



Generalitat de Catalunya
Institut d'Estadística de Catalunya

Métodos de nowcasting para la estimación del PIB: una aplicación para la economía catalana

Mònica Gasulla, Jonatan Jorba, Jesús Muñoz, Sergi Plaza

22 de setiembre de 2016

CONTENIDOS

- **INTRODUCCIÓN**
- **MODELO FACTORIAL DINÁMICO:**
 - **PREPROCESAMIENTO**
 - **ANÁLISIS**
 - **ESTIMACIÓN DEL MODELO FACTORIAL DINÁMICO**
 - **NOWCASTING**
- **RESULTADOS**
- **CONCLUSIONES**

INTRODUCCIÓN

El **Producto Interior Bruto (PIB)** es el indicador sintético más reconocido internacionalmente para evaluar la situación económica de un territorio.

La **elaboración del PIB** por parte de los institutos de estadística oficial debe conciliar dos objetivos aparentemente contrapuestos:

- La necesidad de generar estimaciones de calidad a partir de la información disponible.
- Satisfacer una demanda creciente para proporcionar estadísticas con el mínimo retraso.

La falta de estimaciones de calidad derivadas del retraso en las mismas puede generar **errores de diagnóstico** y también en el diseño e implementación de las políticas económicas y monetaria.

Las **estimaciones del PIB flash** tienen por finalidad conciliar ambos objetivos para obtener resultados metodológicamente sólidos y reducir simultáneamente la plazos de disponibilidad respecto de los vigentes actualmente.

INTRODUCCIÓN

Estimaciones del PIB trimestral de Eurostat	Protocolo actual	Objetivo
Avance del PIB (PIB flash)	t+45 días	t+30 días
PIB oferta y demanda (precios corrientes y en volumen)	t+60 días	t+60 días

El objetivo declarado de Eurostat es recortar el período de disponibilidad del PIB flash en la UE y pasar de t+45 días a t+30 días. Este objetivo permite la homogeneización con las estadísticas equivalentes de los EEUU.

INTRODUCCIÓN

Para alcanzar el objetivo de estimación del PIB flash, Eurostat ha impulsado diversos **trabajos metodológicos** en relación a este tema, constatándose una **gran variedad** entre los estados miembros, y que se pueden clasificar en dos grandes grupos:

Métodos directos:

Modelos autorregresivos (ADL y VAR)
Modelos factoriales dinámicos (DFM)
Modelos puente (bridge models)

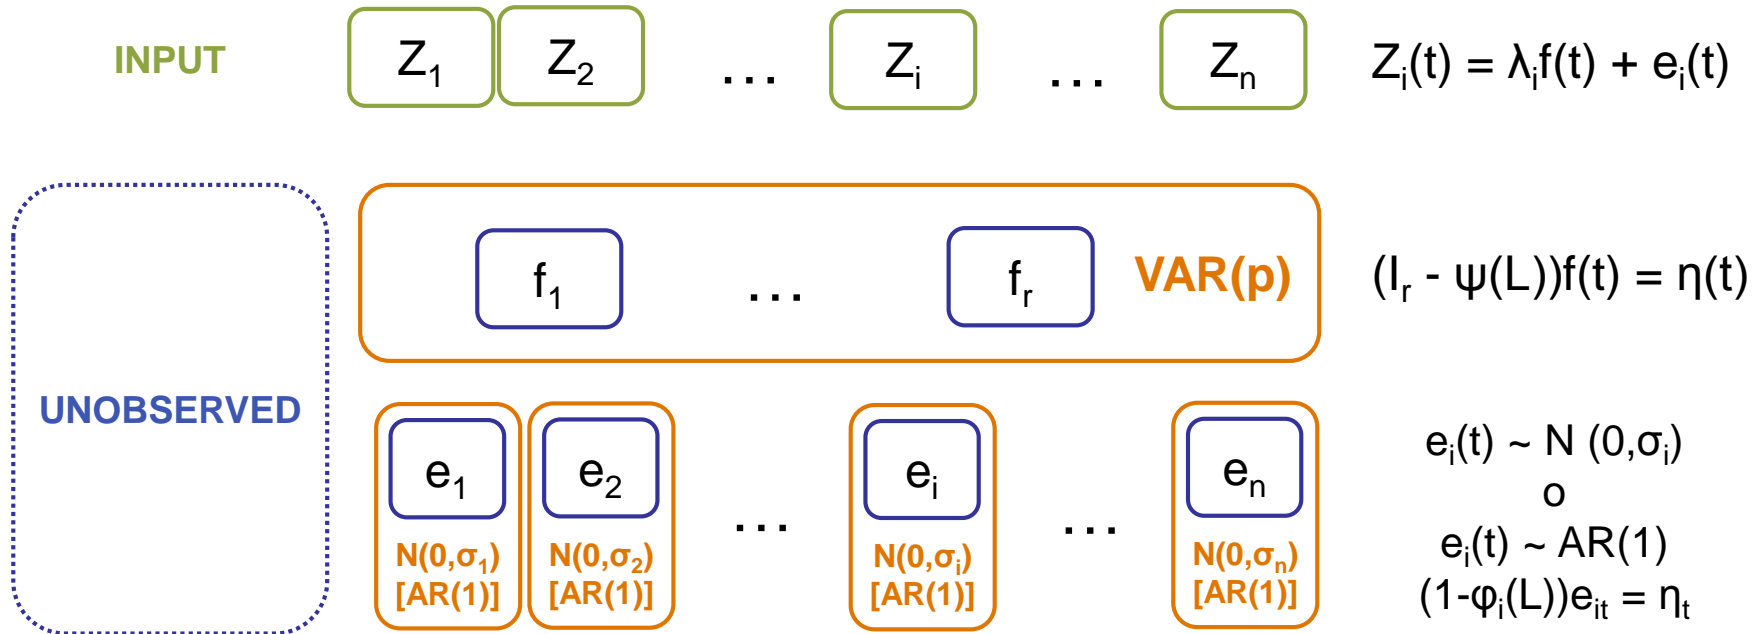
Métodos indirectos:

