

PROGNOSMETODER

KJELL CASENBERG
ERIK SANDBERG

RE-139 april 1974
Inst.för Reglerteknik
Lunds Tekniska Högskola

PROGNOSMETODER

Examensarbete vid Institutionen för Reglerteknik
vid Lunds Tekniska Högskola.

Författare:

Kjell Casenberg

Erik Sandberg

Handledare:

Jan Holst

Absract.

In this master thesis we have studied five different prediction methods on three different dataseries in order to get some insight into the properties of the different methods.

The best forecasting results are given by methods which are adaptive and which take into consideration special a priori features e.g. trends in the data, such as general exponential smoothing and the heuristic method.

Sammanfattning.

I detta examensarbete har vi studerat fem olika prediktionsmetoder på tre olika dataserier, för att få en inblick i de olika metodernas egenskaper.

De bästa prediktionsresultaten ges av metoder som är adaptiva och som tar hänsyn till speciella apriori drag t.ex. trender, såsom generell exponentiell utjämning och heuristiska metoden.

INNEHÄLLSFÖRTECKNING

1.	INLEDNING	1
2.	LITTERATURSTUDIER	2
3.	METODEBESKRIVNING	4
3.1.	Heuristisk metod	4
3.2.	Glidande medelvärde	5
3.3.	Generell exponentiell utjämning	6
3.3.1.	Enkel exponentiell utjämning	12
3.4.	Minimalvariansprediktion	13
	3.4.1. Minimalvariansprediktion med kända delen från dragen	14
4.	PRESENTATION AV DATA	15
4.1.	Genererade data	15
4.1.1.	Trenddata (DAT1)	15
4.1.2.	Svängningsdata (DAT2)	15
4.2.	Verkliga data	18
4.2.1.	Företagsdata	18
4.2.2.	Flygdata	18
4.2.3.	Skogsdata	18
5.	PREDIKTIONSRESULTAT MED HEURISTISK METOD	25
5.1.	Flygdata	25
5.2.	Företagsdata	39
5.3.	Kommentar till heuristiska metoden	51
6.	VAL AV METOD ATT VÄLJA A-PARAMETRAR TILL GENERELL EXPONENTIELL UTJÄMNING	52
6.1.	Trenddata	52
6.2.	Svängningsdata	56
6.3.	Metod för att bestämma parametrar i modellen	60
7.	PREDIKTIONSRESULTAT MED GENERELL EXPONENTIELL UTJÄMNING	70
7.1.	Företagsdata	70
7.1.1.	Okorrigerade företagsdata	70
7.1.2.	Korrigerade företagsdata	81
7.1.3.	Problem med generell exponentiell utjämning på företagsdata	83
7.2.	Flygdata	90
7.3.	Skogdata	100

8.	PREDIKTIONSRESULTAT MED MINIMALVARIANS-PREDIKTION DÅ KÄND DEL ÄR FRÅNDRAGEN	107
8.1.	Flygdata	107
8.2.	Test av hur komplex den kända delen skall vara	114
9.	SAMMANFATTNING AV PREDIKTIONSRESULTATET FÖR DE OLIKA DATASERIerna	131
9.1.	Företagsdata	131
9.2.	Flygdata	133
9.3.	Skogsdata	135
9.4.	Kommentar	136
	REFERENSER	

APPENDIX A1 - A7 PROGRAMLISTNINGAR

Appendix A1	GENE
Appendix A2	MINKO
Appendix A3	ALBER
Appendix A4	GEXP
Appendix A5	SKATT
Appendix A6	RITA
Appendix A7	MLDAT
Appendix A8	Sammanfattning av ML-metoden

1. INLEDNING

När man skall bestämma sina handlingsalternativ inför framtiden, vill man ha en uppfattning om hur denna **framtid ser ut.** För detta används prognoser.

Allmänt kan sägas att prognoser skall avvika så lite ifrån det verkliga utfallet, att kostnaden för en ytterligare förfining av prognosmetoden ej skulle uppvägas av kostnadsbesparingarna p.g.a. höjningen av precisionen. För en prognosmetod kan följande villkor uppställas:

1. Stabilitet gentemot icke **modellerade slumpfluktuationer.**
2. Snabbt svar på systematiska förändringar.
3. Litet prognosfel.
4. Dåg prognoskostnad.

Liksom de flesta målsättningar är dessa stridande mot varandra, ty t.ex. snabbt reagerande prognosmetoder reagerar **även** för slumpfluktuationer. Det bästa sättet att finna en lämplig avvägning av de fyra kriterierna, är en testning av olika metoder på historiska data. Ett problem är att ta hänsyn till systematiska variationer såsom **konjunktur- och säsongsvariationer.**

Målet med vårt examensarbete var att bestämma lämpliga prognosmetoder för tre dataserier med olika utseende.

Examensarbetet är en fortsättning på den obligatoriska uppgiften, som ingår i Systemteknik vid institutionen för Reglerteknik vid Lunds Tekniska Högskola / 2 /.

Uppläggningen av redovisningen är följande:

Först ges en kortfattad redovisning av litteraturstudier. I kapitel 3 redovisas olika prognosmetoder och därefter följer i kapitel 4 en presentation av de olika dataserierna vi använt. De olika prognosmetoderna testas i kapitel 5 - 8. Därefter följer resultatsammanställning.

Den numeriska undersöningen har huvudsakligen utförts med hjälp av datorerna UNIVAC-1108, vid Lunds Datacentral, och PDP-15, vid institutionen för Reglerteknik vid Lunds Tekniska Högskola.

2. LITTERATURSTUDIER

Avsikten med litteraturstudierna var att få en överblick av de prognosmetoder som finns och att för oss finna nya prognosmetoder, som vi kunde ha användning för.

Härvid genomgicks större delen av följande publikationer publicerade under tiden januari 1971 - mars 1973:

1. IEEE Transactions on Education.
2. IEEE Transactions on Ind. Applications.
3. IEEE Transactions on Automatic Control.
4. IEEE Transactions on Information Theory.
5. Automatica (IFAC).
6. International Journal of Control.
7. Automation and Remote Control.
8. Computer and Control Abstracts.

Följande artiklar ansågs intressanta:

A. "Quantitative Expert Estimation (QEE) in Short-Range Prediction".

(Ur 7,15 jan. 1973).

En metod som korrigeras prognoser gjorda av experter mot deras tidigare skatningar och det verkliga utfallet.

B. "Real Time Recursive Prediction of River Flows".

(Ur 5, mars 1973).

I stort sett minimalvarians prediktion för prognostisering av översvämningar hos floder.

C. "An Iterative Linear Prediction Method".

(Ur 8, 1971:224).

Publiserat av Z. Angew. Math. U. Mech. (Germany), vol. 50, n:o 8, p. 445-54 (aug. 1970).

Den asymptotiska konvergensen av den optimala linjära prediktorn undersöks, där prediktorn är en linjär kombination av observerade värden.

D. "A Survey of Statistical Forecasting Techniques with Empirical Comparisons".

(Ur 8, 1971:15688).

Redovisning av Colloquim on statistical model building, prediction and control, London, England, 30 April 1971.
En överblick av olika metoder för prediktion.

Av metoderna i ovanstående artiklar har endast minimalvarians prediktion studerats och teorin till detta har tagits från K. J. Åströms bok "Introduction to Stochastic Control Theory / 3 /".

Detta är en handskriven text.

