



Využitie širokej palety údajov z rôznych zdrojov na odhad reálnej súkromnej spotreby

Anna Vladová, Stanislav Tvrz, Národná banka Slovenska

Po úvahách o využití elektronických indikátorov na odhad nominálnej spotreby¹ sa k téme opäť vraciame a tentoraz ponúkame pohľad na prognózovanie spotreby v reálnom vyjadrení. Zameriame sa na krátkodobú prognózu ukazovateľa súkromnej spotreby, teda spotreby domácností (ako spotrebiteľov a malých nekorporatívnych podnikateľov) a neziskových inštitúcií slúžiacich domácnostiam (odborné združenia, profesijné združenia, spotrebiteľské asociácie, politické strany, náboženské spoločnosti). Stručne opíšeme formalizovaný prístup ku krátkodobej predikcii, ktorý je založený na regresii prevažne mesačných ukazovateľov. Keďže skutočný vývoj spotreby je zverejňovaný štvrťročne a vysvetľujúce veličiny sú k dispozícii mesačne, uvádzame aj možnosti ekonometrického modelovania s využitím dát s rôznou frekvenciou.

¹ A. Vladová: Elektronické indikátory spotrebného dopytu. Biatec, č. 6/2014.

KRÁTKODOBÁ PREDIKCIA SPOTREBY VYCHÁDZA Z FORMALIZOVANÉHO PRÍSTUPU ZALOŽENÉHO NA REGRESII MESAČNÝCH ÚDAJOV Z VIACERÝCH ZDROJOV

Vysvetľujúce ukazovatele spotreby, ktoré používame a ktoré sme podrobili testovaniu, pochádzajú z viacerých oblastí tak, aby spotrebu merali z rôzneho uhla pohľadu. Predovšetkým sa hodnotila príjmová podmienenosť spotreby (priemerné mzdy, objem miezd) a tržby vykázané obchodníkmi (maloobchodný obrat, tržby vo vybraných službách, tržby za spotrebné predmety, tržby za osobné autá a pod.). Okrem týchto základných ukazovateľov sme na účely zlepšenia modelového prístupu testovali sadu tzv. soft indikátorov ako numericky vyjadrenej zmeny názoru spotrebiteľov (napr. index spotrebiteľskej dôvery, očakávaná finančná situácia v nasledujúcich 12 mesiacoch, zámer domácností kúpiť auto) a obchodníkov (index dôvery v maloobchode). Keďže asi tretina národnej spotreby pochádza z dovozu, skúmali sme aj rôzne modifikácie indikátora spotrebného dovozu. Z fiškálnych indikátorov sme testovali dane za tovary a služby (DPH a spotrebné dane).

Vzhľadom na identifikovaný potenciál elektronických ukazovateľov (platobné karty a internetové hľadania) vysvetliť spotrebu sme do testovania vhodných indikátorov reálnej spotreby zaradili aj internetové hľadania. Platobné karty experimentálne využívame iba v modeloch nominálnej spotreby. Zdrojom ukazovateľa internetových hľadanií bola voľne dostupná štatistika návštevnosti slovenských internetových stránok, kategorizovaná do 19 skupín, napr. spravodajstvo, obchod a nakupovanie, ženy a maminy, práca a vzdelávanie, zdravie, freemaily, šport, cestovanie, voľný čas, zoznamovacie servery, reality, katalógy a ich modifikované sumáre. Z rôznych jednotiek meraní návštevnosti slovenských internetových stránok (počty návštev, užívateľov, reálnych užívateľov,

časové jednotky, spôsob prístupu atď.) sa javil byť najvhodnejším indikátorom počet návštev.

