



EKONOMIHÖGSKOLAN
Lunds universitet

Nationalekonomiska institutionen

Kandidatuppsats

Januari, 2006

Inflation: Ger kointegration bättre prognoser?

Kristofer Månsson
831116-3938

Handledare: Thomas Elger

Sammanfattning

Titel:	Inflation: Ger kointegration bättre prognoser
Ämne/Kurs:	NEK691, Examensarbete C, 10 poäng
Författare:	Kristofer Månsson
Handledare:	Thomas Elger
Nyckelord:	Inflationsprognoser, indirekt metod, kvantitetsteori, kointegration
Syfte:	Syftet med uppsatsen är att undersöka om eventuell kointegration mellan inflation och penningmängd ger bättre inflationsprognoser.
Metod:	Jag använder mig av svensk kvartalsdata för inflation och penningmängd (mätt som M0 och M3) mellan 1993:1 och 2005:4, för att se om modeller med en felkorrigeringsterm ger bättre prognoser än VAR-modeller, AR-modeller och RW-modeller. Jag prognostiserar med indirekt metod och använder tre olika prognoshorisonter, $t+1$, $t+4$ och $t+8$.
Slutsats:	Kointegration ger inte bättre prognoser oavsett prognoshorisont. För $t+1$ är AR-modellen bäst och för $t+4$ och $t+8$ är VAR-modellerna bäst. Skillnaden mellan prognosfelen för VAR-modellerna och AR-modellerna är inte särskilt stora oberoende av prognoshorisonten.

Innehåll

1.	Introduktion	4
2.	Tidigare forskning	7
3.	Teori	9
3.1	Kvantitetsteori	9
3.2	Kointegration	11
3.3	Engle-Granger metoden	12
3.4	Prognosmetoder	13
4.	Data	15
5.	Metoder	17
5.1	Prognosmodeller	17
5.2	Prognosutvärdering	19
6.	Resultat	20
6.1	Kointegrationstest	20
6.2	Prognoseerna	21
6.3	Prognosutvärderingen	26
7.	Slutsatser	29
8.	Referenser	30

1. Introduktion

Denna kandidatuppsats behandlar inflationsprognoser. Att veta hur hög inflationen kommer att bli i framtiden är viktigt för många agenter i ekonomin. Riksbanken sätter sin reporänta efter hur stor den tror den framtida inflationen kommer att vara, vilket får effekter för hela samhället. En inflationsprognos som är felaktig kan leda till att reporäntan blir för högt eller för lågt satt vilket kan förstärka konjunktursvängningarna. Vidare är det också viktigt för bland annat arbetsgivare och fackförbund att ha tillgång till säkra inflationsprognoser för att kunna säkerställa en rimlig reallöneutveckling. Alltså påverkar förväntningarna om den framtida inflationen hela samhällsekonomin, vilket gör det viktigt att få dem så exakta som möjligt.

Eftersom inflationsprognoser är viktigt har det forskats mycket kring hur man kan prognostisera inflation så säkert som möjligt. Forskningen som bedrivits har varit inriktad på att undersöka, till exempel, vilka variabler som kan tänkas förklara den framtida inflationen och olika metodologiska frågeställningar angående direkta och indirekta prognosmetoder samt huruvida man ska använda sig av linjära eller icke-linjära modeller. En viktig undersökning som handlar om vilka variabler som bör ingå i inflationsprognoser är Stock och Watson (1999). Dom fann att variabler som kunde länkas till Phillipskurvan var bäst för att prognostisera inflation. Den metodologiska frågan om huruvida direkta eller indirekta modeller ska användas har Marcellino et al. (2006) undersökt grundligt genom att prognostisera 170 makroekonomiska tidsserier. Exempel på undersökning där det undersökts om icke-linjära eller linjära modeller prognostiserar bäst är Binner et al. (2006). De jämförde icke-linjära univariata RNN-modeller och MS-AR-modeller med linjära AR-modeller. Vidare har även Elger et al. (2006) gjort en undersökning om huruvida olika mått på penningmängden förbättrar linjära och icke-linjära prognosmodeller. Den första undersökningen kom fram till att icke-linjära modeller är bäst på kort sikt medan linjära modeller ger lägst prognosfel för längre prognoshorisonter. I den senare undersökningen kom de fram till att prognosmodellerna med penningmängd som förklaringsvariabel som bäst prognostiserar lika bra som de univariata modellerna.

I Sverige bedrivs mycket av forskningen kring inflationsprognoser hos Konjunkturinstitutet och Riksbanken. I Riksbankens inflationsrapport (2006:1) står det mycket utförligt vad banken tar

hänsyn till när den gör sina prognoser. Man tar hänsyn till över 60 indikatorer däribland BNP-tillväxten, utländsk inflation och investeringar. Det är dock inte bara vid dessa två institutioner som forskning bedrivs. Vid Lunds universitet skrev Rebecca Bjärlestam (2006) en kandidatuppsats inspirerad av Marcellino et al. (2006). Den handlade om man ska prognostisera svensk inflation genom direkt- eller indirekt metod. Hon fann att när prognoshorisonten är ett år ger den direkta metoden minst prognosfel medan för prognoshorisonten två år ger den indirekta metoden bäst prognoser.