3. METODBESKRIVNING

3.1 Heuristisk metod

Om historiska data uppvisar säsongsmässiga likheter från år, kan en av nedanstående redovisade metoder användas.

1. Metoden bygger på att en månads andel av säsongsvärdet (års- värde) antages ej förändras från aktuell tidpunkt till predikterad tidpunkt. Säsongsvärdet predikteras med enkel exponentiell utjämning, som därefter **multipliceras** med andelen av säsongsvärdet för att få aktuell prediktion.
Eventuell trend fråndrages, men inget värde får därvid bli negativt. Om detta skulle vara fallet kan till alla data en konstant term adderas, som efter prediktionen dras ifrån.

2. Denna metod tillgår på samma sätt som ovanstående metod, men trenden dras ej ifrån.

Metoden enligt punkt 1 har använts för att prediktera Flygdata och metoden enligt punkt 2 för Företagsdata.

Då den heuristiska metoden behöver värdet över en säsong för att göra en prediktion, är första predikterade värdet säsongens längd plus prediktionsstegets längd.

Utseendet av dataprogrammet SKATT framgår av appendix A5.

3.2 Glidande medelvärde

Glidande medelvärde är en metod som kan användas då efterfrågan är jämn. För att erhålla värdet för nästkommande period, tar man medelvärdet av ett antal perioder just före den period man önskar prediktera. Om man sätter P_i till predikterat värde, där i beteckar tidpunkten, och låter S_i utgöra de gamla periodernas värden, erhåller man den önskade prediktionen genom formeln:

$$P_{i+k} = \frac{S_i + S_{i-1} + \dots + S_{i-N+1}}{N}$$

där N betecknar antalet medtagna värden.

Metoden är ganska trög och tar inte hänsyn till regelbundna variationer. En ytterligare nackdel med metoden är att ingen viktning av de gamla värdena sker.

Utförligare beskrivning av metoden finns i 2/.

Data härrörande från denna metod är framtagna vid projektarbetet / 2/.

3.3 Generell exponentiell utjämning

Antag att våra data kan beskrivas som en linjär kombination av en serie funktioner, $f_i(t)$, härefter kallade anpassningsfunktioner. Vi antar att de kan representeras med följande modell:

$$\begin{aligned}x(t) &= a_1 \cdot f_1(t) + a_2 \cdot f_2(t) + \dots + a_n \cdot f_n(t) + e(t) = \\&= \sum_{i=1}^n a_i \cdot f_i(t) + e(t)\end{aligned}$$

där $e(t)$ är en normalfördelad stokastisk process med medelvärdet noll.

Om man inte känner a -parametrarna kan man skatta dessa rekursivt och får dem då som funktioner av tiden. Prediktionen blir då

$$\begin{aligned}\hat{x}(t + \tau) &= \hat{a}_1(t) \cdot f_1(t + \tau) + \hat{a}_2(t) \cdot f_2(t + \tau) + \dots + \\&+ \hat{a}_n(t) \cdot f_n(t + \tau) = \sum_{i=1}^n \hat{a}_i(t) f_i(t + \tau)\end{aligned}$$

Bestämning av a -parametrarna, $\hat{a}_i(t)$, gör vi genom att minimera funktionen (Jämför Minsta Kvadrat Minimering):

$$\sum_{j=1}^t \beta^i \cdot (x(t - j) - \sum_{i=1}^n \hat{a}_i(t) \cdot f_i(t - j))^2$$

Detta förfaringsätt fodrar att en mängd data, och en mängd uppsättningar anpassningsfunktioner, $f_i(t)$, måste lagras. För att komma ifrån detta är man intresserad av anpassningsfunktioner som kan translateras i tiden.

Vektorn av sådana anpassningsfunktionsvärden måste kunna anges som en linjär kombination av värden för samma funktioner vid den tidigare tidpunkten t .

Detta betyder att det finns en uppsättning koeficienter L_{ij} som inte berojer av tiden, sådan att

$$\begin{aligned}f_1(t + 1) &= L_{11} \cdot f_1(t) + L_{12} \cdot f_2(t) + \dots + L_{1n} \cdot f_n(t) \\f_2(t + 1) &= L_{21} \cdot f_1(t) + L_{22} \cdot f_2(t) + \dots + L_{2n} \cdot f_n(t) \\&\quad \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \\&\quad \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \\f_n(t + 1) &= L_{n1} \cdot f_1(t) + L_{n2} \cdot f_2(t) + \dots + L_{nn} \cdot f_n(t)\end{aligned}$$

Vi skall representera dessa koefficienter med transformationsmatrisen L , så att $f(t+1) = L \cdot f(t)$. Transformationsmatrisen L är i allmänhet inte symmetrisk, men den måste ha en invers L^{-1} . Den enda uppsättningen av funktioner för vilken en sådan transformationsmatris existerar är polynom-, exponential- och trigonometriska funktioner. Dessa funktioner är lösningar till linjära differensekvationer.

Dessa transformationsmatriser kan bestämmas efter undersökning av typen av funktioner som används i modellen. I samband med transformationsmatrisen behöver vi också specificera anpassningsfunktionernas värde vid tiden $t = 0$: $f(0)$. Från en vektor och matrisen kan vi erhålla funktionens värde, vid vilken tidpunkt som helst, $f(t) = L^t \cdot f(0)$.

För olika funktionstyper finns L -matrisen redovisad i / 1 / på sidorna 165 - 168.

Härledning av generell exponentiell utjämning med fix transformationsmatris. (Ur / 1 /)

En sekvens av observationer $\{x(t)\} = (x(1), x(2), \dots, x(t))$ fås från någon process $\xi(t)$ påverkad av ett brus $e(t)$, $x(t) = \xi(t) + e(t)$. Processen kan beskrivas lokalt av

$$\xi(t+\tau) = \hat{a}^T(t) f(\tau)$$

där vi känner

$$f(\tau) = \begin{bmatrix} f_1(\tau) \\ f_2(\tau) \\ \vdots \\ \vdots \\ f_n(\tau) \end{bmatrix}$$

Problemet är att skatta parametrarna $a(t)$, vilka förändras genom $a(t) = L^T a(t-1)$ och dessutom förändras de med små slumpvisa beroenden efter hand. Därför är vid någon tid kvadratfelet viktat och koefficienterna, $a(t)$, beräknas för att minimera

$$\sum_{j=0}^t \beta^j \cdot (\underbrace{x(t-j)}_{\text{utfallet}} - \underbrace{a^T(t) \cdot f(-j)}_{\text{prediktionen}})^2$$

β = viktfaktor

Lösning av detta problem innehåller en matris av viktade anpassningsfunktioner.

