

# GDP nowcasting survey adatok felhasználásával

Németh Kristóf\*

2019. június 14.

## Kivonat

A statisztikai adatgyűjtés és adatfeldolgozás időigényéből adódóan, a Központi Statisztikai Hivatal (továbbiakban: KSH) jellemzően két hónappal elmarad az aktuális negyedév gazdasági teljesítményét mérő GDP adat közlésével. Tanulmányunkban egy olyan becslési eljárást mutatunk be, mely magasabb (egyelőre havi) frekvencián rendelkezésre álló survey adatok információtartalmára támaszkodva készíti el az aktuális negyedév GDP értékének szinkronidejű becslését, vagyis *nowcast*ját. Azt vizsgáljuk, hogy a valós idejű adatfeldolgozást támogató statisztika eljárások, esetünkben a Kálmán-filter, alkalmazása mennyiben javítja a nowcast minőségét? A tanulmányban vállalati felmérések adatait használjuk fel a havi GDP növekedés látens idősorának, majd ez által az aktuális negyedév reálnövekedésének becsléséhez. Meg kell jegyeznünk, hogy a tanulmány jelenlegi változata még inkább a modellezési gyakorlatban rejlő potenciál, illetve a becslési eljárás adta lehetőségek bemutatására fókuszál. A tanulmány központi kutatási kérdésének alapos körüljárása további kutatást, és a modell mintán belüli előrejelző képességének vizsgálatát igényli.

*Kulcsszavak:* Nowcasting, Állapottér modell, Információtömörítés  
Journal of Economic Literature (JEL) kód: E43, E52, E58

## 1. Bevezetés

A statisztikai adatgyűjtés és adatfeldolgozás időigényéből adódóan, a Központi Statisztikai Hivatal (továbbiakban: KSH) jellemzően két hónappal elmarad az aktuális negyedév reálgazdasági teljesítményét jellemző GDP adat közlésével. Mivel az aktuális negyedévre vonatkozó

---

\*Köszönetet mondok mindenképp Lieli Róbertnek, aki a VII. Pécsi PTE-MKE Doktorandusz műhelyen diszkutálta a munkámat. A tőle kapott hasznos, építő jellegű kritikák sokat segítettek a tanulmány jelenlegi változatának elkészítésében, továbbá a kutatás további irányainak kijelölésében. Köszönettel tartozom továbbá Balatoni Andrásnak, Bedics Krisztiánnak, Czelleng Ádámnak, Kehl Dánielnek, Komlósi Sándornak, Kónya Istvánnak, Körösi Gábornak, Mellár Tamásnak, Rappai Gábornak, Schepp Zoltánnak, Várpalotai Viktornak és Váry Miklósnak munkám támogatásáért és előremozdításáért.

A tanulmány a Felsőoktatási Intézményi Kiválósági Program támogatásával készült el.

Németh Kristóf ([nemethkf@ktk.pte.hu](mailto:nemethkf@ktk.pte.hu)): PTE Közgazdaságtudományi Kar – Tudományos segédmunkatárs, PTE KTK Regionális Politika és Gazdaságtan Doktori Iskola – PhD hallgató, GKI Gazdaságkutató Zrt. – Vendégkutató.

tényérték rendszerint csak az adott negyedév vége után két hónappal érhető el, így adott esetben nehezzé válhat a reálgazdaság teljesítményének valós idejű (szinkronidejű) megítélése. A problémát kiküszöbölendő, a hivatalos (negyedéves) adatok beérkezéséig rendszerint a nagyobb frekvencián rendelkezésre álló, jellemzően havi adatok ismeretében próbálunk következtetni az aktuális negyedév növekedésére. Ilyen havi idősor lehet például az ipari termelés volumenindexe (hard adat), vagy például a kiskereskedelmi szektor vállalatainak kilátásait valamiképpen számszerűsítő survey adat. Jóllehet az említett idősorok egy bizonyos mértékig jellemzőek a reálgazdasági teljesítmény szempontjából, egy-egy idősor információtartalmára hagyatkozva azonban csak a reál GDP dinamikájának durva közelítése képzelhető el. Célszerű tehát olyan módszertant használnunk, amely adott esetben nagyszámú, magas frekvencián rendelkezésre álló idősor információtartalmának összegzését teszi lehetővé. Ezáltal ugyanis már jóval megbízhatóbb (hatásosabb) becslést képezhetünk az aktuális negyedév GDP-jére vonatkozóan. Tanulmányunkban a reál GDP negyedéves növekedési rátájának azonos időszakra vonatkozó becslését, vagyis *nowcast*-jét képezzük egy lineáris állapotter modellben, melyben havi frekvenciájú survey adatok információtartalmát használjuk fel. Az így képzett nowcast eredményét egy egyszerű idősoros ARMA modellel való összevetésben vizsgáljuk. A tanulmány egy későbbi változatában a becslött havi növekedési ráták alapján egy mesterséges havi GDP idősor generálására is kísérletet teszünk, ami legjobb tudásunk szerint a magyar gazdaságra még nem készült. Ez a modell alapú interpoláció a későbbiekben azért is fontos lehet, mert bár a havi GDP mérésére nem kerül sor, az elméleti kategória önmagában jól definiált, relevanciája pedig kevésbé vitatható. Jelenleg tehát a reál GDP havi (Month on Month) növekedését becsljük, majd a becslött havi növekedések összegzésével jutunk el a negyedéves növekedés nowcast-jához. A gazdasági növekedés valós idejű értékelését segítő becslés mind a fiskális és monetáris politika számára hasznos lehet, emellett pedig a nagyközönség érdeklődését is felkeltheti, hiszen a becslések nagyszámú havi indikátor információtartalmának szintetizálása során jönnek létre. Egy ilyen irányú vizsgálat hasznos lehet továbbá a hazai gazdaságra vonatkozó empirikus kutatások számára is, ahol a nemzeti számlák negyedéves könyvelése miatt gyakran nehéz a reálgazdaság teljesítményét számszerűsítő havi idősort találni. A tanulmány elkészítésének legfőbb módszertani kihívása abban állt, hogy olyan modellkeretet találjunk, illetve dolgozzunk ki, amely a negyedéves GDP-t képes a magasabb, rendszerint havi frekvencián rendelkezésre álló adatokhoz kötni.

## 1.1. A nowcasting probléma

Mivel tanulmányunkban lényegében különböző feltételes várható értékek (feltételes valószínűségi eloszlások) összehasonlításáról lesz szó, így a feltételképzés alapját jelentő információs halmazok definíciója külön figyelmet érdemel.

