

Previsão do PIB através de uma abordagem *bottom-up* num contexto rico em informação

Francisco Dias
Banco de Portugal

Maximiano Pinheiro
Banco de Portugal

António Rua
Banco de Portugal

Julho 2016

Resumo

Num contexto em que o conjunto de informação estatística é cada vez mais extenso, a utilização de modelos de fatores para previsão tem vindo a ganhar um papel proeminente quer na literatura quer num âmbito mais operacional. Neste artigo, no seguimento do trabalho desenvolvido por Dias, Pinheiro e Rua (2015), pretende-se avaliar o desempenho de modelos de fatores para a previsão das diferentes componentes do PIB e aferir a utilidade de uma abordagem *bottom-up* para a previsão do crescimento do PIB em Portugal. Os resultados obtidos reforçam a utilidade dos modelos de fatores para efeitos de previsão e registam-se ganhos significativos com a prossecução de uma abordagem *bottom-up* baseada nos principais agregados do PIB. (JEL: C22, C53)

Introdução

Nas últimas décadas, o conjunto de dados económicos à disposição dos decisores de política económica aumentou consideravelmente devido ao desenvolvimento generalizado dos sistemas estatísticos. Naturalmente, os agentes económicos e, em particular, as organizações internacionais e os bancos centrais, como prática geral, acompanham estes vastos conjuntos de informação com vista a avaliar a evolução económica em curso e formular políticas económicas adequadas. Perante tal riqueza de informação, a abordagem a este tipo de conjuntos de informação, que podem incluir centenas de séries, coloca naturalmente desafios metodológicos em termos de modelação econométrica.

De facto, a utilização de modelos de fatores para efeitos de previsão tornou-se uma ferramenta cada vez mais generalizada para prever variáveis macroeconómicas num ambiente rico em informação. Ver, por exemplo, Stock e Watson (1998, 2002a,b) e Giannone *et al.* (2008) para o caso dos Estados Unidos, Marcellino *et al.* (2003) e Angelini *et al.* (2011) para a área do euro, Artis *et al.* (2005) para o Reino Unido, Schumacher (2007, 2010, 2011) no caso

da Alemanha, Barhoumi *et al.* (2010) para a França, de Winter (2011) e Reijer (2013) para os Países Baixos, e para um estudo envolvendo vários países europeus ver Rünstler *et al.* (2009).

Os modelos de fatores são concebidos para reduzir a dimensão do número de séries em conjuntos de dados alargados para uma escala manuseável, permitindo ultrapassar o problema da elevada dimensionalidade. Essencialmente, estes modelos permitem condensar o conteúdo informativo de bases de dados vastas num número reduzido de variáveis não observadas, designadas por fatores comuns, que captam uma fração considerável dos co-movimentos existentes no conjunto das séries. Assim, esses fatores contemplam de forma parcimoniosa as características dominantes na dinâmica da base dados e, por isso, são incluídos como regressores em modelos de previsão em vez das variáveis originais.

Contudo, a parte da informação que não é captada pelo pequeno conjunto de fatores estimados não é considerada para efeitos de previsão. Tal procedimento pode desperdiçar informação potencialmente relevante para a variável a ser prevista ou para o horizonte de previsão em consideração.

Para ultrapassar esta potencial limitação, Dias *et al.* (2010) propuseram um procedimento alternativo. Nomeadamente, foi sugerido o cálculo de um *Targeted Diffusion Index*, que no seu cálculo leva em conta não só todos os fatores da base de dados, mas também o seu conteúdo informativo para a variável a ser prevista e respetivo horizonte de previsão. Este índice é uma média ponderada dupla de todos os fatores que considera tanto o poder explicativo de cada fator para a variável a ser prevista bem como a importância relativa do fator em captar os co-movimentos das séries na base de dados. Num estudo empírico para os Estados Unidos, esta abordagem permitiu obter um desempenho superior ao do modelo de fatores tradicional na previsão de várias variáveis macroeconómicas. Além disso, este método também foi recentemente aplicado por Dias *et al.* (2015) para a previsão de crescimento do PIB para Portugal proporcionando resultados encorajadores.

Neste artigo, estende-se o trabalho de Dias *et al.* (2015) avaliando a utilidade dos modelos de fatores acima mencionados para prever as diversas componentes do PIB.

Tipicamente, são apontadas duas razões principais para motivar a importância dessa avaliação. Em primeiro lugar, a previsão das diferentes componentes facilita a compreensão da previsão do respetivo agregado. De facto, em muitas instituições, tais como em bancos centrais, é crucial ter uma perceção completa dos desenvolvimentos macroeconómicos subjacentes de modo a potenciar a formulação de políticas económicas adequadas.

Em segundo lugar, existe o tradicional debate na literatura sobre se se deve prever uma variável agregada diretamente ou indiretamente através da agregação das previsões das suas componentes. Em particular, a qualidade das previsões obtidas prevendo diretamente o agregado de interesse é comparada com a alcançada por meio de uma abordagem *bottom-up*. Artigos

empíricos nesta linha inclui Fair e Shiller (1990) para o PNB nos Estados Unidos, Zellner e Tobias (2000) para o crescimento do PIB em países industrializados, Marcellino *et al.* (2003) para vários agregados da área do euro, Hubrich (2005) e Duarte e Rua (2007) para a inflação na área do euro e em Portugal, Esteves (2013) para o PIB da área do euro, entre outros.

Do ponto de vista teórico, se o processo gerador de dados for conhecido para todas as componentes, então, a previsão obtida pela agregação das previsões das componentes domina em termos de desempenho (ver, por exemplo, Rose (1977), Tiao e Guttman (1980), Kohn (1982) e Lütkepohl (1984)). No entanto, na prática, os processos geradores de dados não são conhecidos *a priori*, e por isso é necessário proceder à sua especificação e estimação. Assim sendo, a superioridade da abordagem *bottom-up* não é garantida à partida (ver Lütkepohl, 1984) resumindo-se a uma questão empírica.