$$F(t) = \sum_{j=0}^t \beta^j \cdot f(-j) \cdot f^T(-j) = F(t-1) + \beta^t \cdot f(-t) \cdot f^T(-t)$$

och en datavektor

$$g(t) = \sum_{j=0}^t \beta^j \cdot x(t-j) \cdot f(-j) = x(t) \cdot f(0) + \beta^{-1} \cdot g(t-1) \quad (1)$$

där L är transformationsmatrisen som genererar succesiva värden av anpassningsfunktionerna, $f(t) = L \cdot f(t-1)$. Minimum av summan av viktade kvadratfelet erhålls när

$$F(t) \cdot \hat{a}(t) = g(t) \quad (2)$$

och eftersom alla "hyggliga" uppsättningar av viktade anpassningsfunktioner, $F(t)$, har en invers $F^{-1}(t)$ är parametrarna

$$\hat{a}(t) = F^{-1}(t) \cdot g(t)$$

Om anpassningsfunktionerna inte avklingar för snabbt

$$f_i(t) < \beta^{-t/2}$$

når matrisen F ett stabilt tillstånd

$$F = F(\infty) = \sum_{j=0}^{\infty} \beta^j \cdot f(-j) \cdot f^T(-j)$$

Genom att kombinera ekvationerna 1 och 2 fås

$$F(t) \cdot \hat{a}(t) = x(t) \cdot f(0) + \beta^{-1} \cdot F(t-1) \cdot \hat{a}(t-1)$$

men då $F(t)$ nått stabilt tillstånd $F(\infty) = F$ erhålls

$$F \cdot \hat{a}(t) = x(t) \cdot f(0) + \beta^{-1} \cdot F \cdot \hat{a}(t-1)$$

Multiplicera från vänster med inversen F^{-1}

$$\hat{a}(t) = x(t) \cdot F^{-1} \cdot f(0) + \beta^{-1} \cdot F^{-1} \cdot L^{-1} \cdot F \cdot \hat{a}(t-1)$$

där $F^{-1} \cdot f(0) = h$ och $F^{-1} \cdot L^{-1} \cdot F = H$ ej beror av tiden. Då kan ekvationen skrivas

$$\hat{a}(t) = h \cdot x(t) + H \cdot \hat{a}(t-1)$$

Sålunda definieras de aktuella värdena av parametrarna i termer

av en vektor h , av konstanter som inte beror av tiden, multiplicerat med den aktuella observationen och en matris H , som inte heller beror av tiden, multiplicerat med den senaste vektorn av parametrar. Vi skall visa att

$$H = L^T - h \cdot f^T(t)$$

Angrip först matrisen $L^{-1} \cdot F$. Multiplicera definitionen av F -matrisen från höger med $L^{-1} \cdot L^T$.

$$\begin{aligned} L^{-1} \cdot F \cdot L^{T-1} \cdot L^T &= \sum_{j=0}^{\infty} p_j \cdot (L^{-1} \cdot f(-j)) \cdot (L^{-1} \cdot f(-j))^T \cdot L^T = \\ &= \frac{1}{B} (F - f(0) \cdot f^T(0)) \cdot L^T \end{aligned}$$

Eftersom

$$H = B \cdot F^{-1} \cdot L^{-1} \cdot F = (I - F^{-1} \cdot f(0) \cdot f^T(0)) \cdot L^T$$

men vi definierade vektorn $h = F^{-1} \cdot f(0)$ så

$$H = L^T - h \cdot (L \cdot f(0))^T = L^T - h \cdot f^T(1)$$

Nu kan vi skriva

$$\hat{a}(t) = h \cdot x(t) + H \cdot \hat{a}(t-1) = h \cdot x(t) + L^T \cdot \hat{a}(t-1) - h \cdot f^T(1) \cdot \hat{a}(t-1)$$

Men eftersom $f^T(1) \cdot \hat{a}(t-1) = \hat{x}_1(t-1)$ är prediktionen av vad observationen vid tiden t skulle vara, om den grundades på data vid tiden $t-1$ är

$$\hat{a}(t) = L^T \cdot \hat{a}(t-1) + h \cdot (x(t) - \hat{x}_1(t-1))$$

Ekvationen visar att parametrarna förändras vid varje samplings-intervall beroende av 1) förändringar i tiden och 2) fel i skattningen av vad nästa observation kommer att bli.

Således blir prediktionen,

$$\hat{x}(t) = \hat{a}^T(t) \cdot f(t)$$

Tillvägagångssätt vid prediktering med generell exponentiell utjämning.

För att klara av uppdateringen av a-parametrarna och för att göra prediktionen har vi skrivit ett dataprogram. Detta program har kallats GEXP (Se Appendix A4). I detta program fodras ett antal speciella ingångsparametrar, L-matrissen, $\hat{a}(t)$:s startvärden och de fixa anpassningsfunktionerna f. Därför har vi gått tillväga på följande sätt.

A. För att identifiera några av de fix anpassningsfunktioerna söker man efter eventuell trend i historiska data. Detta kan ske med hjälp av programmet IDPAC / 2 /. Denna trend kan vara av varierande ordning. Antalet anpassningsfunktioner som trenden bidrar med är lika med trendens ordning. Om ordningen är ett

blir $f_1(t) = 1$ och om ordningen är två blir $f_1(t) = 1$ och $f_2(t) = t$ o.s.v..

B. Då trenden enligt A är fråndragen kan vissa systematiska variationer återstå t.ex. periodicitet. För att få en fingervisning om periodens eller periodernas längd beräknas kovariansfunktionen för residualerna m.h.a. RESID i IDPAC / 2 /. Om periodens längd skulle vara 12 månader skall f-vektorn utökas med $f_i(t) = \sin(2\pi t/12)$ och $f_{i+1}(t) = \cos(2\pi t/12)$. Om flera perioder förekommer läggs dessa till på samma sätt som ovan.

C. Startvärdena för parametrarna $a(t)$ kan väljas på olika sätt.

T.ex. kan

1) Vid prediktering av genererade data för att bestämma hur vi skall välja a-parametrarna till GEXP. Antalet parametrar väljs lika med antalet anpassningsfunktioner i f-vektorn, bestämda under punkt A -

a) — och deras värden väljs så att funktionen $\sum_{j=0}^t (x(j) - a^T f(j))^2$ minimeras. Detta görs m.h.a. programmet MINKO (Se Appendix A2).

b) — och deras värden sättes lika med noll.

c) — minus ett och deras värden enligt a).

- d) — minus ett och deras värden sättes lika med noll.
- e) — plus ett och deras värden enligt a) och den tillagda parametern sättes lika med noll.
- f) — plus ett och deras värden sättes lika med noll.

Då a-parametrarna minskas med en innebär detta att den mest komplexa parametern tas bort. Detta betyder att om endast en trend förekommer så tas termen med högst ordning bort, men om svängningar ingår så försvinner den sist redovisade svängningen, d.v.s. både sinus- och cosinustermen för denna svängning tas ej med.

Då a-parametrarna ökas med en betyder detta, om endast en trend förekommer så läggs en term till vars komplexitet är av näst högre ordning. (t.ex. om anpassningsfunktionen har utseendet $f_1(t) = 1$, $f_2(t) = t$ och $f_3(t) = t \cdot (t - 1)/2$ så har den tillagda termen utseendet $f_4(t) = t \cdot (t - 1) \cdot (t - 2)/2 \cdot 3$), om även svängningar ingår så får de nya termerna en svängningsperiod som är dubbelt så stor som den sist medtagna svängningen (t.ex. om anpassningsfunktionerna har utseendet $f_1(t) = 1$, $f_2(t) = t$, $f_3(t) = \sin(2\pi t/12)$ och $f_4(t) = \cos(2\pi t/12)$ så blir de nya termerna $f_5(t) = \sin(2\pi t/24)$ och $f_6(t) = \cos(2\pi t/24)$).

- 2) Vid prediktering av Företagsdata, Flygdata och Skogsdata väljes a-parametrarna enligt (Se kap. 6).

