



Forord

Denne masteroppgaven er skrevet i forbindelse med avslutningen av vår mastergrad ved handelshøyskolen på Norges miljø- og biovitenskapelige universitet (NMBU). Oppgaven er under vår hovedprofil økonomistyring, og utgjør 30 av de totalt 120 studiepoengene i vår mastergrad.

Vi ønsket å skrive en oppgave innen fagfeltet logistikk, og kontaktet i den forbindelse Flust.no AS med en forespørsel om samarbeid. Flust ønsket primært å få hjelp til deres prognoser, dette var et tema vi hadde stor interesse for.

Vi vil benytte anledningen til å rette en stor takk til vår veileder Kolbjørn Christoffersen, som har hjulpet oss under hele prosessen med nyttige og konstruktive innspill. I tillegg vil vi takke Conrad Carlberg for tillatelsen til å bruke figurer fra hans bok, *Predictive Analytics: Microsoft Excel*.

Til slutt vil vi rette en stor takk til Flust.no AS og spesielt Håkon Skjellevik-Heger for deres tid, imøtekommenhet og overlevering av salgsdata som vi har basert vår analyse på.

Norges miljø- og biovitenskapelige universitet

15. Mai 2015, Ås

X

Vegard Sørensen

X

Truls Zachariassen

Sammendrag

Formålet med denne oppgaven er å sette fokus på hvordan Flust.no AS bør gjøre sitt prognosearbeid i fremtiden. I dag har Flust ikke hatt kapasitet til å utvikle og gjennomføre prognosearbeid i den graden de ønsker. Problemstillingen vi har besvart i denne oppgaven er: «*Hvilke prognosemetoder er best egnet for å lage kortsiktige prognoser for Flust.no AS' basisprodukter?*» For å besvare denne problemstillingen har vi i samarbeid med Flust valgt å analysere underkategorien *bilstoler* i kategorien *barn og baby*.

Produktkategorien *bilstoler* består av fire ulike vektklasser. Vi har i tillegg til å gjort analyse av hver enkelt bilstol, analysert aggregert etterspørsel for bilstoler totalt og etter vektklasse. Analysene vi har gjort er basert på historisk salgsdata fra januar 2013 til februar 2015.

Vi har i analysen brukt metoden ARIMA fordi denne analyserer tidsserier gjennom en prosess som gir objektivt og teoretisk begrunnelse for valg av prognosemodell. Vi har også valgt å analysere tidsserien med gjennomsnitts- og eksponentiell glattingsmodeller ettersom disse er enklere å implementere.

ARIMA-prosessens resultater ga kun signifikante parameterverdier i tre av totalt 16 tidsseriene. I disse tre tilfellene var dog ARIMA-prognosen bedre enn eksponentiell glattings- og gjennomsnittsmoellene. Analysens resultater fortalte oss at på et generelt grunnlag at både aggregert og disaggregert etterspørsel har store svingninger og lite korrelasjon mellom de ulike verdiene i tidsseriene. Vi kan derfor ikke anbefale en spesifikk kvantitativ metode, men heller anbefale å bruke enkel eksponentiell glatting som et hjelpemiddel til beslutninger for prognoser på fremtidig etterspørsel.

Abstract

The purpose of this thesis is to examine how Flust.no AS should perform their forecasting in the future. Today Flust does not have the capacity to develop and implement forecasting to their desired extent. The research question of this thesis is; *"Which forecasting methods are best suited to make short-term forecasts for basic products at Flust.no AS?"* To answer this question we have in collaboration with Flust chosen to analyze the subcategory; *car seats for children* in the category *children and infants*.

The product category *car seats for children* consists of four different weight categories. In addition to analyze each car seat, we have also analyzed aggregated demand for car seats in total and by weight category. Our analysis bases on historical sales data from January 2013 to February 2015.

We have used ARIMA analysis because this method analysis the data through a process that provides objective and theoretical foundation for choosing the best suited forecasting model. We have also chosen to analyze time series with average- and exponential smoothing models, as these are easier to implement.

The ARIMA process only resulted in significant parameter values in three of the total 16 time series. In these three cases, the ARIMA forecast were better than the exponential smoothing and average models. Our results show that on a general basis, both aggregated and disaggregated demand fluctuates, and that correlation between the different values in the time series is low. Thus, we cannot recommend a specific quantitative method, but rather recommend using simple exponential smoothing as an aid for decision making in forecasting future demand.

Innholdsfortegnelse

Forord	2
Sammendrag	3
Abstract	4
1 Innledning	7
1.1 Flust.no AS.....	7
1.2 Bakgrunn for oppgaven.....	7
1.3 Problemstilling.....	8
2 Teori	9
2.1 Hvorfor bruker vi prognoser?.....	9
2.2 Egenskaper ved prognoser.....	10
2.3 Prognoseprosessen.....	10
2.4 Kvantitative prognosemetoder.....	12
2.5 Prognosefeil.....	25
2.6 Kvalitativ prognosemetode.....	27
3 Metode	32
3.1 Forskningsdesign.....	32
3.2 Datainnsamling.....	33
3.3 Optimering av parameterne.....	35
3.4 Sammenligne og bestemme prognosemetoder.....	36
3.5 Prognosemodellene.....	37
4 Resultater og analyse	39
4.1 Analyse av bilstoler, totalt.....	39
4.2 Analyse av bilstoler, vektklasse 0-13 kg.....	42
4.3 Analyse av bilstoler, vektklasse 9-18 kg.....	46
4.4 Analyse av bilstoler, vektklasse 9-25/36 kg.....	49

4.5	Analyse av bilstoler, vektklasse 15-36 kg	52
4.6	Analyse av enkeltproduktene	55
4.7	Oppsummering av resultater	56
5	Diskusjon og konklusjon	57
5.1	Diskusjon av analyseresultatene.....	57
5.2	Hvordan vil resultatene påvirke Flust	59
5.3	Begrensninger.....	60
5.4	Konklusjon	61
6	Litteraturliste.....	62

1 Innledning

1.1 Flust.no AS

Flust.no AS er et nettvarehus som eies av NorgesGruppen ASA. De fører produkter i mange forskjellige produktgrupper, og selger alt fra tredemøller til bestikk. Målet til Flust er å dekke en stor del av behovet som dukker opp for en vanlig familie i løpet av året. På nettsiden finnes det seks ulike hovedkategorier; kjøkken, hus og hage, klær og smykker, sport og fritid, barn og baby og kosmetikk. Innenfor disse kategoriene fører de til enhver tid mellom 6000 til 7000 varelinjer.

Selv om produktutvalget er beregnet for å dekke behovet til hele familien, er hovedmålgruppen til Flust kvinner mellom 30 og 55 år.

Nettbutikken Flust startet i tidlig 2009, og har dermed vært drevet i over 6 år. Ved oppstart var nettbutikken en videreføring av nettbutikken til fordelsprogrammet Trumf, som ble startet i 1997. I dag er Flust løsrevet fra Trumf, selv om det fortsatt er mulig å betale med trumf-bonus når en kjøper produkter.

I dag er det 24 ansatte i Flust, noen av disse er også fortsatt engasjert i Trumf. Lagerdriften til selskapet er outsourcet, og drives av Bring. Lagertjenestene prises ut fra hylleplass som brukes, antall mottak og eventuelle ekstrakostnader for tilleggstjenester. Det er også noen produkter (som for eksempel tredemøller) som leveres direkte fra produsent til sluttkunde.

1.2 Bakgrunn for oppgaven

Flust har i dag mellom 130 og 160 ulike leverandører. Innkjøpene fra disse leverandørene styres av innkjøpsavdelingen til Flust og leveransene leveres direkte til det outsourcete lageret. Innkjøperen baserer i dag sine innkjøp på tidligere salgsdata og intuisjon. Selskapet bruker datasystemet Axapta, og i den versjonen de bruker finnes det ingen integrasjon med prognosemuligheter. De har ikke hatt kapasitet til å lage prognosemodeller, for å vurdere dagens prognostisering og innkjøp.

1.3 Problemstilling

Flust har ikke hatt kapasitet til å utvikle og gjennomføre prognosearbeid i en utstrakt grad. I en bedrift som Flust, hvor det er betydelig ledetid, kan dårlig prognostisering føre til tap av salgsinntekter ved for små innkjøp, og økte kostnader ved feil lagerføring eller ordrekvantum.

Hovedspørsmålet vi vil forsøke å besvare med denne oppgaven er:

Hvilke prognosemetoder er best egnet for å lage kortsiktige prognoser for Flust.no AS' basisprodukter?

Med best egnet mener vi prognosemetoder som gir mest presise prognoser, men som samtidig krever minimalt med ressurser fra Flust å implementere til deres basisprodukter. Det vil dermed være en kostnad-nytte avveining mellom disse to faktorene.

Med basisprodukter menes produkter som er ment å være i sortimentet over lengre tid. Med andre ord produkter med lang levetid, i motsetning til for eksempel moteartikler, som ofte har en levetid på kun noen få måneder.

I denne oppgaven vil vi sette fokus på og analysere hvordan Flust bør gjøre sitt prognosearbeid i fremtiden. I samarbeid med Flust har vi bestemt å analysere bilstoler innen kategorien *barn og baby*. Ledetiden for bilstoler er normalt ca. 14 dager.

I kategorien bilstoler finnes det innenfor datagrunnlaget vi har fått tildelt, 40 ulike produkter. Vi ønsket å analysere en hel produktkategori, for å kunne lage prognoser for både aggregert etterspørsel og etterspørselen til enkeltproduktene. I denne forbindelse var bilstoler egnet ettersom dette var en produktgruppe som har flere underkategorier, i form av vektklasser.

2 Teori

2.1 Hvorfor bruker vi prognoser?

Etterspørselsprognoser er basisen for all planlegging i forsyningskjeden. Når vi vurderer push- og pull-synet på forsyningskjeden kan vi si at alle push-prosesser er basert på prognoser på etterspørselen. Mens alle pull-prosesser er basert på faktisk etterspørsel. Selv om det kan virke som om prognoser kun er viktig eller hvert fall er viktigst ved push-metoden, er det vel så viktig å gjøre prognoser for pull-metoden fordi man må planlegge nivået på ledig kapasitet, lager og tilgang til råvarer (Chopra & Meindl, 2007).

I dag må bedrifter forholde seg til flere risikofaktorer enn de gjorde før. Dette skyldes at informasjon har fått kortere ledetid, som følge av globalisering og markedenes økte kompleksitet og konkurranse. Denne nye utviklingen medfører at gevinsten av å lage gode og tapene ved å lage dårlige prognoser er større enn noen gang (Barren & Target, 1985). Lange ledetider, sesongavhengig etterspørsel, stor produktvariasjon, og korte produktlivssykluser øker alle prognoserisikoen (Chopra & Sodhi, 2004).

Ledetid er tidsdifferansen mellom bevisstheten av et behov eller en hendelse og når denne hendelse faktisk skjer. Ledetiden er en viktig årsak til at vi bruker prognoser. Dersom ledetiden er kort, er det mindre viktig med prognoser enn dersom ledetiden er lang. Dersom ledetiden er null, vil det si at prognoser ikke er nødvendig (Makridis, Wheelright & Hyndman, 1998).

Når tilgangen til råvarer og/eller etterspørselen etter det ferdige produktet er usikkert gjør dette prognosene og ledelsesbeslutningene veldig vanskelige. Dette gjelder for eksempel høy-teknologiske produkter eller moteartikler med kort levetid. I disse tilfellene er prognoser ekstra viktig ettersom salget skal skje innen en kort tidsperiode, da verdien av produktet faller betraktelig etter denne perioden. Det er enklere å gjøre prognoser for modne produkter med stabil etterspørsel, som for eksempel sukker og håndsåpe. (Chopra & Meindl, 2007).

2.2 Egenskaper ved prognoser

Prognoser er alltid feil og burde derfor inkludere både forventet verdi av prognosen og et mål på prognosefeilen. Prognosefeilen bør være et viktig beslutningselement for beslutninger i forsyningskjeden. Dette er dog ikke standarden i bedrifter i dag.

Langsiktige prognoser er vanligvis mindre presise enn kortsiktige prognoser.

Langsiktige prognoser har større standardavvik på feilene i forhold til gjennomsnittet enn det kortsiktige prognoser har. Dette gir mening ettersom desto lengre frem i tid en beslutning tas for, desto større sjanse er det for at omgivelser (vær, politikk, økonomisk situasjon, etc.) endres i løpet av ventetiden.

Aggregerte prognoser er vanligvis mer nøyaktige enn disaggregerte prognoser. Dette er fordi prognoser som regel har lavere standardavvik mot gjennomsnittet desto mindre spesifikke prognosene er. Det er lettere å predikere totalt salg av for eksempel sykler i Norge enn det er å predikere salg av en spesifikk modell i en bestemt butikk.

Generelt, desto høyere opp i forsyningskjeden et selskap er (desto lengre fra forbrukeren), desto mer forvrenges informasjonen. Dette fenomenet er hyppig omtalt som bullwhip-effekten. Dette vil si at ordrevariasjonene blir forsterket oppover i forsyningskjeden, som fører til at prognosefeilene blir større høyere opp i forsyningskjeden. Bullwhip-effekten kan reduseres ved å dele informasjon i hele forsyningskjeden, og at alle ledd baserer sine prognoser på bakgrunn av sluttkundens etterspørsel.

(Chopra & Meindl, s. 188, 2007)

2.3 Prognoseprosessen

Tilnærmingen til å utarbeide optimale prognoser består av seks steg (Chopra & Meindl, 2007).

2.3.1 Forstå målet med å prognostisere

Enhver prognose gjøres på bakgrunn av fremtidige beslutninger som skal baseres på prognosens prediksjon. Det er viktig at alle som er påvirket av forsyningskjedebeholdninger er klar over linken mellom prognosen og hvilke beslutninger som skal gjøres på bakgrunn av den aktuelle prognosen.

2.3.2 Integrere etterspørselsplanlegging og prognoser gjennom hele forsyningskjeden

Prognosearbeidet i en bedrift bør linkes til alle planleggingsaktiviteter som gjøres i hele forsyningskjeden. Dette inkluderer blant annet kapasitetsplanlegging, produksjonsplanlegging, kampanjeplanlegging, markedsføring og innkjøp. Ettersom mange av avdelingene og funksjonene påvirkes av beslutningene og planleggingen som gjøres, er det viktig at de alle er integrert og inkludert i prognosearbeidet. For å oppnå god integrasjon er det nyttig å danne samarbeidsgrupper på tvers av avdelinger og funksjoner innen bedriften.

2.3.3 Forstå og identifisere kundesegmenter

Det er viktig å forstå hvilke kundesegmenter som forsyningskjeden forsyner. Kunder kan grupperes etter likhet i geografi, servicebehov, etterspørselsvolum, ordrehyppighet, etterspørselsvolatilitet, sesong, etc. Dette gjøres ettersom det ofte kreves ulike prognosemetoder for ulike kundesegmenter.

2.3.4 Identifisere viktige faktorer som påvirker etterspørselsprognosen

Selskapet må identifisere etterspørsels-, tilbuds- og produkt-relaterte faktorer som påvirker etterspørselsprognosen. Når det gjelder etterspørselen er det viktig å se om det finnes noen mønster som kan leses, det kan være sesongvariasjoner, eller om etterspørselen har en stigende eller synkende trend.

Når det gjelder tilbudssiden må selskapet vurdere de tilgjengelige tilbudskildene for å kartlegge hvor nøyaktige prognoser som er nødvendig. Dersom alternative tilbudskilder med kort ledetid er tilgjengelig, blir det mindre viktig med presise prognoser. Men dersom dette ikke finnes er nøyaktige prognoser veldig viktig.