Neste artigo, procede-se à avaliação do desempenho relativo, em termos de previsão, de modelos de fatores para prever cada componente do PIB. Com as previsões das diferentes componentes do PIB, torna-se possível avaliar se através de uma abordagem *bottom-up* é possível obter ganhos para a previsão de crescimento do PIB.

Breve resumo de modelos de fatores

Os modelos de fatores foram inicialmente desenvolvidos no final da década de setenta e início da década de oitenta por Geweke (1977), Sargent e Sims (1977) e Geweke e Singleton (1981). Contudo, as aplicações empíricas desses modelos até o início da década de noventa estavam confinadas a um conjunto reduzido de variáveis.

Stock e Watson (1998, 2002a,b) e Forni *et al.* (2000, 2001, 2004, 2005) contribuíram em larga medida para esta literatura possibilitando a aplicação dos modelos de fatores a conjuntos vastos de dados que podem conter centenas de séries. Em particular, James Stock e Mark Watson, no seu trabalho seminal, propuseram a utilização do método de componentes principais para estimar os fatores comuns na presença de um elevado número de variáveis. Devido à sua generalidade e simplicidade, rapidamente se tornou um método muito utilizado. Em particular, para o exercício de previsão será considerado o modelo de fatores na sua versão estática. Refira-se que a especificação do modelo de fatores na versão dinâmica pode ser sempre reescrita numa formulação equivalente com fatores estáticos (ver, por exemplo, Stock e Watson, 2005). Adicionalmente, como mencionado por Bai e Ng (2007), tal distinção não é relevante para efeitos de previsão.

Num contexto de modelo de fatores estáticos, o exercício de previsão compreende duas etapas. Num primeiro passo, que envolve a estimação dos fatores, a especificação do modelo assume que cada variável da base de dados resulta da soma de duas componentes: a primeira corresponde a uma

combinação linear de um pequeno conjunto de fatores estáticos latentes não observáveis, comum a todas as variáveis, e uma segunda componente de caráter idiossincrático que é específica a cada variável. Como referido anteriormente, foi proposto na literatura a estimação dos fatores comuns não observados recorrendo à técnica das componentes principais tendo sido demonstrado que tal procedimento permite a estimação consistente do espaço de fatores em condições bastante gerais.

As componentes principais são ordenadas de acordo com a sua importância relativa em termos da capacidade em captar a dinâmica comum do conjunto de dados. Tipicamente, as primeiras componentes principais captam uma parte importante dos co-movimentos entre as séries no conjunto da base de dados, e o número relevante de fatores a serem considerados no modelo de previsão na segunda etapa pode ser determinado com base num critério de informação (ver, por exemplo, Bai e Ng, 2002).

No segundo passo, a variável a ser prevista é projetada no conjunto de fatores obtido no passo anterior (o que corresponde ao denominado modelo *Diffusion Index* (DI)) e, possivelmente, em desfasamentos da variável dependente (designado por DI-AR). Neste contexto, independentemente da variável objeto de previsão, o mesmo conjunto de fatores é incluído na equação de previsão, *i.e.* a variável dependente não desempenha nenhum papel na seleção dos fatores a serem considerados na regressão.

Assim, todos os fatores que não os principais, identificados no primeiro passo, são descartados, independentemente do seu conteúdo informativo para a variável a ser prevista e correspondente horizonte de previsão, o que pode conduzir a uma perda de informação potencialmente útil. Nessas circunstâncias, o processo de modelação *standard* pode revelar-se limitativo para efeitos de previsão, uma vez que não leva em conta nem a variável específica a ser prevista nem o horizonte de previsão na seleção dos fatores a incluir na equação de previsão.

Para ultrapassar esta limitação, Dias *et al.* (2010) sugeriram a utilização de um *Targeted Diffusion Index* (TDI) no segundo passo em vez do conjunto de fatores acima mencionado. O TDI é uma combinação linear convexa de todos os fatores da base de dados, onde os ponderadores atribuídos a cada fator refletem não só a fração da variância total da base de dados captada pelo fator assim como a sua correlação com a variável a ser prevista no horizonte de previsão relevante. Assim, este procedimento leva em conta todos os fatores combinados num único índice refletindo simultaneamente a informação veiculada pela importância relativa dos fatores no espírito de Stock e Watson e o conteúdo informativo de cada fator para a variável a prever e respetivo horizonte de previsão.

Esta abordagem evita desperdiçar informação potencialmente relevante contida na base de dados e procura obter uma melhor correspondência entre os dados disponíveis e a variável a ser prevista. Dias *et al.* (2010) mostram que esta estratégia de modelação melhora substancialmente os resultados

da previsão *vis-à-vis* o modelo DI para diversas variáveis macroeconómicas referentes aos Estados Unidos enquanto Dias *et al.* (2015) obtiveram resultados assinaláveis para a previsão do crescimento de PIB para Portugal.

Previsão das componentes do PIB

Preliminares

Em relação ao conjunto de informação, recorreremos à base de dados considerada por Dias *et al.* (2015) para a economia Portuguesa e que inclui 126 séries na totalidade. A base de dados engloba quer informação de natureza qualitativa quer quantitativa e inclui inquéritos de opinião aos consumidores e às empresas (43 séries), volume de negócios no comércio a retalho (4 séries), produção industrial (7 séries), volume de negócios na indústria e serviços (20 séries), emprego, horas trabalhadas e índices de salários na indústria e serviços (24 séries), dormidas na hotelaria em Portugal (3 séries), vendas de automóveis (3 séries), vendas de cimento, ofertas de emprego e desemprego registado (5 séries), consumo de energia (3 séries), exportações e importações nominais de bens (10 séries), taxa de câmbio efetiva real, índice do mercado de ações para Portugal e uma série relativa a ATM/POS. Todas as séries são corrigidas de sazonalidade, e com exceção dos dados dos inquéritos qualitativos, foram consideradas em logaritmos. Como habitualmente, as séries foram diferenciadas.