D. Den vektor, f , av anpassningsfunktioner som tagits fram i A och B bestämmer transformationsmatrisen L:s utseende. Om f-vektorn har n komponenter blir L-matrissens storlek $n \times n$. L-matrissens utseende för olika anpassningsfunktioner framgår i / 1 / sidorna 165 – 168.

E. För att kunna läsa in data, L-matrissen och a-parametrarna i programmet GEXP måste de omstruktureras. Detta görs m.h.a. programmet ALBER (Se Appendix A3).

F. Valet av utjämningsfaktorn, β , sker genom simulerings på histiskra data ($0 \leq \beta \leq 1$).

3.3.1 Enkel exponentiell utjämning

En förenklad form av generell exponentiell utjämning är enkel exponentiell utjämning.

Om prediktionen för tiden i blev P_i men det verkliga utfallet S_i så får prognosfelet $\Delta_i = S_i - P_i$. Till skillnad från glidande medelvärde vill man med denna metod ta hänsyn till prognosfelet vid nästkommande prediktion. Prognosens blir för nästa period

$$P_{i+1} = P_i + \alpha \cdot \Delta_i = P_i + \alpha(S_i - P_i) = \alpha S_i + (1 - \alpha) P_i$$

α kallas utjämningskoefficient ($0 \leq \alpha \leq 1$) och ett högt värde på α medför detta att senaste uppmätta utfallet viktas högt. Detta medför att modellen blir känslig för variationer både slumpmässiga och systematiska. Ett lågt α medför att gamla uppmätta utfall viktas högt, modellen blir trög.

Det α som skall väljas kan bestämmas genom simulerings på historiska data. / 2 /.

3.4 MINIMALVARIANS PREDIKTION / 3 /

Vid antar att efterfrågestructuren kan beskrivas med en stokastisk process, $y(t)$. En stokastisk process med medelvärde noll kan allmänt beskrivas med funktionssambandet

$$y(t) + a_1 \cdot y(t-1) + \dots + a_n \cdot y(t-n) = \lambda [e(t) + c_1 \cdot e(t-1) + \dots + c_n \cdot e(t-n)] + y_d(t) + a_1 \cdot y_d(t-1) + \dots + a_n \cdot y_d(t-n)$$

där $e(t)$ är oberoende stokastiska variabler,

$y_d(t)$ är en deterministisk funktion.

Detta funktionssamband kan även skrivas

$$\hat{A}^* y(t) = \hat{C}^* e(t) + A y_d(t)$$

$$\text{där } \hat{A}(q^{-1}) = (1 + a_1 q^{-1} + a_2 q^{-2} + \dots + a_n q^{-n}), \\ \hat{C}(q^{-1}) = (1 + c_1 q^{-1} + c_2 q^{-2} + \dots + c_n q^{-n}), \\ q^{-1} = \text{skiftoperator.}$$

$$y(t+k) = \frac{\hat{C}(q^{-1})}{\hat{A}(q^{-1})} \cdot e(t+k) + y_d(t+k) = \lambda [e(t+k) + f_1 e(t+k-1) + \dots + f_{k-1} e(t+1)] + \frac{\hat{G}(q^{-1})}{\hat{C}(q^{-1})} \cdot y(t) + y_d(t+k)$$

$$\text{där } \hat{G}(q^{-1}) = g_0 + g_1 q^{-1} + \dots + g_{n-1} q^{-n+1} \\ \hat{F}(q^{-1}) = 1 + f_1 q^{-1} + \dots + f_{k-1} q^{-k+1} \\ e(t+k) + f_1 e(t+k-1) + \dots + f_{k-1} e(t+1) = \text{prediktionsfelet}, \\ \frac{\hat{G}(q^{-1})}{\hat{C}(q^{-1})} \cdot y(t) + y_d(t+k) = \hat{y}(t+k|t) = \text{den prediktion som minimiserar variansen hos prediktionsfelet.}$$

Polynomen $\hat{F}(q^{-1})$ och $\hat{G}(q^{-1})$ definieras av identiteten

$$\hat{C}(q^{-1}) = \hat{A}(q^{-1}) \cdot \hat{F}_{k-1}(q^{-1}) + q^{-k} \cdot \hat{G}_{n-1}(q^{-1})$$

Den förväntade variansen vid en k-stegsprediktion med denna metod

$$\text{blir: } \lambda^2 \cdot \sum_{i=0}^{i=k-1} f_i^2, \text{ där } f_0 = 1.$$

3.4.1 Minimalvariansprediktion med kända delen fråndragen

Vid minimalvariansprediktion / 3 / fordras det att data fluktuerar kring nollvärdet, för att kunna göra Maximum-Likelihood skattning (Se appendix A8) av parametrarna i modellen. Detta kan ske genom att ta bort trenden.

Även andra kända delar kan dras ifrån data innan skatningen görs.

Vi skall här beskriva ett sätt att eliminera periodiska svängningar i data innan parameterskattningarna görs.

Tillvägagångssätt

A.

1. Modellen antages ha utseendet

$$y(t) = \frac{c(q^{-1})}{A^*(q^{-1})} e(t) + y_d(t)$$

där $y_d(t)$ betecknar en godtycklig deterministisk funktion t.ex. nivå, trend eller trigonometriska funktioner.

2. Nivå och trend identifieras i IDPAC / 5 /.
3. Eventuella frekvenser konstateras m.h.a. RESID i IDPAC / 5 /.
4. Vi har nu erhållit de delfunktioner i funktionen, som genererar data, vilka skall dragas ifrån ursprungsläget.
4. Bestäm hur mycket av varje delfunktion som skall dras av. Detta fårs genom minimering av förlustfunktionen i MINKO (se appendix A2).

B.

1. M.h.a. den erhållna funktionen, genereras i MLDAT (se appendix A7) den serie data, som skall dras ifrån ursprungsläget.
2. Subtrahera denna serie data från ursprungsläget.

C.

1. Minimalvariansprediktion görs på återstoden.
2. Lägg till den tidigare fråndragna deterministiska delen till resultatet av minimalvariansprediktionen.

4. PRESENTATION AV DATA

För att testa de olika prognosprogrammen behövdes data med olika utseende. Därför konstruerade vi ett genereringsprogram, som vi kallade GENE (se appendix A1). Med hjälp av detta program genererade vi data bestående av trend plus brus, DAT1, och sinusformade data plus brus, DAT2. Dessa data användes för att kunna bestämma vilken metod som skulle användas vid val av a-parametrarna till generell exponentiell utjämning (se kapitel 6).

Även verkliga data användes, nämligen Företagsdata, Flygdata och Skogsdata.

4.1 Genererade data

4.1.1 Trenddata (DAT1)

Dessa data har utseendet:

$$y(t) = 10.0 + 0.05 \cdot t + e(t)$$

där

$e(t)$ är brus $\in N(0,1)$,

$y(t)$ är utsignalen,

Tabell 1 visar de 500 trenddata.

4.1.2 Svängningsdata (DAT2)

Dessa data har utseendet:

$$y(t) = 20.0 + 10.0 \sin\left(\frac{2\pi \cdot t}{24}\right) + e(t)$$

där

$e(t)$ är brus $\in N(0,1)$,

$y(t)$ är utsignalen,

Tabell 2 visar de 500 svängningsdata.