Modelo de Denton
Modelos Chow Lin
Modelos multivariados (multivariate models)

Idescat, a partir de la experiencia de las Reservas Federales de Atlanta y de Nueva York y de la AIREF en España **ha optado por desarrollar la metodología DFM** dada la solidez, congruencia y capacidad predictiva de los resultados publicados.

MODELO FACTORIAL DINÁMICO (DFM)

Dado un período t , $t=1, \dots, T$, el valor del indicador estacionario $Z_i(t)$ se obtiene como combinación lineal de un conjunto de factores comunes $(f_1(t), \dots, f_r(t))$ con una estructura VAR(p) y un término idiosincrásico e_{it} generado por un ruido blanco o un proceso AR(1)



Versión estática del modelo: $Z_{it} = \lambda_i f_t + e_{it}$ $i=1, \dots, n$
 $t=1, \dots, T$


MODELO FACTORIAL DINÁMICO (DFM)

Retos para los DFM:

- Diferencias en las fechas de inicio →
- Diferentes calendarios de publicación →
- Frecuencias mixtas →

ALGORITMOS ITERATIVOS (EM)
IMPUTACIÓN
FILTRO DE KALMAN

DESAGREGACIÓN TEMPORAL



MODELO FACTORIAL DINÁMICO (DFM)

ALGORITMO EM: estimación de factores y parámetros con datos faltantes

ESTIMACIÓN Fed

Dataset inicial + Imputación inicial

ESTIMACIÓN AIReF

Dataset inicial sin valores faltantes

Estimación estática de factores

Imputación del dataset original mediante regresiones factor-indicador

Estimación estática de factores

Estimación de Λ mediante regresión sobre dataset original

Estimación de Λ mediante regresión sobre dataset imputado

Estimación de ψ (y φ_i) mediante autoregresión
Filtro de Kalman:

- Estimación y proyección de factores
- Evaluación verosimilitud

ITERACIÓN HASTA ESTABILIZAR VEROSIMILITUD

PREPROCESAMIENTO DE INDICADORES



Transformaciones para obtener un conjunto desestacionalizado y estandarizado de indicadores mensuales estacionarios.



