# Riksbankens nya indikatorprocedurer

Michael K. Andersson och Mårten Löf
Författarna har doktorerat i ekonometri och är verksamma vid Riksbankens prognosenhet.

*De senaste åren har centralbanker världen över intresserat sig allt mer för formella modeller i prognos- och analysarbetet. Detta gäller såväl strukturella makromodeller som rena tidsseriemodeller. Riksbanken använder i prognosarbetet båda dessa modelltyper, tillsammans med traditionella bedömningsprognoser. Denna artikel syftar till att beskriva den senare typen av modeller. Förutom en genomgång av olika modellprocedurer redovisas också en prognosutvärdering. Resultatet tyder på att de indikatoransatser som presenteras här kan bidra till mer precisa prognoser än vad enklare modellspecifikationer ger.*

## 1. Inledning

De prognoser som presenteras i Riksbankens penningpolitiska rapporter (inflationsrapporter före 2007) är resultatet av prognoser från en strukturell makromodell, olika tidsseriemodeller samt bedömningar av ekonomer. Styrkan hos en strukturell modell, där ett antal teoretiska samband förutsätts gälla, är att modellens prognoser är lätta att tolka.[1] De teoretiska sambanden kan dock avvika från korrelationer i data, vilket kan medföra att modellens prognosförmåga blir lidande för enskilda variabler. Av detta skäl är det nödvändigt att justera den strukturella modellens prognoser. Det kan göras genom expertbedömningar eller med hjälp av alternativa prognoser från tidsseriemodeller (indikatormodeller) som inte ställer samma krav på att variablerna uppfyller de teoretiska sambanden. Olika utvärderingar tyder på att den senare typen av modeller – som i princip bara gör extrapoleringar av de mönster som finns i historiska data – framförallt är användbara för att göra prognoser på kort sikt, se t.ex. Galbraith och Tkacz (2006). Tidsseriemodeller kan därför ses som ett komplement till traditionella bedömningsprognoser på korta prognoshorisonter. Denna artikel syftar till att på ett relativt otekniskt sätt beskriva de indikatormodeller som utvecklats vid Riksbankens penningpolitiska avdelning under de tre senaste åren.

[1] Riksbanken har genom åren använt ett antal makromodeller. Den modell som i dagsläget används är en s.k. allmän jämviktsmodell, se Adolfson m.fl. (2005a) och fördjupningsrutan "RAMSES – ett verktyg för penningpolitisk analys", i Penningpolitisk rapport 2007:1.

Statistiska procedurer som används för att systematiskt utnyttja informationen i stora datamängder har under de senaste åren presenterats inom forskningen, se bl.a. Stock och Watson (2002, 2004) och Bernanke och Boivin (2003). Inom centralbanksvärlden utnyttjas den typen av procedurer ännu relativt sällan i prognosarbetet. Förutom Riksbanken utmärker sig Bank of England och Bank of Canada som användare av sådana procedurer. Dessa centralbanker använder en mängd olika modellansatser, alltifrån enkla univariata tidsseriemodeller till väldigt sofistikerade multivariata icke-linjära modeller.[2] Trots den stora mängden modeller är procedurerna lätthanterliga och i hög grad automatiserade, se Kapetanios m.fl. (2006).

I avsnitt 2 presenteras de indikatorprocedurer som används av Riksbanken i nuläget.[3] De olika modellernas prognosförmåga utvärderas i avsnitt 3. Avsnitt 4 visar en alternativ användning av indikatorinformation. Artikeln avslutas med en sammanfattning i avsnitt 5.

## 2. Riksbankens statistiska indikatormodeller

I detta avsnitt presenteras några av de tidsserieprocedurer Riksbanken använder som stöd i prognosprocessen. Procedurerna används huvudsakligen för prognoser på kort sikt – ca ett år framåt i tiden. Inledningsvis presenterar vi den modell som utgör grunden i de ansatser som beskrivs här. Därefter gör vi en kort genomgång av indikatormodellerna. Procedurerna som presenteras här kan användas på månads-, kvartals- och årsdata. I kapitel 3 utvärderas prognosförmågan på kvartalsvis observerade mätningar av bruttonationalprodukten (BNP) och underliggande inflation (UND1X). Procedurerna är inte designade för endast dessa variabler utan kan lika gärna tillämpas på t.ex. konjunkturutveckling i omvärlden eller olika räntor. I kapitel 3 presenteras även resultaten från en utvärdering av prognoser på månadsförändringar i konsumentprisindex (KPI).

