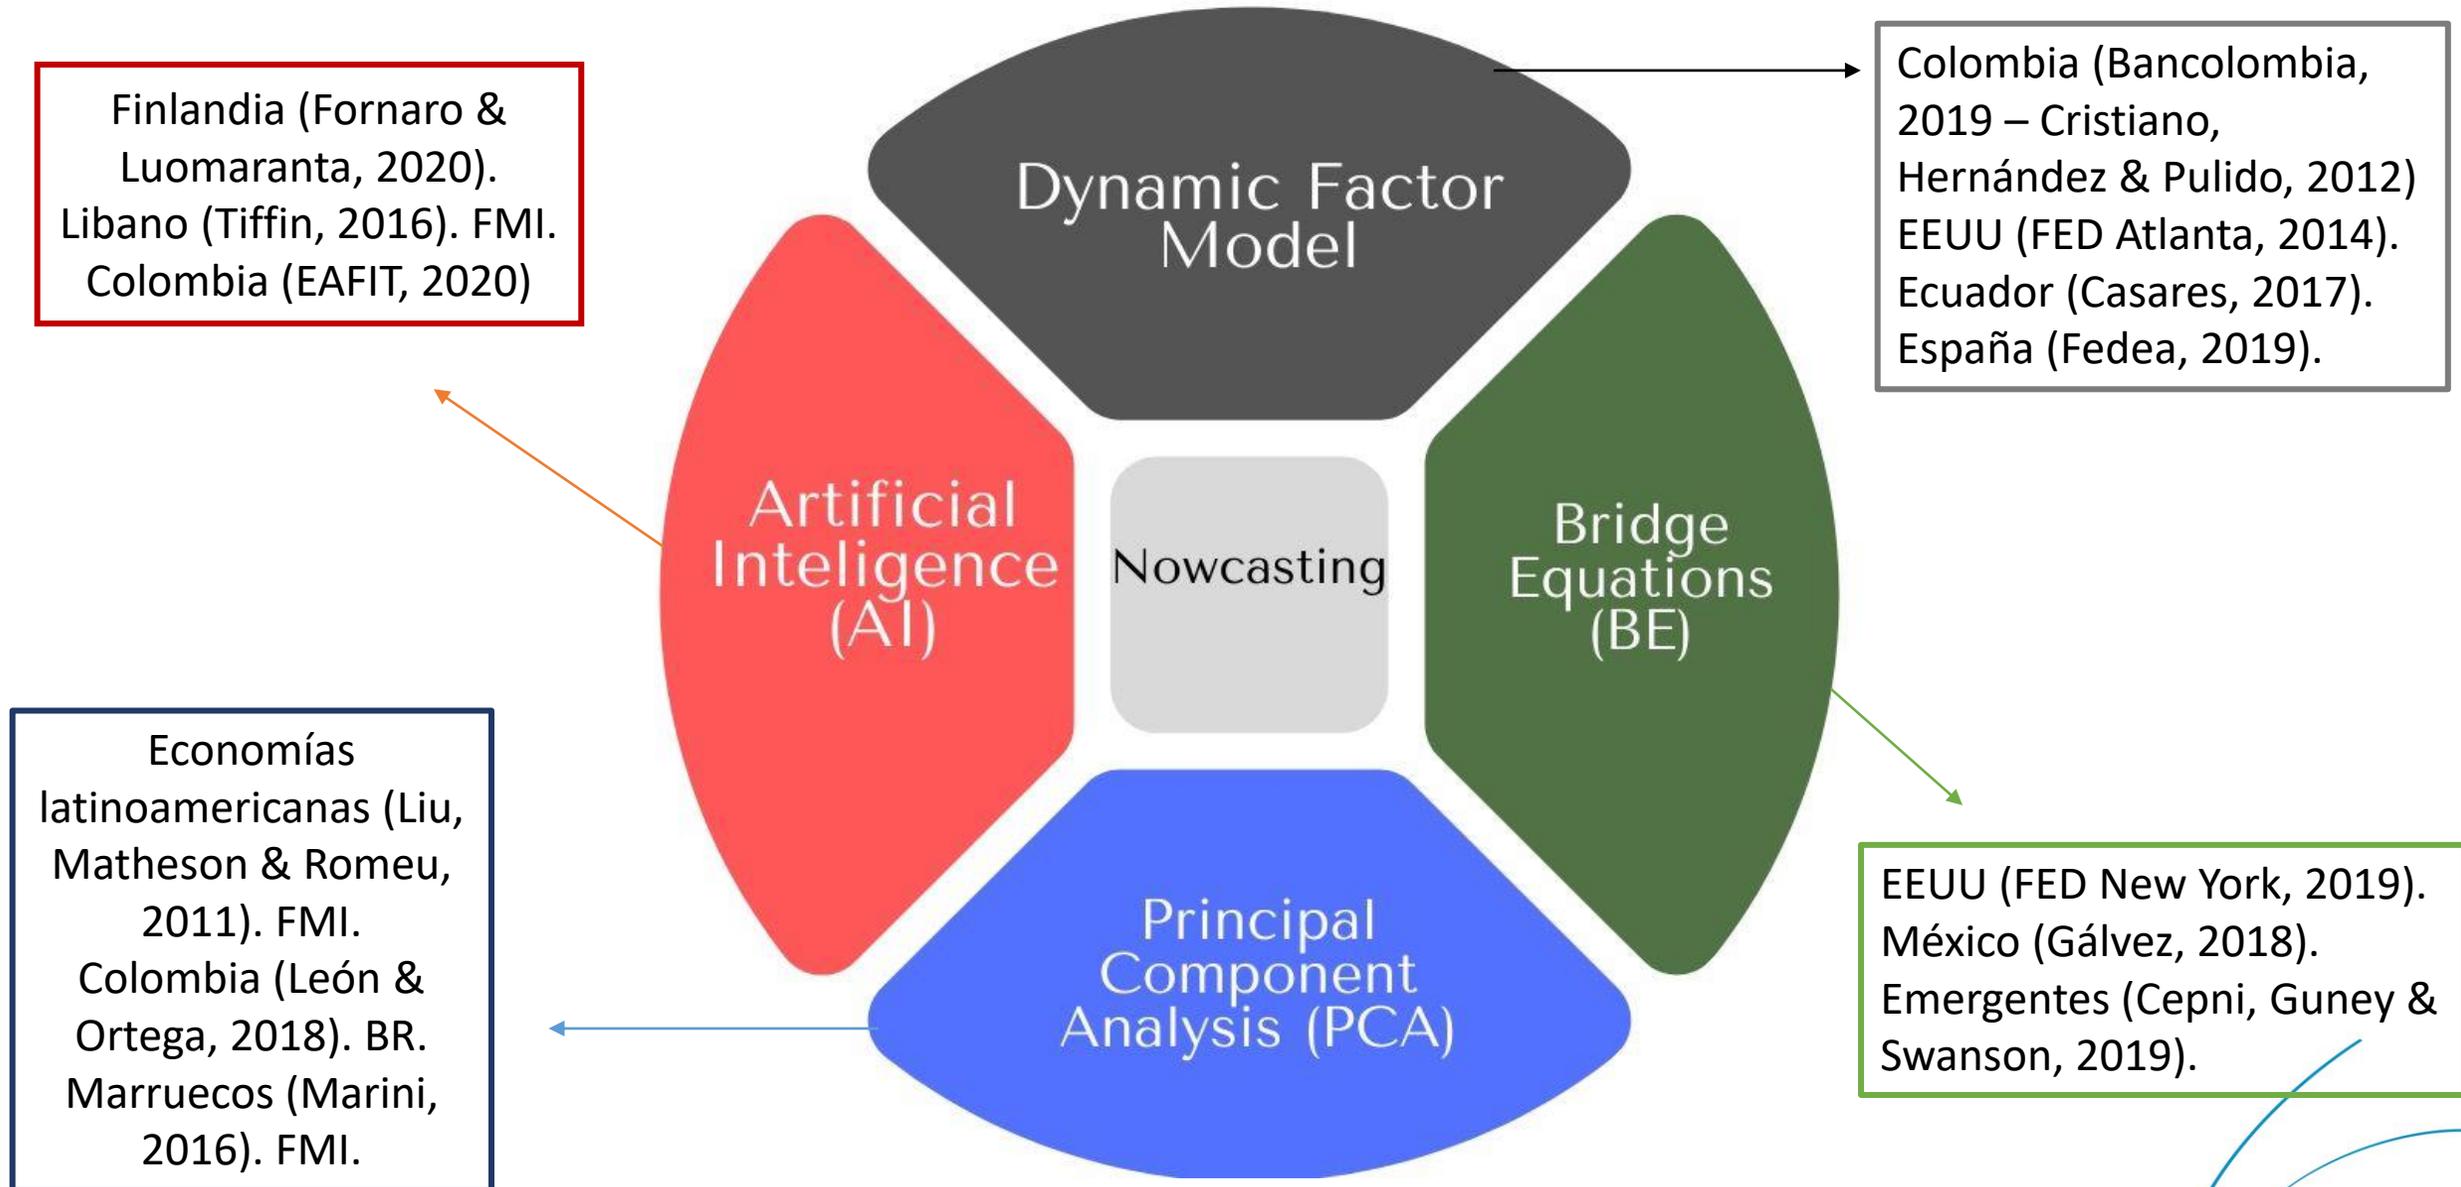
Variables	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5
"Hotel"	-0.205	-0.182	-0.128	0.065	0.221	0.483	0.663	0.468	0.258	-0.060	-0.279
"Restaurante"	-0.066	-0.181	-0.094	-0.064	0.184	0.597	0.539	0.315	0.058	-0.207	-0.242
"Vuelos"	-0.148	-0.131	-0.076	0.055	0.133	0.388	0.538	0.344	0.178	-0.120	-0.282
"Chevrolet"	0.079	0.127	-0.036	-0.054	0.040	0.187	0.436	0.247	0.116	-0.085	-0.278
"Empleo"	0.051	0.152	0.024	-0.035	-0.236	-0.415	0.152	0.275	0.288	0.112	-0.051
"Renault"	0.016	0.019	-0.041	-0.004	0.028	0.176	0.391	0.220	0.160	0.011	-0.131
"Honda"	-0.008	0.049	-0.035	-0.057	-0.067	0.118	0.351	0.305	0.280	0.022	-0.175
"Mazda"	0.051	0.025	-0.072	-0.080	-0.025	0.109	0.325	0.265	0.162	0.059	-0.098
"Carro"	0.030	0.002	-0.083	-0.180	-0.185	-0.072	0.221	0.300	0.232	0.231	0.026
"Toyota"	0.029	0.006	-0.163	-0.164	-0.114	0.066	0.256	0.258	0.252	0.148	0.017
"Usados"	-0.011	0.066	0.009	-0.044	-0.020	-0.025	0.218	0.197	0.054	-0.061	-0.252
"Hyundai"	0.140	0.117	0.008	-0.047	-0.018	-0.029	0.216	0.109	0.011	0.012	-0.047
Procíclica y contemporánea	Procíclica y adelantada			Procíclica y rezagada			Anticíclica y rezagada			Anticíclica y contemporánea	

Fuente: Elaboración propia

Correlaciones dinámicas más altas del conjunto de información respecto al ISE 2010-2021

Variables	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5
"Hotel"	-0.219	-0.201	-0.143	0.098	0.284	0.559	0.719	0.515	0.305	-0.015	-0.251
"Restaurante"	-0.105	-0.185	-0.100	-0.069	0.222	0.669	0.621	0.432	0.196	-0.071	-0.194
"Vuelos"	-0.247	-0.215	-0.125	0.016	0.168	0.490	0.675	0.514	0.315	-0.067	-0.258
"Chevrolet"	0.027	0.037	-0.128	-0.039	0.105	0.332	0.567	0.374	0.170	-0.117	-0.300
"Mazda"	-0.070	-0.053	-0.134	-0.060	0.056	0.330	0.544	0.359	0.226	0.008	-0.208
"Renault"	-0.033	-0.003	-0.051	0.000	0.149	0.332	0.503	0.314	0.196	-0.006	-0.185
"Toyota"	-0.116	-0.072	-0.100	-0.091	0.076	0.255	0.490	0.381	0.270	0.105	-0.076
"Honda"	-0.017	0.033	-0.089	-0.079	-0.047	0.130	0.418	0.387	0.320	0.047	-0.134
"Hyundai"	0.024	-0.021	-0.109	-0.045	0.074	0.211	0.397	0.205	0.108	0.016	-0.135
"Usados"	-0.047	0.079	0.021	0.046	0.071	0.081	0.359	0.298	0.137	-0.086	-0.301
"Empleo"	0.019	0.130	0.010	-0.015	-0.181	-0.339	0.196	0.317	0.313	0.109	-0.057
"Carro"	-0.084	-0.088	-0.144	-0.174	-0.112	0.054	0.328	0.309	0.196	0.181	-0.045
Procíclica y contemporánea	Procíclica y adelantada			Procíclica y rezagada			Anticíclica y rezagada			Anticíclica y contemporánea	

Tipos de modelos Nowcasting de la actividad económica



Extrayendo el factor de GT

$$y_t = \Lambda f_t + Bx_t + u_t$$

$$f_t = A_1 f_{t-1} + \dots + A_p f_{t-p} + \eta_t \quad \eta_t \sim N(0, I)$$

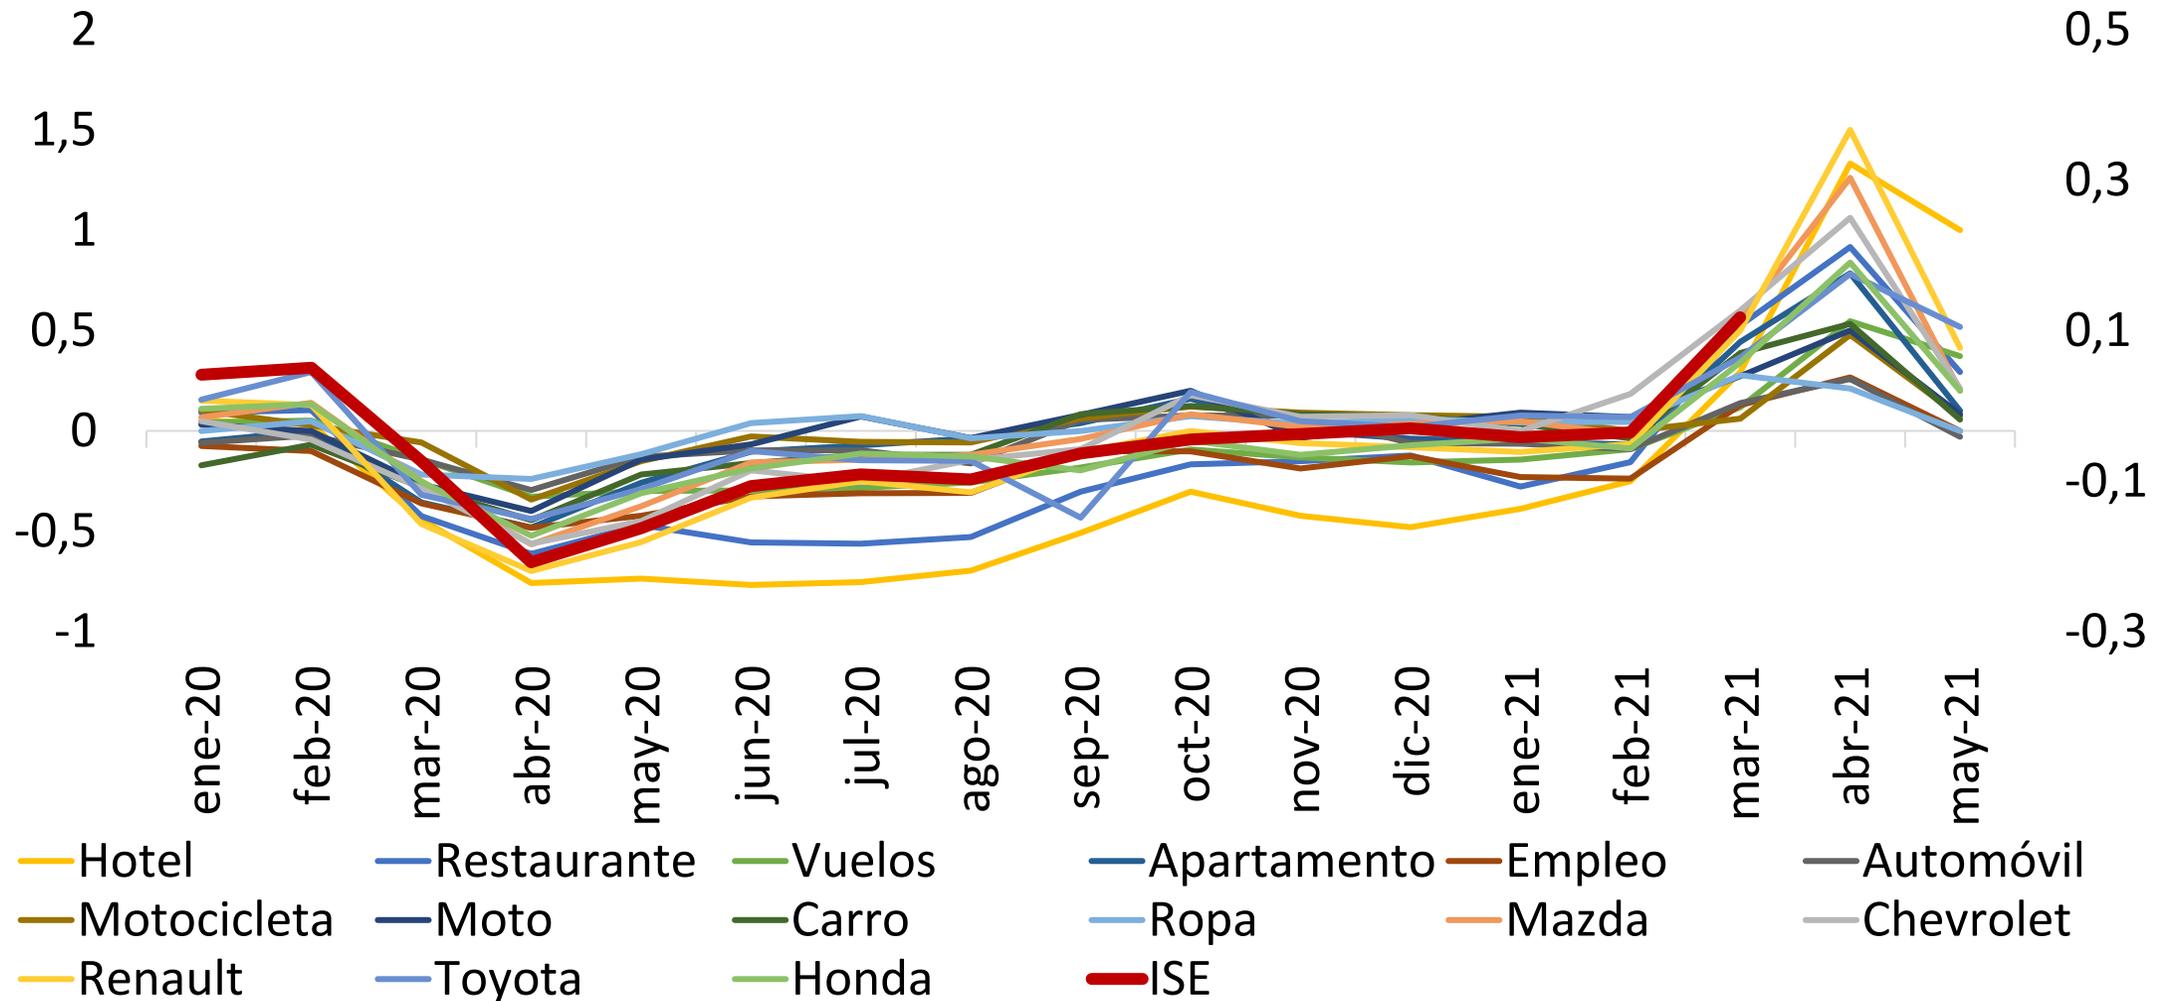
$$u_t = C_1 u_{t-1} + \dots + C_q u_{t-q} + \varepsilon_t \quad \varepsilon_t \sim N(0, \Sigma)$$

$$y_{i,t} = \lambda_i f_t + u_{i,t}$$

$$u_{i,t} = c_{i,1} u_{i,t-1} + c_{i,2} u_{i,t-2} + \varepsilon_{i,t} \quad \varepsilon_{i,t} \sim N(0, \sigma_i^2)$$

