

PREVISÕES MACROECONÓMICAS DE CURTO PRAZO PARA OS E.U.A. A PARTIR DE *NOWCASTS* DO *SURVEY OF PROFESSIONAL FORECASTERS**

Inês Maria Gonçalves**

RESUMO

Este artigo propõe uma estratégia de previsão para um conjunto de variáveis macroeconómicas que utiliza informação de inquéritos a analistas financeiros. Especificamente, assume-se que certas previsões para o estado atual da economia (*nowcasts*) são muito difíceis de superar no curto prazo, pelo que se obtêm benefícios em incluí-las nas séries temporais das variáveis a prever. Para a economia dos E.U.A., o *Survey of Professional Forecasters* (SPF) da Reserva Federal de Filadélfia é uma reconhecida fonte de *nowcasts*, sendo por isso o ponto de partida escolhido para prever sete variáveis macroeconómicas de relevo. Recorrendo a vários modelos, tanto univariados como multivariados, é então possível comparar as previsões que resultam do emprego desta estratégia com as previsões que seriam obtidas caso as séries não incluíssem a informação adicional. Por outro lado, analisa-se também o desempenho dos modelos com *nowcasts* face às próprias previsões dos analistas que participam no inquérito. Enquanto o SPF se afirma, *per se*, como altamente fidedigno, os *nowcasts* parecem contribuir para aumentar a precisão dos modelos usados. Embora sensível à escolha das variáveis, a abordagem proposta neste artigo revela-se bastante promissora e deixa aberto o caminho a um estudo mais aprofundado, visando a aplicação a outras variáveis e/ou economias.

1. Introdução

O desenvolvimento de métodos de previsão credíveis desempenha um papel fundamental no apoio à formulação de políticas económicas. Dado o desfazamento com que as políticas se refletem na economia, aquando da tomada de decisões torna-se relevante avaliar o comportamento esperado, ao invés do comportamento presente, das variáveis de interesse. Os bancos centrais assumem uma responsabilidade importante na melhoria contínua desses métodos, uma vez que através das suas previsões proporcionam a analistas e decisores políticos visões informadas sobre a evolução futura da economia.

Neste artigo, descreve-se uma estratégia de aperfeiçoamento de alguns modelos de previsão *standard* através do uso de informação atempada sobre as variáveis a prever, em linha com Faust e Wright (2007). Especificamente, prolongam-se as séries temporais disponíveis com previsões para o período corrente, o que confere aos modelos uma vantagem de informação não negligenciável. Essas previsões são os

* Este artigo faz um sumário das conclusões mais interessantes de um projeto de estágio realizado no Departamento de Estudos Económicos do Banco de Portugal sob a orientação de João Valle e Azevedo, a quem agradeço a disponibilidade, ideias e sugestões. Agradeço também a Ana Pereira pelo esclarecimento de questões relacionadas com a base de dados e a linguagem de programação em *Mathematica*. Por fim, faço um agradecimento especial a António Antunes pela motivação e confiança que depositou neste projeto. As opiniões expressas no artigo são da responsabilidade da autora, não coincidindo necessariamente com as do Banco de Portugal ou do Eurosistema. Eventuais erros e omissões são da exclusiva responsabilidade da autora.

** Banco de Portugal, Departamento de Estudos Económicos.

chamados *nowcasts*, definidos como previsões produzidas em t para uma qualquer variável macroeconómica em t ¹.

O contributo deste artigo vai sobretudo no sentido de complementar a investigação apresentada em Valle e Azevedo e Pereira (2013). Nomeadamente, recorrendo aos mesmos modelos utilizados no supracitado, conclui-se que o Filtro de Baixa Frequência usado pelos autores tem um desempenho geralmente superior aos restantes métodos estudados. Um aspeto diferenciador do presente artigo é o facto de se avaliar o comportamento dos modelos num contexto em que as séries incluem observações adicionais, os *nowcasts*, comparando os resultados obtidos com aqueles que usam apenas os dados observados.

Para além do Filtro de Baixa Frequência, consideram-se outros modelos univariados e multivariados, bem como a combinação de previsões, partindo do pressuposto que diferentes previsões contêm informação de natureza distinta e que esta deve ser aproveitada. Neste campo, refiram-se os trabalhos de Chong e Hendry (1986), Diebold e Mariano (1995) e Harvey *et al.* (1998). Finalmente, utilizam-se também métodos que têm por base a ideia que existe um conjunto relativamente restrito de fatores que determinam o comportamento de muitas variáveis macroeconómicas, pelo que a previsão se deve concentrar nessas componentes comuns (ver Stock e Watson (2002), por exemplo).