De procedurer som beskrivs är utvecklade vid Riksbankens penningpolitiska avdelning och är programmerade i Compaq Visual Fortran 6.0 och i Eviews 4.5. Programmen är helt automatiska och kräver en ytterst liten arbetsinsats vid varje prognostillfälle. Procedurerna utvecklas kontinuerligt och används av ekonomerna som stöd i bedömningen på kort sikt.

### 2.1 Den vektorautoregressiva (VAR) modellen

Ekonometriska modeller använder korrelationer i data för att beskriva samband mellan variabler och samband mellan en variabel och tidigare (dvs. laggade) observationer på samma variabel. Den senare typen av

[2] I en univariat specifikation ingår endast en variabel. I en multivariat modell ingår flera variabler.
[3] Med procedurer avses en systematisk hantering av flera statistiska modeller.

samband beskrivs av en autoregressiv (eller självregressiv) specifikation. En autoregression (AR) kan skrivas:

$$y_t = \beta_0 + \beta_1 y_{t-1} + u_t, \tag{1}$$

där $y_t$ är värdet på variabel $y$ i period $t$ och $u$ är en slumpmässigt fördelad felterm.[4] Ekvation (1) visar att variabel $y$ i period $t$ beror på sig själv i föregående period. Modellen kallas för en autoregression av ordning ett, AR(1). En autoregression kan utökas till att bero av mer avlägsna observationer, liksom att fånga beroenden mellan variabler. En enkel utvidgning av ekvation (1), där en annan variabel *x* tillåts påverka *y,* ges av följande specifikation:

$$y_t = \beta_0^y + \beta_1^y y_{t-1} + \beta_2^y x_{t-1} + u_t^y. \tag{2}$$

På motsvarande sätt kan även variabel $x$ modelleras:

$$x_t = \beta_0^x + \beta_1^x y_{t-1} + \beta_2^x x_{t-1} + u_t^x. \tag{3}$$

Om ekvationerna (2) och (3) kombineras i ett system av ekvationer erhålls en modell där både *y* och *x* beror på tidigare värden av sig själva och varandra. Specifikationen kallas då för en vektorautoregression (VAR).

## 2.2 Hantering av stora datamängder

De flesta av procedurerna använder en stor mängd tidsserier. Eftersom det inte går att skatta modeller med för många ingående variabler (antalet observationer måste överstiga antalet skattade parametrar), måste modellernas storlek reduceras.[5] Denna reduktion kan ske genom att informationen sammanfattas i några få gemensamma faktorer, se beskrivning i avsnitt 2.5 nedan. Ett annat sätt att hantera stora datamängder är att skatta många små modeller.

## 2.3 Klassiska VAR-modeller

Riksbankens klassiska VAR-procedur skattar en mängd unika VAR-modeller (kombinationer) utifrån datamaterialet. Dessa VAR-modeller sammanfattar korrelationen i de serier som ingår i respektive system och beaktar ingen ytterligare information. Ur kollektionen av de skattade modellernas prognoser kan den bästa modellen, enligt historiska prognosfel, genom-

---

[4] Vid skattning av modellen förutsätts att de ingående serierna är stationära, dvs. att deras medelvärde och varianser är stabila, och att slumptermen är stokastiskt fördelad med konstant varians. Icke-stationära serier modelleras som förändringstakter, $\Delta y_t = y_t - y_{t-1}$, vilket ger att ekvation (1) då får följande utseende: $\Delta y_t = \varphi_0 + \varphi_1 \Delta y_{t-1} + \eta_t$.

[5] Ju större kvantiteten observationer minus skattade parametrar är desto pålitligare blir skattningarna.

snittet av alla modellprognoser eller olika trimmade medelvärden beräknas.[6] Den klassiska VAR-proceduren kan betingas på kända utfall på vissa indikatorvariabler under prognosperioden om så önskas.

I ett exempel nedan kommer modeller av typen ekvation (2) och (3) att skattas för att prognostisera bruttonationalprodukten (BNP). Modellerna inkluderar BNP samt en till tre ytterligare variabler.[7]

## 2.4 Bayesianska VAR-modeller

Även för de Bayesianska VAR-modellerna är här den bärande tanken att använda många mindre modeller för att utnyttja informationen i stora dataset. Till skillnad från klassiska VAR-modeller kan Bayesianska modeller inkludera subjektiva omdömen eller erfarenheter med hjälp av s.k. *priors*.[8] För ekvationssystemet (2) och (3) innebär det att analytikern kan ha en uppfattning om koefficienternas och slumptermernas egenskaper och (eventuellt) hur stor vikt de olika modellerna bör ges vid en sammanvägning. Priorn uppdateras sedan med information från data. När alla modellprognoser vägs ihop beaktas hur viktig respektive modell är enligt de uppdaterade vikterna. Detta förfarande kallas Bayesiansk modellsammanvägning, BMS.[9]

