



Lunds universitet
Statistiska institutionen

En flashestimator för den privata konsumtionen i Sverige med hjälpvariablerna HIP och detaljhandeln

—
En tidsserieanalys med hjälp av statistikprogrammet TRAMO

Åsa Kalderstam

Uppsats i statistik
10 poäng
Nivå 41-60 poäng
Februari 2006

Handledare: Mats Hagnell och Lars-Erik Öller

Abstract

In this essay we aim at finding an appropriate flash estimator of the quarterly Swedish private consumption (PK). With the aid of the statistics program TRAMO we study if monthly data from the consumer survey (HIP) and retail industry (DH) can be used in a transfer function model (TFM) to forecast PK.

In the work of assessing the state of the market and the business trend, fast information from the national accounts is needed for making decisions for the economic politics in Sweden. A way to speed up the information process is to use leading economic indicators to assess this development.

Another way to get information faster is to use a flash estimate. Such an estimate is made by investigating whether a change in one variable can be approximated by another. The idea of flash estimates is that it should be available earlier than the variable that's estimated. This method is used in the UK, Italy and Portugal.

If a flash estimate can be found, then a forecast for PK is possible between 40 and 100 days earlier than the ordinary quarterly report, depending on whether one, two or three months were used to be in the model.

To make one-step ahead forecasts of PK we use the program TRAMO. The forecasts are evaluated by comparing the absolute mean percentage error (MAPE) and by applying the forecast accuracy tests of Granger-Newbold and Diebold-Mariano.

In the analysis of the residuals of the transfer function models with one, two and three months of data we saw that the Jarque-Bera test for normality, Durbin-Watson's and Ljung-Box's test for autocorrelation all gave good values. MAPE for the forecasts all gave a lower value for the TFM than the univariate model. On the basis of these results all the TFM improved the forecasts of PK. PK + (Framåt_{2mån}, DH_{2mån}) gave the lowest MAPE (0,58%) of the models.

The Granger-Newbold and Diebold-Mariano tests resulted in non-significantly better forecasts made by TFM with one month data. For the TFM with two and three months of data only PK+CCI_{2mån}, DH_{2mån} and PK+Framåt_{3mån}, DH_{3mån} respectively were found non-significantly better. All other forecasts made by TFM were significantly better than the forecast made by the univariate model at the 5%-level.

The four TFM (PK+Samtida_{2mån}, DH_{2mån}, PK+Framåt_{2mån}, DH_{2mån}, PK+CCI_{3mån}, DH_{3mån} and PK+Samtida_{3mån}, DH_{3mån}) can be used as a flash estimate of the Swedish private consumption. The most accurate forecast was made with the PK+Framåt_{2mån}, DH_{2mån}, which could present a forecast of PK 70 days before the quarterly forecast of the Swedish private consumption.

Innehållsförteckning

ABSTRACT	2
INNEHÅLLSFÖRTECKNING	3
FÖRORD.....	4
TACK	4
1 INLEDNING	5
2 METOD.....	8
2.1 ARMA MODELLER	8
2.2 ARIMA MODELLER	9
2.3 TRANSFERFUNKTIONSMODELLER	10
2.4 TRAMO/SEATS.....	10
2.5 TRANSFORMATION.....	11
2.6 STATIONARITET	11
2.7 EXTREMVÄRDEN.....	13
2.8 AUTOKORRELATION	13
2.9 MODELL OCH PROGNOSE	14
3 DATA.....	19
3.1 PRIVAT KONSUMTION	19
3.2 HUSHÅLLENS INKÖPSPLANER	19
3.3 DETALJHANDELN.....	20
4 RESULTAT	21
4.1 TEST FÖR STATIONARITET.....	21
4.2 MODELLSPECIFICERING	22
4.3 PROGNOSE	26
4.4 VILKEN PROGNOSE ÄR BÄST?	29
4.5 KAN MAN LITA PÅ DEN BÄSTA MODELLEN?	30
5 SAMMANFATTNING.....	32
REFERENSER	34
LITTERATUR	34
INTERNET	34
BILAGOR.....	35
HIP FRÅGEFORMULÄR.....	35
PRIVAT KONSUMTION	36
HIP – CCI.....	38
HIP – SAMTIDA	39
HIP – FRAMÅT	40
HIP – SFRAMÅT	41
DETALJHANDELN.....	42

Förord

Föreliggande rapport om flash-estimatorer har skrivits av Åsa Kalderstam som en c-uppsats i statistik vid Lunds universitet. Den får ses som ett led i en serie studier över hur man kunde få fram tidiga indikatorer för viktiga makroekonomiska variabler, se *Bakgrundsfakta* 2003:9 och 2004:14. Det är min förhoppning att dessa studier kan vara till hjälp vid utvecklingen av tidig rapportering på Statistiska centralbyrån.

Lars-Erik Öller
MP/LED

Tack

Idén till denna uppsats kommer från Lars-Erik Öller på SCB. Uppsatsen hade inte varit möjlig att genomföra utan hans inspiration och värdefulla hjälp.

1 Inledning

Det stora statistiska underlag som krävs för att kunna mäta ett lands BNP kallas för nationalräkenskaperna (NR). Underlaget hämtas från all möjlig annan statistik, utrikeshandel, detaljhandel, arbetade timmar, investeringsenkäten o.s.v.

Om man vill följa ekonomins utveckling är det inte bara intressant att veta hur mycket resurser som finns tillgängliga, utan också hur de används. Vad gör vi med det som producerats eller importerats? Man brukar dela in användningen av BNP i följande delar:

- Privat konsumtion – de varor och tjänster som hushållen förbrukar under året.
- Offentlig konsumtion – de varor och tjänster som staten, kommuner och landsting förbrukar under året.
- Investeringar
- Lagerinvesteringar
- Export
- Import

Det innebär att man kan skriva:

$$\text{BNP} = \text{privat konsumtion} + \text{offentlig konsumtion} + \text{investeringar} + \text{lagerinvesteringar} + \text{export} - \text{import}$$

Det finns flera faktorer som påverkar den långsiktiga utvecklingen. Några aspekter är att konsumentens beslut, tid och budgetrestriktion sätter gränsen. Då konsumenten har ändliga resurser, måste denne bestämma om han ska spendera hela sin inkomst, eller spara en del för framtida konsumtion eller kanske till och med låna, eller ta till egna sparmedel för att kunna konsumera mer idag. Enligt nationalekonomisk teori försöker alltid individen att maximera sin nytta. En viktig faktor i detta resonemang är förväntningar, vilka i stor utsträckning styr hur konsumenten väljer att spendera sina pengar över tid.

Substitutionsprincipen innebär att konsumenten aldrig är fast i sitt val, utan har möjlighet att ändra sin konsumtionskorg om förutsättningarna förändras. Konsumenten fattar ett beslut vid tidpunkt t som kommer slå igenom vid tidpunkt $t+1$. En vanligare och mer flexibel modell för adaptiva förväntningar är till exempel att kommande inflationsvärde är det samma som det senast observerade värdet. Detta kallas för naiv prognos eller bakåtblickande förväntningar.

Enligt den permanenta inkomsthypotesen väljer inte konsumenten enbart sin konsumtion på dagens inkomst utan även på sin förväntade framtida inkomst. Den förväntade inkomsten kan emellertid förändras om konsumenten får ny information som påverkar dennes förväntningar i någon riktning.

I arbetet med att bedöma konjunkturläget och var i konjunkturcykeln vi befinner oss behövs därför snabb information från nationalräkenskaperna eftersom denna information används som beslutsunderlag för den ekonomiska politiken i Sverige. Ett sätt att påskynda informationsprocessen är att använda ekonomiska indikatorer för att bedöma denna

utveckling. Exempel på ekonomiska indikatorer är industriproduktionsindex, konsumentprisindex och Konjunkturinstitutets enkät hushållens inköpsplaner (HIP).

Ett ytterligare sätt att få information snabbare är att använda sig av så kallade flashestimater. Ett sådant estimat kan närmast beskrivas som en proxyvariabel, där det undersöks om en variabels förändring kan approximeras med någon annan. Idén med flashestimater är att det ska finnas tillgängligt snabbare än det man ursprungligen vill estimeras. Flashestimater har historiskt använts genom kvantifiering av kvalitativa data och kombineras med tidsseriedata för att förutsäga något aggregat inom nationalräkenskaperna. Utifrån dessa estimaters prediktionsförmåga viktas sedan resultaten in i skattningen av NR. Detta tillvägagångssätt används bland annat i Storbritannien, Italien och Portugal, se Bolminger (2004)

Eurostat undersöker lösningar för att få fram information snabbare. Målet är att få ut nationalräkenskaper kvartalsvis på europainivå med en fördröjning med maximalt 45 dagar. För att detta ska bli möjligt krävs att varje land kan leverera data minst lika snabbt, helst snabbare. Idag är detta inte möjligt.

Arbetet med flashestimatorer följer vanligtvis en tvåstegsprocess var det första steget består av att identifiera och välja ett lämpligt datamaterial utifrån vissa önskvärda egenskaper. Förutom att datamaterialet skall vara tillgängligt snabbare än data för den variabel som ska estimeras så måste korrelationen vara stark och stabil så att estimatören blir tillförlitlig. Nästa steg blir att identifiera och skatta sambandet mellan hjälpvariabeln och aggregatet för att sedan kunna skapa prognosmodeller, se Bolminger (2004)

I denna uppsats söker vi efter ett flashestimater för den kvartalsvisa totala privata konsumtionen i Sverige (PK). Syftet är att undersöka möjligheten att använda månadsdata för enkäten Hushållens inköpsplaner (HIP) och detaljhandeln (DH) som ledande information för att få fram en snabb och tillförlitlig prognosmodell för PK. Modellen skall i första hand användas för att skatta innevarande kvartals PK och kommer att jämföras med modeller som enbart bygger på kvartalsdata för PK utan att utnyttja informationen i månadsdata för HIP och DH.

Kvartalsdata för NR publiceras 70 dagar efter kvartalets slut medan månadsdata för DH kommer ut 25-26 dagar efter månadens slut och månadsdata för HIP kommer ut ca. 30 dagar efter månadens slut. Därmed kan man, om korrelationen är tillräckligt stark, skapa prognosmodeller som bygger på dessa månadsdata. I bästa fall räcker det med månadsdata för kvartalets första månad men mer troligt är att det kan behövas två månader. Även en prognos som baseras på tre månaders månadsdata ger snabbare information än om enbart kvartalsdata används. I figur 1.1 kan en tidslinje över de olika publiceringstiderna ses.

Kv 1			Kv 2			Kv 3			Kv 4		
Jan	Feb	Mars	April	Maj	Juni	Juli	Aug	Sep	Okt	Nov	Dec
HIP _{4:2}	HIP _{4:3}	HIP _{1:1}	HIP _{1:2}	HIP _{1:3}	HIP _{2:1}	HIP _{2:2}	HIP _{2:3}	HIP _{3:1}	HIP _{3:2}	HIP _{3:3}	HIP _{4:1}
DH _{4:2}	DH _{4:3}	DH _{1:1}	DH _{1:2}	DH _{1:3}	DH _{2:1}	DH _{2:2}	DH _{2:3}	DH _{3:1}	DH _{3:2}	DH _{3:3}	DH _{4:1}
PK _{Kv4}			PK _{Kv1}			PK _{Kv2}			PK _{Kv3}		

Figur 1.1: Publiceringstider av data för privat konsumtion (PK), hushållens inköpsplaner (HIP) och detaljhandeln (DH).

