

Departamento de Economía

Tipo de documento: Tesis de maestría



Maestría en Econometría

Heterogeneidad y Predicción de Estados en Economías Regionales: Un Análisis Dual con TVP-MF-DFM y Modelos de Markov Switching

Autoría: Alva Da Silva, Fritz Gian Pier

Fecha: 2025

¿Cómo citar este trabajo?

Alva Da Silva, F. (2025). Heterogeneidad y Predicción de Estados en Economías Regionales: Un Análisis Dual con TVP-MF-DFM y Modelos de Markov Switching. [Tesis de maestría. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella <https://repositorio.utdt.edu/handle/20.500.13098/13554>

El presente documento se encuentra alojado en el Repositorio Digital de la **Universidad Torcuato Di Tella** bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Internacional
Dirección: <https://repositorio.utdt.edu>



**UNIVERSIDAD
TORCUATO DI TELLA**

**DEPARTAMENTO DE ECONOMÍA
MAESTRÍA EN ECONOMETRÍA**

**Heterogeneidad y Predicción de Estados en Economías
Regionales: Un Análisis Dual con TVP-MF-DFM y
Modelos de Markov Switching**

Alumno: Fritz Gian Pier Alva Da Silva

Legajo: 23W1902

Tutor: Martín Solá

Fecha: Abril/2025

Índice

1. INTRODUCCIÓN	1
2. LITERATURA RELACIONADA	2
3. METODOLOGÍA	3
3.1. TVP-MF-DFM	4
3.1.1. Algoritmo de estimación	5
3.2. Markov Switching	7
3.2.1. Probabilidades filtradas	8
3.2.2. Probabilidades suavizadas	8
4. DATOS	9
5. RESULTADOS	10
6. CONCLUSIONES	16
REFERENCIAS	18
7. ANEXOS	20

Resumen

Este trabajo desarrolla un enfoque dual para analizar la heterogeneidad y dinámica no lineal de los ciclos económicos regionales en Perú. Primero, se construye un Índice del Ciclo Económico Regional (ICER) mensual para cada región mediante un modelo TVP-MF-DFM (Time Varying Parameters Mixed Frequency Dynamic Factor Model), que integra datos en frecuencia mixta y supera la limitada disponibilidad de información macroeconómica subnacional. Posteriormente, se implementan modelos de Markov Switching sobre estos índices para calcular las probabilidades de que cada economía regional se encuentre en estado de recesión, estancamiento o prosperidad. Los resultados revelan patrones diferenciados entre zonas geográficas, con la región Sur mostrando la menor coincidencia entre sus ciclos (29,6%) debido a su especialización minera, mientras que la zona Norte presenta la mayor sincronización (79,5%) por la similitud en sus estructuras productivas. El enfoque TVP logra un notable grado de sincronización del ICER con las dinámicas macroeconómicas (92,8% en promedio), mientras que los modelos de cambio de régimen detectan efectivamente periodos de crisis y recuperación, evidenciando que durante eventos como la pandemia de COVID-19, la mayoría de las regiones experimentaron una recuperación en forma de "V".

Palabras clave: Heterogeneidad, ciclos económicos regionales, TVP-MF-DFM, Markov Switching, crisis.

1. INTRODUCCIÓN

Dentro de la teoría económica, el apartado de los ciclos económicos siempre ha llamado especial atención desde la popularización de la macroeconomía en el siglo pasado, puesto que comunican en qué situación se encuentra una economía en particular. [Burns y Mitchell \(1946\)](#) postulan al “ciclo de referencia” como aquella variable que captura las amplias oscilaciones de la actividad económica conocidas como ciclo económico. En este sentido, ¿es adecuado señalar que las fluctuaciones del Producto Bruto Interno (PBI) definen el ciclo de referencia? El ciclo económico comúnmente se refiere a los comovimientos de la actividad económica, no solo del PBI, véase [Lucas \(1977\)](#) para un mayor detalle. Por lo tanto, se recomienda utilizar la definición de [Burns y Mitchell \(1946, p.3\)](#) sobre que un ciclo económico “*consiste en expansiones que ocurren aproximadamente al mismo tiempo en muchas actividades económicas, seguidas de recesiones, contracciones y reactivaciones igualmente generales*”. De esta manera, sería incorrecto definir una expansión o recesión solamente en términos del PBI.

En Latinoamérica, existe una deficiencia en el apartado de difusión de información estadística a nivel provincial o departamental, países como Colombia¹, Argentina² y Perú, entre otros, no cuentan con grandes cantidades de datos oficiales vinculados a variables macroeconómicas subnacionales, y en menor medida aún, que se encuentren en frecuencia mensual o trimestral.

El presente trabajo tomará como objeto de análisis al caso peruano, en este país, el Instituto Nacional de Estadística e Informática (INEI) publica un informe técnico sobre un indicador de actividad productiva departamental (IAPD), el cual pretende mostrar la evolución económica de cada región en el corto plazo, concretamente en un trimestre en específico. Sin embargo, este informe se difunde después de aproximadamente dos meses y medio una vez finalizado el trimestre respectivo. De esta manera, resulta altamente importante contar con información macroeconómica regional más actualizada y, preferiblemente, de mayor frecuencia; puesto que, a menudo es más útil conocer en qué situación se encuentra la economía de una región en un mes en particular. No obstante, teniendo en cuenta lo anterior mencionado, el IAPD es un indicador que no proporciona la imagen completa de algunos aspectos sobre la actividad económica real - de hecho, este indicador es considerado como una aproximación trimestral del Valor Agregado Bruto (VAB) regional -, como el sector financiero o el mercado laboral, puesto que solo se elabora a través de información productiva sectorial. Adicionalmente, no se cuenta con una herramienta que permita predecir los estados de cada economía regional.

La presente investigación aborda esta problemática mediante dos procesos metodológicos interrelacionados:

Primer proceso: Construcción de un Índice del Ciclo Económico Regional (ICER) mensual

¹ En Colombia, se encuentra el Departamento Administrativo Nacional de Estadística (DANE), el cual publica oficialmente el PBI por departamentos, pero lo realiza de forma anual con un rezago aproximado de un año.

² En Argentina, se encuentra el Instituto Nacional de Estadística y Censos (INDEC), el cual no cuenta con información oficial actualizada de agregados macroeconómicos a nivel provincial.

El trabajo formaliza la idea de que el ciclo de referencia se mide mejor observando los comovimientos entre diversas series temporales agregadas. Para ello, se propone un Índice del Ciclo Económico Regional (ICER) mensual para cada una de las regiones de Perú. Este índice se construye aplicando un modelo de factores dinámicos con parámetros variantes en el tiempo que incorpora datos en frecuencia mixta (trimestral y mensual), conocido como Time Varying Parameters Mixed Frequency Dynamic Factor Model (TVP-MF-DFM).

El ICER propuesto estima el valor de una única variable no observada, "el estado de la economía", denotada por f_t . Esta variable no observada se define suponiendo que los comovimientos de las series temporales coincidentes observadas en todos los adelantos y retrasos surgen únicamente de movimientos en f_t . Por supuesto, cualquier serie coincidente particular, como los créditos, podría moverse de maneras que no están asociadas con esta variable no observada. Así, se considera que cada serie aproximadamente coincidente tiene un componente atribuible a una única variable no observada, más un componente único (o "idiosincrásico"). A diferencia del IAPD, que solo considera información productiva sectorial, el ICER incorpora otros aspectos de la actividad económica real como los mencionados del sector financiero o empleo.

Segundo proceso: Predicción de estados económicos mediante modelos de cambio de régimen

Una vez construido el ICER para cada región, se desarrollan modelos de cambio de régimen (Markov Switching) para calcular las probabilidades de que cada economía regional se encuentre en estado de recesión, estancamiento o prosperidad económica. Estos modelos permiten analizar la dinámica no lineal de los ciclos económicos regionales y anticipar cambios en las condiciones económicas.

La relevancia de estos indicadores radica en su utilidad para los responsables de políticas económicas, académicos, empresarios y ciudadanos interesados en tomar decisiones informadas considerando la situación específica de cada mercado regional. El enfoque regional permite un análisis más detallado y contextualizado que los indicadores nacionales, facilitando el diseño de políticas específicas para cada territorio.

El aporte principal de este trabajo es doble: por un lado, la construcción de indicadores mensuales del ciclo económico para cada región peruana, superando las limitaciones de disponibilidad de datos; por otro, la implementación de modelos que permiten predecir los estados económicos futuros de cada región. Este enfoque metodológico podría ser replicado en otros países latinoamericanos con similares restricciones de información estadística a nivel subnacional.

2. LITERATURA RELACIONADA

La construcción de índices coincidentes para analizar ciclos económicos ha evolucionado significativamente desde los trabajos pioneros de [Burns y Mitchell \(1946\)](#). El enfoque del NBER (*National Bureau of Economic Research*), refinado por [Moore \(1983\)](#), sentó las bases para los indicadores económicos compuestos.

[Stock y Watson \(1989, 1991\)](#) introdujeron un método basado en modelos de factores dinámicos, que ha sido ampliamente adoptado y extendido ([Chauvet, 1998](#); [Kim y Nelson, 1998](#)). Sin embargo, la mayoría de estos índices se basan exclusivamente en indicadores mensuales, ignorando información trimestral valiosa como el PIB real. Algunos investigadores han abordado la combinación de datos de diferentes frecuencias en modelos macroeconómicos. [Mariano y Murasawa \(2002\)](#) propusieron incorporar el PIB trimestral en un modelo de factor dinámico mensual, mientras que [Aruoba, Diebold y Scotti \(2009\)](#) desarrollaron un modelo de frecuencia mixta para un indicador de actividad económica de alta frecuencia.

Si el análisis se enfoca a un nivel sub nacional, [Gil et al. \(2019\)](#), desarrollan un modelo de factor dinámico bayesiano (BayFaR) para estimar el crecimiento del PIB a corto plazo y la actividad económica en las regiones españolas. El modelo combina datos trimestrales de PIB regional con indicadores mensuales de actividad económica, generando un índice de actividad regional y predicciones de crecimiento del PIB. Aplicado a las cuatro mayores regiones de España, el BayFaR demuestra su capacidad para producir estimaciones robustas en tiempo real, actualizándose con nueva información. Por otro lado, se cuenta con los trabajos de [Gatty \(2017\)](#), y de [Alva y López \(2022\)](#), los cuales están orientados a la economía regional de la Amazonía peruana, en tales estudios se propone un indicador para medir la actividad económica a través de un BayFar utilizando datos anuales y trimestrales, adicionalmente, en el segundo artículo, se construye un modelo ponderado para predecir el VAB regional que utiliza las estimaciones del modelo inicial.

Con respecto al desarrollo de trabajos que implementan modelos de cambio de régimen, [Diebold y Rudebusch \(1996\)](#) proponen un enfoque que incorpora tanto la estructura de factores como el cambio de régimen para analizar los ciclos económicos. Su modelo combina la idea de comovimiento entre variables económicas, capturada por un modelo de factor dinámico, con la noción de cambios de régimen entre períodos de expansión y contracción. Los autores argumentan que este enfoque proporciona una caracterización más completa de las dinámicas del ciclo económico, al capturar tanto el comovimiento generalizado entre indicadores económicos como los cambios no lineales entre diferentes fases del ciclo. Aplican este modelo a los datos del Índice Coincidente Compuesto y sus componentes, encontrando evidencia significativa tanto de estructura factorial como de cambio de régimen en la economía estadounidense.

Por otro lado, [Del Negro y Otrok \(2008\)](#), utilizan modelos de parámetros cambiantes para estimar el ciclo económico internacional, además de economías nacionales, sustentando que este modelamiento permite capturar adecuadamente los cambios bruscos de las series macroeconómicas, así como plasmar una adecuada sincronización dinámica. [Eraslan y Schröder \(2023\)](#), sostienen que la utilización de parámetros variantes en el tiempo mejora los resultados de predicción para periodos crisis.

3. METODOLOGÍA

En este trabajo, utilizo un modelo de factor dinámico de frecuencia mixta con parámetros que varían en el tiempo para estimar y predecir el presente (*nowcasting*) del ciclo

económico regional. Asimismo, construyo modelos de Markov Switching para pronosticar los estados de la economía en cada región del país.

3.1. TVP-MF-DFM

Para definir la forma estructural del modelo, antes se debe establecer la estrategia de agregación temporal de las variables en distinta frecuencia, para ello se seguirá a [Mariano y Murasawa \(2002\)](#).