Definiáljuk mindenekelőtt  $\Omega_q^0 = \{Y_1, Y_2, \dots, Y_{q-1}\}$ , ahol  $q = 1, 2, \dots, Q$ , vagyis a  $q$ -edik negyedévben elérhető GDP megfigyeléseket tartalmazó *információs halmaz*. Vegyük észre, hogy feltevésünk szerint a  $q$ -edik negyedév információs halmaza, csak a  $q-1$ -edik negyedévig bezárólag

tartalmazza a GDP tényadatokat.<sup>1</sup> Ez egy fontos, egyúttal kellően realiztikus feltevés, miszerint a  $q$  negyedévben csak  $Y_{q-1}$  érhető el.

Ezek után definiáljuk  $\Omega_m^n = \Omega_{\lceil \frac{m}{3} \rceil}^0 \cup \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m\}$ , információs halmazt, ahol  $m = 1, 2, \dots, M$ ,  $n = 17$ ,  $\mathbf{X}_m$  az  $n$  darab havi idősor (magyarázó változó) értékét az  $m$ -edik hónapig tartalmazó  $m \times n$  mátrix,  $\lceil \frac{m}{3} \rceil$  pedig  $m/3$  felső egész részét jelöli. Intuitíven,  $\Omega_m^n$  információs halmaz az előzőleg definiált  $\Omega_q^0$  információs halmaz alkalmas kibővítését jelöli, ami tehát a GDP tényértékek mellett különböző, a havi növekedés szempontjából relevánsnak vélt, survey adatokkal egészül ki.<sup>2</sup>

Jelenleg  $n = 17$  és  $\mathbf{X}$  csak vállalati felmérések adatait tartalmazza. A későbbiekben klasszikus hard statisztikákkal tervezzük bővíteni az információs halmazt.

Amennyiben  $y_t = \log(Y_t) - \log(Y_{t-1})$ , vagyis a reál GDP negyedéves (*Quarter on Quarter*) százalékos növekedése, akkor a negyedéves GDP növekedés azonos idejű becslésének, mint valószínűségi változónak a feltételes várható értéke a fenti információs halmazok szerint a következőképpen definiálható:

$$E[y_q | \Omega_q^0], \quad (1)$$

$$E[y_q | \Omega_m^n], \quad (2)$$

ahol tehát  $m = \{3q, 3q - 1, 3q - 2\}$ , vagyis  $m/3$  felső egész része  $q$ -val egyenlő.

Az (1) képlettel definiált nowcast (feltételes várható érték) meghatározása a következő eljárás alapján történt: Különböző ARMA specifikációkat (ahol  $AR = 1, \dots, 4$ ;  $MA = 1, \dots, 4$ ) becslünk a minta időszak (1996 Q1 – 2018 Q4) alatt, majd ezek közül az információs kritériumok (BIC) értéke alapján a legjobban illeszkedő AR(1) modellt választottuk.

$$y_t = \beta_0 + \beta_1 y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma^2), \quad (3)$$

ahol tehát  $y_t = \log Y_t - \log Y_{t-1}$  a reál GDP logaritmusának első differenciája, vagyis a negyedéves (Quarter on Quarter) százalékos reál növekedés.  $Y_t$  pedig a bruttó hazai termék (GDP) termelésének 2005. évi átlagáron, szezonálisan és naptári hatással kiigazított és kiegyensúlyozott idősora. Az MNB modellezési gyakorlatát követve, a mezőgazdaság termelési hozzájárulását, annak kiugróan magas volatilitása miatt, kiszűrtük az aggregált idősorból.<sup>3</sup> Ezek után, az alábbi 1. táblázat a (3) egyenlettel definiált AR(1) modell becslésének eredményét mutatja.

<sup>1</sup>Tanulmányunkat 2019. március 4-én, vagyis 2019 első negyedévében zártuk le. Ekkor, előzetes feltevéseinknek megfelelően, a reál GDP tényértékei 1995Q1-től 2018-ig voltak elérhetőek. A későbbi eredmények és definíciók összehasonlíthatóságát szem előtt tartva, az első négy negyedév adatát kizártuk a mintából. Így  $Q = 94$ ,  $q = 1$  1996 első negyedévére,  $q = 94$  pedig 2018 negyedik negyedévre utal.

<sup>2</sup>Tanulmányunk lezárásakor a becslési eljárásban felhasznált havi adatok 1996 M1-től 2019 M2-ig voltak elérhetőek. Következésképp:  $M = 278$ ;  $m = 1$  1996M1-re,  $m = 278$  pedig 2019M2-re utal.

<sup>3</sup>Az adatok forrása a Központi Statisztikai Hivatal, az adatok 1995 Q1 és 2018 Q4 között álltak rendelkezésre a tanulmány lezárásakor. Az eredmények összevethetőséget szem előtt tartva, az első év megfigyeléseit kizártuk a minta időszakból, ami így 1996 Q1-től 2018 Q4-ig terjedt.

1. táblázat.


A benchmark AR(1) specifikáció becslési eredménye (1996 Q1 – 2018 Q4)

	Koefficiens	Sztd. hiba	t-statisztika	p-érték
$\beta_0$	0.288	0.097	2.962	0.003***
$\beta_1$	0.532	0.052	10.195	0.000***
$\sigma^2$	0.567	0.053	10.642	0.000***

Forrás: Saját szerkesztés. Szignifikancia szintek: \*(10%), \*\*(5%), \*\*\*(1%).

Az 1. táblázat eredményei alapján elmondható, hogy a becült együtthatók minden szinten szignifikánsak, a véletlen tag variancia paraméterének becslése ugyanakkor elsősre is szembeötlő: A variancia paraméter százalékpontban értelmezett nagysága alig kisebb, mint a folyamat feltétel nélküli várható értéke:  $\beta_0/(1 - \beta_1) = 0.615$ .

Az alábbi 1. ábra a negyedéves reál növekedés ( $y_t$ ) 1995 Q2-től rendelkezésre álló tényértékeit, valamint a fenti AR(1) modellbecslés alapján készített négy negyedéves előrejelzés eredményét ábrázolja, ahol az előrejelzési horizont 2019 Q1-től 2019 Q4-ig terjed.



1. ábra. Negyedéves GDP növekedés előrejelzése AR(1) modell alapján. Tényértékek: 1995 Q2 – 2018 Q4, Előrejelzési időszak: 2019 Q1 – 2019 Q4. Forrás: Saját szerkesztés KSH adatok alapján.