Os modelos são (re)estimados a cada período t , com o objetivo de reproduzir o calendário de divulgação de dados em tempo real. Deste modo, simula-se um contexto de previsão *out-of-sample*, em que a estimação dos modelos é feita com os dados observados até t . Esta é uma prática corrente na literatura (ver Angelini *et al.* (2011) ou Valle e Azevedo e Pereira (2013), entre outros). Mais corretamente, a abordagem do artigo poderá ser caracterizada como *pseudo-out-of-sample*, uma vez que se consideram apenas as séries no seu estado mais recente (*final data vintages*), ignorando-se potenciais revisões de dados.

O artigo foca-se nos E.U.A. por esta ser uma economia amplamente estudada, à qual os modelos aqui usados já foram aplicados, assegurando-se assim a sua adequabilidade. Adicionalmente, sublinhe-se a questão da disponibilidade de dados, cuja facilidade de acesso privilegia a opção pela análise desta economia.

No que respeita à fonte de *nowcasts*, escolheu-se o *Survey of Professional Forecasters* (SPF) da Reserva Federal de Filadélfia, uma vez que este permite fazer uso de um conjunto de previsões acessíveis ao público, prontamente disponíveis e consideradas fidedignas para a economia americana. O inquérito é conduzido trimestralmente e integra um painel de analistas financeiros cujo anonimato é preservado, garantindo assim a sua independência. Tal como defendido por Croushore (1993), estas características fazem do SPF um candidato difícil de bater quando comparado com outros inquéritos. De facto, inquéritos similares apresentam algumas desvantagens, tais como a divulgação apenas duas vezes ao ano (*Livingston Survey*), previsões em termos médios anuais (*National Association of Business Economists Outlook*), ou a utilização de um painel conhecido de analistas (*Blue Chip Forecast*). Para além disso, como demonstrado por Stark (2010), o SPF tende a comportar-se muito bem em horizontes curtos. Visto que o artigo se debruça sobre previsões até quatro trimestres, foi este o inquérito considerado mais apropriado para o estudo.

Em termos de variáveis, fazem-se previsões para o produto interno bruto (PIB) real, o índice de preços no consumidor (IPC), o deflator do PIB, a taxa de desemprego, a taxa de juro das obrigações do tesouro a três meses, o investimento residencial e as novas habitações. As previsões são avaliadas com base na raiz dos erros quadráticos médios (REQM) dos erros de previsão, definidos como a diferença entre o valor previsto e o valor observado da variável. Adicionalmente, faz-se uma descrição qualitativa do comportamento relativo dos modelos ao longo do tempo.

¹ A produção de *nowcasts*, habitualmente designada por *nowcasting*, sai fora do âmbito deste artigo. Para mais informação sobre este tópico, ver por exemplo Giannone *et al.* (2008) e Banbura *et al.* (2010).

O artigo está organizado da seguinte forma. A próxima secção apresenta breve e intuitivamente os diferentes tipos de modelos e métodos usados na produção de previsões. De seguida, a secção 3 descreve os dados, caracterizando as variáveis estudadas e a amostra. Na secção 4 discutem-se os resultados. Por fim, a secção 5 faz uma síntese das conclusões e aponta caminhos para investigação futura. Inclui-se ainda um anexo complementar à secção 2, onde se desenvolve a exposição relativa às técnicas de previsão, em particular no que respeita à sua formalização matemática.

2. Modelos e Métodos de Previsão

As previsões são construídas com base em modelos habituais na literatura. Em particular, o artigo segue a abordagem de Faust e Wright (2007) e Valle e Azevedo e Pereira (2013). Nesta secção, introduzem-se os vários tipos de modelos usados na produção de previsões, dando primazia à explicação intuitiva por detrás da sua utilização e remetendo o leitor para o anexo para mais pormenores referentes à formalização matemática.

Uma primeira classe de modelos produz previsões com base nas séries temporais disponíveis, através de uma relação entre os valores observados e os valores futuros das variáveis a prever. Estes são os chamados **Modelos Autorregressivos** ou univariados, em que o comportamento futuro das variáveis é explicado pelo seu comportamento passado. A abordagem é assim bastante simples, uma vez que as variáveis a prever dependem apenas delas próprias. Consideram-se três modelos alternativos: modelo de **Auto-Regressão Iterada (ARI)**, modelo de **Auto-Regressão Direta (ARD)** e **Passeio Aleatório (PA)**.

Seguidamente, introduz-se alguma complexidade no processo ao aumentar os modelos com variáveis adicionais (indicadores). Reconhece-se pois que existem outros fatores suscetíveis de influenciar o comportamento de uma dada variável económica para além dela própria. Constrói-se então um modelo matemático que estabelece uma relação entre a variável que se quer prever, essa mesma variável em períodos anteriores (tal como nos Modelos Autorregressivos) e um dos indicadores (para o período corrente) incluídos num painel que se apresenta na próxima secção. A abordagem adotada no artigo foi no sentido de combinar as previsões obtidas com cada um dos indicadores, visto que se entende existirem ganhos em incorporar informação de natureza distinta. Estes são por isso os **Métodos de Combinação de Previsões**, entre os quais se consideram duas especificações: **Combinação de Regressões Simples (Simples)**, onde se calcula uma média simples das previsões, e **Combinação Bayesiana de Regressões (Bayesiana)**, onde os pesos atribuídos a cada previsão no cálculo da média são escolhidos recorrendo à estatística *bayesiana*.