## 2.5 VAR-modeller med faktorer

Fluktuationer i enskilda variabler behöver inte alltid innehålla signaler som är relevanta för den ekonomiska aktiviteten på aggregerad nivå. Ett alternativt sätt att sammanfatta informationsinnehållet i stora datamängder, och samtidigt reducera variabelspecifikt "brus", är att med hjälp av statistiska metoder försöka summera den del av variationen i datamaterialet som är gemensam för alla variabler i en eller några få faktorer. Istället för att generera och sammanfatta prognoser från en mängd olika modellkombinationer (se avsnitt 2.3 och 2.4) försöker man här först sammanfatta datamaterialet i några få faktorer och sedan modellera dessa tillsammans med prognosvariabeln i en VAR-modell. Faktoransatsen beskrivs av Stock och Watson (2002).[10]

---

6 Den bästa modellen i detta sammanhang är en modell som är bäst enligt någon utvärdering och den behöver inte vara bäst i framtiden. Ett trimmat medelvärde kan vara att helt bortse från den kvartil modeller som genererar de sämsta prognoserna.

7 Datamaterialet består av BNP och ytterligare 108 variabler. Ur detta material kan 108 olika modeller där BNP ingår skapas. När man tillåter för modellering av tre variabler (BNP samt två ytterligare variabler) i systemet ges 5778 unika modeller (kombinationer).

8 Kadiyala och Karlsson (1997) beskriver Bayesianska VAR-modeller. Här används Littermans (1986) prior som innebär att i förväntan kommer stationära serier antas följa ekvation (1) med $\beta_1 = 0{,}9$ och icke-stationära serier (dvs. stationära i differensform) antas följa $\Delta y_t = \varphi_0 + \eta_t$. En poäng med detta Bayesianska förfarande är att mycket av det brus som finns i serierna reduceras. I skattningen uppdateras priorn med information från data.

9 För information om Bayesiansk modellsammanvägning se t.ex. Coop (2003).

10 Här används principalkomponentanalys för att ta fram s.k. statiska faktorer. Den j:te skattade faktorn, baserad på N stycken serier, har utseendet $\hat{f}_{j,t} = \hat{\lambda}_{j,1} x_1 + \mathrm{K} + \hat{\lambda}_{j,N} x_N$, där faktorladdningarna $\hat{\lambda}_{j,i}$ beskriver hur stor vikt variabel *i* har vid konstruktionen av den *j*:te faktorn.

## 2.6 Modeller som beaktar tidig information

Modeller av den typ som ekvationssystem (2) och (3) beskriver använder endast tidigare observationer för att förklara dagens utfall. Ofta existerar dock indikatorinformation som sträcker sig längre fram än den senaste observationen på prognosvariabeln. Ett exempel kan vara omsättningen i detaljhandeln, som är känd ca en månad innan ett nytt BNP-utfall presenteras. Ett annat exempel är Konjunkturinstitutets framåtblickande barometerserier. I de procedurer som beskrivits så här långt kan tidig information beaktas genom att modellernas prognoser betingas på dessa tidiga utfall. En mer direkt hantering av sådan information är att tillåta för ett beroende mellan huvudvariabeln ( $y$ ) och indikatorvariabeln ( $x$ ) i samma tidpunkt. Ekvation (2) får då följande utseende:

$$(4) \quad y_t = \beta_3^y + \beta_4^y y_{t-1} + \beta_5^y x_t + \beta_6^y x_{t-1} + u_t^1 .$$

Ekvation (4) består således av en autoregressiv del (egenlaggar av *y*) och en del som beror av indikatorvariabeln. Den autoregressiva delen kan exkluderas för att renodla informationen från indikatorvariabeln, vilket ger:

$$(5) \quad y_t = \beta_7^y + \beta_8^y x_t + \beta_9^y x_{t-1} + u_t^2 .$$

## 2.7 Komponentmodeller för inflationsprognoser på kort sikt

För vissa delindex (komponenter) i konsumentprisindex (KPI) har man tillgång till specifik information någon eller några månader framåt i tiden. Ett exempel är drivmedelspriser som är kända ca en månad innan nya inflationssiffror publiceras. Andra exempel är bostadsräntor och elpriser som också ingår som delindex i KPI. Om de olika komponenterna i KPI hanteras separat kan det vara lättare att inkludera sådan särskild information. I komponentmodellen genereras prognoser för ett antal delindex med hjälp av AR-ekvationer. Tidsseriemodellerna för de olika komponenterna utökas i detta exempel med säsongsdummys ( $D$ ) för att modellera ofta markerade säsongsvariationer som ser olika ut för olika delindex ( $y^d$).