Tekintve, hogy tanulmányunkat 2019 március 4-én, vagyis 2019 első negyedévében zártuk

le, a 2019 Q1-re vonatkozó előrejelzés, mint valószínűségi változó kivételesnek mondható: Ez esetben ugyanis a feltételes valószínűségi eloszlás meghatározása azonos idejű információk halmaz mellett történt. Az AR(1) modell alapján képzett, ún. *naïv* nowcast számszerű eredményét az alábbiakban láthatjuk:

$$E [y_{2019Q1} | \Omega_{2019Q1}^0] = 0,833\%,$$

$$Var [y_{2019Q1} | \Omega_{2019Q1}^0] = 0,567\%p.$$

Ez esetben azért beszélünk naïv nowcastról, mert bár az előrejelzés az azonos idejű információk halmaz szerint történik, az információk halmaz mégsem tartalmaz az adott időszakhoz tartozó, az adott időszakban publikált időszaki értéket. Ehhez képest a(z)  $E[y_q | \Omega_{3q-2}^n]$ ,  $E[y_q | \Omega_{3q-1}^n]$ ,  $E[y_q | \Omega_{3q}^n]$  előrejelzéseket *valós* nowcastként tekintjük. A megfigyelt változó (negyedéves növekedés) esetében ezúttal is mintán kívüli előrejelzést készítünk, itt azonban az azonos idejű információk halmazban már ténylegesen az adott negyedévben publikált (havi) időszaki értékeket is ismerünk. A tanulmány általánosságban arra a kutatási kérdésre keresi a választ, hogy a valós idejű adatfeldolgozás irányába való elmozdulással mennyiben és hogyan javítható a GDP növekedés azonos idejű előrejelzésének (nowcastjának) minősége? A nowcast, mint valószínűségi változó minőségét két szempont alapján értékeljük: Egyrészt azt vizsgáljuk, hogy a nowcast feltételes várható értéke mennyire esik közel a nemrég (2019. május végén) publikált tényértékhez? Másrészt, arra is kíváncsiak vagyunk, hogy hogyan viszonyul egymáshoz a két típusú nowcast feltételes varianciája? A tanulmány jelenlegi változatában ugyanakkor csak az alábbi, nagyon konkrét kérdést válaszoljuk meg: Hogyan viszonyul egymáshoz a naïv és a valós nowcast eredménye 2019 első negyedévére vonatkozóan:

$$E [y_{2019Q1} | \Omega_{2019Q1}^0] \quad v \quad E [y_{2019Q1} | \Omega_{2019M2}^n],$$

$$Var [y_{2019Q1} | \Omega_{2019Q1}^0] \quad v \quad Var [y_{2019Q1} | \Omega_{2019M2}^n].$$

Vajon az  $n$  darab további magyarázó változóban levő plusz információ hogyan hat  $y_q$  feltételes eloszlására (várható érték és variancia)?

A tanulmány szerkezete a következő: A második fejezet egy rövid szakirodalmi áttekintést tartalmaz, ahol igyekszünk összefoglalni a GDP nowcastingjával kapcsolatos legfontosabb korábbi eredményeket, illetve módszertani megfontolásokat. Ezt követően, a tanulmány harmadik fejezetében leírjuk az ökonometriai vizsgálat alapjául szolgáló állapotteret modellt. A tanulmány negyedik fejezetében a becslési eljárás lépéseit ismertetjük, külön figyelmet fordítva az alkalmazott információ-tömörítési eljárás bemutatására. A tanulmány ötödik fejezetében a becslési eljárás eredményeit ismertetjük: Ábrázoljuk a becslés eredményeként kapott havi GDP növekedés idősorát, majd a mostanra már publikussá vált tényadat ismeretében értékeljük a naïv és a valós nowcast eredményét. Tanulmányunk utolsó fejezetében megfogalmazzuk a vizsgálat legfontosabb tanulságait, és igyekszünk kijelölni a kutatás további szükséges és lehetséges irányait.

## 2. Szakirodalmi áttekintés

A negyedéves és a havi frekvenciájú adatok együttes használatának egyik alapvető eszköze az ún. bridge regresszió (Baffigi és szerzőtársai, 2004). A bridge regresszió alap gondolata meglehetősen egyszerű: Első lépésben a havi mutatók aggregálásával (jellemzően számtani, vagy mértani átlag képzése) negyedéves idősorokat képzünk, majd ezt követően becsüljük a negyedéves GDP növekedés és az immáron ugyancsak negyedéves frekvencián rendelkezésre álló változók közötti regressziót. Az aktuális negyedévben már rendelkezésre álló havi adatok átlagának és a negyedéves adatokon becsült OLS regresszió eredményének ismeretében már elkészíthető az aktuális, de még nem közölt negyedév GDP adatának nowcastja. A bridge regressziók tehát egyszerű OLS specifikációkban jelennek meg, melyek az előrejelezni kívánt eredményváltozót néhány egyedi regresszorral, vagy egy mutatócsoporttal szinkronidőben kapcsolják össze. A klasszikus bridge regresszió alapuló módszer hatékonysága azonban annyiban limitált, hogy a regressziós egyenletbe bevonható magyarázó változók száma erősen: A havi közlésű makro idősorok száma eleve korlátozott, sok esetben ráadásul azok hossza sem elegendő ahhoz, hogy az alacsonyabb frekvenciájú OLS becslés eredmény megbízható legyen a standard hibák tekintetében. Mindeközben nyilvánvaló, hogy a reálgazdasági teljesítményt befolyásoló, általánosabban azzal összefüggésben álló változók száma gyakorlatilag végtelen. A bridge regresszió esetében felmerülő elsődleges gyakorlati problémát tehát az jelenti, hogy az egyedi regresszorok szerepeltetése, az idősorok közötti multikollinearitás miatt, egy idő után már erősen rontja az OLS becslés, így az előrejelzés hatását. A másik probléma az előrejelezni kívánt változónál magasabb frekvencián rendelkezésre álló adatok aggregálásával kapcsolatos: Az adatok aggregálásával egyrészt információt veszítünk, másrészt a havi adatoknak az aggregálása koránt sem magától értetődő: A negyedéves szinten becsült OLS regresszió eredménye alapján problémás lehet az utolsó („csonka”) negyedév havi adatait használni a nowcast elkészítéséhez.