Syftet med kandidatuppsatsen är att se om eventuell kointegration mellan inflation och penningmängd kan ge bättre prognoser. Kointegration är ett långsiktigt samband mellan ekonomiska variabler som säger att variablerna inte kan glida för långt ifrån varandra. Den klassiska kvantitetsteorin visar att ett sådant samband finns mellan penningmängd och inflation vilket får mig att undersöka om det går att använda för att göra säkrare inflationsprognoser.

Jag undersöker om inflation och penningmängd (mätt som M0 och M3) är kointegrerade. Sedan utnyttjar jag dessa resultat för att generera prognoser som tar hänsyn till kointegration. Dessa prognoser jämförs med prognoser erhållna från RW-modeller, AR-modeller och VAR-modeller. RW-modellerna säger att inflationen nästa period kommer vara samma som i föregående period. AR-modellerna byggs upp med laggade värden av inflation. Sedan bygger jag ut mina AR-modeller genom att lägga till laggade värden av penningmängd som förklaringsvariabel. Slutligen lägger jag till en kointegrationsterm till mina VAR-modeller och får felkorrigeringsmodellerna.

Undersökningens urval sträcker sig från första kvartalet 1993 till och med sista kvartalet 2005. Jag har hämtat statistiken från Ecwin. Jag gör prognoser för tre olika horisonter, $t+1$, $t+4$ och $t+8$. Prognoser utvärderas sedan baserat på tre olika och vanligen förekommande kriterium, ME (Mean Error), MAE (Mean Absolute Error) och RMSE (Root Mean Square Error). Vidare jämförs om skillnaden mellan olika modellers prognosfel är statistiskt signifikant genom F-test.

Resultatet från min undersökning visar entydigt att kointegration inte ger bättre inflationsprognoser. För prognoshorisonterna $t+1$ är AR-modellerna bäst medan VAR-modellerna är bäst för horisonterna $t+4$ och $t+8$. Förbättringen för prognoshorisonterna $t+4$ och

$t+8$ när penningmängden används som förklaringsvariabel är marginell och F-testet visar att den inte är statistiskt signifikant.

Uppsatsen är disponerad på följande sätt: Avsnitt 2 beskriver den tidigare forskningen som bedrivits kring inflationsprognoser. I avsnitt 3 kommer kvantitetsteorin och begreppet kointegration att beskrivas. Jag kommer även att beskriva den indirekta prognosmetoden. I avsnitt 4 beskriver jag mina data och sedan visar jag hur jag kommer att transformera dem. Avsnitt 5 börjar med en beskrivning av mina modeller och hur jag praktisk använder dem för att göra prognoser samt hur jag utvärderar mina prognoser. Efter det beskriver jag mina resultat i avsnitt 6 och jag visar tabeller över kointegrationstesten och prognosutvärderingen och jag visar diagram över prognoserna. Slutligen kommer jag att sammanfatta vad jag kommit fram till i avsnitt 7.

2. Tidigare forskning

Som jag nämnde i inledningen så genomförde Stock och Watson (1999) en stor undersökning där de jämförde om olika ekonomiska variabler kunde förbättra inflationsprognoser. Syftet med undersökningen var att dels se om de kunde få fram bättre prognoser med multivariata modeller än univariata modeller samt att i så fall se vilka variabler som bäst prognostiserade inflation. De använde sig bland annat av arbetslöshet, ränta och penningmängd och gjorde prognoser med horisonten tolv månader. Deras resultat var nedslående för kvantitetsteorin eftersom inget penningmängdsmått gav bättre resultat än de univariata AR-modellerna. Den variabel som bäst prognostiserade inflation var olika mått för arbetslöshet.

Elger et al. (2006) undersökte vilket penningmängdsmått som var bäst för att prognostisera inflation genom att använda sig av både linjära och icke-linjära modeller. Deras slutsats låg i linje med Stock och Watsons slutsats att penningmängden inte hjälper till att få fram bättre prognoser och inget mått på penningängden var klart bättre än de andra måtten. Varken för de linjära modellerna eller de icke-linjära modellerna. Binner et al. (2006) gjorde en undersökning om icke-linjära modeller gav bättre prognoser än linjära prognoser. Nu användes inga andra förklaringsvariabler utan de använde univariata RNN-modeller och MS-AR-modeller som icke-linjära modeller och AR-modeller som linjära modeller. Deras slutsats var att de icke-linjära modellerna gav bättre prognoser vid korta prognoshorisonter medan de linjära modellerna gav bättre resultat för längre prognoshorisonter.

Förutom frågan om vilka variabler som ska ingå i inflationsprognoser och om man bör använda sig av linjära eller icke-linjära modeller så har även en metodologisk fråga diskuterats.