$$(6) \quad y_t^d = \beta_0^d + \sum_{i=1}^{p} \beta_i^d y_{t-i}^d + \sum_{s=1}^{1} \lambda_s^d D_{s,t} + u_t^d$$

I de fall man har tillgång till tidigt publicerad specifik information ( $x$ ) som är högt korrelerad med en viss komponent så utökas ekvationen ytterligare.

$$(7) \quad y_t^d = \beta_0^d + \sum_{i=1}^{p} \beta_i^d y_{t-i}^d + \delta^d x_t + \sum_{s=1}^{1} \lambda_s^d D_{s,t} + u_t^d$$

Ekvation (7) visar att delar av komponentmodellen bygger på modellen som presenterades i avsnitt 2.6. I modellspecifikationen som utvärderas nedan genereras prognoser på elva undergrupper i KPI. Information om bostadsräntor, bensinpriser och elpriser antas vara kända en månad innan KPI-utfallet publiceras och används som indikatorer för att prognostisera tre delindex enligt ekvation (7).[11] Prognoser på månadsförändringar i övriga delindex genereras med ekvation (6) ovan. Prognoserna multipliceras med vikten för respektive delindex för att få ett bidrag till månadsförändringen i hela KPI. Dessa bidrag summeras sedan för varje prognoshorisont.

## 3. Prognosförmåga

För att få en uppfattning om hur väl de olika modellerna fungerar *i genomsnitt* är det informativt att genomföra en prognosutvärdering där man sparar data för en viss period i slutet av stickprovet och sedan utvärderar modellernas prognoser mot utfallen under samma period. För varje modell görs prognoser ett till åtta kvartal framåt och för månadsdata en till tolv månader framåt. För de ansatser som inkluderar flera modeller beräknas sedan medelvärdet av alla prognoser.[12] Därefter utökas skattningsperioden med en observation och övningen upprepas på samma sätt. Detta ger en uppsättning prognoser för vilka den genomsnittliga träffsäkerheten kan uppskattas.[13] Detta görs med hjälp av roten ur medelkvadratfelet (RMKF), som sammanfattar hur prognosfelens spridning och systematiska avvikelse förhåller sig.[14] Ju lägre skattad RMKF desto bättre är prognosförmågan. En prognos som alltid träffar rätt har ett RMKF lika med noll.

Utöver RMKF beaktas även prognosernas maximalt användbara horisont (dvs. modellernas minne). Minnesberäkningen utnyttjar det faktum att prognosernas RMKF går mot seriens standardavvikelse då

---

[11] Index för räntekostnader, oljeprodukter samt elpriser. Respektive indikator i detta exempel är medelvärdet av tre korta bostadsräntor, Statoils priser på 95-oktanig bensin samt ett medelvärde av tre tillsvidarepriser på el (Vattenfall, E.on och Fortum). För prognoser längre fram än en månad antas indikatorerna vara oförändrade i prognosutvärderingen.

[12] I fördjupningrutorna "BNP-indikatorer", i Inflationsrapport 2005:3 och "Inflationsindikatorer", i Inflationsrapport 2006:3, utvärderas även den modell som är bäst vid varje tidpunkt. Resultaten visar att de i genomsnitt bästa prognoserna erhålls om man beaktar alla modeller (i form av ett medelvärde) jämfört med att hela tiden använda den modell som man *för stunden tror* är bäst. Eftersom proceduren rangordnar alla modeller efter prognosförmåga kan t.ex. medelvärdet av de 50 % bästa modellerna beräknas. Olika trimningar av modellprognoserna har undersökts, men generellt ger medelvärdet av alla modeller en över tiden stabil och svårslagen prognos.

[13] I ett första steg skattas modellerna på data från tredje kvartalet 1991 till fjärde kvartalet 1998. Ur kollektionen av modeller beräknas genomsnittet av samtliga modellprognoser upp till åtta kvartal in i framtiden. Dessa prognoser, dvs. 1999:1 till 2000:4, sparas. Därefter skattas alla modeller om på data 1991:3 till 1999:1 och medelvärdet av alla nya modellprognoser upp till åtta kvartal framåt registreras. Denna procedur upprepas till dess att observationerna tar slut. I sista steget skattas modellerna t.o.m. 2006:1. Övningen ger 31 enstegsprognoser (ett kvartal framåt), 30 tvåstegsprognoser o.s.v. Från dessa prognoser och motsvarande utfall beräknas sedan mått på prognosprecisionen.