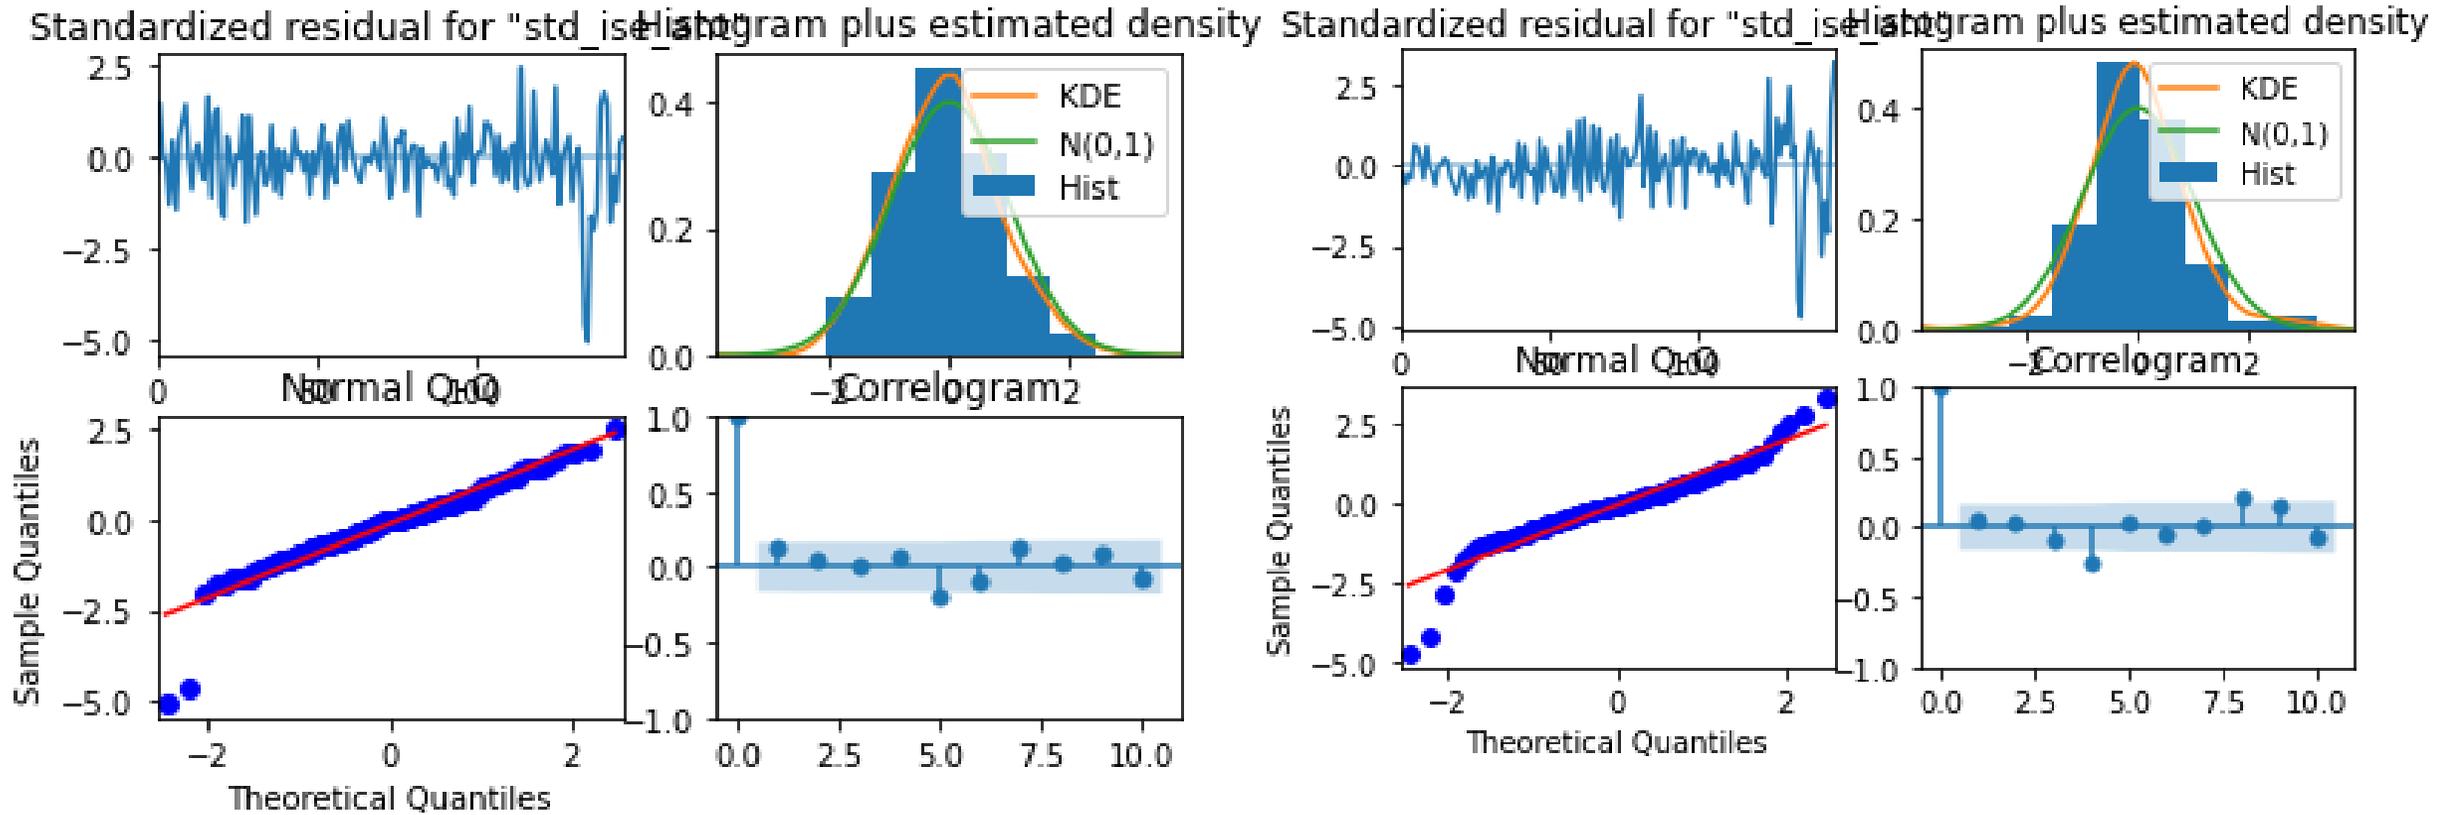
$$f_t = a_1 f_{t-1} + a_2 f_{t-2} + \eta_t \quad \eta_t \sim N(0, I)$$

Extrayendo el factor de GT

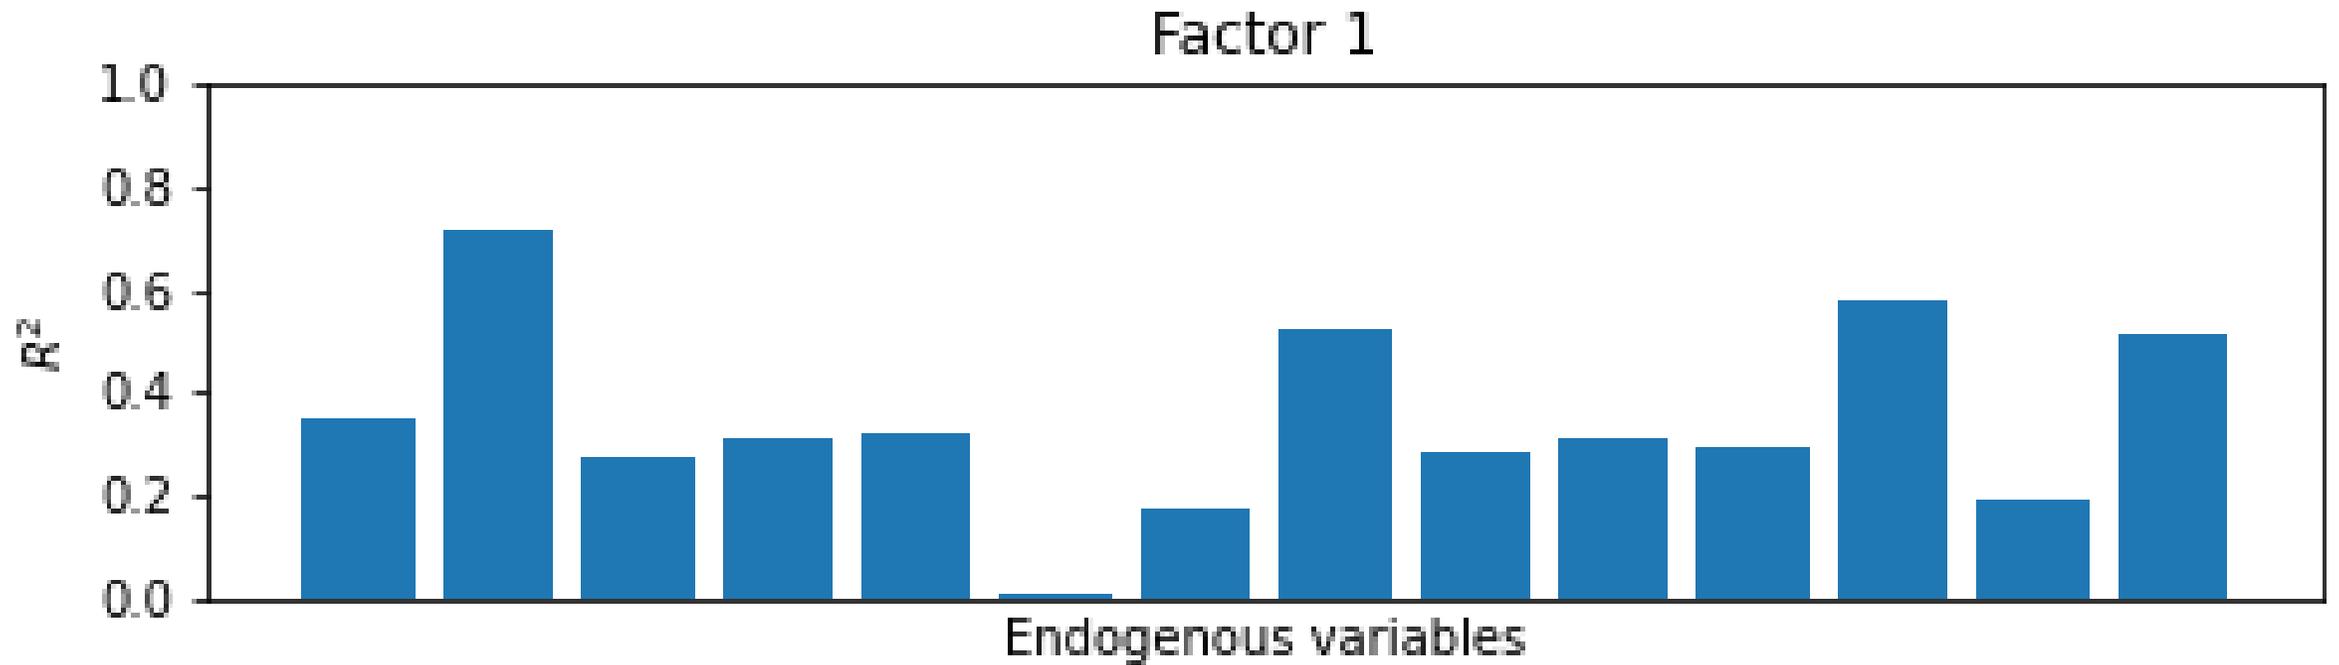


Fuente: Elaboración propia con datos de Google Trends & DANE

Extrayendo el factor de GT Brazil - EEUU



Fuente: Estimación propia.

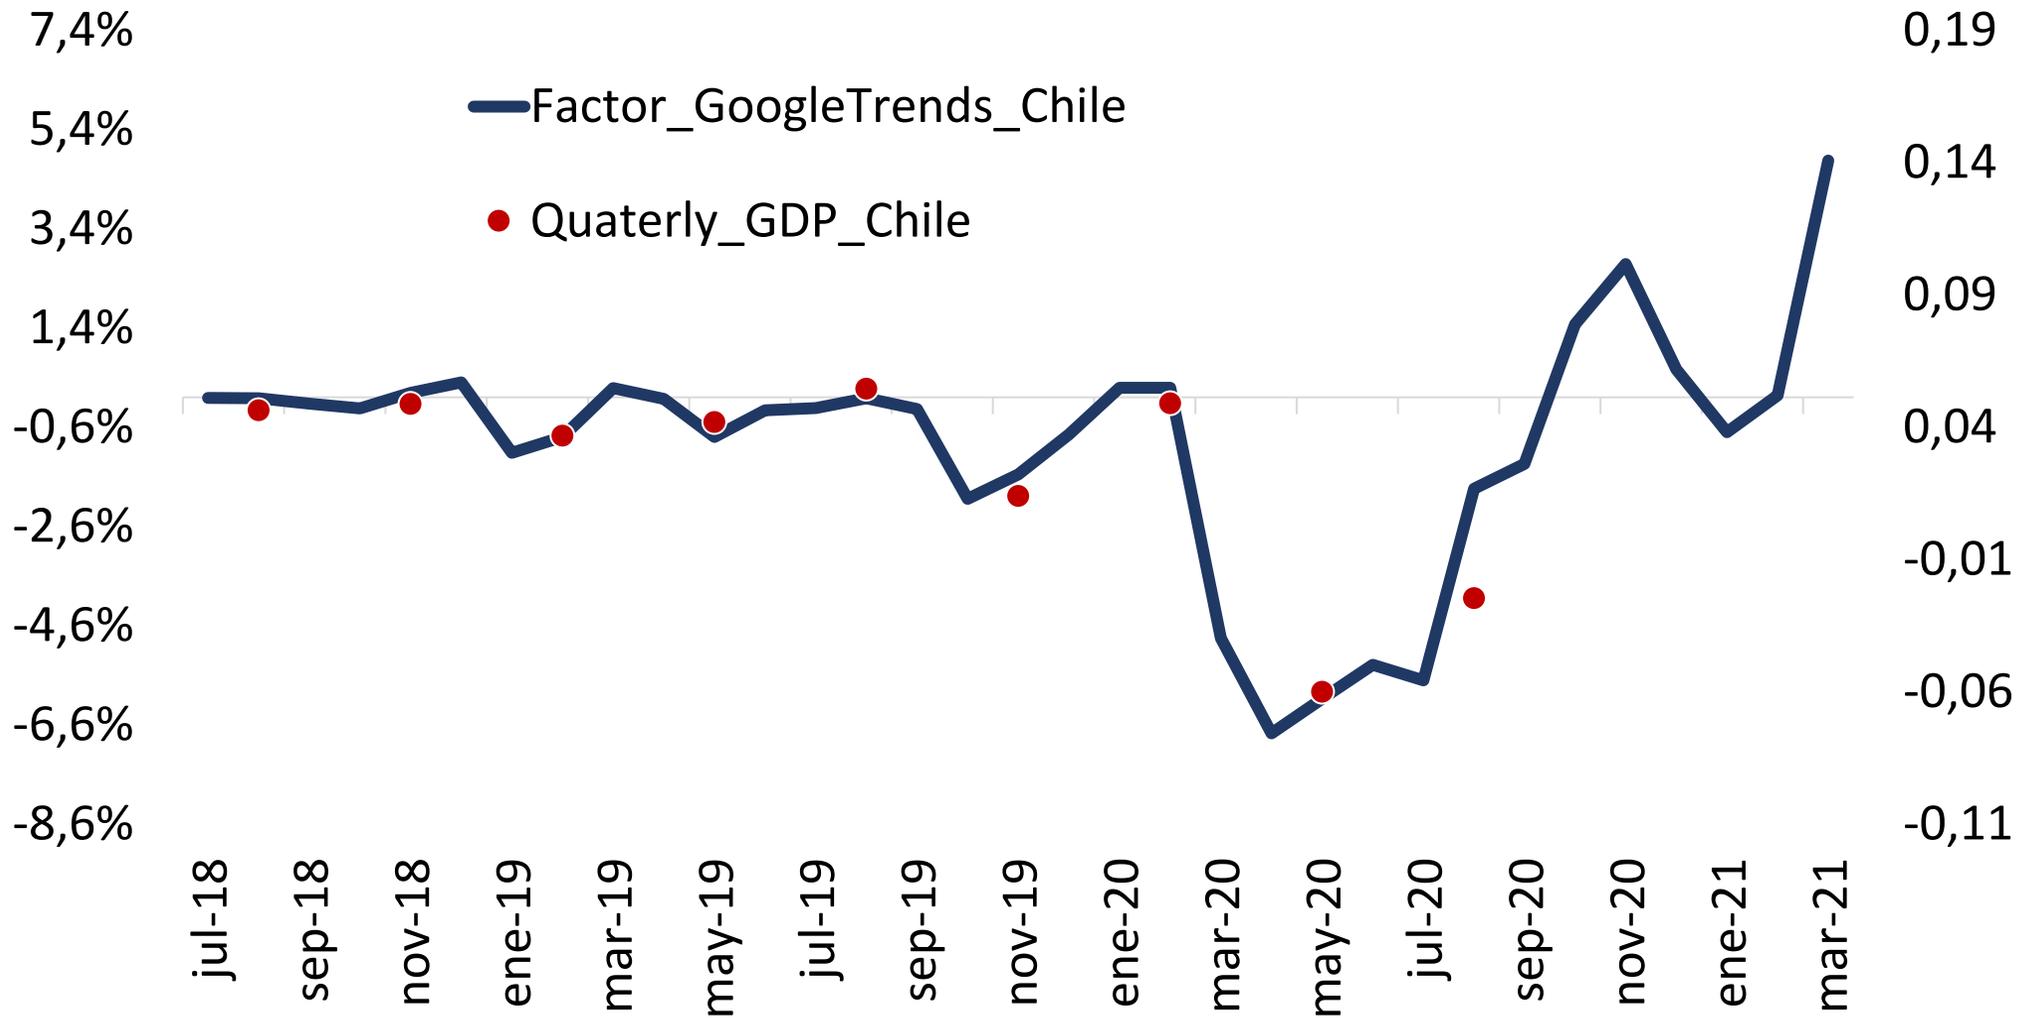


Fuente: Estimación propia.