Marcellino et al. (2006) gjorde en mycket grundlig undersökning med 170 makroekonomiska variabler för att se om indirekt- eller direkt metod är bäst lämpad för markoekonomiska prognoser. Rent teoretiskt bör de indirekta modellerna ge bättre prognoser om prognosmodellen är rätt specificerad medan de direkta prognosmodellerna är bäst när modellen är felspecificerad. Vad Marcellino et al. kom fram till tyder på att det stämmer. Vid kortare laggängder är det osannolikt att prognosmodellen är rätt specificerad vilket enligt teorin skulle göra att den direkta

metoden är bäst. Empirin när Marcellino et al. jämförde metoderna ger den generella slutsatsen att så är fallet. De undersökte även om vilken metod som var bäst lämpad vid långa och korta prognoshorisonter oberoende av lagglängden. De kom då fram till att de indirekta modellerna var bättre när prognoshorizonten blev längre. Slutligen poängterade de att dessa resultat är generella och om man vill veta vilken metod som är bäst för en enskild makroekonomisk variabel så måste detta undersökas. Bjärlestam (2006) tog fasta på det och gjorde en studie där hon jämförde vilken av de två olika metoderna som var bäst lämpad för svensk inflationsdata. Hon använde sig av kortare lagglängder upp till och med fyra. Hennes resultat liknar väldigt mycket de som Marcellino et al. kom fram till. För den kortare prognoshorizonten $t+4$ gav de direkta prognoserna bättre resultat medan för den längre prognoshorizonten $t+8$ gav de indirekta prognoserna bäst resultat.

3. Teori

3.1 Kvantitetsteori

Målsättningen med denna uppsats är att undersöka om kointegration kan ge bättre inflationsprognoser. Kointegrationssambandet mellan inflation och penningmängd finns inom kvantitetsteorin. Bland annat Fregert och Jonung (2003, 235-237) har beskrivit kvantitetsteorin som är ett samband mellan inflation, pengars omloppshastighet, BNP och penningmängd. Bytesekvationen säger att inflation multiplicerat med omloppshastigheten är lika med penningmängden multiplicerat med antalet penningtransaktioner. Eftersom antalet penningtransaktioner är svårt att mäta skattar man det med den reala BNP-tillväxten och därmed får man bytesekvationen:

$$MV \equiv PY \tag{3.1}$$

Ekvation 3.1 är en identitet där M står för penningmängden, V för omloppshastigheten, P för inflationen och Y för den reala BNP-tillväxten. För att en identitet ska övergå till en teori krävs det att man gör antaganden om hur de olika variablerna bestäms och hur de påverkar varandra. I den klassiska kvantitetsteorin så antas pengarnas omloppshastighet vara konstant. Den reala BNP-tillväxten antas vara oberoende av de andra variablerna och den bestäms av kapitalstocken, antalet arbetade timmar och förbättringar inom teknologin. Efter dessa antaganden om den reala BNP-tillväxten och pengarnas omloppshastighet återstår det ett proportionellt förhållande mellan penningmängden och inflationen när identiteten övergår till teori. För att kunna använda det sambandet logaritmeras de fyra variablerna så att jag får variablernas tillväxthastighet och därigenom ekvation 3.2:

$$m + v = p + y \tag{3.2}$$

Den klassiska kvantitetsteorins antagande är att pengarnas omloppshastighet och den reala BNP-tillväxten är konstant. Jag kan därför nollställa dem i ekvation 3.2 eftersom en konstant variabel

har noll i tillväxthastighet. Därmed finns ett direkt samband mellan penningmängden och inflationen som jag använder mig av.

3.2 Kointegration

I föregående stycke beskrev jag kvantitetsteorin och det direkta samband som finns mellan penningmängd och inflation. När två variabler har ett sådant långsiktigt samband så kan de vara kointegrerade. För att förstå begreppet kointegration måste man förstå innebörden av stationaritet. Det finns olika definitioner på stationaritet som skiljer sig genom hur strikta krav som ställs. Woolridge (2003, 361-364) redogör för kovariansstationaritet vilket är den vanligaste definitionen. Tidsserien x_t måste uppfylla följande tre krav för att anses vara stationär:

- (i) $E(x_t)$ måste vara konstant
- (ii) $\text{Var}(x_t)$ måste vara konstant
- (iii) $\text{Cov}(x_t, x_{t+h})$ beror bara på h och inte på t

De två första kraven innebär att en tidsseries medelvärde och varians måste vara konstant över tiden. Det tredje kravet säger att kovariansen mellan två observationer inte ska bero på vilka observationer man jämför utan enbart på tiden som passerat mellan dem. Man ser om kraven är uppfyllda när tidsserien utsätts för en chock. Om tidsserien är stationär får chocken inga permanenta effekter och tidsserien återvänder snabbt till sitt medelvärde. Om chocken däremot får permanenta effekter är tidsserien icke-stationär eftersom medelvärdet och variansen förändras efter chocken. Granger och Newbold (1974) visade att problemet med icke-stationära variabler är att de ger upphov till falsk regression (*eng. Spurious regression*) på grund av trenden. Med falsk regression menas att de statistiska testerna, t- och F-tester, ger utslag trots att de inte borde det på grund av att trenden gör att det finns ett samband mellan variablerna som egentligen inte existerar. Om en variabel inte förklarar en annan variabel men de följer en liknande trend kan den falska regressionen uppstå. När man gör prognoser blir det också problem med icke-stationära tidsserier eftersom prognosmodellen antar att chocker är temporära när de egentligen är permanenta. Det har utvecklats tester för att upptäcka att en tidsserie är icke-stationär, bland

annat DF-testet och ADF-testet som står beskrivit i nästföljande avsnitt. Det har också utvecklats sätt att få icke-stationära tidsserier att bli stationära. Det senare sker genom differentiering enligt ekvation 3.3:

$$\Delta y_t = y_t - y_{t-1} \quad (3.3)$$

Definitionen för kointegration är hämtad från en artikel av Engle och Granger (1987). När man pratar om stationära och icke-stationära tidsserier brukar man kalla dem $I(d)$. d står för hur många gånger man behöver differentiera en tidsserie innan den blir stationär. Alltså är en redan stationär tidsserie $I(0)$ och de flesta makroekonomiska variablerna är icke-stationära av graden $I(1)$ och behöver därför differentieras en gång.