Em relação ao PIB e suas componentes, as séries divulgadas pelo Instituto Nacional de Estatística (INE) estão disponíveis desde o primeiro trimestre de 1995 até ao quarto trimestre de 2015 corrigidas de sazonalidade e a preços constantes. Consideram-se as taxas de variação em cadeia trimestral e restringe-se a análise de previsão para o trimestre corrente (*nowcast*) e para o trimestre seguinte (previsão a um período de distância), uma vez que os ganhos obtidos com recurso aos modelos de fatores são relativamente diminutos para horizontes mais distantes (ver também Dias *et al.*, 2015).

O período de previsão fora da amostra estende-se desde o primeiro trimestre de 2002 até ao quarto trimestre de 2015. Este período de previsão fora da amostra relativamente longo permite testar de uma forma mais sistemática o desempenho relativo dos modelos concorrentes e possibilita ainda, a consideração de análise por sub-amostras. Em particular, foram consideradas duas sub-amostras: desde o primeiro trimestre de 2002 até ao quarto trimestre de 2007 e desde o primeiro trimestre de 2008 até ao quarto trimestre de 2015. Refira-se que a segunda sub-amostra corresponde a um período muito exigente sob qualquer perspetiva uma vez que a economia Portuguesa registou alterações macroeconómicas pronunciadas desde a última crise económica e financeira.

Como é habitual neste tipo de exercícios, considerou-se como modelo de referência (*benchmark*) o modelo autoregressivo univariado com a ordem de defasamento a ser determinada pelo critério de informação BIC em cada iteração do exercício recursivo e com amostra crescente. No caso do modelo DI, onde o número de fatores tem que ser determinado à priori, foram considerados quatro fatores tal como discutido extensivamente em Dias *et al.* (2015).

Reporta-se o Erro Quadrático Médio (EQM) das previsões para o modelo de referência e o EQM relativo para os modelos concorrentes, calculado como o rácio entre o EQM do modelo alternativo o EQM do modelo de referência. Assim, um EQM relativo inferior a um significa que o modelo concorrente supera o modelo de referência ao passo que se for superior a um, é o oposto. Finalmente, para avaliar a significância estatística dos ganhos de previsão em relação ao *benchmark* calculou-se o teste de Diebold e Mariano (1995) (nas tabelas *, **, *** representam a significância estatística a um nível de 10, 5 e 1 por cento, respetivamente).

Resultados

i) Consumo privado

Em primeiro lugar, analisam-se os resultados para o consumo privado como um todo (ver Quadro 1). Para todo o período de previsão fora da amostra, tanto o modelo DI como o TDI proporcionam desempenhos estatisticamente superiores para a previsão do trimestre corrente. Os ganhos *vis-à-vis* o modelo de referência são de 26 por cento e 37 por cento, respetivamente. Em termos de comportamento ao longo do período de avaliação, os ganhos são maiores na primeira sub-amostra atingindo 43 e 48 por cento, respetivamente. Ainda que os ganhos sejam menores na segunda parte da amostra, são mesmo assim bastante consideráveis, em particular, no caso do modelo TDI (33 por cento). Em suma, o modelo TDI apresenta sempre o menor EQM para qualquer período amostral em termos de *nowcast*.

Período fora da amostra	2002T1-2015T4		2002T1-2007T4		2008T1-2015T4	
	$h = 0$	$h = 1$	$h = 0$	$h = 1$	$h = 0$	$h = 1$
Total						
Modelo AR (EQM)	0,009	0,010	0,005	0,006	0,012	0,014
Modelo DI (EQM relativo)	0,74*	1,03	0,57**	1,48	0,80	0,89
Modelo TDI (EQM relativo)	0,63**	0,73	0,52*	0,95	0,67*	0,66
Duradouros						
Modelo AR (EQM)	0,389	0,380	0,225	0,236	0,511	0,488
Modelo DI (EQM relativo)	0,73	0,92	0,86	1,13	0,68	0,84***
Modelo TDI (EQM relativo)	0,61**	0,88	0,64	1,39	0,60*	0,69**
Não duradouros						
Modelo AR (EQM)	0,005	0,005	0,004	0,004	0,006	0,007
Modelo DI (EQM relativo)	0,88	1,16	0,42***	1,27	1,09	1,12
Modelo TDI (EQM relativo)	0,78	0,86	0,53**	0,71	0,89	0,91

QUADRO 1. Previsão do consumo privado

Para a previsão a um período de distância, como seria de esperar, os ganhos são menores. Em particular, o modelo DI não supera o modelo de referência, ao passo que o modelo TDI apresenta um ganho relativo de 27 por cento, embora estatisticamente não significativo. Neste caso, o desempenho preditivo é melhor na segunda parte da amostra para ambos os modelos com o modelo TDI a sobressair.

De seguida, procede-se à análise das componentes do consumo privado nomeadamente consumo de duradouros e não-duradouros. No caso do *nowcast* dos bens duradouros, os ganhos obtidos com os modelos DI e TDI são semelhantes aos registados para o consumo privado total. Enquanto o modelo DI parece ter um desempenho relativo melhor na segunda parte da amostra, o modelo TDI apresenta um desempenho estável ao longo do tempo. Para a previsão a um trimestre de distância, a precisão das previsões deteriora-se e os ganhos são substancialmente menores. Contudo, os ganhos na segunda parte da amostra são estatisticamente significativos.

Em relação ao consumo de não-duradouros, ambos os modelos DI e TDI superam o *benchmark* univariado no caso do *nowcast*. No entanto, os ganhos são inferiores aos acima relatados. Em termos do seu comportamento nas sub-amostras, ambos os modelos apresentam um desempenho melhor na primeira parte da amostra do que na segunda. Na previsão a período de distância, o modelo DI não supera o modelo de referência ao passo que o TDI é superior, mas não por muito.