På produktsiden er det viktig å finne ut hvilke varianter av et aktuelt produkt som selges, og om produktet er komplementært eller substituerbart med noen av disse produktene. Det må kartlegges om etterspørselen av produktet påvirkes av etterspørselen på et annet produkt. Dersom det sistnevnte er tilfelle lønner det seg å aggregere prognosene for disse produktene.

2.3.5 *Bestemme den riktige prognosemetoden*

Før en bestemmer den riktige prognosemetoden, bør selskapet forstå de ulike dimensjonene som er relevante for prognosen. Blant annet geografisk område, produktgrupper og kundegrupper. Det kan være ulik etterspørsel for de ulike gruppene og derfor kan det være ulike prognosemetoder som er ideelle for de ulike gruppene.

2.3.6 *Måle ytelse og feil på prognosene*

Det er viktig at selskapet har klare metoder for å måle ytelsen og nøyaktigheten av prognosene. Disse metodene bør være høyt korrelert med selskapets mål og beslutninger som blir gjort på bakgrunn av prognosene.

2.4 Kvantitative prognosemetoder

Kvantitative prognosemetoder bruker talldata til å finne eller dokumentere etterspørselstendenser.

Tidsseriedatametoder er designet til å identifisere historisk etterspørselstendenser hvor det er lite variasjon fra år til år (Moon, 2013). Disse metodene er blant de mest brukte og effektive prognosemetodene. Ballou (2014) påpeker at dersom man har gode historiske data og i tillegg stabile og godt definert trend og sesongvariasjoner kan man lage effektive kortsiktige prognoser med kvantitative metoder.

Videre er det tre komponenter for historisk etterspørsel som tidsseriedata-algoritmene forsøker å identifisere og forutse. Disse tre er trend, sesongvariasjon og støy (Moon, 2013).

Trend eksisterer når det er en langsiktig økning eller reduksjon i etterspørselen. Dette kan være på grunn av eksterne faktorer som makroøkonomiske endringer eller interne faktorer som hvor produktet er i sin livssyklus.

Sesongvariasjoner er et repeterende mønster av etterspørselen i form av en reduksjon eller økning. Normalt så ser vi på variasjonen innenfor ett år, variasjonene kan komme av for eksempel årstider eller høytider.

Støy er tilfeldige variasjoner i tidsseriedata som hverken faller under trendvariasjon eller sesongvariasjon. Støy er all variasjon som ikke kan forklares av modellen. Etterspørselsmønstre har som oftest en viss grad av tilfeldig variasjon, og desto

mindre tilfeldig variasjon, jo lettere er det å lage prognoser. Med høy grad av støy er nærmest umulig å forutsi om fremtidig etterspørsel vil øke eller avta.

2.4.1 ARIMA-prosessen

ARIMA er en objektiv prosess for å finne riktig prognosemodell. Prosessen bestemmer den optimale prognosemetoden basert på datagrunnlaget som skal prognostiseres. ARIMA ble utviklet på 60-tallet av Box og Jenkins, og kalles derfor ofte Box-Jenkins metoden (Carlberg, 2012). ARIMA består av:

- **AR: (autoregressive):** Modellen og prognosen kan baseres delvis eller fullstendig på auto-regresjon. Dette vil si at tidsseriens verdi på et gitt tidspunkt kan uttrykkes som en funksjon av tidligere verdier av samme tidsserie.
- **I: (integrated):** Datagrunnlaget må kanskje differensieres (på grunn av for eksempel en positiv trend) og den differensierte serien modelleres. Deretter, når tiden er inne for å lage prognoser, snus differensieringen ved en enkel prosess som kalles integrering. Dette setter datagrunnlaget tilbake til sine originale dataverdier.
- **MA: (moving average):** Dette er en litt forskjellig betydning av glidende gjennomsnitt enn det vi tidligere har beskrevet i denne oppgaven, som dreier seg om snittet av verdiene. Her er det snakk om et vektet snitt av prognosefeilene. Allikevel vil vi omtale dette som glidende gjennomsnitt i dette kapitlet.

En fordel med en ARIMA-prosess som basis for prognoser er at det er en prosedyre for å analysere strukturen i datasettet. Dette gjør det mulig å stadfeste om det er trend i dataene, dermed kan man på et objektivt grunnlag bestemme om en skal konvertere/differensiere datagrunnlaget til å bli stasjonært. ARIMA gir også grunnlag til å vurdere objektivt, på bakgrunn av datasettet, om det bør anvendes autoregressive- eller glidende gjennomsnittsmetoder eller om det finnes sesong i datasettet, og hvor sesongvariasjonene eventuelt finnes (Carlberg, 2012).

Notasjonen til ARIMA uttrykker hvilken type modell som blir brukt eller vurdert.

Basisnotasjonen er:

ARIMA (p, d, q)

ARIMA beskriver at vi bruker en ARIMA modell.

p er antall auto-regressive parametere i modellen.

d er antall ganger serien har blitt differensiert/konvertert for å oppnå en stasjonær serie.

q er antall glidende gjennomsnitts-parametere i modellen.

Dersom identifiseringsfasen i ARIMA-analysen fastslår at datagrunnlaget har sesongvariasjon legges tre nye parametere til for å beskrive sesongvariasjonene;

ARIMA (p, d, q) (P, D, Q)

De store bokstavene (P,D,Q) har her den samme meningen som de små bokstavene, men anvendes for sesongparameterne. ARIMA (1,0,0) (1,0,0) betyr altså at det må legges til en auto-regressiv parameter i forhold til siste verdi og i tillegg en auto-regressiv parameter for sesongen (samme periode for 12 måneder siden dersom det er månedlig data og sesongvariasjon).


2.4.1.1 Identifiseringsfasen

I identifiseringsfasen fastslås det om datagrunnlaget er auto-regressive (AR), glidende gjennomsnitt (MA) eller en miks av de to (ARMA), om det er trend eller stasjonært og om det er sesong i datasettet. Måten å identifisere er gjennom korrelogrammer.


Idéen er at tidsserier som bør prognostiseres med for eksempel glidende gjennomsnitt, har visse kjennetegn i sitt korrelogram. Det samme gjelder for auto-regressive og miks modeller. Det er også mulig å identifisere om en tidsserie har trend gjennom korrelogrammene (Carlberg, 2012).

Differensiering i ARIMA analyse

Ettersom identifisering av hvilken modell som passer til tidsserien (AR, MA eller ARMA) avhenger av riktige AKF (autokorrelasjonsfunksjon) og PAKF (Partiell autokorrelasjonsfunksjon) grafer, er det viktig at dataene er stasjonære og ikke har trend i seg.



Figur 2 - Tidsserie med trend (Carlberg, 2012)



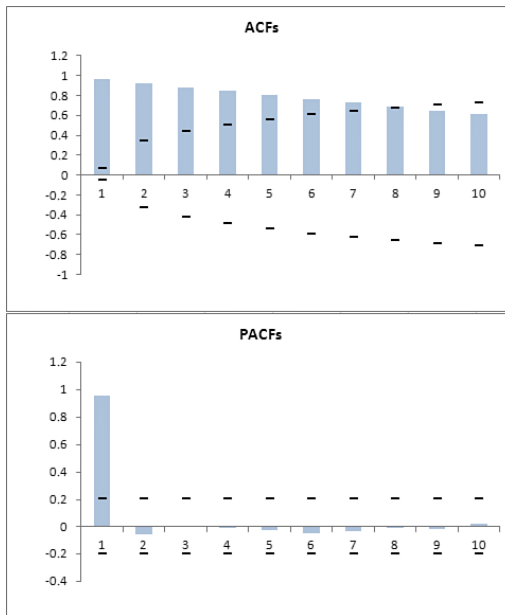
Figur 1 - Differensiert tidsserie (Carlberg, 2012)

Hvis det finnes trend kan vi differensiere, dette kan gjøres ved å trekke fra verdien fra den forrige perioden for alle verdiene i datasettet. Formelen for første differensiering er da:


$$\Delta Y_t = Y_t - Y_{t-1}$$

Dersom det fremdeles er trend etter dette, kan samme prosess gjøres igjen. Figur 1 viser en tidsserie med trend, mens figur 2 viser samme tidsserie differensiert én gang. Når en AR modell må differensieres to ganger for å bli stasjonær betegnes denne slik; ARIMA (1,2,0) (Carlberg, 2012).

Figur 3 viser en tidsserie med trend som ikke er differensiert. Som vi ser av AKF vil den gradvis avta, mens det vil være en «spiss» i første «lagg» i PAKF. Figur 4 viser AKF og PAKF for den samme tidsserien differensiert en gang (Carlberg, 2012).



Figur 3 - AKF og PAKF for tidsserie med trend, (Carlberg 2012)




Figur 4 - AKF og PAKF for differensiert tidsserie, (Carlberg 2012)

Identifiserer en AR prosess

Når vi skal vurdere tidsserien ser vi både på AKF og PAKF. Figur 6 viser kjennetegn på en auto-regressiv tidsserie (ARIMA (1,0,0)), tidsserien til disse korrelogrammene er vist i figur 5.

AKF til en AR-serie avtar og dør ut gradvis i løpet av serien, mens PAKF kuttes etter den første «spissen». Det faktum at det kun er en «spiss» i PAKF indikerer at det kun er en auto-regressiv parameter i tidsserien.

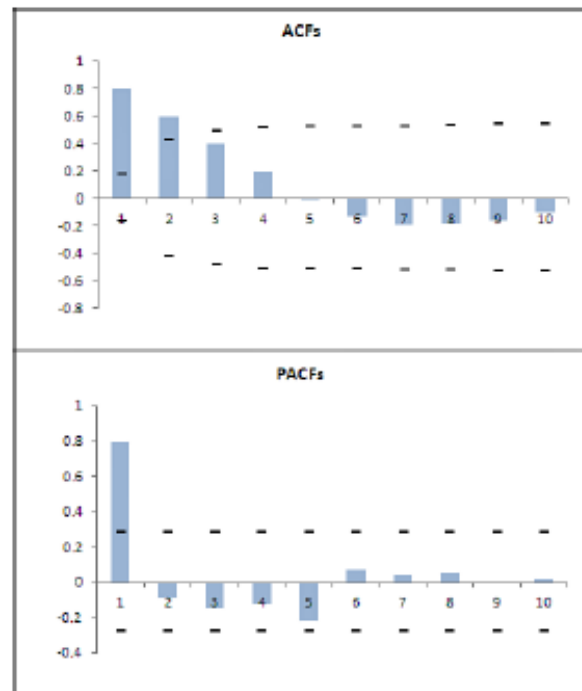


Figur 3 - Tidsserie AR-prosess


Når det er to «spisser» er det to auto-regressive parametere, altså ARIMA (2,0,0). Dersom det er to spisser på de to første intervallene vil det si at én periodes prognose må baseres på både den siste og den nest siste verdien.

Ofte indikerer to «spisser» at det er sesongvariasjon i tidsserien. Hvis det opereres med månedlige data og det er «spisser» i den første og den tolvte intervallet vil det si at ved prognoser må legge vekt på siste måned og samme måned året før (ARIMA (1,0,0) (1,0,0)).

Negativ korrelasjon i mellom verdiene i tidsserien kan sees i figur 7. Dersom grafen ser ut som et sagblad tyder dette på negativ korrelasjon, mens ved positiv korrelasjon vil grafen bølge mer, slik vi kan se fra figur 5 der korrelasjonen er positiv.

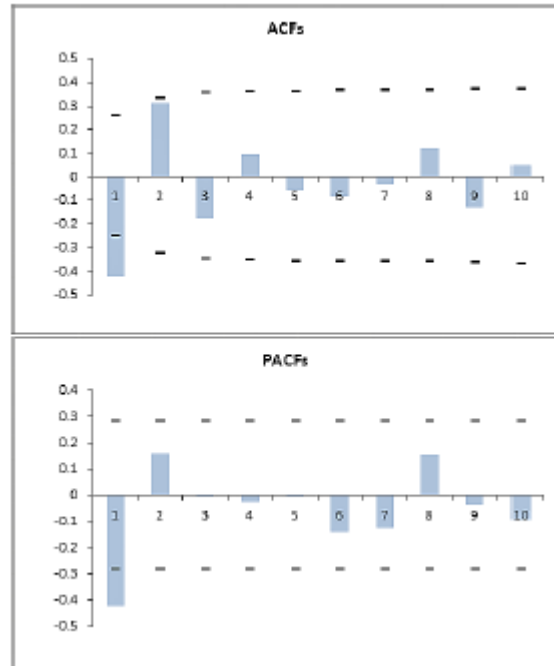


Figur 4 - AKF og PAKF, ARIMA (1,0,0) (Carlberg, 2012).



Figur 5 - Tidsserie med negativ korrelasjon (Carlberg, 2012)

Figur 8 viser AKF og PAKF til en ARIMA (1,0,0) tidsserie der korrelasjonen mellom tidsperiodene er negativ. Vi ser at AKF her også reduseres og gradvis «dør ut», mens PAKF har en negativ «spiss» som tilsier at det er en auto-regressiv parameter. At negative og positive verdier kommer annenhver gang bekrefter at tidsserien er negativt korrelert (Carlberg, 2012).




Figur 6 - AKF og PAKF, ARIMA (1,0,0) med negativ korrelasjon (Carlberg, 2012).


Identifisere en MA prosess

Som vi så over faller AKF gradvis og PAKF faller brått ved en AR prosess. Figur 9 forteller oss at ved en MA prosess (ARIMA (0,0,1)) er dette mønsteret reversert. AKF faller brått, mens PAKF (absoluttverdiene) gradvis faller.

MA parameteren i figur 9 er negativ, mens parameteren i figur 10 er positiv (Carlberg, 2012).



Figur 9 - AKF og PAKF, ARIMA (0,0,1) negativ parameter (Carlberg, 2012).



Figur 10 - AKF og PAKF, ARIMA (0,0,1) positiv parameter (Carlberg, 2012).

Test for signifikans

Dersom vi for eksempel ser på Figur 9 er den stiplede linjen over og under AKF- og PAKF-diagrammene en test for å kontrollere om AKF og PAKF er signifikant forskjellige fra null. Dersom ikke «spissene» når over eller under den stiplede linjen, bør en tolke det som om den verdien er lik null.

Mål for modellens «fit»

For å måle de ulike ARIMA modellen passer til dataserien har vi et mål som heter Akaike Information Criterion (AIC) (Katchova, 2013).

$$AIC = -2 \ln(L) + 2k$$

L er verdien av likelihood-funksjonen til modellen

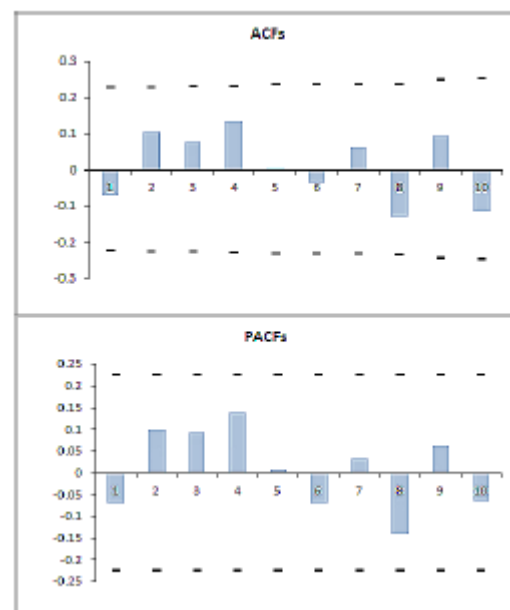
k er antall estimerte parametere

AIC måler bytteforholdet mellom modellens «fit» og kompleksiteten til modellen. Vi bruker dermed AIC for å sammenligne de ulike ARIMA modellene, og ARIMA modellen med lavest AIC som passer med de parameterverdiene som vi kan lese fra korrelogrammene er den vi velger. Det er selvfølgelig også viktig å se på om parameterverdiene er signifikante. Dersom to modeller gir tilnærmet lik AIC, anbefales det å bruke den men færrest parametere (Katchova, 2013).