	1	2	3	4	5	6	7	8	9	0
1	8.39	9.37	11.44	10.22	10.33	10.41	9.07	10.94	9.65	10.82
11	11.08	10.04	12.35	10.61	11.46	9.52	9.41	9.77	10.21	11.37
21	10.86	9.31	11.35	10.59	10.68	11.22	12.85	12.19	11.87	11.51
31	11.73	9.17	12.44	10.17	10.99	12.52	13.39	12.21	11.62	12.25
41	10.70	12.62	11.63	12.35	12.40	11.41	13.01	14.82	13.47	11.57
51	11.77	13.67	13.91	12.11	13.90	10.90	13.73	12.03	12.41	14.50
61	13.93	12.31	14.29	12.47	14.49	11.98	14.54	13.82	13.44	14.01
71	13.18	15.55	14.76	15.43	13.18	14.65	12.45	14.22	14.56	13.12
81	13.52	14.38	13.32	13.98	13.97	12.92	15.45	14.20	14.78	14.83
91	14.96	12.80	15.98	14.12	13.84	14.78	13.55	14.78	15.10	15.13
101	14.49	15.82	14.73	15.85	15.81	16.23	15.74	13.95	15.50	16.02
111	15.12	14.43	16.57	15.18	14.87	14.28	15.02	16.72	17.01	15.50
121	14.84	14.63	15.51	14.10	18.03	16.92	15.39	16.08	18.60	16.58
131	17.65	15.43	16.54	16.62	16.28	16.16	18.86	15.03	18.29	17.26
141	16.56	15.82	16.67	17.73	18.63	16.98	19.43	15.58	19.07	16.52
151	17.56	17.81	17.89	18.44	18.07	18.41	17.08	17.72	19.95	17.38
161	17.65	18.39	18.20	18.73	18.60	19.42	17.84	19.46	18.92	17.84
171	18.84	17.56	18.61	19.62	19.22	17.03	19.68	18.79	19.98	18.88
181	20.12	18.33	19.11	18.11	19.94	20.24	18.62	18.71	21.14	19.53
191	18.50	20.69	17.71	20.19	19.76	20.04	20.65	20.23	19.39	20.76
201	20.97	20.64	20.40	20.86	20.66	22.43	20.78	21.34	20.73	19.59
211	20.53	20.19	20.18	20.13	21.67	22.41	20.00	22.04	21.17	22.01
221	21.19	21.33	22.05	21.99	20.76	21.99	22.31	19.34	20.70	21.03
231	20.94	20.06	23.02	20.44	21.95	21.17	22.72	22.23	22.33	21.64
241	22.79	22.39	23.09	22.49	20.23	22.93	21.22	22.72	22.05	22.84
251	21.73	22.32	23.24	22.13	23.61	23.29	22.81	22.80	23.86	23.64
261	22.76	24.83	24.50	23.37	21.08	22.25	21.50	23.47	22.77	23.03
271	23.88	22.94	22.84	24.20	23.64	25.79	24.28	23.73	21.77	23.02
281	23.10	25.65	23.28	22.62	25.30	22.94	25.16	22.60	23.87	25.60
291	24.42	23.95	23.81	25.64	24.05	23.67	23.13	25.05	26.05	24.77
301	25.82	24.84	23.44	25.25	25.89	23.00	26.19	28.10	25.34	26.54
311	26.32	26.32	25.16	24.45	25.83	25.92	26.35	26.74	25.71	24.90
321	27.92	25.40	24.97	26.25	25.86	26.44	25.60	25.97	25.18	26.85
331	25.61	27.07	26.88	26.64	26.99	26.55	25.95	25.80	26.75	25.40
341	28.39	27.34	26.88	24.63	29.21	29.25	28.38	26.23	28.40	28.54
351	27.27	26.20	24.97	27.20	28.52	29.55	27.92	27.24	29.15	27.28
361	29.24	28.66	28.16	27.38	28.93	27.44	28.54	25.85	29.00	29.61
371	29.30	26.70	28.44	27.14	28.43	29.93	29.26	28.06	29.94	28.53
381	29.46	29.34	27.82	28.50	30.03	28.01	28.08	27.85	29.97	29.05
391	28.71	29.58	30.29	29.46	30.71	29.68	30.98	31.25	31.10	30.16
401	30.05	30.41	30.85	30.01	30.50	29.95	30.98	29.23	30.32	28.86
411	31.49	30.83	31.51	30.15	29.37	30.81	30.08	30.81	30.63	33.16
421	32.02	32.85	32.26	29.88	33.34	31.26	32.27	29.98	31.04	31.05
431	31.65	31.46	31.11	31.21	31.41	32.31	32.55	32.75	31.54	31.53
441	33.37	33.66	31.04	32.14	30.56	31.95	32.93	31.11	32.13	32.61
451	32.18	30.46	32.08	33.65	32.81	32.19	32.40	34.06	33.82	34.29
461	34.09	31.85	32.20	33.76	34.16	34.02	32.96	33.61	32.60	33.55
471	34.09	31.84	33.42	33.47	34.60	34.44	33.62	32.75	32.48	33.41
481	35.19	34.42	33.74	33.76	35.13	35.46	34.37	34.49	34.45	35.87
491	34.37	34.59	35.14	34.66	35.76	34.07	34.21	33.82	36.51	34.92