Um terceiro tipo de modelos afina a técnica descrita no parágrafo acima, ao sumariar o efeito dos indicadores através das suas componentes principais. Explicitamente, opta-se por sintetizar a informação contida no painel de indicadores já referido, partindo da ideia que o comportamento dessas variáveis é largamente determinado por um conjunto mais restrito de fatores comuns. Estes modelos são então denominados **Modelos com Fatores** e consideram-se também duas especificações: **Modelo Vetorial Autorregressivo com Fatores (VARF)** e **Auto-Regressão Direta com Fatores (ARDF)**.

Por último, fazem-se previsões usando o **Filtro de Baixa Frequência**. Este método, usado em Valle e Azevedo e Pereira (2013), visa captar as frequências mais baixas das séries temporais de interesse, uma vez que as frequências elevadas tendem a conter um elevado grau de ruído, o que as torna difíceis de prever. Assim, as variáveis são estimadas através de uma versão alisada das mesmas, obtida após a aplicação de um filtro que elimina flutuações acima de uma frequência ótima. Consideram-se especificações dentro de cada uma das classes de modelos anteriormente descritas: **Especificação Univariada (Filtro)**, **Especificação de Combinação (Combinação)** e **Especificação Com Fatores (Filtro com Fatores)**.

3. Dados

Fazem-se previsões para sete variáveis macroeconómicas dos E.U.A., a saber: o PIB real, o IPC, o deflator do PIB, a taxa de desemprego, a taxa de juro das obrigações do tesouro a três meses, o investimento residencial e as novas habitações. As previsões têm uma frequência trimestral e abrangem horizontes de um a quatro trimestres, ou seja, estendem-se até um ano após o momento inicial de previsão. Estas previsões são depois comparadas com a mediana das previsões trimestrais do SPF. A amostra cobre o período entre o quarto trimestre de 1968, correspondendo à data da primeira divulgação do SPF, e o terceiro trimestre de 2012. Em cada trimestre, t , estimam-se os modelos com os dados disponíveis até t , com as primeiras previsões calculadas para o primeiro trimestre de 1984, o início da chamada “Grande Moderação”. Simula-se assim um contexto de previsão em tempo real (*out-of-sample*). Contudo, simplifica-se o exercício ao usar as *vintages* disponíveis no terceiro trimestre de 2012 (não anualizadas) extraídas da base de dados da Reserva Federal de Filadélfia, independentemente de revisões posteriores². À exceção da taxa de desemprego e da taxa de juro das obrigações do tesouro a três meses, às quais se aplicam diferenças de nível, transformam-se as variáveis através de diferenças de logaritmos de modo a garantir a sua estacionaridade.

O painel de indicadores é essencialmente igual ao usado em Valle e Azevedo e Pereira (2013), incorporando diversos indicadores de atividade e variáveis monetárias e financeiras³. Assinala-se, contudo, uma diferença importante. O cálculo de médias de três meses, que transforma as variáveis de periodicidade mensal em variáveis trimestrais, é aqui feito da última para a primeira observação disponível. Pretende-se, assim, alinhar a informação de modo a que o calendário de divulgação de dados coincida com a sua disponibilidade para os analistas do SPF, o que permite a recursividade das previsões.

4 Resultados

Nesta secção, discutem-se os resultados obtidos, dando particular destaque a duas variáveis fundamentais: o PIB real, enquanto medida da atividade económica, e o IPC, enquanto medida da evolução dos preços. Por uma questão de brevidade, os resultados apresentados para as restantes variáveis são mais sintéticos.

A precisão relativa dos modelos é apurada com base na raiz dos erros quadráticos médios (REQM) de previsão⁴. Este exercício é feito tanto para o caso em que os modelos usam os *nowcasts* como ponto de partida (*jump-off*), como para o caso contrário. Para comparar as previsões, torna-se então necessário assegurar que estas se referem a um mesmo trimestre. Deste modo, em t , a previsão para $t + 1$ sem *nowcast* é feita a dois trimestres, visto que o último valor disponível da série temporal se refere habitualmente a $t - 1$. Já com o *nowcast*, a previsão para $t + 1$ é feita a um trimestre apenas, uma vez que

² Os dados estão disponíveis on-line em: <http://www.phil.frb.org/research-and-data/real-time-center/survey-of-professional-forecasters/data-files/>.