En este caso, como la variable que solo se encuentra en frecuencia trimestral es el IAPD -que es una aproximación del producto bruto interno (PBI) para el caso regional-, el cual se puede definir de la siguiente manera:

$$Y_t^Q = \frac{1}{3} \sum_{i=0}^2 Y_{t-i}^M \approx (\prod_{i=0}^2 Y_{t-i}^M)^{\frac{1}{3}} \quad (1)$$

En donde Y_t^M hace referencia al valor del IAPD mensual no observado. Nótese que Y_t^Q es un promedio más no una suma, esto se debe a que el IAPD es un índice. Los exponentes Q y M hacen referencia al tipo de frecuencia de la variable en cuestión, siendo el primero para observaciones trimestrales, y mensuales para el segundo.

Luego de transformar la Y_t^Q observada a través de aplicar diferencias logarítmicas, se puede definir la serie mensual parcialmente observada:

$$y_t^Q = \begin{cases} \ln(Y_t^Q) - \ln(Y_{t-4}^Q), & t = 4, 8, 12, \dots \\ \text{no observado, de otra manera} \end{cases} \quad (2)$$

Donde y_t^Q es observada cada tercer mes y no observada durante los primeros y segundos meses de cada trimestre. Teniendo en cuenta que el subíndice t para el caso de la variable trimestral representa un periodo trimestral t , y para el caso de la variable mensual, el mismo subíndice representa un periodo mensual, entonces, tomando logaritmo a la ecuación (1) y remplazándola en (2), se tiene:

$$y_t^Q = \frac{1}{3} (\sum_{i=0}^2 \ln(Y_{t-i}^M) + \sum_{i=0}^2 \ln(Y_{t-12-i}^M)) = \frac{1}{3} \sum_{i=0}^2 y_{t-i}^M \quad (3)$$

Esta aproximación mantiene las restricciones sobre la dinámica observacional lineal, y permite expresar al modelo en una representación estado-espacio asumiendo la dependencia directa de cada y_t^M sobre un factor común f_t de la forma:

$$y_t^M = \alpha_t^y f_t + u_t^y \rightarrow y_t^Q = \frac{1}{3} \sum_{i=0}^2 \alpha_{t-i}^y f_{t-i} + \frac{1}{3} \sum_{i=0}^2 u_{t-i}^y \quad (4)$$

No obstante, dado que y_t^Q solo se observa cada tres meses, se genera un conflicto entre estas cargas factoriales y este esquema de agregación. Además, para realizar una adecuada estimación bayesiana de α_t^y , es necesario conocer su varianza, y para estimarla, se requiere una estimación de α_t^y en cada punto del tiempo. Para lidiar con este inconveniente, condicionando sobre el factor, la relación se re expresa como el producto entre la carga factorial trimestral y el promedio móvil trimestral del factor común, de modo que:

$$y_t^Q = \alpha_t^y \frac{1}{3} \sum_{i=0}^2 f_{t-i} + u_t^y \quad (5)$$

En el caso de las variables económicas mensuales que sí son observables, el planteamiento es más directo, tal que:

$$z_t^M = \Lambda_t^M f_t + u_t^z, \quad u_t^z \sim \mathbf{Normal}(\mathbf{0}, V^z) \quad (6)$$

Donde z_t^M es un vector n -dimensional de variables en frecuencia mensual, Λ_t^M es una matriz $n \times k$ que contiene las cargas factoriales del modelo en cada instante de tiempo. Nótese que, en este estudio $k=1$.

Una vez que he definido la agregación temporal de la data en frecuencia mixta (MF), procedo a introducir la variación en el tiempo de los parámetros (TVP) para el modelo de factor común dinámico (DFM). El sistema estado-espacio se puede representar como:

$$x_t = H_t s_t + u_t, \quad u_t \sim \mathbf{Normal}(\mathbf{0}, V) \quad (7a)$$

$$s_t = A s_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \mathbf{Normal}(\mathbf{0}, Q) \quad (7b)$$

$$\Lambda_t = \Lambda_{t-1} + v_t, \quad v_t \sim \mathbf{Normal}(\mathbf{0}, \Sigma) \quad (7c)$$

Donde

$$x_t = [z_t^M \quad y_t^Q]'$$

$$H_t = \begin{bmatrix} \Lambda_t^M & \mathbf{0} & \mathbf{0} & \mathbf{0}_{(m \times p-3)} \\ \frac{1}{3}\Lambda_t^Q & \frac{1}{3}\Lambda_t^Q & \frac{1}{3}\Lambda_t^Q & \mathbf{0}_{(q \times p-3)} \end{bmatrix},$$

$$s_t = [f_t \quad f_{t-1} \quad f_{t-2} \quad \dots \quad f_{t-p+1}]'$$

Con Λ_t^M y Λ_t^Q de dimensiones $m \times l$ y $q \times l$, respectivamente; m indica la cantidad de variables mensuales, y q la cantidad de variables trimestrales, en este trabajo $q=1$.

$$A = \begin{bmatrix} \beta_1 & \dots & \beta_{p-1} & \beta_p \\ 1 & \dots & 0 & 0 \\ \vdots & \ddots & \vdots & \\ 0 & \dots & 1 & 0 \end{bmatrix}, \quad u_t = \begin{bmatrix} u_{1,t} \\ \vdots \\ u_{n,t} \end{bmatrix}$$

$$\varepsilon_t = [e_t \quad \mathbf{0} \quad \dots \quad \mathbf{0}]'$$

Los vectores de cargas factoriales Λ_t^M y Λ_t^Q se encuentran dentro de H_t . El vector de estado s_t se encuentra restringido para tener al menos tres elementos a consecuencia del esquema de agregación temporal empleado, su dinámica se encuentra controlada por la matriz compañera A , en este trabajo establezco un orden de rezago p igual a dos, de acuerdo con la literatura relacionada. Finalmente, los errores gaussianos de media cero en las ecuaciones de medición y transición están dadas por u_t y ε_t , donde V es diagonal, y Q es singular con un bloque no singular, esto significa que, en la esquina superior izquierda está el escalar σ_ε^2 , mientras que en el resto de la matriz contiene ceros.

En este modelo, la ecuación (7c) establece la variación temporal de las cargas factoriales Λ_t , y se asume que siguen un proceso *random walk*. Además, v_t es independiente e idénticamente distribuido.

3.1.1. Algoritmo de Estimación: La estimación del modelo se realiza mediante métodos bayesianos de Markov Chain Monte Carlo (MCMC) utilizando:

1. El algoritmo del Filtro de Kalman de acuerdo a la estructura del modelo planteado, adaptando así los datos en frecuencia mixta. Antes de comenzar el proceso, se establecen las distribuciones *prior* que se detallan en el Anexo A. Se utilizaron *priors* difusos para los coeficientes, y *priors* informativos para los parámetros de varianza en el sentido de garantizar su positividad. La etapa de inicialización utiliza estas distribuciones y las muestrea, estableciendo así de manera aleatoria el vector inicial de los parámetros $\Lambda_{0|0}$. Por su parte, se define al vector de estado inicial $s_{0|0} = \mathbf{0}$ y a su matriz de covarianzas $P_{0|0} = (0.1)I$ donde I es la matriz identidad.
2. Luego, se realiza un filtrado inicial *forward* sobre el vector de estado imponiendo la restricción de estabilización numérica para garantizar simetría y positividad en la matriz de covarianzas de la forma: $P_{t|t} = (P_{t|t} + P'_{t|t})/2$.
3. Posteriormente, se aplica el algoritmo de MCMC guiado bajo el esquema Gibbs³ *sampling*, donde se re muestrea secuencialmente los bloques respectivos al factor latente, los parámetros cambiantes y a las varianzas, de la forma:
 - 3.1. Se aplica el algoritmo de [Carter-Kohn \(1994\)](#), el cual funciona para obtener muestras de la distribución posterior conjunta de toda la trayectoria de estados latentes. El proceso inicia con un filtro hacia adelante aplicando el Filtro de Kalman con las ecuaciones de predicción y actualización estándar, luego se realiza un muestreo hacia atrás de la manera:
 - i. Se muestrea el estado final de la distribución filtrada:

$$s_T \sim \mathbf{Normal}(s_{T|T}, P_{T|T})$$
 - ii. Se procede recursivamente hacia atrás para $t = T - 1, T - 2, \dots, 1$. Se generan las muestras de la distribución conjunta

$$p(s_1, \dots, s_T | x_1, \dots, x_T, \Theta) = p(s_T | x_1, \dots, x_T, \Theta) \prod_{t=1}^{T-1} p(s_t | s_{t+1}, x_1, \dots, x_T, \Theta).$$
 Donde Θ representa el conjunto completo de parámetros a estimar en el modelo que no son el factor común latente. Para cada t se calcula la distribución condicional $p(s_t | s_{t+1}, x_1, \dots, x_T, \Theta)$, que es normal con:

$$\text{Media: } s_{t|t} + P_{t|t}A'(AP_{t|t}A' + Q)^{-1}(s_{t+1} - As_{t|t})$$

$$\text{Varianza: } P_{t|t} - P_{t|t}A'(AP_{t|t}A' + Q)^{-1}AP_{t|t}$$
 - 3.2. Para el caso de los parámetros variantes en el tiempo, el proceso es conceptualmente similar. Se aplica el algoritmo Carter-Kohn para muestrear la trayectoria de cada parámetro con algunas diferencias, esto es:
 - i. Asumiendo que las cargas factoriales no están correlacionadas entre las variables, es posible muestrearlas ecuación por ecuación. Es decir, se pueden construir estimaciones separadas del Filtro de Kalman para las variables mensuales (Λ_t^M) y trimestrales (Λ_t^Q). Por

³ Se emplea este algoritmo de muestreo considerando la complejidad del modelo y para explorar adecuadamente el espacio de parámetros.

tanto, se muestrea el estado final de las distribuciones filtradas de la forma:

$$\Lambda_t^j \sim \mathbf{Normal}(\Lambda_{T|T}^j, P_{T|T}^j), \quad j = \{M, Q\}$$

Recordar que Λ_t^Q captura la estructura de agregación descrita en la ecuación (5).

- ii. Se continúa recursivamente hacia atrás para $t = T - 1, T - 2, \dots, 1$. Se generan las muestras de la probabilidad conjunta

$$p(\Lambda_1^j, \dots, \Lambda_T^j | x_1, \dots, x_T) = p(\Lambda_T^j | x_1, \dots, x_T) \prod_{t=1}^{T-1} p(\Lambda_t^j | \Lambda_{t+1}^j, x_1, \dots, x_T).$$

Para cada t se calcula la distribución condicional $p(\Lambda_t^j | \Lambda_{t+1}^j, x_1, \dots, x_T)$, que es normal con:

$$\text{Media: } \Lambda_t^j + P_{t|t}^j (P_{t|t}^j + \Sigma)^{-1} (\Lambda_{t+1}^j - \Lambda_{t|t}^j)$$

$$\text{Varianza: } P_{t|t}^j - P_{t|t}^j (P_{t|t}^j + \Sigma)^{-1} P_{t|t}^j$$

- 3.3. Finalmente, se aplica el muestreo de Gibbs para calcular las distribuciones *posteriors* de los coeficientes autorregresivos del factor y de las varianzas. Las funciones de distribución *prior* utilizadas se encuentran en el Anexo A.

Todos los resultados reportados por este modelo para cada región están basados en 20000 simulaciones por Gibbs *sampling*. Las primeras 5000 son descartadas (*burn-in*) para minimizar la influencia de los valores iniciales.

3.2. Markov Switching

En el presente artículo se supone que existen tres estados de la naturaleza en el ciclo económico para cada región del país, los cuales son recesión, estancamiento y prosperidad. Teniendo en cuenta que el ciclo de referencia viene representado por el ICER (f_t), en el modelo de Markov Switching se establecerán tres regímenes para esta variable. Así, el proceso generador de datos (PGD) se expresa de la forma:

$$f_t^m = \mu_{a_t}^m + \Psi(L)^m f_t^m + \varepsilon_t^m,$$

donde $\mu_{a_t} = I_{a_t=0}\mu_0 + I_{a_t=1}\mu_1 + I_{a_t=2}\mu_2$, estableciendo a $I_{s_t=j}$ como una función indicadora que adopta el valor 1 cuando la condición de a_t (variable categórica latente que varía según el régimen) es verdadera y 0 en otro caso. La utilización del exponente m hace referencia al PGD que se utilizó para cada región m , esto se debe a que, al ser economías diferentes, la utilización de un mismo PGD para todos los departamentos del Perú es poco realista y no genera los resultados apropiados. Por tal motivo, se utiliza el polinomio de rezago $\Psi(L)^m$, que tomará los rezagos en función a la necesidad de cada PGD. El error es ε_t^m y se asume que se distribuye normal con media cero y varianza σ^2 .