Em suma, o modelo TDI apresenta melhor capacidade preditiva, seja para o agregado seja para qualquer uma das suas componentes. Os ganhos são notórios no caso do *nowcast* ao passo que para um período de distância

a melhoria é substancialmente inferior. Refira-se que estes resultados são relativamente robustos em termos de sub-amostras.

ii) Consumo público

No caso do consumo público, verifica-se que tanto o modelo DI como o TDI apresentam um melhor desempenho quando acrescidos de componentes auto-regressivas (denominadas como DI-AR e TDI-AR, respetivamente). Como se pode constatar do Quadro 2, o DI-AR não é capaz de superar o modelo auto-regressivo univariado simples no caso de *nowcast* ou na previsão a um período de distância. Além disso, este resultado mantém-se válido para qualquer uma das sub-amostras consideradas para efeitos de previsão.

Período fora da amostra	2002T1-2015T4		2002T1-2007T4		2008T1-2015T4	
	$h = 0$	$h = 1$	$h = 0$	$h = 1$	$h = 0$	$h = 1$
Modelo AR (EQM)	0,004	0,009	0,000	0,000	0,008	0,016
Modelo DI-AR (EQM relativo)	1,05	1,00	1,06	1,08	1,05	1,00
Modelo TDI-AR (EQM relativo)	0,96	0,82	0,89	0,82	0,96	0,82

QUADRO 2. Previsão do consumo público

Em contraste, o modelo TDI-AR apresenta sempre um EQM relativo inferior a um, independentemente do horizonte de previsão ou período amostral. Em particular, o ganho relativo é maior para a previsão a um período de distância (isto é, de 18 por cento) do que no caso de *nowcast*. Porém, nenhum desses ganhos é estatisticamente significativo.

Assim, estes resultados parecem sugerir que, no caso do consumo público, é difícil alcançar resultados melhores do que os obtidos com o modelo auto-regressivo simples (ver também Esteves, 2013). Esta evidência estará associada ao facto da série do consumo público trimestral em Portugal apresentar um perfil relativamente alisado, dado que resulta tipicamente da distribuição trimestral de valores anuais.

iii) Investimento

Os resultados obtidos referentes ao investimento encontram-se reportados no Quadro 3. Os dois modelos, DI e TDI, apresentam ganhos consideráveis no caso do *nowcast* do investimento total, nomeadamente, 30 e 40 por cento, respetivamente. Ganhos consideráveis similares são encontrados para as duas sub-amostras com o modelo TDI a registar um desempenho superior ao modelo DI. No caso da previsão a um trimestre de distância, os modelos DI e TDI proporcionam ganhos em torno de 10 por cento. Essa superioridade reflete o desempenho na primeira parte da amostra, onde os ganhos são muito substanciais, uma vez na segunda parte da amostra os resultados estão próximos do *benchmark*.

Período fora da amostra	2002T1-2015T4		2002T1-2007T4		2008T1-2015T4	
Horizonte de previsão	$h = 0$	$h = 1$	$h = 0$	$h = 1$	$h = 0$	$h = 1$
Total						
Modelo AR (EQM)	0,212	0,186	0,102	0,093	0,295	0,256
Modelo DI (EQM relativo)	0,70**	0,91	0,76	0,55	0,68*	1,01
Modelo TDI (EQM relativo)	0,60**	0,90	0,52	0,46*	0,62**	1,02
Máquinas e equipamento						
Modelo AR (EQM)	0,853	0,996	0,190	0,193	1,351	1,598
Modelo DI (EQM relativo)	0,86	0,77	1,01	1,21	0,85	0,73
Modelo TDI (EQM relativo)	0,82	0,77	0,94	1,07	0,80	0,74
Material de transporte						
Modelo AR (EQM)	2,394	2,402	1,599	1,638	2,991	2,976
Modelo DI-AR (EQM relativo)	0,89	0,91	1,03	1,07	0,83	0,84*
Modelo TDI-AR (EQM relativo)	0,86	0,93	1,06	1,12	0,78*	0,86
Construção						
Modelo AR (EQM)	0,120	0,109	0,095	0,081	0,140	0,130
Modelo DI (EQM relativo)	1,02	1,02	1,00	0,72	1,03	1,17
Modelo TDI (EQM relativo)	0,87	1,09	0,58	0,82	1,02	1,21
Outro						
Modelo AR (EQM)	4,614	5,227	4,890	5,493	4,406	5,027
Modelo DI (EQM relativo)	0,99	0,79*	0,90	0,67*	1,07	0,88
Modelo TDI-AR (EQM relativo)	1,02	0,86	1,13	0,78	0,93	0,93

QUADRO 3. Previsão do investimento

Adicionalmente, foram objeto de estudo as várias componentes do investimento nomeadamente máquinas e equipamento, material de transporte, construção e outro investimento. No caso das máquinas e equipamento, tanto o modelo DI como o modelo TDI apresentam uma melhoria face ao modelo auto-regressivo univariado registando ganhos semelhantes, tanto para a previsão *nowcast* como para a previsão a um trimestre de distância (cerca de 20 por cento). Refira-se que, os ganhos estão essencialmente concentrados na segunda parte do período considerado para efeitos de previsão.

No que diz respeito ao investimento em material de transporte, os ganhos são ainda mais limitados (cerca de 10 por cento), com ambos os modelos DI e TDI a apresentarem novamente um desempenho relativamente similar para ambos os horizontes de previsão. A melhoria também é mais significativa na parte final do período de avaliação.

Relativamente ao investimento em construção, apenas o modelo TDI apresenta um ganho no caso do *nowcast* uma vez que o modelo DI não suplanta o modelo de referência no período de previsão como um todo. Para a previsão a um período de distância, nenhum dos modelos supera o modelo auto-regressivo. Em termos de sub-amostras, ambos os modelos têm um

desempenho relativamente melhor na primeira parte da amostra, ainda que os ganhos não sejam estatisticamente significativos. Finalmente, para o outro investimento, basicamente não existem ganhos a reportar no caso da previsão do trimestre corrente enquanto se observa alguma melhoria na previsão a um período de distância, refletindo em grande parte o desempenho na primeira parte da amostra.