Lenguajes de programación para el Nowcast_GT_DL: Un enfoque Dinámico de Factores

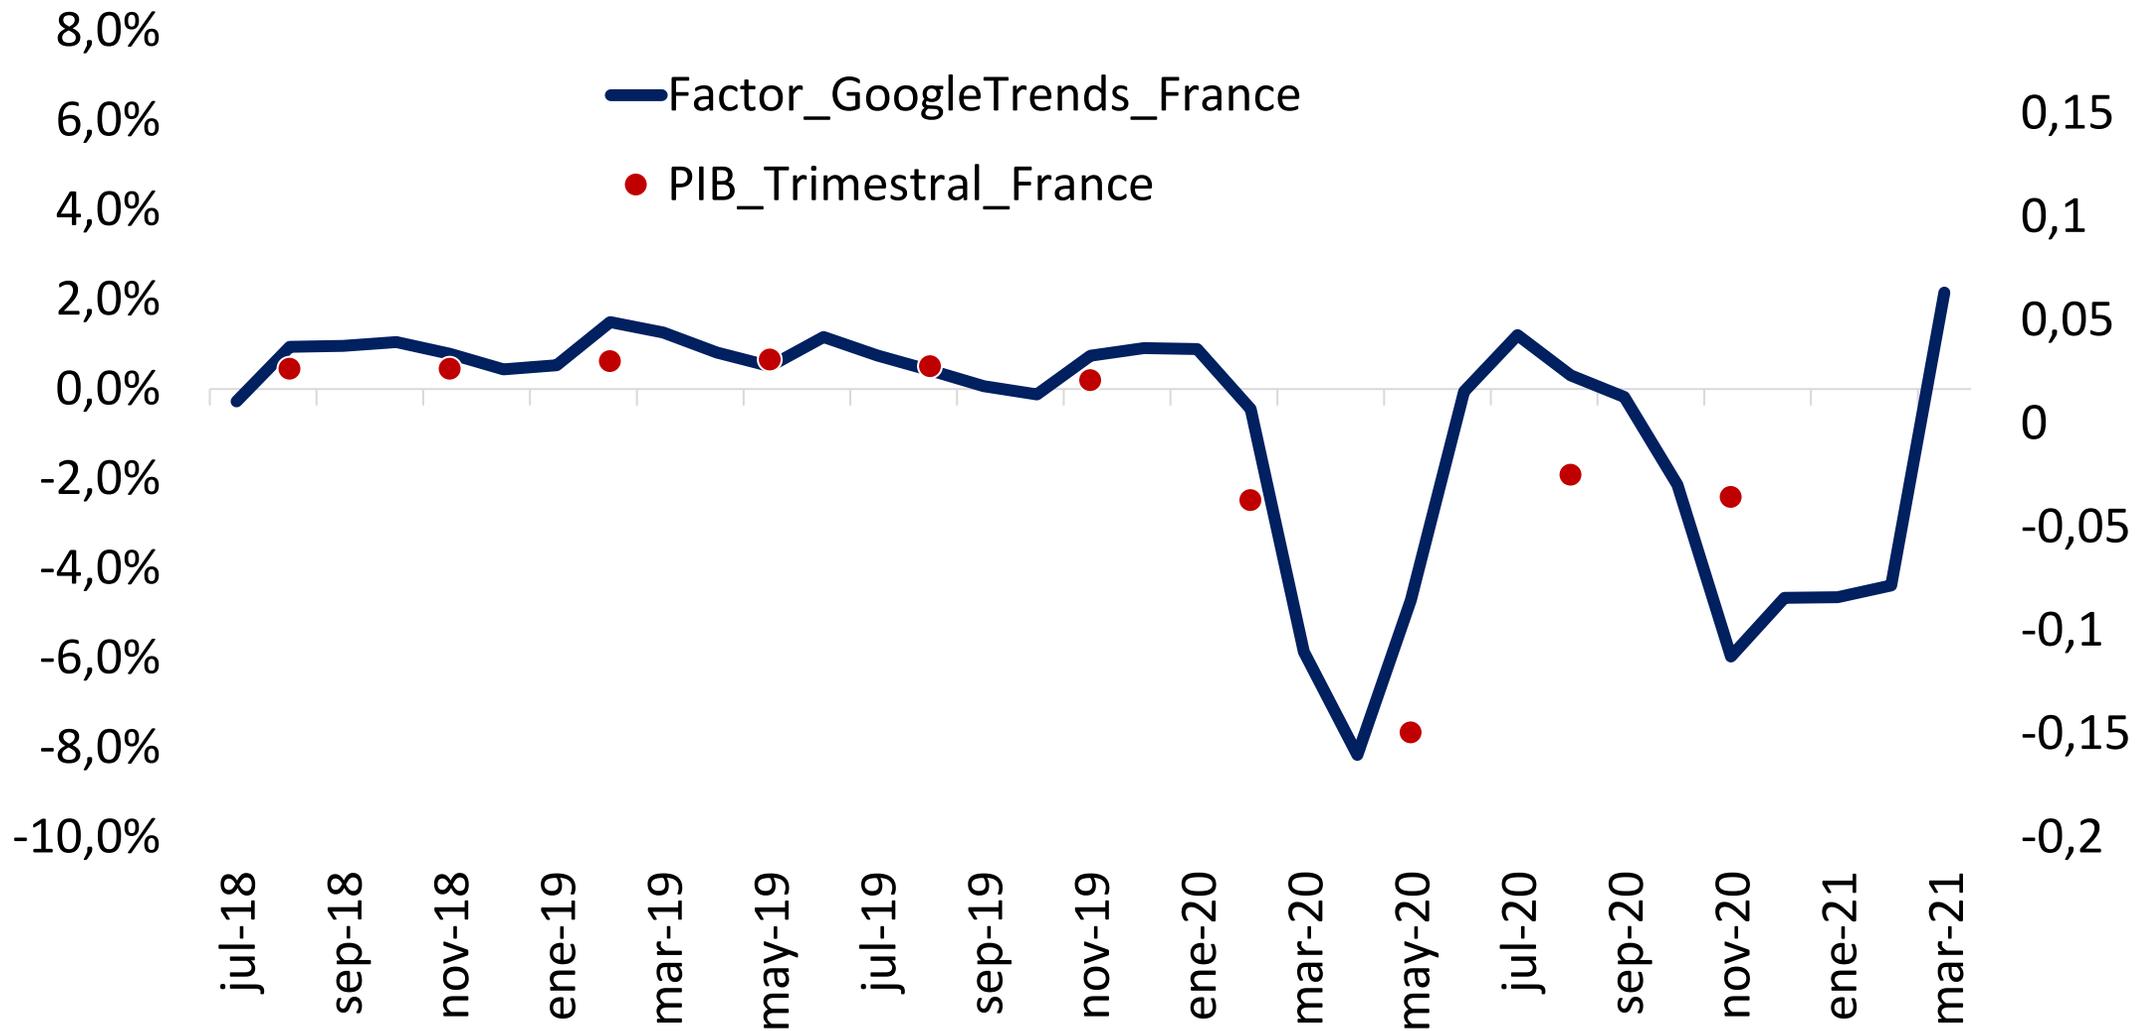


Factor vs PIB Chile



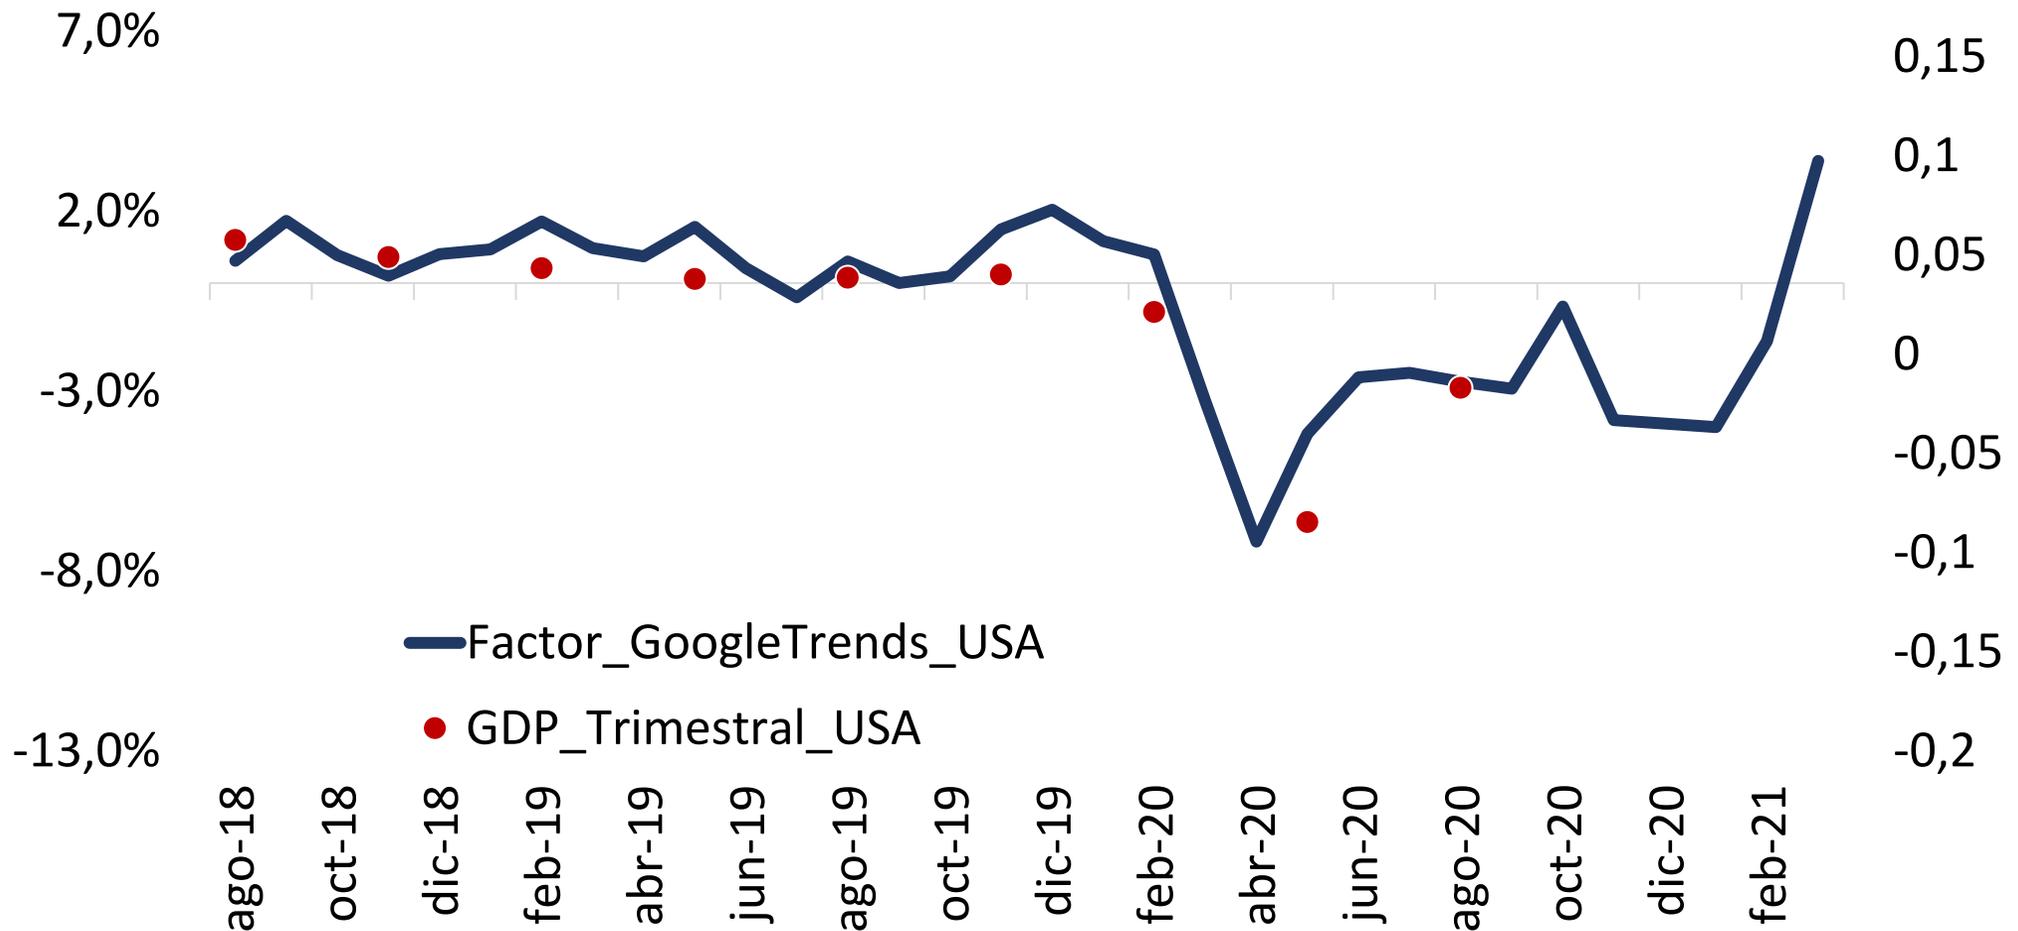
Fuente: Estimación propia con DFM

Factor vs PIB France



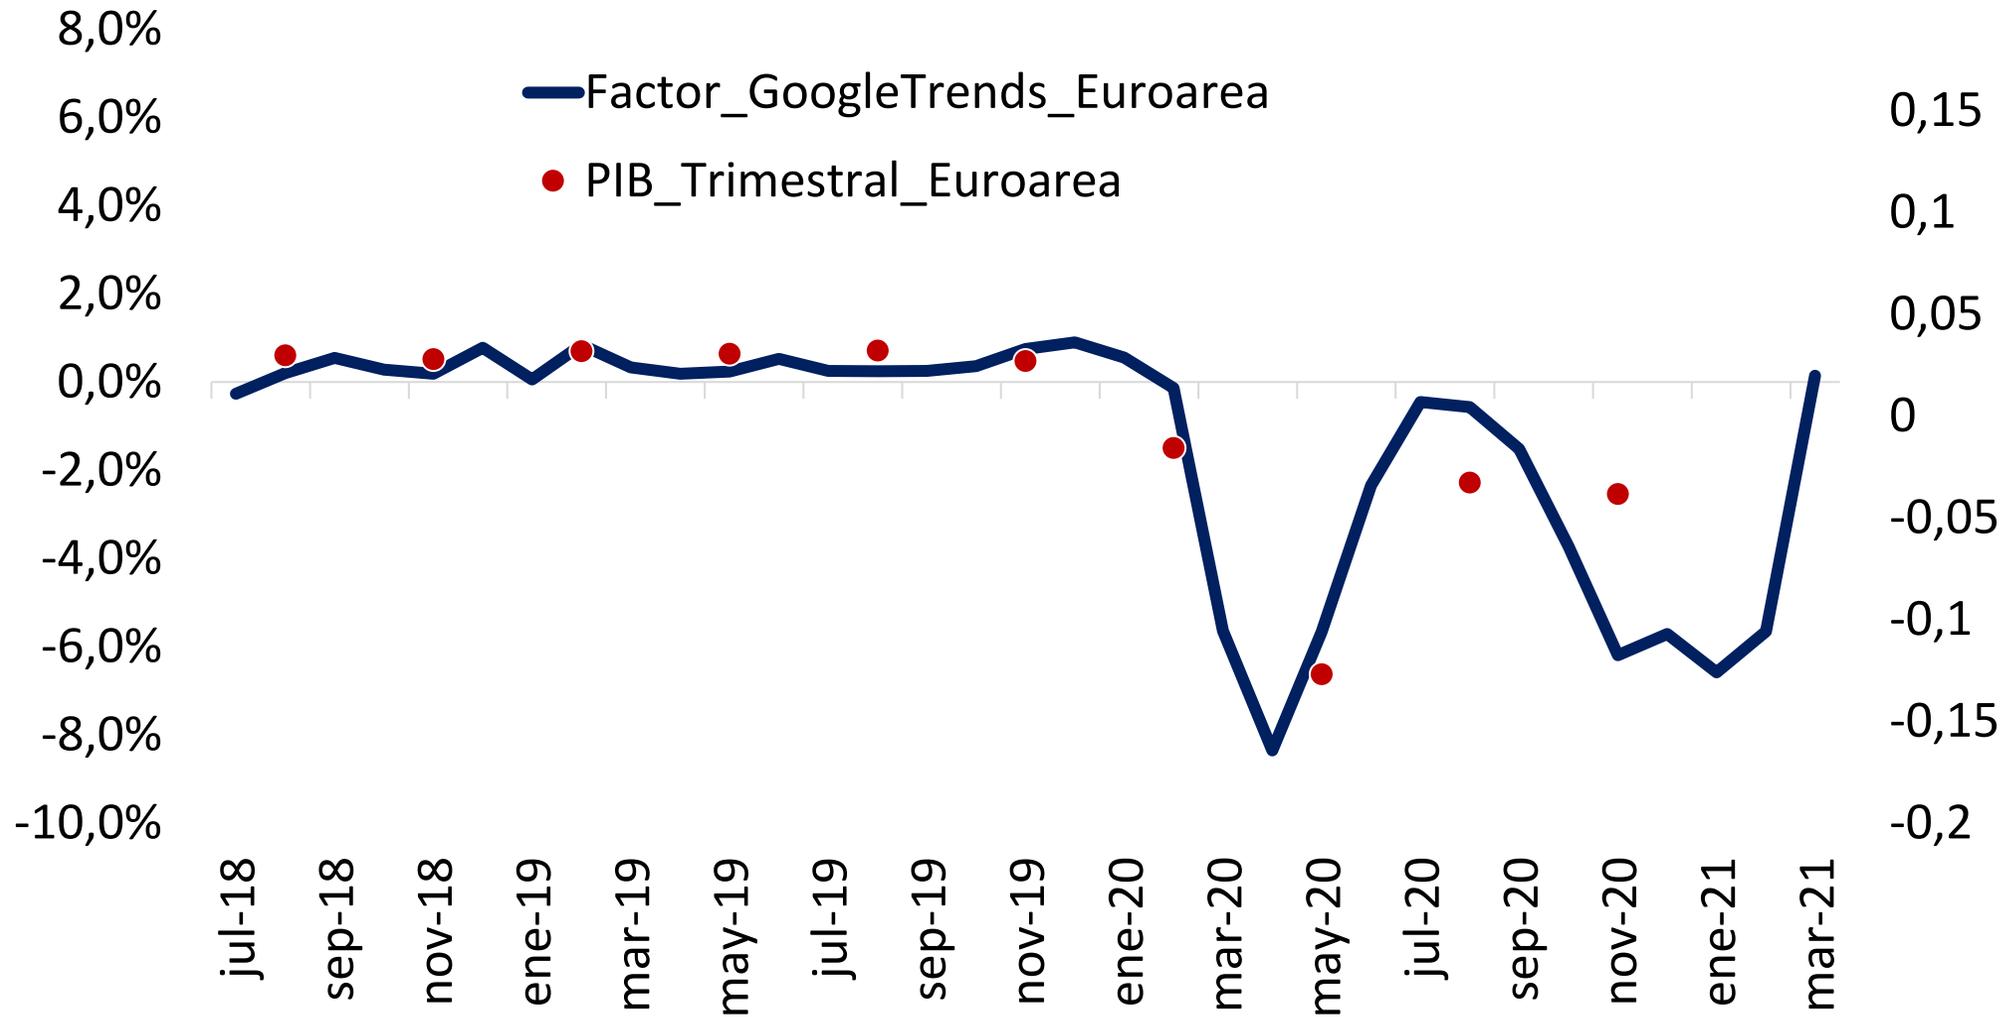
Fuente: Estimación propia con DFM