La función de densidad propuesta es:

$$f(f_t^m | a_t = j, \Omega_{t-1}) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{\left\{ \frac{-(f_t^m - \mu_j^m - \Psi(L)^m f_t^m)^2}{2\sigma^2} \right\}}$$

Donde Ω_{t-1} representa a toda la información desde la primera observación hasta el instante $t - 1$, y μ_j es la media del PGD correspondiente al estado j .

Para la obtención de las probabilidades se aplicará el filtro de Hamilton, siguiendo a [Hamilton \(1994\)](#). Se necesitan calcular las probabilidades filtradas y suavizadas, de las cuales, estas últimas son las de interés principal. Así,

3.2.1. **Probabilidades filtradas:** Se representan por $Pr(a_t = j|\Omega_t)$ es decir, por la probabilidad de estar en el estado j en el tiempo.

Aplicando la regla de Bayes:

$$Pr(a_t = j|\Omega_t) = \frac{Pr(f_t^m, a_t = j|\Omega_{t-1})}{Pr(f_t^m|\Omega_{t-1})}$$

Utilizando la regla de la cadena, el numerador se puede descomponer como:

$$Pr(f_t^m, a_t = j|\Omega_{t-1}) = Pr(f_t^m|a_t = j, \Omega_{t-1})Pr(a_t = j|\Omega_{t-1})$$

Donde $Pr(f_t^m|a_t = j, \Omega_{t-1})$ es la función de densidad $f(f_t^m|a_t = j, \Omega_{t-1})$ y $Pr(a_t = j|\Omega_{t-1})$ es la probabilidad predictiva del estado j .

Para el denominador, se aplica la ley de probabilidad total:

$$Pr(f_t^m|\Omega_{t-1}) = \sum_{i=0}^2 Pr(f_t^m|a_t = i, \Omega_{t-1})Pr(a_t = i|\Omega_{t-1})$$

Sustituyendo en la ecuación de Bayes se tiene:

$$Pr(a_t = j|\Omega_t) = \frac{f(f_t^m|a_t = j, \Omega_{t-1})Pr(a_t = j|\Omega_{t-1})}{\sum_{i=0}^2 f(f_t^m|a_t = i, \Omega_{t-1})Pr(a_t = i|\Omega_{t-1})}$$

3.2.2. **Probabilidades suavizadas:** Representan la probabilidad de estar en el estado j en el tiempo t condicionada a toda la información disponible de la muestra T ($Pr(a_t = j|\Omega_T)$).

Se expresa como un promedio ponderado de la forma:

$$\begin{aligned} Pr(a_t = j|\Omega_T) &= \sum_{i=0}^2 Pr(a_t = j, a_{t+1} = i|\Omega_T) \\ &= \sum_{i=0}^2 [Pr(a_{t+1} = i|\Omega_T)Pr(a_t = j|a_{t+1} = i, \Omega_T)] \end{aligned}$$

Utilizando la aproximación de [Kim \(1994\)](#): $Pr(a_t = j|a_{t+1} = i, \Omega_T) \approx Pr(a_t = j|a_{t+1} = i, \Omega_t)$. Entonces,

$$\begin{aligned} &\approx \sum_{i=0}^2 [Pr(a_{t+1} = i|\Omega_T)Pr(a_t = j|a_{t+1} = i, \Omega_t)] \\ &= \sum_{i=0}^2 [Pr(a_{t+1} = i|\Omega_T) \frac{Pr(a_t = j, a_{t+1} = i|\Omega_t)}{Pr(a_{t+1} = i|\Omega_t)}] \\ &= \sum_{i=0}^2 [Pr(a_{t+1} = i|\Omega_T) \frac{Pr(a_t = j, \Omega_t)Pr(a_{t+1} = i|a_t = j)}{Pr(a_{t+1} = i|\Omega_t)}] \end{aligned}$$

Notar que $Pr(a_{t+1} = i|a_t = j) = Pr(a_{t+1} = i|a_t = j, \Omega_t)$ es la probabilidad de transición de la cadena Markoviana. Reorganizando los términos, se tiene:

$$Pr(a_t = j|\Omega_T) = Pr(a_t = j|\Omega_t) \sum_{i=0}^2 \frac{Pr(a_{t+1} = i|\Omega_T)Pr(a_{t+1} = i|a_t = j)}{Pr(a_{t+1} = i|\Omega_t)}$$

4. DATOS

Utilizo cinco variables en frecuencia mensual y una en frecuencia trimestral, durante el periodo 2012-2023. Las transformaciones empleadas sobre las series son diferencias logarítmicas interanuales. Para un mayor detalle sobre la descripción de la data, véase la Tabla 1.

Se debe recalcar que la obtención de datos a nivel regional se encuentra restringida por la disponibilidad de información estadística oficial, es decir, no existe una gran abundancia de datos recopilados a través del tiempo enfocados a los sectores macroeconómicos subnacionales, como es el caso también de Perú. Asimismo, la selección de las variables se realizó en función del nivel de coincidencia que presentan cada una con respecto al VAB.

Tabla 1. Descripción de los datos

Indicador	Sector	Frec.	Fuente
Crédito total	Financiero	M	SBS
Gasto público	Administración pública	M	MEF
Consumo de electricidad	Consumo	M	OSINERGMIN
Empleo	Laboral	M	INEI
PBI	Producción nacional	M	BCRP
IAPD	Producción regional	T	INEI

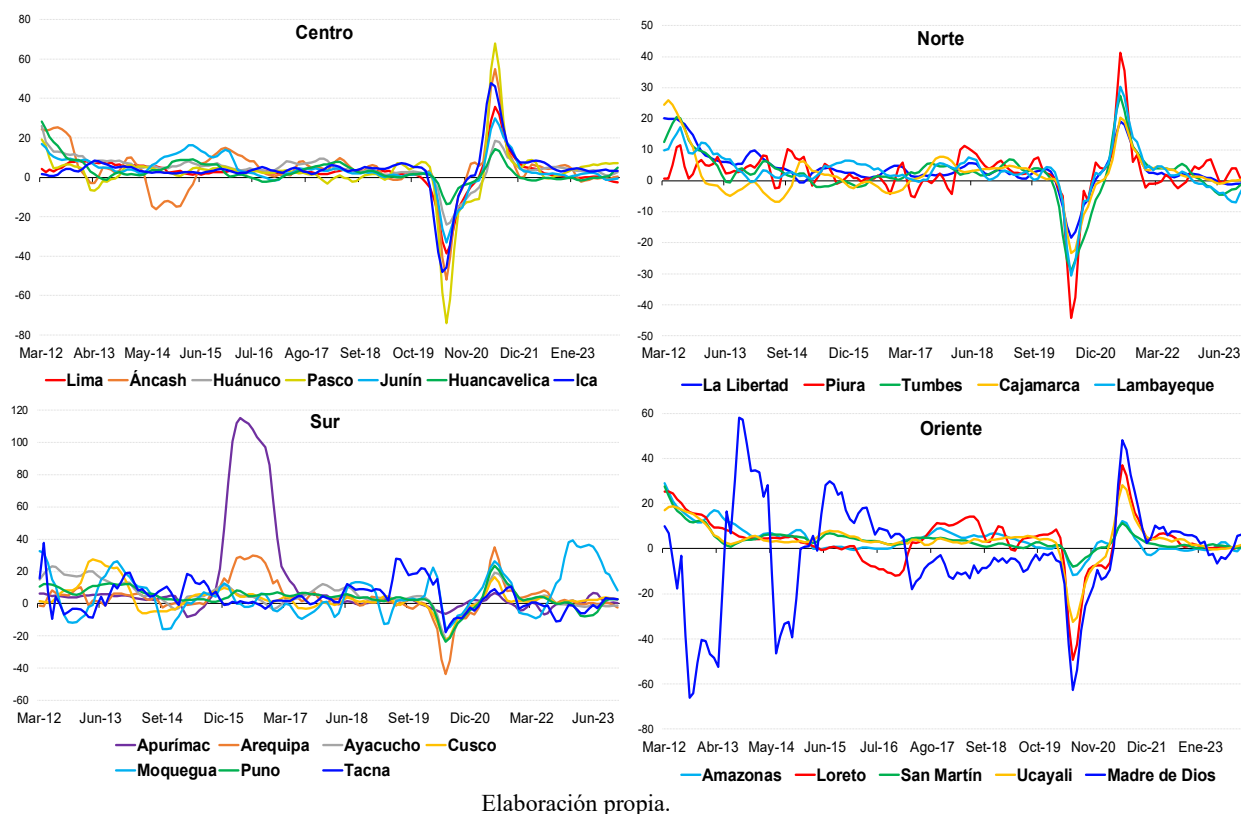
Nota: Esta tabla otorga una descripción general sobre los datos que se usan como variables de medida en el modelo TVP-MF-DFM. La abreviación “Frec.” indica la frecuencia de observación que se registra para cada indicador, siendo “M” para el caso mensual y “T” para el trimestral. En “Fuente” se describe el acrónimo de las instituciones gubernamentales que publican oficialmente los datos para el respectivo indicador, donde se encuentran la Superintendencia de Banca, Seguros y AFP (SBS), el Ministerio de Economía y Finanzas (MEF), el Organismo Supervisor de la Inversión en Energía y Minas (OSINERGMIN) y el Banco Central de Reserva del Perú (BCRP).

Al observar los datos por primera vez, uno puede pensar que el conjunto de indicadores es relativamente pequeño, teniendo en cuenta que los modelos factoriales son capaces de trabajar con mayores cantidades de variables. No obstante, en la literatura macroeconómica reciente se ha mostrado que el uso de una cantidad modesta de indicadores representativos suele ser mejor que una mucho mayor. [Alvarez et al. \(2012\)](#) demostraron que usar un conjunto pequeño de indicadores macroeconómicos para predecir el presente del PBI de Estados Unidos genera mejores resultados que el uso de un conjunto grande. Asimismo, trabajos como el de [Duarte y Süßmuth \(2018\)](#), evalúan data macroeconómica de manera secuencial, empleando un método sistemático de selección y filtrado que les permite reducir un amplio conjunto inicial de 258 series temporales a solo 14 indicadores finales. Esta reducción, se fundamenta en criterios estadísticos robustos que identifican las variables con mayor poder explicativo para realizar una estimación más precisa respecto al PBI español.

5. RESULTADOS

Una vez ejecutadas las estimaciones del ICER para cada región a través del modelo TVP-MF-DFM, se procedió a calcular el promedio móvil trimestral para cada mes durante el horizonte temporal de análisis, con el objetivo de obtener series suavizadas y coincidentes con la estructura del factor planteada en la ecuación (5).