Flashestimatern som identifieras med första månadsdata för respektive kvartal skulle ge en tidsvinst med ca 100 dagar. Motsvarande tidsvinst skulle vara ca. 70 dagar om flashestimatern konstrueras med att använda data om första och andra månad för respektive kvartal. För en flashestimator konstruerad att använda data om första, andra och tredje månaden för respektive kvartal skulle tidsvinsten bli ca. 40 dagar.

I den här uppsatsen används statistikprogrammet TRAMO, se avsnitt 2.4, för att göra ettstegsprognoser för privat konsumtion med hjälp av månadsdata från hushållens inköpsplaner och detaljhandeln. Vi kommer inte att undersöka om andra programpaket ger andra resultat eftersom användandet av TRAMO är en del av syftet med uppsatsen.

Prognoserna utvärderas sedan genom att de jämförs med en prognos gjord med en univariat modell för privat konsumtion. Man jämför det absoluta procentuella medelfelet, MAPE. Därefter testas om träffsäkerheten skiljer sig mellan univariata prognoser och de som använder sig av hjälpvariabler på månad. Granger-Newbolds och Diebold-Marianos tester används för detta ändamål. Avslutningsvis kommer vi även att se på ett 95% konfidensintervall för den bästa modellen.

Uppsatsen inleds med avsnitt 1 följt av avsnitt 2 som bland annat tar upp metodiken bakom TRAMO/SEATS samt det tillvägagångssätt som använts. I avsnitt 3 redovisas data-materialet och i avsnitt 4 presenteras resultaten. En sammanfattning presenteras i avsnitt 5.

2 Metod

2.1 ARMA modeller

En stationär tidsserie kan beskrivas av en ARMA modell. Man använder sig av historiska data för att ta fram modellen och med hjälp av den göra prognoser. Den generella formen för ARMA-modellen beskrivs nedan.

AR(p)-modell

AR(p) är en autoregressiv modell med p parametrar, där det nuvarande värdet i processen är en linjär kombination av tidigare p stycken värden, samt en slumpterm.

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t \quad (2.1.1)$$

där δ är en konstant, ϕ_i är parametrar och a_t är ett gaussiskt vitt brus. Vi kan flytta över alla z_t till en sida av ekvationen och skriva:

$$[1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p] z_t = \phi_p(B) z_t = a_t \quad (2.1.2)$$

Där B är den bakåtskiftande operatorm som definieras enligt:

$$B^p z_t = z_{t-p} \quad (2.9.1)$$

MA(q)-modell

MA(q) är en glidande medeltalsmodell med q parametrar, där det nuvarande värdet i processen är en linjär funktion av ett konstant värde δ och ett ändligt antal av tidigare slump-termer.

$$z_t = \delta + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (2.1.3)$$

Antaget att δ är lika med noll kan vi skriva ekvationen på följande sätt:

$$z_t = [1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q] a_t = \theta_q(B) a_t \quad (2.1.4)$$

ARMA(p,q)-modell

En ARMA-modell av ordning p och q , som består av dessa två delar, betecknas därför som:

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t - \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}, \quad (2.1.5)$$

vilket kan skrivas i kortare form enligt ovan:

$$\phi_p(B) z_t = \theta_q(B) a_t \quad (2.1.6)$$

2.2 ARIMA modeller

Alla tidsserier är dock inte stationära, se avsnitt 2.6, från början. När differentieringar krävs för att göra en tidsserie stationär talar man om ARIMA-modeller där I står för Integrated (antalet differentieringar). Modellen kan skrivas som:

$$\phi_p(B), \nabla^d z_t = \theta_q(B) a_t \quad (2.2.1)$$

där $\nabla^d = (1-B)^d$ är differentieringsoperatorm och d betecknar det minsta möjliga antal differentieringar som krävs för att tidsserien ska bli stationär.

Om serien uppvisar ett säsongsmönster finns det korrelation mellan observationer tillhörande samma säsong vid olika år. Om vi betecknar säsongen med s , så är z_t och z_{t-s} korrelerade. På säsongnivå betecknas AR(p)- och en MA(q)-parametrarna med Φ_p respektive Θ_Q . Vi definierar på säsongnivån enligt:


$$\Phi_p(B^s) \nabla_s^D z_t = \Theta_Q(B^s) a_t \quad (2.2.2)$$

$\nabla_s = 1 - B^s$ är differentieringsoperatorm på säsongnivå och D betecknar det minsta möjliga antal differentieringar på säsongnivå som krävs för att göra tidsserien stationär.

Tillsammans bildar (2.2.1) och (2.2.2) en ARIMA-modell definierad på icke-säsong- och säsongnivån, illustrerat i figur 2.2.1 och vars uttryck är:

$$\phi_p(B) \Phi_p(B^s) \nabla^d \nabla_s^D z_t = \theta_q(B) \Theta_Q(B^s) a_t \quad (2.2.4)$$

Modellens struktur karaktäriseras av värdena inom parenteserna (p,d,q) och (P,D,Q), ickesäsong- respektive säsongnivå. De anger antalet autoregressiva termer och antalet glidande medelvärdestermer. Dessutom anges det minsta antal differentieringar som krävs för att göra serien stationär. Periodiciteten s är 4 för kvartalsdata eller 12 för månadsdata. Visar tidsserien ingen säsongsvariation beskrivs processen utan säsongsdelen.



Figur 2.2.1: ARIMA-modellens struktur

2.3 Transferfunktionsmodeller

En ARIMA modell använder information från bara en tidsserie. Men ofta kanske det finns annan information som skulle kunna utnyttjas för att på ett bättre sätt modellera tidsserien. Detta kan man göra genom att lägga till en eller flera förklarande variabler.

Den generella transferfunktionsmodellen med en förklaringsvariabel x_t är:

$$y_t = \delta^{-1}(B)w(B)x_{t-b} + \phi^{-1}(B)\theta(B)a_t \quad (2.3.1)$$

där b är antalet perioder innan x_t börjar påverka y_t - värdena. $w(B) = (1 - w_1B - w_2B^2 - \dots - w_pB^p)$ är ett täljarpolynom av ordning p , där p är antalet tidigare värden av variabeln och $\delta(B) = (1 - \delta_1B - \delta_2B^2 - \dots - \delta_rB^r)$ är ett nämnarpolynom av ordningen r , där r är antalet lags, se Bowerman, O'Connell och Koehler (2004).

En ARIMA modell med k regressionsvariabler ser ut enligt:

$$(1 - B)z_t = b_0 + b_1x_{1,t} + b_2x_{2,t} + \dots + b_kx_{k,t} + N_t \quad (2.3.2)$$

där $(x_{1,t}, x_{2,t}, \dots, x_{k,t})$ är de förklarande variablerna i regressionen och N_t antas följa en ARIMA process. Konstanterna $(b_0, b_1, b_2, \dots, b_k)$ är regressionsparametrar, vilka skattas samtidigt som parametrarna för ARIMA processen. I en vanlig regression antas slump termen i ekvationen ovan vara vitt brus, se Enders (2004).

För en ARIMA (1,1,1) modell och en förklarande variabel ger detta modellen:

$(1 - B)z_t = b_0 + b_1x_{1,t} + N_t$ där $(1 - \phi_1B)N_t = (1 - \theta_1B)e_t$ och e_t är vitt brus.

En prognos kan se ut enligt: $\hat{z}_{t+h} = b_0 + b_1\hat{x}_{1,t+h} + \hat{N}_{t+h}$ (2.3.3)

2.4 TRAMO/SEATS

Statistikprogrammen TRAMO, "Time Series Regression with Arima Noise, Missing Observations and Outliers", och SEATS, "Signal Extraction in ARIMA Time Series", är två Fortran-program som utvecklades av Augustin Maravall och Victor Gomez vid Spaniens centralbank. Dessa program finns att ladda ner gratis från Spaniens centralbanks hemsida.

De två programmen är officiellt rekommenderade av Eurostat och den Europeiska centralbanken (ECB). Sedan 1999 använder SCB TRAMO/SEATS vid säsongrensning av den officiella statistiken, exempelvis nationalräkenskaperna och industriproduktionsindex. Dessförinnan användes programmet X-11-ARIMA. Bytet av säsongrensningsprogram ägde rum efter ett utvecklingsarbete, som genomfördes på SCB under slutet av 1990-talet, delvis i samarbete med Eurostat, se (Öhlén, 2003).

TRAMO är ett program för skattning och prognostisering av regressionsmodeller med hjälp av "exakt maximum likelihood" metod. Programmet identifierar och korrigerar för de olika typerna av extremvärden och kan även skatta speciella effekter såsom kalender-

effekt. Programmet kan identifiera adekvat ARIMA-modell och kan automatiskt även undersöka om en predifferanstransformation behövs. Dessa två möjligheter har använts för att välja rätt differens och modell för tidsserierna.

SEATS är ett program för skattning av icke-observerbara komponenter i tidsserier. Programmet använder en ARIMA-baserad metod. De olika komponenterna skattas och prognostiseras med signalextraheringsteknik applicerad på ARIMA-modeller, se (Öhlén, 2003).

En utförlig beskrivning av metodologin bakom de båda programmen finns att läsa i Gomez och Maravall (1994, 1996, 1998) och Maravall och Sánchez (2000).

2.5 Transformation

Vid skattning av univariata ARIMA-modeller utgår man från att tidsseriens varians är konstant över tiden, det vill säga homoskedastisk. Ekonomiska tidsserier är dock ofta växande över tiden och kortsiktsvariationen proportionell mot nivån. Det vanligaste förfaringsättet för att stabilisera serien är då att logaritmera den, vilket kan ha flera praktiska fördelar. Dels får man en direkt skattning på elasticiteten i regressionsekvationer med ekonomiska variabler och dels gäller, för små förändringar, att differensen av en logaritmisk serie är approximativt en procentuell förändring. Den viktigaste egenskapen är dock att vi kan få tidsserien homoskedastisk.

En mer generell transformation som kan användas för att stabilisera en tidserie med varierande varians är den så kallade Box Cox-transformationen.

För tidserien y_t definieras Box Cox-transformationen $T(y_t)$ som:

$$T(y_t) = \begin{cases} \frac{y_t^\lambda - 1}{\lambda} & \lambda \neq 0 \\ \ln(y_t) & \lambda = 0 \end{cases} \quad (2.5.1)$$

där λ är transformationsparametern.

2.6 Stationaritet

För att en ARIMA modell ska kunna användas måste residualen vara stationär. Det betyder att data fluktuerar kring ett konstant värde, medelvärdet, och att kovariansmatrisen är konstant över tiden. För att en slumpprocess ska kunna betraktas som stationär måste alltså följande villkor vara uppfyllda för alla t :

$$\text{Medelvärde: } E(y_t) = \mu \quad (2.6.1)$$

$$\text{Variansen: } \text{Var}(y_t) = E(y_t - \mu)^2 = \sigma^2 \quad (2.6.2)$$

$$\text{Kovariansen: } \gamma_k = E[(y_t - \mu)(y_{t-k} - \mu)] = g(k) \quad k = 1, 2, \dots \quad (2.6.3)$$

Om tidsserien inte är stationär kan den differentieras så att den blir stationär, se avsnitt 2.2. En icke-stationär tidserie av d :te graden kan alltså transformeras till en stationär

tidsserie genom differentiering d gånger. Ofta räcker det med att ta första differensen. Att tidsserien har blivit stationär kan testas genom ett Dickey-Fuller test.