PREPROCESAMIENTO DE INDICADORES

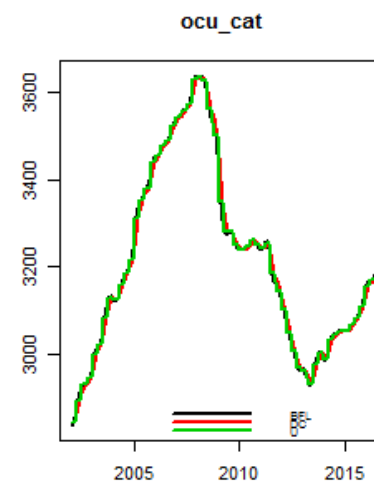
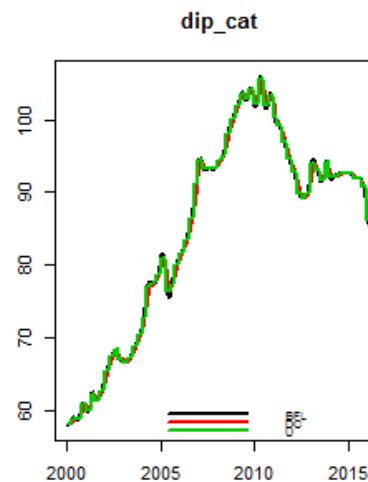