Figura 1. ICER de cada Región por Zona Geográfica
(Var. % a/a)



Para visualizar la heterogeneidad en los ciclos económicos subnacionales, en la Figura 1 se encuentra la clasificación por zonas geográficas⁴. De las cuatro zonas, la que mayor relevancia económica supone es la de centro, debido a que la capital del país (que representa el 43,9% del PBI en promedio durante los últimos diez años⁵) se encuentra en ella. En general, las economías de la zona centro muestran ciclos económicos similares con leves diferencias durante ciertos periodos de crisis. Por ejemplo, en 2014 se experimentó una abrupta caída de la producción minera en la región Áncash que luego repercutió en un descenso de 13,3% anual en su VAB; esta dinámica negativa es capturada adecuadamente por el ICER respectivo. Por otro lado, la crisis ocasionada por la pandemia mundial en 2020 impactó de distinta manera a la actividad económica de cada departamento (a unas regiones más que a otras), por ejemplo, la región que sufrió en menor medida este choque fue Huancavelica, registrando un pico negativo de -13,7% en

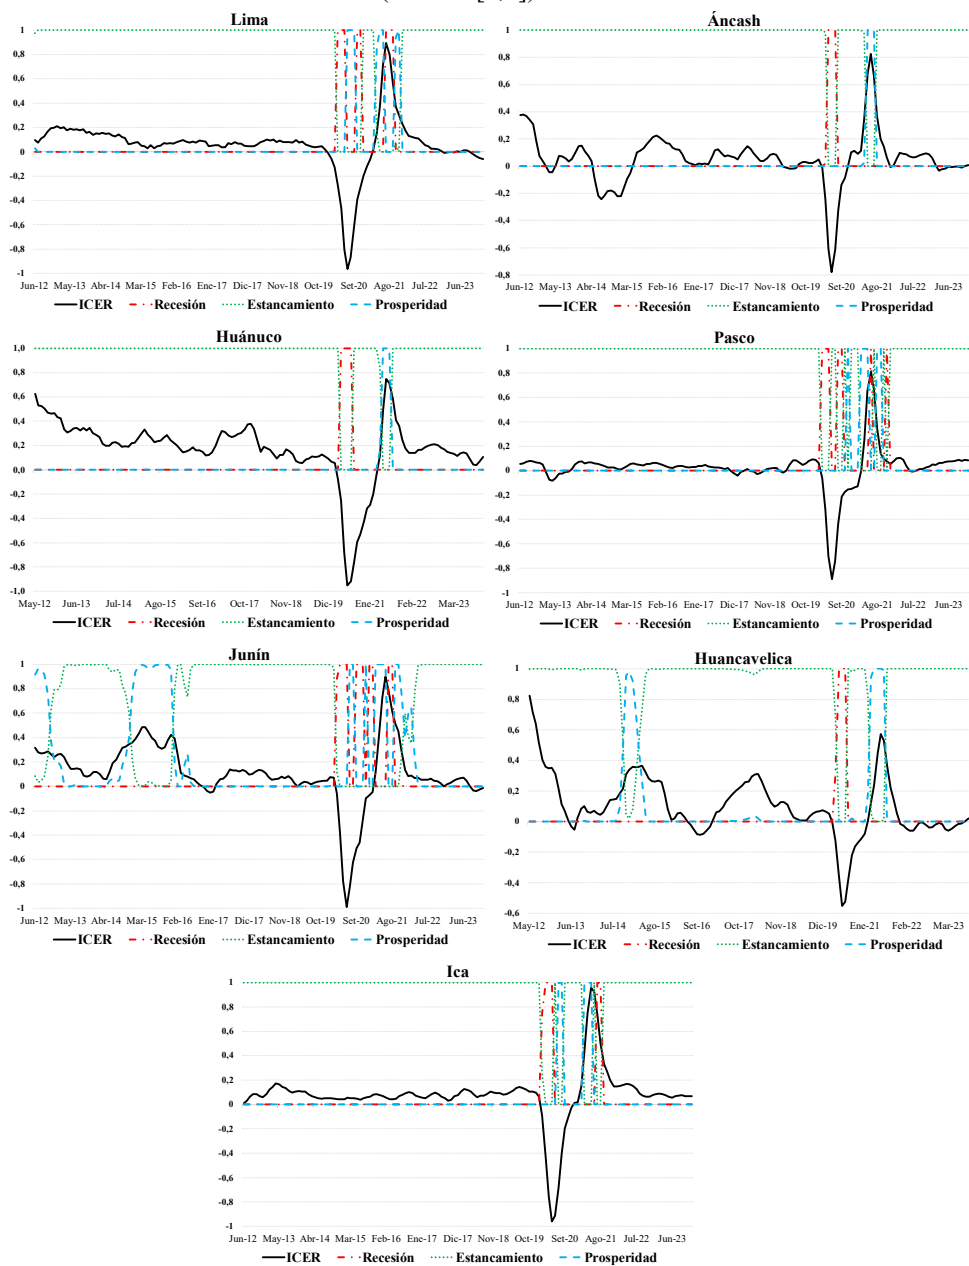
⁴ Se sigue a la clasificación recomendada por el [BCRP](#).

⁵ Fuente: [INEI](#).

el mes de junio, a diferencia de Pasco que cayó en 74,0%, colocándose así, como la región que más se vio contraída en la zona centro y en el país.

Para verificar el grado de congruencia dinámica entre los ciclos económicos de la zona centro, en el Anexo B se encuentra la Tabla 3 que muestra los valores de las correlaciones dinámicas, y se observa que, las regiones Pasco y Lima presentan el valor más alto con un nivel de coincidencia de 90,5%. Por otro lado, el menor nivel de correlación dinámica en esta zona es de 43,5% entre Huancavelica e Ica.

Figura 2. Probabilidades Suavizadas de estar en Recesión, Estancamiento o Prosperidad - Zona Central (Prob. $\in [0,1]$)

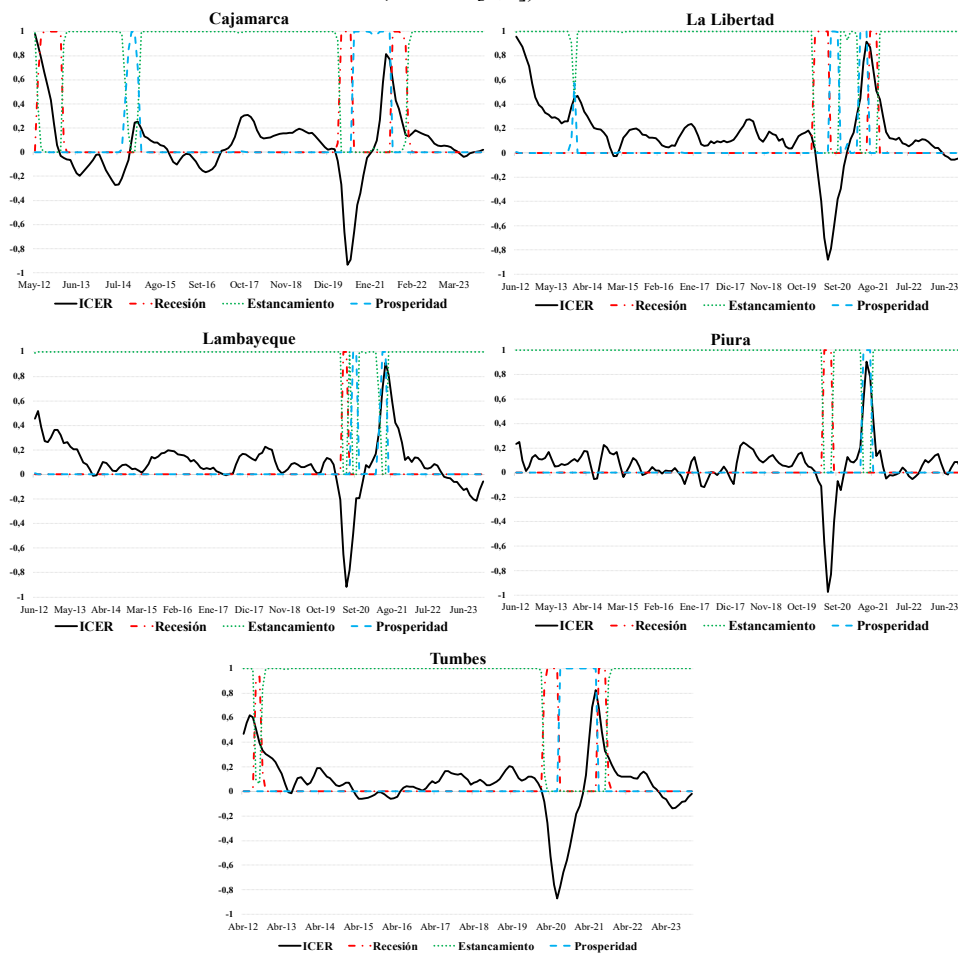


Elaboración propia.

La segunda zona con mayor relevancia económica durante los últimos diez años es la Sur (16,8% del PBI). Un hallazgo importante que se evidencia es que, esta zona registra una dinámica agregada bastante diferente a la observada en las demás zonas, es decir, en la

economía sureña, el ciclo económico subyacente responde a otros factores macroeconómicos plasmados mayoritariamente en el desempeño de la producción minera (de acuerdo a la naturaleza de las estructuras productivas regionales que la integran). El primer pico más notorio se observa durante los años 2016-2017, que es captado principalmente por las regiones Apurímac y Arequipa, las cuales en tal periodo experimentaron grandes expansiones en sus VAB, sustentadas fundamentalmente por las mayores inversiones plasmadas en la gran operación minera de Las Bambas⁶. En Apurímac, el impacto fue histórico, ya que, su producción bruta registró un crecimiento 1'305,1% para 2016, y la participación del sector minería pasó de un 6,6% (promedio durante 2009-2015) a un 60,8% (promedio 2016-2023) de su VAB. Para el caso de Arequipa, este departamento registró su mayor crecimiento del siglo en 2016 con un 25,9%⁷, del cual, también, principalmente se explica por la expansión de su producción minera, la cual se duplicó en dicho año.

Figura 3. Probabilidades Suavizadas de estar en Recesión, Estancamiento o Prosperidad - Zona Norte (Prob. $\in [0,1]$)



Elaboración propia.

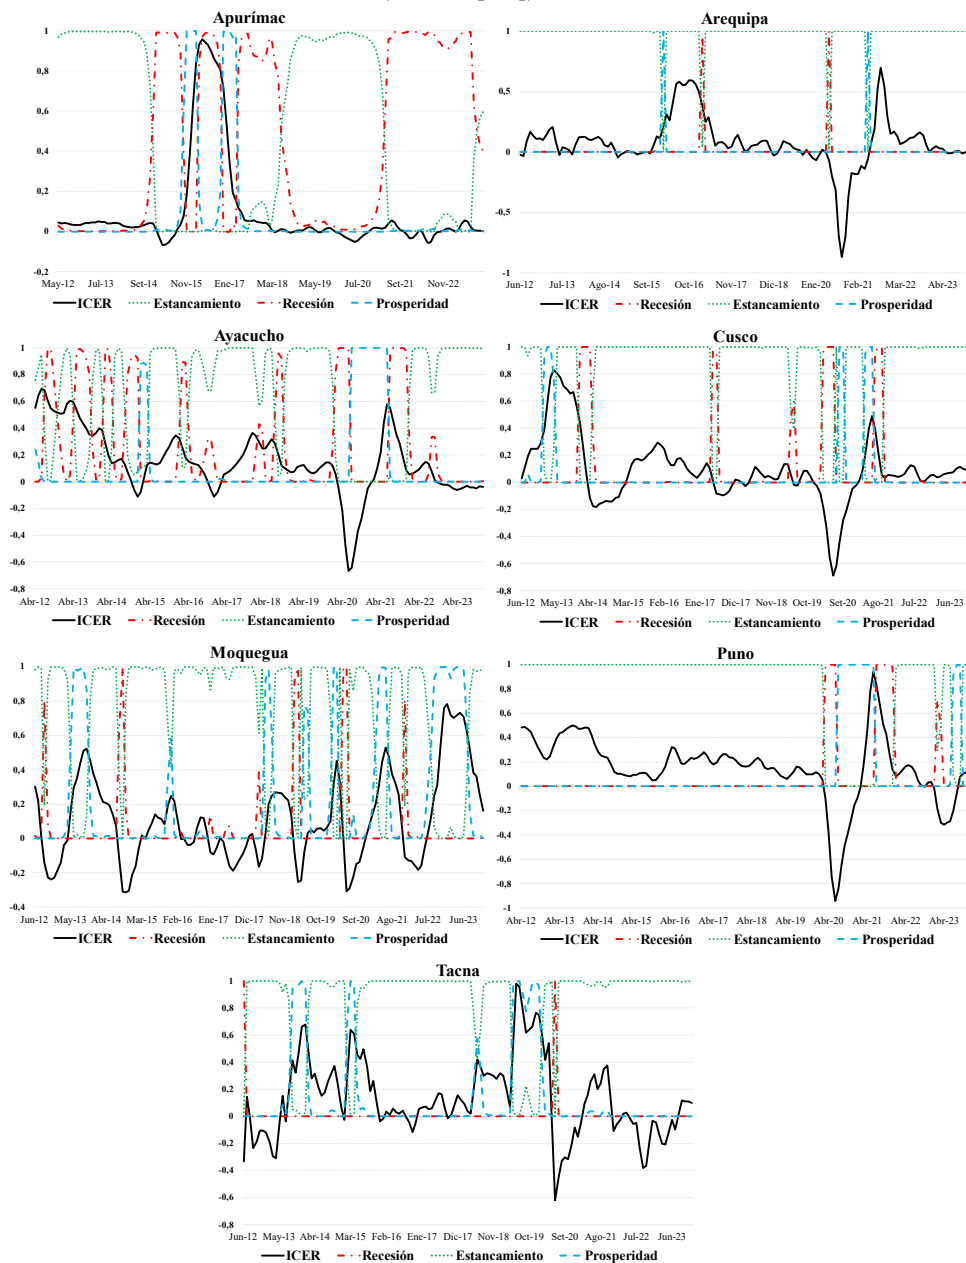
Otra novedad encontrada en esta zona se refleja en la heterogeneidad de la dinámica coincidente entre los ciclos económicos, incluso, se registran correlaciones dinámicas negativas entre algunas regiones como Tacna y Apurímac (-14,9%), o muy cercanas a

⁶ Unidad minera concentrada en cobre.