[14] $RMKF(h) = \sqrt{\sum_{t=\tau_1}^{\tau_2} \left( y_{t+h} - y_{t+h}^{pred} \right)^2 / (\tau_2 - \tau_1 + 1)}$. Där $y_{t+h}$ är utfall i tidpunkt *t+h* och $y_{t+h}^{pred}$ är prognos för tidpunkt *t+h* gjord i *t*. *h* är prognoshorisonten.

horisonten förlängs, för den typen av modeller som används här. En matematisk beskrivning av relationen mellan RMKF och standardavvikelse ges i appendix. För en sämre modell kan RMKF även överstiga variabelns standardavvikelse. I denna studie definieras modellens minne som den längsta prognoshorisont där RMKF är lägre än seriens standardavvikelse.

RMKF ger en uppskattning av hur väl en prognosmetod fungerar i genomsnitt men ger långt ifrån hela bilden. Ett sätt att få ut mer information om prognoserna är att rita ett diagram för prognosfelen över tiden. I denna artikel redovisas prognosfel för horisonten ett kvartal respektive en månad framåt på detta sätt.

De modeller som används förutsätter stationära serier, dvs. konstant medelvärde och varians. Stationära serier modelleras i nivåer och icke-stationära serier i första differenser, vilket innebär kvartalsvisa eller månatliga förändringstakter. Vid utvärderingen har sedan prognoserna räknats om till årlig procentuell förändring.

### 3.1 Utvärdering av kvartalsprognoser på BNP

I detta avsnitt utvärderas procedurernas kvartalsvisa prognoser för årlig procentuell tillväxt av BNP för perioden 1999:1 - 2006:3. I utvärderingen används ett datamaterial som inkluderar 108 indikatorserier, se tabell 1. Resultaten redovisas i tabell 2. Förutom medelvärdesprognosen från de indikatorprocedurer som beskrivits ovan visas även resultat från en autoregressiv modell, se ekvation (1), och en slumpvandringsmodell.[15] I en slumpvandringsmodell får det senast kända utfallet utgöra prognoser på alla horisonter.

Resultaten i tabell 2 visar att samtliga modellansatser ger mer träffsäkra prognoser än slumpvandringen, och de olika indikatorprocedurerna uppvisar ungefär samma träffsäkerhet. Precisionen, mätt som RMKF, uppgår till just under 0,4 procentenheter för BNP-prognoser ett kvartal framåt i tiden och ungefär 0,7 procentenheter två kvartal framåt. Om prognosfelen följer normalfördelningen kommer alltså ett prognosintervall med bredden 1,6 procentenheter att i 95 procent av fallen inkludera BNP-utfallet för nästa kvartal.[16] Utvärderingen visar att autoregressionen endast är marginellt sämre än VAR-proceduren. Att autoregressioner står sig relativt väl mot mer sofistikerade ansatser är ett välkänt resultat från forskningen. Två studier som visar detta är gjorda av Stock och Watson (2004, 2005).

---

[15] Den autoregressiva modellen är av samma typ som ekvation (1) men laglängden tillåts vara längre än ett om det finns ett längre beroende i data.

[16] Givet normalfördelningen ges det 95-procentiga konfidensintervallet av $y_{t+h}^{pred} \pm 1.96 \times 0,4$ , där 0,4 = RMKF.

Storleken på indikatormodellernas prognosfel är alltså påtaglig, men ändå mindre än för motsvarande prognoser från strukturella modeller. Detta visas exempelvis av Del Negro m.fl. (2005).[17] Exempelvis uppgår RMKF för prognoserna ett kvartal framåt i Riksbankens strukturella modell till ca 0,5 procentenheter. Indikatormodellerna har ungefär samma precision som Riksbankens publicerade prognoser ett till fyra kvartal framåt i tiden.

Rent teoretiskt ska RMKF öka i takt med att prognoshorisonten förlängs och när modellen inte längre bidrar med någon information ska RMKF stabiliseras kring seriens standardavvikelse. För utvärderingen av indikatormodellerna gäller att prognosernas RMKF i stort sett sammanfaller med standardavvikelsen för BNP när prognoshorisonten är ungefär fyra kvartal. Tidsserie- och indikatormodeller har alltså sin huvudsakliga användning för BNP-prognoser på kort sikt och i bästa fall ett år framåt i tiden.