AJUSTE ESTACIONAL

Sin filtro de outliers
Con filtro de outliers

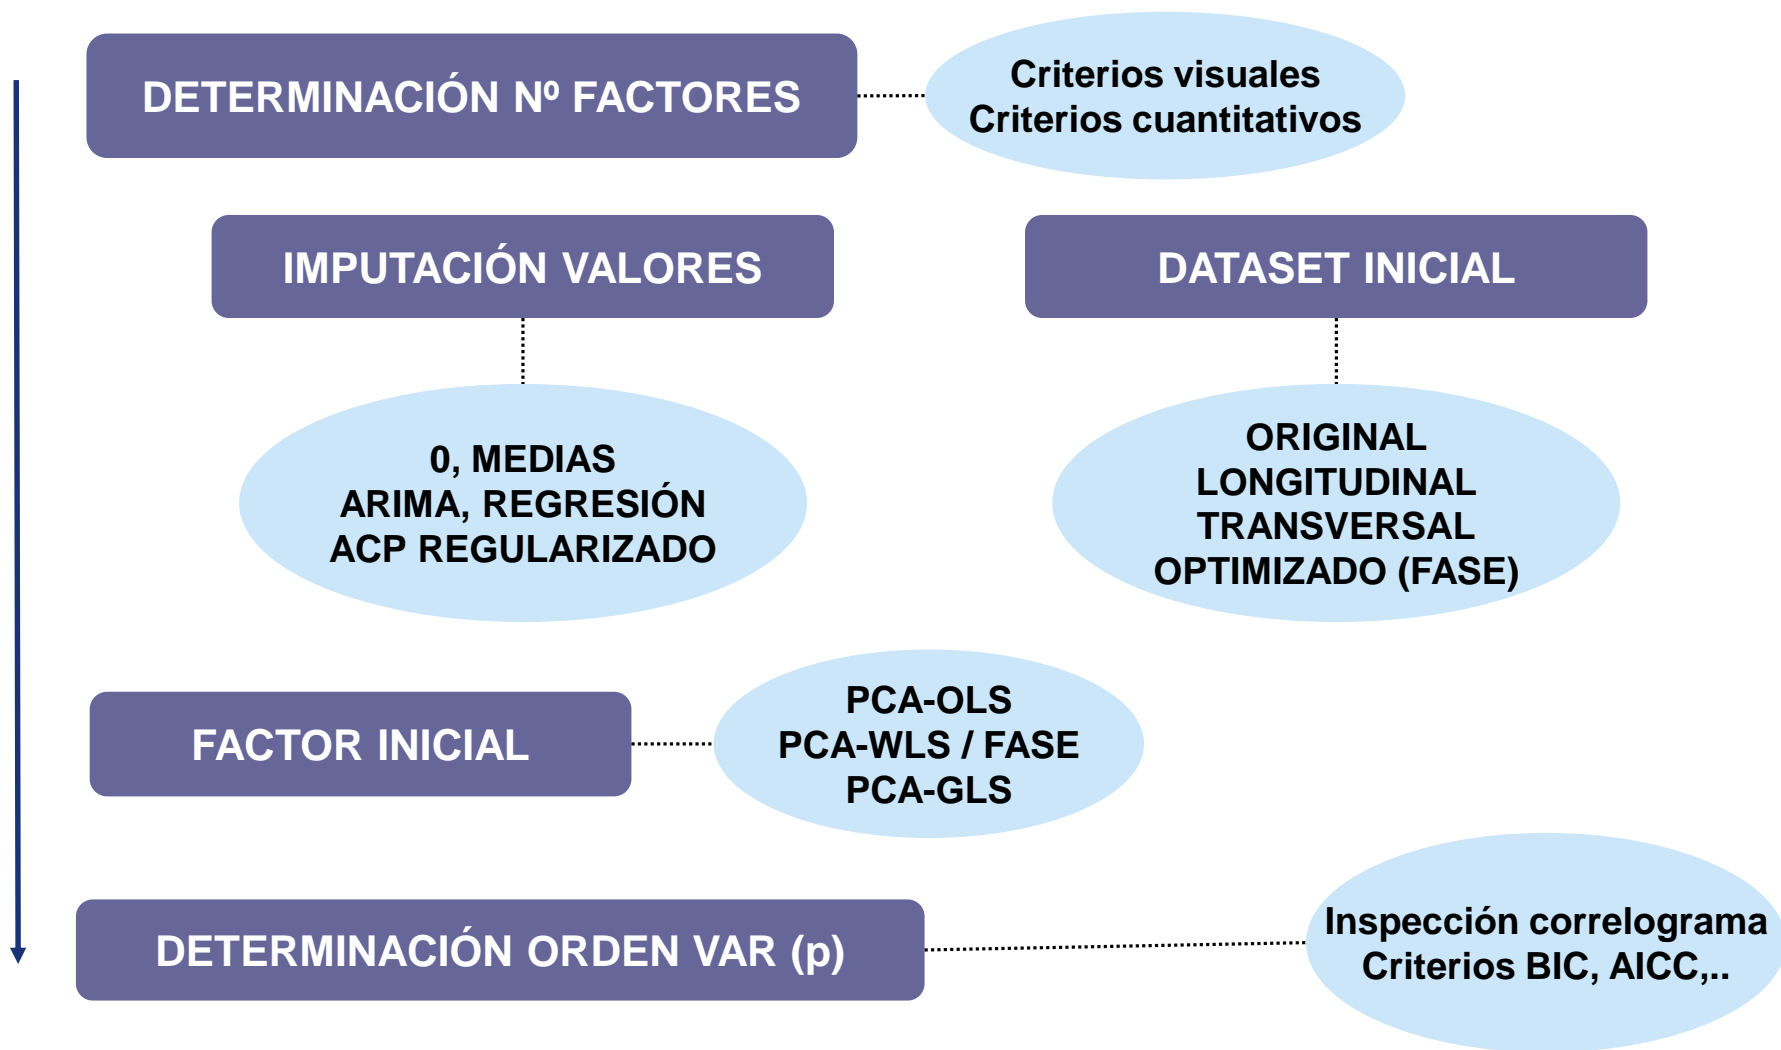


MENSUALIZACIÓN

Boot, Feibes & Lisman
Denton-Cholette
Uniforme



ANÁLISIS PRELIMINAR




ANÁLISIS PRELIMINAR


DETERMINACIÓN DE FACTORES

CRITERIOS GRÁFICOS
SCREEPLOT
SUCESIÓN DE TRANSVERSALES

SCREE PLOT - ALL



FIRST 4 EIGENVALUES

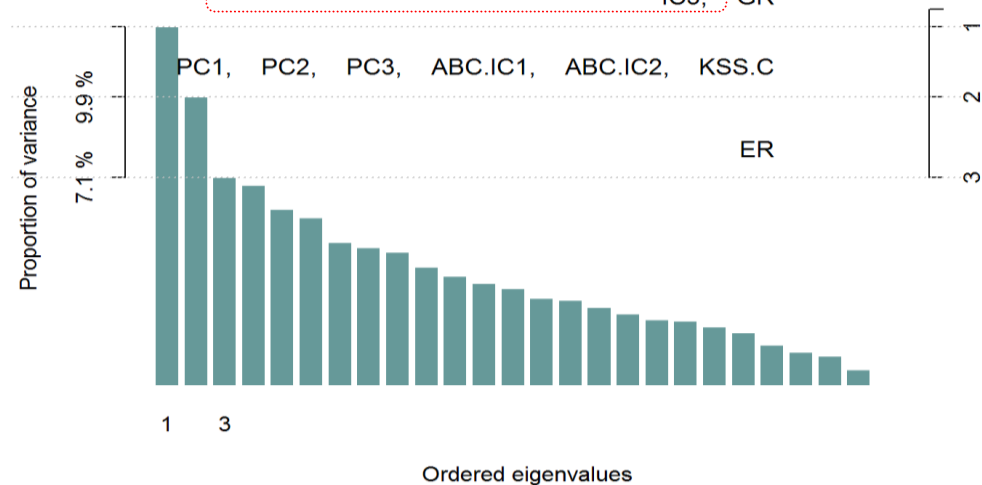


Cross section dimension

CRITERIOS CUANTITATIVOS
BIC3,
IC1, IC2, IC3,
IPC1, IPC2 e IPC3
de Bai & Ng

1 factor/s reg 0.5

BIC3, IC1, IC2, IPC1, IPC2, IPC3, ED, GR




ANÁLISIS PRELIMINAR


DATASET INICIAL

ORIGINAL
TRANSVERSAL
LONGITUDINAL
OPTIMIZADO (AIReF)


CAT 24




CROSS-SECTION 80 %



LONG 99 %



CAT 24 FASE




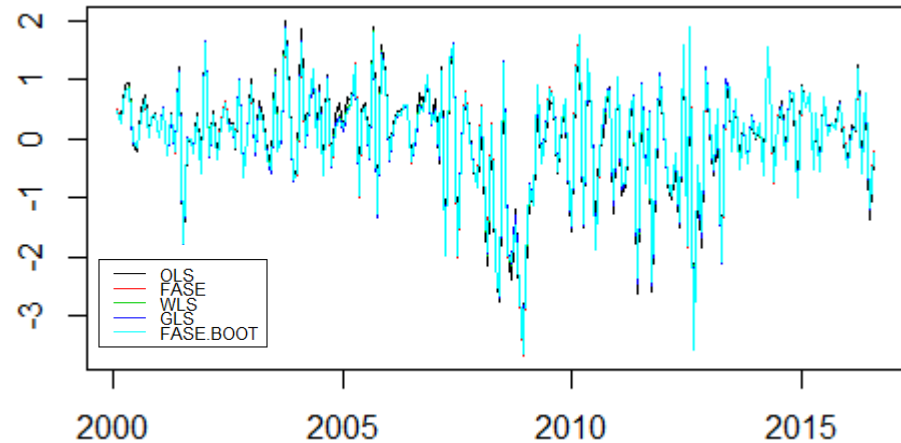
ANÁLISIS PRELIMINAR

ESTIMACIÓN INICIAL

MODELOS ESTÁTICOS
ACP-OLS
ACP-WLS
ACP-GLS

DETERMINACIÓN DE p

INSPECCIÓN VISUAL
BIC



```
$wls
```

```
Call:
ar.ols(x = scale(f.object$factor), demean = F)
```

```
Coefficients:
```

```
      1      2      3      4
-0.1889  0.2717  0.4398  0.2220
```

```
Order selected 4  sigma^2 estimated as  0.6607
```

ESTIMACIÓN DFM



ESTIMACIÓN DFM

MODELO FACTORIAL DINÁMICO

$$Z_{it} = \lambda_i f_t + e_{it}$$

$$(I_r - \psi(L))f_t = \eta_t$$

$$(1 - \varphi_i L) e_{it} = u_t$$

ESPACIO DE ESTADOS

$$Z_{it} = HX_t + W_t \quad \text{Eq de medida}$$

$$X_t = GX_{t-1} + V_t \quad \text{Eq de transición}$$

$$W_t \sim N(0, R) \quad V_t \sim N(0, Q)$$

FACTORES IDIOSINCRÁSICOS $N(0, \sigma^2)$

Nº de estados = p

Matriz de transición $p \times p$

FACTORES IDIOSINCRÁSICOS AR(1)