Dickey-Fuller- och utökat Dickey-Fuller-test

Antag:

$$Y_t = \rho Y_{t-1} + \varepsilon_t \quad (2.6.4)$$

där ε_t är ett vitt brus och ρ är AR-parametern för Y_t , då sägs den ha enhetsrot i fall $\rho=1$. En process med en enhetsrot är inte stationär. I detta fall betecknas serien med I(1). Om $|\rho|<1$ så är tidsserien stationär och betecknas med I(0). Är däremot $|\rho|>1$ blir processen explosiv.

Y_{t-1} kan subtraheras på båda sidorna av ekvationen och vi får:

$$Y_t - Y_{t-1} = \rho Y_{t-1} - Y_{t-1} + \varepsilon_t = (\rho - 1)Y_{t-1} + \varepsilon_t, \quad (2.6.5)$$

vilket kan skrivas om till:

$$\Delta Y_t = \delta Y_{t-1} + \varepsilon_t, \quad (2.6.6)$$

där Δ är symbolen för första differensen och δ är lika med $\rho-1$. Är $\delta=0$ har vi en I(1) tidsserie.

Nollhypotesen för Dickey-Fuller-test (DF-test) är $\delta=0$ och mothypotesen är att $\delta < 0$. Förkastar man nollhypotesen är tidsserien I(0). Teststatistikan har en icke-standardfördelning (τ -fördelning) och värdet på statistikan skall vara negativt, annars är tidsserien explosiv.

DF-testet kan utföras i tre versioner:

- 1) För Y_t , process utan drift och utan deterministisk trend: $\Delta Y_t = \delta Y_{t-1} + \varepsilon_t$
- 2) För Y_t , process med drift (β) och utan deterministisk trend: $\Delta Y_t = \beta + \delta Y_{t-1} + \varepsilon_t$
- 3) För Y_t , process med drift och deterministisk trend (t): $\Delta Y_t = \beta + \beta_2 t + \delta Y_{t-1} + \varepsilon_t$

Det kritiska värdet för DF-testen är olika beroende på vilken version som används. Valet av version som skall användas beror på empiriska grunder.

ADF-test (Augmented Dickey-Fuller test) tar hänsyn till att feltermerna kan vara korrelerade. Testet innehåller ett specifikt antal laggade värden av den beroende variabeln ΔY_t . ADF- testet kan även detta utföras i de tre ovan nämnda versionerna. Teststatistikan är

$$t_{ADF} = \frac{\hat{\delta}}{s_{\hat{\delta}}} \quad (2.6.7)$$

där $s_{\hat{\delta}}$ är standardavvikelsen för $\hat{\delta}$ och "H₀: enhetsrot i y_t " förkastas vid stora negativa t_{ADF} värden. För utförligare information om Dickey-Fuller test, se Enders, W. (2004).

2.7 Extremvärden

Extremvärden (outliers) är observationer, som avviker från de övriga värdena i serien även om vi tar hänsyn till säsong- och kalendereffekter (för att kunna definiera en avvikelse måste en specifik gräns fastställas). Extremvärdena definieras utifrån tre skilda typer:

- Additivt extremvärde (AO) – karakteriseras av att den påverkar serien endast vid en tidpunkt, varvid serien ”hoppas till” men genast återgår till ungefär samma nivå som tidigare.
- Nivåskifte (LS) – serien hoppas till en annan nivå och stannar där.
- Temporär förändring (TC) – serien hoppas till en ny nivå, men återgår till den ursprungliga nivån efter några perioder.

Orsakerna till att extremvärdena existerar i en serie kan variera. I vissa fall kan förändringar i den ekonomiska politiken ge upphov till extremvärden. I andra fall kan externa händelser påverka serien, till exempel att världsmarknadspriset på olja av någon anledning drastiskt förändras, fel i statistiken eller en strejk.

Extremvärden bör undersökas noggrant. Det finns flera problem som extremvärden kan ge upphov till ex. bias och felaktig slutledning.

2.8 Autokorrelation

Autokorrelation uppstår om det finns samband mellan observationerna för olika tidsperioder i en tidsserie. Om autokorrelation existerar i residualerna är koefficientskattningens standardfel och teststatistikor inte längre konsistenta. Vid test för autokorrelation utan strikt exogena förklarande variabler används ett annat test än det vanliga Durbin-Watson testet.

Durbin-Watsons test

För att testa om det föreligger negativ eller positiv linjär autokorrelation mellan ε_t , dvs. feltermen i period t och ε_{t-1} , feltermen i perioden $t-1$, används Durbin-Watson test vars statistika är:

$$d = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad (2.8.1)$$

där e_1, e_2, \dots, e_n är de estimerade residualerna i tidsordning. Nollhypotesen är att feltermerna inte är autokorrelerade och mothypotesen är att de är antingen positivt eller negativt autokorrelerade. Durbin och Watson visade att genom att sätta sannolikheten för så kallade Typ I-fel till α så gäller följande:

1. Om $d < d_{L,\alpha/2}$ kan nollhypotesen förkastas.
2. Om $d > d_{U,\alpha/2}$ kan nollhypotesen inte förkastas.
3. Om $d_{L,\alpha/2} \leq d \leq d_{U,\alpha/2}$ kan nollhypotesen varken bekräftas eller förkastas.

För utförligare resonemang kring Durbin-Watson test se Ramanathan (2002).

Ljung-Boxs test

Det kan även förekomma en annan form av autokorrelation än den av första ordningen. När den beroende variabeln är fördröjd på höger sida i modellen används Ljung-Box testet Q_{LB} . Q -statistikan testar nollhypotesen att det inte föreligger någon autokorrelation upp till ordning k . Q_{LB} definieras som:

$$Q_{LB} = n'(n' + 2) \sum_{l=1}^K \frac{r_l^2(\hat{a})}{(n' - l)} \quad (2.8.2)$$

Här är $n' = n - d$, där n är antalet observationer i original-tidsserien och d är antalet differentieringar på icke-säsongnivå som använts för att göra tidsserien stationär. r_l^2 är den kvadrerade autokorrelationen mellan två residualer separerade med l tidsenheter. Q_{LB} är $\chi^2_{m,\alpha}$ -fördelad. Frihetsgraderna, m , ges av antalet observationer minus antalet skattade parametrar och α är den valda signifikansnivån. Om $Q > \chi^2_{m,\alpha}$ påvisas autokorrelation vilket innebär att modellen inte är adekvat. Om man väljer för få laggar upptäcker inte testet korrelation mellan laggar av högre ordning. Om istället för många laggar väljs blir styrkan i testet svagt.

För utförligare resonemang kring Ljung-Box test se Bowerman, O'Connel, Koehler (2005).

2.9 Modell och prognos

Ett prognosfel, e_t , definieras som skillnaden mellan verkligt (y_t) och skattat (\hat{y}_t) värde, $e_t = y_t - \hat{y}_t$. Bias är ett konstant prognosfel över tiden, dvs. att de verkliga värdena i genomsnitt är högre eller lägre än prognosvärden. För att upptäcka bias jämför man verkliga värden med prognosvärden över en längre tidsperiod. Slumpmässig variation är den andra delen av prognosfelet. När bias är borttagen betyder detta att prognosen är lika sannolik att vara låg som hög vid en given tidpunkt.

Ett sätt att utvärdera prognoser är att kontrollera riktningssfel eller om prognosen är bättre eller sämre än en naiv prognos. Det är viktigt att tänka långsiktigt i val av prognosmetodik och utvärdera de statistiska egenskaperna hos olika prognoser. Exempelvis kan en prognos som systematiskt överskattar/underskattar utvecklingen av privat konsumtion, men som har god precision, föredras framför en annan prognos som inte gör något genomsnittligt fel på efterfrågenivån, men istället har dålig precision.

För att ta reda på hur bra prognosmodeller är på att göra prediktioner kan man jämföra prognosen med det man vill prognostisera genom att rita diagram. Detta kan fungera som en första indikator.

Naiv modell

När en tidsserie utgör en kumulation av chocker som beter sig som vitt brus kallas den för en slumpvandring och kan skrivas som $y_t = y_{t-1} + \varepsilon_t$ där alltså ε_t är i.i.d. För att det överhuvudtaget ska vara meningsfullt att göra prognoser måste de prognoser man får fram visa sig bättre överrensstämma med det sanna värdet än vad en naiv prognos gör,

det vill säga den optimala prognosen för en slumpvandring. Den naiva prognosen kan användas som ett slags måttstock på hur bra de andra prognoserna är.

Om den studerade tidsserien innehåller ett tydligt säsongmönster kommer den naiva modellen att göra dåliga prognoser. Det man då kan göra är att använda en variant på denna modell för att kunna ta hänsyn till säsongvariationen. Den naiva modell som istället kommer att användas är t.ex. $(1 - B)(1 - B^4)y_t = \varepsilon_t$ eller $(1 - B^4)y_t = \varepsilon_t$.

Prognosen kan i det förra fallet skrivas som:

$$\hat{y}_t^{Prog} = E(y_t) = y_{t-1} + (y_{t-4} - y_{t-5}) \quad (2.9.1)$$

I denna uppsats kommer istället en univariat ARIMA-modell för privat konsumtion, se avsnitt 4.2, att användas som måttstock vid jämförelse av modellerna. Att vara bättre än ARIMA är ett strängare krav än att vara bättre än en naiv prognos.

BIC

Vid identifiering av ARIMA-modeller i programmet TRAMO läggs ofta speciell vikt vid måttet BIC (Bayes Information Criterion). Den modell som minimerar värdet på BIC är enligt kriteriet också den bästa modellen. BIC-värdet används följaktligen till att jämföra de olika modellerna som anpassats till en given tidsserie. Värdet bygger på likelihood-funktionen, L , och definieras enligt:

$$BIC = -2\log(L) + K\log(T) \quad (2.9.3)$$

där K representerar antalet parametrar i modellen och T antalet observationer, som används vid skattningen av modellens parametrar. Genom att öka komplexiteten hos en tidsseriemodell, dvs. att öka antalet parametrar, kan värdet på L ökas, vilket dock kan leda till en så kallad överparametrisering av modellen. BIC-måttet kan därmed ses som en justering av likelihoodfunktionen på så sätt att ett straff utdelas för antalet parametrar, K , som modellen innehåller.

AIC

Ett mått som liknar BIC är AIC (Akaike's Information Criterion), som definieras enligt:

$$AIC = -2\log(L) + 2K \quad (2.9.4)$$

En skillnad mellan AIC och BIC är att AIC har en tendens att godkänna överparameteriserade modeller, medan BIC kan vara för sträng.