Nem véletlen tehát hogy a gazdasági idősorokban lévő információ(k) összegzésének, illetve tömörítésének lehetséges módszereit számos tanulmány és szakkönyv vizsgálja. A faktoranalízis, mint látens változós módszer alap gondolata, hogy a vizsgálatba bevont nagyszámú idősor szóródása néhány mögöttes látens változóra, faktorra vezethető vissza. Amennyiben ezek a közös faktorok valóban képesek a teljes adatállomány szóródásának (varianciájának) kellően nagy arányát reprodukálni, úgy azok feltehetőleg a teljes adatállományban levő információ nagy részét sűrítik magukba: Ilyenkor a faktor modell becsülésével hatékony dimenzió csökkentést hajtunk végre. Ebben az esetben megengedhető, hogy a több tucat, vagy több száz elérhető havi indikátor helyett, figyelmünket csupán erre a néhány faktorra irányítsuk. Amennyiben pedig az adatállomány közös szóródását reprezentáló faktorok száma szerencsésen alacsony (pl. három), úgy az eredményváltozó egy egyszerű lineáris regresszióban is hatékonyan összeköthető a nagyszámú magyarázó változót reprezentáló néhány faktoral.

A releváns havi indikátorokat reprezentáló közös faktorok becsülésén (kinyerésén) túl az is problémát jelent, hogy miként aggregáljuk negyedéves szintre a meglévő havi adatokat. A különböző havi indikátorok ugyanis rendszerint eltérő időpontban kerülnek közlésre, másrészt az

sem garantált hogy az aktuális negyedévben mindhárom hónapot tekintve van adatunk. Felmerül tehát a kérdés, miként kezelhető hatékony és következetes módon a hiányzó adatok pótlása. A szakirodalom mostanra már számos technikát és modell alapú megoldást kínál a hiányzó adatok pótlására. Egyrészt létrehozhatunk egy olyan speciális (ARIMA) idősori modellt, amely az utolsó hónapokban hiányzó adatok előrejelzéséhez használható. A hiányzó adatok pótlása a faktor modell Expectation Maximization (EM) algoritmussal történő rekurzív becslésével is megvalósítható (lásd: Stock – Watson (2002a); Schumacher – Breitung (2008)). Végezetül a hiányzó értékek állapotter modellkeretben, a Kálmán-filter segítségével is jól kezelhetők (Giannone és szerzőtársai, 2008; Matheson, 2010; Rusnak, 2013).

Az elmúlt években az irodalom számos olyan modellt mutatott be, amely a növekedési ráták nowcastingjét nagyszámú rendelkezésre álló havi mutató dinamikájára alapozza. Az ez irányú kutatási kiinduló pontját Giannone és szerzőtársai (2008) munkája jelentette. Tanulmányukban a szerzők egy olyan algoritmust javasolnak, mely a havi GDP látens idősorának becslését két lépésben állítja elő: Az első lépésben a havi adatállomány közös komponenseinek (faktorainak) meghatározása történik. A dinamikus faktor modell becslése egy állapotter modell becslését jelenti. Ez után, az algoritmus második lépésében az előzőleg meghatározott közös komponensek és a havi GDP látens idősora közötti regressziós kapcsolat becslése történik (Giannone és szerzőtársai, 2008). A szerzők arra a következtetésre jutnak, hogy modelljük sikeresebb az aktuális negyedév növekedési rátájának becslésében, mint a növekedési rátákra random walkot feltételező naiv modell, valamint a Survey of Professional Forecasters (SPF) által készített további szakértői becslések. Azt is látnunk kell ugyanakkor, hogy a valós előrejelzések esetén (tehát az azonos negyedévre vonatkozó előrejelzést nem tekintve) sem a saját modelljükre alapozott, sem az SPF bármely más modelljére alapozott előrejelzés átlagos pontossága nem tudta felülmúlni a random walk eredményét. A Giannone és szerzőtársai (2008) tanulmányában bemutatott dinamikus faktormodell becselőfüggvényének aszimptotikus tulajdonságait tárgyalja Doz és szerzőtársai (2011).

Bañbura – Modugno (2010) a Giannone és szerzőtársai (2008) tanulmányában látottakhoz hasonlóan készíti GDP nowcastot, ez esetben azonban a dinamikus faktormodell becslése nem állapotter modellkeretben, hanem az Expectation maximization algoritmus segítségével történik. Fontos megjegyezni, hogy a hiányzó adatok pótlása ez úton kezelhető. A becselőfüggvény aszimptotikus tulajdonságaitól ír Doz és szerzőtársai (2012). A téma eredményeinek összegzése Bañbura és szerzőtársai (2013) tanulmányában található meg.

Számunkra mindebből az a lényeges, hogy a dinamikus faktormodell becslésének nem feltétlenül kell állapotter modellen alapulnia. Giannone és szerzőtársai (2008) munkájával ellentétben, Stock – Watson (2002a), Bañbura – Modugno (2010), Schumacher – Breitung (2008) a Kálmán-szűrő helyett a már említett Expectation Maximization algoritmust (továbbiakban: EM algoritmus) használják a látens faktorok becslésére, valamint a hiányzó adatok kezelésére (pótlására). Schumacher – Breitung (2008) német adatokon becsül havi növekedési rátákat az EM algoritmus felhasználásával.

A korábban publikált szakirodalomnak megfelelően a faktor modell alternatív változatát

javasoljuk ebben a cikkben. Az első lépésben, a Schumacher – Breitung (2008) példáját követve, használva PCA a rendelkezésre álló havi adatokra, néhány közös tényezőt becsülnek, amelyek összefoglalják az a számos rendelkezésre álló havi mutató. Ezt követően, ahogy azt Giannone és szerzőtársai (2008), a növekedési ütem a becsült tényezőket a GDP-nek egy speciális OLS előrejelzésével számolnak. A hiányzó értékeket vagy az EM algoritmussal számolják be, amint azt a Schumacher – Breitung (2008), vagy egyszerű idősoros módszerekkel. A javasolt modell előnye egyszerűbb megvalósítás, mint a Giannone és szerzőtársai (2008), mivel a tényezők becsléséhez az állami tér reprezentáció nem használható.