Em suma, modelos de fatores tendem a apresentar um desempenho superior, na maioria dos casos, comparativamente ao modelo de referência. No entanto, enquanto para o investimento como um todo, os ganhos são claramente notórios com o modelo TDI a destacar-se, os resultados para as componentes do investimento são relativamente decepcionantes. Esta evidência parece sugerir que os modelos de fatores podem ser potencialmente mais úteis para a previsão de agregados mais latos e não tanto quando se está interessado numa componente muito específica. Tal parece natural, dado que os modelos de fatores foram concebidos para explorar os principais movimentos na base de dados e, por isso, menos apropriados para a projeção de componentes detalhadas da atividade.

iv) Exportações

No Quadro 4 apresentam-se os resultados para as exportações totais bem como para as exportações de bens e serviços separadamente. Em relação às exportações totais, obtêm-se ganhos substanciais com os modelos DI e TDI no caso de *nowcast* e, menores, para a previsão a um período de distância, onde o modelo TDI regista resultados ligeiramente superiores ao modelo DI. Para qualquer um dos horizontes de previsão e para ambos os modelos, os ganhos são maiores na segunda sub-amostra, ainda que estatisticamente não significativos dado que a melhoria parece estar concentrada num pequeno número de observações.

Período fora da amostra	2002T1-2015T4		2002T1-2007T4		2008T1-2015T4	
Horizonte de previsão	$h = 0$	$h = 1$	$h = 0$	$h = 1$	$h = 0$	$h = 1$
Total						
Modelo AR (EQM)	0,079	0,079	0,036	0,037	0,111	0,110
Modelo DI (EQM relativo)	0,45	0,86	0,65	0,96	0,40	0,84
Modelo TDI (EQM relativo)	0,42	0,80	0,68	1,00	0,36	0,76
Bens						
Modelo AR (EQM)	0,112	0,112	0,035	0,036	0,170	0,170
Modelo DI (EQM relativo)	0,48	0,95	0,85	1,24	0,42	0,90
Modelo TDI (EQM relativo)	0,42	0,86	0,84	1,11	0,35	0,82
Serviços						
Modelo AR (EQM)	0,087	0,081	0,139	0,131	0,048	0,043
Modelo DI (EQM relativo)	1,07	1,01	0,75	0,98	1,77	1,08
Modelo TDI (EQM relativo)	0,98	1,29	0,73	1,09	1,51	1,75

QUADRO 4. Previsão das exportações

Em termos das componentes, existem diferenças assinaláveis entre as exportações de bens e de serviços. No caso dos serviços, os modelos de fatores não parecem superar o *benchmark* auto-regressivo. Para as exportações de bens, a avaliação é semelhante à relatada anteriormente para as exportações totais ainda que os ganhos sejam ligeiramente inferiores. Esta evidência parece sugerir que não se ganha muito na capacidade preditiva em considerar a desagregação das exportações.

v) Importações

Finalmente, foi avaliado o desempenho relativo dos modelos de fatores para prever as importações (ver Quadro 5). Para as importações no seu conjunto, obtiveram-se ganhos estatisticamente significativos no caso do *nowcast*, com o modelo TDI a destacar-se mais uma vez comparativamente ao modelo DI. Os resultados são ainda mais assinaláveis quando se foca na previsão na segunda sub-amostra. Na previsão a um trimestre de distância, os ganhos são menores e mais visíveis na primeira parte da amostra.

Período fora da amostra	2002T1-2015T4		2002T1-2007T4		2008T1-2015T4	
Horizonte de previsão	h = 0	h = 1	h = 0	h = 1	h = 0	h = 1
Total						
Modelo AR (EQM)	0,100	0,095	0,049	0,054	0,138	0,126
Modelo DI (EQM relativo)	0,56*	0,78	0,83	0,64	0,48*	0,82
Modelo TDI (EQM relativo)	0,48**	0,77	0,65	0,69	0,43**	0,79
Bens						
Modelo AR (EQM)	0,126	0,114	0,053	0,052	0,180	0,160
Modelo DI (EQM relativo)	0,50**	0,81	0,71	0,70	0,46**	0,84
Modelo TDI (EQM relativo)	0,45**	0,78	0,56*	0,66	0,42**	0,81
Serviços						
Modelo AR (EQM)	0,154	0,156	0,165	0,177	0,147	0,140
Modelo DI (EQM relativo)	1,21	1,00	1,19	1,14	1,23	0,87
Modelo TDI (EQM relativo)	1,15	1,13	1,08	1,33	1,20	0,95

QUADRO 5. Previsão das importações

Em termos das componentes, tal como no caso das exportações, também se verifica que existem ganhos apenas no caso das importações de bens uma vez que os modelos de fatores não melhoram face ao modelo auto-regressivo de referência no caso dos serviços. Para as importações de bens, a avaliação é muito semelhante à reportada para as importações totais.

Abordagem *bottom-up* para o PIB

Com base nas previsões para as várias componentes do PIB, torna-se possível aferir se a qualidade das previsões para o crescimento do PIB pode ser melhorada ou não recorrendo a uma abordagem *bottom-up*. Para avaliar se a abordagem *bottom-up* pode conduzir a ganhos de precisão face às previsões obtidas diretamente, é necessário considerar um modelo para a previsão direta do agregado de interesse. Para esse efeito, procedeu-se à avaliação do desempenho dos modelos acima utilizados para prever diretamente o crescimento do PIB, à semelhança do que foi feito para cada uma das suas componentes. No Quadro 6, apresentam-se os respetivos resultados.