⁷ Fuente: [INEI](#).

cero como la calculada entre Ayacucho y Apurímac (1,5%). De hecho, en esta zona se registra el menor grado de coincidencia de los ciclos económicos regionales, presentando un promedio de 29,6% (nivel bastante inferior comparado, por ejemplo, con el de la zona centro que registra un 75,2%), y siendo Tacna la región que menos coincide en promedio con sus vecinas (11,8% de correlación dinámica promedio).

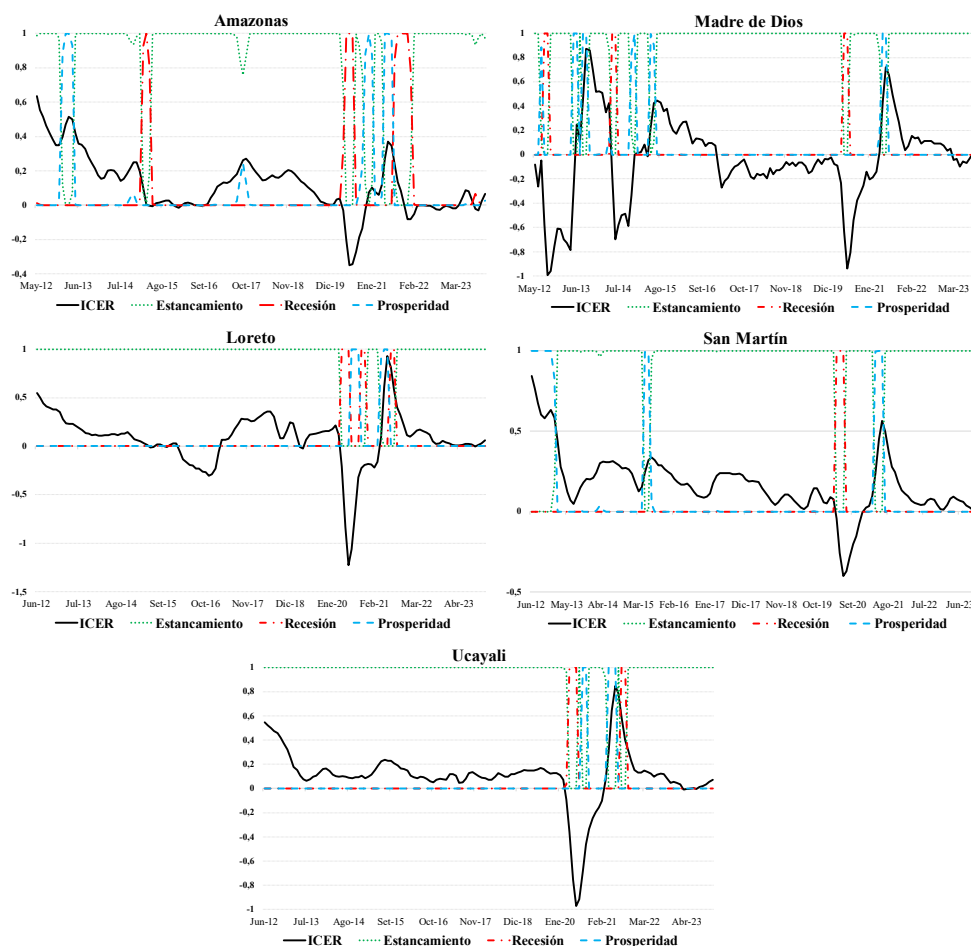
Figura 4. Probabilidades Suavizadas de estar en Recesión, Estancamiento o Prosperidad - Zona Sur
(Prob. $\in [0,1]$)



La tercera zona en analizar es la Norte, la cual presenta el menor grado de discrepancia dinámica en comparación a las demás zonas, registrando una correlación dinámica promedio de 79,5%. La explicación detrás de este comportamiento agregado se basa en la similitud existente entre las estructuras productivas de los departamentos norteños, incluso, para cada región, 8 de las 12 actividades económicas que componen el VAB

(medidas en participación porcentual), presentan diferencias absolutas entre ellas menor a 2,5%, sin contar la actividad de otros servicios, que presenta una diferencia absoluta promedio de 4,6%, no obstante, esta última no debe implicar una incongruencia con el común de la estructura productiva, ya que, para todas las regiones en esta zona, la actividad de otros servicios es la que ocupa el primer lugar en participación productiva.

Figura 5. Probabilidades Suavizadas de estar en Recesión, Estancamiento o Prosperidad, Zona Oriente (Prob. $\in [0,1]$)



Elaboración propia.

Por último, en lo que respecta a este análisis, en la zona oriente (4,6% del PBI en los últimos diez años) se presenta el ciclo con mayores impactos en una región previo al periodo COVID-19, el cual corresponde al de Madre de Dios durante 2012-2014. La razón detrás de estos choques se basa en los cambios abruptos que experimentó la producción de gas natural (principal motor de actividad económica de Madre de Dios durante ese periodo), localizada en el Lote⁸ 76. Con respecto al resto de departamentos, se presenta un notable nivel de coincidencia de 77,0% entre sus ciclos económicos sin considerar el ICER de Madre de Dios, es más, esta presenta una correlación promedio de 12,8% en esta zona.

⁸ Fuente: [Rumbo Minero](#).

Con el objetivo de validar la robustez en las estimaciones, los resultados se deben contrastar con lo observado en la realidad, ante ello, en el Anexo C, se encuentran las series del ICER e IAPD para cada región de las zonas centro, norte, sur y oriente. Considerando que la serie del IAPD es trimestral, para la comparación con el ICER se utilizó el valor observado en el último mes de cada trimestre del promedio móvil calculado. Como se puede observar en cada una de las regiones, la coincidencia de la estimación del ciclo económico con la producción agregada es bastante alta, de hecho, en algunos departamentos, como en La Libertad o Ica, el ICER reacciona más rápido a periodos de crisis como el experimentado en 2020. En general, todos los ciclos económicos coinciden en promedio en 92,8% con su producción observada respectiva. Ahondando en los casos de mínima y máxima congruencia, el ICER de Huancavelica registra un 82,1% de correlación dinámica con su IAPD, siendo así la región con el menor grado de coincidencia, mientras que, el ICER de Piura se correlaciona en 98,5%, posicionándose como el ICER que más se sincroniza con su producción regional. Este nivel tan alto de robustez es sustentado principalmente por el enfoque utilizado de parámetros cambiantes en el tiempo (TVP), ya que, permite un aprendizaje rápido del factor común ante distintos choques y/o cambios estructurales ocurridos en las series macroeconómicas.

Con respecto a los resultados de los modelos Markov de cambio de régimen, en las Figuras 2, 3 4 y 5, se encuentran graficadas las probabilidades suavizadas de caer en recesión, estancamiento o prosperidad económica para cada región en las zonas centro, norte, sur y oriente, respectivamente. Para mostrar más claramente la reacción de las probabilidades con los estados de los ciclos, se re escaló cada serie ICER dividiendo por una constante adecuada.

Se verifica que todos los modelos de Markov Switching se comportan adecuadamente para detectar periodos de crisis y estancamiento económico, en donde este último estado, no debe entenderse necesariamente como una situación negativa o dañina para las economías regionales, debido a que principalmente el estado de prosperidad, en la mayoría de los casos se atribuye a etapas de recuperación económica más que a una fase de auge o bonanza, de acuerdo con la evidencia histórica.

En este análisis, también se observó que la región más cíclica, es decir, aquella que presenta la mayor cantidad de fases de recesión y prosperidad, es Moquegua, ya que durante el periodo analizado registró cinco ciclos económicos. Por otro lado, se observa que la región con el ciclo el más ruidoso parece ser Tacna, por lo que, procedí a descomponer tales series y extraer sus componentes de ruido para después compararlos mediante el índice de suavidad de [Rudebusch \(1995\)](#), el cual arrojó como resultado un valor de 182,3 para Moquegua y 800,9 para Tacna, por lo que, se puede determinar que si bien una región puede presentar mayor volatilidad cíclica, esto no necesariamente se traduce en una mayor incertidumbre económica en el corto plazo.

Si bien es cierto que existe heterogeneidad en los ciclos económicos regionales, también existen patrones que son comunes, los cuales son más evidentes durante periodos de crisis que afectan a la economía nacional. En general, a excepción de algunas regiones, el impacto macroeconómico del COVID-19 se plasmó en una caída en “V” -según la literatura de teoría del crecimiento- para las economías subnacionales.

6. CONCLUSIONES

En este trabajo se ha desarrollado un análisis dual de los ciclos económicos regionales peruanos, aplicando secuencialmente dos metodologías complementarias. En primer lugar, se construyeron Índices del Ciclo Económico Regional (ICER) mensuales mediante un modelo de factores dinámicos con parámetros variantes en el tiempo y frecuencia mixta (TVP-MF-DFM). Posteriormente, estos índices sirvieron como insumo para implementar modelos de cambio de régimen (Markov Switching) que permiten predecir los estados económicos de cada región.

La primera etapa metodológica permitió superar el obstáculo de escasez de datos macroeconómicos a nivel regional, demostrando que es posible construir indicadores confiables incluso con conjuntos limitados de variables. El enfoque TVP-MF-DFM logró capturar un notable grado de sincronización entre cada ICER y las dinámicas macroeconómicas observadas en la realidad, respaldado por un nivel de coincidencia promedio de 92,8% con los datos oficiales. Este alto grado de ajuste valida la robustez del primer componente metodológico del trabajo.

El análisis de los ICER construidos reveló patrones de heterogeneidad significativos. Se identificó que la zona Sur presenta una dinámica agregada notablemente diferente a las demás zonas, influenciada principalmente por la actividad minera. La zona Norte muestra el menor grado de discrepancia dinámica (correlación promedio de 79,5%), mientras que la zona Sur presenta la menor coincidencia entre ciclos económicos regionales (promedio de 29,6%). Estos resultados confirman que la similitud en las estructuras productivas, como la observada en la zona Norte, conduce a una mayor sincronización de ciclos económicos, mientras que la especialización en sectores específicos, como la minería en la zona Sur, genera dinámicas más idiosincráticas.

En la segunda etapa metodológica, los modelos de Markov Switching aplicados a los ICER previamente construidos han funcionado adecuadamente para detectar y clasificar periodos de recesión, estancamiento y prosperidad económica en las diferentes regiones. Esta fase predictiva del análisis mostró su utilidad para anticipar cambios en las condiciones económicas regionales, complementando la capacidad descriptiva de los índices creados en la primera etapa. El estudio de las probabilidades suavizadas evidenció que una mayor cantidad de ciclos económicos, como en el caso de Moquegua (que registró cinco ciclos durante el periodo analizado), no necesariamente se traduce en una manifestación mayor de incertidumbre económica.

A pesar de la heterogeneidad capturada por ambas metodologías, también se identificaron patrones comunes entre las regiones, que son más evidentes durante periodos de crisis nacional. Por ejemplo, durante la pandemia de COVID-19, se observó una mayor sincronización en los ciclos económicos regionales, manifestándose generalmente en una recuperación en forma de "V" según la literatura de la teoría del crecimiento.

La implementación secuencial de estas dos metodologías complementarias (construcción de índices y predicción de estados) proporciona una visión integral de la dinámica económica regional peruana, ofreciendo tanto herramientas descriptivas como predictivas para el análisis económico subnacional.

Implicancias de Política Económica: La marcada heterogeneidad entre regiones, evidenciada tanto por los ICER como por los modelos de Markov Switching, sugiere que las políticas macroeconómicas nacionales pueden tener efectos asimétricos, lo que debería justificar la implementación de políticas públicas adaptadas a las realidades de cada región. El enfoque dual adoptado en este trabajo ofrece dos ventajas principales para los hacedores de política: primero, el ICER, al ser mensual, se anticipa a la publicación del IAPD trimestral, proporcionando información más oportuna; segundo, los modelos de cambio de régimen permiten identificar probabilísticamente el estado actual de cada economía regional y anticipar transiciones entre estados, facilitando la implementación de políticas preventivas o contra cíclicas específicas.