Tanulmányunkban alapvetően a Giannone és szerzőtársai (2008) munkájában látható becslési eljárást követjük, két fontos egyszerűsítéssel. A becslési eljárás nálunk is két lépésből: Elsőként a nowcast szempontjából relevánsnak vélt havi survey adatok információtartalmát igyekszünk tömöríteni. Ez után a havi GDP növekedés látens idősorát a Kálmán-filter segítségével kötjük össze az eljárás első lépésében meghatározott látens komponensekkel. A becslési eljárás egyszerűsítése az eljárás első fázisát érinti: A Giannone és szerzőtársai (2008) által feltételezett dinamikus faktormodell helyett egy jóval egyszerűbb módszert, a statikus főkomponens-analízist használjuk a havi változókészlet információtartalmának tömörítéséhez (az ebből adódó esetleges torzításokkal a *Becslési eljárás* c. fejezetben foglalkozunk). További egyszerűsítés az idézett irodalmakhoz képest, hogy a havi változókészlet adottságait (kovariancia mátrixát) figyelembe véve csak az első statikus főkomponenst használjuk fel a havi növekedés idősorának becsléséhez, így a nowcast elkészítéséhez. Mivel a tanulmány lezárásakor a survey adatállomány minden időszora 2019. februárig volt elérhető, ezért a hiányzó adatok kezelésével nem kellett foglalkoznunk.<sup>4</sup> A következő fejezetben a becslési eljárás második lépést megalapozó állapotter modellt írjuk le.

### 3. Modellspecifikáció

Ebben a fejezetben bemutatjuk a becslési eljárás alapjául szolgáló állapotter specifikációt. Modellünk havi frekvencián értelmezett, állapot- és megfigyelési egyenleteiben is lineáris, normális eloszlású hibtagokat feltételez. Ezek szerint a modell állapotegyenleteit az alábbi (4)–(6) egyenletek írják le:

$$x_t = c + \phi x_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2) \quad (4)$$

$$w_t = x_{t-1}, \quad (5)$$

$$q_t = w_{t-1}. \quad (6)$$

Ahol tehát  $x_t$  a havi GDP növekedés látens idősora, amire a negyedéves növekedéshez hasonlóan egy AR(1) folyamatot feltételezünk. Ezek szerint  $\phi$  a folyamat, illetve a sokk perzisztenciáját meghatározó autoregresszív paraméter,  $c/(1 - \phi)$  pedig a folyamat feltétel nélküli várható értéke. Láthatjuk továbbá, hogy az (5)-ös és (6)-os egyenletben csak segédváltozók szerepelnek,

---

<sup>4</sup>Lényegében ez a kedvező adottság is statikus főkomponens-analízis alkalmazása mellett szólt.



amik a negyedéves növekedés havi idősorának elsőrendű ( $w_t$ ) és másodrendű ( $q_t$ ) késleltetését jelölik.

Ezek után, az alábbi (7)-(8) egyenletek írják le modellünk megfigyelési egyenleteit:

$$y_t = x_t + w_t + q_t, \quad (7)$$

$$F_t = \gamma \left( w_t - \frac{c}{1-\phi} \right) + \epsilon_t, \quad \epsilon_t \sim N(0, \sigma_\epsilon^2) \quad (8)$$

ahol  $y_t$  a minden harmadik hónapban megfigyelt negyedéves (Quarter on Quarter) GDP növekedés,  $F_t$  pedig a 17, havi frekvenciájú survey időorból képzett első statikus főkomponens  $t$  időszaki értéke.

A (7) megfigyelési egyenlet valójában egy azonosságot ír le, ezért ahhoz megfigyelési hiba sem tartozik. Az összefüggés lényegében azt az ismeretünket formalizálja, miszerint a GDP egy flow természetű mutató: Ez alapján egyértelmű, hogy az adott év első három hónapjában termelt GDP-jének összege lesz egyenlő az év első negyedéves GDP értékével. Miután pedig a tényidősor logaritmusát képeztük, a negyedéves növekedés a havi növekedések összegeként adódik.

Szerepét tekintve a (8) megfigyelési egyenlet modellünk kulcsfontosságú egyenlete: Ez a megfigyelési egyenlet a havi survey adatokból képzett főkomponens értéke, valamint a havi GDP növekedés késleltetett értéke között feltételez sztochasztikus (korrelációs) kapcsolatot. Lényegében azt feltételezzük tehát, hogy a vállalatok  $t$  időszakban képzett várakozásait befolyásolja az elmúlt időszak (hónap) növekedése. A specifikációs feltevést kellően intuitívnek nevezhetjük, azonban a konkrétan alkalmazott egy havi késleltetés már problémás lehet, így a későbbiekben általánosításra szorul.

## 4. Becslési eljárás

Ebben a fejezetben előbb bemutatjuk a becslési eljárásban felhasznált havi frekvenciájú idősoros adatállományt, majd ez után röviden ismertetjük a statikus főkomponens-analízis (Principal Component Analysis, továbbiakban: PCA) módszerét: Bemutatjuk az információtömörítési (dimenziócsökkentési) eljárás mögötti intuíciót, valamint röviden az eljárás korlátait is ismertetjük. Végül definiáljuk a fentiekben leírt állapotter modellt becsléséhez használt log-likelihood függvényt.

Aktuálisnak mondható az a felismerés, miszerint a reálgazdaság ciklikus pozíciójának megítélésében sokat segíthet, ha a hivatalos statisztikák (az ún. hard adatok) mellett, esetleg azok helyett, különböző felmérések eredményeire, vagyis survey adatokra támaszkodunk. Ez a megközelítés a hazai szakirodalomban először Rácz (2012) tanulmányában jelent meg, aki Aastveit – Trovik (2008) valamint Nyman (2010) korábbi eredményeit szintetizálta. Munkájában a *Gazdaságkutató Intézet* ESI felméréseinek adataira támaszkodva igyekszik felmérni a GDP ciklikus komponensét. A Rácz (2012) tanulmányában hivatkozott ESI adatok az Eurostat honlapján ugyancsak elérhetőek, az Európai Unió fontosabb gazdasági indikátorait (Principal European

Economic Indicators, PEEIs) tartalmazó EUROIND adatbázisban. A felmérés az Európai Bizottság Gazdasági és Pénzügyi Főigazgatóságának (European Commission's Directorate General for Economic and Financial Affairs) megbízásából készül el, és a fogyasztók valamint a vállalatok jövőre vonatkozó kilátásait, optimizmusát próbálja számszerűsíteni. Az adatok minden egyes idősor esetén -100 és +100 közötti skálán mozognak. Az adatok szintje ennek megfelelően azt számszerűsíti, hogy a gazdaság szereplői hogyan ítélik meg a jelenlegi, valamint a közeljövőben várható gazdasági fejlemények alakulását (pl. a foglalkoztatási kilátásokat, vagy a beszállítói megrendelések számának alakulását). Nem kérdés, hogy a várakozások, a vállalkozói optimizmus, vagy az értéklánc szereplői közötti bizalom szintje jelentősen befolyásolhatja a makrogazdasági változók alakulását (lásd: Keynes a beruházások természetéről). Az idősoros adatállományunkat alkotó havi frekvenciájú idősorok leírását a *Függelék 3.* táblázatában láthatjuk.