Tabell 1. Trenddata

	1	2	3	4	5	6	7	8	9	0
1	20.93	24.27	28.36	28.68	29.74	30.11	28.38	29.20	26.27	25.32
11	23.11	19.44	19.11	14.91	13.64	10.06	8.91	8.87	9.61	11.71
21	12.74	13.21	17.61	19.39	22.02	24.92	28.57	29.46	30.08	30.01
31	29.84	26.23	27.86	23.47	21.83	20.72	18.95	15.31	12.60	11.59
41	9.00	10.52	9.82	11.49	13.08	14.11	18.07	22.42	23.61	24.08
51	26.29	29.73	30.92	29.41	30.81	26.76	27.95	24.13	22.04	21.50
61	18.29	14.21	14.07	10.61	11.59	8.68	11.54	11.76	12.92	15.51
71	17.04	21.95	23.70	26.73	26.50	29.51	28.26	30.32	30.27	27.78
81	26.54	25.28	21.76	19.77	17.13	13.62	14.03	11.14	10.67	10.33
91	10.75	9.54	14.26	14.42	16.50	19.98	21.29	24.88	27.22	28.79
101	29.10	30.72	29.24	29.31	27.63	25.93	22.97	18.55	17.47	15.52
111	12.50	10.17	11.26	9.48	9.47	9.82	12.10	15.82	18.47	19.50
121	21.38	23.53	26.43	26.56	31.44	30.62	28.70	28.34	29.22	25.08
131	23.69	18.83	17.31	14.92	12.46	10.69	12.35	8.13	11.68	11.60
141	12.44	13.72	16.93	20.53	23.97	24.69	29.15	26.84	31.28	29.02
151	29.67	28.87	27.31	25.73	22.90	20.61	16.65	14.82	14.93	10.72
161	9.94	10.29	10.40	11.87	13.28	16.12	16.90	21.06	23.06	24.34
171	27.36	27.62	29.62	30.92	30.13	26.89	27.90	24.89	23.62	19.88
181	18.49	14.22	12.89	10.25	11.03	10.94	9.61	10.65	14.62	15.03
191	16.36	21.09	20.65	25.49	27.08	28.90	30.46	30.33	29.10	29.42
201	27.99	25.54	22.83	20.66	17.82	17.13	13.36	12.28	10.62	9.09
211	10.32	10.93	12.46	14.43	18.33	21.61	21.74	26.14	27.29	29.67
221	29.80	30.23	30.56	29.45	26.58	25.69	23.55	17.94	16.66	14.53
231	12.32	9.80	11.71	8.74	10.54	10.71	13.80	15.33	17.79	19.64
241	23.33	25.30	28.01	28.95	27.64	30.63	28.53	28.98	26.67	25.34
251	21.76	19.72	18.00	14.43	13.78	11.83	10.30	9.90	11.25	11.98
261	12.64	16.73	18.76	20.17	20.42	23.95	25.22	28.73	28.98	29.53
271	29.99	28.00	26.26	25.50	22.48	21.99	17.84	14.83	10.75	10.36
281	9.39	11.55	9.47	9.76	13.98	13.64	18.22	18.20	22.01	26.10
291	26.94	28.01	28.82	30.94	28.96	27.53	25.35	25.15	23.69	19.77
301	18.18	14.74	11.21	11.39	10.98	7.70	11.18	14.04	12.82	16.04
311	18.19	20.72	22.10	23.75	27.15	28.78	30.16	30.84	29.42	27.56
321	28.94	24.30	21.41	20.05	17.02	15.14	12.18	10.91	9.07	10.35
331	9.40	11.82	13.16	14.94	17.65	19.75	21.69	23.90	26.87	27.06
341	31.00	30.24	29.39	26.08	29.03	26.95	23.62	18.82	18.36	16.04
351	12.64	9.94	7.66	9.50	11.11	13.09	13.00	14.34	18.62	19.28
361	23.78	25.56	27.08	27.84	30.34	29.14	29.85	26.11	27.62	26.10
371	23.34	18.10	17.20	13.44	12.61	12.47	10.75	9.16	11.33	10.87
381	13.34	15.25	16.08	19.31	23.37	23.71	25.80	27.12	30.18	29.55
391	28.82	28.64	27.71	24.76	23.55	19.88	18.54	16.34	14.07	11.49
401	10.34	10.31	11.04	11.15	13.18	14.65	18.05	18.83	22.46	23.36
411	28.01	28.89	30.52	29.45	28.28	28.67	26.30	24.91	22.26	22.16
421	18.38	16.75	14.04	10.02	12.43	9.96	11.26	9.92	12.52	14.55
431	17.51	19.86	22.05	24.51	26.73	29.17	30.36	30.85	29.25	28.19
441	28.39	26.56	21.48	19.93	15.72	14.65	13.50	10.05	10.02	10.11
451	9.97	9.20	12.36	15.95	17.48	19.39	22.14	26.17	27.94	29.95
461	30.70	28.75	28.71	29.22	27.98	25.71	22.19	20.21	16.56	15.05
471	13.47	9.58	10.11	9.77	11.19	11.98	12.70	13.86	15.94	19.42
481	23.73	25.32	26.66	28.23	30.54	31.16	29.68	28.75	27.07	26.37
491	22.41	19.99	17.90	14.95	13.93	10.60	9.70	8.92	11.90	11.26

Tabell 2. Svängningsdata

4.2 Verkliga data

4.2.1 Företagsdata

Dessa data visar bruttofaktureringen för ett svenskt företag under åren 1959 - 1972. En fusion ägde rum månad 153 vilket resulterar i ett steg i denna månad. Dessa data ser ut att innehålla en del slumpmässiga variationer. Tabell 3 visar Företagsdata och dess utseende framgår av figur 4.1.

För att undersöka semestermånadernas inverkan på prediktionen, gjordes även testerna på data, där julivärdena sattes lika med junivärdena. Utseendet av korrigrade Företagsdata visas i fig. 4.2.

4.2.2 Flygdata

Dessa data visar antalet passagerare i tusental per månad på internationella flyglinjer under åren 1949 - 1960 / 1 /. Dessa data har även tidigare använts av Brown / 1 / och Gustavsson / 6 /. Tabell 4 visar dessa data och dess utseende framgår av figur 4.3. Av figur 4.3 framgår det att data har starka säsongsvariationer.

4.2.3 Skogsdata

Dessa data utgör omsättningen i miljoner DM i den träberarbtande industrin i Västtyskland under tiden 1958 - 1967 (se tabell 5) / 4 /. Av figur 4.4 framgår det att dessa data innehåller oregelbundenheter, dock ej så starka som Företagsdata, och innehåller även säsongsvariationer, dock ej så kraftiga som Flygdata.

Tabell 3. Bruttofaktureringen för ett svenskt företag under åren 1959 - 1972 (i tusental kronor).