³ O painel é construído com dados da Reserva Federal de St. Louis, disponíveis em <http://research.stlouisfed.org/>. Para uma descrição detalhada das variáveis e transformações aplicadas, ver Valle e Azevedo e Pereira (2013). O painel usado no referido artigo incorpora 83 séries, enquanto aqui se usam apenas 78. Foram eliminadas as séries “Reservas Não-Emprestadas de Instituições Depositárias” e “Variação Real de Existências do Setor Privado” devido a observações em falta. Foram também descartadas as séries “Despesas Pessoais de Consumo Real: Bens Duradouros”, “Despesas Pessoais de Consumo Real: Bens Não-Duradouros” e “Despesas Pessoais de Consumo Real: Serviços”, por discrepâncias no tamanho das séries e na sua decomposição. Por fim, substituíram-se as séries “Investimento Real Fixo Residencial do Setor Privado”, “Investimento Real Fixo Não-Residencial do Setor Privado”, “Despesas Reais de Consumo e Investimento Bruto do Estado: Nível Federal” e “Despesas Reais de Consumo e Investimento Bruto do Estado: Nível Local” por séries equivalentes disponíveis através da Reserva Federal de Filadélfia em <http://www.phil.frb.org/research-and-data/real-time-center/survey-of-professional-forecasters/data-files/>.

⁴ A REQM é dada por $\sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{n}}$, onde n denota o número de previsões e $\hat{y}_t - y_t$ o erro de previsão. Quanto menor a REQM, maior a precisão dos modelos.

neste caso o cálculo parte de t . Este raciocínio aplica-se a previsões para $t + h$, com $h \in \{1, 2, 4\}$ no âmbito deste estudo.

Para facilitar a leitura, a REQM é apresentada em rácio, calculado sempre face ao modelo ARI sem *nowcast*, por se considerar que este constitui um referencial ao mesmo tempo simples e robusto em termos de desempenho⁵.

Complementa-se ainda a análise com uma descrição qualitativa do comportamento dos modelos ao longo do tempo.

4.1. Raiz dos erros quadráticos médios

A avaliação sugere que a estratégia proposta se traduz em previsões geralmente mais acertadas. Este não é um resultado muito surpreendente, uma vez que o uso dos *nowcasts* implica uma vantagem de informação importante face às previsões produzidas sem *nowcasts*. Não obstante, regista-se alguma sensibilidade à escolha das variáveis. Um outro resultado a retirar desta análise é que os *jump-off* parecem ter um efeito dispar, no sentido em que a performance dos modelos mais fracos melhora relativamente mais face ao SPF.

O quadro 1 apresenta os resultados para o PIB. Para $t + 1$ e $t + 2$, o SPF supera as previsões dos modelos mesmo após a inclusão dos *nowcasts*. Contudo, para $t + 4$, os modelos ARI e ARD com *nowcasts* geram previsões mais certas, o que indicia alguma diluição da vantagem do SPF para horizontes mais longos. Para além disso, à exceção do modelo ARD (para $t + 1$) e dos Modelos com Fatores (para $t + 2$ e $t + 4$), o prolongamento das séries temporais disponíveis resulta em valores mais baixos dos erros de previsão. Verificam-se assim *de facto* ganhos na utilização desta estratégia, especialmente evidentes nos modelos com pior performance.

Quadro 1

RAIZ DOS ERROS QUADRÁTICOS MÉDIOS RELATIVA: PIB REAL						
	$t+1$		$t+2$		$t+4$	
	Sem <i>nowcast</i>	Com <i>nowcast</i>	Sem <i>nowcast</i>	Com <i>nowcast</i>	Sem <i>nowcast</i>	Com <i>nowcast</i>
Modelos Autorregressivos						
ARI	1.000	0.985	1.000	0.976	1.000	0.994
ARD	0.998	1.003	1.003	0.975	1.037	0.995
PA	1.138	1.037	1.282	0.997	1.369	1.084
Métodos de Combinação de Previsões						
Simples	0.996	0.978	1.005	0.980	1.055	1.024
Bayesiana	1.028	0.983	1.059	1.005	1.074	1.045
Modelos com Fatores						
VARF	1.100	1.096	1.074	1.096	1.082	1.095
ARDF	1.056	1.035	1.059	1.076	1.059	1.061
Filtro de Baixa Frequência						
Filtro	1.030	0.998	1.061	1.021	1.059	1.042
Combinação	1.012	0.990	1.043	1.011	1.059	1.042
Filtro com Fatores	1.019	1.006	1.044	1.030	1.053	1.040
SPF	0.949	-	0.970	-	1.006	-

Fonte: Cálculos da autora.

Nota: Para cada horizonte, assinalam-se a sombreado os três melhores modelos e a negrito o modelo com melhor desempenho.

- 5 Para cada modelo k , calcula-se $\frac{REQM_k}{REQM_{ARI \text{ sem nowcast}}}$ (REQM relativa). Quando a REQM relativa é < 1 , o modelo k gera previsões mais corretas do que o modelo ARI sem *nowcast*. Quanto menor o rácio, melhor a performance do modelo k .