Skevhets och Kurtosis

TRAMO/SEATS testar om residualerna är normalfördelade genom att kontrollera fördelningens symmetri och toppighet. Skevhet kan översättas med ordet asymmetri och innebär att den ena svansen i normalfördelningskurvan är mer utdragen än den andra. För normalfördelning ska värdet på skevheten vara 0. Värdet definieras enligt:

$$\frac{E((x - \mu)^3)}{(\text{Var}(x))^{3/2}} \quad (2.9.5)$$

Kurtosis eller toppighet är ett mått på i vilken utsträckning värdena befinner sig nära medelvärdet av fördelningen eller i svansarna. Man skiljer på flera olika typer av kurtosis, vilka bestäms som:

- *Mesokurtosis* är benämningen på fördelningar med kurtosisvärde likt normalfördelningen.
- *Platykurtosis* innebär att fördelningen har ett kurtosisvärde, som är mindre än normalfördelningens värde. Fördelningen har ett relativt tjockt mittparti på båda sidorna av medelvärdet och en låg toppighet.
- *Leptokurtosis* är en beteckning för ett kurtosisvärde, som är större än normalfördelningens värde. Fördelningen har mer sannolikhetsmassa i svansarna, så kallade "tjocka" svansar, och är toppigare än normalfördelningen.

För normalfördelningen ska värdet på kurtosis vara 3 och beräknas enligt följande:

$$\frac{E((x - \mu)^4)}{(\text{Var}(x))^2} \quad (2.9.6)$$

Jarque-Bera

Jarque-Beras normalitetstest kontrollerar om feltermerna följer en normalfördelning. Teststatistikan JB är $\chi^2_{2,\alpha}$ - fördelad och ger ett kritiskt värde på 5,99 på 5%-nivån.

$$JB = n \left[\frac{S^2}{6} + \frac{(K - 3)^2}{24} \right] \quad (2.9.7)$$

där n är antal observationer i stickprovet, S är skevheten och K är kurtosismåttet. Är teststatistikan mindre än 5,99 kan nollhypotesen att feltermerna följer en normalfördelning ej förkastas. Skulle nollhypotesen förkastas innebär detta att det finns en asymmetri (skevhet) och/eller toppighet (kurtosis) som avviker från normalfördelningen. Skevhet och kurtosis kan även testas var för sig med den ena av de två termerna i JB och med en frihetsgrad.

Granger-Newbold

Detta test jämför två prognosers precision. Låt δ_1 vara prognosfelet i den första och δ_2 vara prognosfelet i den andra prognosen, $(\delta_{1,i}, \delta_{2,i})$ är oberoende av $(\delta_{1,j}, \delta_{2,j})$ för $i \neq j, i=1 \dots n$ och $j=1 \dots n$ där n är antalet prognoser. Ponera att det finns två nya stokastiska variabler $\delta^+ = \delta_1 + \delta_2$ och $\delta^- = \delta_1 - \delta_2$. Det förväntade värdet av produkten är:

$$E(\delta^+ \delta^-) = E(\delta_1^2 + \delta_1 \delta_2 - \delta_1 \delta_2 - \delta_2^2) = E(\delta_1^2) - E(\delta_2^2) = \sigma_1^2 - \sigma_2^2 \quad (2.9.8)$$

Där $E(\delta^+)$ och $E(\delta^-)$ antas vara 0 och där σ_1^2 och σ_2^2 är lika om och endast om de nya variablerna δ^+ och δ^- är okorrelerade så att korrelationen

$$\rho = \frac{\sum_{i=T+1}^M \delta_i^+ \delta_i^-}{\sqrt{\sum_{i=T+1}^M (\delta_i^+)^2 \sum_{i=T+1}^M (\delta_i^-)^2}} = 0 \quad (2.9.9)$$

Om den andra prognosen är bättre än den första så är σ_1^2 större än σ_2^2 , dvs. $r > 0$. Förutsatt att σ_1^2 är felvariansen för första prognosen och σ_2^2 är felet för den andra prognosen. T är antalet observationer som använts för att göra prognoserna och M är $T +$ antalet prognoser som gjort.

Följande hypoteser testas genom ett t-test:

$$H_0 : \sigma_1^2 = \sigma_2^2 \text{ mot } H_1 : \sigma_1^2 > \sigma_2^2$$

$$t_{GN} = \frac{\hat{r} \sqrt{N-2}}{\sqrt{1-\hat{r}^2}} \quad (2.9.10)$$

t_{GN} följer en t-fördelning med beslutsregel $P(t_{GN} > \alpha)$ där $\alpha = t_{0,05}(N-2)$ där N är antalet observationer som används för att göra prognoserna. För utförligare resonemang, se Enders (2004).

Diebold-Mariano

Ett annat sätt att bedöma vilken prognosmetod som är bäst är Diebold-Mariano testet, som gör parvisa jämförelser där man utgår från två prognoser $\hat{y}_{1,t}$ och $\hat{y}_{2,t}$ för tidsserien y_t med prognosfelen $u_{1,t}$ och $u_{2,t}$. Jämförelsen består av att skillnaden av de kvadrerade prognosfelen, $d_{t+1} = \hat{u}_{1,t+1}^2 - \hat{u}_{2,t+1}^2$, beräknas för att sedan räkna ut skillnaden mellan medelkvadratfelet, MSE, för de båda prognoserna:

$$\bar{d} = \frac{\sum_{i=1}^H d_{i+1}}{H} = MSE_1 - MSE_2 \quad (2.9.11)$$

$$t_{DM} = \frac{MSE_1 - MSE_2}{\sqrt{\text{Var}(MSE_1 - MSE_2)}} \frac{\bar{d}}{\sqrt{\text{Var}(\bar{d})}} = \frac{\bar{d}}{\sqrt{\sum_{i=1}^H (d_{i+1} - \bar{d})^2 / H^2}} \quad (2.9.12)$$

$$H_0 : MSE_1 = MSE_2$$

$$H_1 : MSE_1 > MSE_2$$

t_{DM} följer en t-fördelning med beslutsregel $P(t_{DM} > \alpha)$ där $\alpha = t_{0,05}(H-1)$ där H är antalet prognoser. För utförligare information se Enders (2004) samt Clark och McCracken (1999).

MAPE

Det procentuella felet räknas ut enligt: $PE_t = \left(\frac{e_t}{y_t} \right) \cdot 100$ (2.9.13)

Då negativa och positiva fel kan ta ut varandra använder man absolutbeloppet för att undvika detta. Ekvationen används för att räkna ut det absoluta medelfelet i procent för en tidsperiod enligt:

$$MAPE = \frac{1}{n} \sum_{t=1}^n |PE_t| \quad (2.9.14)$$

Prediktionsintervall

För att utvärdera hur bra en prognos är kan man använda sig av ett prediktionsintervall och genom att studera bredden på intervallet bedöma hur träffsäker prognosen är och därmed göra bedömningen om man kan lita på den prognos man tar fram.

$$[\hat{y}_{n+\tau}(n) \pm z \cdot SE_{n+\tau}(n)] \quad (2.9.15)$$

$\hat{y}_{n+\tau}(n)$ betecknar en prognos gjord vid tidpunkt n vid period $n + \tau$, detta ger formeln för prediktionsintervallet. Där $SE_{n+\tau}(n)$ är standardfelet för prognosfelet, i tidpunkt n när man prognostiserar τ steg framåt.

3 Data

3.1 Privat konsumtion

Med privat konsumtion (PK) avses i denna uppsats den totala privata konsumtionen i miljoner kr per kvartal i 2000 års penningvärde. Data som används är perioden kvartal 1 1980 till kvartal 2 2005 (102 observationer). Data har hämtats från SCBs statistikdatabas på Internet. Den totala privata konsumtionen kommer att representeras av y_t i formlerna och herefter endast benämnas som privat konsumtion i uppsatsen. 12 observationer (3 år) i slutet av datamaterialet (kvartal 3, 2002 – kvartal 2, 2005) har tagits bort ur tidsserieanalysen för att kunna jämföras med prognoserna. Tidserien PK_t omfattar 90 observationer (kv.1 1980 – kv.2 2002).

3.2 Hushållens inköpsplaner

Undersökningen Hushållens inköpsplaner (HIP) har genomförts sedan oktober 1973. Den belyser hushållens uppfattning om den egna samt den svenska ekonomiska utvecklingen, och ligger till grund för konjunkturprognoser.

Undersökningen har sedan 1973 genomförts av SCB och startade som en kvartalsundersökning men är sedan 1993 månatlig. Konjunkturinstitutet (KI) har varit uppdragsgivare sedan 1979 och från oktober 1995 även EG-kommissionen i Bryssel.

Urvalsstorleken har successivt reducerats sedan 1973. Urvalet var från början 10000 hushåll, från juli 1979 var det 6600 hushåll och 1985 minskades urvalet ytterligare till 4200 för april- och oktoberundersökningarna och 1500 för januari- och juliundersökningarna.

Från och med 1993 gjordes undersökningen i anslutning till SCB:s arbetskraftsundersökning (AKU) och omfattade då 2200 hushåll. Från oktober 1995 gjorde SCB ett tilläggsurval av personer 65 år och äldre. Från och med januari 2000 genomförde SCB undersökningen i en s.k. telefonbuss med flera kunder. Urvalet omfattade då telefonbussens 2000 individer 18 – 74 år plus ett tilläggsurval av 100 personer 16-17 år och 75- år. Det totala urvalet under 2000-2001 utgjordes därmed av 2100 intervjuer.

Från och med januari 2002 genomförs undersökningen av GfK Sverige AB. Undersökningen genomförs månadsvis med individer 16 – 84 år och det totala urvalet utgörs av 1500 nettointervjuer. Några justeringar genomfördes i frågeformuläret inför 2002. Eftersom frågorna i enkäten har varierat har jag valt att titta på de tre frågor som varit med längst

- Hushållets ekonomi jämför med ett år tidigare (Samtida)
- Hushållets ekonomi om ett år (Framåt)
- Sveriges ekonomi om ett år (SFramåt)

(Frågornas exakta formulering framgår av bilagan)

Förtroendeindikatorn (CCI) är ett medeltal av det tre första HIP-variablerna och kallas ofta för förtroendeindikator. I denna uppsats avser CCI den gamla förtroendeindikatorn eftersom det tillkommit två frågor i beräkningen av CCI som i dagsläget är ett medeltal av fem frågor.

Resultatet av HIP-undersökningarna kommer i slutet av den månad enkäten görs. Det är därför intressant att se om denna serie kan förutspå privat konsumtion då resultatet av HIPen kommer ut ca ett kvartal före data för privat konsumtion.

Svaren som ges av dessa undersökningar är ”mycket bättre”, ”något bättre”, ”ungefär lika”, ”något sämre”, ”mycket sämre” och ”vet inte”. För att kunna representera hela denna fördelning med en enda siffra gör man om resultaten till netttotal. Detta görs genom att man tilldelar svaren olika värden. +1 för ”mycket bättre” och ”bättre”, 0 för ”samma” och -1 för ”sämre” och ”mycket sämre”. Före 1993 gavs endast svaren ”bättre”, ”samma” och ”sämre”. Om till exempel 40 procent anser att den ekonomiska situationen är bättre i nuläget jämfört med för tolv månader sen, 10 procent anser att den är sämre och 50 procent anser att den är oförändrad. Då blir nettotalet 40 minus 10, det vill säga 30.

Data som används är kvartalsdata för kvartal 1 1980 – kvartal 4 1992 (52 observationer) och månadsdata för januari 1993 – augusti 2005 (152 observationer). Dessa kommer från Konjunkturinstitutet.

Tidsserien $HIP_{1mån,t}$ skapas genom att ta första månaden i varje kvartal. Tidsserien $HIP_{2mån,t}$ skapas genom att ta medelvärdet av första och andra månaden i varje kvartal och tidsserien $HIP_{3mån,t}$ skapas genom att ta medelvärdet av första, andra och tredje månaden i varje kvartal. Samtliga serier innehåller totalt 103 observationer.