Apertura a nuevas líneas de investigación: En investigaciones futuras, se podría explorar la inclusión de más variables sectoriales para mejorar la precisión del ICER, especialmente para regiones con estructuras productivas altamente especializadas. Asimismo, sería valioso expandir el segundo componente metodológico incorporando modelos de Markov Switching con transiciones endógenas o dependientes del tiempo, que podrían capturar mejor la dinámica no lineal y los cambios estructurales en las economías regionales. Finalmente, la metodología dual desarrollada en este trabajo podría extenderse a otros países latinoamericanos con similares limitaciones de información estadística subnacional.

REFERENCIAS

- Alvarez, R., Camacho, M., y Perez-Quiros, G. (2012). *Finite sample performance of small versus large scale dynamic factor models*. Banco de España working paper No. 1204.
- Alva, F. y López, M. (2022). *Desarrollo de un Indicador de Actividad Económica Regional y Pronósticos del Valor Agregado Bruto: El Caso de Loreto*. Banco Central de Reserva del Perú. Revista Estudios Económicos No. 40, 59 – 80.
- Aruoba, S., Diebold, F. & Scotti, C. (2009). *Real-Time Measurement of Business Conditions*. *Journal of Business & Economic Statistics*, 27(4), 417-427.
- Bañbura, M. y Modugno, M. (2014). *Maximum likelihood estimation of factor models on datasets with arbitrary patterns of missing data*. *Journal of Applied Econometrics*, 29(1), 133–160.
- Burns, A. & Mitchell, W. (1946). *Measuring Business Cycles*. New York: NBER.
- Carter, C. & Kohn, R. (1994). *On Gibbs Sampling for State Space Models*. *Biometrika*, Vol. 81, No. 3 (Aug., 1994), pp. 541-553.
- Chauvet, M. (1998). *An econometric characterization of business cycle dynamics with factor structure and regime switching*. *International Economic Review*, 39(4), 969-996.
- Del Negro, M. y Otrok, C. (2008). *Dynamic Factor Models with Time-Varying Parameters Measuring Changes in International Business Cycles*. Federal Reserve Bank of New York, No. 326.
- Diebold, F. & Rudebusch, G. (1996). *Measuring Business Cycles: A Modern Perspective*. *The Review of Economics and Statistics*, 78(1), 67-77.
- Duarte, P., & Süßmuth, B. (2018). *Implementing an approximate dynamic factor model to nowcast gdp using sensitivity analysis*. *Journal of Business Cycle Research*, 14(1), 127–141.
- Eraslan, S. y Schröder, M. (2023). *Nowcasting GDP with a pool of factor models and a fast estimation algorithm*. *International Journal of Forecasting*, 39 (2023) 1460-1476.
- Gatty, A. (2017). *Nuevo indicador de actividad económica de la región Loreto*. Colegio de Economistas de Loreto.
- Gil, M., Leiva-Leon, D., Pérez, J. & Urtasun, A. (2019). *An application of dynamic factor models to nowcast regional economic activity in Spain*. Banco de España Occasional Paper No. 1904.
- Hamilton, J. (1994). *Time series analysis*. Princeton.
- Kim, C. (1994). *Dynamic linear models with Markov-switching*. *Journal of econometrics*, 60(1-2), 1-22.
- Kim, C. & Nelson, C. (1998). *Business cycle turning points, a new coincident index, and tests of duration dependence based on a dynamic factor model with regime switching*. *Review of Economics and Statistics*, 80(2), 188-201.

- Lucas, R. (1977). *Understanding Business Cycles*. Carnegie-Rochester Conference on Public Policy 5: 7-29.
- Moore, G. (1983). *Business Cycles, Inflation, and Forecasting*, 2nd edition, Cambridge, Mass.: Ballinger Publishing Company for NBER.
- Mariano, R. & Murasawa, Y. (2002). *A new coincident index of business cycles based on monthly and quarterly series*. PIER Working Paper No. 02-014.
- Rudebusch, G. (1995). *Federal Reserve interest rate targeting, rational expectations, and the term structure*. Elsevier Science. *Journal of Monetary Economics*, 35 (1995) 245 – 274.
- Stock, J. & Watson, M. (1989). *New Indexes of Coincident and Leading Economic Indicators*. NBER Macroeconomics Annual 1989, vol. 4., 351-409.
- Stock, J. & Watson, M. (1991). *A probability model of the coincident indicators*. In *leading economic indicators*, Lahiri K, Moore GII (eds). Cambridge University Press.

7. ANEXOS

A. Distribuciones *prior* de los parámetros estructurales

En la estimación bayesiana de un modelo TVP-MF-DFM se requiere definir las distribuciones prior de los vectores de interés; para el caso del presente estudio, se expresan de la siguiente manera:

Tabla 2. Especificación de las distribuciones *prior*

Parámetro	Descripción	Dist. Prior	Hiperparámetro
Λ_0	Coefficientes iniciales de carga del factor	$Normal(\mu_{\Lambda_0}, \Sigma_{\Lambda_0})$	$\mu_{\Lambda_0} = \mathbf{0}_{6 \times 1}$ $\Sigma_{\Lambda_0} = \mathbf{I}_{6 \times 6}$
β	Coefficientes AR del factor	$Normal(\mu_{\beta}, \Sigma_{\beta})$	$\mu_{\beta} = \mathbf{0}_{2 \times 1}$ $\Sigma_{\beta} = \mathbf{I}_{2 \times 2}$
σ_j^2	Varianza del error j	$IG(a, b)$	$a = 2.5, b = 0.1$

Nota: Esta tabla describe las distribuciones prior utilizadas para los parámetros del modelo TVP-MF-DFM. “Dist.” es la abreviatura de distribución, asimismo, IG denota la distribución Gamma Inversa.

Donde, $\Lambda_0 = [\Lambda_0^{iapd}, \Lambda_0^e, \Lambda_0^{cd}, \Lambda_0^{gp}, \Lambda_0^l, \Lambda_0^y]'$, $\beta = [\beta_1, \beta_2]$ y $j \in \{iapd, e, cd, gp, l, y\}$. Siguiendo con la especificación, los términos $\{iapd, e, cd, gp, l, y\}$ hacen referencia a las variables IAPD, consumo de electricidad, crédito total, gasto público, empleo y PBI, respectivamente.

Como se puede observar, se utilizaron *priors* difusos para los coeficientes para otorgar mayor libertad a la información generada por los datos y a la heterogeneidad de realidades económicas a nivel regional. Para las varianzas, se utilizaron distribuciones a priori moderadamente informativas con el objetivo de garantizar su positividad.

B. Correlaciones dinámicas de los ICER's por zonas geográficas

Tabla 3. Correlaciones dinámicas de los ICER's

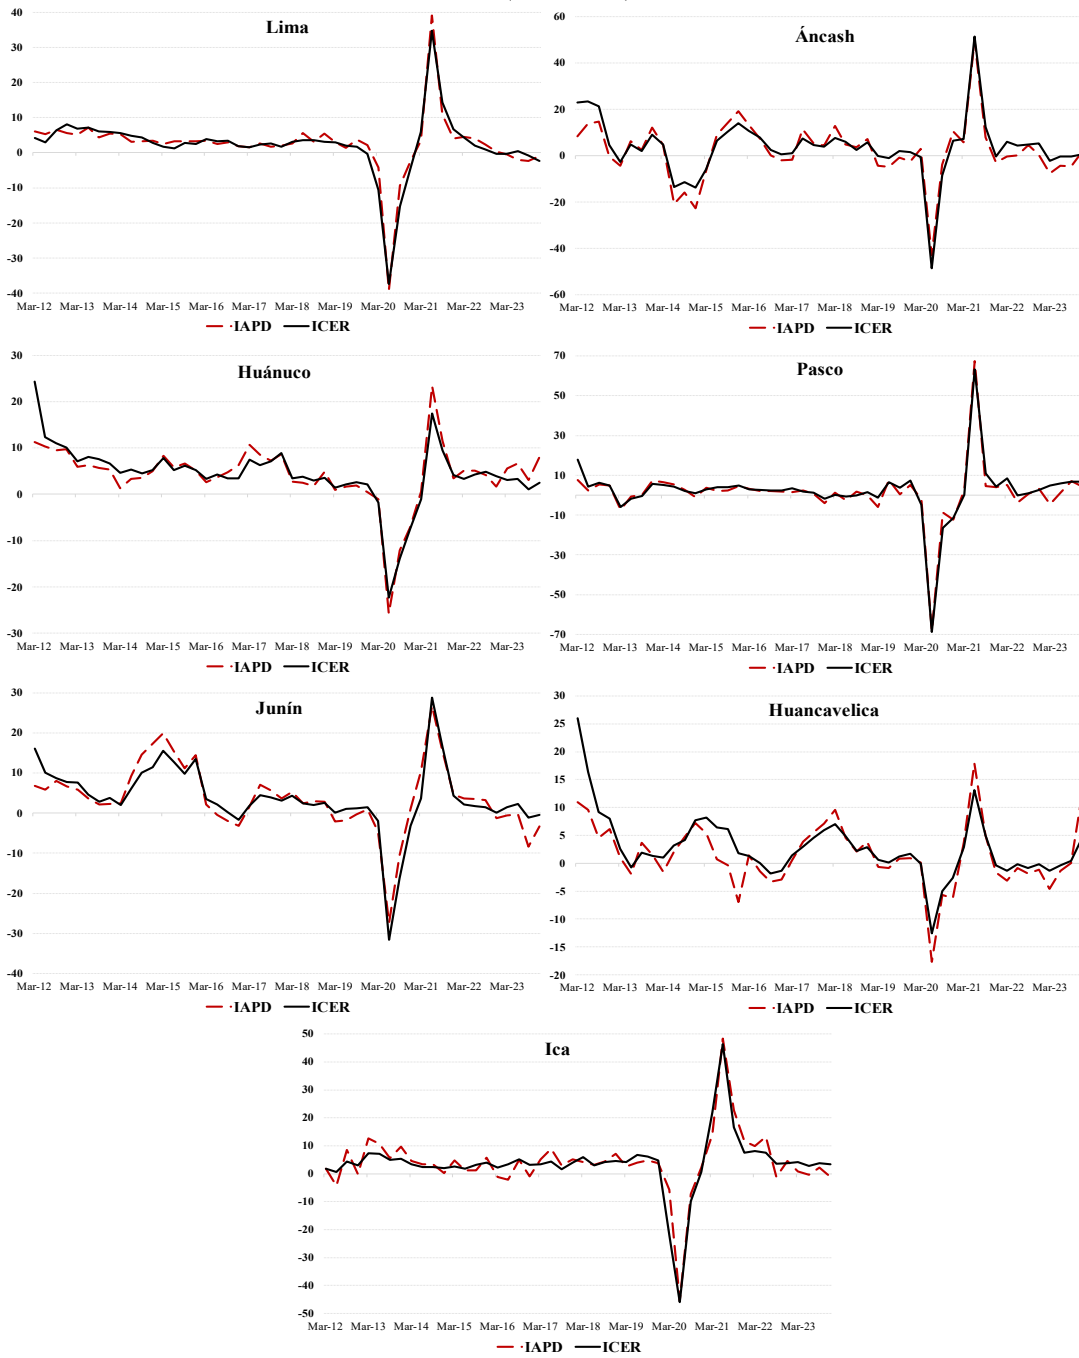
Zona Centro							
ρ	Lima	Áncash	Huánuco	Pasco	Junín	Huancavelica	Ica
Lima	1						
Áncash	0,775	1					
Huánuco	0,814	0,705	1				
Pasco	0,905	0,813	0,776	1			
Junín	0,861	0,701	0,864	0,833	1		
Huancavelica	0,565	0,625	0,801	0,599	0,773	1	
Ica	0,922	0,751	0,638	0,882	0,750	0,435	1
Zona Norte							
ρ	La Libertad	Piura	Tumbes	Cajamarca	Lambayeque		
La Libertad	1						
Piura	0,701	1					
Tumbes	0,904	0,750	1				
Cajamarca	0,799	0,625	0,839	1			
Lambayeque	0,866	0,822	0,885	0,758	1		
Zona Oriente							
ρ	Amazonas	Loreto	San Martín	Ucayali	Madre de Dios		
Amazonas	1						
Loreto	0,749	1					
San Martín	0,821	0,715	1				
Ucayali	0,676	0,878	0,783	1			
Madre de Dios	-0,060	0,197	0,045	0,329	1		
Zona Sur							
ρ	Apurímac	Arequipa	Ayacucho	Cusco	Moquegua	Puno	Tacna
Apurímac	1						
Arequipa	0,660	1					
Ayacucho	0,015	0,509	1				
Cusco	0,131	0,493	0,717	1			
Moquegua	-0,080	0,108	0,163	0,265	1		
Puno	0,158	0,699	0,837	0,671	0,163	1	
Tacna	-0,149	0,056	0,219	0,055	0,181	0,346	1

Elaboración propia.