No caso do IPC (Quadro 2), a REQM relativa é sempre menor para as versões dos modelos com *nowcasts*, sugerindo que os ganhos são superiores aos observados para o PIB. Continua no entanto a registar-se uma diminuição desigual, mais pronunciada nos modelos com pior performance *a priori*. Apesar do melhor desempenho, as previsões não conseguem superar as do SPF em nenhum dos horizontes estudados. Ainda assim, note-se que a vantagem relativa do SPF diminui com o horizonte. Por oposição à experiência no PIB, o Filtro de Baixa Frequência tem um desempenho claramente superior aos restantes modelos considerados, sendo o concorrente mais sério do SPF.

Quadro 2

RAIZ DOS ERROS QUADRÁTICOS MÉDIOS RELATIVA: IPC						
	<i>t</i> +1		<i>t</i> +2		<i>t</i> +4	
	Sem <i>nowcast</i>	Com <i>nowcast</i>	Sem <i>nowcast</i>	Com <i>nowcast</i>	Sem <i>nowcast</i>	Com <i>nowcast</i>
Modelos Autorregressivos						
ARI	1.000	0.878	1.000	0.953	1.000	0.953
ARD	0.981	0.878	0.999	0.954	1.142	1.022
PA	1.109	0.853	1.059	0.894	1.072	0.909
Métodos de Combinação de Previsões						
Simples	0.980	0.881	1.000	0.950	1.090	0.985
Bayesiana	1.081	0.905	1.088	1.038	1.311	1.149
Modelos com Fatores						
VARF	1.049	0.932	1.067	0.970	1.045	1.002
ARDF	1.043	0.898	1.034	1.017	1.057	1.031
Filtro de Baixa Frequência						
Filtro	0.834	0.799	0.798	0.798	0.801	0.794
Combinação	0.830	0.800	0.811	0.803	0.832	0.815
Filtro com Fatores	0.828	0.797	0.827	0.808	0.862	0.834
SPF	0.754	-	0.761	-	0.785	-

Fonte: Cálculos da autora.

Nota: Para cada horizonte, assinalam-se a sombreado os três melhores modelos e a negrito o modelo com melhor desempenho.

Ainda que estes resultados não apontem para benefícios inequívocos na utilização dos *nowcasts*, verificaram-se ganhos mais pronunciados para as restantes variáveis estudadas, que, embora possam não ser consideradas tão fundamentais, são também muito importantes na análise da evolução da economia. Apresentam-se agora esses resultados.

Uma vez que o uso dos *nowcasts* nos modelos para o PIB e o IPC conduz, salvo raras exceções, a previsões mais corretas, os resultados para as restantes variáveis concentram-se apenas nestas versões, restringindo-se também o número de modelos considerados. Especificamente, mantêm-se os modelos ARI, enquanto referencial, Combinação Simples, pela consistência na performance, e todas as versões do Filtro de Baixa Frequência, pelo bom desempenho nas previsões para o IPC. Pelo contrário, eliminam-se da análise os Modelos com Fatores, devido ao comportamento algo dececionante para as variáveis já caracterizadas.

O quadro 3 detalha a REQM relativa. Por regra, o Filtro de Baixa Frequência supera agora o SPF, cuja primazia não é já de todo óbvia. Na verdade, embora variando as especificações, o Filtro de Baixa Frequência assume-se como método de previsão preferencial, independentemente da variável ou horizonte. Este resultado reforça assim as conclusões de Valle e Azevedo e Pereira (2013) onde o uso deste método, ainda sem *nowcasts*, resultava já em previsões muito competitivas face ao SPF.

A experiência do conjunto de variáveis estudadas aponta então para um aperfeiçoamento da qualidade das previsões obtidas quando os modelos usam os *nowcasts* do SPF enquanto ponto de partida.

Quadro 3

RAIZ DOS ERROS QUADRÁTICOS MÉDIOS RELATIVA: OUTRAS VARIÁVEIS (COM NOWCASTS)			
	$t+1$	$t+2$	$t+4$
Deflator do PIB			
ARI	0.994	1.009	0.990
Combinação Simples	0.964	0.981	1.133
Filtro de Baixa Frequência			
Filtro	0.871	0.846	0.725
Combinação	0.872	0.875	0.799
Filtro com Fatores	0.904	0.901	0.863
SPF	1.002	0.986	0.896
Taxa de Desemprego			
ARI	0.929	0.924	0.989
Combinação Simples	0.929	0.911	0.972
Filtro de Baixa Frequência			
Filtro	0.927	0.885	0.917
Combinação	0.909	0.860	0.886
Filtro com Fatores	0.931	0.879	0.908
SPF	1.052	1.077	1.254
Taxa de Juro das Obrigações do Tesouro a 3 meses			
ARI	0.881	1.092	0.979
Combinação Simples	0.875	1.131	1.008
Filtro de Baixa Frequência			
Filtro	0.812	0.965	0.979
Combinação	0.809	0.964	0.978
Filtro com Fatores	0.824	0.985	0.990
SPF	0.953	1.308	1.431
Investimento Residencial			
ARI	0.964	0.980	0.997
Combinação Simples	0.940	0.936	0.992
Filtro de Baixa Frequência			
Filtro	0.948	0.921	0.897
Combinação	0.920	0.911	0.892
Filtro com Fatores	0.928	0.897	0.884
SPF	0.913	0.953	0.973
Novas Habitações			
ARI	0.980	0.981	1.002
Combinação Simples	0.971	0.971	1.002
Filtro de Baixa Frequência			
Filtro	0.943	0.941	0.959
Combinação	0.941	0.938	0.959
Filtro com Fatores	0.943	0.934	0.955
SPF	0.949	1.047	1.063

Fonte: Cálculos da autora.