3.3 Detaljhandeln

Detaljhandeln (SNI-kod 52) omfattar all försäljning inom detaljhandeln. De värden som används avser egentlig detaljhandel vilket innebär att försäljning vid apotek och systembolag inte räknas med. Detaljhandeln (DH) sammanställs av SCB och Handelns Utredningsinstitut (HUI). Siffrorna över detaljhandeln tas fram genom att stora och små butikskedjor skickar in sina omsättningsdata till HUI och SCB. Publicering sker 25 till 26 dagar efter månadsskiftet.

Data för detaljhandeln är månadsdata i miljoner kronor i fasta priser med basår 2000. De har sedan omvandlats till årsförändringar kvartalsvis i procent och omfattar perioden januari 1980 – augusti 2005 (308 observationer).

Tidsserien $DH_{1mån,t}$ skapas genom att ta första månaden i varje kvartal. Tidsserien $DH_{2mån,t}$ är medelvärdet av första och andra månaden i varje kvartal och $DH_{3mån,t}$ medelvärdet av första, andra och tredje månaden i varje kvartal. Samtliga serier innehåller totalt 103 observationer.

Samtliga tidsserier åskådliggörs grafiskt i bilagan.

4 Resultat

I detta avsnitt presenteras de modeller som valts i TRAMO samt diagnostiken för varje modell. Modellerna kommer sedan att både testas med hjälp av de teststatistikor som presenterades i teoriavsnittet och ställas mot varandra med hjälp av Granger-Newbold och Diebold-Mariano test och det absoluta procentfelet, MAPE, för att få en antydning om vilken modell som är bäst.

4.1 Test för stationaritet

Dickey-Fuller testet används för att testa om tidsserierna kan betraktas som stationära, vilket beskrevs i teoriavsnittet. Ofta räcker det med en differentiering för att få en ekonomisk tidsserie stationär. Testet har dålig styrka, vilket innebär att det finns en risk att man inte upptäcker en felaktig nollhypotes (Enders 2004).

Tabell 4.1.1	Utan drift & trend		AIC	BIC		Utan drift & trend		AIC	BIC
PK	1,68	I (1)	1958	18,93	Framåt _{1mån}	-1,49	I (1)	529	3,22
lnPK	1,62	I (1)	-262	-5,74	Framåt _{2mån}	-1,28	I (1)	513	3,04
lnPK _{1-4 Diff}	-7,78	I (0)**	-471	-8,31	Framåt _{3mån}	-1,22	I (1)	512	3,03
CCI _{1mån}	-2,1	I (0)**	591	3,89	SFramåt _{1mån}	-2,47	I (0)**	721	5,31
CCI _{2mån}	-2	I (0)**	579	3,75	SFramåt _{2mån}	-2,38	I (0)**	689	5,02
CCI _{3mån}	-1,99	I (0)**	573	3,69	SFramåt _{3mån}	-2,41	I (0)**	684	4,95
Samtida _{1mån}	-1,65	I (0)*	526	3,12	DH _{1mån1-12Diff}	-3,86	I (0)**	442	2,16
Samtida _{2mån}	-1,66	I (0)*	520	3,06	DH _{2mån1-12Diff}	-3,61	I (0)**	387	1,66
Samtida _{3mån}	-1,55	I (1)	515	3,00	DH _{3mån1-12Diff}	-3,77	I (0)**	383	1,54
Kritiskt värde			** 5%-nivå = -1,95				* 10%-nivå = -1,61		

Tabell 4.1.1: ADF-test utökat med en lag.

Antalet lags bestäms genom att AIC/BIC värdet minimeras. Ingen antydning om autokorrelation i residualerna enligt Ljung-Box autokorrelationstest.

Samtida_{3mån}, Framåt_{1mån}, Framåt_{2mån}, Framåt_{3mån} kan ha enhetsrötter utan drift och deterministisk trend enligt ADF-testet utökat med en lag. De respektive τ -statistikorna är -1,55, -1,49, -1,28 och -1,22, se tabell 4.1.1. Alla är större än det kritiska τ -värdet -1,95 på signifikansnivån 5%. Därför kan nollhypotesen ej förkastas och processerna anses vara I(1), d.v.s. innehålla enhetsrötter och vara icke stationära.

När en av hjälpvariablerna används för att bestämma prognosmodellen för privat konsumtion finns det stor risk för meningslös regression, detta eftersom alla tidsserierna ej är stationära. Modellen som skattas utifrån tidsseriens observationer kan då inte användas för prognoser. För att kunna hitta en modell som kan användas för prognoser utanför de observerade värdena är det viktigt att egenskapen om svag stationaritet gäller.

Det kan dock uppstå kointegration mellan de icke-stationära serierna. Denna visar att en långsiktig relation mellan den beroende variabeln och hjälpvariablerna existerar. Feltermerna av regressionen mellan dessa två icke-stationära tidsserier är då stationära.

För att kontrollera om månadsdata för HIP och DH och PK är kointegrerade används AEG-test (Augmented Engle-Granger test). Testet består av att ett ADF-test på residualerna av regression av månadsdata för hjälpvariablerna på PK utförs. Det ADF-test som används på residualerna är utan drift och deterministisk trend. I tabell 4.1.2 kan vi se att vi kan förkasta nollhypotesen för alla hjälpvariablerna. Om nollhypotesen kan förkastas är variablerna kointegrerade och feltermerna stationära. Regressionen mellan PK och månadsdata av hjälpvariablerna är relevant och skattningarna robusta.

Tabell 4.1.2	Utan drift o trend		Utan drift o trend		
$\ln PK_{1-4 \text{ Diff } +}$			$\ln PK_{1-4 \text{ Diff } +}$		
CCI _{1mån} , DH _{1mån1-12Diff}	-7,50	I(0)**	Framåt _{1mån} , DH _{1mån1-12Diff}	-7,59	I(0)**
CCI _{2mån} , DH _{2mån1-12Diff}	-7,46	I(0)**	Framåt _{2mån} , DH _{2mån1-12Diff}	-7,56	I(0)**
CCI _{3mån} , DH _{3mån1-12Diff}	-7,43	I(0)**	Framåt _{3mån} , DH _{3mån1-12Diff}	-7,52	I(0)**
Samtida _{1mån} , DH _{1mån1-12Diff}	-7,79	I(0)**	SFramåt _{1mån} , DH _{1mån1-12Diff}	-7,45	I(0)**
Samtida _{2mån} , DH _{2mån1-12Diff}	-7,72	I(0)**	SFramåt _{2mån} , DH _{2mån1-12Diff}	-7,39	I(0)**
Samtida _{3mån} , DH _{3mån1-12Diff}	-7,71	I(0)**	SFramåt _{3mån} , DH _{3mån1-12Diff}	-7,59	I(0)**
Kritiskt värde	** 5%-nivå = -1,95		* 10%-nivå = -1,61		

Tabell 4.1.2: AEG-test utökat med en lag

Sammanfattningsvis ser vi att månadsdata för HIP och DH kan användas som regressionsvariabeln för att skatta den logaritmerade totala privata konsumtionen.

4.2 Modellspecificering

Som univariat modell har två modeller testats för den privata konsumtionen. Den ena är den klassiska Airlinemodellen, AIRMA(011)(011), vilket är en mycket vanlig modell som ofta passar för ekonomiska tidsserier med säsongmönster. Den andra en ARIMA(010)(011) modell, vilken även den är en enkel modell.

I tabell 4.2.1 kan vi se att båda modellerna har signifikanta MA-parametrar men en ARIMA(011)(011) har både lägst AIC- (-471,277) och BIC-värde (-8,3068) vilket tyder på att denna modell är den bättre av de två. För Airline-modellen hittas en signifikant temporär outlier vid kv.1 1993. Kritisk gräns för t-värdena är -1,96 och 1,96 för en signifikans på 5% nivå.

Airline-modellen kommer att användas som univariat modell för privat konsumtion vid jämförelse av enstegsprognoserna i avsnitt 4.3-4.4.

Tabell 4.2.1	θ_1 (t-värde)	Θ_1 (t-värde)	Extremvärden (t-värde)	AIC	BIC
ARIMA (011)(011)	-0,23791 (-2,23)	-0,43754 (-4,12)	TC (1 1993) -0,037936 (-3,32)	-471,277	-8,3068
ARIMA (010)(011)		-0,50822 (-5,44)		-462,412	-8,2633

Tabell 4.2.1: Parametervärden, AIC och BIC för två univariata modeller av PK inom samplet (kv. 1 1980 – kv. 2 2002).

Samtliga modeller med månadsdata som hjälpvariabler i tabell 4.2.2 har signifikanta MA-parametrar men för PK+Framåt_{1mån},DH_{1mån} och PK+SFRamåt_{1mån},DH_{1mån} är regressionsvariablerna DH_{1mån} respektive SFRamåt_{1mån} icke-signifikanta på 5%-nivån. PK+Framåt_{1mån},DH_{1mån} är dock signifikant på 10% nivån. I tre av modellerna med hjälpvariabler hittas samma nivåskiftande outlier vid kv.1 1993.

AIC och BIC är lägre för samtliga modeller med hjälpvariabler jämfört med den univariata men lägst för PK+CCI_{1mån},DH_{1mån} med en AIC på -480,08 och BIC på -8,35.

Tabell 4.2.2 1 mån	PK + HIP _{1mån} ,DH _{1mån}			
	CCI, DH	Samtida,DH	Framåt,DH	SFRamåt,DH
θ_1 (t-värde)	-0,25330 -2,33	-0,24685 -2,26	-0,23299 -2,16	-0,23808 -2,25
Θ_1 (t-värde)	-0,37986 -3,51	-0,39015 -3,64	-0,40087 -3,76	-0,36918 -3,36
Extremvärden (t-värde)	LS (1 1993) -0,03651 -3,25		LS (1 1993) -0,03664 -3,24	LS (1 1993) -0,03683 -3,45
HIP_t (t-värde)	0,00040 2,38	0,00094 3,68	0,00057 2,52	0,00012 1,31
DH_t (t-värde)	0,00055 2,22	0,00049 2,02	0,00049 1,93	0,00063 2,58
AIC	-480,08	-478,40	-480,97	-477,70
BIC	-8,35	-8,36	-8,36	-8,32

Tabell 4.2.2: ARIMA(011)(011) - Parametervärden, AIC och BIC för PK + (HIP_{1mån,t} + DH_{1mån,t}) inom samplet (kv. 1 1980 – kv. 2 2002).

I tabell 4.2.3 har samtliga modeller för hjälpvariabler med två månadersdata signifikanta MA-parametrar och endast PK+SFRamåt_{2mån},DH_{2mån} har regressionsvariablen SFRamåt_{2mån} icke-signifikanta på 5%-nivån. I tre av modellerna med hjälpvariabler hittas samma nivåskiftande outlier vid kv.1 1993 som för hjälpvariablerna med en-månadsdata.

AIC och BIC är lägre för samtliga modeller med hjälpvariabler jämfört med den univariata, men lägst för PK+Framåt_{2mån},DH_{2mån} med en AIC på -483,12 och BIC på -8,39, vilket är lägre än för modellerna med en månadsdata.