Hvit støy

Det er ikke alltid mulig å modellere en tidsserie til enten AR eller MA basis. Et eksempel på en slik serie sees i figur 11. Her ser vi at ingen av «laggene» i AKF og PAKF er signifikant forskjellige fra null.

Dersom korrelogrammene som er basert på en tidsserie som ser slik ut, betyr det at prosessen er tilfeldig hvit støy, og det ikke er mulig å gjøre bedre prognoser enn gjennomsnittet til alle observasjonene i tidsserien (Carlberg, 2012).



Figur 7 - AKF og PAKF, hvit støy-prosess (Carlberg, 2012)

2.4.1.2 Estimeringsfasen

Etter at identifisering er gjort står man ofte igjen med en ARIMA (1,0,0) eller ARIMA (0,0,1) modell. Eventuelt ARIMA (1,1,0) eller (0,1,1) dersom man må differensiere. Det neste steget i prosessen blir da å estimere verdiene på parameterne som skal brukes.

Dersom tidsserien er identifisert som for eksempel en ARIMA (1,0,0) modell vet man allerede at det kun er én auto-regressiv parameter. I tillegg til å vite hvor mange parametere som skal være med i modellen, må du også vite «laggene» til parameterne. PAKF grafen gir svaret på dette, der antall «spisser» indikerer hvor mange parametere som skal inkluderes i modellen i tillegg til konstanten c .

For å gi beste mulige ARIMA (1,0,0) modell, brukes minste kvadraters metode for å minimere prognosefeilen som modellen gir.

2.4.1.3 Kontroll- og prognosefasen

Allerede i identifiseringsfasen sjekker vi signifikansen av parameterne ved hjelp av signifikanstest i korrelogrammene.

Men etter å ha estimert ARIMA-modellen skal residualene (prognosefeilene) til prognosene være hvit støy. Dette kan sjekkes ved å se på korrelogrammene til residualene. Ingen av disse skal være signifikant forskjellige fra null. Dersom det er signifikante «spisser» i korrelogrammene, indikerer disse hvordan modellen kan forbedres. Dersom det er signifikante «spisser» på sesongnivå, kan det være lurt å legge til en sesongparameter i modellen (Makridis et. Al., 1998).

Prognosefasen dreier seg om å bruke parameterverdiene til å lage fremtidige prognoser. For en AR(p) modell vil ligningen være:

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t$$

$$Y_t = \text{Etterspørsel periode } t$$

$$c = \text{Konstant}$$

$$\phi_p = \text{Parameterene som angir hvor mye vekt som skal legges på observasjoner i perioden } t-p$$

$$e_t = \text{Restleddet som antas å være hvit støy}$$

Ligningen for en MA(q) modell er:

$$Y_t = c + e_t - \phi_1 e_{t-1} - \phi_2 e_{t-2} - \dots - \phi_q e_{t-q}$$

$$Y_t = \text{Etterspørsel periode } t$$

$$c = \text{Konstant}$$

ϕ_q = Parameterene som angir hvor mye vekt som skal legges på observasjoner i perioden $t-p$

e_t = Forutsettes at restleddet er hvit støy

For en miks modell (ARMA(p,q)) modell vil ligningene slås sammen og se slik ut:

$$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + e_t - \phi_1 e_{t-1} - \dots - \phi_q e_{t-q}$$

2.4.2 Naive prognoser

Naive prognoser er den enkleste av prognosemetodene og tar ikke hensyn til trend, sesongvariasjoner eller støy. Når man bruker denne metoden, så vil prognosen for eksempelvis februar basere seg på etterspørselen som var i januar (Moon 2013).

2.4.3 Gjennomsnitt

Aritmetisk gjennomsnitt av tidsseriedata er også en av de enkleste prognosemetodene, den beregnes ved å summere alle verdiene (etterspørselen) og dele på antall verdier (etterspørselsperioder). Ved å bruke denne metoden vil neste månedsprognose være den aritmetiske gjennomsnittlige etterspørselen av alle de forrige månedene (Moon, 2013). Denne metoden fungerer når sesongvariasjon og trend ikke er tilstede. Når det er innslag av støy vil ytterpunktene jevne hverandre ut, og et gjennomsnitt av all tidligere data vil da være den beste metoden for å forutse etterspørselen. Dette er derimot en lite egnet metode når det forekommer sesongvariasjoner og trend (Moon, 2013).

2.4.4 Glidende gjennomsnitt

Når man tar gjennomsnittet av alle dataene, kan prognosene være kalkulert på bakgrunn av mye irrelevant og gammel data. Hvis det eksempelvis er en vedvarende positiv trend vil den aritmetiske gjennomsnittsmetoden prognostisere lavere forespørsel enn den faktiske etterspørselen fordi den kalkulerer med gammel data

(Moon, 2013). Et glidende gjennomsnitt kan bøte noe på dette problemet. Når man bruker et glidende gjennomsnitt som prognosemetode, bestemmer man hvilke perioder som er relevante, og eliminerer de periodene som er irrelevante (Moon, 2013). Man bruker følgende formel når man skal kalkulerer glidende gjennomsnitt:

$$F_{t+1} = (Y_t + Y_{t-1} + Y_{t-2} + \dots + Y_{t-[N-1]}) / N$$

Hvor F_{t+1} = prognoser for perioden $t+1$

Y_t = etterspørsel for perioden t

N = antall perioder.

Prognosene kan derimot vise noe etterslep i forhold til den aktuelle etterspørselen, og dette gjelder spesielt ved bruk av en lengre periode. Derimot vil ikke denne metoden klare å fange opp sesongvariasjoner, da det i disse tilfellene vil eksisterer et større etterslep i prognosene (Moon, 2013).

2.4.5 Enkel eksponentiell glatting

Fordelen med eksponentiell glattingsmetoder er metodenes enkelhet og lavkost. Når man skal lage prognoser for et stort antall produkter, er eksponentiell glattingsmetodene ofte de eneste som er raske og effektive nok til en tilfredsstillende implementering (Makridakis, et al., 1998).

Den enkleste formen for eksponentiell glatting er enkel eksponentiell glatting.

Formelen for denne metoden er (Makridakis, et al., 1998):

$$F_{t+1} = \alpha Y_t + (1 - \alpha) F_t$$

Hvor F_{t+1} = Prognoser for periode $t+1$

$$0 < \alpha < 1$$

Y_t = Etterspørsel for periode t

F_t = Prognose for periode t

Som man kan se av formelen så er (α) hvor mye en vektet etterspørselen (Y_t). F_t er prognosen for nåværende periode t og $(1-\alpha)$ er hvor mye man vektet prognosen for nåværende periode. Denne periodens prognose inkluderer forrige periodes vektete etterspørsel.

Ved enkel eksponentiell glatting kan man bestemme hvor mye man vil vekte de nyeste dataene og hvor mye man vil vekte de eldre dataene (Moon, 2013).

Glattingskonstanten (α) kan settes mellom 0 og 1. Hvis (α) settes nærme 0, vil de nyeste dataen i liten grad bli vektet, men hvis (α) settes nærmere 1, vil de nyeste dataen bli vektet i en mye større grad enn de eldre dataene (Moon, 2013).

2.4.6 Holts metode

Enkel eksponentiell glatting kan være effektiv hvis det ikke forekommer en trend i tidsseriedataene. Hvis det finnes en trend i tidsseriedataen vil enkel eksponentiell glatting være på etterskudd av trenden (Wheelwright & Makridakis, 1989). I tilfeller hvor det forekommer trend i tidsseriedataene, vil det være hensiktsmessig å bruke Holts metode. Denne metoden tar hensyn til utvikling av trend i tidsseriedataene. For å lage prognoser med denne metoden bruker man to glattingskonstanter, nivå (α) og trend (β), i tre ligninger (Makridakis, et al., 1998).

$$\text{Nivå: } L_t = \alpha Y_t + (1 - \alpha) (F_t)$$

$$\text{Trend: } b_t = \beta (L_t - L_{t-1}) + (1 - \beta) b_{t-1}$$

$$\text{Prognose: } F_{t+m} = L_t + b_t m$$

L_t betegner estimatet på nivået i dataserien i perioden t , mens b_t betegner estimat på helningen på dataserien i perioden t . Den første ligningen er lik som enkel eksponentiell glatting (Makridakis, et al., 1998).

Videre så ser vi at ligning 2, oppdaterer for trend, som er uttrykt som differansen mellom de to siste glattede verdiene. Når det finnes trend, så skal de nyeste dataene ha en høyere eller lavere verdi enn de eldre dataene. Da noe av variasjonen kan skyldes tilfeldigheter, er trenden modifisert ved å glatte (β) trenden i forrige periode ($L_t - L_{t-1}$), og legge til forrige periodes trendestimat ganget med $(1 - \beta)$ (Makridakis, et al., 1998).

Til slutt ser vi at den siste ligningene blir brukt til å prognostisere fremover. Trenden (b_t) ganges med antall perioder fremover som skal prognostiseres (m). I tillegg legges basisverdien (L_t) til i ligningen (Makridakis, et al., 1998).

2.4.7 Winters metode

Prognosemetoder som glidende gjennomsnitt, enkel eksponentiell glatting eller Holts metode kan være effektive når det ikke forekommer sesongvariasjoner i tidsseriedataene. Winters metode er en videreutvikling av Holts metode, som skal fange opp sesongvariasjoner i dataene. Denne metoden er basert på tre glattingsligninger, nivå (α), trend (β) og sesong (γ) (Makridakis, et al., 1998).

Det er to ulike varianter av denne metoden, additiv og multiplikativ. Den additive er foretrukket når sesongvariasjonene er tilnærmet konstant gjennom serien, mens den multiplikative fremgangsmåte er foretrukket når sesongvariasjonene endrer seg proporsjonal med nivået i serien. Den sistnevnte er også den som er hyppigst brukt av disse to metodene. Ligningene som Makridakis, et al., (1998) bruker i den multiplikative metoden er:

$$\begin{aligned} \text{Nivå: } L_t &= \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha) L_t \\ \text{Trend: } b_t &= \beta (L_t - L_{t-1}) + (1 - \beta) b_{t-1} \\ \text{Sesong: } S_t &= \gamma \frac{Y_t}{L_t} + (1 - \gamma) S_{t-1} \\ \text{Prognose: } F_{t+m} &= (L_t + b_t m) S_{t-s+m} \end{aligned}$$

Her er s antall måneder eller kvartal i et år, L_t er nivået på serien, b_t betegner trenden, S_t er sesongkomponenten, og F_{t+m} er prognosen for m perioder fremover.

L_t er en glattet verdi av serien som ikke inkluderer sesongvariasjoner. Y_t , derimot, inneholder sesongvariasjoner og tilfeldige variasjoner.

Trendligningen er her akkurat lik som trendligningen i Holts modell, derimot er nivåligningen noe annerledes i dette tilfellet. I denne nivåligningen er første leddet, Y_t , delt på sesongantall, S_{t-s} . Dette er gjort for å eliminere sesongvariasjoner fra Y_t .

For å jevne ut tilfeldige variasjoner, vekter ligningen nylige beregnede sesongfaktorer med γ og den siste sesongs tall med $(1 - \gamma)$. Sesongligningen viser forholdet mellom den aktuelle verdi av serien, Y_t , dividert med den aktuelle enkelt glattede verdien for serien, L_t . Hvis Y_t er større enn L_t , vil forholdet være større enn 1, mens hvis den er mindre enn L_t , vil forholdet være mindre enn 1.

2.5 Prognosefeil

Mange metoder finnes for å summere feilene som genereres ved bruk av en spesiell prognosemodell. De fleste av disse involverer å finne gjennomsnittet av forskjellen mellom prognosen og den faktiske verdien. Disse enkeltforskjellene (eller feilene) betegnes ofte som residualer (Hanke & Wichern, 2009). Formelen under brukes for å beregne residualen for hver enkelt tidsperiode.

$$e_t = Y_t - F_t$$

e_t = residualen

Y_t = verdien av en tidsserie på tidspunkt t

F_t = prognoseverdien av Y_t

2.5.1 Mean absolute deviation (MAD)

MAD er et prognosefeilmål som måler gjennomsnittet av absoluttfeilene til prognosen. Dette gir gjennomsnittlig feil uansett retning, i samme verdi som den opprinnelige tidsserien (Hanke & Wichern, 2009).

$$MAD = \frac{1}{N} \sum_{t=1}^n |Y_t - F_t|$$

2.5.2 Mean absolute percentage error (MAPE)

MAPE er kalkulert ved å finne den absolutte prosentvise feilen i hver periode, for deretter å ta gjennomsnittet av disse. Denne metoden er bra dersom feilen relativt sett mot størrelsen av verdien i tidsserien er viktig for å vurdere nøyaktigheten av prognosen. MAPE er spesielt bra dersom størrelsene på Y_t er store. MAPE kan ikke kalkuleres hvis noen av Y_t er lik null (Hanke & Wichern, 2009).

$$MAPE = \frac{1}{N} \sum_{t=1}^n \frac{|Y_t - F_t|}{Y_t} * 100\%$$

2.5.3 Mean squared error (MSE)

MSE er en annen metode for å evaluere en prognosemodell. Hver residual (feil) er kvadrert, deretter er de summert og delt på antall observasjoner. Man får dermed gjennomsnittet av de kvadrerte feilene. Denne metoden legger større vekt på de store residualene i forhold til de små, ettersom de blir kvadrert. Dette kan være et viktig mål ettersom i noen tilfeller kan en metode som gir middels store feil være bedre enn en metode som stort sett gir små feil, men noen få, veldig store feil (Hanke & Wichern, 2009).

$$MSE = \frac{1}{N} \sum_{t=1}^n (Y_t - F_t)^2$$

2.5.4 Bias

Når prognosene ikke reflekterer de underliggende etterspørselsdataene over tid, er prognosefeilene (residualene) mest sannsynligvis ikke sentrert rundt null. For å overvåke dette trenger vi en metode for å måle nettopp dette. Og Bias er en slik metode. Ved denne metoden summerer vi prognosefeilene, og ideelt skal denne bli tilnærmet lik null (Chopra & Meindl, 2007).

$$Bias = \sum_{t=1}^n (Y_t - F_t)$$

2.5.5 Tracking signal (TS)

TS er Bias delt på MAD. Dersom på noe tidspunkt TS er utenfor ± 6 , er dette et signal på at modellen er enten under-prognostiserer ($TS < -6$) eller over-prognostiserer ($TS > +6$). Dette kan skyldes trend, plutselig endring i etterspørsel eller lignende (Hanke & Wichern, 2009).

$$TS = \frac{Bias}{MAD}$$

2.6 Kvalitativ prognosemetode

Ifølge Ballou (2004) er kvalitativ metode subjektiv ettersom de er avhengige av skjønnsmessige vurderinger, intuisjon, undersøkelser eller komparative teknikker for å produsere kvalitative estimater om fremtiden. Det kan være at historiske data ikke er tilgjengelig og gjør det dermed vanskelig å lage standardiserte kvantitative prognoser.