Varför det är viktigt med begreppet stationaritet när man pratar om kointegration är för att två variabler ska kunna vara kointegrerade måste de vara icke-stationära av samma grad. Tanken om kointegration kan förklaras utifrån formeln nedan:

$$x_t = z_t - \beta y_t \quad (3.4)$$

Tanken bakom denna formel är att efter att man tagit de två variablerna z_t och y_t minus varandra så blir x_t stationär. Detta kräver som jag tidigare har skrivit att z_t och y_t är integrerade av samma grad eftersom x_t är integrerad av graden $I(d-b)$. Om d och b skiljer sig åt kommer inte x_t att bli stationär. Vektorn β kallas för kointegrationsvektorn och indikerar att man måste göra om skalan för en av variablerna för att differentieringen ska fungera. Om man efter denna differentiering får det till att x_t har ett konstant medelvärde så kommer x_t ofta att passera medelvärdet och ekonomin kommer därmed ofta att hamna i jämvikt. Detta kan man utnyttja i prognoser eftersom när de två variablerna inte befinner sig i jämvikt kan man anta att de kommer att röra sig mot jämvikt.

3.3 Engle-Granger metoden

För att undersöka om penningmängd och inflation är kointegrerade använder jag mig av en metod som utvecklades av Engle och Granger och som står beskriven i Enders (2004, 335-337). Som jag tidigare beskrivit är det första kravet för att två variabler är kointegrerade att variablerna är icke-stationära av samma grad. Detta undersöker man genom ett Augmented Dickey-Fuller-test (ADF-test) som det står om i Enders (2004, 189-190). Man skattar först följande ekvation:

$$\Delta y_t = \alpha_0 + \gamma y_{t-1} + \sum_{i=1}^p \beta_i \Delta y_{t-i+1} + \varepsilon_t \quad (3.5)$$

Den viktiga parametern i ekvationen ovan är y_{t-1} . Om den blir statistiskt signifikant när man skattar ovanstående modell så är tidsserien stationär. Vad som kan vara komplicerat att förstå i ekvationen är termen $\sum_{i=1}^p \beta_i \Delta y_{t-i+1}$. Den visar att man ska lagga de differentierade värdena av y_t så många gånger att ingen autokorrelation föreligger när man skattar modellen. En viktig sak som man bör notera när man undersöker om y_{t-1} är statistiskt signifikant är att t-testet inte följer den vanliga t-distributionen utan en speciell variant av den som är utvecklad av MacKinnon.

När man har gjort ADF-testet och kommit fram till att båda är integrerade av samma grad kan man gå vidare i testet som står beskrivet i Enders (2004, 336-337) genom att skatta ekvation 3.6:

$$y_t = \beta_1 + \beta_2 z_t + e_t \quad (3.6)$$

När ovanstående modell är skattad så sparas residualerna och man gör ytterligare ett ADF-test med residualserien. För att två variabler ska vara kointegrerade så måste ADF-testet visa att residualserien som är sparad är stationär. För att se om residualserien är stationär undersöker man än en gång om y_{t-1} är statistiskt signifikant genom ett t-test. Nu följer dock t-testet varken sin vanliga distribution eller MacKinnons distribution utan en annan speciell distribution som är

hämtad från Enders (2004, s 441). Om de två variablerna är kointegrerade kan man nu skatta felkorrigeringsmodellerna:

$$\Delta y_t = \alpha_1 + \alpha_y \hat{\varepsilon}_{t-1} + \sum_{i=1} \alpha_{11}(i) \Delta y_{t-i} + \sum_{i=1} \alpha_{12}(i) \Delta z_{t-i} + \varepsilon_{yt} \quad (3.7)$$

$$\Delta z_t = \alpha_2 + \alpha_z \hat{\varepsilon}_{t-1} + \sum_{i=1} \alpha_{21}(i) \Delta y_{t-i} + \sum_{i=1} \alpha_{22}(i) \Delta z_{t-i} + \varepsilon_{zt} \quad (3.8)$$

För att skatta felkorrigeringstermen så används residualserien som sparades efter ekvation 3.6.