Tabell 4.2.3 2 mån	PK + HIP _{2mån} ,DH _{2mån}			
	CCI, DH	Samtida,DH	Framåt,DH	SFRamåt,DH
θ_1 (t-värde)	-0,25394 -2,35	-0,24354 -2,22	-0,23360 -2,15	-0,23618 -2,20
Θ_1 (t-värde)	-0,38174 -3,53	-0,40383 -3,80	-0,40459 -3,77	-0,36707 -3,34
Extremvärden (t-värde)	LS (1 1993) -0,03887 -3,47		LS (1 1993) -0,03854 -3,46	LS (1 1993) -0,03743 -3,59
HIP_t (t-värde)	0,00043 2,39	0,00082 3,07	0,00056 2,25	0,00010 1,03
DH_t (t-värde)	0,00052 2,10	0,00066 2,46	0,00060 2,14	0,00078 2,95
AIC	-480,16	-478,05	-483,12	-480,19
BIC	-8,35	-8,36	-8,39	-8,35

Tabell 4.2.3: ARIMA(011)(011) - Parametervärden, AIC och BIC för PK + (HIP_{2mån,t} + DH_{2mån,t}) inom samplet (kv. 1 1980 – kv. 2 2002).

I tabell 4.2.4 har endast PK+(Samtida_{3mån,t}, DH_{3mån,t}) signifikanta MA-parametrar och regressionsvariabler. Inga outliers hittas för någon av modellerna. AIC och BIC för PK+(Samtida_{3mån,t}, DH_{3mån,t}) är visserligen lägre än för den univariata med en AIC på -477,54 och BIC på -8,32 men dessa är inte lägre än för modellerna för en och två månadersdata. Därför har även en (010)(011)-modell testats för tre månadersdata.

Tabell 4.2.4 3 mån	PK + HIP _{3mån} , DH _{3mån}			
	CCI, DH	Samtida, DH	Framåt, DH	SFramåt, DH
θ_1 (t-värde)	-0,16075 -1,38	-0,22979 -2,01	-0,15925 -1,38	-0,14850 -1,26
Θ_1 (t-värde)	-0,43157 -4,05	-0,41698 -3,92	-0,45141 -4,26	-0,43873 -4,12
Extremvärden (t-värde)				
HIP _t (t-värde)	0,00038 1,92	0,00089 3,32	0,00054 2,07	0,00011 1,05
DH _t (t-värde)	0,00089 2,56	0,00089 2,79	0,00080 2,23	0,00100 2,87
AIC	-470,97	-477,54	-471,58	-468,32
BIC	-8,25	-8,32	-8,25	-8,21

Tabell 4.2.4: ARIMA(011)(011) - Parametervärden, AIC och BIC för PK + (HIP_{3mån,t} + DH_{3mån,t}) inom samplet (kv. 1 1980 – kv. 2 2002).

Tabell 4.2.5 3 mån	PK + HIP _{3mån} , DH _{3mån}			
	CCI, DH	Samtida, DH	Framåt, DH	SFramåt, DH
Θ_1 (t-värde)	-0,31256 -3,03	-0,39813 -4,00	-0,33370 -3,26	-0,37505 -3,73
Extremvärden (t-värde)	LS (1 1993) -0,03761 -3,68 AO (2 1987) 0,02297 3,15 AO (1 1985) 0,02267 3,12	AO (1 1985) 0,02561 3,20	LS (1 1993) -0,03980 -3,91 AO (2 1987) 0,02455 3,39 AO (1 1985) 0,02922 3,17	TC (1 1993) -0,03524 -3,50 AO (1 1985) 0,02464 3,12
HIP _t (t-värde)	0,00039 2,38	0,00082 3,19	0,00062 2,95	0,00008 0,89
DH _t (t-värde)	0,00101 3,56	0,00108 3,57	0,00089 3,06	0,00119 3,90
AIC	-496,36	-485,89	-498,80	-486,74
BIC	-8,51	-8,45	-8,54	-8,43

Tabell 4.2.5: ARIMA(010)(011) - Parametervärden, AIC och BIC för PK + (HIP_{3mån,t} + DH_{3mån,t}) inom samplet (kv. 1 1980 – kv. 2 2002).

I tabell 4.2.5 ser vi resultatet av en ARIMA(010)(011)-modell och hjälpvariablerna. Samtliga modeller för hjälpvariabler med tre månadersdata har nu signifikant MA-parametrar och endast PK+(SFramåt_{3mån,t}, DH_{3mån,t}) har regressionsvariabeln SFramåt_{2mån,t} icke-signifikanta på 5%-nivån. Dock hittas fler outliers för dessa modeller. I tre av modellerna med hjälpvariabler hittas samma nivåskiftande outlier vid kv.1 1993 som för hjälpvariablerna med en och två månadsdata. Dessutom hittas ytterligare två signifikanta additiva outliers vid kv. 2 1987 och kv.1 1985 för PK+(CCI_{3mån,t}, DH_{3mån,t}) och PK+(Framåt_{3mån,t}, DH_{3mån,t}). För PK+(Samtida_{3mån,t}, DH_{3mån,t}) hittas endast en signifikant additiv outlier vid kv. 1 1985.

AIC och BIC är lägre för samtliga modeller med hjälpvariabler jämfört med den univariata men lägst för PK+(Framåt_{3mån,t}, DH_{3mån,t}) med en AIC på -485,89 och BIC på -8,45, vilket även är lägre än för modellerna med en och två månadersdata.

I tabell 4.2.6-4.2.8 ser vi residualanalysen av respektive transferfunktionsmodell med en, två och tre månadersdata. TRAMO/SEATS kräver stark stationaritet för modellens residualer. Detta betyder att residualerna även skall vara normalfördelade. Den valda signifikansnivån är 5%. Det kritiska värdet närmar sig då 5,99. Om Jarque-Bera statistikan är mindre än det kritiska värdet kan nollhypotesen om att residualerna är normalfördelade ej förkastas. Vi konstaterar därför att alla modeller kan antas ha normalfördelade residualer då inget värde överskrider 5,99.

Tabell 4.2.6	PK	PK + HIP _{1mån} , DH _{1mån}		
		CCI, DH	Samtida, DH	Framåt, DH
Skevhets	-0,04	0,15	-0,01	0,31
Kurtosis	3,05	3,74	4,00	3,32
Jaqu-Bera	0,028	2,24	3,56	1,76
Durbin-Watson	1,8319	1,7570	1,7246	1,8582
LB _Q lag 16	11,52	7,87	6,96	12,58
(P-värde)	0,65	0,95	0,94	0,56
Kritiskt värde	23,689	26,296	23,685	23,685

Tabell 4.2.4: Diagnostik för residualerna för respektive transferfunktionsmodell med en-månadsdata inom samplet (kv. 1 1980 –kv. 2 2002).

Tabell 4.2.7	PK	PK + HIP _{2mån} , DH _{2mån}		
		CCI, DH	Samtida, DH	Framåt, DH
Skevhets	-0,04	0,16	0,02	0,35
Kurtosis	3,05	3,74	4,01	3,54
Jaqu-Bera	0,028	2,30	3,64	2,78
Durbin-Watson	1,8319	1,7583	1,7853	1,9082
LB _Q lag 16	11,52	12,58	7,25	13,97
(P-värde)	0,65	0,56	0,93	0,45
Kritiskt värde	23,689	23,685	23,685	23,685

Tabell 4.2.7: Diagnostik för residualerna för respektive transferfunktionsmodell med två-månadersdata inom samplet (kv. 1 1980 –kv. 2 2002).

Tabell 4.2.8	PK	PK + HIP _{3mån} , DH _{3mån}		
		CCI, DH	Samtida, DH	Framåt, DH
Skevhets	-0,04	-0,10	0,21	-0,18
Kurtosis	3,05	4,25	3,50	4,19
Jaqu-Bera	0,028	5,65	1,49	5,49
Durbin-Watson	1,8319	2,0686	2,0845	1,8335
LB _Q lag 16	11,52	7,82	19,59	8,89
(P-värde)	0,65	0,93	0,19	0,88
Kritiskt värde	23,689	24,996	24,996	24,996

Tabell 4.2.8: Diagnostik för residualerna för respektive transferfunktionsmodell med tre-månadersdata inom samplet (kv. 1 1980 –kv. 2 2002).

Med Durbin-Watson's test kontrollerar vi för linjär autokorrelation av första ordningen i residualerna. För en signifikansnivå på $\alpha=0.05$ med 85 observationer är $d_L=1,600$ och

$d_U=1,696$. Detta betyder att om Durbin-Watson d -statistika befinner sig mellan 1,600 och 2,400 förekommer ej autokorrelation av första ordningen i residualerna. Alla modeller har sin respektive statistika inom dessa gränser.

Ljung-Box-testen vid lag 16 ger även den bra resultat för samtliga modeller, eftersom alla värden ligger klart under den kritiska värdet för en signifikans på 5%-nivån. Linjär autokorrelation av högre ordning än ett förekommer därför ej.

4.3 Prognoser

För den univariata modellen, PK, och transferfunktionsmodellerna, PK+HIP_{1mån}, DH_{1mån}, PK+HIP_{2mån}, DH_{2mån}, PK+HIP_{3mån}, DH_{3mån}, har enstegsprognoser ($F_{t|t-1}$) gjorts, dvs. prognoser som är konstruerade så att endast ett kvartal isänder prognostiseras. Sedan läggs det verkliga värdet in från denna period när man sedan går ytterligare ett kvartal framåt. För modellerna med hjälpvariabler har $n+1$ värden använts dvs. när man gör prognoser på privat konsumtion för t.ex. $n=91$ så har använts $n=92$ observationer av HIPen och detaljhandeln.




Diagram 4.3.1: Prognoser för privat konsumtion med hjälp av en månadsdata för CCI, DH.




Diagram 4.3.2: Prognoser för privat konsumtion med hjälp av en månadsdata för Samtida, DH.




Diagram 4.3.3: Prognoser för privat konsumtion med hjälp av en månadsdata för Framåt,DH.

I diagram 4.3.1 - 4.3.3 ser vi enstegsprognoserna för de transferfunktionsmodellerna med en månadsdata. Att döma av diagrammen ser PK+Samtida_{1mån},DH_{1mån} ut att ge bäst prognoser.




Diagram 4.3.4: Prognoser för privat konsumtion med hjälp av två månadsdata för CCI,DH.




Diagram 4.3.5: Prognoser för privat konsumtion med hjälp av av två månadsdata för Samtida,DH.




Diagram 4.3.6: Prognoser för privat konsumtion med hjälp av av två månadsdata för Framåt, DH.

I diagram 4.3.4 - 4.3.6 ser vi enstegsprognoserna för transferfunktionsmodellerna med två månadersdata. Att döma av diagrammen ser PK+Samtida_{2mån}, DH_{2mån} ut att ge bäst prognoser.