En esta Tabla 3 se presentan los valores de las correlaciones dinámicas entre cada una de las regiones por zona geográfica. Los valores promedios de las correlaciones por zona son: Centro 75,2%, Norte 79,5%, Oriente 51,3% y Sur 29,6%.

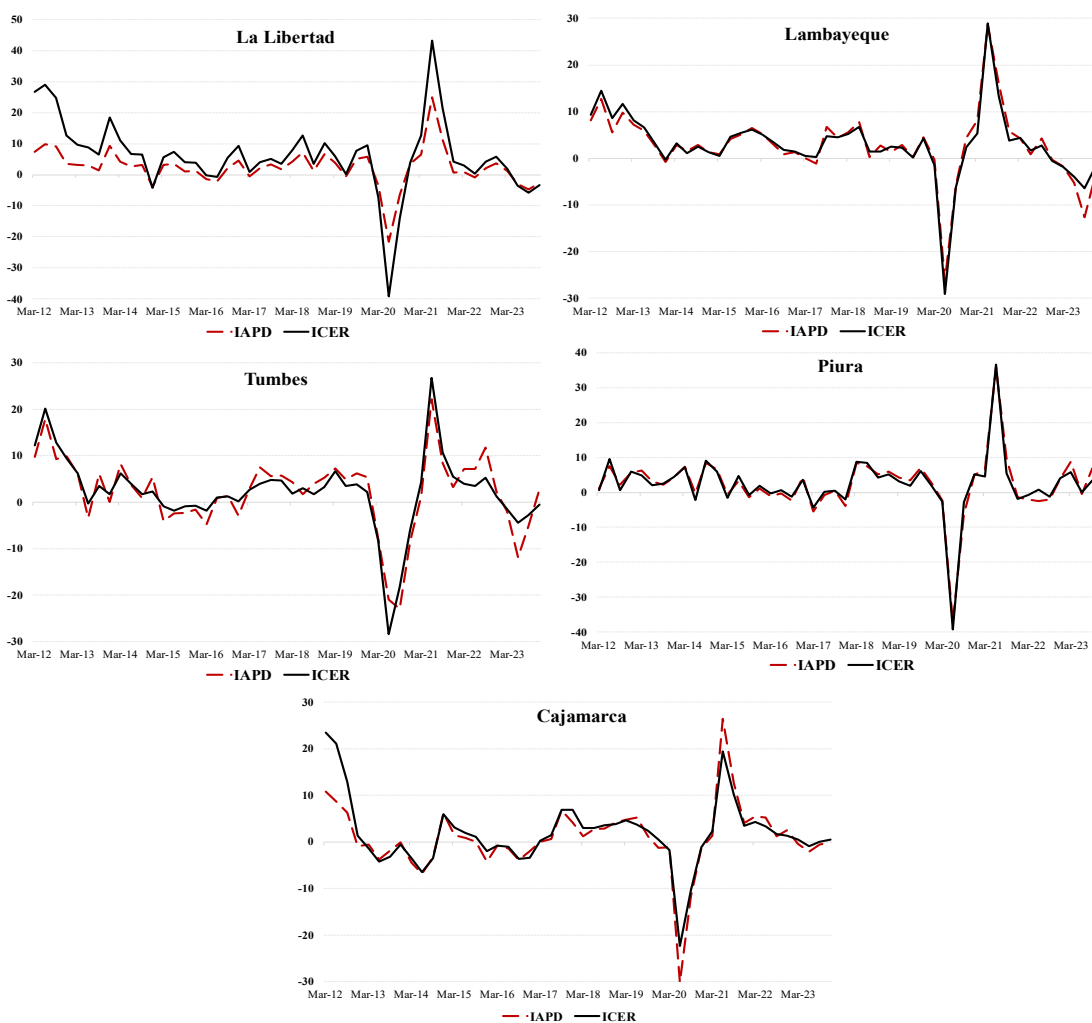
C. Comparación del Índice del Ciclo Económico Regional con el Indicador de Actividad Productiva Departamental

IAPD e ICER: Zona Centro
(Var. % a/a)



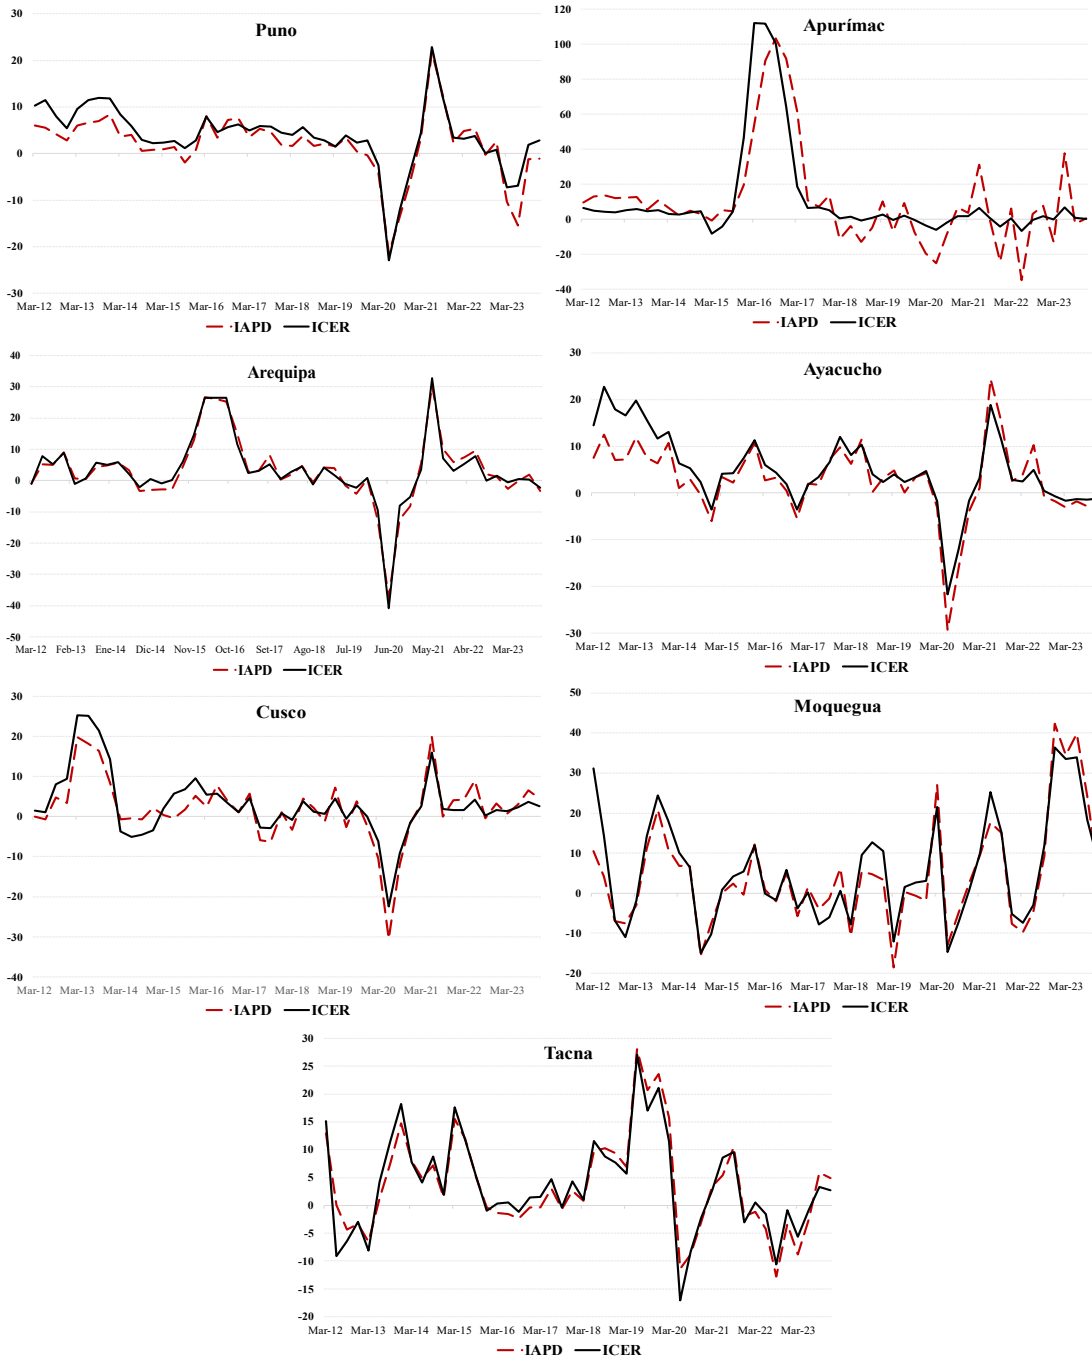
Fuente: INEI. Elaboración propia.

IAPD e ICER: Zona Norte (Var. % a/a)



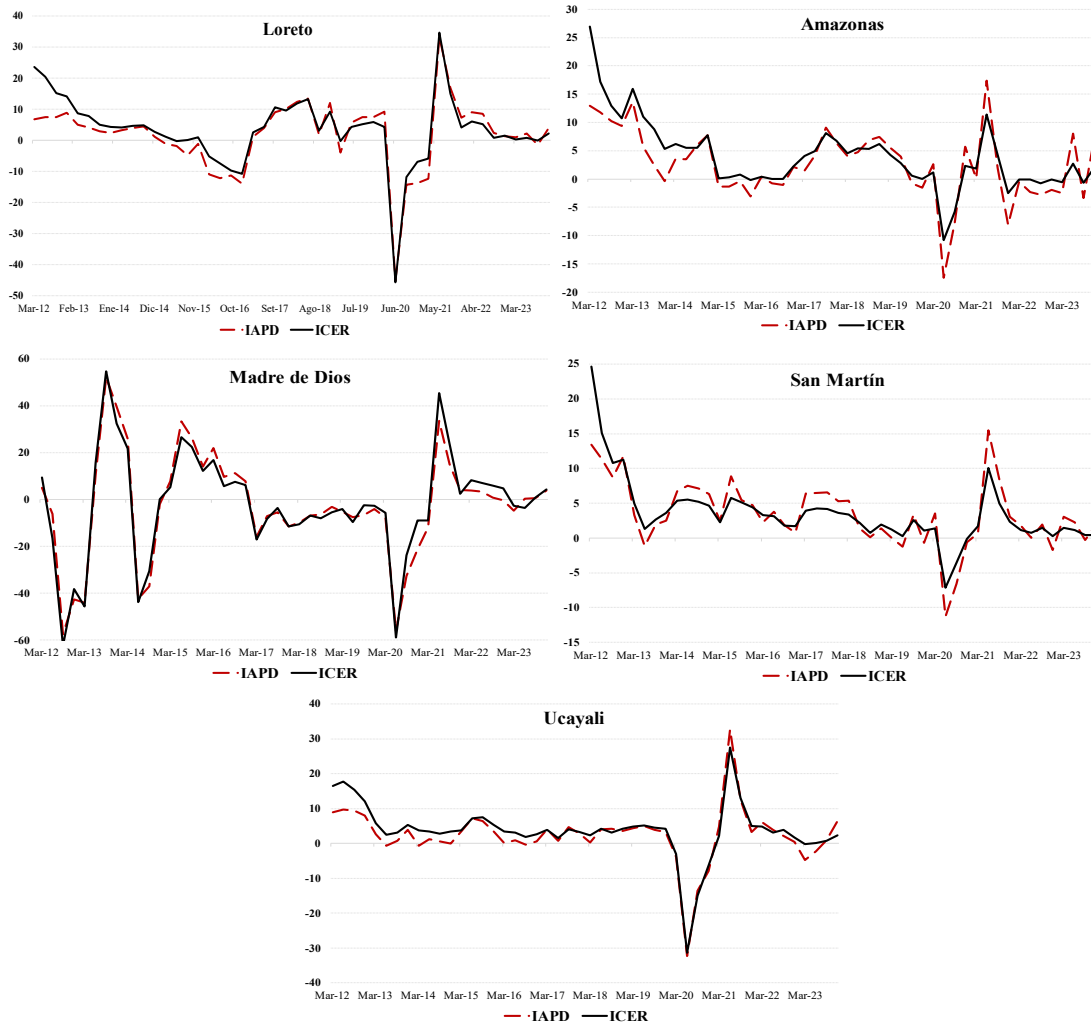
Fuente: INEI. Elaboración propia.