EKONOMETRICKÉ MODELOVANIE S VYUŽITÍM DÁT S RÔZNOU FREKVENCIOU

Keďže skutočný vývoj vysvetľovanej veličiny – spotreby – je zverejňovaný štvrťročne a vysvetľujúce veličiny máme k dispozícii mesačne, narážame na problematiku ekonomického modelovania s využitím dát s rôznou frekvenciou. Tento problém možno riešiť viacerými spôsobmi. Na účely krátkodobej prognózy spotreby používame vzhľadom na jeho prispôsobivosť a ľahkú interpretovateľnosť interpoláciu štvrťročného časového radu a získanie implikovaných mesačných hodnôt vysvetľovanej premennej mimo vlastného prognostického modelu. Postupovali sme podľa Chowa a Lina (1971), ktorí umožňujú výpočet neznámych mesačných hodnôt štvrťročného indikátora na základe regresie na príbuznom časovom rade s mesačnou frekvenciou. Pri interpolácii je zároveň možné zvažovať rôzne podmienky, ktoré majú získané hodnoty spĺňať. Možno napríklad rozhodnúť, či suma alebo priemer vypočítaných trojíc mesačných hodnôt v každom štvrťroku má byť totožný s pôvodnou štvrťročnou hodnotou. Získané odhady mesačných hodnôt pôvodného štvrťročného časového radu môžeme následne spracovať s využitím klasickej lineárnej regresie alebo napríklad v rámci klasickeho VAR modelu mesačných údajov. Chowovu-Linovu interpoláciu používa napríklad bayesovský VAR model pre makroekonomickú prognózu USA (Robertson a Tallman, 1999).

Iným prístupom môže byť využitie dynamických faktorových modelov (DFM), ktoré možno zaradiť medzi tzv. state-space modely. V nich je štvrťročná vysvetľovaná premenná naviazaná na latentné premenné (faktory) s mesačnou frekvenciou, pričom je pozorovaná len každá tretia



hodnota. Chýbajúce dve pozorovania zabezpečí prechodová rovnica, ktorá opisuje vývoj nepozorovaných faktorov v čase. Aktualizáciou modelu s využitím nových mesačných údajov získavame nové odhady faktorov, a teda aj novú prognózu štvrťročnej premennej. Tento prístup bol použitý pre krátkodobú predikciu vývoja španielskeho HDP (Camacho a Perez-Quiros, 2009) alebo aj pre krátkodobý výhľad ekonomickej aktivity na Slovensku (Tóth, 2014).

Ďalším možným prístupom sú MIDAS (*Mixed Data Sampling Frequency*) modely. Ide o jednorovnicové modely, v ktorých je štvrťročná vysvetľovaná premenná naviazaná na oneskorené hodnoty mesačných ukazovateľov a prípadne aj na svoje vlastné oneskorené hodnoty (AR-MIDAS). Vhodným nastavením minimálneho oneskorenia mesačných dát je možné nastaviť potrebný horizont prognózy. MIDAS modely pracujú obvykle s vyšším počtom oneskorení vysvetľujúcich premenných. Vzhľadom na identifikáciu vyššieho počtu parametrov (v prípade neobmedzeného modelu) a na interpretovateľnosť výsledkov je súčasťou modelu reštrikcia váh oneskorených mesačných indikátorov tak, aby váhy smerom do minulosti klesali. Porovnanie výsledkov *nowcasting* HDP eurozóny s využitím MIDAS a MF-VAR modelov opisuje Kurzin et al. (2011).

PREHLAD VYSVETLJÚCICH PREMENNÝCH V JEDNOTLIVÝCH MODELOCH

Použitím Chowovej-Linovej interpolácie získame odhady mesačných hodnôt pôvodne štvrťročného časového radu. Za exogénnu mesačnú premennú sme zvolili objem tržieb v maloobchode bez motorových vozidiel. Pri interpolácii sme požadovali, aby priemer odhadnutých hodnôt v každom štvrťroku zodpovedal pôvodnej hodnote

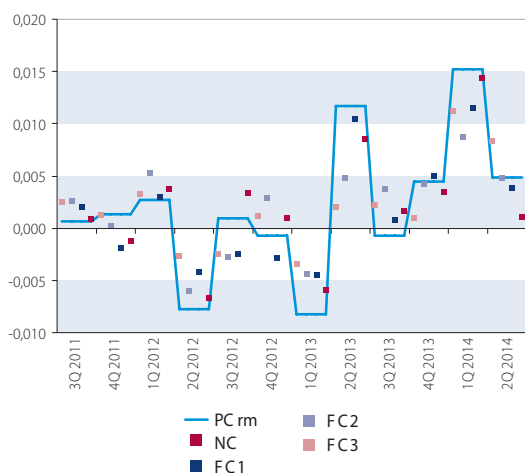
štvrťročného časového radu. Keďže cieľom bolo skonštruovať model pre medzištvrťročné tempá rastu, prešli sme ďalej od pôvodných hodnôt ku kľazovým priemerom z troch posledných mesačných hodnôt. Analogicky boli transformované tiež vysvetľujúce premenné s výnimkou soft ukazovateľov, ktoré zostali vo forme úrovňových indexov. Z takto transformovaných dát boli skonštruované modely na prognózovanie medzištvrťročného rastu reálnej súkromnej spotreby s horizontom predikcie tri, dva a jeden mesiac a nowcast.