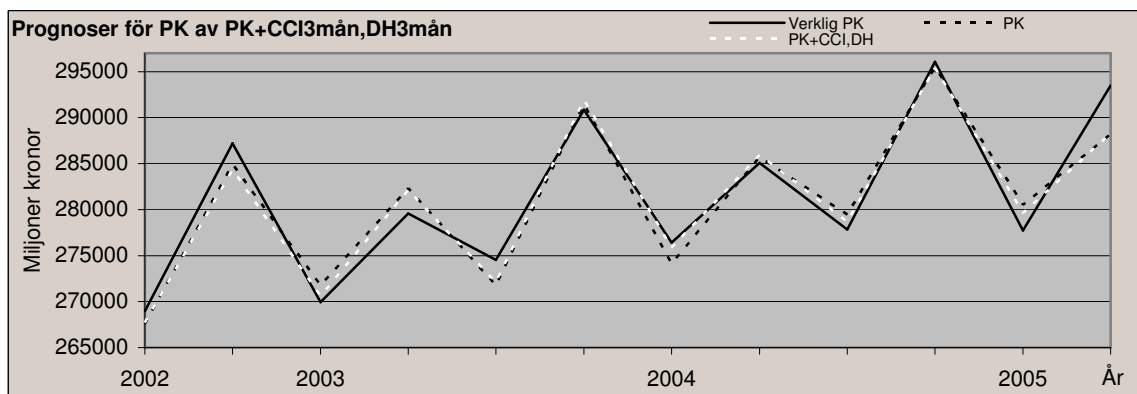


Diagram 4.3.7: Prognoser för privat konsumtion med hjälp av av tre månadsdata för CCI, DH.




Diagram 4.3.8: Prognoser för privat konsumtion med hjälp av av tre månadsdata för Samtida, DH.




Diagram 4.3.9: Prognoser för privat konsumtion med hjälp av av tre månadsdata för Framåt,DH.

I diagram 4.3.7 - 4.3.9 ser vi enstegsprognoserna för transferfunktionsmodellerna med tre månadersdata. Att döma av diagrammen ser PK+Samtida_{3mån},DH_{3mån} ut att ge bäst prognoser.

För alla transferfunktionsmodellerna ser det ut att vara den med Samtida, DH som ger bäst prognoser. Vid jämförelse av modellerna ser vi att prognoserna är väldigt lika och det är svårt att säga om det är någon skillnad genom att enbart se på diagrammen.

Alla prognoser ligger till grund för resultaten när modellerna ställs mot varandra i avsnitt 4.4 samt när konfidensintervallet plottas i avsnitt 4.5. Modellernas prognosförmåga och hur adekvata de är har givetvis ett samband. Genom att studera diagnostiken kan man få en första bild av hur bra prognoserna kan tänkas bli.

4.4 Vilken prognos är bäst?

Prognosfelen redovisas i procentuell avvikelse från det sanna värdet, summerat över alla gjorda prognoser, (MAPE) absolut medelfel i procent. Detta gör det möjligt att på ett enkelt sätt överblicka eventuella skillnader mellan serierna och även mellan de två modellerna.

Tabell 4.4.1	PK	PK + CCI, DH			PK + Samtida,DH			PK + Framåt,DH		
		1 mån	2 mån	3 mån	1 mån	2 mån	3 mån	1 mån	2 mån	3 mån
MAPE	0,73%	0,67%	0,65%	0,61%	0,71%	0,60%	0,61%	0,72%	0,58%	0,64%

Tabell 4.4.1: Det absoluta medelfelet i procent, MAPE

För samtliga prognoser blir MAPE relativt lågt. För ett-stegsprognoserna ger att transferfunktionsmodellerna alla har lägre MAPE än den univariata. Utifrån dessa värden förbättrar transferfunktionsmodellerna prognosen för privat konsumtion i samtliga fall. PK+Framåt_{2mån}, DH_{2mån} ger dock allra lägst MAPE (0,58%) av modellerna.

Vilken prognos är bäst? Och är den bästa prognosen signifikant bättre än den univariata? Detta testas med Granger-Newbold- och Diebold-Mariano-test, där vi ställer modellerna mot varandra. Teorin bakom testet redovisades i teoriavsnittet.

Tabell 4.4.2	PK + CCI, DH			PK + Samtida, DH			PK + Framåt, DH		
	1 mån	2 mån	3 mån	1 mån	2 mån	3 mån	1 mån	2 mån	3 mån
r	-0,012	0,083	0,331	-0,112	0,407	0,303	-0,256	0,376	0,061
t _{GN}	-0,11	0,76	3,20	-1,02	4,06	2,89	-2,42	3,69	0,55

Tabell 4.4.2: Granger-Newbold test, korrelationen r och t-värden. Kritiskt värde för t_{GN} > 1,67 för en signifikans på 5%-nivån. Jämförelse med ARIMA.

Tabell 4.4.3	PK + CCI, DH			PK + Samtida, DH			PK + Framåt, DH		
	1 mån	2 mån	3 mån	1 mån	2 mån	3 mån	1 mån	2 mån	3 mån
t _{DM}	-0,05	1,09	1,84	-0,44	1,96	1,88	-0,93	2,03	0,28

Tabell 4.4.3: Diebold-Mariano test. Kritiskt värde för t_{DM} > 1,796 för en signifikans på 5%-nivån. Jämförelse med ARIMA.

I tabell 4.4.2 - 4.4.3 ser vi att både Granger-Newbold och Diebold-Mariano testet ger ungefär samma resultat. För prognoserna gjorda med en-månadsdata har samtliga modeller t_{GN}- och t_{DM}-värden som är icke-signifikanta på 5%-nivån. Hypotesen om att de modellerna ger lika bra prognoser som ARIMA-modellen kan alltså inte förkastas för en månadsdata.

För två- och tre-månadersdata är endast PK+CCI, DH respektive PK+Framåt, DH icke-signifikanta. Övriga transferfunktionsmodeller ger alltså signifikant bättre prognoser än den univariata modellen.

Det är fortfarande svårt att se vilken av dessa modeller som är bäst genom att bara se på MAPE, Grange-Newbold och Diebold-Mariano testen. PK+Framåt_{2mån}, DH_{2mån} har visserligen lägst MAPE (58%) och högst t_{DM} (2,03) men bara näst högst t_{GN} (3,69). PK+Samtida_{2mån}, DH_{2mån} har näst lägst MAPE (60%), näst högst t_{DM} (1,96) och högst t_{GN} (4,06). Alla värden ligger väldigt nära varandra och ytterligare ett Granger-Newbold test genomförs för att se om någon av dessa två modeller är överlägset bättre än de andra.

I tabell 4.4.4 kan resultatet av testet ses som visar att PK + Samtida_{2mån}, DH_{2mån} var signifikant bättre än PK + CCI_{3mån}, DH_{3mån} (2,28) och PK + Samtida_{3mån}, DH_{3mån} (2,81) på 5%-nivån men endast signifikant bättre än PK + Framåt_{2mån}, DH_{2mån} (1,50) på 10%-nivån. PK + Framåt_{2mån}, DH_{2mån} är däremot inte signifikant bättre än vare sig PK + Samtida_{3mån}, DH_{3mån} eller PK + CCI_{3mån}, DH_{3mån} men har lägst MAPE (0,58%) vilket borde antyda att PK + Framåt_{2mån}, DH_{2mån} är den bättre av modellerna.

Tabell 4.4.4	Samtida _{2mån} , DH _{2mån}	Samtida _{3mån} , DH _{3mån}	CCI _{3mån} , DH _{3mån}	Framåt _{2mån} , DH _{2mån}
Samtida _{2mån} , DH _{2mån}		-2,81	-2,28	-1,50
Samtida _{3mån} , DH _{3mån}	2,81		-0,04	0,97
CCI _{3mån} , DH _{3mån}	2,28	0,04		0,82
Framåt _{2mån} , DH _{2mån}	1,50	-0,97	-0,82	

Tabell 4.4.4: Kritiskt värde för t_{GN} > 1,67 för en signifikans på 5%-nivån.

4.5 Kan man lita på den bästa modellen?

Förutom att fastställa vilken prognosmodell som är bäst, är det viktigt att undersöka hur bra den bästa modellen är. Med resultaten från MAPE, Granger-Newbold och Diebold-Mariano testet kan man konstatera att prognoserna för privat konsumtion av transferfunktionsmodellerna är signifikant bättre än prognoser gjorda med en univariat modell för två

modeller med två-månadersdata och två modeller med tre månadersdata. En transferfunktionsmodell med två-månadersdata, $PK + \text{Framåt}_{2\text{mån}}, \text{DH}_{2\text{mån}}$, tycks dock vara den bästa. När den bästa modellen identifierats är det givetvis intressant att undersöka hur bra denna modell är. Ett sätt att mäta detta är att undersöka hur breda konfidensintervallen blir för respektive serie.




Diagram 4.5.1: 95% Konfidensintervall för prognoser av privat konsumtion med två månadersdata av Samtida,DH.




Diagram 4.5.2: 95% Konfidensintervall för prognoser av privat konsumtion med två månadersdata av Framåt,DH.

I diagram 4.5.1-4.5.2 ser vi att det prognostiserade värdet ligger innanför konfidensintervallet och prognoserna ser ut att stämma relativt väl med det observerade värdet, även om avvikelser förekommer. Prognoserna av $PK + \text{Framåt}_{2\text{mån}}, \text{DH}_{2\text{mån}}$ ser ut att ligga något närmre de verkliga värdena med en MAPE på 0,58% och $PK + \text{Samtida}_{2\text{mån}}, \text{DH}_{2\text{mån}}$ är inte mycket sämre med en MAPE på 0,60%.

Om man gör prognoser på längre sikt kommer detta att resultera i att konfidensbanden blir bredare, detta beror på osäkerheten och att det finns mer slump i serierna. Konfidensbanden som ges ovan är för 95 procentig konfidens. Om man istället skulle tillåta lite lägre konfidensgrad skulle detta ge smalare band, men på bekostnad av att utfallet oftare ligger utanför banden.

De fyra transferfunktionsmodeller, PK+Samtida_{2mån},DH_{2mån}, PK+Framåt_{2mån},DH_{2mån}, PK+CCI_{3mån},DH_{3mån} och PK+Samtida_{3mån},DH_{3mån}, kan alla fungera som en flashestimatorer för den privata konsumtionen. För att få en fingervisning om den privata konsumtionens utveckling under innevarande kvartal kan den univariata modellen som baserades på enbart tidigare kvartalsdata användas. Säkrare prognoser kan däremot göras med PK+Framåt_{2mån},DH_{2mån}, vilket skulle motsvara en tidsvinst på 70 dagar.

5 Sammanfattning

I arbetet med att bedöma konjunkturläget behövs snabb information från nationalräkenskaperna eftersom denna information används som beslutsunderlag för den ekonomiska politiken i Sverige. Ett sätt att påskynda informationsprocessen är att se på ekonomiska indikatorer för att bedöma denna utveckling eller att använda sig av så kallade flashestimater. I denna uppsats söker vi efter ett flashestimater för den kvartalsvisa totala privata konsumtionen i Sverige (PK). Syftet är att undersöka möjligheten att använda månadsdata för enkäten hushållens inköpsplaner (HIP) och detaljhandeln (DH) som ledande information för att få fram en snabb och tillförlitlig prognosmodell för PK. Modellen skall i första hand användas för att skatta innevarande kvartals PK.

Flashestimater som identifieras med första månadsdata för respektive kvartal skulle ge en tidsvinst med ca. 100 dagar. Motsvarande tidsvinst skulle vara ca. 70 dagar om flashestimator konstrueras med att använda data om första och andra månad för respektive kvartal. För en flashestimator konstruerad att använda data om första, andra och tredje månaden för respektive kvartal skulle tidsvinsten bli ca. 40 dagar.