Den enkleste formen for kvalitative prognoser er at innkjøperen bruker sin erfaring og intuisjon om kundene, markedet og konkurransesituasjonen til å forutse den fremtidige etterspørselen. Hjelpemidler for å få innsikt i dette kan være enkle markedsundersøkelser (Archer, 1980).

Et virkemiddel å basere prognosene på er scenarioanalyse. Her tar ekspertgruppen for seg ulike sannsynlige scenarioer og diskuterer hvordan disse scenarioene eventuelt vil påvirke etterspørselen. Dette er ikke en prognosemetode i seg selv, men heller en metode for å avgjøre hvilke variabler som påvirker etterspørselen i hvilken grad (Archer, 1980).

Archer (1980) peker også på en ikke ulik metode, som legger vekt på variablene som påvirker etterspørselen. Denne metoden er morfologisk analyse, der målet er å strukturere den eksisterende informasjonen, i form av variabler/hendelser som påvirker etterspørselen. Deretter er målet å finne sannsynlighetene for de ulike hendelsene. Ved å gjøre dette, er det enklere å finne den optimale mengden tilbud i forhold til det etterspørselen man kan forvente seg.

En av de vanligste kvalitative metodene er å oppnå konsensus mellom de ulike ekspertene i virksomheten, som for eksempel innkjøp, marked, logistikk, ledelse, osv. Dette oppnås ved hjelp av samlinger, møter eller seminarer der det skapes debatt og utveksling av erfaring og læring mellom de ulike ekspertene. Disse prosessene gjøres naturligvis på veldig mange forskjellige måter, der målet ofte er å skape rutiner og struktur i samtalene for å nå konsensus om fremtidige prognoser (Archer, 1980).

Delphi-metoden er en slik metode, som brukes intern i bedrifter og er basert på middels til langsiktige predikasjoner av salgstall i bransjen. Ved denne prosessen møtes ikke deltakerne ansikt til ansikt (Mentzer & Moon, 2005).

Delphi-metoden bruker innspill fra eksperter for å lage prognoser, som skjer på følgende måte:

1. Et ekspertpanel med ulik kompetanse fra ulike avdelinger i selskapet skal svare individuelt på undersøkelsesspørsmålene om prognosen for produktet, samt begrunnelsen for denne prognosen (Mentzer & Moon, 2005).
2. Svarene til panelet skal oppsummeres og returneres til medlemmene av panelet uten å identifisere hvilke eksperter som kom opp med hvilke prognoser (Mentzer & Moon, 2005).
3. Etter å ha mottatt sammendrag av svarene, vil hver person av panelet enten opprettholde sin prognose, eller revurderer den første prognosen og deretter sende inn den nye prognosen samt begrunnelsen bak endringene (Mentzer & Moon, 2005). Prosessen kan gå i flere sykluser før det fremkommer konsensus om prognose.

Prosessen er avhengig av en uavhengig gruppe som administrerer prosessen. Det er de som kommuniserer med ekspertene og lager spørsmålene de skal besvare. Det kreves at den administrative gruppen gjør et nøye forarbeid og setter seg inn i hva som påvirker etterspørselen på produktet som prognostiseres, dette er viktig slik at de kaller inn eksperter på alle relevante områder (Archer, 1980).

Formålet med denne metoden er altså å forene individuelle meninger til en gradvis felles oppfatning som man kan bygge beslutninger på. Fordelen med denne metoden er at man forhindrer at sterke personligheter dominerer undersøkelsen, som tillater at mer tilbakeholdne personer får fremmet sine meninger (Mentzer & Moon, 2005).

Det finnes en del fallgruver ved bruk av Delphi-metoden. Det kan være vanskelig å unngå at en uttrykker seg for sikkert når det gjelder fremtidige hendelser. Det er lett å simplificere prosesser, og ikke beholde kompleksitet i variabler der det eksisterer. I tillegg er det lett å være partisk, og legge for stor vekt på eksperter på visse områder sine meninger. Det er også vanskelig og veldig viktig at prosessen er satt opp riktig. Det vil si at det er et representativt panel av eksperter, riktig formulering av spørsmål og nøyaktig og upartisk analyse av responsen fra eksperten og formuleringen av denne (Linstone, 1975).

Ved et forsøk der Delphi-metoden ble testet mot kvantitative metoder, viste resultatene fra dette forsøket at Delphi-metoden gjorde det bedre i 12 av 16 forsøk, mens i to forsøk ble det likt resultat ved begge metoder (Rowe & Wright, 1999).

2.6.1 Tidligere forskning på kvalitativ prognosemetode

I dag er kvalitativ metode og bruk av skjønnsmessig vurderinger og intuisjoner ansett som en viktig del av prognosesetting og det har vært mye forskning på dette området de siste 30 årene.

Lawrence et al. (1985) forsket på kvalitativ metode og prognostiserte et utvalg av tidsserier ved bruk av to alternative kvalitative metoder. Begge disse metodene ble utført av to ulike prognoseettere, som var forskere eller økonomistudenter, som prognostiserte en tidsserie hver. Studien demonstrert at kvalitativ metode kan være minst like presis som kvantitativ metode. I tillegg var standardavviket til prognosefeilene for kvalitativ metode mindre enn ved kvantitativ metode, noe som kan tyde på mer presise prognoser.

Flere andre studier viser derimot at prognosevurderinger av mennesker er mindre presise enn enkle kvantitative modeller (Hogarth & Makridakis, 1981). Et eksempel er Carbone & Gorr (1985) som konkluderer med at kvalitativ metode er mindre presise enn kvantitativ metode. Dette støttes av Lawrence & Makridakis (1989) som mener at menneskelige vurderinger ofte forutser endringer og ustabilitet, selv når tidsseriedataen er stabil. Menneskets skjønnsmessige vurderinger er påvirket av en rekke begrensninger som svekker presisjonen på våre prediksjoner. En kritisk svakhet når det gjelder prognoser basert på skjønnsmessige vurderinger er vanskeligheten av å bruke de samme beslutningskriterier i like situasjoner, noe som har en negativ innvirkning på prognosene (Hogarth & Makridakis, 1981).

Snizek (1989, 1990) har kommet frem til at prognosearbeid i grupper ikke lager bedre prognoser enn å ta gjennomsnittet til hver av prognosene, utarbeidet individuelt av personene i gruppen. Når alle gruppemedlemmene hadde lik tilgang på informasjon, var det i tillegg lite forskjell på hvilke gruppeteknikker man bruker i prognosesettingen. Videre viser det seg at prognosesetting gjennom gruppediskusjoner ofte kan være mer optimistiske enn prognoser som er gjort individuelt. Dette er fordi at i gruppediskusjoner så fokuseres det ofte på faktorer som fremmer suksess, som dermed gjør gruppen mer optimistisk.

Relevant førstehåndskunnskap er all informasjon utenom tidsseriedata som vil være relevant for prognosesetteren. Dette kan være kunnskap om salgskampanjer, informasjon fra leverandører, osv. Edmund, Lawrence & O'Connor (1988) undersøkte den kvalitative prognoseprosessen for et stort selskap i forbruksvarebransjen. Produktprognosene fremkom ut i fra konsensus mellom en gruppe mennesker med førstehåndskunnskap som inkluderte produksjefen, markedssjefen og en person fra finansavdelingen. Disse ble i hovedsak drevet av produksjefen. I denne undersøkelsen, ble førstehåndskunnskapen fra konsensusmøtene sammenlignet med to andre metoder. Den ene var skjønnsmessige vurdering fra andre produksjefer i selskapet, som ikke hadde førstehåndskunnskap rundt dette produktet, den andre var kvantitativ metode. Analysen ble også gjort i forhold til nøkkel- og ikke-nøkkelprodukter. Undersøkelsen viste at når produksjefene prognostiserte produktene (ikke sine egne), var disse like presise som de kvantitative metodene. Dette tyder på at førstehåndskunnskaper fra industrien har lite betydning på prognosene.

Men for prognosene på nøkkelproduktene utarbeidet fra konsensusmøtene, var disse mer presise enn begge sammenligningsmetodene. Men dette var ikke tilfelle på ikke-nøkkelproduktene. Dette kan tyde på at nærmere produktkunnskap er en stor bidragsyter til presisjonen på prognosene. Nærmere produktkunnskap kan være seg kampanjer, distribusjon eller konkurrentkunnskap.

En strategi for å forbedre kvalitative prognoser kan være å kombinere disse prognosene med enten kvantitative prognoser eller andre kvalitative prognoser. Å kombinere metoder kan være gunstig da prognosene blir utarbeidet på bakgrunn av ulike informasjonskilder, og derav øker informasjonen som prognosen baseres på. Kvalitativ metode er mindre korrelert med kvantitative metoder, enn de kvantitative metodene er med hverandre. Dette betyr at det kan være mer hensiktsmessig å kombinere en kvalitativ metode og en kvantitativ metode, enn å kombinere to ulike kvantitative metoder (Lawrence et al, 1985).

En måte å for å kombinere kvantitative metoder og kvalitative metoder er hvis prognosesetteren kan foreta skjønnsmessig justeringer på kvantitative prognoser. Willemain (1989) hevder at skjønnsmessige justeringer kan forbedre presisjonen til kvantitative metoder under to betingelser. Den første betingelsen er at den

kvantitative metoden er mangelfull i estimeringen av tidsseriedataen. Den andre betingelsen er at prognosesetteren har relevant tilleggskunnskap, som kunnskap om kommende salgskampanjer.

Justering av kvantitative modeller basert på skjønnsmessige vurderinger har fungert bra i praksis fordi det har gitt muligheten til å inkludere tilleggsinformasjon og førstehåndskunnskap fra eksperter i selskapet. (Makridakis, et al., 1998).

Empiriske funn viser at prognoser basert på skjønnsmessige vurderinger ofte har mer omfattende innflytelse på beslutningstakere (McHugh & Sparkers, 1983). Hvis det er en mangel på forståelse for hvordan en kvantitativ prognose er utviklet, kan det være lettere å klamre seg til en kvalitativ prognose som kan være enklere å forstå og forklare.

Hvis prognosene er en kombinasjon av kvantitative modeller og justeringer basert på subjektive vurderinger, må brukerne av prognosene forstå hvordan de kvantitative modellene fungerer før de gjøre sine justeringer (Mahmoud, 1984).

3 Metode

3.1 Forskningsdesign

Forskningsdesign er en oppskrift på hvordan en undersøger kan finne svar på spørsmål angående hva som skal observeres, når observasjonene skal finne sted og hvordan datainnsamlingen skal foregå. Det finnes tre ulike metoder innen forskningsdesign, som er kvalitativ, kvantitativ eller en kombinasjon av kvalitativ og kvantitativ.

Kvalitativ metode bruker ord og åpne spørsmål, mens kvantitativ metode bruker talldata og lukkede spørsmål (Creswell, 2009). I denne oppgaven har vi valgt å bruke en kvantitativ metode da denne er mest hensiktsmessig for å besvare vår problemstilling.

Kvantitativ metode er målbart, og resultatet fremkommer i form av et tall eller en tallrekke. Vi bruker en tilnærming hvor det antas at effekten av et utfall trolig avgjøres av en årsak. For eksempel så antar vi at hvis etterspørselsmønsteret endres signifikant for et produkt, så vil dette også tilsi en endring i prognosemodellen som brukes for å opprettholde nøyaktige prognoser.

Ifølge Yin (1994) er det fem hovedmetoder innen forskning. Disse er eksperimenter, undersøkelser, historier, arkivanalyser og casestudier. Valg av metode er basert på type problemstilling og forskernes tilgang på informasjon på tema som skal forskes på.

Casestudier kan være et effektivt verktøy for å studere sammenhengen mellom teori og et oppstått fenomen. Denne strategien brukes for å få en dyp forståelse av et bestemt fenomen, ettersom den er best egnet til å studere fenomener som er dynamiske, men enda ikke har modnet. Denne strategien tillater variasjon og fleksibilitet i forskningen, som følge av endringer som kan oppstå i løpet av forskningsperioden (Yin, 1994)

Vårt formål er å få en dyp forståelse av etterspørselsprognoser og finne de best egnede metodene for Flust. Metodene for etterspørselsprognoser er ikke fastsatt i dag, på bakgrunn av dette velger vi å bruke casestudie for å svare på problemstillingen. Dette tillater oss å utforske ulike prognosemetoder for Flust.

3.2 Datainnsamling

Datainnsamling er en viktig del av oppgaven når vi undersøker hvilke prognosemetoder som er best egnet for Flust. Yin (1994) nevner seks spesifikke kilder til datainnsamling ved casestudier. Disse er dokumenter, arkivmateriale, intervjuer, direkte observasjoner, deltakende observasjoner og fysiske bevis som samles under befarings.

For mange casestudier kan arkivmateriale i form av datafiler, registre eller andre kvantitative data være nyttig. Arkivmateriale i vårt tilfelle er salgsinformasjon som har blitt tatt ut av Flust databaser, og overlevert til oss. I denne oppgaven bruker vi historiske salgs-/etterspørselstall til å lage fremtidige prognoser, samt sammenligne prognosefeil mellom de ulike prognosemetodene.

Ved datainnsamlingen for denne oppgaven har Håkon Skjellevik-Heger, logistikk sjef for Flust vært veldig behjelpelig. Etter samtaler om hvilke produkttyper vi skal lage prognoser for, har vi bestemt at det mest hensiktsmessige er å se på basisproduktene til Flust. Dette er fordi disse varene stort sett har mer data enn eksempelvis sesongvarer som klær. Ved å lage prognoser for klær, må man blant annet ta hensyn til sesongvariasjoner, vær, usikre leveringstidspunkter fra leverandørene, samt at produktene forventes å bli satt ned i pris mot slutten av sesongen. Ved basisvarer innen barn & baby er det lite kampanjer og tilbud, som påvirker etterspørselen. Ettersom Flust har lite ressurser til å lage prognoser i dag, var det derfor hensiktsmessig å se på prognosene til i denne kategorien. Vi valgte da i samarbeid med Flust å bruke analyser av etterspørselen for alle bilstoler for å finne optimale prognosemodeller for Flust sine basisprodukter.

Vi ønsket å se på samlet etterspørsel for hele kategorien, og analyserte derfor den totale aggregerte etterspørselen for bilstoler. I tillegg har vi delt inn etterspørselen aggregert for hver enkelt vektklasse, og gjort analyser på disse tidsseriene. Flust opererer med fire ulike vektklasser i kategorien bilstoler, dette er; 0-13 kg, 9-18 kg, 9-25/36 kg og 15-36 kg. På den måten kan vi undersøke etterspørselen på for eksempel bilstoler fra 15-36 kg samlet. Dette kan være nyttig hvis Flust ønsker å utvide eller redusere sortimentet i denne kategorien. I tillegg er aggregert prognoser mer nøyaktige enn disaggregerte prognoser.

Da vi analyserte etterspørselen brukte vi konsekvent salgstallene som data. Fra Flust har vi fått tilgang til produktenes salgstall og dato for salget, ordretall og dato for ordren. I tillegg har vi fått informasjon om produktkostnad, produktinntekt og salgspris. I analysen har vi sortert salgstallene inn i månedlige perioder. Hvis det i perioder oppsto store avvik i salgstallene, gikk vi nærmere inn i dataene og sjekket om det kan ha vært tomt på lager ved unormalt lave salgstall, eller undersøkte om det har vært tilbud/kampanjer ved unormalt høye salgstall. Vi har observert noen prisvariasjoner på enkelte produkter. Vi ser at en prisjustering på et par hundre kroner har vært relativt ubetydelig for etterspørselen. Videre har vi tatt utgangspunkt i at bilstoler er et lite priselastisk produkt, da vi antar at sikkerhet og kvalitet er viktigere enn pris. Vi har derfor bestemt at vi ikke gjør noen endringer på salgsdataen, til tross for noen prisvariasjoner.