Factor vs PIB USA



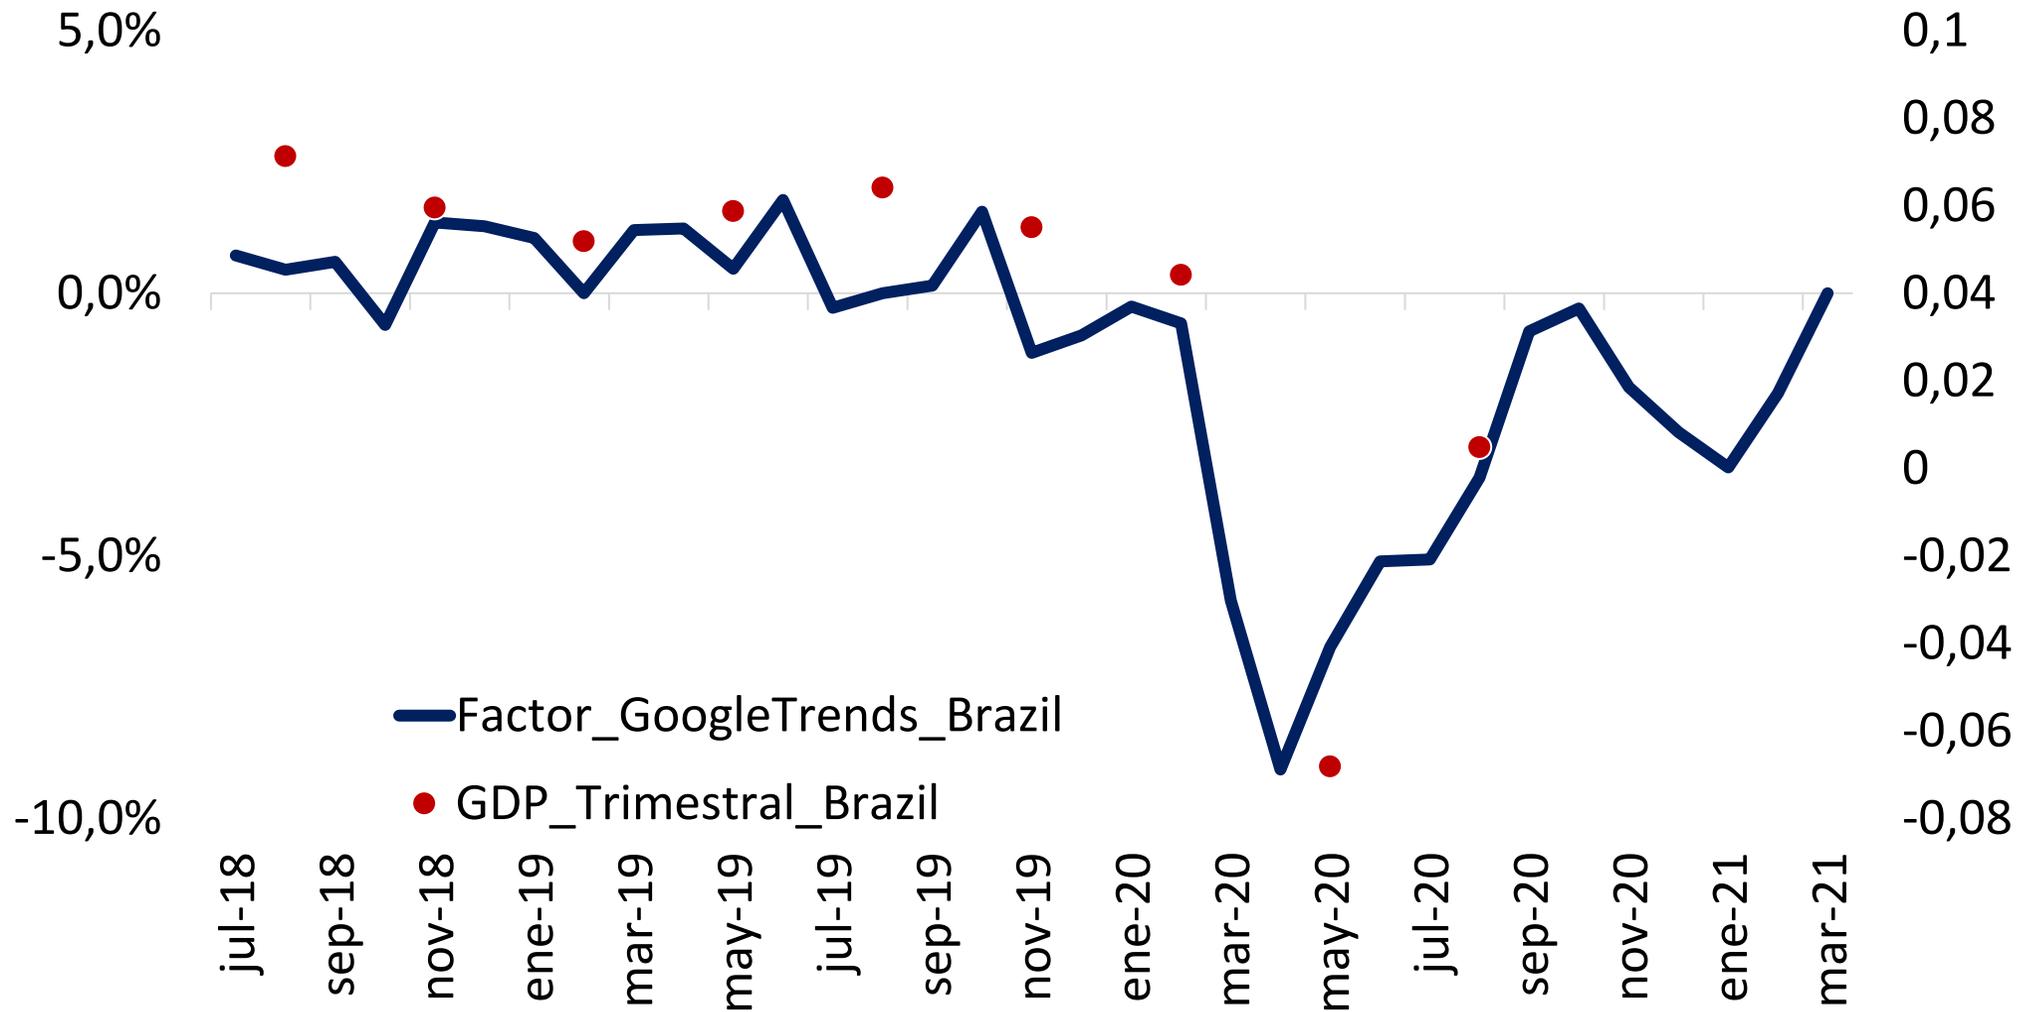
Fuente: Estimación propia con DFM

Factor vs PIB Zona Euro



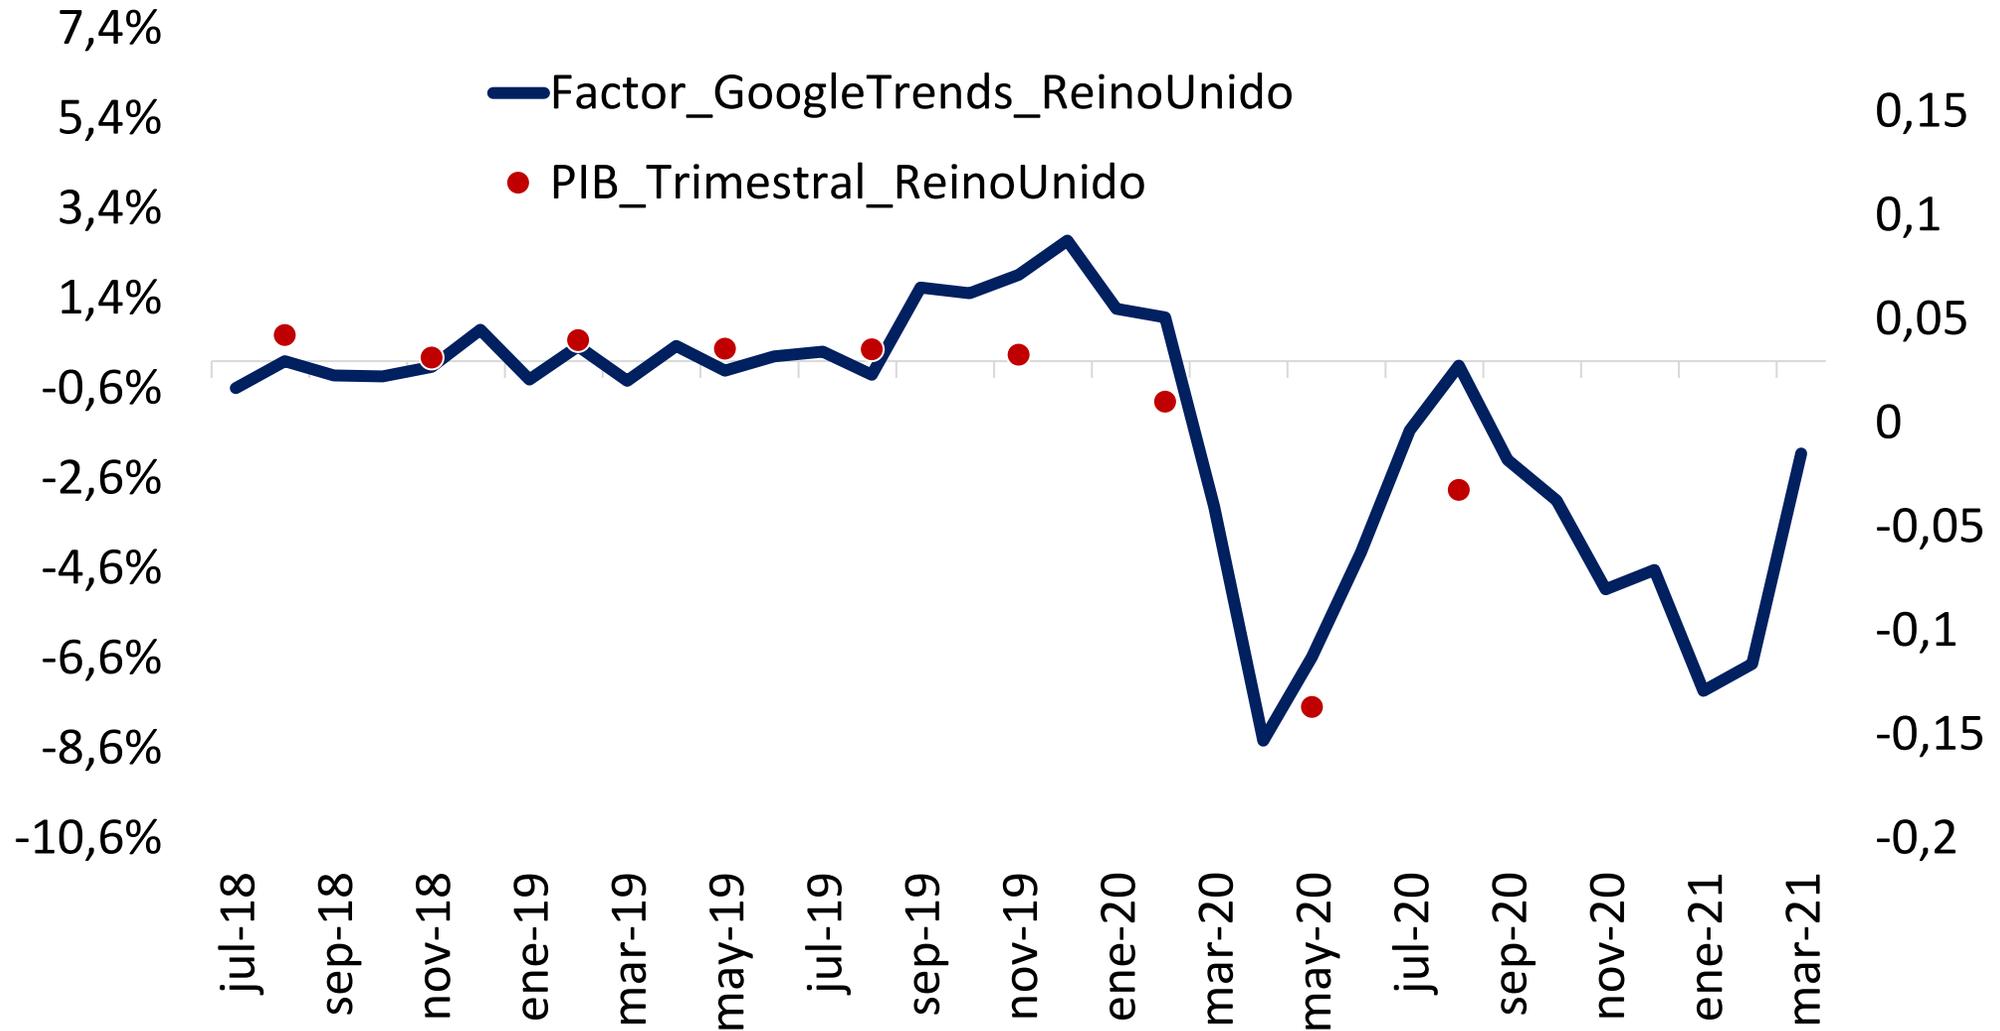
Fuente: Estimación propia.

Factor vs PIB Brazil



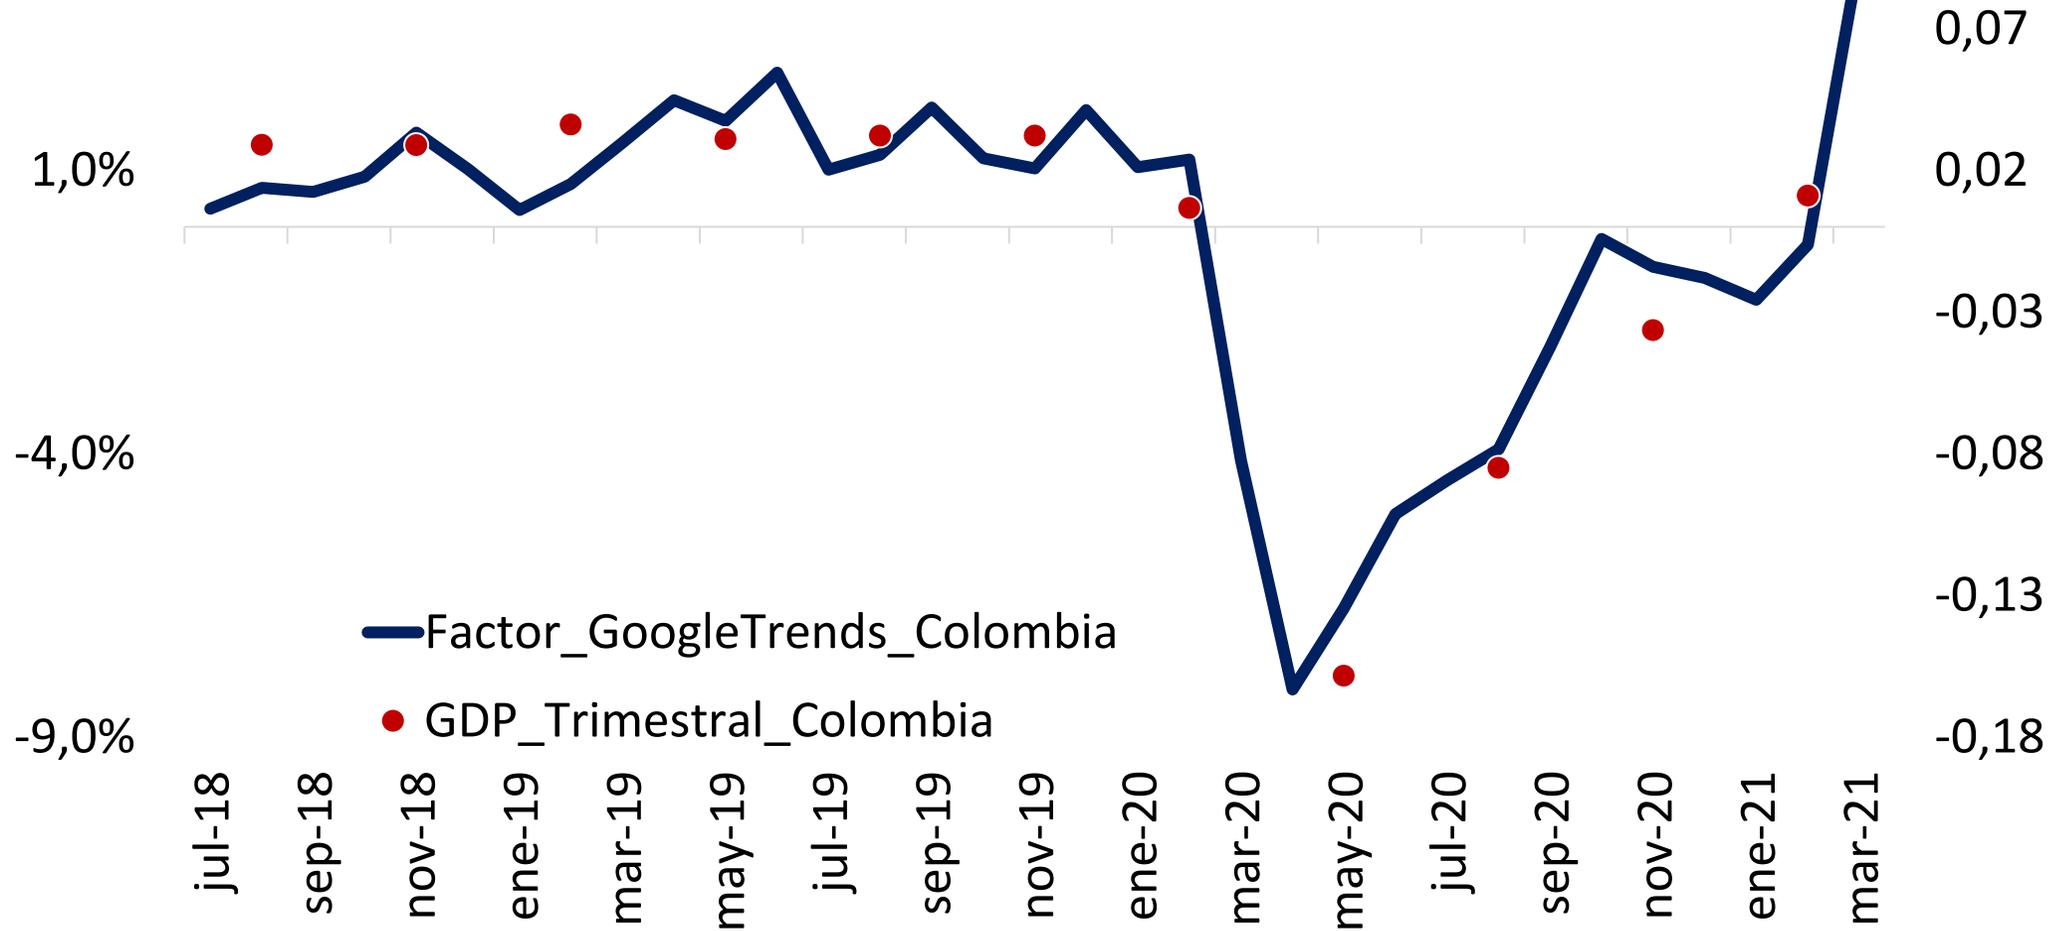
Fuente: Estimación propia.

Factor vs PIB Reino Unido



Fuente: Estimación propia.