IAPD e ICER: Zona Sur (Var. % a/a)



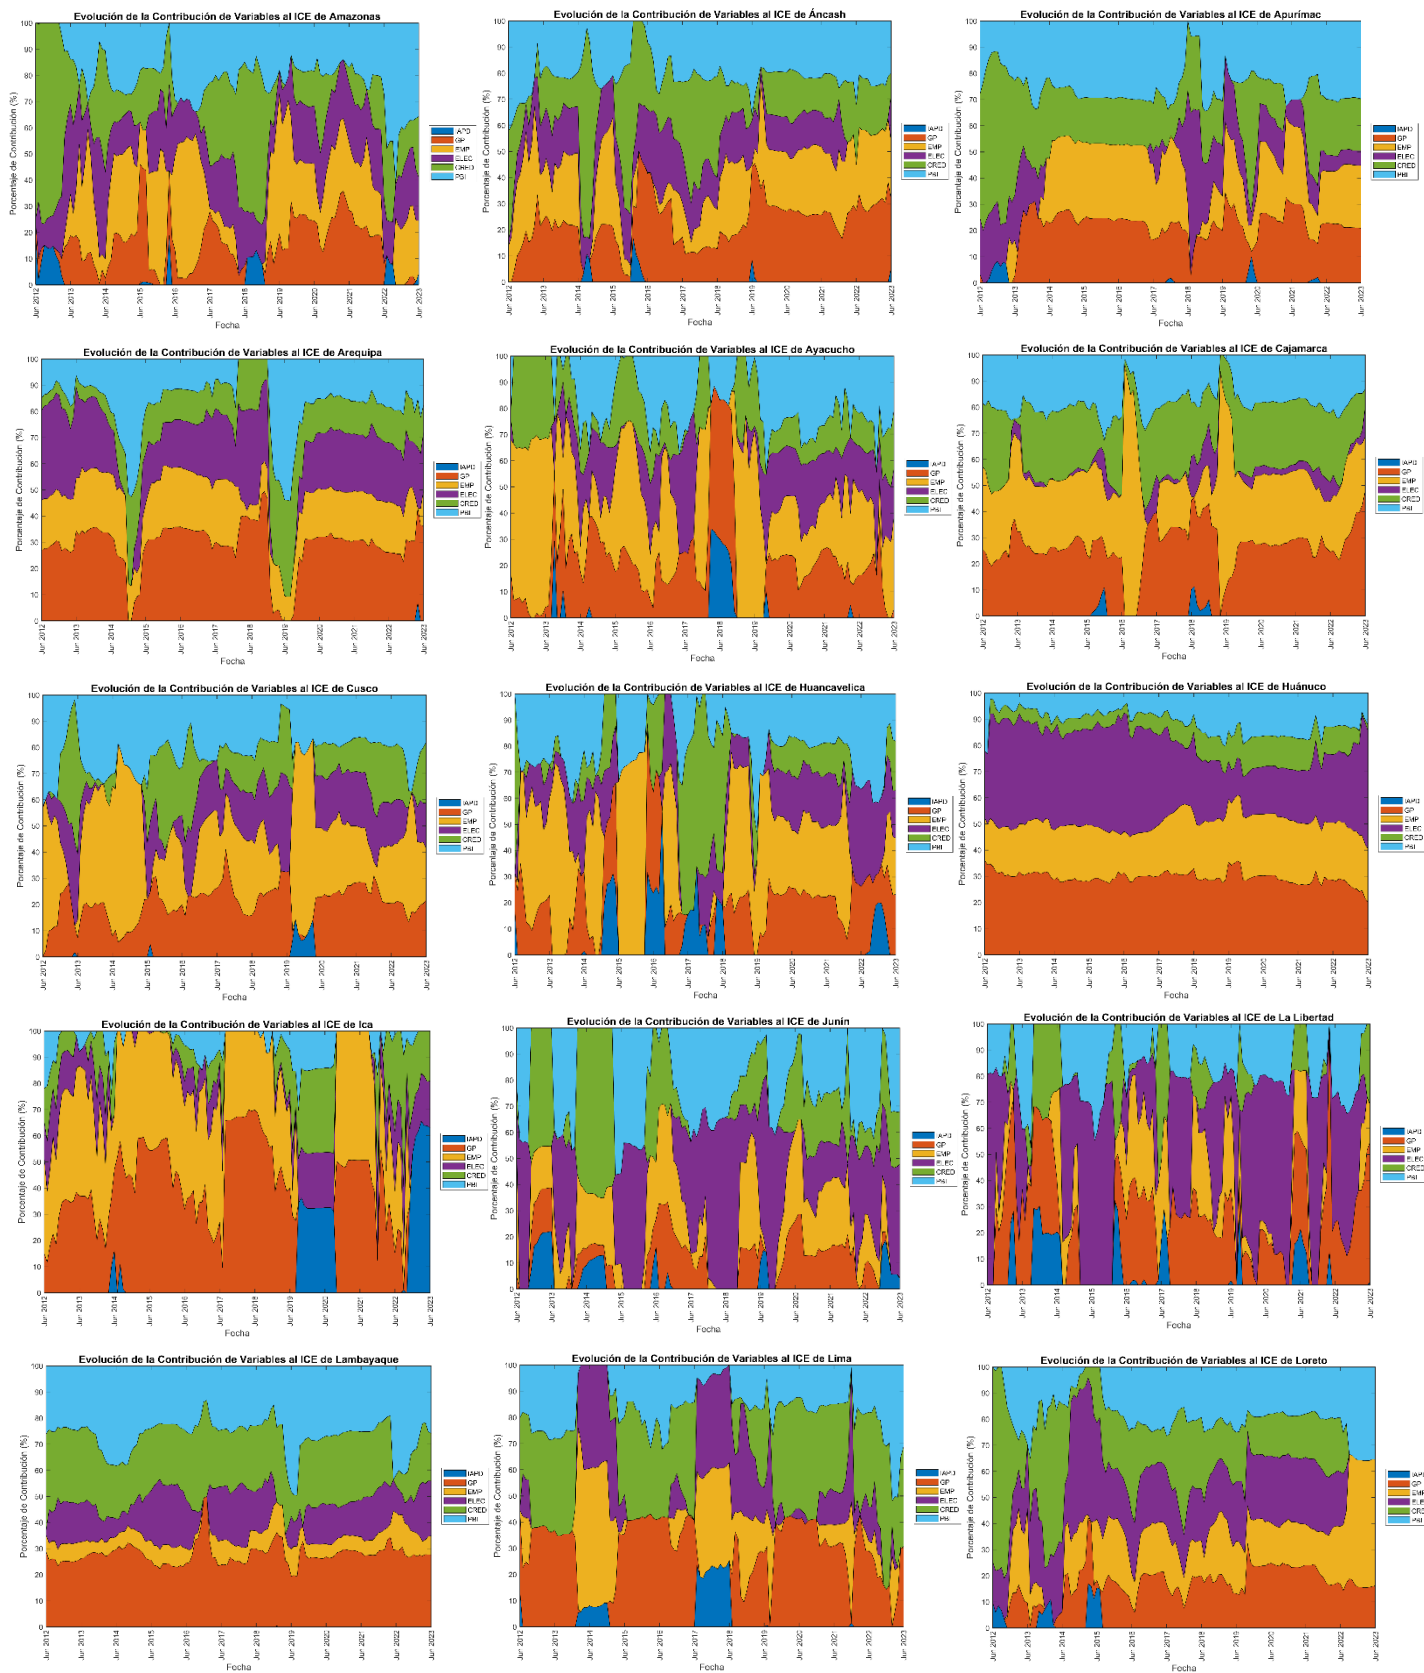
Fuente: INEI. Elaboración propia.

IAPD e ICER: Zona Oriente (Var. % a/a)

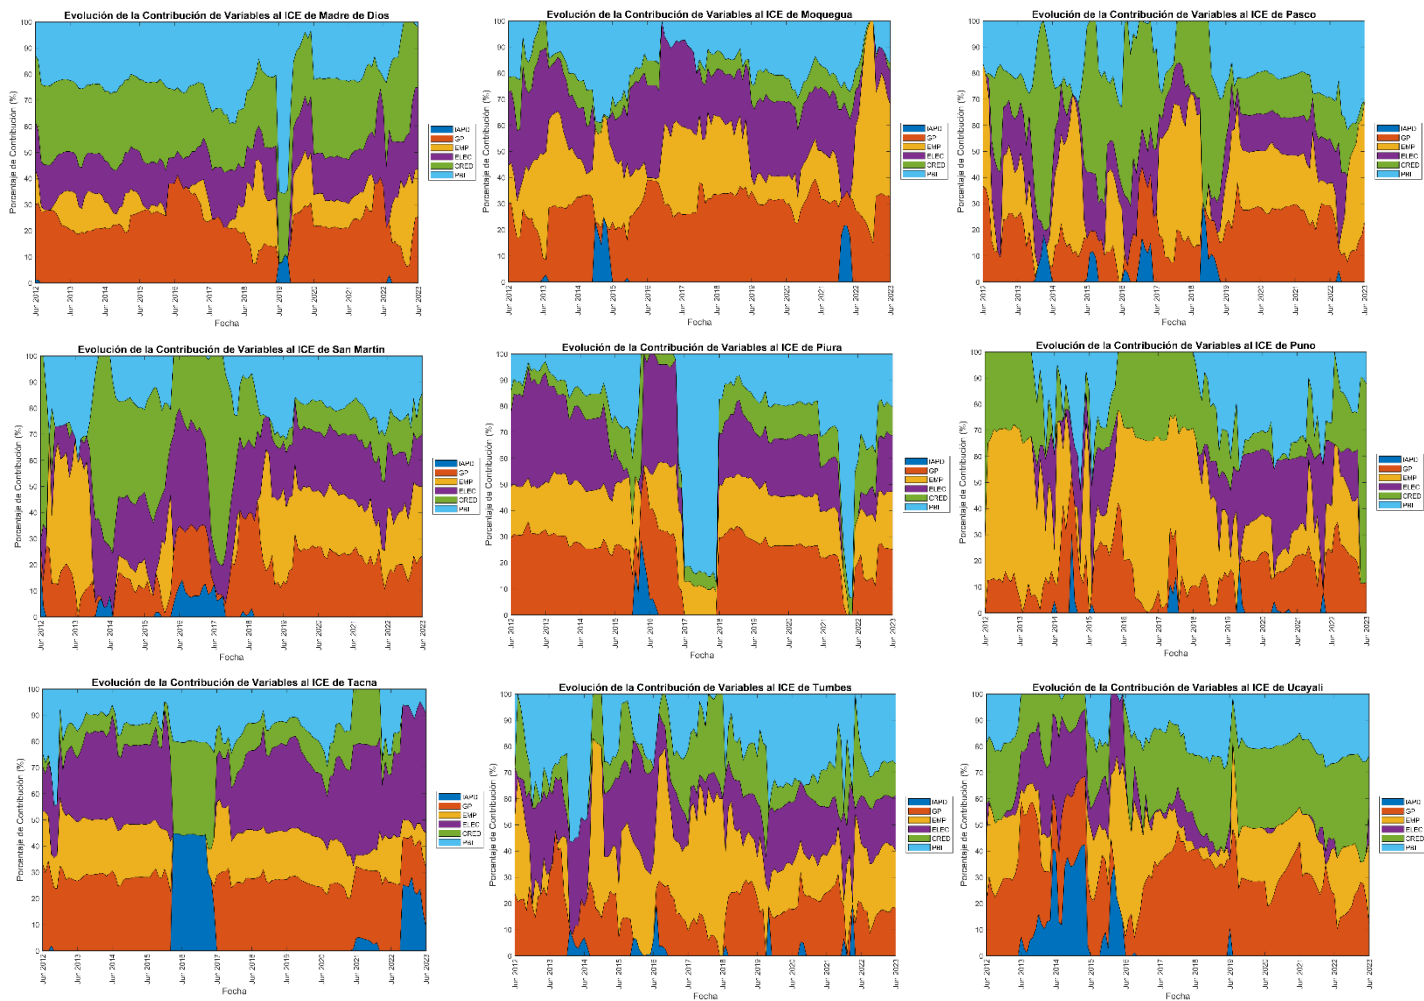


Fuente: INEI. Elaboración propia.

E. Evolución de la contribución de variables al ICE de cada región



Fuente: INEI, MEF, BCRP, OSINERGMIN y SBS. Elaboración propia.



Fuente: INEI, MEF, BCRP, OSINERGMIN y SBS. Elaboración propia