Produktporteføljen vi har analysert i denne oppgaven, står oppført i tabell 1, sortert etter kg.

Tabell 1 - Produktliste bilstoler

Produsent	Modell	KG		Produsent	Modell	KG
Britax	Baby safe sleeper	0-10		Britax	Two-way	9-25
Britax	Baby safe	0-13		Maxi cosi	Mobi	9-25
Britax	Baby safe plus II SHR	0-13		Besafe	plus	9-25
Maxi cosi	Cabriofix	0-13		Britax	Evolva	9-36
Maxi cosi	Pebble	0-13		Maxi cosi	Rodi Airprotect	15-36
Besafe	Sleep	0-13		Maxi cosi	Rodi SPS	15-36
Besafe	Go	0-13		Maxi cosi	Ferofix	15-36
Besafe	Go X1	0-13		Maxi cosi	Rodifix	15-36
Besafe	kid isofix	0-18		Maxi cosi	Rodi XP2	15-36
Besafe	kid I-size	0-18		Britax	Kid II	15-36
Britax	Max-fix	0-18		Britax	Adventure	15-36
Maxi cosi	Axiss	9-18		Britax	kid plus	15-36
Maxi cosi	Pearl	9-18		Britax	kid plus SICT	15-36
Maxi cosi	Priori XP	9-18		Britax	Kidfix	15-36
Britax	Trifix	9-18		Britax	Kidfix SICT	15-36
Besafe	Combi X3	9-18		Britax	Kidfix SL SICT	15-36
Besafe	Combi X3 Isofix	9-18		Britax	Kidfix SL	15-36
Besafe	Combi X4 ISOfix	9-18		Besafe	Up X3	15-36
Britax	Max-Way	9-25		Besafe	Up X3 Fix	15-36
Britax	Multi-tech II	9-25		Besafe	Up X2	15-36

Samtlige 40 av produkter i tabell 1 er brukt til å lage aggregert etterspørselsprognose for bilstoler samlet. Det har ikke vært tilstrekkelig med salgsdata på alle produktene til å lage etterspørselsprognoser på produktene hver for seg. De produktene som vi har laget prognoser for hver for seg er 11 produkter som har vært i varesortimentet i hele perioden, og er markert med fet skrift i tabell 1.

3.3 Optimering av parameterne

Alle eksponentiell glattingsmetodene trenger å spesifisere glattingsparameterne, da de bestemmer hvor raskt prognosene vil reagere på endringer i dataen. Disse parameterne er α (nivå), β (trend) og γ (sesong). Dette kan gjøres ved å teste tilgjengelig salgsdata, og bruke Excel Solver for å optimalisere parameterne. Når solver er mulig å bruke finner vi den optimale parameterverdien ved å minimere prognosens MSE. Andre mål på prognosefeil kan også brukes, men vi har i hovedsak valgt å fokusere på dette målet.

Imidlertid viser det seg at Solver enkelte ganger ved bruk av enkel eksponentiell glatting bommer på sine beregninger, og ikke klarer å optimalisere parameterverdiene. Dette skyldes at modellen er feil spesifisert i forhold til datamaterialet, og kan skje når det finnes innslag av trend i tidsserien. Ved å bruke Solver på glattingskonstanten (α), som brukes til å justere differansen mellom periodens faktiske etterspørsel og det som ble prognosert for i den samme perioden, vil Solver ofte foreslå (α) på lik 1, ved innslag av trend. Dette er fordi enkel eksponentiell glatting konstant vil under- eller over-prognostisere når det finnes trend. For å unngå risikoen ved feil parameterverdi, har vi i tillegg justert parameterverdien manuelt, ved prøve-og-feile-metoden, for å finne verdien som gir lavest prognosefeil.

Ved alle gjennomsnitts- og eksponentiell glattingsmetoder har vi valgt å sette startverdien for prognosen (L_0) lik verdien på første etterspørselsverdi, som er verdien i januar 2013.

Når det gjelder parameterverdiene (p,d,q) (P,D,Q) i ARIMA-modellene har vi fulgt prosedyrene som er beskrevet mer detaljert i teori-kapittelet. Da kunne vi avgjøre om vi måtte differensiere tidsserien for at den skulle bli stasjonær, om det fantes en AR-prosess og om det fantes en MA-prosess i tidsserien. I tillegg til å følge prosedyren

har vi også kontrollert utfallet av disse modellene med å se om disse parameterverdiene ga lavest AIC og MSE.

3.4 Sammenligne og bestemme prognosemetoder

I analysen ønsket vi å teste prognosemetodene gjennomsnitt, glidende gjennomsnitt, enkel eksponentiell glatting, Holts metode og Winters metode, i tillegg til de ulike ARIMA-modellene.

En viktig del av denne oppgaven er hvordan vi velger riktig metode til produktene. Dette har vi gjort ved å sjekke hvilke metode som gir lavest prognosefeil, dette gjorde vi i hovedsak ved å sjekke hvilken metode som ga lavest MSE. Men vi har også sett på Bias og TS for å se om prognosene konstant over- eller underprognostiserer. Dette kan skyldes trend eller plutselige endringer i dataen, og vi har derfor sjekket dataene for trend og sesongvariasjoner. Når vi vurderer tilstedeværelsen av trend og sesongvariasjoner, kan en fremgangsmåte for å bestemme disse mønstrene være å undersøke autokorrelasjonsfunksjon (AKF) og partiell autokorrelasjonsfunksjon (PAKF). Dette kan gjøres effektivt ved bruk av XLSTAT, en tilleggsfunksjon til Excel som vi har brukt. I tillegg har vi sjekket om vi finner sesong eller trend ved å se på grafer av etterspørselen.

Hvis vi ikke ser klare indikasjoner på sesongvariasjoner eller trend vil enkel eksponentiell glatting være en egnet metode. Skulle vi derimot finne indikasjoner på trend og/eller sesongvariasjoner vil Holts metode eller Winters metode være mer passende.

Ved å se på AKF, PAKF og tidsseriedata vil vi derfor på forhånd se hvilke metoder som kan være passende. Ved å kun se på for eksempel MSE vil vi ikke kunne indentifisere sesongvariasjoner. Derfor har vi studert både korrelogrammene, etterspørselsgrafene og prognosefeilen ved MSE, samt brukt våre egne vurderinger for å peke på de best egnede metodene.

3.5 Prognosemodellene

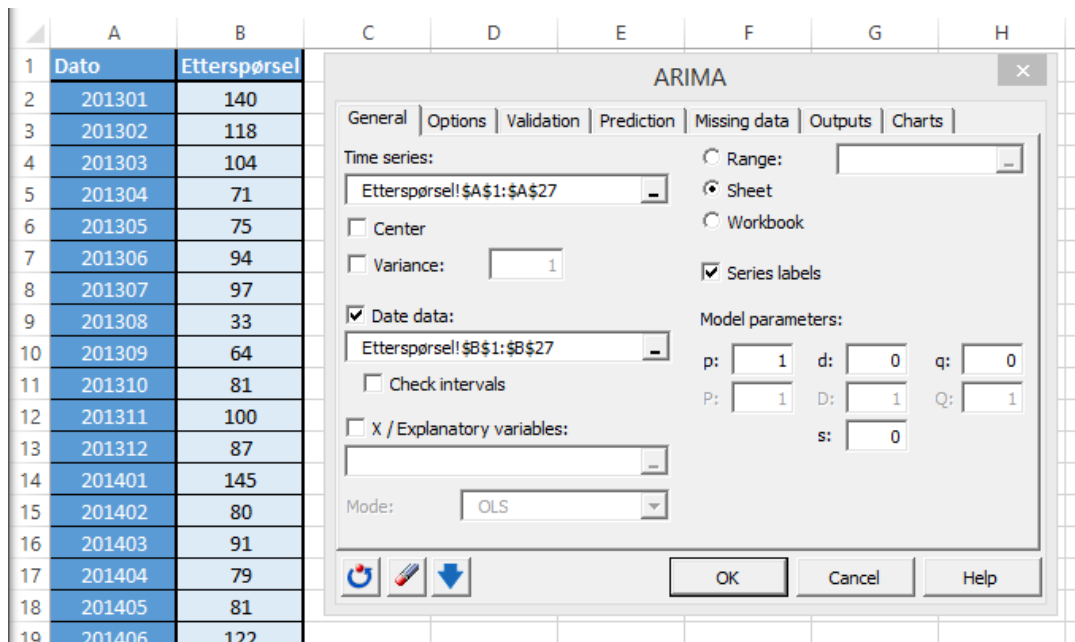
3.5.1 ARIMA-modeller

ARIMA er en prosess for å identifisere parameterne til en tidsserie og dermed riktig prognosemodell. I ARIMA-analysen har vi brukt et Excel add-in som heter XLSTAT til å optimere parameterverdiene.

3.5.1.1 Fremgangsmåte ARIMA-prosess

Det første vi gjør for å finne optimal ARIMA-modell er å kopierer inn månedlig etterspørsel på produkt eller produktgruppe vi vil prognostisere i XLSTAT.

Da åpnes en input-boks (figur 12) hvor vi plotter inn etterspørselsdata og hvilke ARIMA parametere vi ønsker å teste ((p,d,q) og eventuelt (P,D,Q) dersom det er sesongvariasjon i dataen).



Figur 12 - ARIMA input-boks i XLSTAT

ARIMA analysen, i dette tilfelle for ARIMA (1,0,0), vil da åpnes i en ny fane. Her vil vi få mye informasjon rundt analysen, blant annet autokorrelasjonsfunksjonen (AKF) og den partielle autokorrelasjonsfunksjonen (PAKF). Disse brukes i identifiseringsfasen for å få en indikasjon på om tidsserien må differensieres og hvilken modell som bør brukes. Vi sjekker om parameterene er signifikant forskjellige fra null og vurderer deretter hvilken modell som har lavest AIC.

Summary statistics:

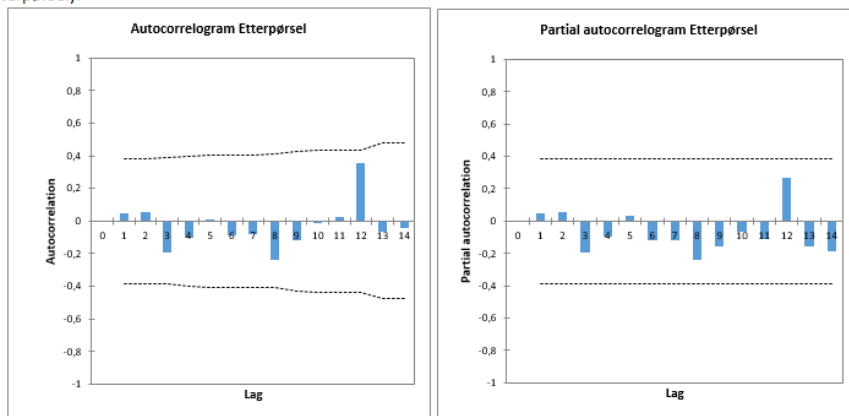
Variable	Observations	Obs. with missing data	Obs. without missing data	Minimum	Maximum	Mean	std. deviation
Etterspørsel	26	0	26	30,000	145,000	91,269	24,833

Results of ARIMA modeling of the Etterspørsel series:

Results after optimization (Etterspørsel):

Goodness of fit statistics:

Observation	25,000
DF	22,000
SSE	15357,028
MSE	614,281
RMSE	24,785
WN Variance	614,281
MAPE(Diff)	107,034
MAPE	24,616
-2Log(Like.)	234,499
FPE	665,471
AIC	240,499
AICC	241,642
SBC	244,156
Iterations	23,000




Figur 13 - ARIMA-utskrift fra XLSTAT

3.5.2 Gjennomsnitts- og eksponentiell glattingsmodeller

For å best mulig kunne sammenligne og identifisere hvilke gjennomsnitt- og eksponentiell glattingsmodeller som egner seg for å prognostisere etterspørselen til Flust har vi designet en prognosemodell i Excel. Vårt fokus under utvikling av denne modellen har vært at den på best mulig måte skal gjøre analysene som lar oss svare på problemstillingen.

3.5.2.1 Utarbeidelse av programvaren

Vi har utarbeidet en Excel-programvare hvor vi legger inn månedlig etterspørselsdata inn i første ark som har navnet «etterspørsel». I programmet finnes det ett ark for hver av de ulike prognosemodellene, samt ulike mål på prognosefeil. Det siste arket i filen er ett oppsummeringsark, som vises i figur 14, der vi sammenligner de ulike prognosemodellenes ytelse for det aktuelle produktet.




Figur 14 - Oppsummering eksponentiell glattings- og gjennomsnittsanalyse i Excel-programvaren

4 Resultater og analyse

4.1 Analyse av bilstoler, totalt

Det første vi har sett på er hvilke metoder som passer best til den totale etterspørselen til bilstoler. Dette gjør vi for å få en oversikt over den totale etterspørselen for denne produktgruppen, uavhengig av vektklasse eller merke. Når vi aggregerer etterspørselen gir dette også mer presise prognoser. Figur 15 viser den total månedlig etterspørselen til bilstoler. Vi ser at etterspørselen svinger ganske kraftig, fra et minimum på 33 til et maksimum på 145. Ut fra figur 15 ser det ikke ut som det er trend. Noe sesongvariasjon kan kanskje sees, ut fra at det er topper i januar hvert år.



Figur 8 - Etterspørsel bilstoler totalt

4.1.1 ARIMA for total etterspørsel bilstoler

Gjennomsnittlig etterspørsel for underkategorien bilstol er 91,9 med et standardavvik på 24,5, noe som tilsier store variasjoner i datasettet (tabell 2).

Tabell 2 - Statistikk sammendrag bilstoler totalt

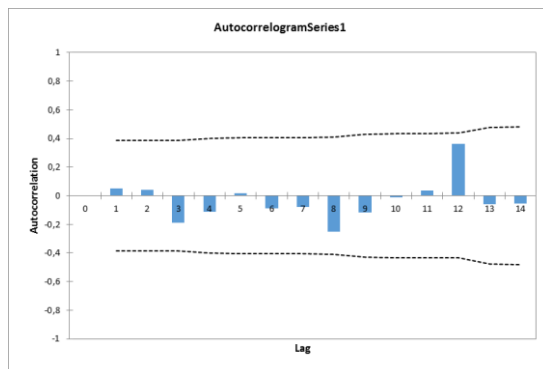
Variable	Observations	Minimum	Maximum	Mean	Std. deviation
Bilstol total	26	33,000	145,000	91,923	24,552

Første steg i ARIMA-prosessen å undersøke autokorrelasjons funksjonen (AKF) og den partielle autokorrelasjonsfunksjonen (PAKF) for å få et inntrykk av hvilken ARIMA modell som passer best med tidsserien.


AKF og PAKF i figur 16 og 17 forteller oss at ingen av «laggene» er signifikante og vi kan dermed ikke modellere tidsserien på AR- eller MA-nivå (Carlberg, 2012).

Dette betyr at etterspørselen i en gitt periode ikke korrelerer med noen av de foregående periodene eller et bevegelig snitt av disse. Dette er det som kalles en hvit støy prosess, at verdiene er uten mønster, og dermed tilfeldige. Disse korrelogrammene indikerer at det er vanskelig å lage bedre prognoser enn det man får ved å ta gjennomsnittet av alle tidligere tilgjengelige verdier (Carlberg, 2013). Vi ser dog en indikasjon som vi også gjorde i figur 15 at det er mulig at det kan være sesong i tidsserien. Den tolvte «laggen» markerer seg, dette kan indikere en korrelasjon mellom verdien i en gitt tidsperiode og tilsvarende måned ett år tidligere. Dette er dog ikke signifikant på et 95 % nivå, og vi kan ikke slå fast at det finnes sesongvariasjon.