Vi använde programmet TRAMO för att göra enstegsprognoser för privat konsumtion med hjälp av månadsdata från HIP och DH. Prognoserna utvärderades sedan genom att de jämfördes med en univariat modell för privat konsumtion. Detta undersöktes genom att se på det absoluta medel procent felet, MAPE, och prognos osäkerhetstesten av Granger-Newbold och Diebold-Mariano. Avslutningsvis såg vi även på ett 95% konfidensintervall för den bästa modellen.

I residualanalysen av respektive transferfunktionsmodell med en, två och tre månadersdata såg vi att Jarque-Beras normalitetstest, Durbin-Watson och Ljung-Boxs autokorrelationstest gav bra värden. Alla modeller kan antas ha normalfördelade residualer och ingen autokorrelation föreligger. MAPE för enstegsprognoserna ger att transferfunktionsmodellerna alla har lägre MAPE än den univariata. Utifrån dessa värden förbättrar transferfunktionsmodellerna prognosen för privat konsumtion i samtliga fall. PK+(Framåt_{2mån}, DH_{2mån}) gav lägst MAPE (0,58%) av modellerna.

Granger-Newbold och Diebold-Mariano testen gav att hypotesen om att modellerna ger lika bra prognoser inte kan förkastas på 5%-nivån för en månadsdata. För två och tre månadersdata är endast PK+CCI,DH respektive PK+Framåt,DH icke-signifikanta. Övriga transferfunktionsmodeller ger alltså signifikant bättre prognoser än den univariata modellen och vi förkastar nollhypotesen på 5% nivån.

De fyra transferfunktionsmodeller, PK+Samtida_{2mån},DH_{2mån}, PK+Framåt_{2mån},DH_{2mån}, PK+CCI_{3mån},DH_{3mån} och PK+Samtida_{3mån},DH_{3mån}, kan alla fungera som en flashestimator

för den privata konsumtionen. Säkrast prognoser kan däremot göras med $PK+Framåt_{2mån}, DH_{2mån}$, vilket skulle motsvara en tidsvinst på 70 dagar.

Referenser

Litteratur

Bolminger, Lars (2004), ”*Detaljhandeln som flashestimat för privat konsumtion*”, Örebro universitet, Institution för Ekonomi, Statistik och Informatik.

Bowerman, Bruce L., O’Connell Richard T. och Koehler Anne B. (2005), ”*Forecasting, Time Series and Regression – An Applied Approach*”, Fourth Edition, Duxbury Press, San Fransisco USA.

Clark Todd E. and McCracken Michael W. (1999), ”*Tests of Equal Forecast Accuracy and Encompassing for Nested Models*”, Federal Reserve Bank of Kansas City, Research Working Paper No. 99-11

Enders, W. (2004), ”*Applied Econometric Time Series*”, Second Edition, John Whily & Sons, Danvers USA.

Gomez, V. och Maravall, A. (1994), ”*Estimation, Prediction and Interpolation for Non-stationary Series with the Kalman Filter*”, Journal of the American Statistical Association, 89, 611-624.

Gomez, V. och Maravall, A. (1997), ”*Programs TRAMO and SEATS. Instructions for the user (Beta version: September 1997)*”, Working Paper no. 9628, Bank of Spain.

Gomez, V. och Maravall, A. (1997), ”*Guide for Using the Programs TRAMO and SEATS*”, Working Paper no. 9805, Research Department, Bank of Spain.

Kaiser, R. och Maravall, A. (2001), ”*Measuring Business Cycles in Economic Time Series*”, Springer-Verlag, New York USA.

Maravall, A. och Sánchez, F. (2000). ”*An Application of TRAMO-SEATS: Model Selection and Out-of-Sample Performance: the Swiss CPI series*”, Working Paper 9914, Research Department, Bank of Spain.

Ramanathan, R. (2002), ”*Introductory Econometrics with Applications*”, Fifth Edition, South-Western, Ohio USA.

Öhlén, S. (2003), ”*Säsongsrensning av nationalräkenskaperna – en Översikt*”, ISSN 1650-9447. Bilaga A till Tidsserieprojektes slutrapport. Statistiska centralbyrån.

Internet

SCBs statistikdatabas – September 2005
<http://www.ssd.scb.se/databaser/makro/start.asp>

Konjunkturinstitutet – September 2005
<http://www.konj.se/statistik/hushallensinkopsplaner.4.165f40035bbd27fff647.html>

Bilagor

HIP frågeformulär

1. **Hur är Ditt hushålls ekonomiska situation för närvarande jämfört med för 12 månader sedan? Är den ...? (Läs upp)**
 - (1) Mycket bättre
 - (2) Något bättre
 - (3) Ungefär lika
 - (4) Något sämre
 - (5) Mycket sämre
 - (6) Vet inte

2. **Hur tror Du att Ditt hushålls ekonomiska situation är om 12 månader? Är den ...? (Läs upp)**
 - (1) Mycket bättre
 - (2) Något bättre
 - (3) Ungefär lika
 - (4) Något sämre
 - (5) Mycket sämre
 - (6) Vet inte

4. **Hur tror Du att den ekonomiska situationen är i Sverige om 12 månader? Är den ...? (Läs upp)**
 - (1) Mycket bättre
 - (2) Något bättre
 - (3) Ungefär lika
 - (4) Något sämre
 - (5) Mycket sämre
 - (6) Vet inte

Övriga frågor finns att läsa i dokumentationen över hushållens inköpsplaner på konjunkturinstitutets hemsida: http://www.konj.se/download/18.1aae94ff740534be07fff120/HIP_dokumentation+2003.pdf

Privat konsumtion




Diagram B.1 Tidsseriediagram över PK




Diagram B.2 Tidsseriediagram över ln PK




Diagram B.3 Tidsseriediagram över 1-diff ln PK




Diagram B.4 ACF över 1-diff ln PK




Diagram B.5 Tidsseriediagram över 4-diff ln PK

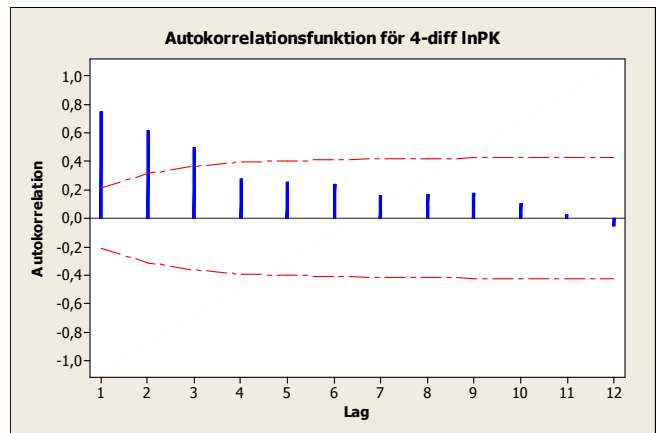


Diagram B.6 ACF över 4-diff ln PK

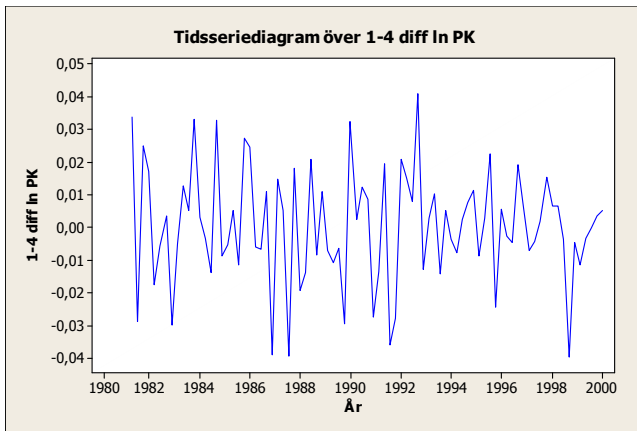


Diagram B.7 Tidsseriediagram över 1-4 diff ln PK

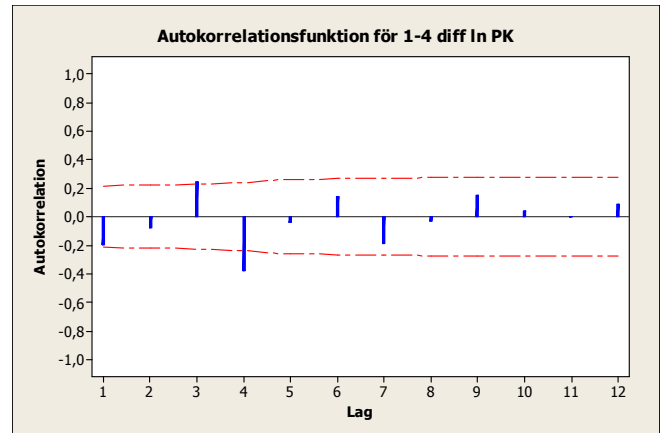


Diagram B.8 ACF över 1-4 diff ln PK




Diagram B.9 PACF över 1-4 diff ln PK

1-diff: Första differensen av $\ln(\text{PK})$
 4-diff: Första säsongdifferensen av $\ln(\text{PK})$
 1-4 diff: Första kombinerade differensen $\ln(\text{PK})$

HIP – CCI




Diagram B.9 Tidsseriediagram över CCI_{1mån}




Diagram B.10 Tidsseriediagram över CCI_{2mån}




Diagram B.11 Tidsseriediagram över CCI_{3mån}

HIP – Samtida




Diagram B.12 Tidsseriediagram över Samtida_{1mån}




Diagram B.13 Tidsseriediagram över Samtida_{2mån}




Diagram B.14 Tidsseriediagram över Samtida_{3mån}

HIP – Framåt




Diagram B.15 Tidsseriediagram över Framåt_{1mån}

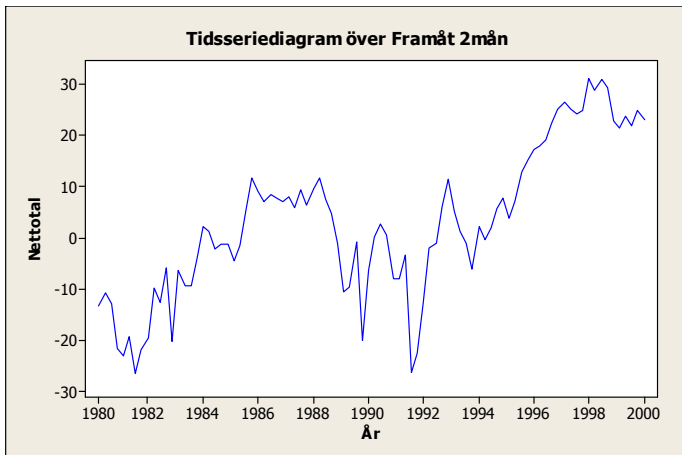


Diagram B.16 Tidsseriediagram över Framåt_{2mån}




Diagram B.17 Tidsseriediagram över Framåt_{3mån}

HIP – SFramåt




Diagram B.18 Tidsseriediagram över SFramåt_{1mån}




Diagram B.19 Tidsseriediagram över SFramåt_{2mån}




Diagram B.20 Tidsseriediagram över SFramåt_{3mån}

Detaljhandeln




Diagram B.21 Tidsseriediagram över DH_{1mån,1-12Diff}




Diagram B.22 Tidsseriediagram över DH_{2mån,1-12Diff}




Diagram B.23 Tidsseriediagram över DH_{3mån,1-12Diff}