A fenti (8)-as megfigyelési egyenlet specifikációját tekintve azt látjuk, hogy a becslési eljárás első szakaszában a havi idősorokban rejlő közös információ kinyerésére van szükség. Az információtömörítés (dimenziócsökkentés) alkalmas eszköze lehet a statikus főkomponens-analízis, ami azzal a feltételezéssel él, hogy az indikátorok időbeli szóródásának, változásának egy, vagy több közös meghatározó faktora van (Hajdu, 2003). A statikus főkomponens-elemzés módszere lényegében egy súlyvektort határoz meg, amellyel összesúlyozva a változókészlet minden elemét, az adott (első) főkomponens egyetlen idősorként áll elő. Az első statikus főkomponenshez tartó súlyvektor (sajátvektor) ráadásul úgy határozódik meg, hogy az eredeti változókészlet varianciájának (információtartalmának) lehető legnagyobb részét reprodukálja.

Formálisan, az elemzés célja annak a  $\beta'X$  lineáris kombinációnak az előállítása, ahol  $X$  az idősoros adatállományt tartalmazó  $m \times n$ -es mátrix,  $\beta$   $m \times 1$ -es oszlopvektor, amire  $var(\beta'X)$  maximális. Ezek szerint a megoldandó optimumfeladat:

$$\max_{\beta} [var(\beta'X)] = \max_{\beta} \beta' \Sigma \beta \quad s.t. \beta' \beta = 1$$

Amennyiben tehát elfogadjuk, hogy a változókészletben lévő információt a változók összes varianciájával mérjük, akkor azt is mondhatjuk, hogy az első főkomponens kiemelésével az információveszteség minimális lesz (Hajdu, 2003). Jegyezzük meg, hogy a fenti összefüggésben szereplő  $\beta' \beta = 1$  korlátozó feltétel nélkül, a megoldás értelemszerűen  $\beta = \infty$ , ami értelmetlen eredményre vezet. Idősoros adatállományunkat tekintve azt mondhatjuk, hogy az információtömörítés meglehetősen sikeres volt: A becslési eljárás második szakaszában használt első statikus főkomponens a változókészlet varianciájának (információtartalmának) 65%-át reprodukálja.

Meg említenünk, hogy a bár a statikus PCA alkalmazásával sok helyen találkozhatunk, idősoros adatállományok esetén problémás lehet a módszer használata. A statikus PCA fontos alapfeltevése ugyanis, hogy az eredeti (kiindulási) változókészletet reprezentáló  $X$  mátrix egyes sorai egy független azonos eloszlású, esetünkben  $1 \times n$  dimenziójú véletlen vektor realizációt tartalmazza, vagyis  $X \sim i.i.d.(0, \Sigma)$ . Ez alapján  $X$  mátrix oszlopait, mint a véletlen vektorváltozó különböző reprezentációit tekintjük. Az eljárás feltevéseit tekintve, természetesen felmerül

a kérdés: Mennyiben korrekt az eljárás idősoros adatállományon való alkalmazása? Idősoros változók esetén ugyanis mind az azonos eloszlásra, mind a függetlenségre vonatkozó feltevés problémásnak látszik. A nagyobb problémát az jelenti, ha az adatállományt generáló véletlen vektor eloszlása időben változik, vagyis (némi egyszerűsítéssel élve) nem teljesíti a gyenge stacionaritás feltételeit. Ha például az egyes idősorok varianciája időben növekvő ( $\Sigma$  mátrix nem állandó az időben), akkor az eljárás eredménye értelmezhetetlen. Kisebb problémát jelent a függetlenségi feltétel sérülése, ám a statikus PCA eredményre ez esetben is torzított, vagyis nem a maximális varianciát reprodukálja. Ez esetben az egyes idősorokra teljesülnek a gyenge stacionaritás feltételei, azonban azok között szignifikáns auto- és keresztkovariancia mérhető. A függetlenségi feltétel sérülésével fellépő probléma szemléltetéséhez gondoljunk csak az egyszerű kétváltozós esetre! Ekkor az időszaki megfigyeléseket (a realizációkat) egy-egy pont jelöli a kétdimenziós síkban. Belátható, hogy az információtömörítés szempontjából problémás, ha két pont az időbeli közelség (serial correlation) miatt kerül közel egymáshoz.

A becslési eljárás első szakaszában felhasznált havi idősorokra kivétel nélkül teljesülnek a gyenge stacionaritás feltételei (KPSS és ADF próbák egybehangzó eredménye alapján), azokra ugyanakkor szignifikáns elsőrendű autokovariancia jellemző.

Ezek után, a (4)–(8) egyenletekkel leírt állapotter modell becsülendő paramétereikhez tartozó log-likelihood függvény:

$$\log L(c, \phi, \sigma_\varepsilon^2, \gamma, \sigma_\varepsilon^2) = -\frac{T}{2} \log(2\pi) - \frac{1}{2} \sum_{t=1}^T \log |S_t| - \frac{1}{2} \sum_{t=1}^T e_t' S_t^{-1} e_t, \quad (9)$$

ahol  $S_t$  és  $e_t$  a Kálmán-filter szempontjából fontos mennyiségek:  $S_t$  egy valószínűségi vektorváltozó feltételes eloszlásához tartozó kovariancia mátrix,  $|S_t|$  pedig ennek a pozitív szemidefinit mátrixnak a determinánsát jelöli. Végül  $e_t$  a predikció  $t$  időszaki hibáját jelölő vektor. A fenti log-likelihood függvényben szereplő változók bővebb leírását, valamint a Kálmán-filter működésének részletes bemutatását lásd: Harvey (1990).

A modellt az 1996 M1-től 2019 M2-ig terjedő, ez által **278** érvényes megfigyelést tartalmazó mintán becsültük meg. Az állapotter modell becslése a Matlab beépített Econometrics Toolboxnak segítségével történt.