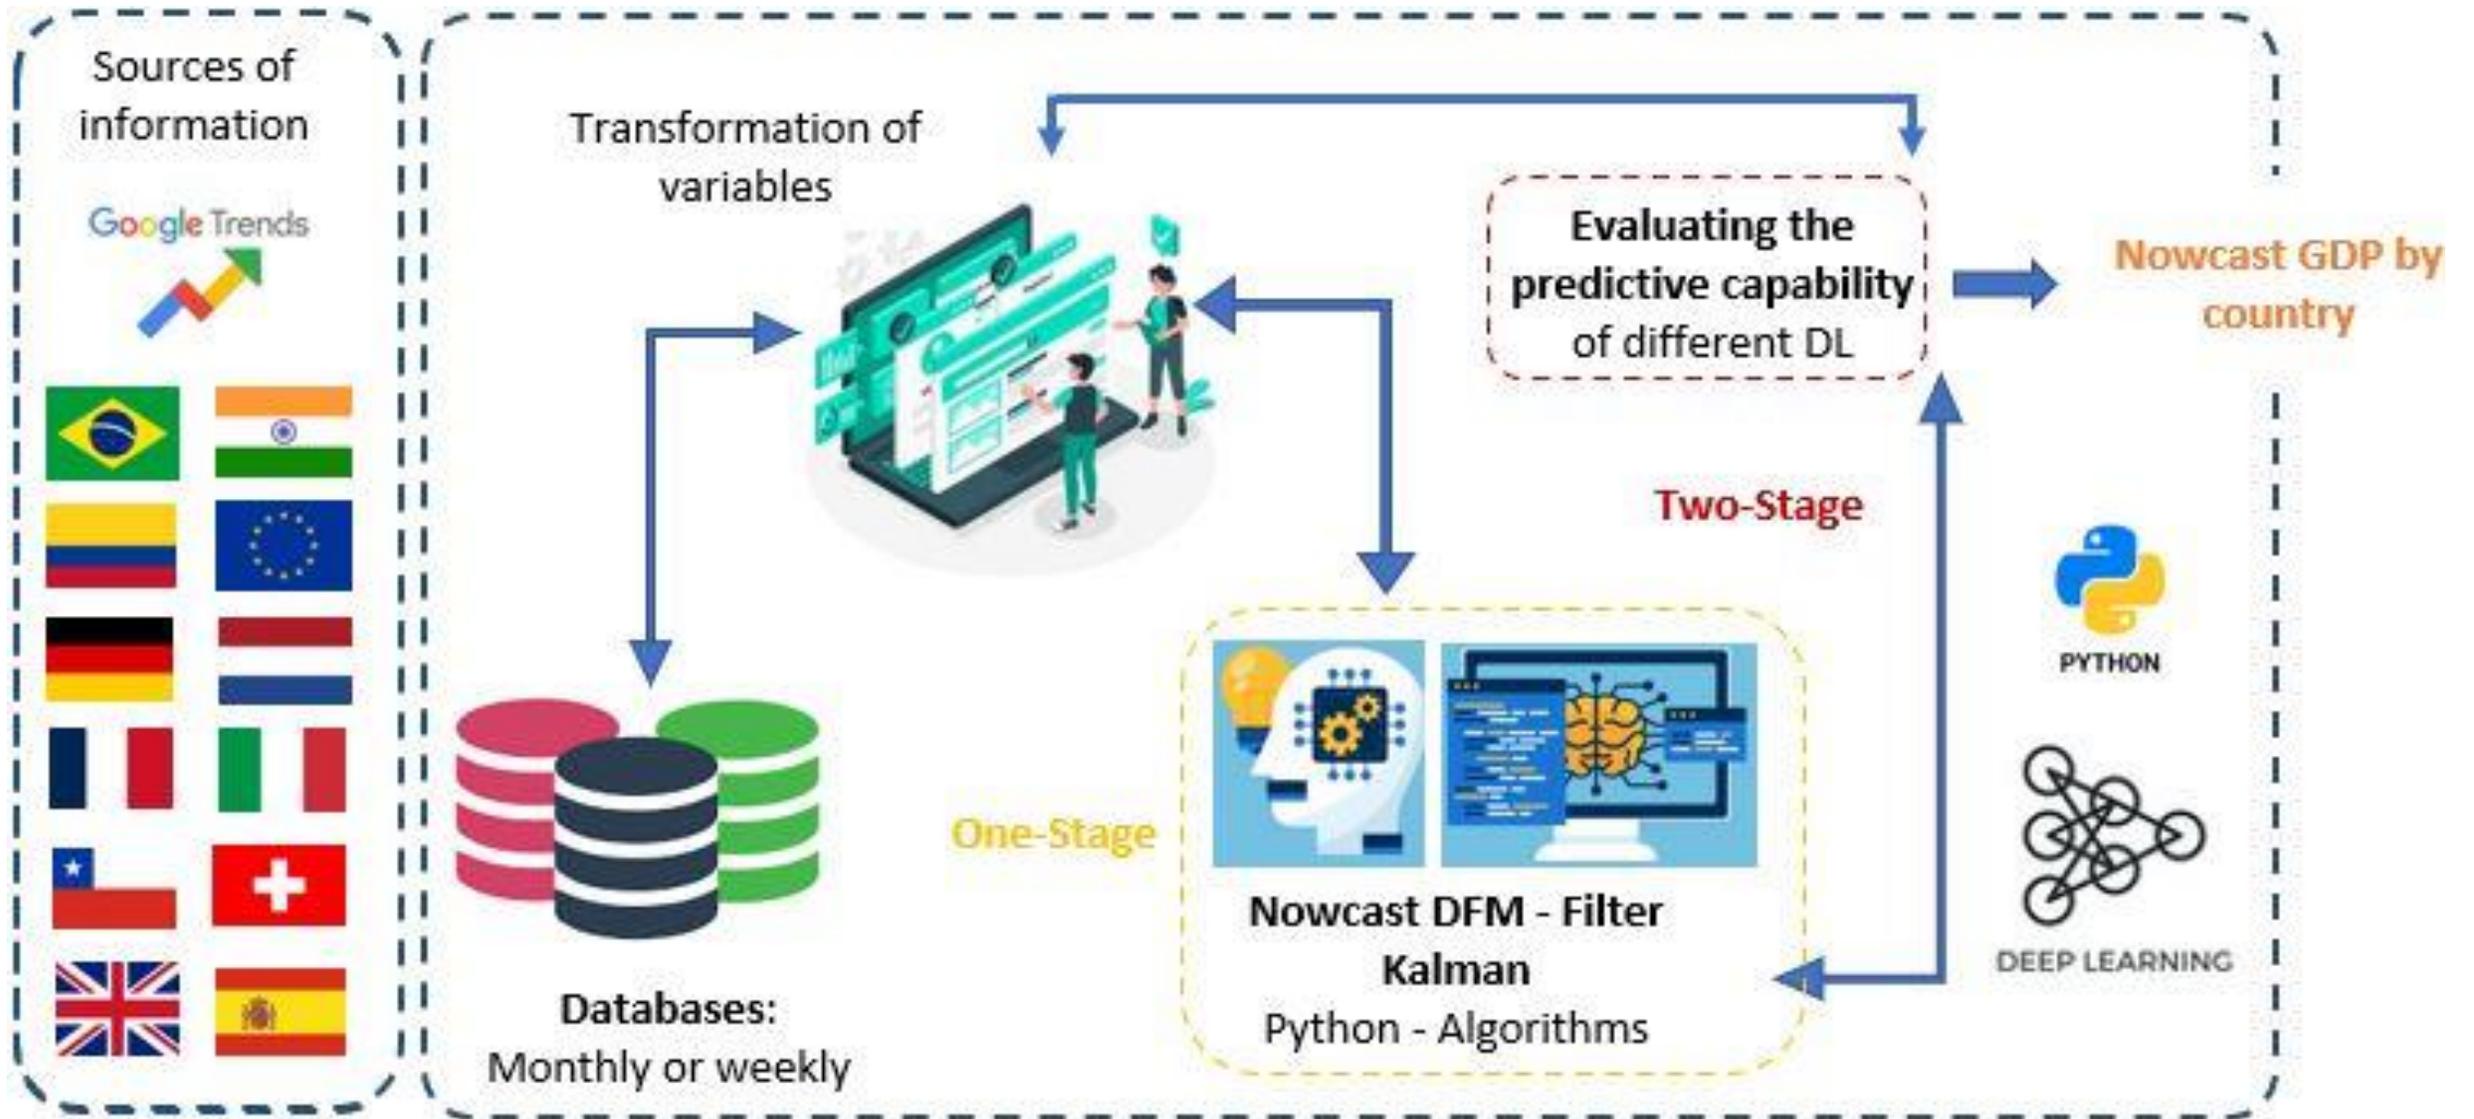
Factor vs PIB Colombia

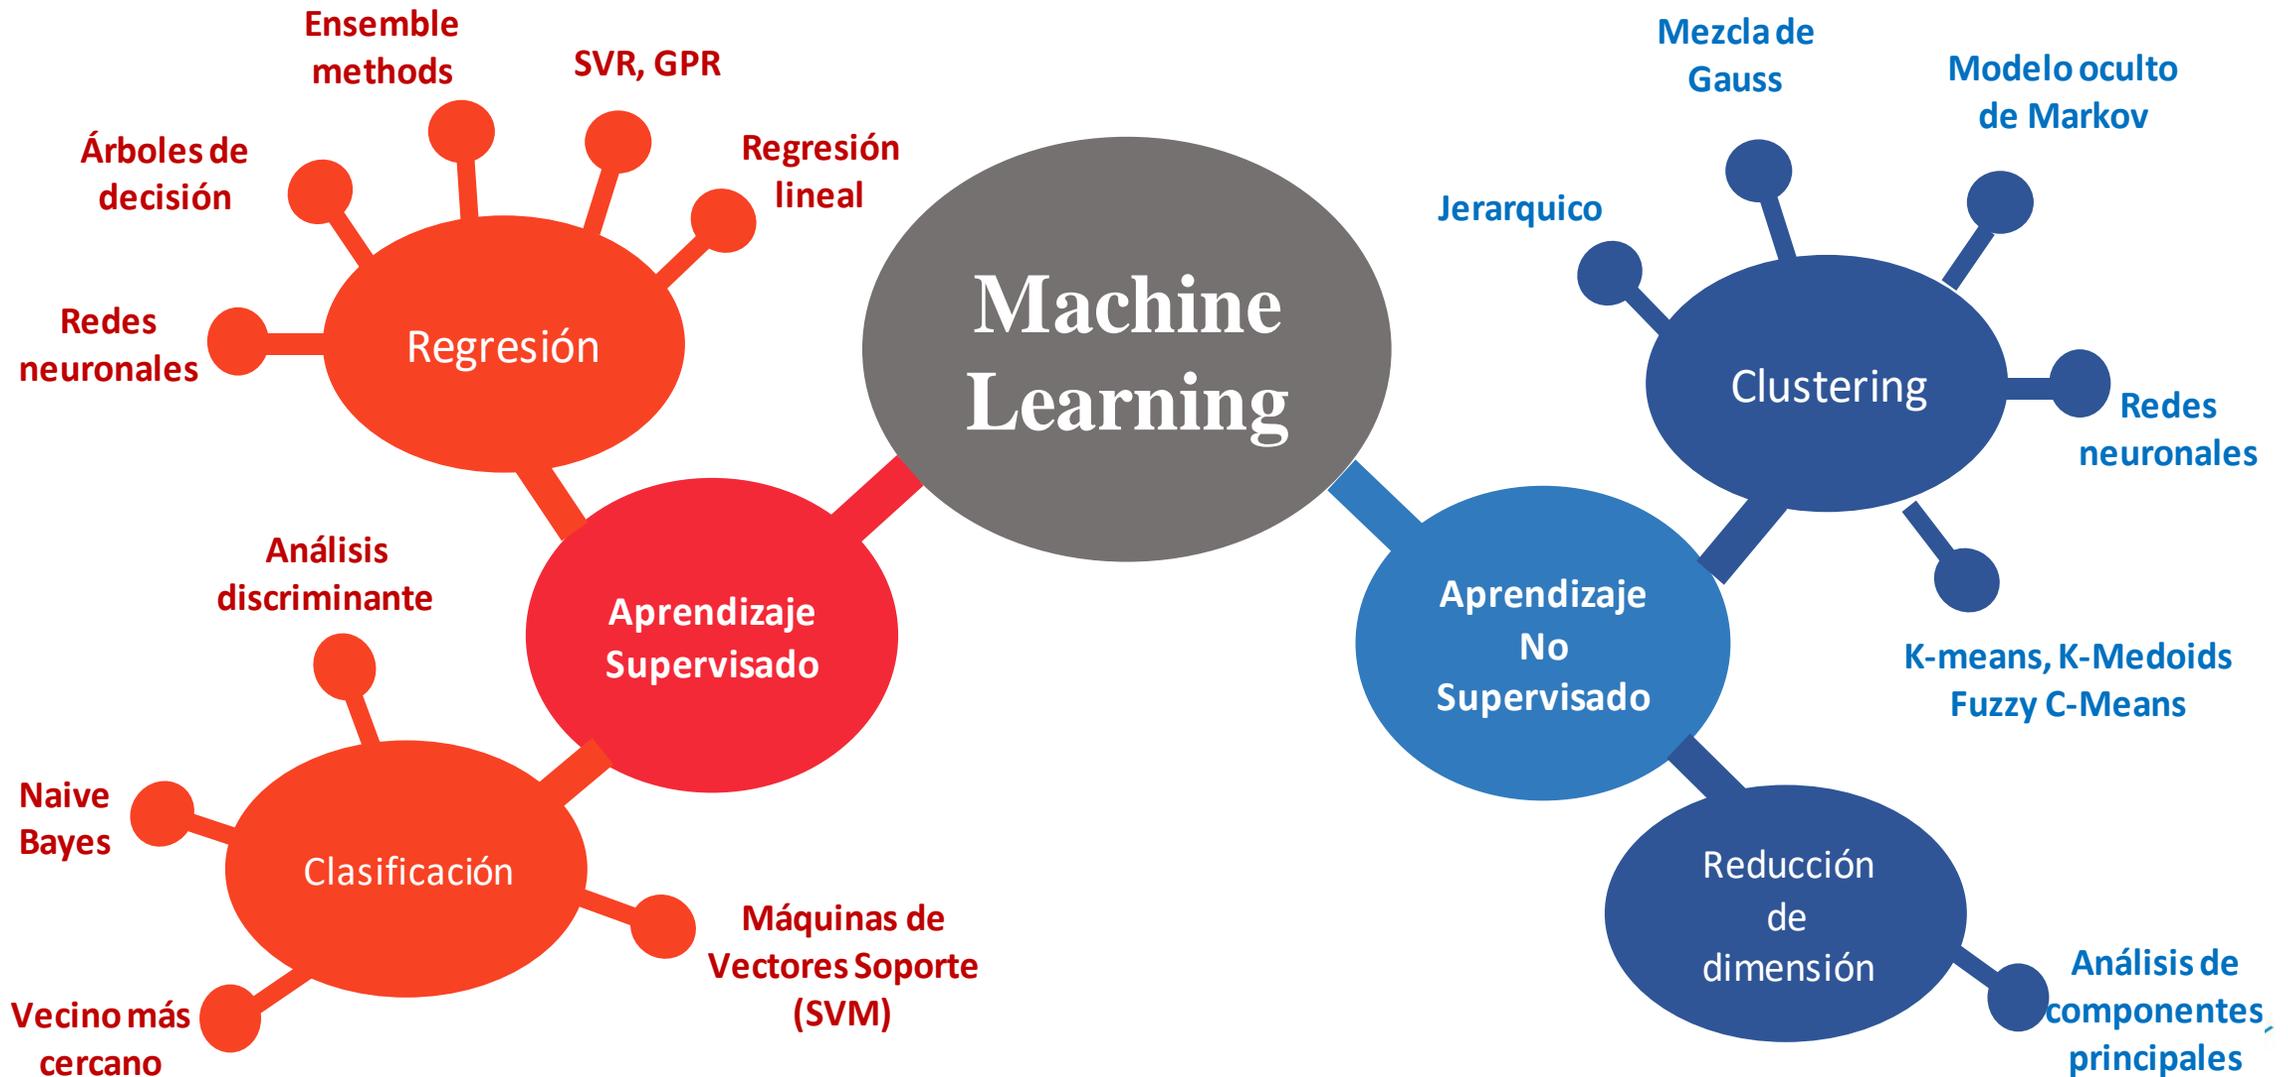


Fuente: Estimación propia.

- Muchos procesos en Inteligencia Artificial puede asimilarse a juegos, en los que distintos atributos considerados hacen algún aporte al resultado buscado, como lo harían los agentes que participan en juegos cooperativos, a través de coaliciones.
- El valor de Shapley determina el aporte de un agente al resultado de una coalición, a partir de cuatro axiomas básicos:
 - Eficiencia: el resultado de la coalición se reparte íntegramente entre los aportes de los participantes.
 - Simetría: se considera igual el aporte jugadores, cuya contribución ha sido la misma para al resultado de la coalición.
 - Aditividad: el resultado no se modifica si el juego de subdivide en componentes.
 - El aporte de quienes no contribuyen al resultado de la coalición se considera nulo.
- El valor de Shapley puede ser usado para atribuir el ajuste de una regresión a los atributos considerados, reentrenando el modelo con diferentes subconjuntos de atributos.
- Puede usarse también para establecer la importancia de un atributo en una predicción específica.
- En nuestro caso, permite determinar la importancia de los atributos elegidos en la construcción del factor usado en la predicción en cada país.

Proceso de construcción Nowcast_GT_DL

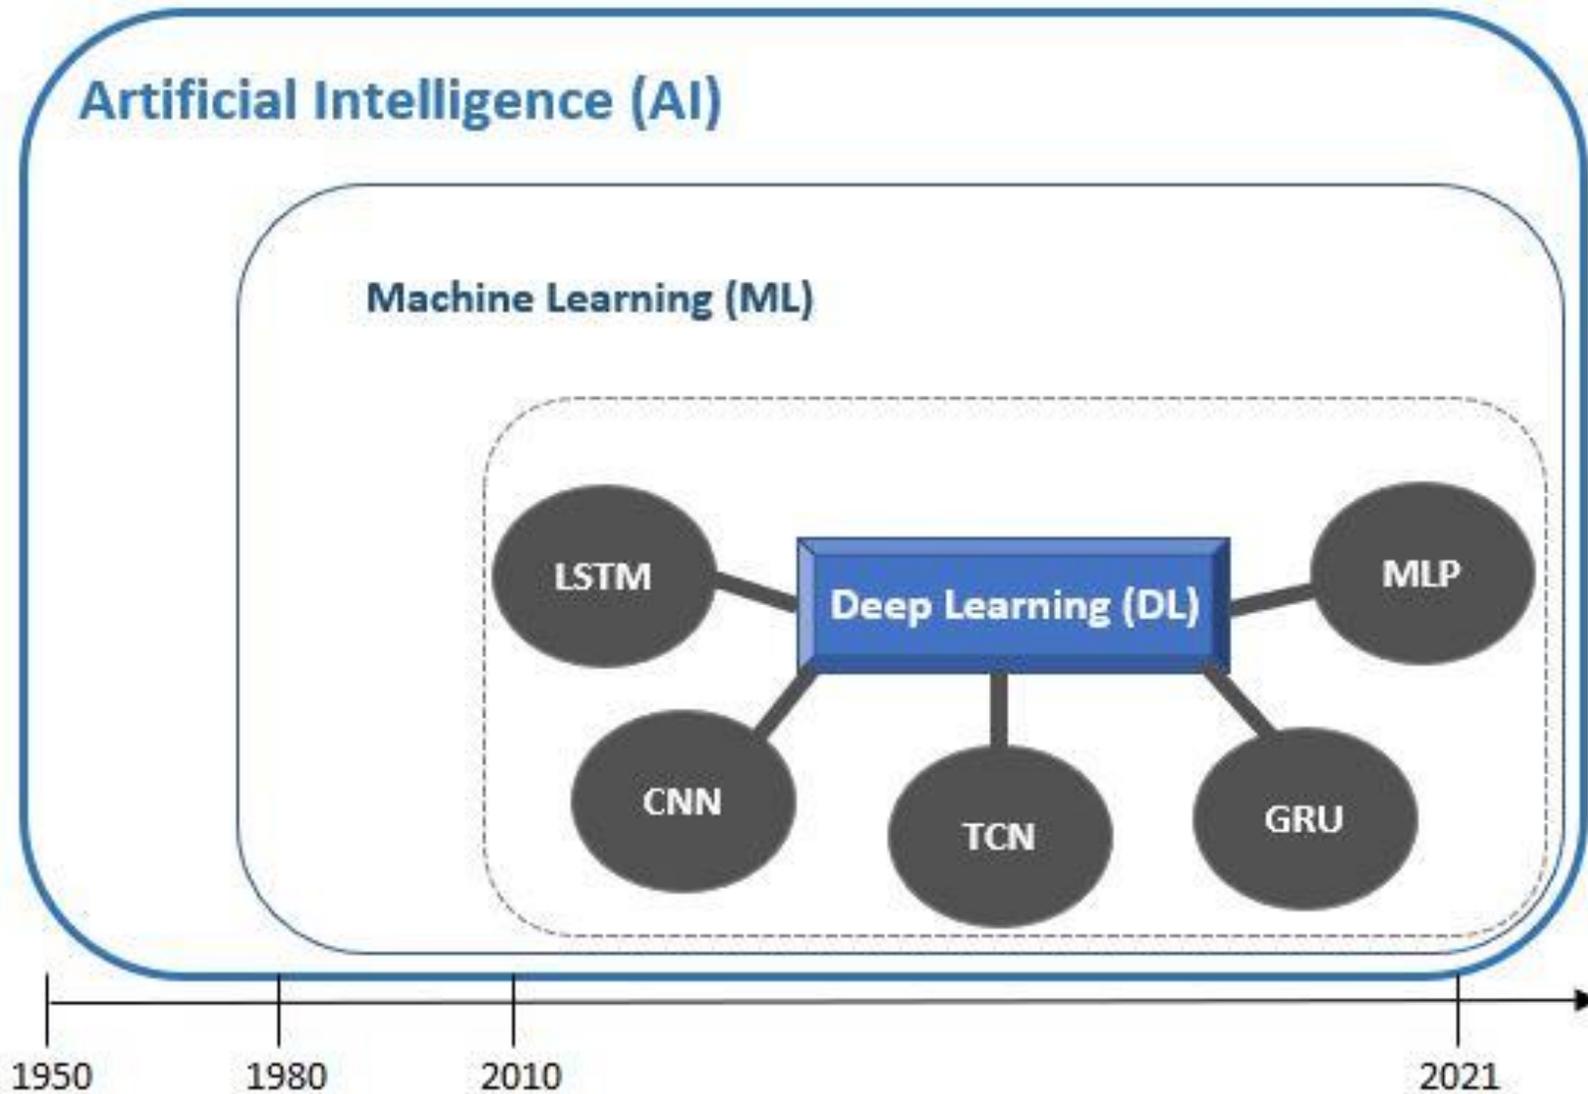




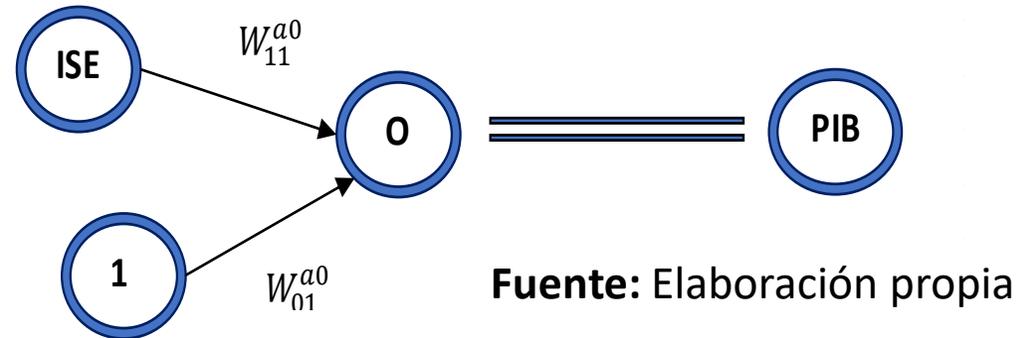
Desventaja del aprendizaje automático tradicional

Es bien sabido que estos modelos tradicionales de Machine Learning tienen muchas limitaciones:

- los valores perdidos pueden afectar realmente el rendimiento de los modelos;
 - no pueden reconocer patrones complejos en los datos;
 - generalmente funcionan bien solo en pronósticos de pocos pasos, no en pronósticos a largo plazo.
- 



Nowcast con Multicapa (MLP)



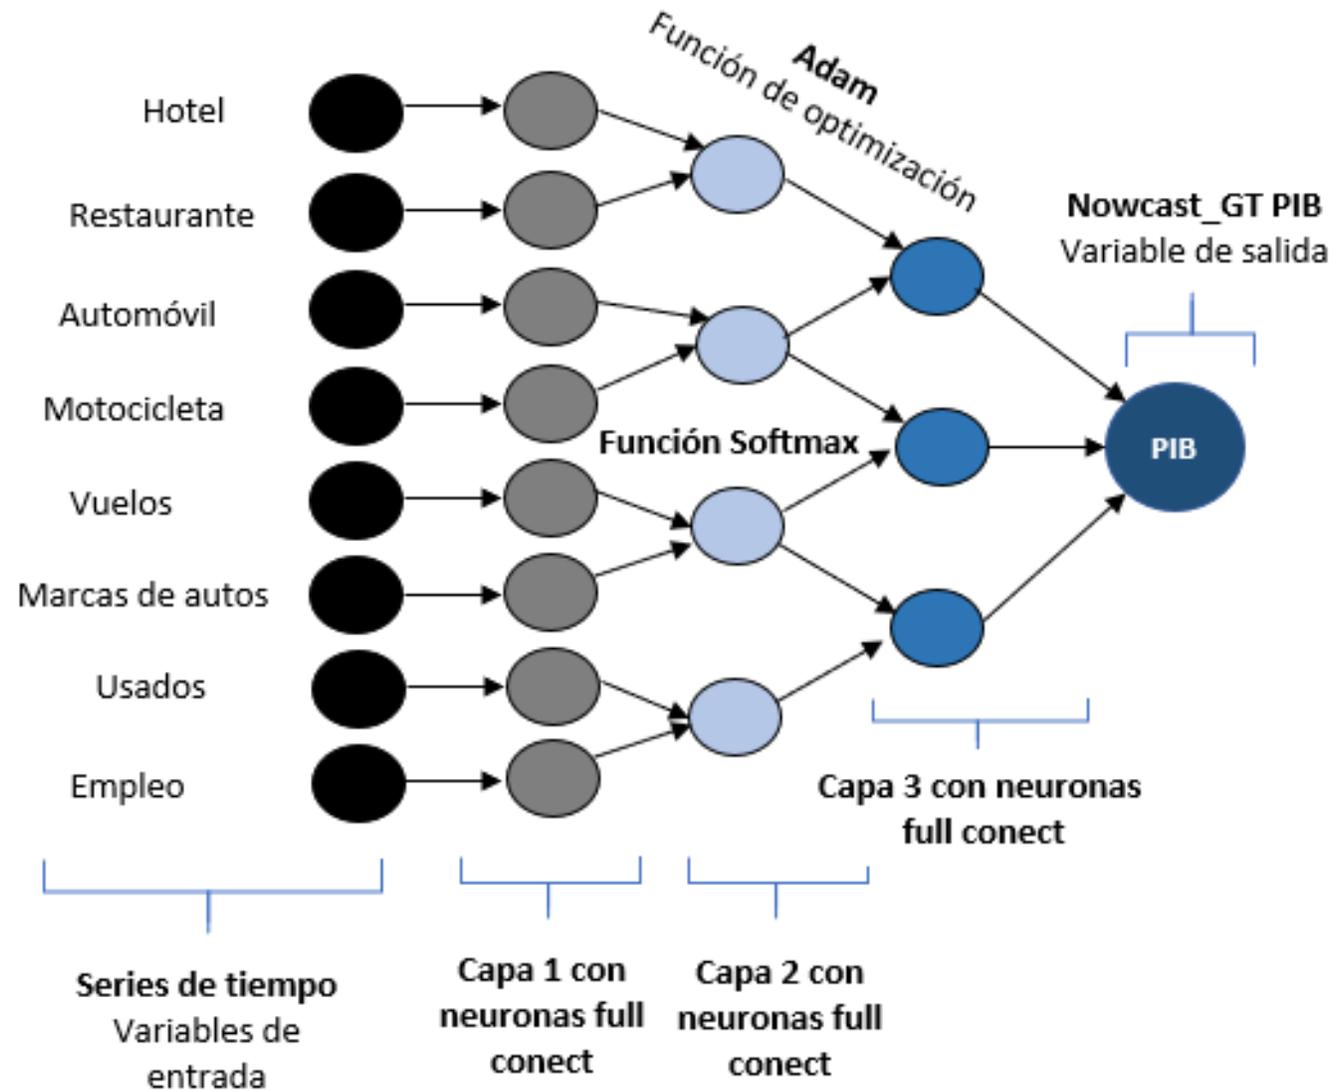
Generalmente, las redes neuronales como los perceptrones multicapa o MLP proporcionan capacidades que ofrecen algunos algoritmos, como:

- ➔ **Robusto al ruido** . Las redes neuronales son resistentes al ruido en los datos de entrada y en la función de mapeo e incluso pueden apoyar el aprendizaje y la predicción en presencia de valores perdidos.
- ➔ **No lineal** . Las redes neuronales no hacen suposiciones sólidas sobre la función de mapeo y aprenden fácilmente las relaciones lineales y no lineales.
- ➔ **Entradas multivariadas** . Se puede especificar un número arbitrario de características de entrada, lo que proporciona soporte directo para la previsión multivariante.
- ➔ **Pronósticos de varios pasos** . Se puede especificar un número arbitrario de valores de salida, lo que proporciona soporte directo para pronósticos de múltiples pasos e incluso de múltiples variables.

Solo para estas capacidades, las redes neuronales de retroalimentación pueden ser útiles para el pronóstico de series de tiempo.

Fuente: Tomado de (Brownlee, 2018).

Nowcast con Multicapa (MLP)