Nota: Para cada horizonte, assinalam-se a sombreado os três melhores modelos e a negrito o modelo com melhor desempenho.

4.2. Comportamento ao longo do tempo

Dada a natureza estática da análise da subsecção anterior, centrada no cálculo da REQM relativa, importa complementar a avaliação com uma descrição qualitativa do comportamento global dos modelos ao longo do tempo. De facto, deve ter-se em conta a possibilidade de os resultados previamente apresentados dependerem da amostra, ou seja, poderão haver variações no comportamento das diversas previsões. Nesta subsecção, aborda-se essa questão salientando aspetos de estabilidade ao longo da amostra.

Um resultado geral é a persistência de diferenças significativas entre variáveis. Uma outra observação prende-se com a atuação dos modelos durante a crise financeira, em particular no quarto trimestre de 2008 e no primeiro trimestre de 2009, quando se registam as maiores diferenças face ao SPF. No caso do PIB, observa-se uma grande instabilidade ao longo do tempo e a performance relativa deteriora-se substancialmente com a crise. Já para IPC, o desempenho dos modelos apresenta um perfil de elevada estabilidade ao longo de toda a amostra, mas também o período da crise determina uma degradação da qualidade das previsões face ao SPF, particularmente acentuada nos horizontes mais curtos. Contudo, para as restantes variáveis os resultados são de novo mais animadores, com performances ou equivalentes ou superiores ao SPF e inclusive melhorias de precisão no período da crise. De facto, à exceção do deflator do PIB (cujos modelos são consistentemente superiores ao SPF e não se assinalam quebras significativas ao longo da amostra) e da taxa de desemprego (para a qual se observa uma deterioração apenas pontual nos trimestres da crise), as variáveis registam tendências de melhoria face ao SPF, sobretudo pronunciadas nos horizontes mais longos.

Em geral, os resultados desta análise confirmam assim os obtidos com base na REQM na amostra considerada.

5. Conclusões

Este artigo propõe uma estratégia de previsão que visa incorporar *nowcasts* do SPF em modelos de previsão de curto prazo para a economia dos E.U.A. De uma forma geral, esta abordagem revela-se bastante promissora, uma vez que se observa uma redução dos erros nos modelos que fazem uso desta informação adicional. Para além disso, o artigo mostra que, prolongando as séries temporais disponíveis, é possível calcular previsões mais precisas do que as do SPF para a maioria das variáveis, em especial nos horizontes mais longos. A análise da estabilidade dos resultados ao longo da amostra complementa e confirma a da REQM, sugerindo aliás uma tendência de melhoria na qualidade das previsões face ao SPF para grande parte das variáveis, todavia não imune a choques como o episódio da crise financeira com início em 2008.

Com este artigo, reforçam-se as conclusões de Valle e Azevedo e Pereira (2013), uma vez que o Filtro de Baixa Frequência usado por aqueles autores se afirma como um modelo de previsão capaz e consistente. De facto, à exceção das previsões para o PIB, o Filtro de Baixa Frequência assume-se como o mais forte candidato a superar o SPF, pese embora os resultados obtidos não permitirem nomear uma especificação única para todas as variáveis. Entre os restantes modelos estudados, sublinha-se ainda a boa performance dos modelos mais simples, com destaque para a ARI, e do método de Combinação Simples.

Dois aspetos fazem contudo com que a experiência do artigo possa ser considerada algo inconclusiva. Na verdade, não só os resultados dependem da variável a prever, como parece haver um efeito desigual sobre os modelos. Para além do mais, essa assimetria é de sentido contrário ao que seria desejável, no sentido em que modelos com pior desempenho beneficiam relativamente mais do uso dos *nowcasts*, implicando que o aperfeiçoamento dos melhores modelos, que seria o objetivo primordial do estudo, é comparativamente menor.

De qualquer modo, o artigo justifica a prossecução da análise a fim de apurar os resultados alcançados, deixando aberto o caminho a uma investigação mais aprofundada, através da aplicação a um conjunto de variáveis mais alargado e a outras economias, como a área do euro, e usando também previsões de outras fontes para além do SPF.