Nº de estados = p+n

Matriz de transición $(p+n) \times (p+n)$

$$X_t = (f_t, f_{t-1}, \dots, f_{t-p+1})$$

$$W_t = (e_{1t}, e_{2t}, \dots, e_{nt})$$

$$H = (\lambda_1, \lambda_2, \dots, \lambda_n) = \Lambda = \text{matriz de cargas}$$

$$G = \text{matriz basada en } \psi$$

$$V_t = \text{shocks del modelo VAR}(p)$$

$$X_t = (f_t, f_{t-1}, \dots, f_{t-p+1}, e_1, e_2, \dots, e_n)$$

$$W_t = 0_n$$

$$H = (\Lambda \ 0_n \ I_n)$$

$$G = \text{matriz basada en } \psi \text{ y } \varphi_i$$

$$V_t = \text{shocks del VAR}(p) \text{ y los AR}(1)$$

GENERACIÓN DE NOWCASTINGS

PIB en DFM

$$PIB_t^* = \lambda_{PIB^*} f_t + e_{PIB_t^*} \quad PIB^* = PIB \text{ transformado}$$

Relación simple, deshacer transformaciones!

MODELO ADL

PIB en función de sus retardos y los de factores

$$PIB_t = a + b_1 f_t + b_2 f_{t-1} + b_3 PIB_{t-1} + u_t$$

PIB externo

FUNCIÓN TRANSFERENCIA

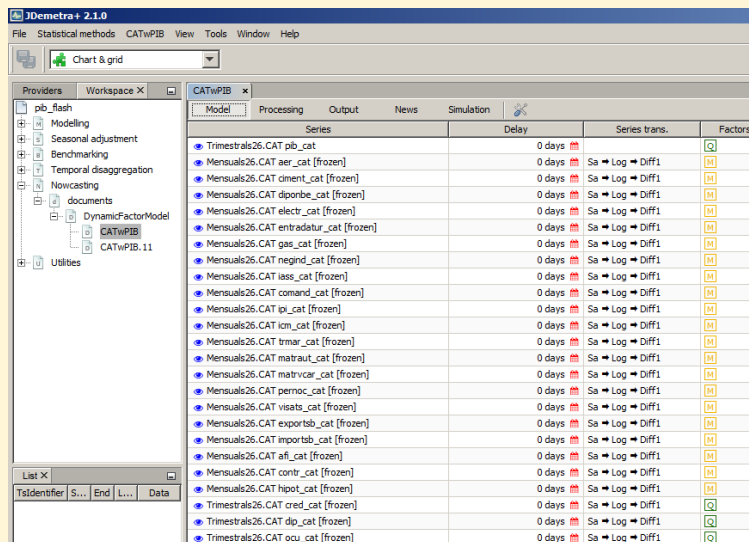
PIB en función de sus retardos y shocks + retardos y shocks de factores

$$PIB_t = c + \frac{\omega_s(L)L^d}{1 - \delta_r(L)} f_t + \frac{\theta_q(L)}{\varphi_p(L)} u_t$$

HERRAMIENTAS

CON INTERFAZ GRAFICA

JDemetra+ para metodología
Fed con factores idiosincráticos
 $N(0, \sigma)$



SIN INTERFAZ GRAFICA

R para todos los modelos

Implementación de matrices
variables en el tiempo
complicada.


Paquetes: interfaz JDemetra+/R,
forecast, missMDA, phtt, MTS,
tempdisagg, signal, KFAS, nlme,
Amelia, ...

Posibilidad de generar interfaz
gráfica con Shiny

RESULTADOS

- 24 INDICADORES
- 1 FACTOR, $p = 4$
- ENERO 2000 - AGOSTO 2016
- 200 OBSERVACIONES MENSUALES


CAT 24




VARIABLE	ANY.INI	MES.INI	FRECUENCIA	TIPUS	ESTOC	ON	M1	M2	M3
aer_cat	2000	1	12	0	0	1	-18	13	43
ciment_cat	2000	1	12	0	0	1	-14	17	48
diponbe_cat	2000	1	12	0	0	1	-15	16	46
electr_cat	2000	1	12	0	0	1	-19	14	46
entradatur_cat	2000	1	12	0	0	1	-5	27	57
gas_cat	2000	1	12	0	0	1	-21	10	40
negind_cat	2002	1	12	0	0	1	-14	15	48
iass_cat	2005	1	12	0	0	1	-14	15	48
comand_cat	2002	1	12	0	0	1	-14	15	48
ipi_cat	2002	1	12	0	0	1	-26	3	34
icm_cat	2005	1	12	0	0	1	-6	27	56
trmar_cat	2000	1	12	0	0	1	-31	0	30
matraut_cat	2000	1	12	0	0	1	-19	12	42
matrvcar_cat	2000	1	12	0	0	1	-19	10	42
pernoc_cat	2000	1	12	0	0	1	-12	20	50
visats_cat	2000	2	12	1	0	1	-5	24	57
exportsb_cat	2000	1	12	0	0	1	-15	16	46
importsb_cat	2000	1	12	0	0	1	-15	16	46
afi_cat	2000	1	12	0	0	1	-30	-1	29
contr_cat	2000	1	12	0	0	1	-32	-2	28
hipot_cat	2003	1	12	0	0	1	-7	24	54
cred_cat	2000	1	4	0	1	1			45
dip_cat	2000	1	4	0	1	1			45
ocu_cat	2002	1	4	0	1	1			-6
pib_cat	2000	1	4	0	1	1			43