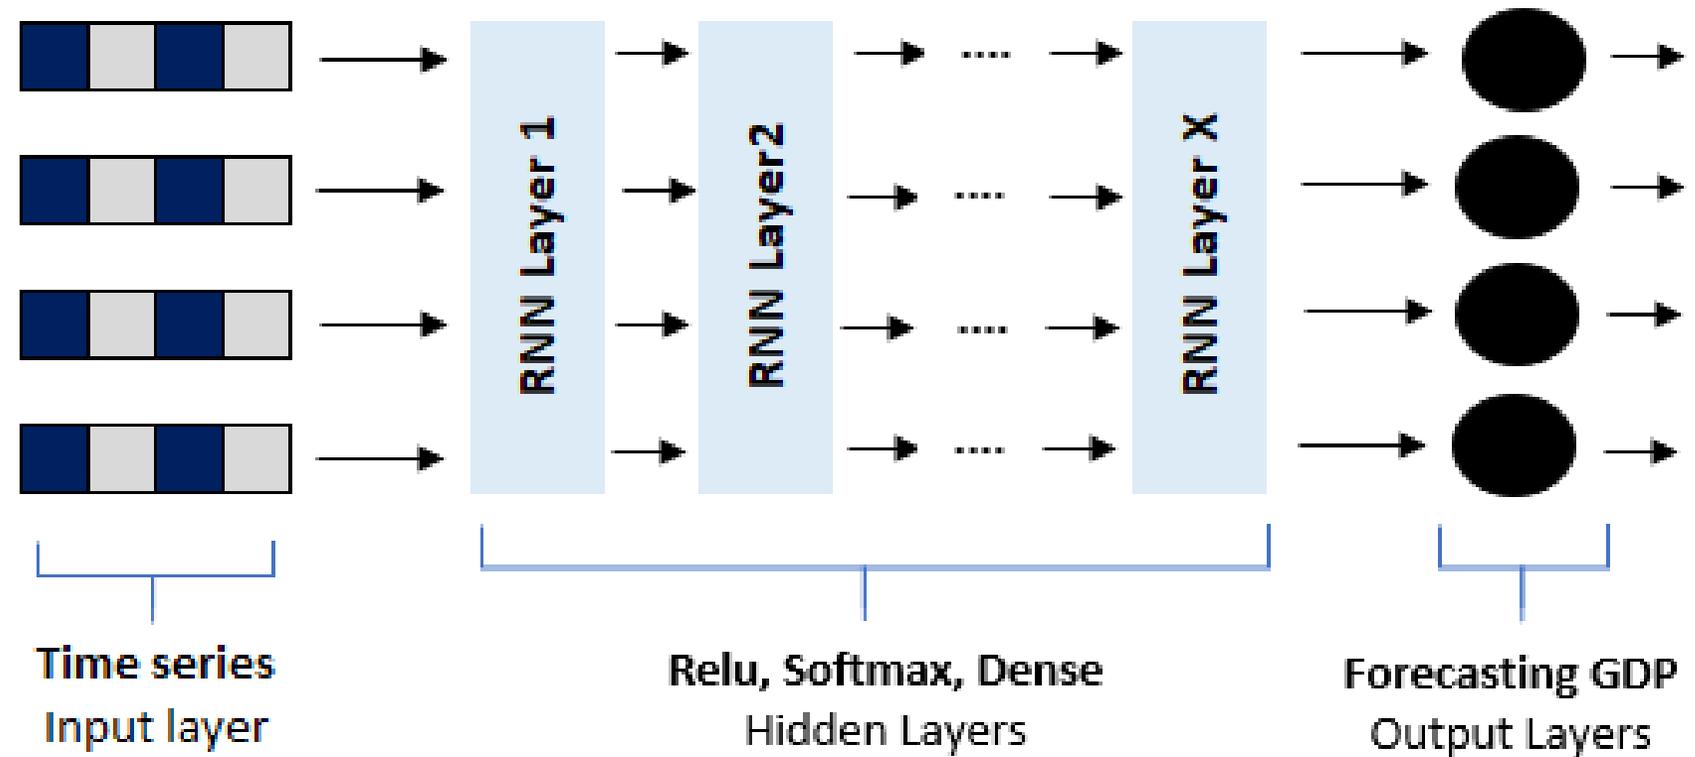
Fuente: Elaboración propia

Nowcast_GT_DL: DL for time series: RNN

$$h_t = W f(h_{t-1}) + W^{hx} x_{[t]}$$

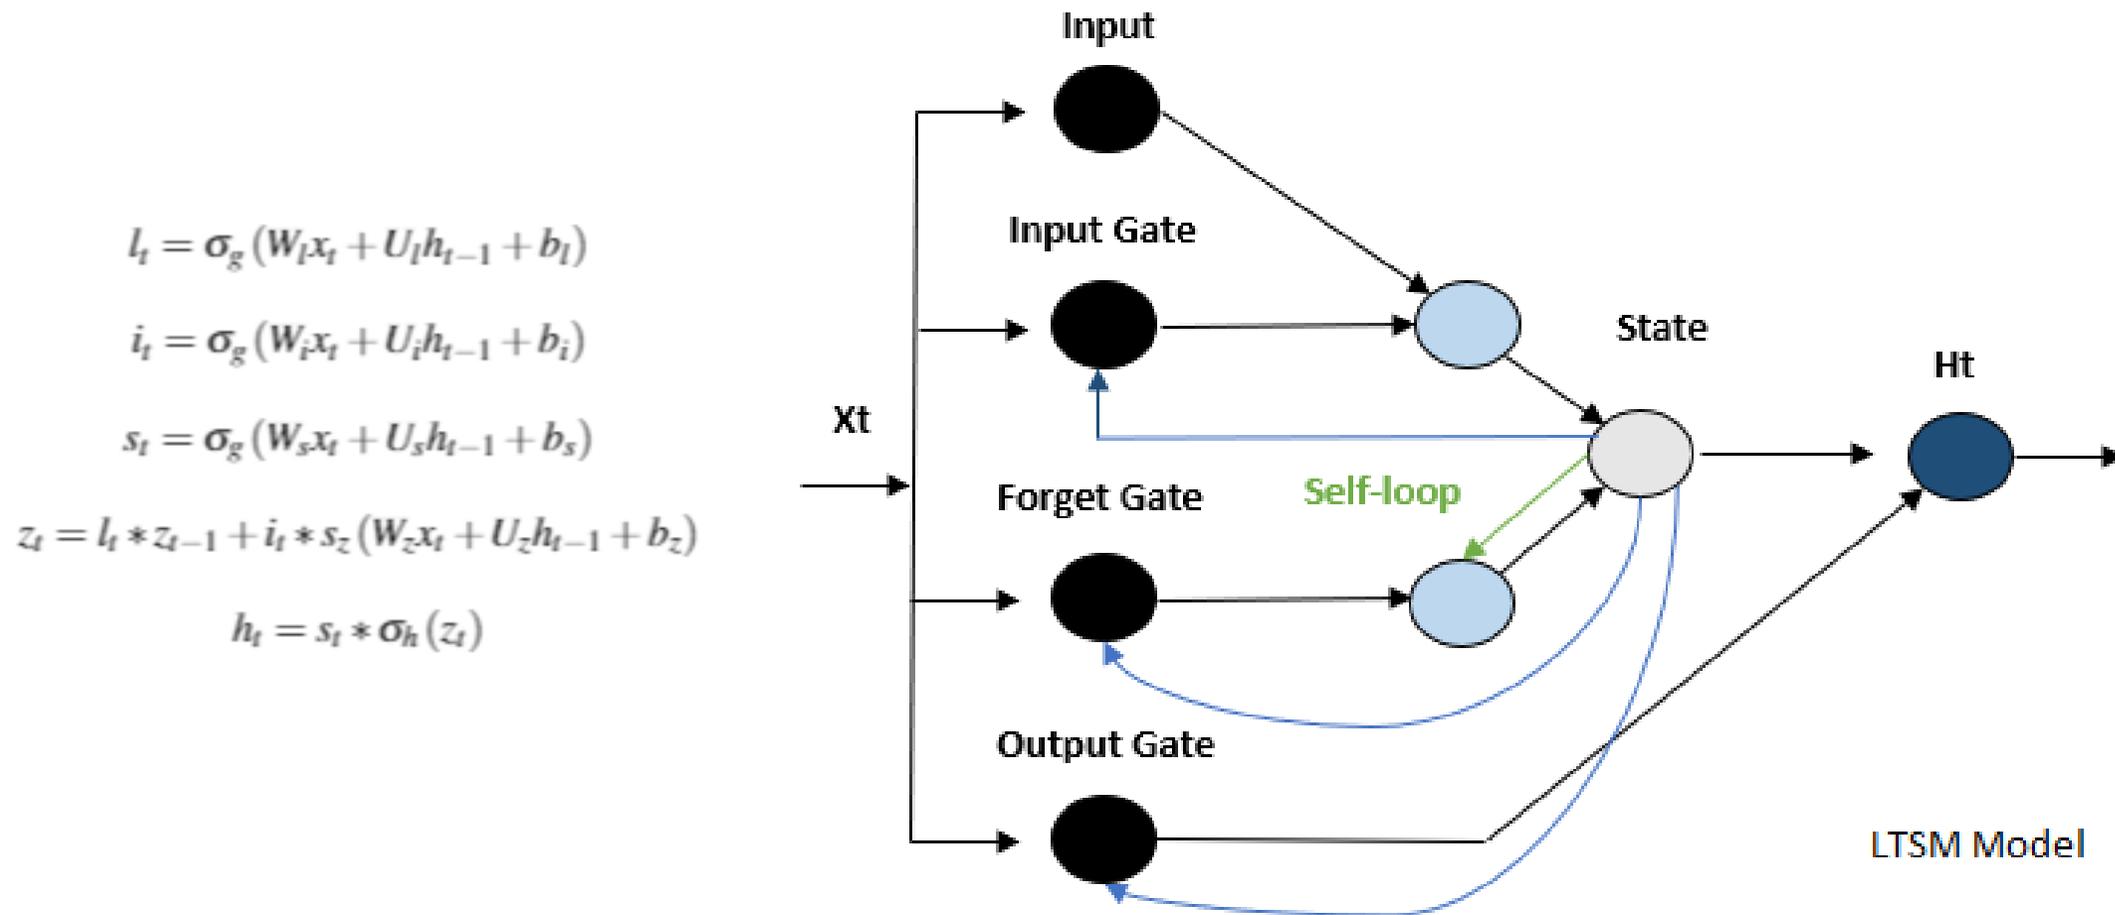
$$y_t = W^{(s)}$$

$$f(h_t) \frac{\partial E}{\partial W} = \sum_{i=1}^T \frac{\partial E_i}{\partial W}$$



Fuente: Elaboración propia con información de Goodfellow et al., (2018)

Nowcast con Memoria a corto plazo (LSTM)



Fuente: Elaboración propia con información de Goodfellow et al., (2018)

Nowcast con Unidad Recurrente Cerrada (GRU)

El GRU es una nueva generación de redes neuronales recurrentes y es muy similar a un LSTM. Para resolver el problema del gradiente de desaparición de un RNN estándar, GRU usa la *puerta de actualización* y la *puerta de reinicio*. Estas son dos puertas que deciden qué información se debe pasar a la salida. Estas dos puertas se pueden entrenar para mantener la información de muchos pasos de tiempo antes del paso de tiempo real, sin lavarla a través del tiempo, o para eliminar información que es irrelevante para la predicción. Si se entrena cuidadosamente, GRU puede funcionar extremadamente bien incluso en escenarios complejos.

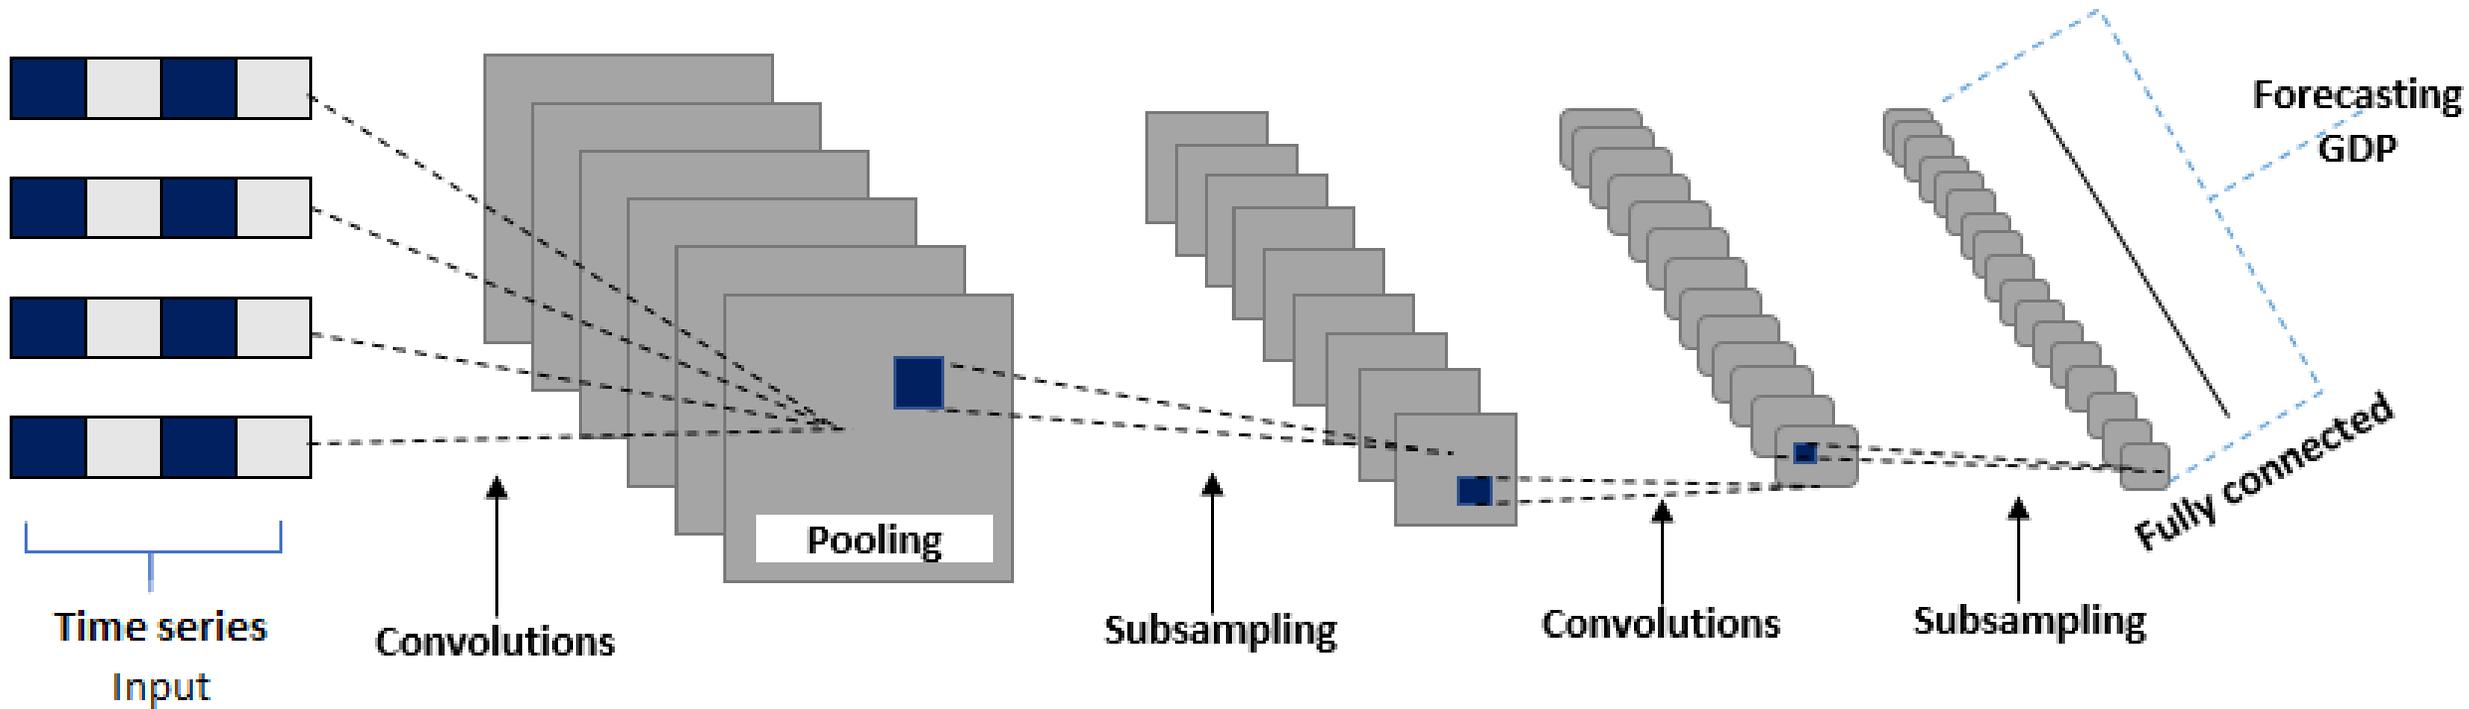
Las redes neuronales convolucionales o CNN son un tipo de red neuronal que fue diseñada para manejar datos de imágenes de manera eficiente.

La capacidad de las CNN para aprender y extraer automáticamente características de los datos de entrada sin procesar se puede aplicar a los problemas de predicción de series de tiempo. Una secuencia de observaciones puede tratarse como una imagen unidimensional que un modelo de CNN puede leer y destilar en los elementos más destacados.

- ➔ **Aprendizaje de funciones** . Identificación, extracción y destilación automáticas de características destacadas a partir de datos de entrada sin procesar que pertenecen directamente al problema de predicción que se está modelando.

Las CNN obtienen los beneficios de los perceptrones multicapa para el pronóstico de series de tiempo, es decir, soporte para entrada multivariante, salida multivariante y aprendizaje de relaciones funcionales arbitrarias pero complejas, pero no requieren que el modelo aprenda directamente de las observaciones de retardo. En cambio, el modelo puede aprender una representación de una secuencia de entrada grande que es más relevante para el problema de predicción.

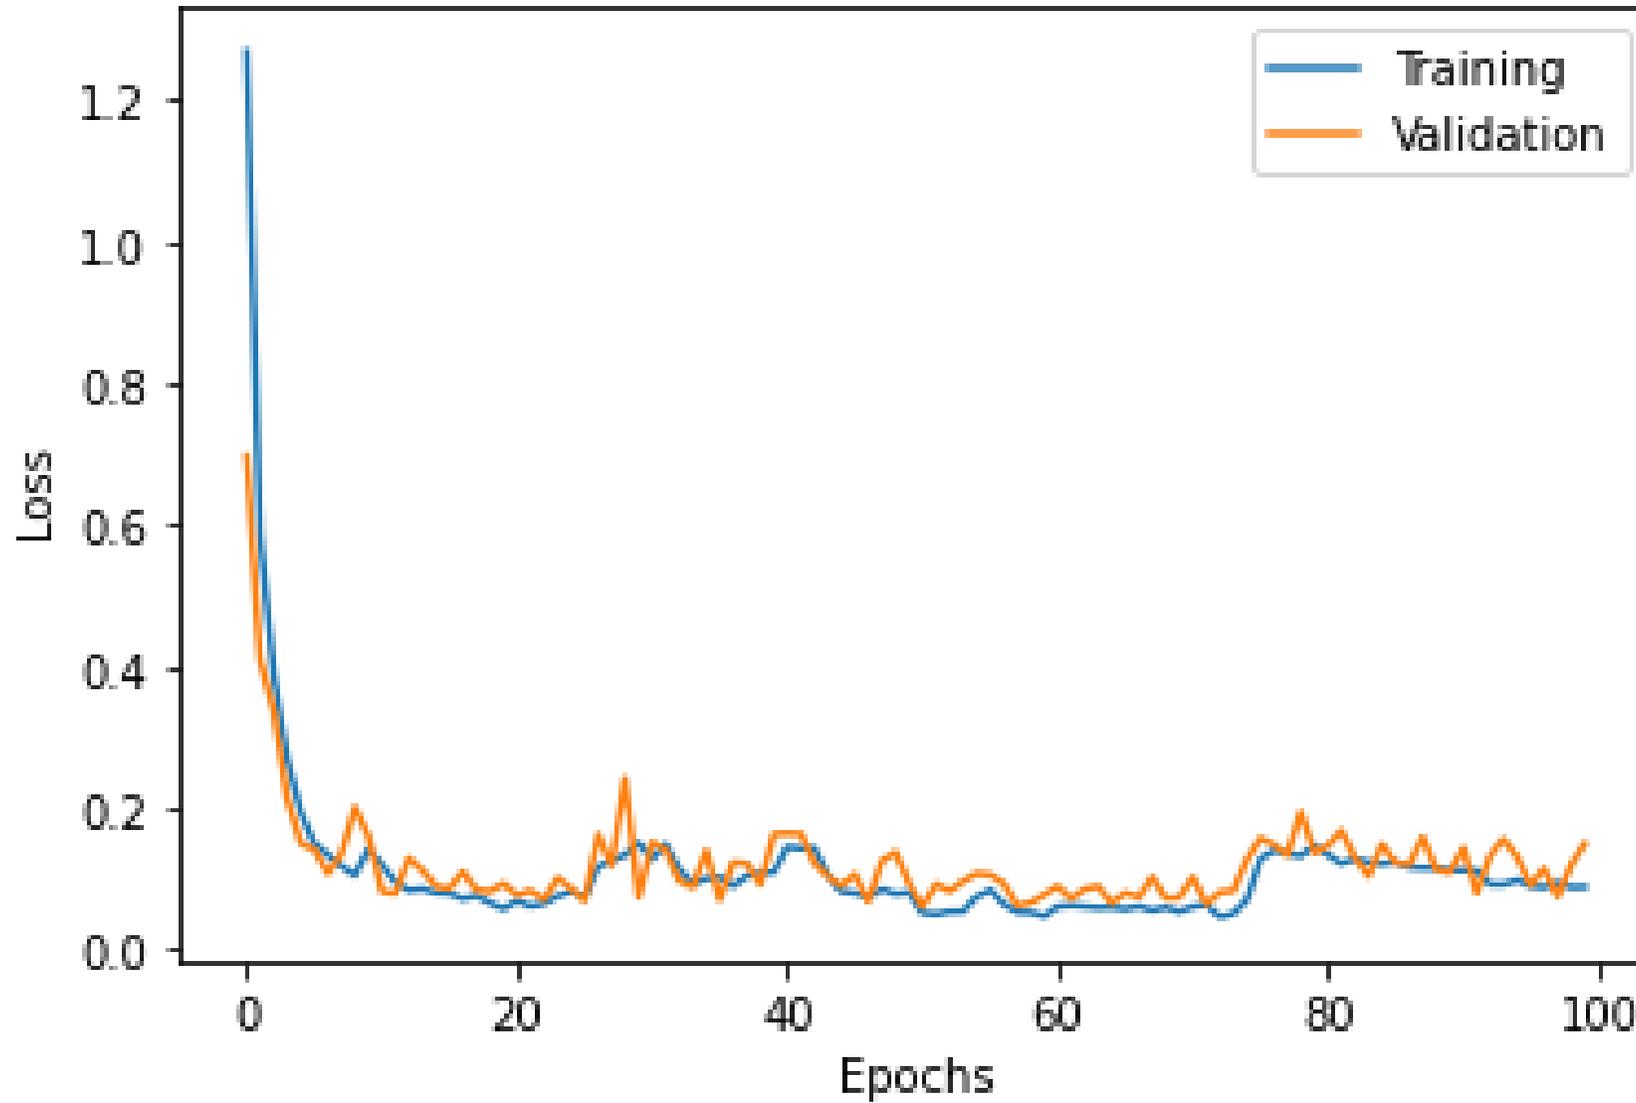
Nowcast con Redes Neuronales Convolucionales (CNN)



Fuente: Elaboración propia con información de Goodfellow et al., (2018)