Referências

- Angelini, E., Camba-Mendez, G., Giannone, D., Reichlin, L. e Rünstler, G., (2011), "Short-Term Forecasts of Euro Area GDP Growth", *The Econometrics Journal*, 14(1), C25-C44.
- Banbura, M., Giannone, D. e Reichlin, L., (2010), "Nowcasting", *Working Paper Series*, No. 1275, European Central Bank.
- Bernanke, B. S., Boivin, J. e Elias, P., (2005), "Measuring the Effects of Monetary Policy: A Factor-Augmented Vector Autoregressive (FAVAR) Approach", *The Quarterly Journal of Economics*, 120(1), 387-422.
- Chong, Y. Y. e Hendry, D. F., (1986), "Econometric Evaluation of Linear Macro-Economic Models", *The Review of Economic Studies*, 53(4), 671-690.
- Croushore, D., (1993), "Introducing: The Survey of Professional Forecasters" *Business Review*, 6.
- Diebold, F. X. e Mariano, R. S., (1995), "Comparing Predictive Accuracy", *Journal of Business & Economic Statistics*, 13(3), 253-63.
- Faust, J. e Wright, J. H., (2007), "Comparing Greenbook and Reduced Form Forecasts Using a Large Real-Time Dataset", *National Bureau of Economic Research*, No. w13397.
- Fernandez, C., Ley, E., e Steel, M. F., (2001), "Benchmark Priors for Bayesian Model Averaging", *Journal of Econometrics*, 100(2), 381-427.
- Giannone, D., Reichlin, L. e Small, D., (2008) "Nowcasting: The Real-Time Informational Content of Macroeconomic Data", *Journal of Monetary Economics*, 55(4), 665-676.
- Harvey, D. S., Leybourne, S. J. e Newbold, P., (1998), "Tests for Forecast Encompassing", *Journal of Business & Economic Statistics*, 16(2), 254-259.
- Stark, T., (2010), *Realistic Evaluation Of Real-Time Forecasts In The Survey Of Professional Forecasters*, Federal Reserve Bank of Philadelphia Research Rap, Special Report.
- Stock, J. H. e Watson, M. W., (2002), "Forecasting Using Principal Components from a Large Number of Predictors", *Journal of the American Statistical Association*, 97(460), 1167-1179.
- Valle e Azevedo, J. e Pereira, A., (2013), "Macroeconomic Forecasting Using Low-Frequency Filters", *Working Paper 1*, Banco de Portugal.

Anexo: Modelos e Métodos de Previsão (Formalização)

Neste anexo, aprofunda-se a exposição da secção 2, detalhando os modelos e métodos usados para produzir previsões. As especificações escolhidas, em particular no que respeita aos critérios de determinação das ordens de desfasamento, são aquelas que resultam na melhor performance dos diversos modelos, sendo que especificações alternativas não alteram significativamente os resultados.

MODELOS AUTORREGRESSIVOS

- ▶ Auto-regressão Iterada (ARI): Estima-se $y_t = \rho_0 + \sum_{j=1}^p \rho_j y_{t-j} + \varepsilon_t$ pelo Método dos Mínimos Quadrados (MMQ), com a ordem de desfasamento dada por $p = 4$.
- ▶ Auto-regressão Direta (ARD): Para cada horizonte, h , estima-se $y_{t+h} = \rho_{0,h} + \sum_{j=1}^p \rho_{j,h} y_{t+1-j} + \varepsilon_{t+h}$ pelo MMQ, com a ordem de desfasamento escolhida através do critério de informação de Akaike.
- ▶ Passeio Aleatório (PA): O modelo do PA prevê simplesmente y_{t+h} como y_t .

MÉTODOS DE COMBINAÇÃO DE PREVISÕES

Os métodos de combinação de previsões partem da estimação do mesmo modelo, dado pela equação $y_{t+h}^i = \rho_{0,h}^i + \sum_{j=1}^p \rho_{j,h}^i y_{t+1-j} + \beta_{i,h} x_{it} + \varepsilon_{t+h}^i$, com $i = 1, \dots, n$ e onde $\{x_{it}\}_{i=1}^n$ representa o painel de indicadores descrito no texto principal. Seguem-se as duas especificações.