3.4 Prognosmetoder

För att undersöka om kointegration mellan penningmängd och inflation ger bättre prognoser har jag valt att använda mig av den vanligaste indirekta prognosmetoden. Denna metod står beskriven i flera läroböcker däribland Enders (2004, 79-81). Jag kommer att använda mig av AR-modellen för att förklara metoden:

$$y_t = a_0 + a_1 y_{t-1} + \varepsilon_t \quad (3.7)$$

Genom OLS (Ordinary Least Squares) skattas parametrarna a_0 och a_1 så att man får fram prognosekvationen 3.8.

$$E_t y_{t+1} = a_0 + a_1 y_t \quad (3.8)$$

Prognosekvationen visar att det enda som behövs göras när skattningarna är gjorda är att sätta in värdet för y_t , vilket ger en prognos för nästa period. När prognoshorisonten är $t+1$ så är man färdig, men när prognoshorisonterna är längre behöver man iterera framåt enligt ekvation 3.9:

$$E_t y_{t+2} = a_0 + a_1 (a_0 + a_1 y_t) \quad (3.9)$$

Alltså sätter man in det prognostiserade värdet för föregående period för att prognostisera nästföljande period, vilket man fortsätter med tills den prognoshorisont man är ute efter är nådd.

4. Data

När jag gör mina prognoser använder jag två olika definitioner på penningmängd och ett mått för inflation. Jag har hämtat kvartalsdata som sträcker sig från 1993-2005 från Ecwin. Definitioner för penningmängden är däremot tagna från SCB:s hemsida¹ och definitionen för KPI är hämtad från Fregert och Johnung, (2003, s. 156)

- (i) M0 definieras som allmänhetens innehav av sedlar och mynt. Beräknas utifrån riksbankens totala mängd utelöpande sedlar och mynt reducerat med bankernas innehav av sedlar och mynt.
- (ii) M3 definieras som allmänhetens innehav av sedlar och mynt (M0), svensk allmänhets inlåning i bank samt svensk allmänhets innehav av bankcertifikat denominerade i svenska kronor.
- (iii) KPI mäter den genomsnittliga prisnivån för varor och tjänster som hushållet köper för sin konsumtion.

När variablerna används för prognoser så börjar man vanligtvis med att logaritmera dem. Det gör även jag enligt ekvation 4.1:

$$y_t = \log(Y_t) \quad (4.1)$$

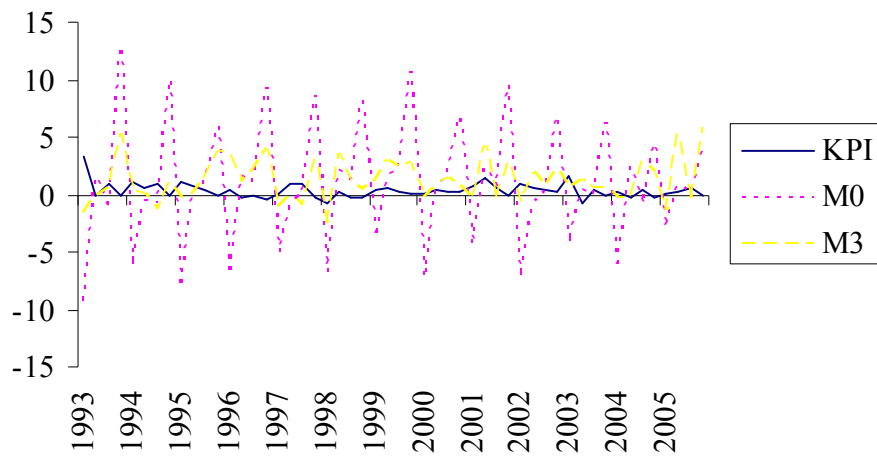
Efter logaritmeringen så differentieras de tre tidsserierna för att få dem stationära. När man differentierar visar ekvation 4.2 att man exempelvis tar 1994 års inflation minus 1993 års inflation:

$$\Delta y_t = y_t - y_{t-1} \quad (4.2)$$

¹ http://www.scb.se/templates/tableOrChart___90736.asp

Figur 4.1 visar variablernas procentuella förändring. I figuren ser man att M0 varierar betydligt mer än M3. KPI är den variabel med minst variation.

Figur 4.1



5. Metoder

5.1 Prognosmodeller

Jag skattar fyra prognosmodeller för att besvara min fråga. För att dels kunna göra prognoserna men även utvärdera dem har jag delat upp datamaterialet i två delar. Det första som sträcker sig från 1993:1 till och med 1999:4 är min in-sample period som jag använder för att skatta modellernas parametrar. Perioden 2000:1 och 2005:4 som är out-of-sample perioden använder jag för att utvärdera prognoserna. De olika modellerna som används för att göra prognoserna är felkorrigeringsmodellerna (ekvation 5.1 och 5.2), VAR-modellerna (ekvation 5.3 och 5.4), AR-modellen (ekvation 5.5) och RW-modellen (ekvation 5.6). Jag använder två prognosmodeller när penningmängd är med som förklaringsvariabel eftersom penningmängden också behöver prognostiseras för prognoshorisonterna $t+4$ och $t+8$. För alla modellerna kommer jag att välja lagglängd fyra vilket är den vanligaste lagglängden när man använder sig av kvartalsdata. Felkorrigeringstermen i ekvation 5.1 och 5.2 är däremot enbart laggad en gång:

$$E_t \Delta y_{t+j+1} = a_0 + a_1 E_t e_{t+j} + a_2 E_t \Delta y_{t+j} + a_3 E_t \Delta z_{t+j} \quad (5.1)$$

$$E_t \Delta z_{t+j+1} = a_0 + a_1 E_t e_{t+j} + a_2 E_t \Delta y_{t+j} + a_3 E_t \Delta z_{t+j} \quad (5.2)$$