## 5. Becslési eredmények

A fentiekben bemutatott állapotter modell maximum likelihood becslésének eredményét az alábbi 2. táblázatban láthatjuk:


2. táblázat.

A (4)–(8) állapotter modell maximum likelihood becslésének eredménye

	Koefficiens	Sztd. hiba	t-statisztika	p-érték
$c$	0.053	0.009	6.044	0.000***
$\phi$	0.752	0.032	23.432	0.000***
$\sigma_\varepsilon^2$	0.219	0.012	19.038	0.000***
$\gamma$	5.006	0.488	10.256	0.000***
$\sigma_\varepsilon^2$	2.866	0.130	21.986	0.000***

Forrás: Saját szerkesztés. Szignifikancia szintek: \*(10%), \*\*(5%), \*\*\*(1%).

A 2. táblázat eredményei alapján mindenekelőtt azt látjuk, hogy minden paraméter becslése egyértelműen szignifikáns. A becslés eredménye alapján a látens havi GDP növekedés feltétel nélküli várható értéke 0.215%, ami nagyjából a harmada a negyedéves növekedés esetén becsült feltétel nélküli várható értéknek. Ezek után az alábbi 2. ábra a havi GDP növekedés idősorának, mint állapotváltozónak a *simított becslését* ábrázolja (Harvey, 1990).



2. ábra. A havi GDP növekedés becsült idősora (simított becslés). Minta időszak: 1996 M1 – 2019 M2. Forrás: Saját szerkesztés KSH és Eurostat adatok alapján.

A modellbecslés eredménye alapján 2019. évi első negyedéves GDP növekedésének nowcastját úgy készíthetjük el, hogy a modell (4)–(6) állapotegyenleteit egy időszakkal, konkrétan

egy hónappal tovább léptetjük. Miután  $F_t$  értékei csak 2019 februárjáig állnak rendelkezésre, ezért a (7) megfigyelési egyenletet a 2019. márciusi (látens) havi növekedés becslésekor már nem használhatjuk. Így a 2019. márciusi GDP növekedésre vonatkozó becslés esetén a predikció során kapott érték már nem változik a korrekció fázisában (Harvey, 1990). Ezek után a 2019 első negyedére vonatkozó nowcast értelemszerűen a 2019. januári, februári és márciusi havi növekedések (becslések) összegeként adódik. Lássuk tehát az előző fejezetben leírt becslési eljárás eredményeként adódó valós nowcast eredményét, a korábbi benchmark értékek feltüntetésével mellet:

Naiv nowcast:

$$E [y_{2019Q1} | \Omega_{2019Q1}^0] = 0.833\%,$$

$$Var [y_{2019Q1} | \Omega_{2019Q1}^0] = 0.567\%p$$

Valós nowcast:

$$E [y_{2019Q1} | \Omega_{2019M2}^n] = 1.553\%,$$

$$Var [y_{2019Q1} | \Omega_{2019M2}^n] = 0.552\%p$$

Ehhez képest a tényadat:  $1.5^5$

Ne feledjük: Az hogy a nowcast, mint valószínűségi változó, feltételes várható értéke közel esett a tényadathoz ugyanúgy lehet a véletlen műve, mint a modell eredménye. A modell előrejelző képességének tényleges feltérképezése mintán belüli validációt igényel.

## 6. Következtetések

Tanulmányunkban egy olyan eljárást mutattunk be, mely a magasabb (havi) frekvencián elérhető adatok információtartalmának kinyerésével érdemben segítheti a reálgazdaság teljesítményének valós idejű megítélését. A kezdeti eredmények mindenképp biztatóak: A fentiekben azt láttuk, hogy a 2019 Q1-re vonatkozó negyedéves GDP növekedés esetén a havi frekvenciájú survey adatokkal (is) dolgozó valós nowcast eredménye jóval közelebb esett a május végén publikált tényértékhez, mint a kizárólag a reál GDP tényértékeire alapozott naiv nowcast.

Ez természetesen még csak egy kezdeti eredmény, a modell validációja, vagyis a mintán belüli előrejelző képességének vizsgálata még várat magára, lényegében ez jelenti a további kutatás elsődleges tárgyát. A becslési eljárás alapját képező idősoros adatállomány bővítését is tervezzük: A survey adatok mellett természetesen a növekedés szempontjából releváns, havi frekvencián elérhető hard statisztikák (pl. ipari termelés volumenindexe) bevonása is javíthatja a nowcast minőségét. Ami a becslési eljárás megalapozottság illeti, a statikus PCA helyett előremutató lehet akár a dinamikus főkomponens-analízis, akár a dinamikus faktormodellek használata.

---

<sup>5</sup>Forrás: KSH(2019) Letöltve: [http://www.ksh.hu/docs/hun/xstadat/xstadat\\_evkozi/e\\_qpt001.html](http://www.ksh.hu/docs/hun/xstadat/xstadat_evkozi/e_qpt001.html)

## Hivatkozások

- Aastveit, K. A. – Trovik, T. (2014): Estimating the output gap in real time: A factor model approach. *The Quarterly Review of Economics and Finance*, Vol. 54. Iss. 2. 180–193. o. <http://dx.doi.org/10.1016/j.qref.2013.09.003>.
- Baffigi, A. – Golinelli, R. – Parigi, G. (2004): Bridge models to forecast the euro area GDP. *International Journal of Forecasting*, Vol. 20. No. 3. 447–460. o. [http://dx.doi.org/10.1016/s0169-2070\(03\)00067-0](http://dx.doi.org/10.1016/s0169-2070(03)00067-0).
- Bañbura, M. – Giannone, D. – Modugno, M. – Reichlin, L. (2013): Now-casting and the real-time data flow, Working Paper Series 1564, European Central Bank.
- Bañbura, M. – Modugno, M. (2010): Maximum likelihood estimation of factor models on data sets with arbitrary pattern of missing data, Working Paper Series 1189, European Central Bank.
- Benk Szilárd, Jakab Zoltán, Vadas Gábor (2005): Potential Output Estimations for Hungary: A Survey of Different Approaches. MNB Occasional Papers, No. 43. (2005. December). Letöltve: <https://www.mnb.hu/letoltes/op-43.pdf>
- Borio, C. – Disyatat, P. – Juselius, M. (2014): A Parsimonious Approach to Incorporating Economic Information in Measures of Potential Output. BIS Working Papers, No 442. Letöltve (2016. szeptember 8.): <https://www.bis.org/publ/work442.htm>
- Borio, C. – Disyatat, P. – Juselius, M. (2017): Rethinking potential output: Embedding information about the financial cycle. *Oxford Economic Papers*, 69(3), pp. 655–677. <https://doi.org/10.1093/oep/gpw063>
- Canova, F. (1998): Detrending and business cycle facts. *Journal of Monetary Economics*, 41(3), pp. 475–512. [http://dx.doi.org/10.1016/s0304-3932\(98\)00006-3](http://dx.doi.org/10.1016/s0304-3932(98)00006-3)
- Canova, F. (2007): *Methods for Applied Macroeconomic Research*. Princeton University Press.
- Doz, C. – Giannone, D. – Reichlin, L. (2011): A two-step estimator for large approximate dynamic factor models based on Kalman filtering. *Journal of Econometrics*, Vol. 164. No. 1. 188–205. o.
- Doz, C. – Giannone, D. – Reichlin, L. (2012): A Quasi-Maximum Likelihood Approach for Large, Approximate Dynamic Factor Models, *The Review of Economics and Statistics*, Vol. 94. No. 4. 1014–1024. o.
- Durbin, J. – Koopman, S. J. (2012): *Time Series Analysis by State Space Methods*, 2nd Revised Ed. Oxford Statistical Science Series.
- Galí, J. (2015): *Monetary Policy, Inflation, and the Business Cycle: An Introduction to the New Keynesian Framework and Its Applications*, 2nd ed., Princeton University Press.