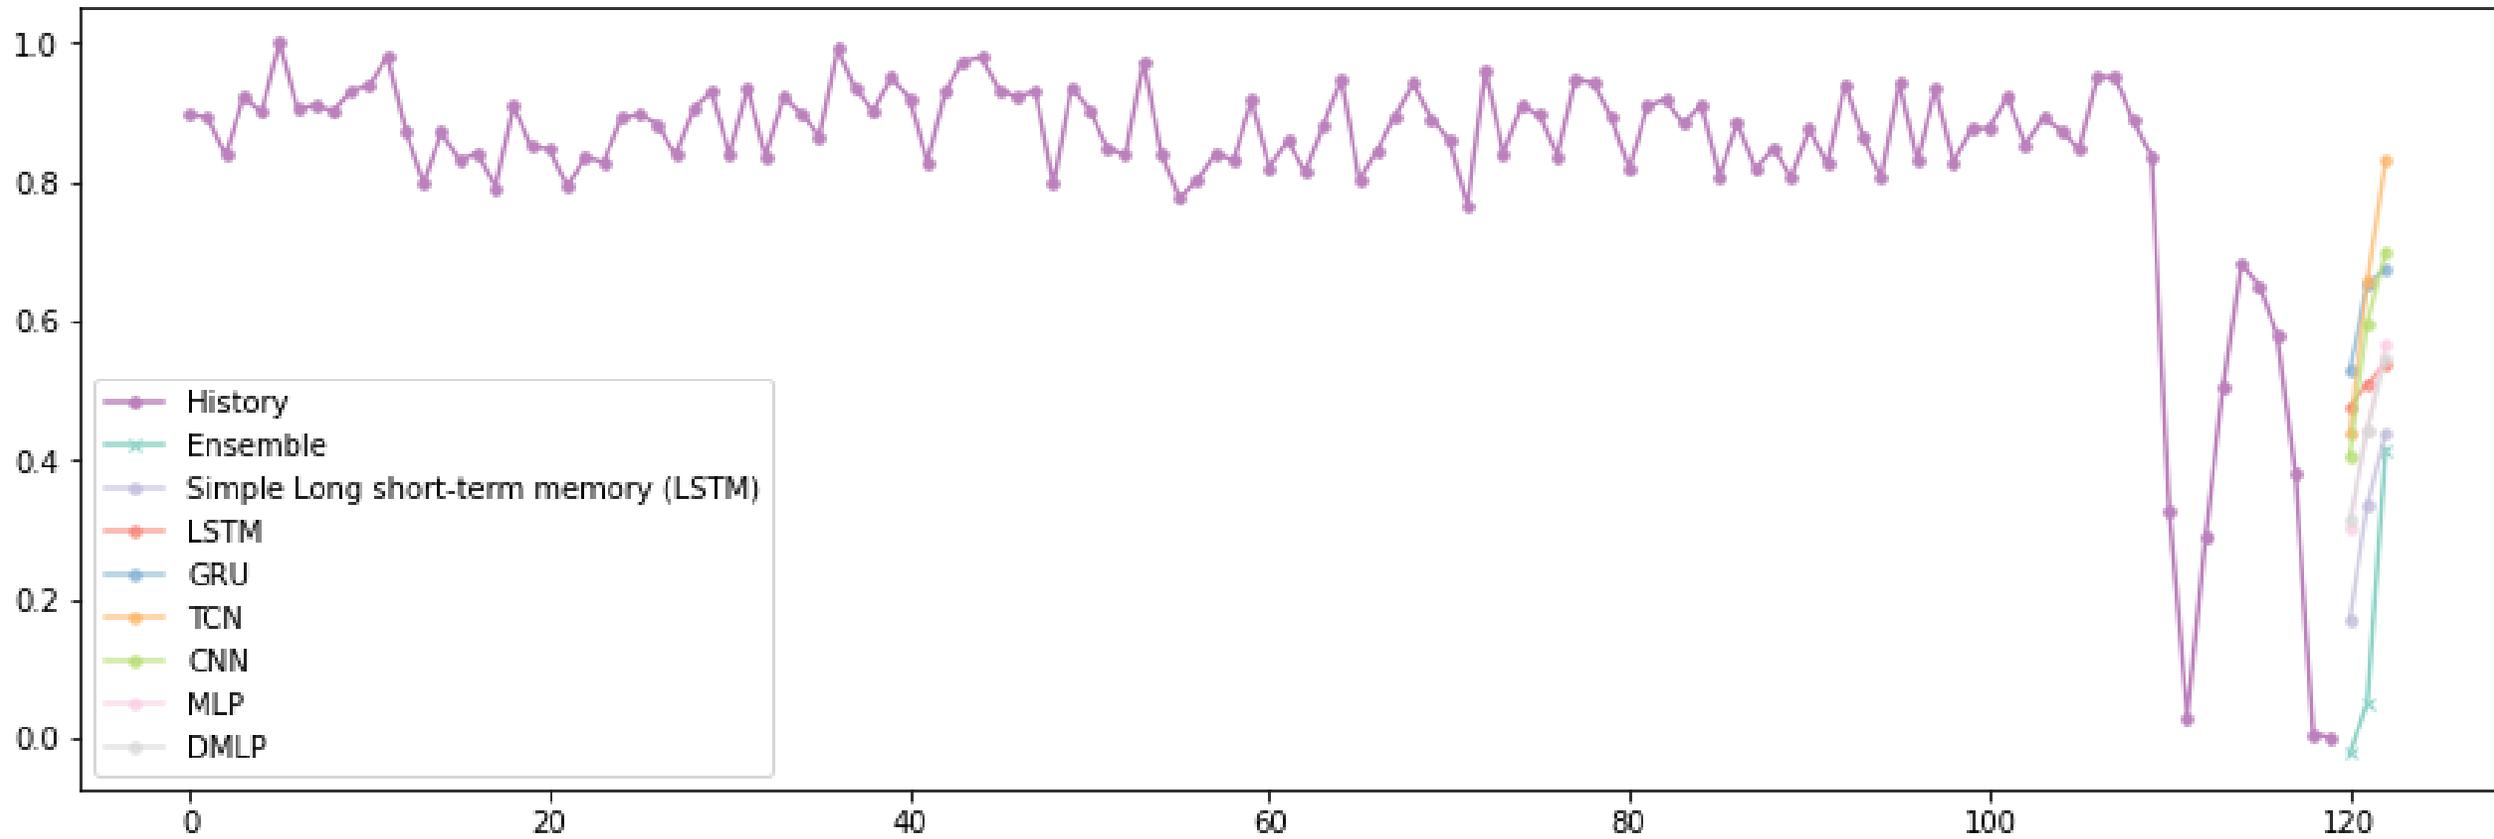
Simple Long short-term memory (LSTM)	0.045649
LSTM	0.046262
GRU	0.044287
TCN	0.150184
CNN	0.053221
MLP	0.045583
Name: MAE, dtype: float64	

Resultados modelo Deep Learning: TCN



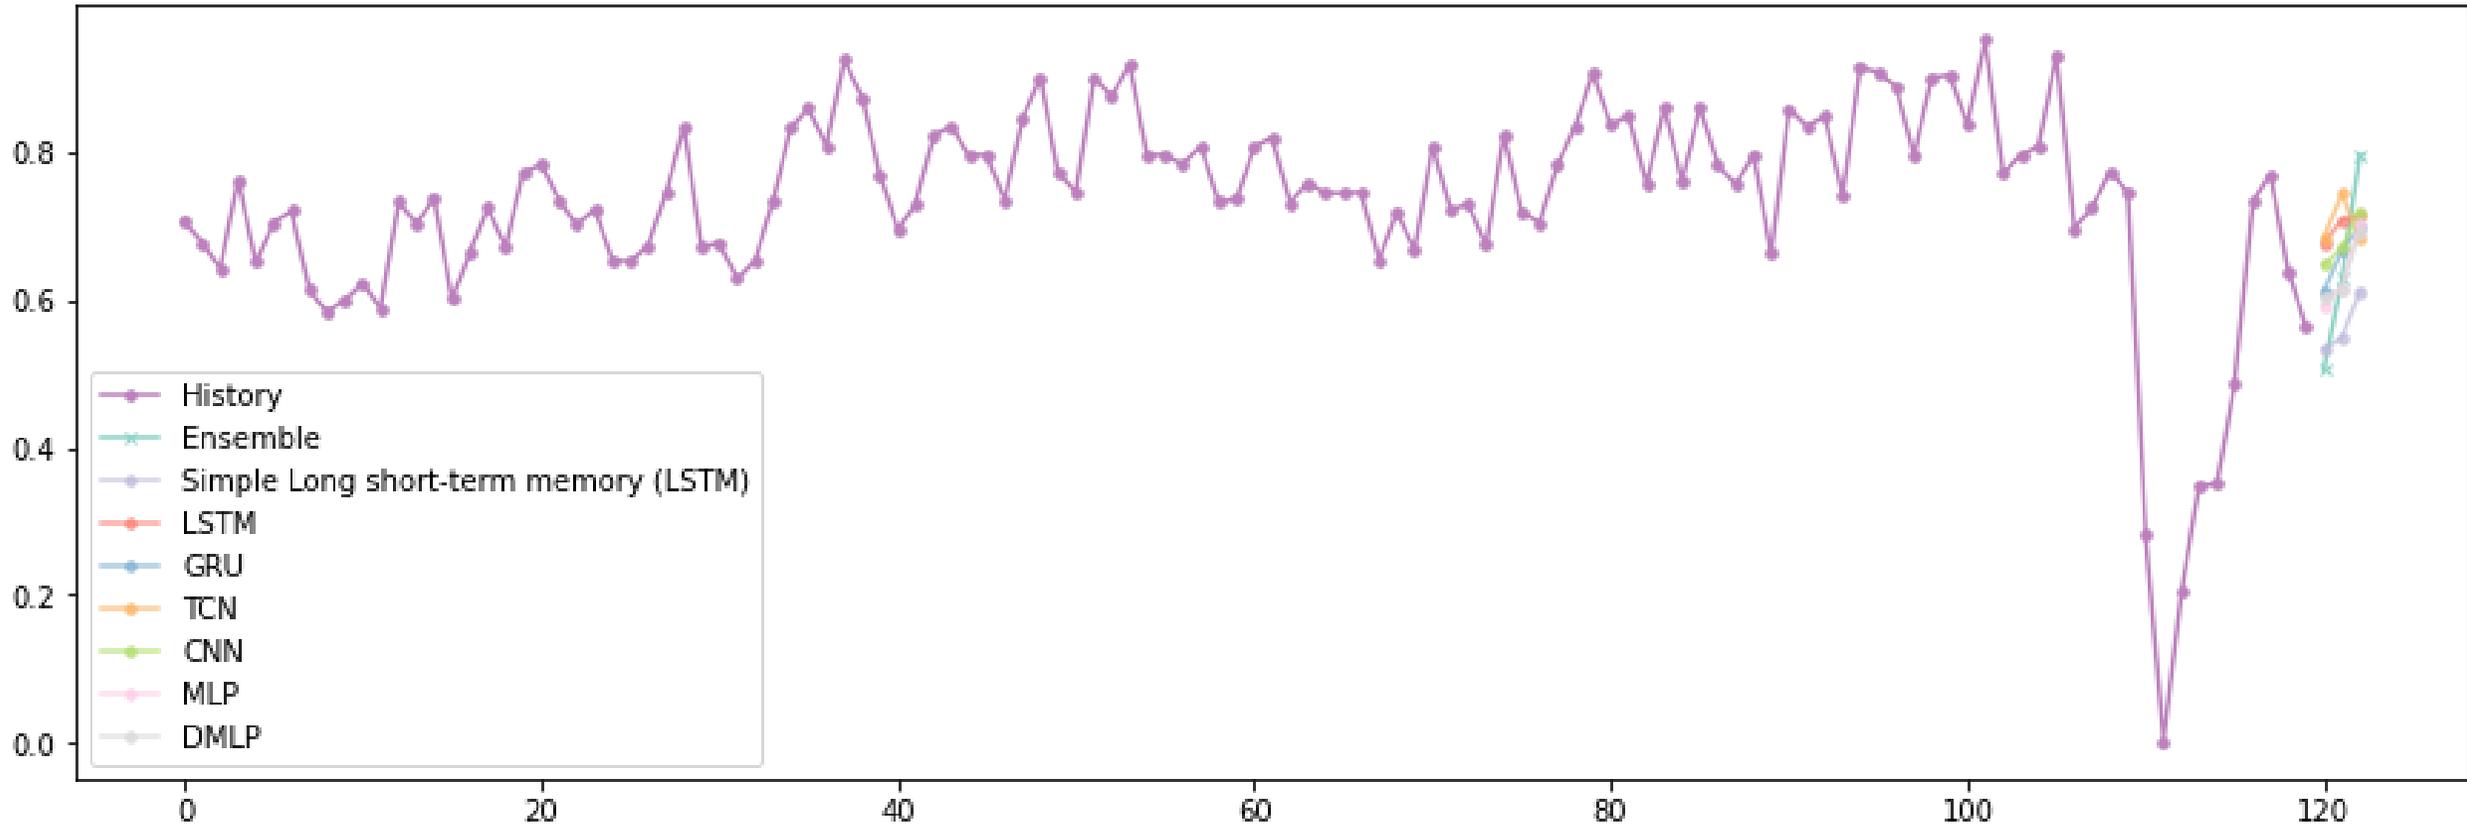
Fuente:
Estimación
propia.