$$E_t \Delta y_{t+j+1} = a_0 + a_1 E_t \Delta y_{t+j} + a_2 E_t \Delta z_{t+j} \quad (5.3)$$

$$E_t \Delta z_{t+j+1} = a_0 + a_1 E_t \Delta y_{t+j} + a_2 E_t \Delta z_{t+j} \quad (5.4)$$

$$E_t y_{t+j+1} = a_0 + a_1 E_t \Delta y_{t+j} \quad (5.5)$$

$$E_t \Delta y_{t+j+1} = \Delta y_{t+j} \quad (5.6)$$

För att göra prognoser använder jag den indirekta metoden som står beskriven i avsnitt 3.4. Jag gör prognoserna för tre olika horisonter, $t+1$, $t+4$ och $t+8$. För att göra prognoserna så börjar jag med att skatta parametrarna genom att använda mitt in-sample mellan 1993:1 och 1999:4.

Därefter uppdaterar jag parameterskattningarna fram till 2005:4. När AR-modellen används vid prognoshorisont $t+1$ sätter jag därefter in de faktiska värdena för inflationen för kvartalen 1999:4, 1999:3, 1999:2 och 1999:1 i modellen. Sedan fortsätter jag genom att ta bort det sista kvartalet och lägga till nästföljande kvartal tills jag har prognoser för hela min out-of-sample period. När jag har längre prognoshorisonter än $t+1$ använder jag mig av både faktiska och prognostiserade värden för att göra prognoserna. Det första året jag kan göra prognoser för är 2000:4 när jag har prognoshorisonten $t+4$. Då får jag iterera framåt i tiden som jag beskrev i avsnitt 3.4, så jag till slut använder de prognostiserade värdena för 2000:3, 2000:2, 2000:1 och det faktiska värdet för 1999:4. När jag har prognoshorisonten $t+8$ itererar jag ännu längre fram i tiden. Nu är det 2001:4 som är det första kvartalet jag kan göra en prognos för vilket gör att jag då använder mig av de prognostiserade värden för kvartalen 2001:3, 2001:2, 2001:1 och 2000:4. Att prognostisera med RW-modellen är mycket enklare än de övriga. Där behöver jag inga parameterskattningar utan den modellen säger att inflationen i nästa period är lika med inflationen i föregående period.

5.2 Prognosutvärderingar

Elger et al. (2006) skriver om olika prognosmetoder och hur man utvärderar prognoserna. De beskriver tre olika metoder för att göra utvärderingar. Det första måttet är genomsnittsfelet (ekvation 5.5), sedan använder jag också det absoluta genomsnittsfelet (ekvation 5.6) och rotgenomsnittligt kvadratfel (ekvation 5.7).

$$ME = \frac{1}{K} \sum_{t=(0,1,\dots,T)+\tau}^T E_{t-\tau} [dP_t] - dP_t \quad (5.5)$$

$$MAE = \frac{1}{K} \sum_{t=(0,1,\dots,T)+\tau}^T |E_{t-\tau} [dP_t] - dP_t| \quad (5.6)$$

$$RMSE = \frac{1}{K} \left[\sum_{t=(0,1,\dots,T)+\tau}^T (E_{t-\tau} [dP_t] - dP_t)^2 \right]^{1/2} \quad (5.7)$$

ME, MAE och RMSE är engelska förkortningar som står för Mean Error, Mean Absolute Error och Root Mean Squared Error. ME är ett väldigt enkelt mått där man tar de prognostiserade värdena minus de faktiska värdena. Sedan summerar man ihop det och delar med antalet prognoser man gjort. ME visar om modellen generellt överskattar eller underskattar de faktiska värdena och ska därför helst ligga så nära noll som möjligt. MAE liknar ME men där summerar man ihop de absoluta felen för att sedan dela med antalet prognoser. När man räknar ut RMSE upphöjer man alla prognosfelen med två och sedan summerar man dem och delar med antalet prognoser. Därefter tar man roten ur det talet. MAE och RMSE visar båda ett genomsnitt för prognosfelen men skillnaden mellan de två måtten är att MAE är mindre känsligt för uteliggare (*eng. outliers*).

För att besvara min fråga väljer jag ut den modell bland felkorrigeringsmodellerna, VAR-modellerna, AR-modellerna och RW-modellerna som har lägst värde för RMSE. Sedan jämför jag den bästa och den näst bästa modellen för att avgöra om skillnaden är statistiskt signifikant. I Enders (2004, s. 84) står det att man kan avgöra det genom nedanstående F-test med antagandet att prognosfelen är normalfördelade och att de inte är autokorrelerade:

$$F = \frac{\sum_{i=1}^H e_{1i}^2}{\sum_{i=2}^H e_{2i}^2} \quad (5.8)$$

I ekvation 5.8 tar jag det största RMSE värdet delat med det minsta. Därefter låter jag Minitab räkna ut p-värdet.