Kolumnerna 7 och 8 i tabell 2 visar prognosprecisionen för de modeller som utnyttjar tidig information som beskrevs i avsnitt 2.6. Resultaten visar att de modeller som utnyttjar den autoregressiva dynamiken i BNP gör prognoser som är jämförbara med de övriga indikatorprocedurerna och att modeller som bara bygger på korrelationer mellan BNP och övriga variabler är sämre. Detta indikerar att den autoregressiva delen är viktig då man vill göra bästa möjliga prognos. Dock kan även modeller utan en autoregressiv del ibland vara av (kvalitativt) intresse eftersom de renodlar informationen från de övriga variablerna.

Jämfört med en autoregression är VAR-modellerna genomgående bättre, se diagram 1 som visar prognosfelen ett kvartal framåt. Den största skillnaden i prognosfel gäller prognoser för tredje kvartalet 2005. AR-prognosen gör då ett stort prognosfel vilket beror på en oväntat stark konjunkturutveckling. VAR-modellerna som beaktar information utöver BNP själv ger en prognos som uppvisar hälften så stort fel. Detta visar att mer sofistikerade procedurer kan vara värdefulla vid speciella tidpunkter.

## 3.2 Utvärdering av kvartalsprognoser för UND1X-inflationen

I likhet med i utvärderingen av BNP-prognoser ovan, så används kvartalsvisa observationer för att utvärdera procedurernas prognosförmåga för UND1X. Datamaterialet beskrivs i tabell 1. Utvärderingsperioden är 1999:1-2006:3 även här.

[17] En rättvisande jämförelse mellan svenska och amerikanska data kräver egentligen att man i beräkningen av standardavvikelserna tar hänsyn till att BNP-tillväxten i de bägge länderna inte har samma variabilitet (det är förstås lättare att göra prognoser för en variabel som utvecklas mer stabilt). Eftersom USA:s BNP-tillväxt i genomsnitt varierar mindre än Sveriges förstärker en sådan jämförelse slutsatsen att tidsserie- och indikatormodeller gör bättre prognoser än strukturella modeller.

Av tabell 2 framgår att de olika ansatserna ger prognoser med ungefär samma träffsäkerhet, åtminstone för prognoser på kort sikt. RMKF uppgår till runt 0,4 procentenheter för UND1X-prognoser ett kvartal framåt och till ungefär 0,5-0,6 för prognoser två kvartal framåt. Samtliga utvärderade modeller har genomgående en högre träffsäkerhet än prognoser från en slumpvandring. De sofistikerade procedurerna uppvisar även här en prognosprecision som på korta horisonter är aningen bättre än autoregressionens.

Vid en jämförelse av RMKF för UND1X-prognoser och seriens standardavvikelse, som är just över 0,8, kan man konstatera att procedurernas prognosminne är tre till fyra kvartal, vilket innebär att indikatormodellerna har sin huvudsakliga användning för UND1X-prognoser upp till ett år framåt i tiden.

Diagram 2 visar UND1X-prognoser från VAR-proceduren och autoregressionen ett kvartal framåt. Under det andra kvartalet 2001 ökade UND1X-inflationen ganska dramatiskt, vilket bl.a. hängde ihop med stora och oväntade fluktuationer i matpriserna, till följd av galna ko- och mul- & klövsjukan. Ökningen i UND1X kunde inte heller fångas av indikatormodellerna och prognosfelen var stora. I diagram 2 är det dock tydligt att modeller som beaktar information utöver UND1X fungerar betydligt bättre än en autoregression. Det innebär att det fanns information i indikatorerna som pekade på en stigande inflationstakt. Resultat från forskningen tyder på att indikatorinformation, som inte inkluderas i en autoregression, kan vara särskilt användbar då speciella händelser inträffar, se resultat av Stock och Watson (2004, 2005). Detta är helt i linje med exemplet i diagram 2.

Diagram 2 visar också att indikatorinformation förbättrade prognoserna första och andra kvartalet 2003. Under första kvartalet blev energipriserna överraskande höga för att sedan sjunka tillbaka under andra kvartalet. VAR-proceduren gav då noterbart bättre prognoser.