Período fora da amostra	2002T1-2015T4		2002T1-2007T4		2008T1-2015T4	
Horizonte de previsão	h = 0	h = 1	h = 0	h = 1	h = 0	h = 1
Modelo AR (EQM)	0,008	0,008	0,007	0,006	0,008	0,010
Modelo DI (EQM relativo)	0,49**	1,00	0,42**	1,01	0,53	1,00
Modelo TDI (EQM relativo)	0,37***	0,73	0,23**	0,56**	0,47*	0,80

QUADRO 6. Previsão do PIB

Como em Dias *et al.* (2015), constata-se que os modelos de fatores superam o desempenho do modelo de referência com o modelo TDI a destacar-se¹. Para a previsão do trimestre corrente, os ganhos obtidos com este último modelo são muito substanciais (63 por cento para o período fora de amostra como um todo) e estatisticamente significativos em qualquer uma das sub-amostras consideradas. Como seria de esperar, para a previsão a um período de distância os ganhos são menores (27 por cento) sendo mais pronunciados na primeira parte da amostra. Assim sendo, utilizou-se o modelo TDI para a previsão direta do crescimento do PIB como *benchmark* na avaliação do desempenho relativo da abordagem *bottom-up* para o PIB.

No Quadro 7, são apresentados os resultados obtidos para a abordagem *bottom-up*, para o PIB bem como para as suas principais componentes. Em particular, avalia-se, em primeiro lugar, a abordagem *bottom-up* para cada um dos principais agregados do PIB, nomeadamente consumo privado, investimento, exportações e importações. Ou seja, avalia-se se a previsão de cada uma das principais componentes do PIB obtida diretamente é melhor do que a alcançada com a correspondente abordagem *bottom-up*. Isto é, por exemplo, analisa-se se a previsão direta de consumo privado é melhor do que a que resulta da agregação das previsões de bens duradouros e não-duradouros obtidas separadamente, utilizando os correspondentes pesos de contas nacionais. Para cada variável foi escolhido o melhor modelo com base na análise anterior, e que são indicados na segunda coluna do Quadro 7, em consonância com a ordem de discussão da seção anterior.

Constata-se que a prossecução de uma abordagem *bottom-up* para cada uma das principais componentes do PIB não melhora os resultados das previsões quer para o trimestre corrente quer a um período de distância dado que o EQM relativo é quase sempre superior a um para o período sob avaliação como um todo. Esta evidência parece sugerir que os modelos de fatores são menos apropriados quando o foco do exercício é uma componente relativamente detalhada do PIB dado que a sua dinâmica pode ser determinada, em larga medida, por elementos de cariz idiossincrático. Naturalmente, uma vez que os modelos de fatores procuram captar os principais co-movimentos subjacentes na base de dados, o uso deste tipo de modelos tende a ser menos apropriado quando se está perante componentes muito específicas da atividade económica.

1. Estes resultados não correspondem exatamente aos publicados em Dias *et al.* (2015) dado que as contas nacionais trimestrais foram revistas pelo INE devido à adoção do SEC 2010 e pelo facto de se considerar um período de avaliação mais alargado

Período fora da amostra		2002T1-2015T4		2002T1-2007T4		2008T1-2015T4	
Horizonte de previsão		<i>h</i> = 0	<i>h</i> = 1	<i>h</i> = 0	<i>h</i> = 1	<i>h</i> = 0	<i>h</i> = 1
	Modelos						
Consumo privado							
Direta (EQM)	1) TDI	0,006	0,007	0,003	0,005	0,008	0,009
Bottom-up (EQM relativo)	2) TDI+TDI	1,03	1,01	1,14	1,05	1,00	0,99
Consumo público							
Direta (EQM)	3) TDI-AR	0,004	0,008	0,000	0,000	0,007	0,013
Investimento							
Direta (EQM)	4) TDI	0,126	0,167	0,053	0,043	0,181	0,260
Bottom-up (EQM relativo)	5) TDI+TDI-AR+TDI+DI	1,02	1,10	0,94	1,22	1,04	1,09
Exportações							
Direta (EQM)	6) TDI	0,033	0,063	0,024	0,036	0,040	0,083
Bottom-up (EQM relativo)	7) TDI+AR	1,03	1,02	0,99	0,97	1,05	1,03
Importações							
Direta (EQM)	8) TDI	0,048	0,073	0,032	0,037	0,060	0,100
Bottom-up (EQM relativo)	9) TDI+AR	1,00	0,98	0,96	0,94**	1,01	0,99
PIB							
Direta (EQM)	TDI	0,003	0,006	0,002	0,003	0,004	0,008
Bottom-up com principais agregados (EQM relativo)	1)+3)+4)+6)+8)	0,79*	0,97	0,84	1,39	0,78	0,85*
Bottom-up com componentes detalhadas (EQM relativo)	2)+3)+5)+7)+9)	0,85	1,21	0,98	2,05	0,81	0,96

QUADRO 7. Previsão através de uma abordagem *bottom-up*

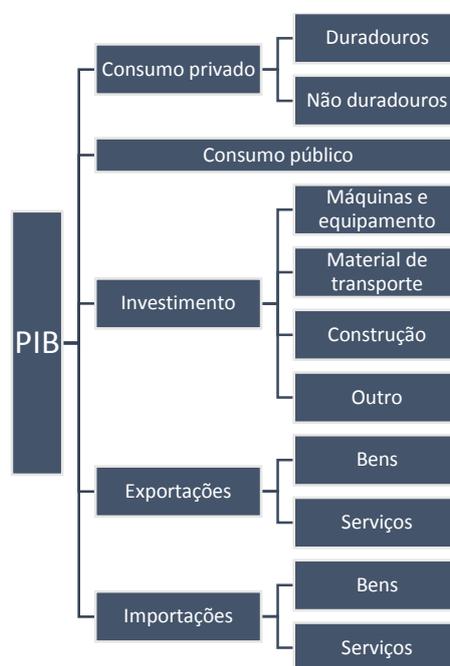


GRÁFICO 1: Decomposição do PIB

Relativamente ao PIB, consideram-se dois níveis alternativos de desagregação para a abordagem *bottom-up* (ver Gráfico 1). Um nível de desagregação que considera os principais agregados do PIB (nomeadamente consumo privado, consumo público, investimento, exportações e importações) e um nível de desagregação maior que considera as componentes do PIB mais detalhadas (ou seja, consumo de bens duradouros, consumo de bens não-duradouros, consumo público, investimento em máquinas e equipamento, material de transporte, construção, outro investimento, exportações de bens, exportações de serviços, importações de bens e importações de serviços).