KORREKTAN VÄRDE											
MARS			APRIL			MAJ			JUNI		
JULI		AUG		SEPT		OKT		NOV		DEC	
5358.0	5720.0	6139.0	6562.0	6935.0	7339.0	7742.0	8145.0	8548.0	8951.0	9359.0	9766.0
5722.0	6106.0	6521.0	6927.0	7336.0	7740.0	8149.0	8554.0	8957.0	9360.0	9767.0	10174.0
6705.0	7109.0	7514.0	7921.0	8326.0	8730.0	9135.0	9540.0	9945.0	10350.0	10755.0	11161.0
6875.4	7281.0	7705.0	8174.0	8574.0	8974.0	9374.0	9774.0	10174.0	10571.0	10964.0	11366.0
8925.0	9404.0	9804.0	10204.0	10693.0	11093.0	11493.0	11893.0	12293.0	12693.0	13093.0	13493.0
9044.0	9444.0	9844.0	10244.0	10693.0	11093.0	11493.0	11893.0	12293.0	12693.0	13093.0	13493.0
10106.0	10593.0	11093.0	11493.0	11893.0	12293.0	12693.0	13093.0	13493.0	13893.0	14293.0	14693.0
10871.0	11392.0	11892.0	12392.0	12892.0	13392.0	13892.0	14392.0	14892.0	15392.0	15892.0	16392.0
11069.0	11590.0	12079.0	12579.0	12979.0	13479.0	13979.0	14479.0	14979.0	15479.0	15979.0	16479.0
11987.1	12487.0	12987.0	13487.0	13987.0	14487.0	14987.0	15487.0	15987.0	16487.0	16987.0	17487.0
12079.0	12590.0	13090.0	13590.0	14090.0	14590.0	15090.0	15590.0	16090.0	16590.0	17090.0	17590.0
12097.0	12600.0	13100.0	13600.0	14100.0	14600.0	15100.0	15600.0	16100.0	16600.0	17100.0	17600.0
12162.0	12662.0	13162.0	13662.0	14162.0	14662.0	15162.0	15662.0	16162.0	16662.0	17162.0	17662.0
12162.0	12662.0	13162.0	13662.0	14162.0	14662.0	15162.0	15662.0	16162.0	16662.0	17162.0	17662.0
12262.0	12762.0	13262.0	13762.0	14262.0	14762.0	15262.0	15762.0	16262.0	16762.0	17262.0	17762.0
12362.0	12862.0	13362.0	13862.0	14362.0	14862.0	15362.0	15862.0	16362.0	16862.0	17362.0	17862.0
12462.0	12962.0	13462.0	13962.0	14462.0	14962.0	15462.0	15962.0	16462.0	16962.0	17462.0	17962.0
12562.0	13062.0	13562.0	14062.0	14562.0	15062.0	15562.0	16062.0	16562.0	17062.0	17562.0	18062.0
12662.0	13162.0	13662.0	14162.0	14662.0	15162.0	15662.0	16162.0	16662.0	17162.0	17662.0	18162.0
12762.0	13262.0	13762.0	14262.0	14762.0	15262.0	15762.0	16262.0	16762.0	17262.0	17762.0	18262.0
12862.0	13362.0	13862.0	14362.0	14862.0	15362.0	15862.0	16362.0	16862.0	17362.0	17862.0	18362.0
12962.0	13462.0	13962.0	14462.0	14962.0	15462.0	15962.0	16462.0	16962.0	17462.0	17962.0	18462.0
13062.0	13562.0	14062.0	14562.0	15062.0	15562.0	16062.0	16562.0	17062.0	17562.0	18062.0	18562.0
13162.0	13662.0	14162.0	14662.0	15162.0	15662.0	16162.0	16662.0	17162.0	17662.0	18162.0	18662.0
13262.0	13762.0	14262.0	14762.0	15262.0	15762.0	16262.0	16762.0	17262.0	17762.0	18262.0	18762.0
13362.0	13862.0	14362.0	14862.0	15362.0	15862.0	16362.0	16862.0	17362.0	17862.0	18362.0	18862.0
13462.0	13962.0	14462.0	14962.0	15462.0	15962.0	16462.0	16962.0	17462.0	17962.0	18462.0	18962.0
13562.0	14062.0	14562.0	15062.0	15562.0	16062.0	16562.0	17062.0	17562.0	18062.0	18562.0	19062.0
13662.0	14162.0	14662.0	15162.0	15662.0	16162.0	16662.0	17162.0	17662.0	18162.0	18662.0	19162.0
13762.0	14262.0	14762.0	15262.0	15762.0	16262.0	16762.0	17262.0	17762.0	18262.0	18762.0	19262.0
13862.0	14362.0	14862.0	15362.0	15862.0	16362.0	16862.0	17362.0	17862.0	18362.0	18862.0	19362.0
13962.0	14462.0	14962.0	15462.0	15962.0	16462.0	16962.0	17462.0	17962.0	18462.0	18962.0	19462.0
14062.0	14562.0	15062.0	15562.0	16062.0	16562.0	17062.0	17562.0	18062.0	18562.0	19062.0	19562.0
14162.0	14662.0	15162.0	15662.0	16162.0	16662.0	17162.0	17662.0	18162.0	18662.0	19162.0	19662.0
14262.0	14762.0	15262.0	15762.0	16262.0	16762.0	17262.0	17762.0	18262.0	18762.0	19262.0	19762.0
14362.0	14862.0	15362.0	15862.0	16362.0	16862.0	17362.0	17862.0	18362.0	18862.0	19362.0	19862.0
14462.0	14962.0	15462.0	15962.0	16462.0	16962.0	17462.0	17962.0	18462.0	18962.0	19462.0	19962.0
14562.0	15062.0	15562.0	16062.0	16562.0	17062.0	17562.0	18062.0	18562.0	19062.0	19562.0	20062.0
14662.0	15162.0	15662.0	16162.0	16662.0	17162.0	17662.0	18162.0	18662.0	19162.0	19662.0	20162.0
14762.0	15262.0	15762.0	16262.0	16762.0	17262.0	17762.0	18262.0	18762.0	19262.0	19762.0	20262.0
14862.0	15362.0	15862.0	16362.0	16862.0	17362.0	17862.0	18362.0	18862.0	19362.0	19862.0	20362.0
14962.0	15462.0	15962.0	16462.0	16962.0	17462.0	17962.0	18462.0	18962.0	19462.0	19962.0	20462.0
15062.0	15562.0	16062.0	16562.0	17062.0	17562.0	18062.0	18562.0	19062.0	19562.0	20062.0	20562.0
15162.0	15662.0	16162.0	16662.0	17162.0	17662.0	18162.0	18662.0	19162.0	19662.0	20162.0	20662.0
15262.0	15762.0	16262.0	16762.0	17262.0	17762.0	18262.0	18762.0	19262.0	19762.0	20262.0	20762.0
15362.0	15862.0	16362.0	16862.0	17362.0	17862.0	18362.0	18862.0	19362.0	19862.0	20362.0	20862.0
15462.0	15962.0	16462.0	16962.0	17462.0	17962.0	18462.0	18962.0	19462.0	19962.0	20462.0	20962.0
15562.0	16062.0	16562.0	17062.0	17562.0	18062.0	18562.0	19062.0	19562.0	20062.0	20562.0	21062.0




Fig. 4.1 Bruttofaktureringen för ett svenskt företag under åren
1959 - 1972.




Fig. 4.2 Bruttofaktureringen för ett svenskt företag under åren 1959 - 1972, där det ursprungliga julivärdet har ersatts med junivärdet.




Fig. 4.3 Antalet passagerare i tusental per månad på internationella flyglinjer under åren 1949 - 1960.

Tabell 4. Antalet passagerare i tusental per månad på internationella flyglinjer under åren 1949 - 1960.

Month	1949	1950	1951	1952	1953	1954	1955	1956	1957	1958	1959	1960
Jan.	112	115	145	171	196	204	242	284	315	340	360	417
Feb.	118	126	150	180	196	188	233	277	301	318	342	391
Mar.	132	141	178	193	236	235	267	317	356	362	406	419
Apr.	129	135	163	181	235	227	269	313	348	348	396	461
May	121	125	172	183	229	234	270	318	355	363	420	472
June	135	149	178	218	243	264	315	374	422	435	472	535
July	148	170	199	230	264	302	364	413	465	491	548	622
Aug.	148	170	199	242	272	293	347	405	467	505	559	606
Sept.	136	158	184	209	237	259	312	355	404	404	463	508
Oct.	119	133	162	191	211	229	274	306	347	359	407	461
Nov.	104	114	146	172	180	203	237	271	305	310	362	390
Dec.	118	140	166	194	201	229	278	306	336	337	405	432
Total	1520	1676	2042	2364	2700	2867	3408	3939	4421	4572	5140	5714

* FAA Statistical Handbook of Civil Aviation (several annual issues).

Tabell 5. Omsättningen i miljoner DM i den träbearbetande industrien i Västtyskland under åren 1958 - 1967.

UMSÄTZE IN MILL. DM - HOLZVERARBEITENDE INDUSTRIE - ID. NR. U54

B1. ORIGINAL SERIES

YEAR	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
1958	306.4	295.7	351.6	342.2	341.0	329.8	361.8	338.2	387.8	430.1	403.4	395.5
1959	303.5	302.0	344.5	372.2	337.4	370.9	371.8	371.8	424.0	456.8	457.0	448.6
1960	337.4	344.2	419.6	406.7	427.8	400.5	417.1	432.2	486.0	504.7	521.1	507.6
1961	411.0	401.4	482.4	436.5	456.6	459.1	443.2	456.0	512.0	549.6	562.0	522.0
1962	428.3	430.2	491.8	479.3	533.2	497.3	509.3	521.2	555.5	644.3	632.4	548.1
1963	451.6	410.8	451.7	489.1	536.2	453.3	528.2	510.5	581.0	669.0	618.1	574.3
1964	475.8	494.9	557.0	609.4	540.0	596.7	627.7	532.2	680.4	742.0	728.3	692.9
1965	545.7	583.9	671.1	660.4	660.8	649.5	658.9	617.3	758.9	775.3	787.2	764.3
1966	589.8	610.7	755.2	697.3	727.6	723.9	708.2	646.4	806.3	824.2	824.4	768.5
1967	607.8	601.8	679.3	665.7	637.6	700.4	660.8	615.6	756.7	815.8	813.7	855.1




Fig. 4.4 Omsättningen i miljoner DM i den träbearbetande industrin i Västtyskland under åren 1958 - 1967.