### 3.3 Utvärdering av månadsprognoser för KPI-inflationen

I utvärderingen nedan jämförs prognoser från komponentmodellen (KM) med AR-prognoser samt genomsnittsprognoser från bivariata klassiska VAR-modeller (se avsnitt 2.3). I datamaterialet för VAR-modeller ingår 33 månatligt observerade indikatorer, förutom KPI-inflationen, se tabell 1. Utvärderingsperioden är januari 2002 till november 2006 och prognoshorisonten är en till tolv månader framåt. Prognosförmågan utvärderas med hjälp av RMKF. Resultaten i tabell 3 visar att samtliga modellansatser ger mer träffsäkra prognoser än slumpvandringen. AR-modellen genererar sämre prognoser än komponentmodellen och genomsnitts-

prognoser från de bivariata VAR-modellerna. Komponentmodellen, som inkluderar specifik information, ger de lägsta prognosfelen upp till åtta månader framåt. Därefter ger VAR-modellerna de mest träffsäkra prognoserna.

De stora prognosfelen 2003 för UND1X-inflationen i diagram 2 kan även noteras för KPI-inflationen mätt på månadsfrekvens. Komponentmodellen som inkorporerar information om energipriserna uppvisar under de första månaderna 2003 nästan inga prognosfel alls, se diagram 3. Även VAR-proceduren genererar klart bättre prognoser jämfört med en enkel autoregression. I början av 2004 uppvisar VAR-modellernas genomsnittsprognos och komponentmodellens prognos också betydligt mindre prognosfel än autoregressionen. Den låga KPI-inflationen berodde då på låga energi- och livsmedelspriser som autoregressionen inte kunde prognostisera. Återigen visar resultaten att mer sofistikerade procedurer kan vara till stor nytta i specifika situationer.

## 4. En omvänd användning av ekonomiska indikatorserier

### 4.1 Procedurbeskrivning

Eftersom de prognoser som publiceras i de penningpolitiska rapporterna är en komplicerad funktion av olika modeller och bedömningar är det svårt att bedöma hur nya utfall på en indikator borde påverka prognoserna. Ett sätt att komma runt detta problem är att bilda sig en uppfattning om hur indikatorn borde falla ut, givet den prognos som är aktuell för tillfället. Den eventuella differensen mellan prognosen och utfallet på indikatorserien kan ge information om revideringsriktningen på prognosvariabeln. Ett enkelt sätt att bilda sig en uppfattning om indikatorvariabeln, givet en prognos på en huvudvariabel, är att utnyttja det historiska sambandet mellan variablerna, vilket ger följande specifikation:

$$x_t = \alpha_0 + \alpha_1 x_{t-1} + \alpha_2 y_{t-1} + \beta y_t + u_t^x . \tag{8}$$

Skillnaden mellan ekvation (4) och ekvation (8) är att den förra används för att göra prognoser på en huvudvariabel givet en indikatorvariabel, och att den senare används för att göra prognoser på indikatorvariabeln givet huvudvariabeln. Ekvation (8) beskriver således en omvänd användning av indikatorserier där en prognos på $y_{t+1}$ utnyttjas för att göra en prognos på $x_{t+1}$. Riksbankens procedur för omvänd användning av indikatorserier är Bayesiansk och tillåter åsikter om parametrarna i ekvation (8). I huvudsak har analytikern en uppfattning om huruvida det samtida sambandet mellan indikatorvariabeln och huvudvariabeln är positivt eller negativt.

När ett nytt indikatorutfall registreras jämförs det med prognosen på samma variabel enligt ekvation (8). Om utfallet är högre än prognosen (och $\beta$ är positiv) så ger det en indikation på att prognosen för $y_{t+1}$ borde ha varit högre. I proceduren registreras då ett plustecken (revidering uppåt av huvudvariabeln) tillsammans med sannolikheten för revideringen uppåt (en sannolikhet över 50 procent ger ett plustecken och en sannolikhet under 50 procent ger ett minustecken, dvs. en revideringstendens nedåt). Om detta förfarande appliceras på flera indikatorserier får man en samling tendenser för revideringsriktningen, med tillhörande sannolikheter. Detta ger en samlad objektiv bild av hur huvudvariabeln bör revideras.

### 4.2 Ett exempel på omvänd användning av indikatorserier

Samma utfallsserie på BNP användes i Inflationsrapporterna 2005:3 och 2005:4. Däremellan publicerades Konjunkturinstitutets kvartalsbarometer. Den omvända användningen antydde att barometerutfallen var starkare än vad som förväntades givet BNP-prognosen i Inflationsrapport 2005:3 och det historiska sambandet mellan BNP och barometerserierna. Diagram 4 visar resultatet från den omvända analysen. Ett 95-procentigt sannolikhetsintervall för uppåtrevidering av BNP-prognosen täckte inte 0,5, vilket tolkades som att kvartalsbarometern starkt signalerade att BNP-prognosen borde revideras uppåt. I Inflationsrapport 2005:3 var prognosen för BNP 0,76 procent. Prognosen reviderades till 0,88 procent i inflationsrapport 2005:4, bl.a. med stöd av den omvända indikatoranalysen. Utfallet som senare publicerades var 0,95 procent.