RESULTADOS


A. FACTOR with WN idio




A. FACTOR with AR(1) idio



B. FACTOR with WN idio



B. FACTOR with AR(1) idio




RESULTADOS

- Simulación año 2016
- Primeros resultados provisionales
- RMSE 2014-2016


Fed, AR	OA	NOA	AIReF, AR	OA	NOA
KF	0.7607	0.760865	KF	0.761024	0.761039
KS	0.7609044	0.760486	KS	0.761983	0.761854

Fed, WN	OA	NOA	AIReF, WN	OA	NOA
KF	0.76116	0.7611596	KF	0.760909	0.7609691
KS	0.761347	0.761093	KS	0.762122	0.7617329

2016Q1



2016Q2



RESULTADOS: LÍNEAS DE TRABAJO FUTURAS

Los resultados presentados hasta el momento son todavía **provisionales**

Se plantean las siguientes **líneas de trabajo**:

- **Evaluación del conjunto de indicadores** a considerar en los diferentes modelos empleados para la estimación del PIB flash
- **Calibración de los resultados** simulados con los obtenidos en modelos alternativos
- **Diseño y desarrollo de modelos más complejos** que ajusten la presencia de heteroscedasticidad (modelos markovianos de cambio de régimen)

CONCLUSIONES

- El desarrollo de una metodología de estimación del PIB flash por medio de modelos factoriales dinámicos permite **obtener previsiones robustas del PIB de la economía catalana en plazos más ajustados** a la disponibilidad de la información estadística de referencia
- La propia construcción el método empleado permite **generalizar la obtención de los resultados a otras frecuencias temporales** y, por lo tanto, calibrar el modelo a tiempo real
- El proceso de validación y selección de indicadores de actividad para su incorporación al modelo factorial dinámico permite determinar su **relevancia como medidas subyacentes de la actividad económica**

REFERENCIAS Y ENLACES DE INTERÉS

▪ ESTADO DEL ARTE

- Eurostat (2016). Overview of GDP flash estimation methods.
- Stock, J. H., & Watson, M. W. (2010). Dynamic Factor Models.
- Stock, J. H., & Watson, M. W. (2016). Factor Models and Structural Vector Autoregressions in Macroeconomics.
- Reichlin, L., Giannone, D., Banbura, M., Modugno, M. (2013). Now-Casting and the Real-Time Data-Flow.

▪ AIReF

- Cuevas A, Quilis E (2009) A factor analysis for the Spanish economy (FASE). Mimemo, Ministerio de Economía y Hacienda, Madrid

REFERENCIAS Y ENLACES DE INTERÉS

▪ FED/ECB

- Banbura & Modugno, 2010, "Maximum Likelihood Estimation of Factor Models on Data Sets with Arbitrary Pattern of Missing Data" Working Paper Series 1189, European Central Bank
- Doz C, Giannone D, Reichlin L, (2009) A two-step estimator for large approximate dynamic factor models based on Kalman filtering.
- Giannone D, Reichlin L, Small D (2008) Nowcasting: the real-time informational content of macroeconomic data. J Monet Econ 55:665–676.

JDEMETRA+

Repositorio JDemetra+ en Github

<https://github.com/jdemetra/jdemetra-app/releases>

Manual y documentación JDemetra+

https://ec.europa.eu/eurostat/cros/content/documentation_en

Interfaz R/JDemetra+

<https://github.com/nbbird/jdemetra-R>

Pluggin "Nowcasting" de JDemetra+

<https://github.com/nbbird/jdemetra-nowcasting/releases>