6. Resultat

6.1 Kointegrationstesten

Den klassiska kvantitetsteorin visar att det ska finnas ett kointegrationssamband mellan penningmängd och inflation. Tabell 6.1 visar resultaten av ett ADF-test gjort i E-views. ADF-testet är gjort på residualserierna från regressionen beskriven i formel 3.5. Jag använder lagglängderna ett till och med fyra med antagandet att residualerna inte är autokorrelerade. Det går inte att använda de vanliga kritiska värdena för t-testet så jag kommer att använda mig av kritiska värden som är utarbetade för kointegrationstest och som finns i Enders (2004, s.441). Om man kan förkasta nollhypotesen innebär det att residualserien är stationär och därmed är inflation och penningmängd kointegrerade.

Tabell 6.1 visar att penningmängd och inflation inte är kointegrerade, oberoende vilket mått på penningmängd som jag använder och oberoende av vilket urval som jag undersöker. t-värdena är långt ifrån de kritiska värdena som måste överskridas för att nollhypotesen ska förkastas. Därför är resultatet att penningmängd och inflation inte är kointegrerade i just mitt urval ett stabilt resultat.

Tabell 6.1

Urval	Variabler	Lagglängd	t-värde
1993-2000	M0, KPI	1	-1,78
		2	-1,79
		3	-2,04
		4	-1,93
	M3, KPI	1	-2,55
		2	-2,69
		3	-2,45
		4	-2,12
1993-2005	M0, KPI	1	-1,57
		2	-1,42
		3	-1,89
		4	-2,26
	M3, KPI	1	-2,15
		2	-2,49
		3	-2,64
		4	-2,55

6.2 Prognoserna

Trots att kointegrationstestet visar att kointegration inte kan påvisas enligt ADF-testet så skattar jag ändå felkorrigeringsmodellerna för att se om de prognostiserar bättre. Jag gör det eftersom det teoretiska sambandet mellan penningmängd och inflation är väldigt starkt. På nästföljande sidor presenterar jag prognoserna gjorda med horisonten $t+1$, $t+4$ och $t+8$. Jag har gjort alla prognoser i Excel med de olika modellerna som beskrevs i avsnitt 5.1.

För prognoshorisont $t+1$ är skillnaden mellan VAR-modellerna och felkorrigeringsmodellerna inte så stor. De följer samma upp- och nedgångar men felkorrigeringsmodellerna prognostiserar nästan hela tiden något lägre inflation. Undantaget är den stora uppgången fjärde kvartalet 2003 som VAR-modellerna fångar upp medan felkorrigeringsmodellerna prognostiserar en nedgång. AR-modellen är mindre volatil än de övriga modellerna och är därför inte kapabel till att fånga upp de stora upp- och nedgångarna som exempelvis det fjärde kvartalet 2003.


För de längre prognoshorisonterna $t+4$ och $t+8$ så förändras prognoserna mindre från kvartal till kvartal. Prognoserna blir mer ett jämt streck desto längre prognoshorisonten blir. Eftersom prognosmodellerna blir mer jämna lyckas inte prognosmodellerna nu heller fånga upp de stora förändringarna i inflationen, däribland den höga inflationen det fjärde kvartalet 2003 och det tredje kvartalet 2001.

Prognoshorisont $t+1$


Figur 6.1 : Felkorrigeringsmodell



Figur 6.2: VAR-modell



Figur 6.3: AR-modell




Figur 6.4: RW-modell




Prognoshorisont $t+4$


Figur 6.5: Felkorrigeringsmodell



Figur 6.6: VAR-modeller



Figur 6.7: AR-modell




Figur 6.8: RW-modell




Prognoshorisont $t+8$


Figur 6.9: Felkorrigeringsmodell



Figur 6.10: VAR-modell



Figur 6.11: AR-modell



Figur 6.12: RW-modell



6.3 Prognosutvärderingen

Tabell 6.2 visar prognosutvärderingar för alla modeller. Jag har gjort dem enligt formlerna som jag beskrev i avsnitt 5.2. För ME som mäter om modellerna konsekvent över- eller underskattar inflationen ser man att alla modeller förutom RW-modellerna underskattar inflationen för prognoshorisonterna $t+1$ och $t+4$. Felkorrigeringsmodellerna underskattar inflationen mest. För $t+8$ däremot överskattar alla modeller inflationen förutom felkorrigeringsmodellen med M3.

Enligt de två kriterierna för prognosfelens magnitud får AR-modellen lägst värden för prognoshorisonten $t+1$. För horisonten $t+4$ och $t+8$ får VAR-modellen med M0 bäst resultat. Skillnaden mellan den bästa och näst bästa modellen är aldrig särskilt stor. För $t+4$ är skillnaden som störst för kriterat RMSE med ungefär 0,03 % differens mellan AR-modellen och VAR-modellen med M0. Felkorrigeringsmodellerna prognostiserar aldrig bäst oavsett prognoshorisont. Skillnaden är ändå inte särskilt stor mellan den bästa felkorrigeringsmodellen och den bästa prognosmodellen. Som störst är skillnaden för prognoshorisont $t+4$ med 0,04 % differens mellan felkorrigeringsmodellen med M3 och VAR-modellen med M0.