Verifica-se que a abordagem *bottom-up* melhora significativamente o desempenho no *nowcast* do crescimento do PIB² Em particular, constata-se que os maiores ganhos são alcançados quando se considera o nível de desagregação baseado nos principais agregados do PIB. Essa abordagem proporciona um ganho estatisticamente significativo de 21 por cento relativamente ao melhor modelo para previsão direta do crescimento do

2. Também foi considerado o caso em que as importações são modeladas como uma função da procura global ponderada pelos conteúdos importados (ver Esteves *et al.*, 2013). Contudo, tal não se traduziu numa melhoria do desempenho preditivo.

PIB. Além disso, o ganho é relativamente estável nas duas sub-amostras consideradas.

No caso da previsão a um período de distância, a abordagem *bottom-up* que proporciona os melhores resultados é novamente a que se baseia nos principais agregados do PIB. Embora a melhoria seja marginal *vis-à-vis* a previsão direta do crescimento do PIB para todo o período sob avaliação, obteve-se um ganho estatisticamente significativo de 15 por cento na segunda parte da amostra, que é em qualquer circunstância, um período muito exigente em termos de previsão.

Em suma, embora a abordagem *bottom-up* não pareça melhorar o desempenho das previsões no caso dos principais agregados do PIB, ganhos consideráveis podem ser obtidos quando tal abordagem é prosseguida no caso do PIB. Estes resultados ganham ainda maior destaque quando se considera um grau de desagregação baseada nas principais componentes do PIB. Esta particularidade reflete o fato de os modelos de fatores serem naturalmente mais apropriados para prever agregados mais amplos da atividade económica do que componentes muito detalhadas³.

Conclusões

Dada a comprovada utilidade dos modelos de fatores para a previsão do crescimento do PIB para Portugal, foi conduzido um exercício semelhante para avaliar o seu desempenho para a previsão das diferentes componentes do PIB. À semelhança do observado para o PIB, verificou-se que os modelos de fatores normalmente superam o modelo auto-regressivo univariado de referência com o modelo TDI de Dias *et al.* (2010) a destacar-se. Esta evidência reforça a utilidade da abordagem TDI num contexto mais alargado.

Em particular, verificou-se que os ganhos são maiores no caso do *nowcasting* e tendem a diminuir com o horizonte de previsão. Acresce ainda, que se constata que os modelos de fatores são menos úteis quando se prevê componentes relativamente detalhadas do PIB. Na presença de bases de dados alargadas, este resultado parece natural uma vez que os modelos de fatores tendem a ser mais apropriados para captar a dinâmica de grandes agregados da atividade económica.

Com base nas previsões para as diferentes componentes do PIB, também foi avaliado o comportamento da previsão obtida pela abordagem *bottom-up vis-à-vis* a abordagem direta. Os resultados obtidos apontam para ganhos significativos com a abordagem *bottom-up* para a previsão do crescimento do PIB, em particular quando se considera um nível de desagregação baseada nos principais agregados do PIB.

3. No Apêndice, são reportados os resultados considerando o Erro Absoluto Médio (EAM) das previsões à semelhança de Dias *et al.* (2015). As conclusões são qualitativamente similares.

Referências

- Angelini, E., G. Camba-Mendez, D. Giannone, L. Reichlin, e G. Rünstler (2011). "Short-term forecasts of euro area GDP growth." *Econometrics Journal*, 14(1), C25–C44.
- Artis, M., A. Banerjee, e M. Marcellino (2005). "Factor forecasts for the UK." *Journal of Forecasting*, 24, 279–298.
- Bai, J. e S. Ng (2002). "Determining the number of factors in approximate factor models." *Econometrica*, 70, 191–221.
- Bai, J. e S. Ng (2007). "Determining the number of primitive shocks in factor models." *Journal of Business & Economic Statistics*, 25, 52–60.
- Barhoumi, K., O. Darné, e L. Ferrara (2010). "Are disaggregate data useful for factor analysis in forecasting French GDP?" *Journal of Forecasting*, 29(1-2), 132–144.
- de Winter, J. (2011). "Forecasting GDP growth in times of crisis: private sector forecasts versus statistical models." DNB Working Papers 320, Netherlands Central Bank.
- Dias, F., M. Pinheiro, e A. Rua (2010). "Forecasting using targeted diffusion indexes." *Journal of Forecasting*, 29(3), 341–352.
- Dias, F., M. Pinheiro, e A. Rua (2015). "Forecasting Portuguese GDP with factor models: Pre- and post-crisis evidence." *Economic Modelling*, 44(C), 266–272.
- Diebold, F. e R. Mariano (1995). "Comparing predictive accuracy." *Journal of Business & Economic Statistics*, 13, 253–263.
- Duarte, C. e A. Rua (2007). "Forecasting inflation through a bottom-up approach: how bottom is bottom?" *Economic Modelling*, 24, 941–953.
- Esteves, P. S. (2013). "Direct vs bottom-up approach when forecasting GDP: Reconciling literature results with institutional practice." *Economic Modelling*, 33, 416–420.
- Esteves, P.S., F. Cardoso, e A. Rua (2013). "The import content of global demand in Portugal." *Economic Bulletin*, Autumn, 107-121, Banco de Portugal.
- Fair, R. e J. Shiller (1990). "Comparing information in forecasts from econometric models." *American Economic Review*, 80, 375–389.
- Forni, M., M. Hallin, M. Lippi, e L. Reichlin (2000). "The Generalized Dynamic-Factor Model: Identification And Estimation." *The Review of Economics and Statistics*, 82(4), 540–554.
- Forni, M., M. Hallin, M. Lippi, e L. Reichlin (2001). "Coincident and Leading Indicators for the Euro Area." *Economic Journal*, 111(471), C62–85.
- Forni, M., M. Hallin, M. Lippi, e L. Reichlin (2004). "The generalized dynamic factor model consistency and rates." *Journal of Econometrics*, 119(2), 231–255.
- Forni, M., M. Hallin, M. Lippi, e L. Reichlin (2005). "The Generalized Dynamic Factor Model: One-Sided Estimation and Forecasting." *Journal of the American Statistical Association*, 100, 830–840.