- ▶ Combinação de Regressões Simples (Simples): Calcula-se uma média simples das n previsões obtidas pela estimação do modelo acima descrito, em que a ordem de desfasamento é fixa com $p = 4$.
- ▶ Combinação Bayesiana de Regressões (Bayesiana): Neste método, usa-se a estatística bayesiana para escolher os pesos atribuídos a cada uma das n previsões. Assume-se uma probabilidade constante para cada modelo, M_i , dada por $P(M_i) = n^{-1}$. De acordo com Fernandez *et al.* (2001), assume-se também que $\varepsilon_{t+h}^i \sim N(0, \sigma^2)$ e que a distribuição *a priori* de $\lambda_{i,h} = [\rho_{0,h}^i \ \rho_{1,h}^i \ \dots \ \rho_{p,h}^i \ \beta_{i,h}]$ condicional em σ é dada por $N\left(\bar{\lambda}_h, \phi \left(\sigma^2 \sum_{t=1}^T (w_{it} w_{it}')^{-1} \right)\right)$, onde $w_{it} = [1 \ y_t \ y_{t-1} \ \dots \ y_{t+1-p} \ x_{it}]$ e a distribuição *a priori* marginal de σ é proporcional a $1/\sigma$. ϕ é um hiperparâmetro que determina o grau de informação dado pela distribuição *a priori*. Para cada horizonte, o valor de ϕ é escolhido em Valle e Azevedo e Pereira (2013)⁶. $\bar{\lambda}_h$ resulta da estimação dos parâmetros numa subamostra compreendida entre o quarto trimestre de 1968 e o primeiro trimestre de 1984⁷. Após a estimação de cada modelo, a média da distribuição *a posteriori* de $\lambda_{i,h}$, dada por $\tilde{\lambda}_{i,h} = \frac{\hat{\lambda}_{i,h\phi}}{1+\phi} + \frac{\bar{\lambda}_{i,h\phi}}{1-\phi}$ (onde $\hat{\lambda}_{i,h}$ é a estimativa MMQ de $\lambda_{i,h}$ para cada M_i), é usada para calcular previsões para y_{t+h} , como $\hat{y}_{t+h|t}^i = \tilde{\lambda}_{i,h}' w_{it}$. A

6 Ver Valle e Azevedo e Pereira (2013).

7 Ver secção 3 do texto principal para mais pormenores sobre a amostra.

previsão da Combinação *Bayesiana* é então finalmente dada por $\hat{y}_{t+h|t} = \sum_{i=1}^n P\left(\frac{M_i}{D}\right) \hat{y}_{t+h|t}^i$, em que $P\left(\frac{M_i}{D}\right)$ é a probabilidade, dada a amostra D , de o modelo i ser o verdadeiro.

MODELOS COM FATORES

► **Modelo Vetorial Autorregressivo com Fatores (VARF):** Estima-se o modelo VARF apresentado em Bernanke *et al.* (2005) dado por $\zeta_t = \phi_0 + \sum_{j=1}^s \phi_j \zeta_{t-j} + \varepsilon_t$, onde $\zeta_t = (y_t, z_{1t}, z_{2t}, \dots, z_{mt})'$, com y_{t+h} estimado através da iteração do modelo. $\{z_{it}\}_{i=1}^m$ são as primeiras m componentes principais do conjunto $\{x_{it}\}_{i=1}^n$ de indicadores. A ordem de defasamento, s , é de um trimestre e são usadas as três primeiras componentes principais ($m = 3$).

► **Auto-regressão Direta com Fatores (ARDF):** Este modelo corresponde ao modelo ARD previamente descrito, mas aumentado com fatores. Sublinhe-se que os fatores utilizados, $\{z_{it}\}_{i=1}^m$, são exatamente os mesmos que entram no modelo VARF. Para cada horizonte, estima-se $y_{t+h} = \rho_{0,h} + \sum_{j=1}^p \rho_{j,h} y_{t+1-j} + \sum_{j=0}^p \sum_{i=1}^m \gamma_i z_{it-j} + \varepsilon_{t+h}$ fixando o parâmetro m em 3. A ordem de defasamento, p , é determinada pelo critério de informação de Akaike tanto para a variável dependente, como para os fatores.

FILTRO DE BAIXA FREQUÊNCIA

Propõe-se a estimação de y_{t+h} através de uma versão alisada, $y_{t+h}^{Baixa\ Frequência} = B(L) y_{t+h}$, onde $B(L) = \sum_{j=-\infty}^{\infty} B_j L^j$ é o filtro que elimina flutuações acima de uma frequência ótima, determinada em Valle e Azevedo e Pereira (2013)⁸. Descrevem-se as especificações consideradas.

► **Especificação Univariada (Filtro):** As previsões são calculadas através da solução do problema de otimização: $\min_{\alpha_0, \{\hat{B}_j^p\}_{j=0, \dots, p}} E\left[\left(y_{T+h}^{Baixa\ Frequência} - \hat{y}_{T+h}^{Baixa\ Frequência}\right)^2\right]$, usando os $\{\hat{B}_j^p\}_{j=0, \dots, p}$ apropriados

em $\hat{y}_{t+h|t}^{Baixa\ Frequência} = \alpha_0 + \sum_{j=0}^p \hat{B}_j^p y_{t-j}$ e ajustando p por forma a que $p = 50 - h$.

► **Especificação de Combinação (Combinação):** Tomando cada um dos indicadores $\{x_{it}\}_{i=1}^n$ considerados, calculam-se n previsões para y_{t+h} com o Filtro de Baixa Frequência, que são depois agregadas através de uma média simples.

► **Especificação Multivariada com Fatores (Filtro com Fatores):** Aumenta o modelo com os mesmos $\{z_{it}\}_{i=1}^m$ fatores utilizados nos modelos supradescritos.

⁸ Ver Valle e Azevedo e Pereira (2013).