Modely s horizontom predikcie tri a dva mesiace používajú tri rovnaké vysvetľujúce premenné: súmár tržieb v obchode, ubytovaní a reštauráciách, DPH a očakávanú finančnú situáciu domácností v nasledujúcom období. Predikcia spotreby 1. štvrťroka 2014 získaná z údajov po december 2013 (resp. po január 2014) dosiahla hodnotu 1,12 % (resp. 0,87 %), skutočná hodnota bola 1,53 %. Predikcia spotreby 2. štvrťroka 2014 získaná z údajov po marec 2014 (resp. apríl 2014) dosiahla hodnotu 0,83 % (resp. 0,48 %), pričom skutočnosť bola 0,49 %.

Model s horizontom predikcie jeden mesiac (z prognózovaného štvrťroka chýba jeden mesiac) pracuje so siedmimi vysvetľujúcimi premennými: maloobchodné tržby, tržby vo vybraných trhových službách, registrácia nových automobilov, DPH, spotrebiteľská dôvera, očakávaná finančná situácia domácností v nasledujúcom období a z internetových hľadání súmár za kategórie spravodajstvo, obchod a nakupovanie, ženy a maminy. Predikcia na 1. štvrťrok 2014 získaná z údajov po február 2014 dosiahla hodnotu 1,15 %, skutočná hodnota bola 1,53 %. Predikcia na 2. štvrťrok 2014 získaná z údajov po máj 2014 dosiahla 0,39 %, skutočnosť bola 0,49 %.

Nowcast model (keď sú k dispozícii vysvetľujúce ukazovatele za všetky tri mesiace daného štvrť-

Graf 1 Porovnanie modelových predikcií (štvrťročne pozorované hodnoty)

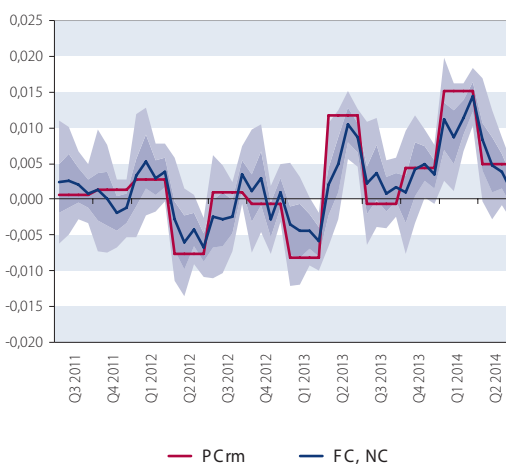


Zdroj: ŠÚ SR, vlastné výpočty.

Vysvetlivky ku grafom:

PCrm – reálny medzištvrťročný rast súkromnej spotreby
FC3, FC2, FC1 – výsledky modelu s horizontom predikcie 3, 2 a 1 mesiac
NC – nowcast

Graf 2 Porovnanie modelových predikcií vrátane neistoty ($\pm 2 a \pm 1 RMSE$)



Zdroj: ŠÚ SR, vlastné výpočty.



Tabuľka 1 Porovnanie predikčných schopností

Model	Naive1	Naive2	FC3	FC2	FC1	NC
RMSPE	0,0095	0,0094	0,0043	0,0038	0,0024	0,0020
MAPE	0,0085	0,0076	0,0037	0,0032	0,0020	0,0018

2 Pre každý štvrťrok sú modely odhadované na údajoch, ktoré tomuto obdobiu predchádzajú, čiže predikcia je vždy založená iba na informáciách dostupných z minulosti. Štatistiky takto vypočítaných predikcií sú relevantnejšie pre vyhodnotenie predikčnej schopnosti modelov na ich reálne využitie v praxi než tzv. statická predikcia získaná s využitím modelu odhadnutého na celej údajovej vzorke.

3 RMSPE – root mean squared prediction error, t. j. odmocnina z priemernej kvadratickej chyby predikcie. MAPE – mean absolute prediction error, t. j. priemerná absolútna chyba predikcie.

roka) pracuje s piatimi vysvetľujúcimi premennými: maloobchodné tržby, registrácia nových automobilov, objem miezd, spotrebná daň a zo soft ukazovateľov súčasne úspory domácností. Predikcia na 1. štvrťrok 2014 z mesačných údajov vrátane marca dosiahla hodnotu 1,43 %, skutočná hodnota bola 1,53 %. Predikcia na 2. štvrťrok 2014 z údajov zahŕňajúcich júnové dáta dosiahla 0,11 %, skutočnosť bola 0,49 %.