Resultados de nowcasting Germany



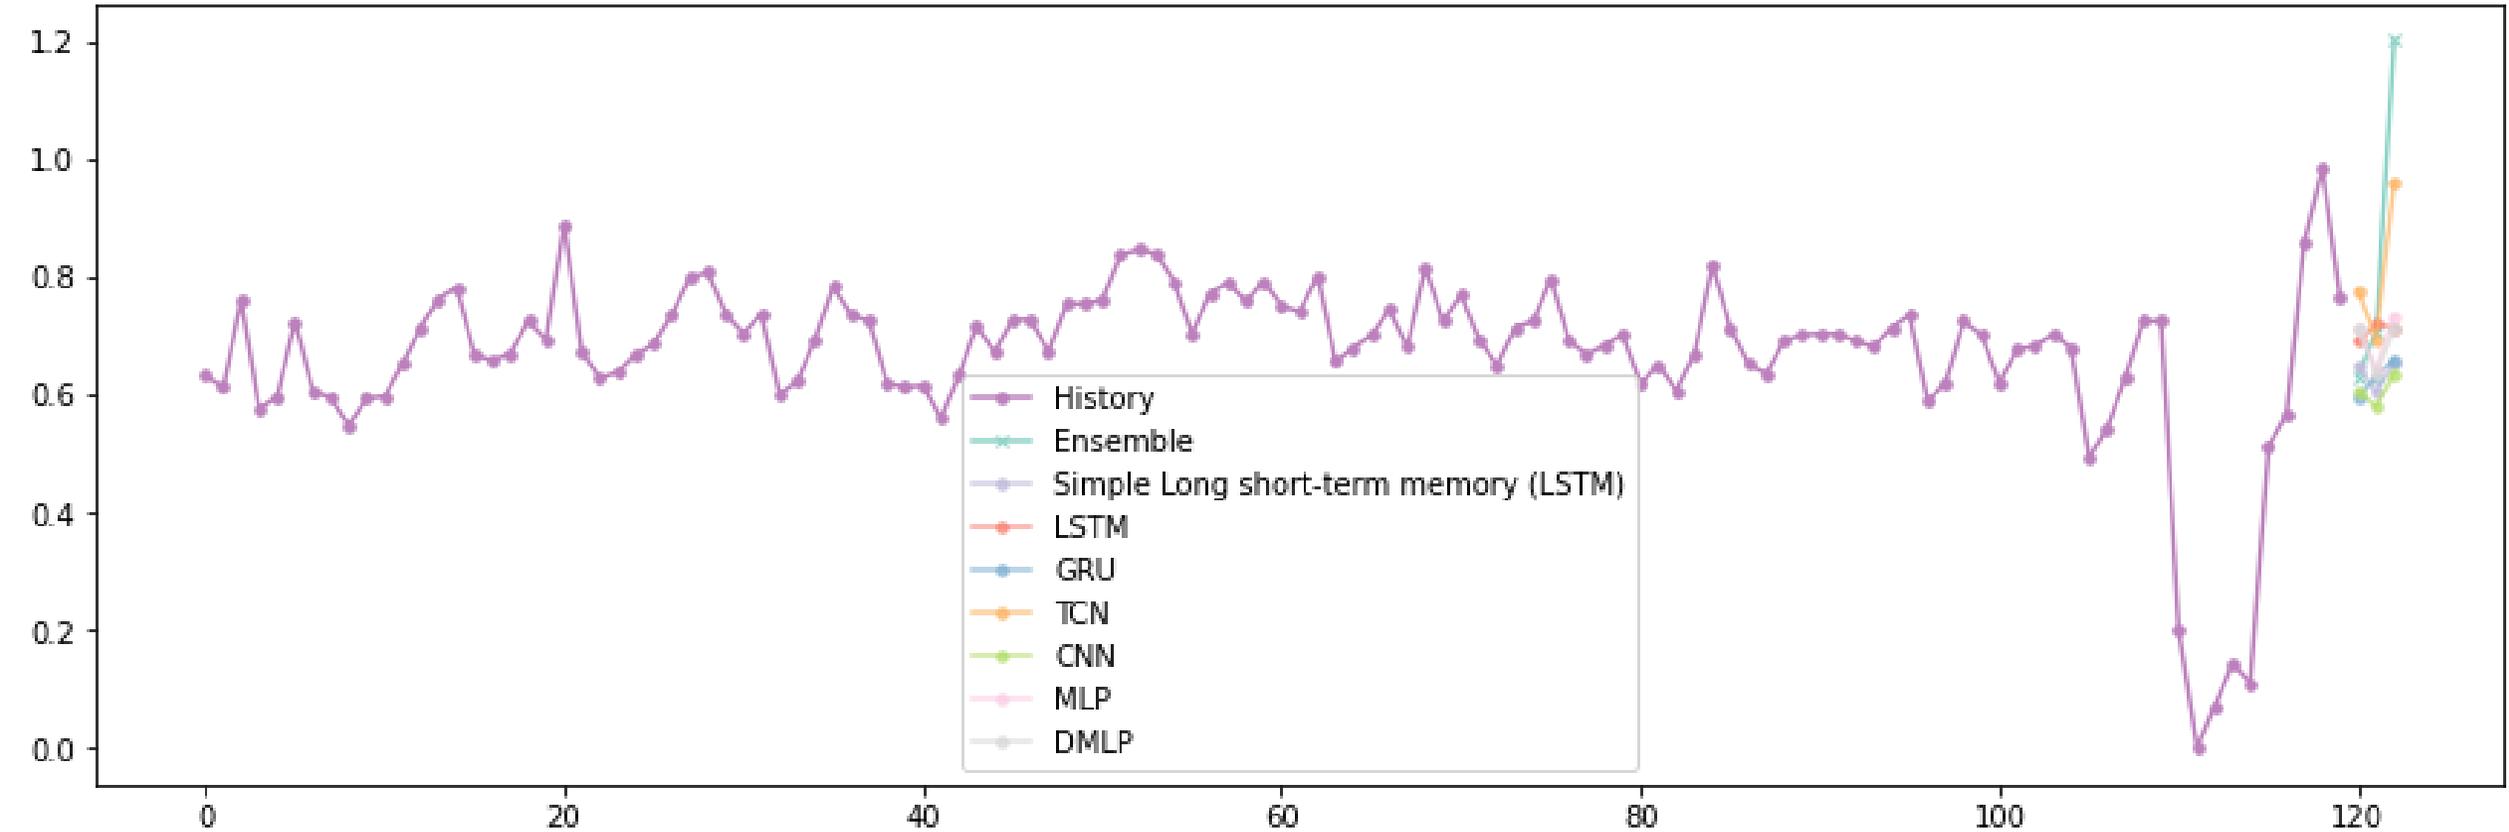
Fuente: Estimación propia en Python

Resultados de nowcasting Brazil



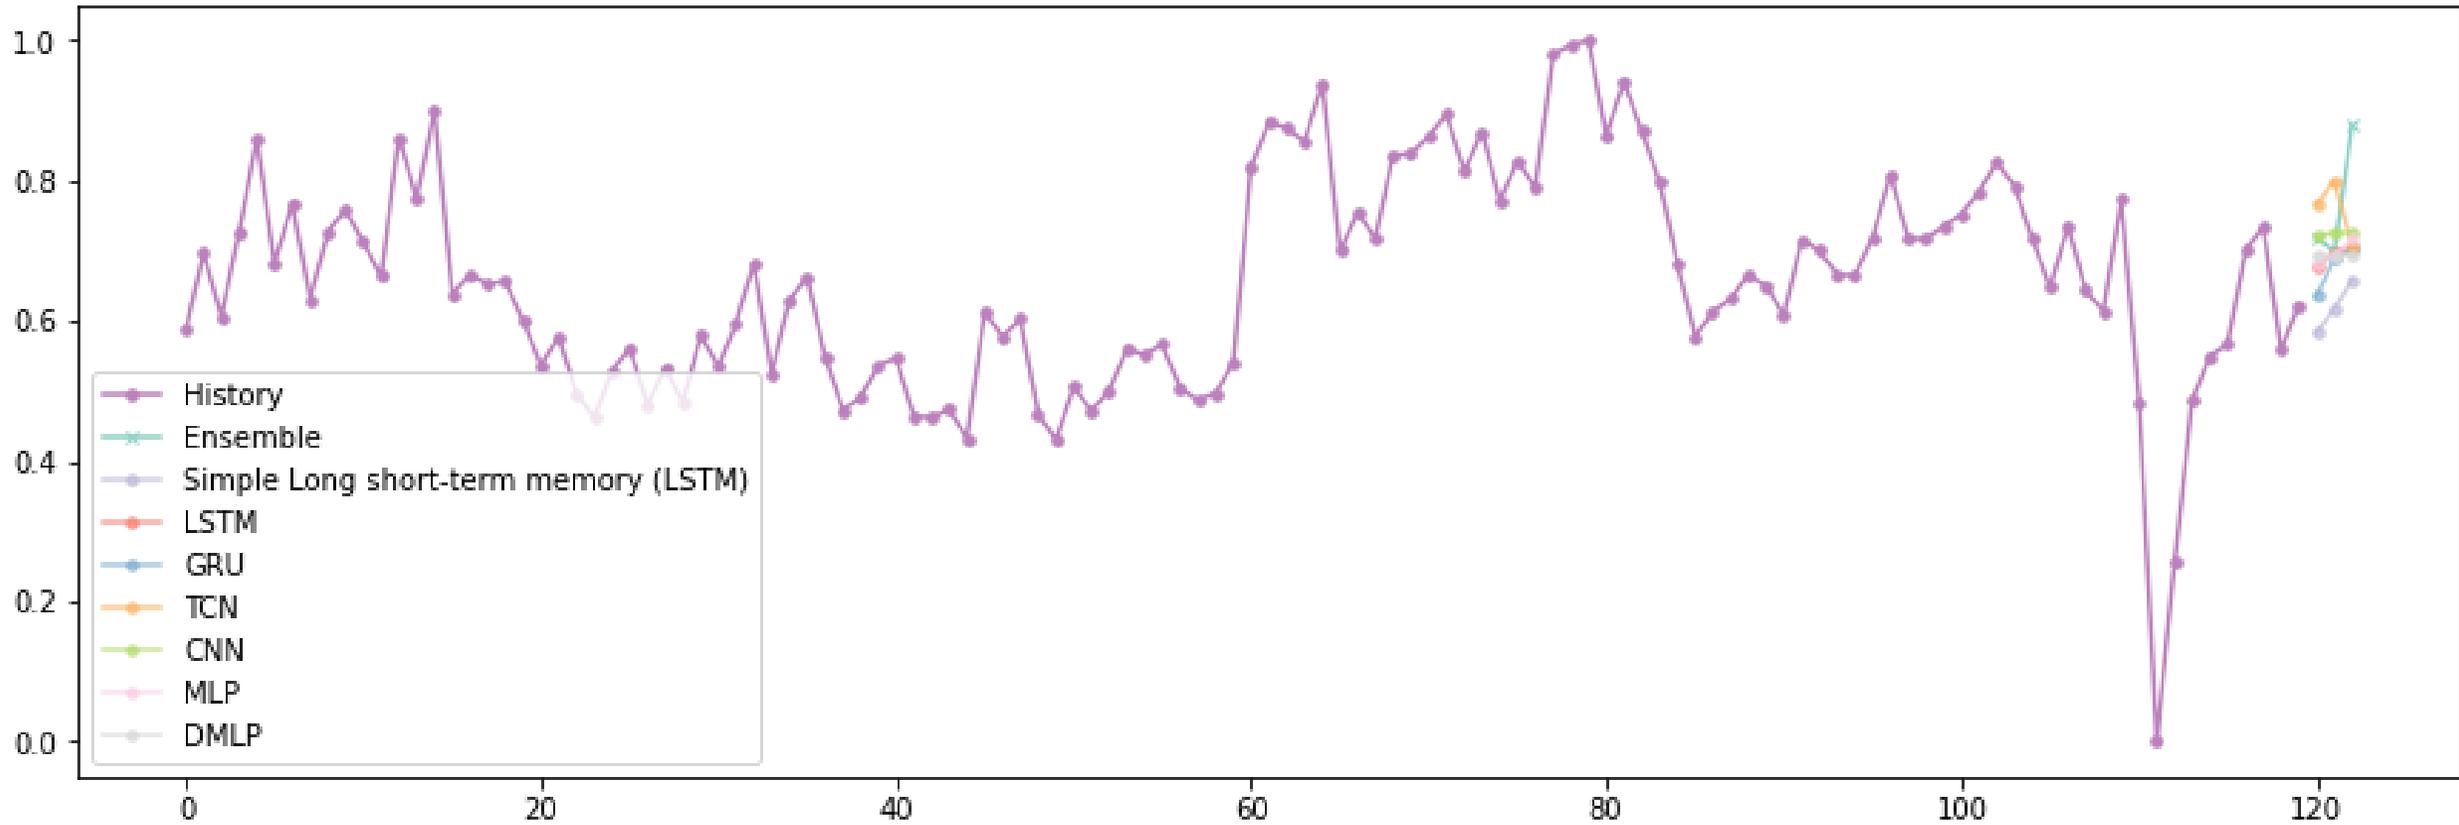
Fuente: Estimación propia en Python

Resultados de nowcasting Chile



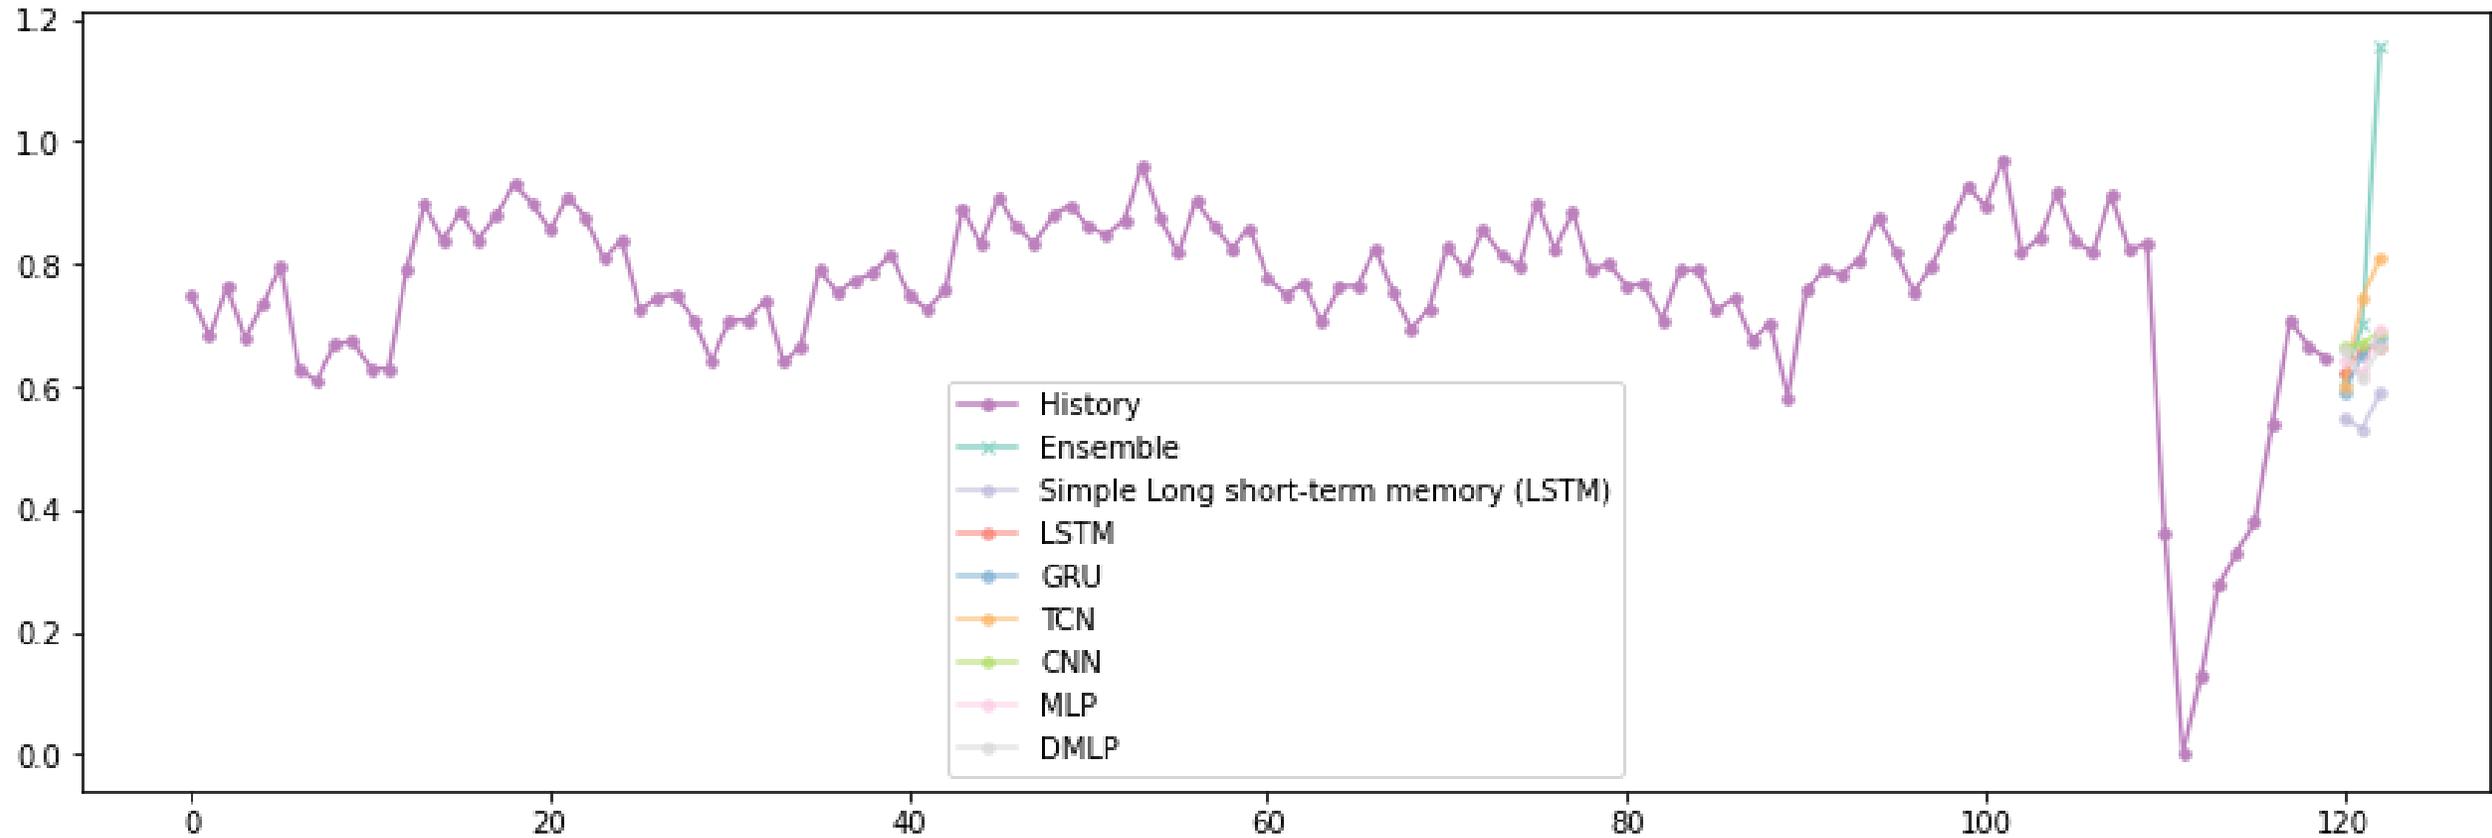
Fuente: Estimación propia en Python

Resultados de nowcasting Estados Unidos



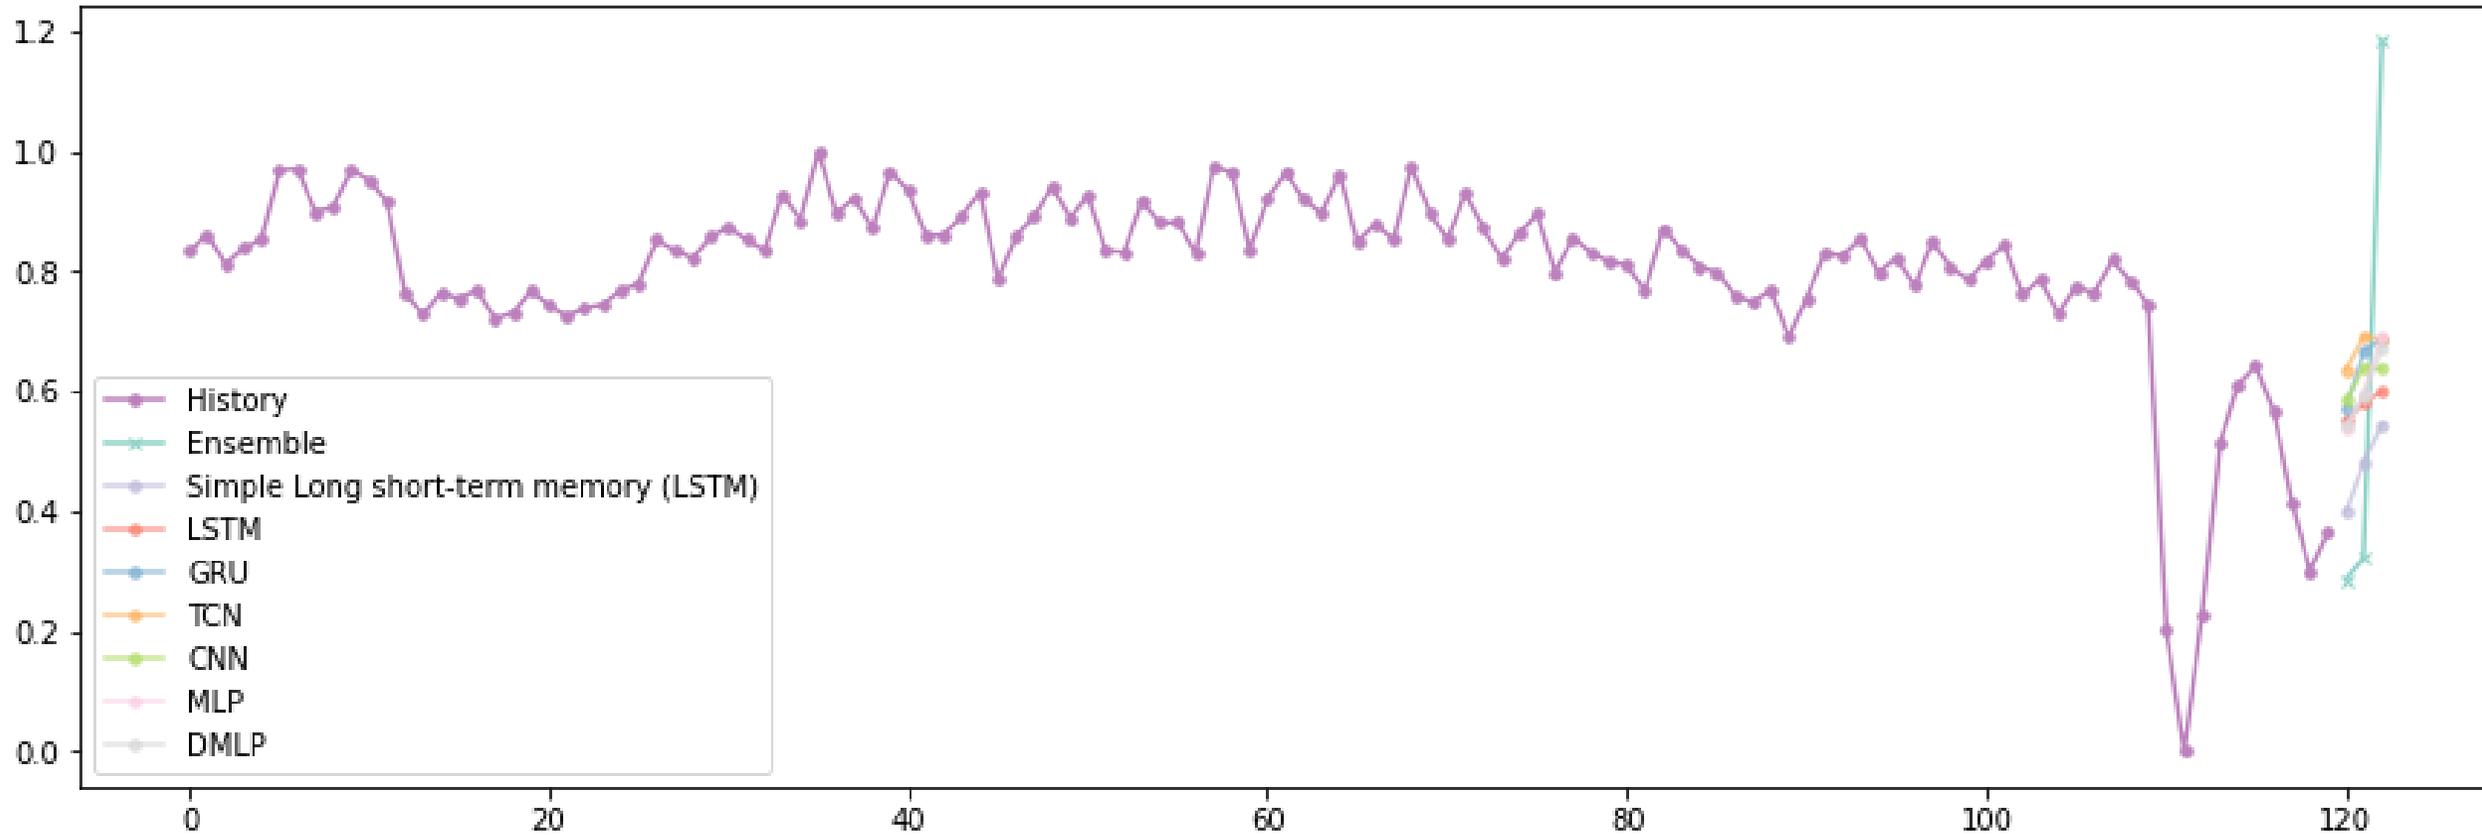
Fuente: Estimación propia en Python

Resultados de nowcasting Colombia



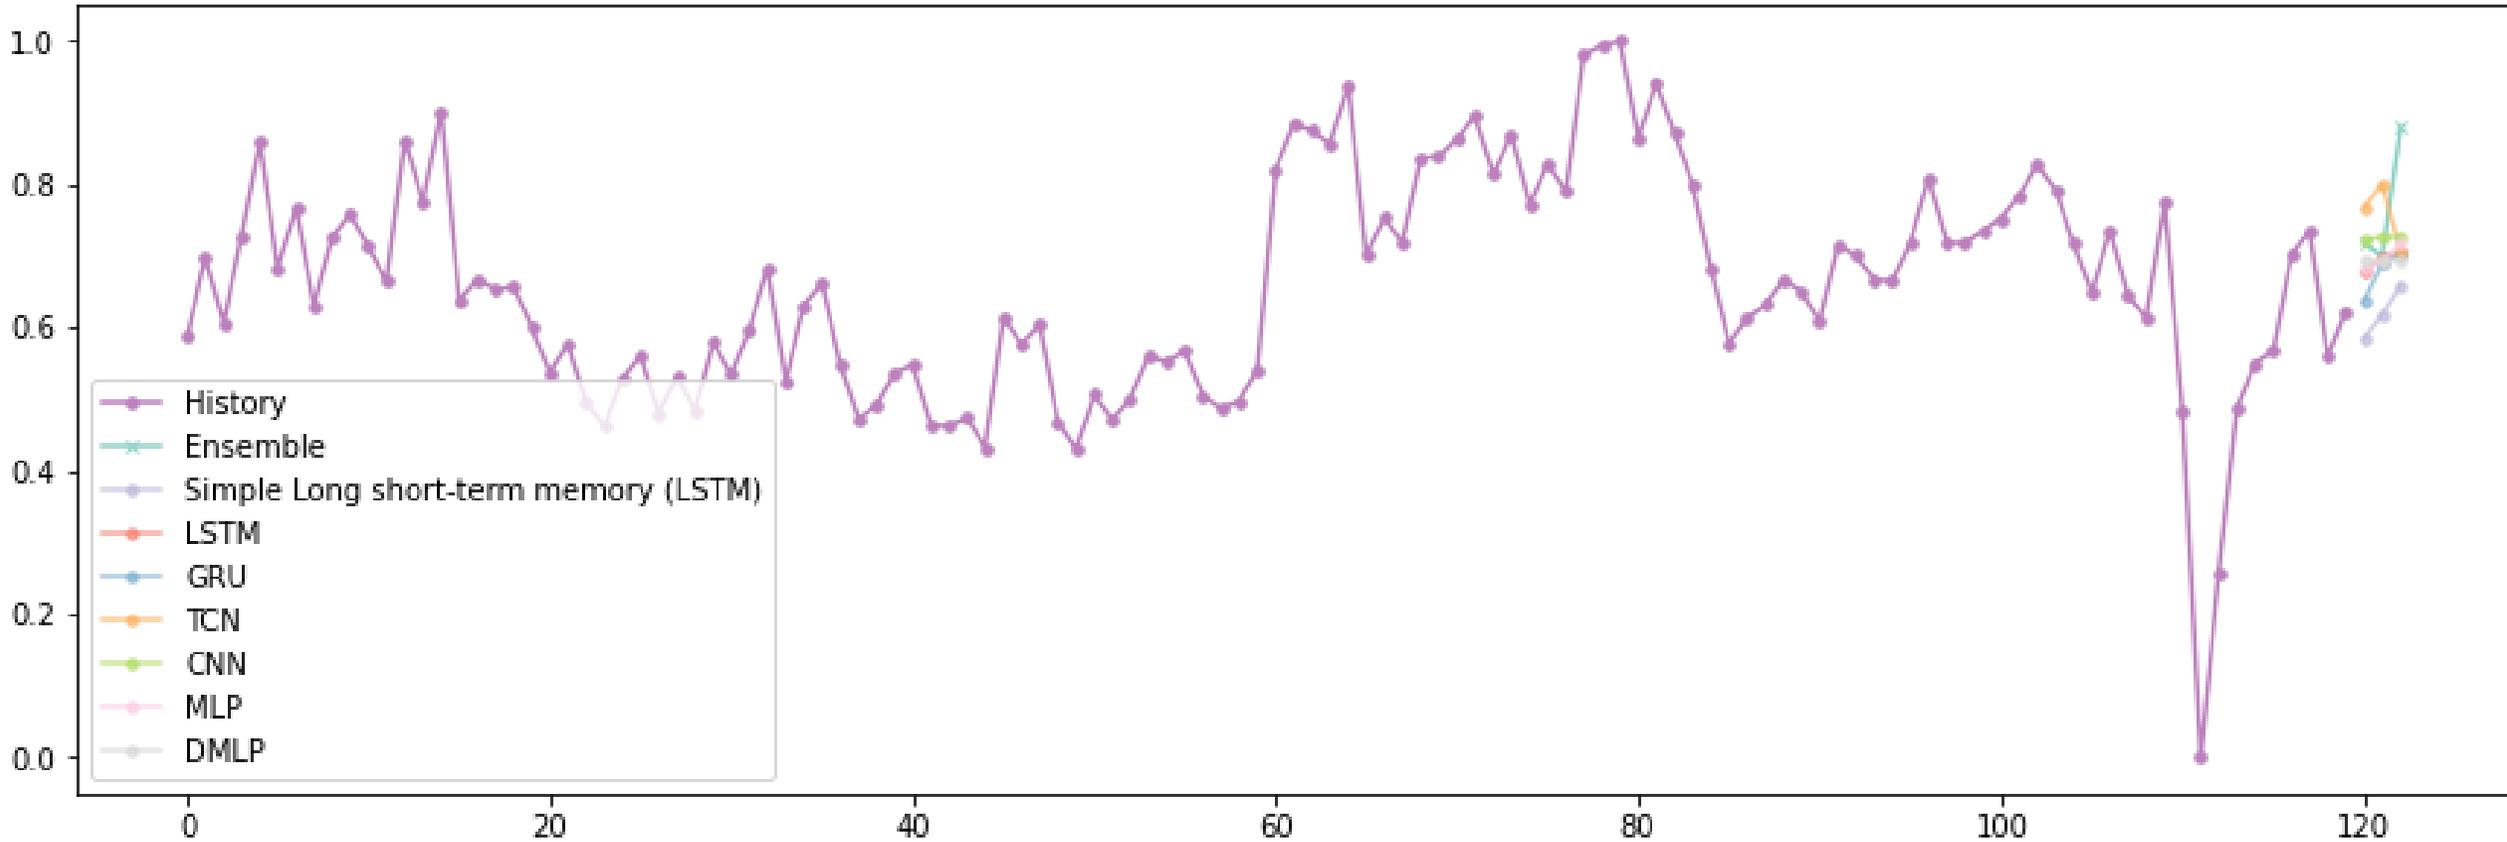
Fuente: Estimación propia en Python

Resultados de nowcasting España



Fuente: Estimación propia en Python

Resultados de nowcasting Russia



Fuente: Estimación propia en Python

La integración de nowcasting DFM y Deep Learning, sumada a la adecuada selección de las principales palabras clave de Google Trends por país con mayor dinamismo y correlaciones significativas respecto al PIB, conforman un modelo de diagnóstico de la actividad económica en "pseudo tiempo real" por su fácil actualización de GoogleTrends, siendo una herramienta rápida, con un alto nivel de precisión y de fácil aplicación por parte de los agentes económicos, eliminando los vacíos de información que se producen en la difusión de los datos macro en las economías avanzadas y emergentes.

Gracias por
su atención!