Etterspørselsgrafene i figur 15 og AKF og PAKF i figur 16 og 17 viser at det ikke finnes noe trend i tidsserien.



Figur 16 - AKF bilstoler totalt



Figur 17 - PAKF bilstoler totalt

4.1.2 Eksponentiell glattings- og gjennomsnittsmoeller for total etterspørsel bilstoler

ARIMA-prosessen viste oss at det hverken finnes trend eller sesong i tidsserien.

Dette tar vi med oss inn i denne delen av analysen, og utelukker da Holts og Winters modell ettersom de tar med henholdsvis trend og sesong i sine prognoser.

Vi har da testet tre modeller, gjennomsnitt, glidende gjennomsnitt og enkel eksponentiell glatting.


Tabell 3 oppsummerer disse tre modellene, vi ser at gjennomsnittsmodellen kommer best ut på alle tre målene for prognosefeil. Men vi ser også at det ikke er store forskjeller på hvilken metode som brukes. At gjennomsnittsmetoden gjør det så bra i forhold til de andre, bekrefter noe av konklusjonen vi gjorde i ARIMA-analysen. Etter å ha optimert (α) med Excel Solver endte (α) i enkel eksponentiell glatting modellen på 0,41.

Tabell 3 – Oppsummeringstabell eksponentiell glattings- og gjennomsnittsmodeller, bilstoler totalt

	MSE	MAD	MAPE
Gjennomsnitt	713,28	19,70	28 %
Glidende gjennomsnitt	753,52	21,57	29 %
Enkel eksp. glatting	750,42	20,64	28 %

Det er utfordrende å lage prognoser med så store svingninger i etterspørselen, noe som kommer tydelig frem når vi ser på størrelsen på MAD. Når den gjennomsnittlige etterspørselen er 91 bilstoler per måned, er det et ganske stort avvik å bomme med ca. 20 enheter hver måned i gjennomsnitt.


Figur 18 viser at prognosen ikke følger samme mønster som den faktiske etterspørselen, men justerer seg til gjennomsnittet av tidsserien.



Figur 18 - Gjennomsnittsprgnose, bilstoler totalt

4.2 Analyse av bilstoler, vektklasse 0-13 kg

Som figur 19 viser er det også her store variasjoner i etterspørselen, laveste verdi i denne under-kategorien er to solgte bilstoler mot 24 som er den høyeste verdien i datasettet. Av grafen er det vanskelig å se klare indikasjoner på hverken sesong eller trend, selv om vi ser at salget er høyere fra mai til juli i både 2013 og 2014.



Figur 19 - Etterspørsel for bilstoler, vektklasse 0-13 kg

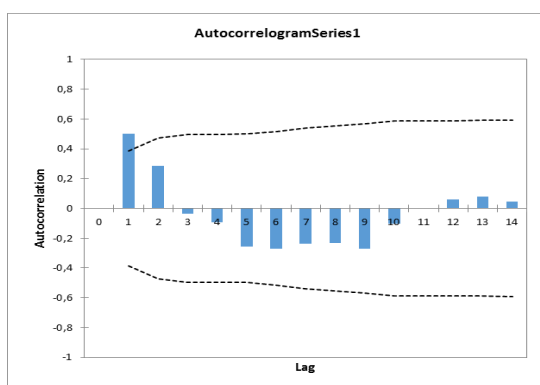
4.2.1 ARIMA for bilstoler vektklasse 0-13 kg.

I denne vektklassen er det solgt litt over 13 stoler i gjennomsnitt per måned innenfor tidsserien. Standardavviket har i samme periode vært på 6,6. Dette må sies å være høyt sammenlignet på snittet og tyder på at det er store svingninger i tidsserien, med tanke på at det ikke finnes trend.

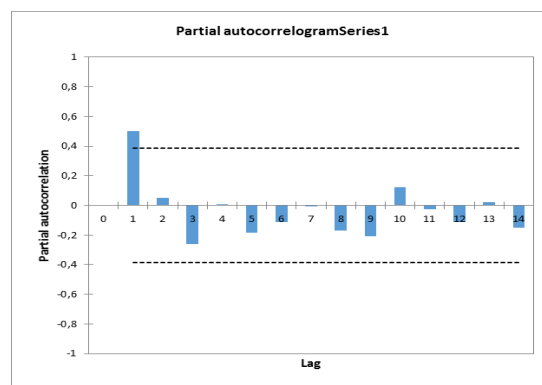
Variable	Observations	Minimum	Maximum	Mean	Std. deviation
0-13 KG	26	2,000	24,000	13,269	6,649

Tabell 4 - Statistiksammendrag, bilstoler 0-13 kg

I tidsseriens AKF ser vi at det finnes en «spiss» i første «lagg» og deretter faller den relativt gradvis. I PAKF finnes det også en «spiss» i første «lagg», men her kuttes de videre «laggene». Dette indikerer at dette er en ARIMA (1,0,0), altså at modellen bør inkludere en AR parameter. Dette betyr at verdien i en gitt måned er positivt korrelert med verdien i forrige måned (Carlberg, 2012). Vi kan se ut fra korrelogrammene at differensiering ikke er nødvendig, ettersom de ikke indikerer trend i tidsserien. Det er heller ikke tegn på sesong i datasettet.



Figur 20 - AKF, bilstoler 0-13 kg



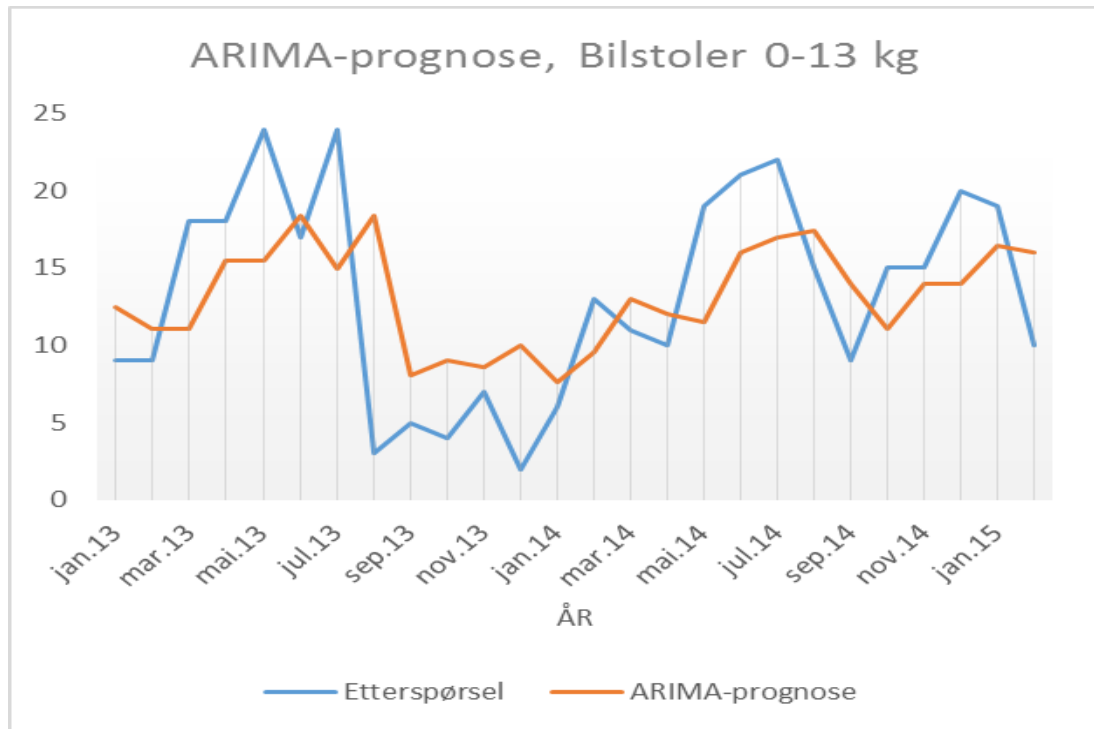
Figur 21 - PAKF, bilstoler 0-13 kg

Selv om AKF og PAKF indikerer at ARIMA (1,0,0) er riktig modell, valgte vi i tillegg å teste de nærliggende modellene ARIMA (2,0,0) og ARIMA (1,0,1). Men som vi ser av tabell 5, er det som forventet ARIMA (1,0,0)-modellen som får lavest AIC, og dermed kan vi konkludere med at denne modellen er den optimale ARIMA-modellen for denne tidsserien. AR(1) parameteren (ϕ_1) er 0,494 og konstantleddet (c) er 13,006.

Tabell 5 - Oppsummeringstabell ARIMA

ARIMA	AIC	MSE
1,0,0	167,88	31,64
2,0,0	169,83	31,58
1,0,1	169,86	31,62

Figur 22 viser grafen til ARIMA (1,0,0)-modellen, her kan vi tydelig se at en del av prognosen baseres på forrige verdi, og at grafen følger etterspørsels-grafen delvis, med et etterslep.



Figur 22 - ARIMA- prognose, bilstoler 0-13 kg

4.2.2 Eksponentiell glattings- og gjennomsnittsmoeller for bilstoler vektklasse 0-13 kg.


I likhet med tidsserien for den totale etterspørselen av bilstoler kan vi også her på bakgrunn av ARIMA-prosessen utelukke trend og sesong i tidsserien. Vi har dermed ikke benyttet Holts og Winters modell.

Som vi ser av tabell 6 er det enkel eksponentiell glatting som kommer best ut av modellene. Gjennomsnittsalget er som skrevet tidligere på ca. 13 bilstoler i måneden, og som MAD viser bommer prognosen gjennomsnittlig på 4,7 per måned.

Tabell 6 - Oppsummeringstabell eksponentiell glattings- og gjennomsnittsmoeller, bilstoler 0-13 kg

	MSE	MAD	MAPE
Gjennomsnitt	50,14	5,96	86 %
Glidende gjennomsnitt	53,57	5,94	82 %
Enkel eksp. glatting	38,54	4,68	63 %

Figur 23 viser enkel eksponentiell glattingsprognosen for bilstoler 0-13 kg. Som vi ser er prognosen lite treffsikker, og får ikke med seg de store svingningene i etterspørselen. Etter optimering med Solver blir (α) for denne modellen 0,71.



Figur 23 – Enkel eksponentiell glatting prognose, bilstoler 0-13 kg

4.2.3 ARIMA (1,0,0) vs. enkel eksponentiell glatting

De to modellene som var best egnet for denne tidsserien var ARIMA (1,0,0) og enkel eksponentiell glatting. Vi bruker MSE for å sammenligne modellene og deres prestasjoner, og som tabell 7 viser er det ARIMA (1,0,0) som gir lavest MSE på 31,64 mot 38,54 for enkel eksponentiell glattingsmodellen.


Tabell 7 – MSE enkel eksponentiell glatting mot. ARIMA prognose

	MSE
Enkel eksp. glatting	38,54
ARIMA (1,0,0)	31,64

Dette vil si at ARIMA-modellen gir de beste prognosene for denne tidsserien.

4.3 Analyse av bilstoler, vektklasse 9-18 kg.

Mønsteret med store svingninger i etterspørselen fortsetter også i vektklasse 9-18 kg. Etterspørselen svinger fra to solgte bilstoler i august 2013 til 74 solgte bilstoler i januar 2014. Ut fra figur 24 ser det ikke ut som det er trend eller sesongvariasjon i tidsserien.



Figur 24 - Etterspørsel, bilstoler vektklasse 9-18 kg

4.3.1 ARIMA for bilstoler vektklasse 9-18 kg.

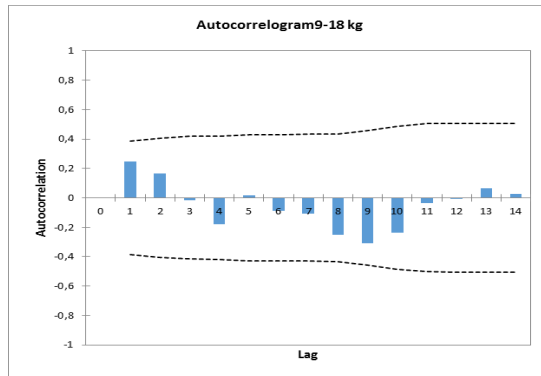
Gjennomsnittlig salg av bilstoler i vektlassen 9-18 kg per måned har vært på 21 bilstoler i tidsseriens periode. Standardavviket i samme periode har vært på hele 16 bilstoler, noe som er mye relativt til gjennomsnittet da det ikke finnes trend i dataserien.

Tabell 8 - Statistikk sammendrag, bilstoler 9-18 kg

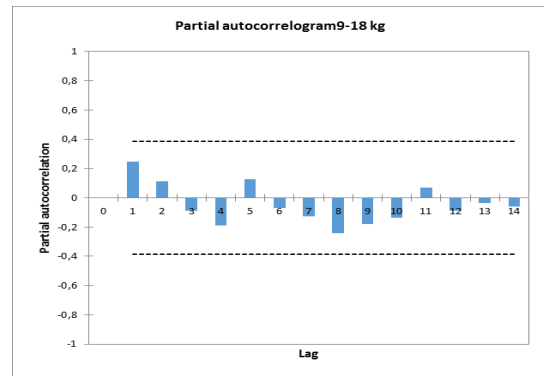
Variable	Observations	Minimum	Maximum	Mean	Std. deviation
9-18 kg	26	2,000	74,000	20,885	16,278

Som vi kan se fra figur 25 og 26 er ingen av «laggene» i datagrunnlagets AKF og PAKF signifikant forskjellig fra null og vi kan dermed ikke modellere tidsserien på AR eller MA nivå (Carlberg, 2012). Som skrevet tidligere indikerer dette at det er vanskelig å lage bedre prognoser enn det man kan gjøre ved å ta gjennomsnittet av

alle tidligere tilgjengelige verdier (Carlberg, 2013). Ut fra korrelogrammene kan vi også her utelukke at det finnes trend og sesong i tidsserien.



Figur 25 - AKF, bilstoler 9-18 kg



Figur 26 - PAKF, bilstoler 9-18 kg


4.3.2 Eksponentiell glattings- og gjennomsnittsmoeller for bilstoler vektklasse 9-18 kg.

Tabell 9 viser de ulike målene for prognosefeil for de tre aktuelle modellene. Vi har også her utelukket Holts- og Winters modell ettersom det ikke finnes trend og sesong i datagrunnlaget. Som vi ser av tabellen har enkel eksponentiell glatting en lavere MSE på 284,58 enn gjennomsnitts- og glidende gjennomsnittsmoellene som har MSE på henholdsvis 316,14 og 321,36. Enkel eksponentiell glattingsmoellen fikk en (α) på 0,29 etter at vi brukte Excel Solver til å optimere parameteren.

Tabell 9 - Oppsummeringstabell eksponentiell glattings- og gjennomsnittsmoeller, bilstoler 9-18 kg

	MSE	MAD	MAPE
Gjennomsnitt	316,14	13,00	107 %
Glidende gjennomsnitt	321,36	14,00	89 %
Enkel eksp. glatting	284,58	12,71	93 %

Figur 27 forteller oss at enkel eksponentiell glattingsmodellen ikke klarer å fange opp de betydelige svingningene i etterspørselen.