Paradoxne práve prognóza nowcast modelu s najaktuálnejšími údajmi sa najviac odlišovala od skutočnej spotreby 2. štvrťroka. Hlavným vinníkom bol prepad počtu registrovaných automobilov v 2. štvrťroku (z približne 14 % rastu v 1. štvrťroku na pokles o 10 % v 2. štvrťroku), čo spôsobilo zníženie predikcie o 0,6 percentuálneho bodu oproti nowcastu predchádzajúceho štvrťroka (1,43 %). Ostatné faktory znížili túto predikciu každý jednotlivu vždy maximálne o 0,3 percentuálneho bodu. Pokles registrácií áut však môže byť indikáciou nielen zníženej spotreby dlhodobých predmetov, ale aj nižších investícií do dopravných prostriedkov (čo sa napokon aj potvrdilo). Keďže sa v tomto prípade dal pomerne ľahko identifikovať a interpretovať dôvod zníženia nowcastu, väčšiu váhu pri predikcii sme pripísali forecastovým modelom.

V grafoch 1 a 2 uvádzame rekurzívnu predikciu² reálnej spotreby získanú s využitím vyššie opísaných ekonometrických modelov. Tieto grafy nám umožňujú vizuálne posúdiť úspešnosť modelovej predikcie na celom predikčnom horizonte. Z grafického znázornenia vyplýva, že najmenšiu predikčnú chybu v priemere dosahuje nowcast model. Všeobecne tiež platí, že sa chyba predikcie znižuje spolu s počtom známych mesačných

pozorovaní z daného štvrťroka – v grafe 2 sa táto skutočnosť odráža v zužovaní intervalu predikcie v rámci štvrťroka.

Exaktnejšie môžeme predikčnú schopnosť modelov porovnať na základe štatistik³ RMSPE a MAPE (tabuľka 1). Pre úplnosť uvádzame tiež štatistiky tzv. naivných predikcií, teda jednoduchého benchmarku. Predikcia Naive1 zodpovedá dlhodobému priemeru medzištvrtročného rastu reálnej spotreby. Predikcia Naive2 zodpovedá hodnote medzištvrtročného rastu reálnej spotreby pozorovanej v predchádzajúcom štvrťroku (*random walk*). Na základe hodnôt v tabuľke 1 možno tvrdiť, že predikčné modely dosahujú podstatne lepšie výsledky než jednoduchý benchmark. Zároveň je vidno, že modely FC3 a FC2, rovnako ako FC1 a NC sú z hľadiska presnosti predikcie približne rovnako spoľahlivé.

ZÁVER

Predpokladom nášho modelovania súkromnej spotreby je využitie Chowovej-Linovej interpolácie, ktorou získame odhady mesačných hodnôt pôvodne štvrtročného časového radu súkromnej spotreby. Modely na krátkodobú prognózu reálnej spotreby sú konštruované na mesačnej báze a pracujú s ukazovateľmi obratu, akými sú tržby v maloobchode a vo vybraných trhových službách, so mzdami, objemom vybranej DPH a spotrebnej dane, niektorými mäkkými indikátormi meranými medzi spotrebiteľmi, registráciou áut z administratívnych zdrojov a so sumárom vybraných internetových hľadání. Využitie modelových výsledkov v praxi je podmienené ich ekonomickou interpretovateľnosťou.

Literatúra

1. Tóth, P.: Model pre krátkodobý výhľad ekonomickej aktivity (MRKVA). Inštitút finančnej politiky, Ministerstvo financií SR, 2014.
2. Camacho, M. – Perez-Quiros, G.: N-STING: Espana short term indicator of growth. Banco de Espana WP no. 0912. 2009.
3. Kuzin, V. – Marcellino, M. – Schumacher, Ch.: MIDAS vs. Mixed-frequency VAR: Nowcasting GDP in the euro area. International Journal of Forecasting, vol. 27 (2011), pp. 529-542. 2011.
4. Chow, G. – Lin, A. L.: Best linear unbiased distribution and extrapolation of economic time series by related series. Review of economics and statistics, vol. 53, no. 4, pp. 372-375.
5. Robertson, J. C. – Tallman, E. W.: Vector autoregressions: Forecasting and reality. Economic review, Federal reserve bank of Atlanta, 1999(1).