## 5. Sammanfattning

Resultaten i denna artikel visar att prognoser är behäftade med en påtaglig osäkerhet. Vidare antyder resultaten att den enkla autoregressiva modellen gör prognoser som i genomsnitt står sig väl jämfört med mer sofistikerade prognosmetoder. Det kan dock noteras att indikatorprocedurerna som presenterats under speciella perioder kan bidra till mer precisa prognoser än autoregressionen. Det beror på att indikatormodellerna beaktar en stor mängd information som inte finns i serien själv. Detta är en ganska viktig begränsning för autoregressionen, eftersom man i praktiken aldrig i förväg kan veta när sådana speciella perioder kommer att inträffa.

Men även om tidsseriemodeller har visat sig vara användbara som prognosinstrument så saknar de förmåga att ge ekonomiska förklaringar till vad som driver prognoserna. Därför är det nödvändigt att också använda modeller som bygger på ekonomisk teori för att möjliggöra ekonomiska tolkningar av prognoserna. Dessutom visar en utvärdering av Adolfson m.fl. (2005b) att Riksbankens strukturella modell gör jämförelsevis bra prognoser på lite längre sikt.

Såväl indikatormodeller som strukturella modeller är alltså viktiga prognos- och analysinstrument, men de är givetvis grova förenklingar av verkligheten. Detta innebär att de omöjligen kan beakta all information som påverkar ekonomin, vilket medför ett behov att med hjälp av ekonomer bedömningsmässigt justera modellprognoserna på såväl kort som lång sikt.

## Referenser


Adolfson, M., S. Laséen, J. Lindé & M. Villani, (2005a), "Bayesian Estimation of an Open Economy DSGE Model with Incomplete Pass-Through", Sveriges Riksbank Working Paper Series No. 179.

Adolfson, M., M. K. Andersson, J. Lindé, M. Villani & A. Vredin, (2005b), "Modern Forecasting Models in Action: Improving Analyses at Central Banks", Sveriges Riksbank Working Paper Series No.188.

Andersson M. K., (2000), "Do Long-Memory Models have Long Memory" *International Journal of Forecasting 16*, 121-124.

Bernanke, B. S. & J. Boivin (2003), "Monetary Policy in a Data-Rich Environment", *Journal of Monetary Economics* 50 (3), 525-546.

"BNP-indikatorer", Fördjupningsruta, Inflationsrapport 2005:3, Sveriges riksbank.

Del Negro, M., F. Schorfheide, F. Smets & R. Wouters, (2005), "On the Fit and Forecasting Performance of New-Keynesian Models", European Central Bank Working Paper Series No. 491.

Galbraith, J. & G. Tkacz, (2006), " How Far Can We Forecast?: Forecast Content Horizons for Some Important Macroeconomic Time Series", Working Paper 2006-13, Department of Economics, McGill University.

"Inflationsindikatorer", Fördjupningsruta, Inflationsrapport 2006:3, Sveriges riksbank.

Kadiyala, K. R. & S. Karlsson, (1997), "Numerical Aspects of Bayesian VAR-Modeling", *Journal of Applied Econometrics*, Vol. 12, 99-132.

Kapetanios G., V. Labhard & S. Price, (2006), "Forecast Combinations and the Bank of England's Suite of Statistical Forecasting Models", manuskript, Bank of England.

Koop, G. (2003), Bayesian Econometrics, John Wiley and Sons.

Litterman, R., (1986), "Forecasting with Bayesian Vector Autoregressions: Five years of experience", *Journal of Business and Economic Statistics* 4, 25-37.

"RAMSES – ett verktyg för penningpolitisk analys", Fördjupningsruta, Penningpolitisk rapport 2007:1, Sveriges riksbank.

Stock, J. H. & M. W. Watson, (2002), "Forecasting using Principal Components from a Large Number of Predictors", *Journal of the American Statistical Association* 97, No. 460, 1167-1179.

Stock, J. H. & M. W. Watson, (2004), "Combination Forecasts of Output Growth in a Seven-Country Data Set", *Journal of Forecasting* 23 (Issue 6), 405–430.

Stock, J. H. & M. W. Watson, (2005), "An Empirical Comparison of Methods for Forecasting Using Many Predictors," manuscript.

Wold, H., (1938), A Study in the Analysis of Stationary Time Series, Almqvist & Wicksell, Stockholm.