Figur 27 – Enkel eksponentiell glatting prognose, bilstoler 9-18 kg

4.4 Analyse av bilstoler, vektklasse 9-25/36 kg.

I Figur 28 ser vi at selv om etterspørselen svinger ganske mye, er den mer stabil enn det vi har sett i de foregående kategoriene. Den laveste etterspørselsverdien er ni bilstoler, mens den høyeste observerte verdien er 29 bilstoler.

Dersom vi observerer grafen, kan det se ut som om det er en positiv trend i tidsserien. Ut fra grafen kan vi dog ikke se noen antydninger til sesong.



Figur 28 - Etterspørsel, bilstoler vektklasse 9-25/36 kg

4.4.1 ARIMA for bilstoler vektklasse 9-25/36 kg.

Tabell 10 viser at gjennomsnittsetterspørselen etter bilstoler i vektklassen 9-25/36 kg har vært 15,7 i tidsseriens periode. I samme tidsrom har etterspørselens standardavvik vært 5,5. Dette er en mindre variasjon i forhold til gjennomsnittet enn de to tidligere analyserte vektklassene.

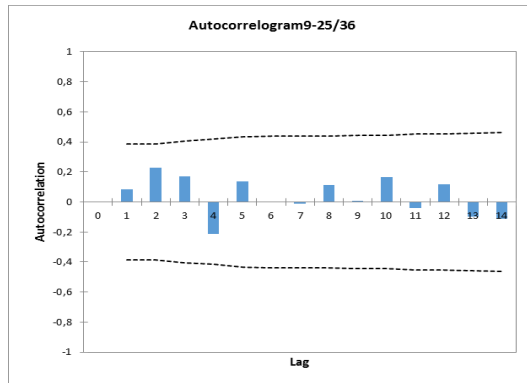
Tabell 10 - Statistikk sammendrag, bilstoler 9-25/36 kg

Variable	Observations	Minimum	Maximum	Mean	Std. deviation
9-25/36	26	9,000	29,000	15,731	5,489

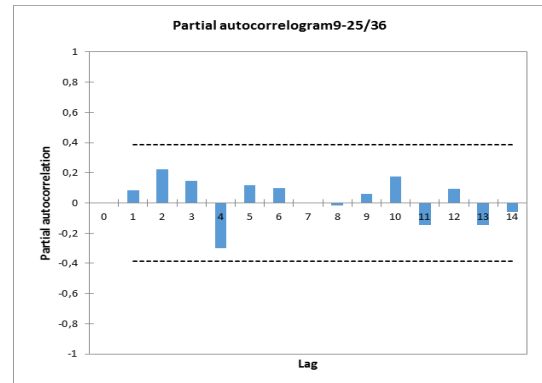
AKF og PAKF i figur 29 og 30 avkrefter det vi antydte ut fra grafen i figur 28 at det kunne være trend i datasettet, og tidsserien må derfor ikke differensieres.

Korrelogrammene utelukker også at det finnes noe signifikant sesongvariasjon i tidsserien.

Det kommer frem av korrelogrammene at ingen av «laggene» er signifikant forskjellige fra null. Dette vil antyde at det ikke er mulig å modellere tidsserien med hverken AR- eller MA-parametere. Gjennomsnittet av tidligere verdier er ofte den beste prognosemetoden i slike tilfeller.



Figur 29 - AKF, bilstoler 9-25/36 kg



Figur 30 - PAKF, bilstoler 9-25/36 kg

4.4.2 Eksponentiell glattings- og gjennomsnittsmoeller for bilstoler vektklasse 9-25/36 kg.

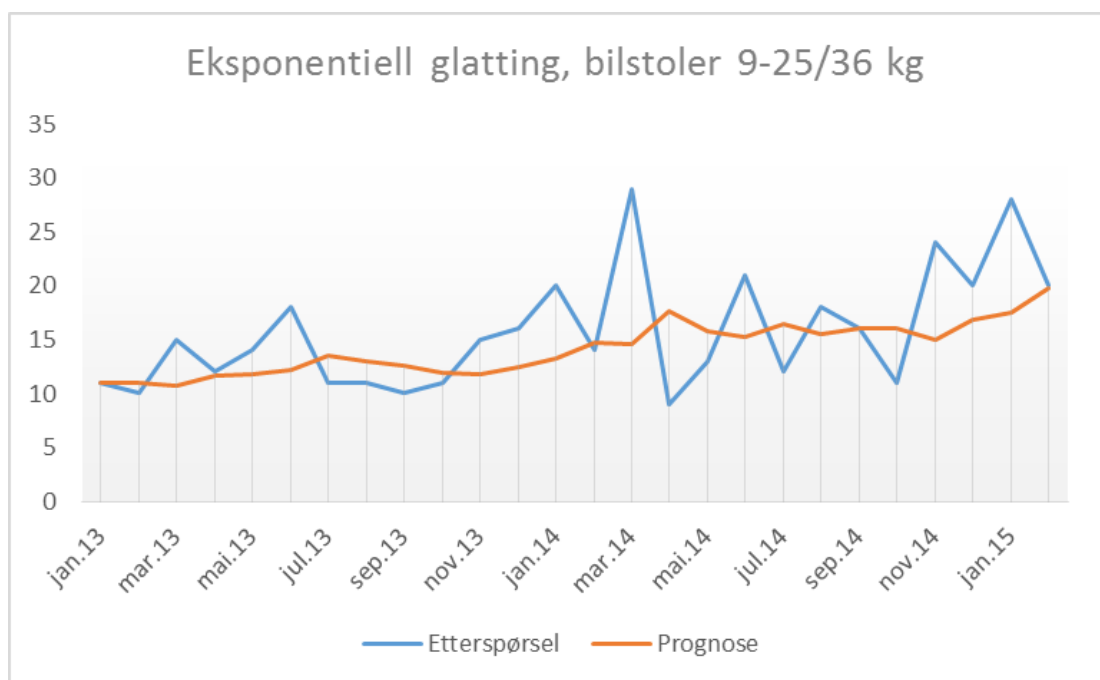
Selv om ARIMA-prosessen ikke bekreftet at det var trend i tidsserien til etterspørselen i denne vektklassen, valgte vi å inkludere Holts modell i analysen på grunn av at etterspørselsgrafene viste tendenser til trend.

Tabell 11 - Oppsummeringstabell eksponentiell glattings- og gjennomsnittsmoeller, bilstoler 9-25/36 kg

	MSE	MAD	MAPE
Gjennomsnitt	32,38	4,32	25 %
Glidende gjennomsnitt	35,28	4,93	32 %
Enkel eksp. glatting	27,74	3,93	24 %
Holts	27,43	3,94	25 %

Holts modell og enkel eksponentiell glatting gir de beste resultatene, disse ga en MSE på henholdsvis 27,43 og 27,74. Ettersom det ikke er gunstig å ta med flere parametere enn nødvendig vil da vår anbefaling være å bruke enkel eksponentiell glatting for denne tidsserien.

Ved å optimere med Excel Solver får vi en optimal (α) på 0,21. Enkel eksponentiell glattingsmodellen vises i figur 31. Vi ser at glattingsmodellen ikke klarer å fange opp svingningene i etterspørselen og ikke klarer å modellere etterspørselsstigningen mot slutten av tidsserien. Dette gir utslag i prognosefeilmålet tracking error (TS) som blir høyere enn 6 mot slutten av tidsserien.




Figur 31 – Enkel eksponentiell glatting-prognose, bilstoler 9-25/36 kg.

4.5 Analyse av bilstoler, vektklasse 15-36 kg.

Etterspørselen til bilstoler i vektklassen 15-36 kg vises i figur 32. Etter at det var høye verdier i de tre første månedene i tidsserien, svinger etterspørselen mindre i resten av tidsserien.

Som grafen viser er måneden med høyest etterspørsel i denne vektklassen i første periode, januar 2013, med en etterspørsel på 77 bilstoler. Den laveste verdien var i august samme år med en etterspørsel på 17 bilstoler.

Det er ikke indikasjon på trend eller sesongvariasjon i dataserien.



Figur 32 - Etterspørsel, bilstoler vektklasse 15-36 kg

4.5.1 ARIMA for bilstoler vektklasse 15-36 kg.


Tabell 12 forteller oss at gjennomsnittssalget av bilstoler i vektklassen 15-36 kilo har vært 37 per måned i tidsperioden, samtidig har standardavviket vært på 13,5 stoler.

Det bekrefter at også her er det store svingninger i etterspørselen relativt til gjennomsnittsetterspørselen.


Tabell 12 - Statistikk sammendrag, bilstoler 15-36 kg

Variable	Observations	Minimum	Maximum	Mean	Std. deviation
15-36 kg	26	17,000	77,000	37,308	13,466

Figur 33 og 34 viser korrelogrammene (AKF og PAKF) for denne vektclassens tidsserie. Korrelogrammene i figur 33 og 34 antyder at det ikke finnes trend eller sesong i datasettet. Slik vi kan lese ut fra disse, er ingen av korrelasjonene signifikant forskjellige fra null. Som beskrevet tidligere, indikerer dette at det er vanskelig å modellere prognoser som presterer bedre enn et gjennomsnitt av tidligere verdier.



Figur 33 - AKF, bilstoler 15-36 kg



Figur 34 - PAKF, bilstoler 15-36 kg


4.5.2 Eksponentiell glattings- og gjennomsnittsmoeller for bilstoler vektclass 15-36 kg.

Ettersom ARIMA-prosessen ikke antydet trend og sesong, velger vi også her å utelukke Holts og Winters modell. Av de tre resterende modellene er det glidende gjennomsnittsmoellen som presterer best, med en MSE på 165,49, mot en MSE på henholdsvis 183,43 og 221,70 for enkel eksponentiell glattings- og gjennomsnittsmoellen. Denne moellen har et glidende gjennomsnitt på de siste fire verdiene.

Tabell 13 – Oppsummeringstabell eksponentiell glattings- og gjennomsnittsmoeller, bilstoler 15-36 kg

	MSE	MAD	MAPE
Gjennomsnitt	221,70	11,43	41 %
Glidende gjennomsnitt	165,49	10,47	36 %
Enkel eksp. glatting	183,43	11,15	36 %

Figur 35 viser grafen til glidende gjennomsnittsprognosen mot etterspørselen til bilstoler 15-36 kg.



Figur 35 - Glidende gjennomsnittsprognose, bilstoler 15-36 kg.

4.6 Analyse av enkeltproduktene

For å analysere enkeltproduktene har vi har brukt samme prosess som for de aggregerte prognosene. Vi studerte først etterspørselsgrafene, før vi sjekket standardavvik, AKF og PAKF i ARIMA-utskriften. Dette ga oss en pekepinn på om vi kunne identifisere en AR-prosess eller en MA-prosess, i tillegg til at vi fikk sjekket tilstedeværelsen av sesongvariasjoner og trend.

Kun ved to av produktene, *Besafe Up X3 Fix 15-36 kg* og *Maxi Cosi Cabriofix 0-13 år*, fant vi signifikante parameterverdier. Korrelogrammene viste at en AR-prosess var best egnet. Dette resulterte i en ARIMA(2,0,0)-modell og en ARIMA(1,0,0)-modell for disse to produktene.

For *Besafe Up X3 Fix* var MSE for ARIMA modellen på 27 mens den var 36,5 for enkel eksponentiell glatting, vil dette si at det er ARIMA-modellen som lager best prognoser for dette produktet. For *Maxi Cosi Cabriofix* er MSE for ARIMA-modellen 5,7. Mens MSE er 7,06 for enkel eksponentiell glatting. ARIMA-modellen er derfor marginalt bedre.

Vi fant hverken sesongvariasjon eller trend i tidsseriedataen til noen av produktene. Derfor kunne vi utelukke både Holts- og Winters modell. Som tabell 14 viser oss så var det enkel eksponentiell glatting som var den modellen som ga lavest MSE av gjennomsnitts- og eksponentiell glattingsmodellene på de fleste av produktene. På tre av produktene var det glidende gjennomsnitt som ga lavest prognosefeil.

Tabell 14 - Oppsummering optimale prognosemetode for enkeltproduktene

Produkt	Metode	ARIMA
Besafe Combi X3 9-18 kg	Enkel eksp. glatting.	
Besafe Combi X3 Isofix 9-18 kg	Enkel eksp. glatting.	
Besafe Go 0-13	Enkel eksp. glatting.	
Besafe plus 9-25 kg	Enkel eksp. glatting.	
Besafe Up X3 15-36 kg	Glidende gj.snitt	
Besafe Up X3 Fix 15-36 kg	Enkel eksp. glatting.	2,0,0
Britax Adventure 15-36 kg	Enkel eksp. glatting.	
Britax Evolva 9-36 kg	Enkel eksp. glatting.	
Britax Multitech II 9-25 kg	Glidende gj.snitt	
Maxi Cosi Cabrio fix 0-13 år	Enkel eksp. glatting.	1,0,0
Maxi Cosi Rodi Airprotect 15-36 kg	Glidende gj.snitt	

4.7 Oppsummering av resultater

Totalt har vi gjort analyser av 16 ulike tidsserier. Vi har gjort analyse av aggregert etterspørsel for alle bilstolene og de fire forskjellige vektklassene hver for seg. I tillegg har vi gjort analyser disaggregert for 11 av bilstolene. Stolene vi har analysert disaggregert er de stolene som har vært i produktsortimentet under hele analyseperioden.

Det var kun i tre (*Besafe Up X3 Fix*, *Maxi Cosi Cabriofix* og vektklasse 0-13 kg) av disse 16 analysene der resultatet av ARIMA-analysen ga signifikante parameterverdier.

Analysen av gjennomsnitts- og eksponentiell glattingsmodellene konkluderte med at enkel eksponentiell glatting var modellen som ga lavest prognosefeil i flest tidsserier. I 11 av de 16 tidsseriene var enkel eksponentiell glatting den best egnede prognosemetoden, mens glidende gjennomsnitt var best egnet i fire av tidsseriene og gjennomsnitt var best egnet i den siste.

Det vi kan si generelt etter denne analysen er at prognosemetodene gjennomsnitt, glidende gjennomsnitt og enkel eksponentiell glatting, oppnår relativt like prognosefeil. Videre så er det store variasjoner i tidsseriene, som gjør det vanskelig å lage presise prognoser.

I de tre tilfellene der ARIMA-prosessen resulterte i parameterverdier som er signifikant forskjellige fra null ga ARIMA-analysen lavere prognosefeil, i form av MSE, enn den optimale gjennomsnitts- eller eksponentiell glattingsmodellen.

5 Diskusjon og konklusjon

5.1 Diskusjon av analyseresultatene

Problemstillingen vi forsøker å besvare er som følger:

Hvilke prognosemetoder er best egnet for å lage kortsiktige prognoser for Flust.no AS' basisprodukter?

Med bakgrunn i problemstillingen tar vi både prognosenes presisjon og implementeringens kompleksitet til betraktning når vi vurderer hvilke prognosemetoder som er best egnet for Flust.

Det har vært vanskelig å lage modeller som prognostiserte tidsseriene nøyaktig på grunn store variasjoner i tidsseriedataen. Standardavviket for total etterspørsel etter bilstoler er 24,5, som kan anses som høyt, i en tidsserie uten trend og sesong, ettersom gjennomsnittlig etterspørsel er 92 bilstoler. Moon (2013) påpeker at det er vanskelig å forutsi om fremtidig etterspørsel vil øke eller avta med høyt innslag av støy. Dette betyr da at det er vanskelig å gjøre bedre prognoser en gjennomsnittet til alle observasjonene i tidsserien (Carlberg, 2012).