Tabell 6.2

Prognoshorisont	Prognosmodell	ME	MAE	RMSE
$t+1$	Felkorrigeringsmodell (M0)	-0,2808	0,4243	0,5928
	VAR-modell (M0)	-0,0087	0,4268	0,5823
	Felkorrigeringsmodell (M3)	-0,1151	0,3942	0,5530
	VAR-modell (M3)	-0,0230	0,3890	0,5444
	AR-modell	-0,0125	0,3658	0,5349
	Random-Walk	0,0047	0,5874	0,7840
$t+4$	Felkorrigeringsmodell (M0)	-0,2057	0,4745	0,5953
	VAR-modell (M0)	-0,0655	0,3522	0,5031
	Felkorrigeringsmodell (M3)	-0,2734	0,4027	0,5596
	VAR-modell (M3)	-0,0331	0,3625	0,5100
	AR-modell	-0,0357	0,3952	0,5306
	Random-Walk	0,0067	0,4477	0,5939
$t+8$	Felkorrigeringsmodell (M0)	0,0550	0,3919	0,5481
	VAR-modell (M0)	0,0184	0,3728	0,5275
	Felkorrigeringsmodell (M3)	-0,1049	0,4039	0,5493
	VAR-modell (M3)	0,0530	0,3728	0,5326
	AR-modell	0,0422	0,3982	0,5434
	Random-Walk	0,1662	0,5306	0,7861

Jag har valt ut de två bästa prognosmodellerna för varje prognoshorisont och jämfört om den bästa är statistiskt signifikant bättre genom att göra ett F-test beskrivit i avsnitt 5.2. Den bästa modellen för prognoshorisont $t+1$ är AR-modellen vilken jag jämför med VAR-modellen med M3. För $t+4$ och $t+8$ är VAR-modellerna med M0 bäst och den jämför jag med AR-modellerna. Skillnaderna är för små för att vara statistiskt signifikanta. Man kan alltså inte påvisa att någon modell är bättre än den näst bästa modellen.

Tabell 6.3

Prognoshorisont	Prognosmodeller	F-värde	P-värde
$t+1$	VAR-modell (M3)/AR-modell	1,0178	0,4833
$t+4$	AR-modell/VAR-modell (M0)	1,0545	0,4532
$t+8$	AR-modell/VAR-modell (M0)	1,0203	0,4837

7. Slutsatser

Inom den klassiska kvantitetsteorin finns en stark teoretisk koppling på lång sikt mellan penningmängd och inflation. Om det teoretiska sambandet håller bör man kunna använda penningmängden för att förbättra inflationsprognoser. Många forskare har därför undersökt om så är fallet genom att skatta VAR-modeller och felkorrigeringsmodeller där sambandet mellan penningmängd och inflation används. Resultatet för bland annat Stock och Watson (1999) och Elger et al. (2006) är att de multivariata modellerna med penningmängd som förklaringsvariabel som bäst prognostiserar lika bra som univariata AR-modeller.

Min kandidatuppsats hade som syfte att undersöka om kointegration kunde förbättra svenska inflationsprognoser. Jag började först med att undersöka om penningmängd och inflation är kointegrerade genom ett ADF-test. Resultatet blev att ingen kointegration kunde påvisas. Därefter skattade jag ändå felkorrigeringsmodeller och VAR-modeller eftersom det teoretiska sambandet är så starkt. Resultatet från prognosutvärderingen visade att AR-modellerna är bättre än modellerna där penningmängd ingår som förklaringsvariabel för prognoshorizonten $t+1$. För de längre prognoshorisonterna $t+4$ och $t+8$ var VAR-modellerna med $M0$ bäst. Skillnaderna är dock små och ingen av de bästa VAR-modellerna blev statistiskt signifikant bättre än AR-modellerna, oavsett prognoshorizont. Detta resultat är konsistent med vad den tidigare forskningen har kommit fram till. Syftet med uppsatsen var dock att se om eventuell kointegration gav bättre prognoser och det kunde jag inte påvisa oavsett prognoshorizont.

8. Referenser

Binner, J. M., Elger, T., Nilsson, B och Tepper, J. A. (2005). Tools for non-linear time series forecasting in economics- an empirical comparison of regime switching vector autoregressive models and recurrent neural networks. *Advances in Econometrics*, 19. (pp. 71-92)

Bjärlestam, R. (2006). Indirekta och direkta inflationsprognoser: En studie baserad på svenska kvartalsvis inflationsdata. *Kandidatuppsats*. Lunds Universitet

Elger, T., Jones B. E. och Nilsson B. Forecasting with Monetary Aggregates: Recent Evidence for the United States. *Journal of Economics & Business*, 58. (pp. 428-426)

Enders, W. (2004). *Applied Econometrics Time Series*. John Wiley & Sons, New York.

Engle R. F. och Granger C. W. J. (1987). Co-Integration and Error Correction: Representation, Estimation and Testing. *Econometrica* 55:251-276.

Fregert, K. och Jonung, Lars. (2003). *Makroekonomi Teori, Politik & Institutioner*. Studentlitteratur, Lund.

Granger, C. W. J. och Newbold, P. (1974). Spurious Regressions in Econometrics. *Journal of Econometrics* 2:111-120.

Marcellino, M., Stock, J. H. och Watson, M. V. (2006). A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series. *Journal of Econometrics*.

Stock, J. H., och Watson, M. V. (1999a). Forecasting inflation. *Journal of Monetary Economics*, 44.(pp.293-335)

Woolridge, J. M. (2003). *Introductory Econometrics*. South-Western, Mason, Ohio