- Geweke, J. (1977). "The Dynamic Factor Analysis of Economic Time Series." In *Latent variables in socio-economic models*, edited by D. J. Aigner e A. S. Goldberger, chap. 19. North-Holland.
- Geweke, J. e K. Singleton (1981). "Maximum likelihood 'confirmatory' factor analysis of economic time series." *International Economic Review*, 22(1), 37–54.
- Giannone, D., L. Reichlin, e D. Small (2008). "Nowcasting: The real-time informational content of macroeconomic data." *Journal of Monetary Economics*, 55(4), 665–676.
- Hubrich, K. (2005). "Forecasting euro area inflation: does aggregating forecasts by HICP component improve forecast accuracy?" *International Journal of Forecasting*, 21, 119–136.
- Kohn, R. (1982). "When is an aggregate of a time series efficiently forecast by its past?" *Journal of Econometrics*, 18, 337–349.
- Lütkepohl, H. (1984). "Forecasting Contemporaneously Aggregated Vector ARMA Processes." *Journal of Business & Economic Statistics*, 2(3), 201–214.
- Marcellino, M., J. Stock, e M. Watson (2003). "Macroeconomic forecasting in the euro area: country specific versus euro wide information." *European Economic Review*, 47, 1–18.
- Reijer, A. (2013). "Forecasting Dutch GDP and inflation using alternative factor model specifications based on large and small datasets." *Empirical Economics*, 44(2), 435–453.
- Rose, D.E. (1977). "Forecasting aggregates of independent ARIMA processes." *Journal of Econometrics*, 5, 323–345.
- Rünstler, G., K. Barhoumi, S. Benk, R. Cristadoro, A. Den Reijer, A. Jakaitiene, P. Jelonek, A. Rua, K. Ruth, e C. Van Nieuwenhuyze (2009). "Short-term forecasting of GDP using large datasets: A pseudo real-time forecast evaluation exercise." *Journal of Forecasting*, 28(7), 595–611.
- Sargent, T. J. e C. A. Sims (1977). "Business Cycle Modelling Without Pretending to Have too Much A-Priori Economic Theory." In *New methods in business cycle research*, edited by C. Sims *et al.* Federal Reserve Bank of Minneapolis.
- Schumacher, C. (2007). "Forecasting German GDP using alternative factor models based on large datasets." *Journal of Forecasting*, 26(4), 271–302.
- Schumacher, C. (2010). "Factor forecasting using international targeted predictors: The case of German GDP." *Economics Letters*, 107(2), 95–98.
- Schumacher, C. (2011). "Forecasting with Factor Models Estimated on Large Datasets: A Review of the Recent Literature and Evidence for German GDP." *Journal of Economics and Statistics*, 231(1), 28–49.
- Stock, J. e M. Watson (1998). "Diffusion Indexes." NBER Working Paper 6702, National Bureau of Economic Research.
- Stock, J. e M. Watson (2002a). "Forecasting using principal components from a large number of predictors." *Journal of the American Statistical Association*, 97(460), 1167–1179.

- Stock, J. e M. Watson (2002b). "Macroeconomic forecasting using diffusion indices." *Journal of Business & Economic Statistics*, 20(2), 147–162.
- Stock, J. e M. Watson (2005). "Implications of dynamic factor models for VAR analysis." NBER Working Paper 11467, National Bureau of Economic Research.
- Tiao, G. C. e I. Guttman (1980). "Forecasting contemporaneous aggregates of multiple time series." *Journal of Econometrics*, 12, 219–230.
- Zellner, A. e J. Tobias (2000). "A Note on aggregation, disaggregation and forecasting performance." *Journal of Forecasting*, 19(5), 457–469.

Apêndice

Período fora da amostra		2002T1-2015T4		2002T1-2007T4		2008T1-2015T4	
Horizonte de previsão		<i>h</i> = 0	<i>h</i> = 1	<i>h</i> = 0	<i>h</i> = 1	<i>h</i> = 0	<i>h</i> = 1
	Modelos						
Consumo privado							
Direta (EAM)	1) TDI	0,55	0,64	0,38	0,57	0,69	0,69
Bottom-up (EAM relativo)	2) TDI+TDI	1,01	1,01	1,06	1,03	0,99	0,99
Consumo público							
Direta (EAM)	3) TDI-AR	0,37	0,52	0,07	0,16	0,59	0,78
Investimento							
Direta (EAM)	4) TDI	2,72	3,05	1,71	1,68	3,48	4,08
Bottom-up (EAM relativo)	5) TDI+TDI-AR+TDI+DI	1,00	1,02	1,02	1,15	0,99	0,98
Exportações							
Direta (EAM)	6) TDI	1,42	1,90	1,09	1,45	1,66	2,24
Bottom-up (EAM relativo)	7) TDI+AR	1,02	0,98	1,01	0,94	1,03	1,00
Importações							
Direta (EAM)	8) TDI	1,56	2,09	1,28	1,46	1,78	2,57
Bottom-up (EAM relativo)	9) TDI+AR	0,96**	0,98	0,93**	0,96***	0,98	0,99
PIB							
Direta (EAM)	TDI	0,41	0,62	0,31	0,49	0,49	0,71
Bottom-up com principais agregados (EAM relativo)	1)+3)+4)+6)+8)	0,87**	0,98	0,91	1,12	0,86*	0,91
Bottom-up com componentes detalhadas (EAM relativo)	2)+3)+5)+7)+9)	0,95	1,07	1,01	1,32	0,92	0,94

QUADRO 8. Resultados com base no erro absoluto médio, em percentagem