Vi har valgt å legge hovedvekt på aggregerte prognoser i analysen. Da ARIMA-analysen indikerte at tidsserien for bilstolars totale etterspørsel kun var hvit støy, gir dette en indikasjon på at også de disaggregerte prognosene sannsynligvis kun er hvit støy. Dette er i samsvar med Chopra & Meindl (2007) som skriver at aggregerte prognoser vanligvis er mer nøyaktige enn disaggregerte prognoser, fordi prognoser som regel har lavere standardavvik mot gjennomsnittet desto mindre spesifikke prognosene er,

Videre viste det seg at når ARIMA-parameterne var signifikante, så var også ARIMA-modellen mer presis enn eksponentiell glattings- og gjennomsnittsmoellene. Men med tanke på det store antallet produkter Flust fører, vil det være lite effektivt å gjennomføre en ARIMA-prosess på alle disse produktene.

Det var kun analysen av *Besafe Up X3 Fix* (15-36 kg), *Maxi Cosi Cabrio Fix* (0-13 kg) og Bilstoler vektklasse 0-13 kg hvor ARIMA-parameterne var signifikante og vi kunne gjennomføre en ARIMA-prosess. Ved alle disse tre analysene har ARIMA-modellene lavere MSE enn gjennomsnitt- og eksponentiell glattingsmodellene. For

Besafe up X3 fix var MSE for ARIMA-modellen på 27 mens den var 36,5 for enkel eksponentiell glatting. For *Maxi cosi cabriofix* var MSE for ARIMA-modellen 5,7, mens MSE er 7,06 for enkel eksponentiell glatting. Og for vektklasse 0-13 kg var MSE for ARIMA-modellen 31,64 mot 38,54 for enkel eksponentiell glatting. Hvis vi kun hadde tatt prognosefeilene til betraktning ville ARIMA-modellene vært en anbefalt metode på de produktene som ga signifikante parameter.

Ved et så stort antall produkter er eksponentiell glattings- og gjennomsnittsmoeller ofte de eneste som er egnet en rask og tilfredsstillende implementering (Makridakis, et al., 1998). Det eneste som kreves for å gjennomføre gjennomsnitt- og eksponentiell glattingsmodellene er historiske salgstall. Modellene er gjennomsnitt, glidende gjennomsnitt og enkel eksponentiell glatting, da vi hverken finner trend eller sesongvariasjoner i dataene utelukker vi Holts og Winters modell. I 11 av de 16 analysene vi har gjort gir enkel eksponentiell glatting lavest MSE av gjennomsnitt- og eksponentiell glattingsmodellene. Det vil være minst ressurskrevende for Flust å kun implementere en prognosemodell, og resultatet av analysen viser at enkel eksponentiell glatting gir lavest prognosefeil.

Det er likevel viktig å være klar over at disse modellen gir lite presise prognoser. Gjennomsnittlig absoluttfeil (MAD) for den prognosen til den totale etterspørselen for bilstoler var på ca. 20 bilstoler per måned for både gjennomsnitt- og enkel eksponentiell glattingsmodellen. Derfor bør man i tillegg bruke skjønn, intuisjon og egne erfaring i prognosearbeidet. Ifølge Ballou (2004) er kvalitativ metode effektiv når historiske data ikke er tilgjengelig eller mangelfull. Dette er tilfelle for Flust, ettersom de ofte fornyer produkttilbudet.

Forskning på presisjonen for kvalitative metoder konkluderer ulikt. Dette kan skyldes ulik kontekst eller ulik metode. Lawrence et al. (1985) demonstrerte i sin studie at kvalitativ metode kan være minst like presis som kvantitativ metode. Dette er i motsetning til flere andre studier, blant annet Carbone & Gorr (1985) som konkluderer med at kvalitativ metode er mindre presise enn kvantitativ metode.

En strategi for å forbedre kvalitative prognoser kan være å kombinere disse prognosene med enten kvantitative prognoser eller andre kvalitative prognoser. Willemain (1989) hevder at skjønnsmessige justeringer kan forbedre presisjonen til kvantitative metoder hvis den kvantitative metoden er mangelfull i estimeringen av

tidsseriedataen eller at prognossetteren har relevant førstehåndskunnskap. Som analysen viser er estimeringen av tidsseriedataen mangelfull, og en skjønnsmessig justering av prognosen vil dermed være aktuelt. Justeringen kan skje på bakgrunn av førstehåndskunnskap som produktkunnskap, kampanjer, distribusjon eller konkurrentkunnskap. Dette støttes av Edmund, Lawrence & O'Connor (1988) som konkluderer med at nærmere produktkunnskap er en stor bidragsyter til presisjonen på prognosene. Denne førstehåndskunnskapen ligger gjerne hos ekspertene i ulike avdelinger i selskapet, som marked, logistikk, økonomi og innkjøp.

Hvis prognosene er en kombinasjon av kvantitative metoder og justeringer basert på skjønnsmessige vurderinger, må brukerne av prognosene forstå hvordan de kvantitative modellene fungerer, før de gjøre sine justeringer (Mahmoud, 1984). Dersom Flust skal kombinere metodene, er det da fortsatt viktig at de som er involvert i prognoseprosessen forstår hvordan den eller de aktuelle kvantitative metodene fungerer.

Flust har en innkjøper for hver kategori, og det vil være fordelaktig at disse mottar informasjon fra andre eksperter i selskapet som kan påvirke prognosen, som for eksempel marked, logistikk og økonomi. En av de vanligste kvalitative metodene er å oppnå konsensus mellom de ulike ekspertene i virksomheten. Dette kan gjøres på ulike måter der målet ofte er å skape rutiner og struktur i samtalene for å nå konsensus om fremtidige prognoser (Archer, 1980).

En slik metode er delphi-metoden, som bruker innspill fra eksperter for å lage prognoser. Formålet med denne metoden er altså å forene individuelle meninger til en gradvis felles oppfatning som man kan bygge beslutninger på uten at sterke personligheter dominerer undersøkelsen (Mentzer & Moon, 2005). Delphi-metoden krever mye forarbeid og er tidkrevende (Archer, 1980). Med tanke på det store vareutvalget til Flust, samt begrenset med menneskelige ressurser, vil denne metoden trolig bli for tidkrevende.

5.2 Hvordan vil resultatene påvirke Flust

Det viktigste å trekke frem i fra analysen er det store innslaget av støy i tidsseriedataene. På bakgrunn av dette fikk alle prognosemetodene vi testet store prognosefeil. For bilstoler totalt avviker den optimale prognosemetoden med et gjennomsnitt på 20 bilstoler per måned, Dette er høyt ettersom gjennomsnittlig salg

er 91 bilstoler per måned. For Flust vil dette medføre at det blir utfordrende å utføre gode prognoser. Som kjent så kan mangel på prognoser føre til høye lagerkostnader ved for store innkjøp, eller tap av salgsinntekter ved for små innkjøp. Dette er derimot ikke så ulikt situasjonen i dag, der Flust beregner innkjøpene sine på bakgrunn av erfaringer, intuisjoner og tidligere salgsdata. Det er i dag utfordrende for Flust å hente ut salgsdata tilbake i tid, de baserer derfor innkjøpene på forrige måneds salgs- og innkjøpstall.

Hvordan disse resultatene kan overføres til andre produkter, er avhengig av hvordan salgsdataen ser ut. Vi testet metodene på en rekke produkter innen kategorien bilstoler, og tendensen var at det var stort innslag av støy. Videre testet vi, for å sammenligne, 15-20 andre produkter innen kategorien *barn & baby*, og fant også her samme tendensen med stort innslag av støy. Prognoser på bakgrunn av tidsseriedata er effektive hvis vi har gode og stabile salgsdata. Dette har ikke vært tilfelle på de produktene vi har testet, derav de store prognosefeilene. Dette gjelder produktene innenfor kategorien barn & baby og andre produkter som har store innslag av støy i salgsdataen.

Ledetiden for bilstoler er ca. 14 dager, dette betyr at Flust må ta hensyn til etterspørselen i løpet av 14 dager når de beregner sitt optimale bestillingspunkt (re-order point) og sikkerhetslaget. På bakgrunn av resultatene i analysen, med store avvik fra måned til måned, må sikkerhetslageret være betydelige dersom Flust skal opprettholde en høy servicegrad og unngå tomt-situasjoner.

5.3 Begrensninger

Ved utarbeidelsen av denne rapporten kan vi slå fast at oppgaven møter på noen begrensninger når det gjelder å løse problemstillingen på en optimal måte. Når vi har beregnet etterspørselen har vi brukt historiske salgsdata som grunnlag. Salgsdata viser ikke nødvendigvis den eksakte etterspørselen da årsaker som kampanjer, tilbud eller tomme lager kan påvirke salgstallene. Videre så har vi ingen informasjon om andre faktorer som kan påvirke salgstallene. Dette kan for eksempel være forbrukertester, som kan gi store oppsving i salgstallene, hvis et produkt kommer meget bra ut.

En av utfordringen ved salgsdataene er at enkelte av bilstolene kun har vært solgt i en kort periode. Andre bilstoler varierer også veldig i salgstallene fra måned til måned.

Videre har vi fått tildelt datamaterialet som strekker seg tilbake til januar 2013. Dette gjør det utfordrende å oppdage sesongvariasjoner, da vi kun har to år å sammenligne med. Men da de fleste produktene til Flust har en relativ kort livssyklus, har det vært vanskelig å oppdrive salgstall som strekker seg flere år tilbake. Kun 11 av 40 bilstoler har vært i sortimentet til Flust gjennom hele perioden vi har analysert. Chopra og Sodhi (2004) skriver at produkter med kort livssyklus øker prognoserisikoen.

Hovedfokuset i oppgaven har vært å analysere kvantitative prognosemetoder. Det ville vært for tidskrevende både for oss og for Flust å utføre forsøk og analyse av kvalitative prognosemetoder.

5.4 Konklusjon

Resultatene fra vår analyse viser at tidsseriedataen i stor grad er hvit støy ettersom det er lite signifikant korrelasjon mellom de ulike verdiene i tidsserien. Alle metodene vi testet i analysen ga store prognosefeil, gjennomsnittlig avvik på prognoser for bilstoler totalt var 20 stoler per måned, mot et gjennomsnittlig salg på 91 bilstoler. Vi kan derfor ikke anbefale å lage prognoser kun basert på kvantitative metoder. Allikevel kan gjennomsnittsmetoden og enkel eksponentiell glatting brukes som et hjelpemiddel til beslutninger rundt prognoser og fremtidig etterspørsel. Enkel eksponentiell glatting ga lavest MSE i 11 av de 16 analysene, og vil dermed være den kvantitative metoden som egner seg best.

Men med tanke på en effektiv implementering så vil ARIMA-modellene være lite egnet. Først og fremst fordi ARIMA-prosessen er komplisert og tar tid å lære for de ansatte hos Flust. I tillegg har Flust mellom 6000-7000 produktlinjer, og det vil være umulig å rekke gjennom alle disse produktene ved å anvende en ARIMA-prosess. Vi vil derfor ikke anbefale denne metoden.

Derimot vil det være mulig å implementere de noe enklere gjennomsnitt- og eksponentiell glattingsmodellene på en tilfredsstillende måte. Vi mener det er viktig for Flust å fortsette å bruke intuisjonen og førstehåndkunnskapen de ansatte i bedriften sitter med som beslutningsgrunnlag for prognoser og innkjøp. Dermed vil vi anbefale Flust å kombinere den kvantitative prognosemetoden, enkel eksponentiell glatting, med skjønnsmessige vurderinger.

6 Litteraturliste

Archer, Brian H. (1980). Forecasting Demand: Quantitative and Intuitive Techniques.. *International Journal of Tourism Management*, vol. 1, no. 1, March 1980, pp. 5-12.

Ballou Ronald H. (2004), *Business Logistics / Supply Chain Management*. Prentice Hall: Pearson Education International, New Jersey

Barren, M. og Targett, D. (1985). *The Manager's Guide to Business Forecasting. How to understand and use forecasts for better business results*. Oxford, Basil Blackwell Ltd.

Carbone, R., & Gorr, W. (1985). Accuracy of judgmental forecasting of time series. *Decision Sciences*, 16, 153 – 160.

Carlberg, C. (2012). *Predictive analytics: Microsoft Excel*. Indianapolis, Ind.: Que ;.

Chopra, S., & Meindl, P. (2007). *Supply chain management: Strategy, planning, and operation* (3rd ed.). Upper Saddle River, N.J.: Pearson Prentice Hall.

Chopra, S. & Sodhi, M. S. (2004). Managing Risk To Avoid Supply-Chain Breakdown. *MIT Sloan Management Review*. 46(1), 53-61.

Creswell, J.W.(2009). *Research design: qualitative, quantitativ, and mixed methods approaches*. Los Angeles, SAGE:

Edmundson, R., Lawrence, M., & O'Connor, M. (1988). The use of non time series information in sales forecasting: A case study. *Journal of Forecasting*, 7, 201 – 211.

Hanke, J., & Wichern, D. (2009). *Business forecasting* (9th ed.). London: Pearson Prentice Hall.

Hogarth, R., & Makridakis, S. (n.d.). Forecasting and Planning: An Evaluation. *Management Science*, 115-138

Katchova, A. (2013). Time Series ARIMA Models. EconometricsAcademy. Hentet fra: <https://www.youtube.com/watch?v=Y2khrpVo6qI>

Lawrence, M., Edmundson, R., & O'Connor, M. (1985). An examination of the accuracy of judgmental extrapolation of time series. *International Journal of Forecasting*, 1, 25 – 35.

Lawrence, M., & Makridakis, S. (1989). Factors affecting judgmental forecasts and confidence intervals. *Organizational Behavior and Human Decision Processes*, 43, 172 – 187

Linstone, H. (1975). *The Delphi method: Techniques and applications*. Reading, Mass.: Addison-Wesley Pub., Advanced Book Program.

Mahmoud, E. (n.d.). Accuracy in forecasting: A survey. *Journal of Forecasting*, 139-159.

Makridakis, S., Wheelwright S. C. and Hyndman, R. J. (1998). *Forecasting: Methods and Applications*. New York, Wiley.

McHugh, A. K. and Sparkes, J. R. (1983). The Forecasting Dilemma. *Management Accounting*. 61, 30-34.

Mentzer, John T. and Mark A. Moon (2005), "Sales Forecasting Management: A Demand Management Approach," Thousand Oaks, CA: Sage Publications, Inc.

Moon, M. (2013). *Demand and supply integration: The key to world-class demand forecasting*. New Jersey: FT Press.

Moore, T. (1989). *Handbook of business forecasting*. New York: Harper & Row.

Rowe, G., & Wright, G. (n.d.). The Delphi technique as a forecasting tool: Issues and analysis. *International Journal of Forecasting*, 353-375.

Snizek, J. A. (1989). An examination of group process in judgmental forecasting. *International Journal of Forecasting*, 5(2), 171 – 178.

Snizek, J. A. (1990). A comparison of techniques for judgmental forecasting by groups with common information. *Group & Organization Studies*, 15(1), 5 – 20

Wheelwright, S., & Makridakis, S. (1989). *Forecasting methods for management* (5th ed.). New York: Wiley.

Willemain, T. R. (1989). Graphical adjustment of statistical forecasts. *International Journal of Forecasting*, 5, 179 – 185.

Willemain, T. R. (1991). The effect of graphical adjustment on forecast accuracy. *International Journal*

Yin, Robert K. (1994), “Case Study Research: Design and Methods,” second edition, Sage Publications: Thousand Oaks, CA.



Norges miljø- og
biovitenskapelige
universitet

Postboks 5003
NO-1432 Ås
67 23 00 00
www.nmbu.no