- Giannone, D. – Reichlin, L. – Small, D. (2008): Nowcasting: The real-time informational content of macroeconomic data. *Journal of Monetary Economics*, Vol. 55 pp. 665-676.
- Greene, W. H. (2011): *Econometric Analysis*, 7th Ed., Pearson.
- Hajdu Ottó (2003): *Többváltozós statisztikai számítások*. Központi Statisztikai Hivatal, Budapest.
- Harvey, A. C. (1990): *Forecasting, Structural Time Series Models and the Kalman Filter*. Cambridge University Press, Cambridge. <http://dx.doi.org/10.1017/cbo9781107049994>
- Harvey, A. C. – Jaeger, A. (1993): Detrending, stylized facts and the business cycle. *Journal of Applied Econometrics*, 8(3), pp. 231-247. <http://dx.doi.org/10.1002/jae.3950080302>
- Hodrick, R. J. – Prescott, E. C. (1997): Postwar US business cycles: An empirical investigation. *Journal of Money, Credit, and Banking*, 29(1), pp. 1-16. <http://dx.doi.org/10.2307/2953682>
- Kunovac, D. – Špalat, B. (2014): Nowcasting GDP Using Available Monthly Indicators. Croatia National Bank Working Papers, W-39.
- Magyar Nemzeti Bank (2017): *Inflációs jelentés (2017. december)*. Budapest, MNB. Letöltve: <https://www.mnb.hu/letoltes/hun-ir-11.pdf>
- Matheson, T. D. (2010): An analysis of the informational content of New Zealand data releases: The importance of business opinion surveys. *Economic Modelling*, Vol. 27. No. 1. 304-314. o.
- Mellár Tamás (2011): *Néhány gondolat a makroegyensúly értelmezéséhez*. KRTI Műhelytanulmányok, No. 2. PTE KTK, Pécs.
- Nyman, C. (2010): An indicator of resource utilisation. *Sveriges Riksbank Economic Commentaries*, No. 4. [https://www.riksbank.se/globalassets/media/rapporter/ekonomiska-kommentarer/fore-2017/engelska/2010/rap\\_ek\\_kom\\_nr4\\_101013\\_eng.pdf](https://www.riksbank.se/globalassets/media/rapporter/ekonomiska-kommentarer/fore-2017/engelska/2010/rap_ek_kom_nr4_101013_eng.pdf)
- Pintér József (2007): A spektrálanalízisről. *Statisztikai Szemle*, 85. évf. 2. sz. pp. 130-156.
- Rácz Olivér Miklós (2012): A gazdaság ciklikus pozíciójának megítélése bizalmi indikátorok segítségével. *MNB-Szemle*, 2012. június. pp. 41-46. Letöltve: <https://www.mnb.hu/letoltes/racz-1.pdf>
- Rusnak, M. (2013): *Nowcasting Czech GDP in Real Time*. Working Papers 2013/06, Czech National Bank, Research Department.
- Schumacher, C. – Breitung, J. (2008): Real-time forecasting of German GDP based on a large factor model with monthly and quarterly data, *International Journal of Forecasting*, Vol. 24. No. 3. 386-398. o.

Stock, J. H. – Watson, M. W. (2002a): Macroeconomic Forecasting Using Diffusion Indexes, *Journal of Business & Economic Statistics*, American Statistical Association, Vol. 20. No. 2. (April) 147–162. o.

Stock, J. H. – Watson, M. W. (2002b): Forecasting Using Principal Components from a Large Number of Predictors, *Journal of the American Statistical Association*.

## Függelék

3. táblázat.

A főkomponens-elemzésben felhasznált változók listája – Havi adatok. Minta: 1996M01 – 2019M02

Változó neve, tartalma	Szektor	Kód
A termelés alakulása az elmúlt 3 hónapban	ipar	Ind_m01
Foglalkoztatási kilátások a következő három hónapban	ipar	Ind_m02
Rendelésállomány értékelése	ipar	Ind_m03
Export megrendelések értékelése	ipar	Ind_m04
Saját termelésű készletek értékelése	ipar	Ind_m05
Termelési kilátások a következő három hónapban	ipar	Ind_m06
Ipari bizalmi index	ipar	Ind_m07
Építési tevékenység alakulása az elmúlt 3 hónapban	építőipar	Constr_m01
Evolution of the current overall order books	építőipar	Constr_m02
Foglalkoztatási kilátások a következő három hónapban	építőipar	Constr_m03
Építőipari bizalmi index	építőipar	Constr_m04
Üzleti tevékenység (bevétel) alakulása az elmúlt 3 hónapban	kiskereskedelem	Ret_m01
Jelenlegi készletszint nagysága	kiskereskedelem	Ret_m02
A beszállítói megrendelések számának várható alakulása a következő három hónapban	kiskereskedelem	Ret_m03
Üzleti tevékenység (bevétel) várható alakulása a következő három hónapban	kiskereskedelem	Ret_m04
Foglalkoztatási kilátások a következő három hónapban	kiskereskedelem	Ret_m05
Kiskereskedelmi bizalmi index	kiskereskedelem	Ret_m06