5. PREDIKTIONSRESULTAT MED HEURISTISK METOD

5.1 Flygdata.

Trenden som befanns ha utseendet

$$1.2320 \cdot t + 0.0229 \cdot t \cdot (t - 1)/2$$

drogs ifrån de verkliga flygdata.

Men som framgår av figur 5.1, där de avtrendade flygdata visas, blir några värden negativa och detta medför att prediktionen blir fel. För att undvika detta adderas en konstant term (=50.0) till alla data.




Fig. 5.1 Avtrendade Flygdata.

Beräkningar utfördes för prediktionsstegen 1, 2, 3, 6, 12, 24 och 48. Utjämningskoefficienter, α , som användes vid prediktering av säsongsvärdet, från 0.0 till 1.0 i steg om 0.05 undersöktes. Värdena på medelfel och varians framgår av tabellerna 6 - 12. Minima för medelfel och varians är understrykna.

Figuerna 5.2 - 5.4 visar prediktionen med prediktionsstegen 1, 12 och 48 månader. Som framgår av figurerna prickar prediktionen in variationen bra i tiden, dock ligger den något högt.

Prediktionsfelet för prediktionssteget 1 mån. visas i figur 5.5. Figuren 5.6 visar summa prediktionsfel i kvadrat för prediktionssteget 1.

De branta stigningarna kommer av att vissa perioder avviker från genomsnittet och därfor ger ett stort bidrag till prediktionsfelet. Sådana perioder är t.ex. månaderna 60-65, 88-92, 100-105, 110-120 och 133-135. Detta framgår även i figur 5.5 av de djupa dipparna.

Tabel 6. Varians och medelfel vid 1-stegsprediktion av Flygdata

för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSSTEG= 1	ALFA=0,00	VARIANS=	481,5755005	MEDELFEL=	-3,4969016
PREDIKTIONSSSTEG= 1	ALFA=0,05	VARIANS=	401,6689224	MEDELFEL=	-4,3353434
PREDIKTIONSSSTEG= 1	ALFA=0,10	VARIANS=	370,3140716	MEDELFEL=	-3,0399593
PREDIKTIONSSSTEG= 1	ALFA=0,15	VARIANS=	331,4353027	MEDELFEL=	-2,6796252
PREDIKTIONSSSTEG= 1	ALFA=0,20	VARIANS=	303,9913483	MEDELFEL=	-2,5680990
PREDIKTIONSSSTEG= 1	ALFA=0,25	VARIANS=	285,8089905	MEDELFEL=	-2,5238186
PREDIKTIONSSSTEG= 1	ALFA=0,30	VARIANS=	273,4894028	MEDELFEL=	-2,5042650
PREDIKTIONSSSTEG= 1	ALFA=0,35	VARIANS=	264,8566894	MEDELFEL=	-2,4984514
PREDIKTIONSSSTEG= 1	ALFA=0,40	VARIANS=	258,5951843	MEDELFEL=	-2,5016285
PREDIKTIONSSSTEG= 1	ALFA=0,45	VARIANS=	253,9051094	MEDELFEL=	-2,5104332
PREDIKTIONSSSTEG= 1	ALFA=0,50	VARIANS=	250,2925148	MEDELFEL=	-2,5222650
PREDIKTIONSSSTEG= 1	ALFA=0,55	VARIANS=	247,4447365	MEDELFEL=	-2,5352709
PREDIKTIONSSSTEG= 1	ALFA=0,60	VARIANS=	245,1578407	MEDELFEL=	-2,5482332
PREDIKTIONSSSTEG= 1	ALFA=0,65	VARIANS=	243,2952728	MEDELFEL=	-2,5604472
PREDIKTIONSSSTEG= 1	ALFA=0,70	VARIANS=	241,7630424	MEDELFEL=	-2,5715544
PREDIKTIONSSSTEG= 1	ALFA=0,75	VARIANS=	240,4953537	MEDELFEL=	-2,5814094
PREDIKTIONSSSTEG= 1	ALFA=0,80	VARIANS=	239,4452171	MEDELFEL=	-2,5900132
PREDIKTIONSSSTEG= 1	ALFA=0,85	VARIANS=	238,5785103	MEDELFEL=	-2,5974237
PREDIKTIONSSSTEG= 1	ALFA=0,90	VARIANS=	237,8698349	MEDELFEL=	-2,6037426
PREDIKTIONSSSTEG= 1	ALFA=0,95	VARIANS=	237,2999878	MEDELFEL=	-2,6090899
PREDIKTIONSSSTEG= 1	ALFA=1,00	VARIANS=	266,5587997	MEDELFEL=	-2,7968730

Tabell 7. Varians och medelfel vid 2-stegsprediktion av Flygdata

förf $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG= 2	ALFA=0,00	VARIANS=	451,4224853	MEDELFEL=	-8,2662177
PREDIKTIONSSTEG= 2	ALFA=0,05	VARIANS=	379,7917251	MEDELFEL=	-4,2349410
PREDIKTIONSSTEG= 2	ALFA=0,10	VARIANS=	360,1575928	MEDELFEL=	-2,8567821
PREDIKTIONSSTEG= 2	ALFA=0,15	VARIANS=	326,2444000	MEDELFEL=	-2,4418537
PREDIKTIONSSTEG= 2	ALFA=0,20	VARIANS=	299,9817276	MEDELFEL=	-2,3009157
PREDIKTIONSSTEG= 2	ALFA=0,25	VARIANS=	281,5089721	MEDELFEL=	-2,2341134
PREDIKTIONSSTEG= 2	ALFA=0,30	VARIANS=	268,3904495	MEDELFEL=	-2,1932594
PREDIKTIONSSTEG= 2	ALFA=0,35	VARIANS=	258,8630371	MEDELFEL=	-2,1678368
PREDIKTIONSSTEG= 2	ALFA=0,40	VARIANS=	251,7570610	MEDELFEL=	-2,1546556
PREDIKTIONSSTEG= 2	ALFA=0,45	VARIANS=	246,3011475	MEDELFEL=	-2,1512691
PREDIKTIONSSTEG= 2	ALFA=0,50	VARIANS=	241,9904442	MEDELFEL=	-2,1551569
PREDIKTIONSSTEG= 2	ALFA=0,55	VARIANS=	238,4930038	MEDELFEL=	-2,1640258
PREDIKTIONSSTEG= 2	ALFA=0,60	VARIANS=	235,5871964	MEDELFEL=	-2,1759705
PREDIKTIONSSSTE	ALFA=0,65	VARIANS=	233,1227035	MEDELFEL=	-2,1895823
PREDIKTIONSSSTE	ALFA=0,70	VARIANS=	230,9961281	MEDELFEL=	-2,2038719
PREDIKTIONSSSTE	ALFA=0,75	VARIANS=	229,1368675	MEDELFEL=	-2,2181702
PREDIKTIONSSSTE	ALFA=0,80	VARIANS=	227,4980545	MEDELFEL=	-2,2320631
PREDIKTIONSSSTE	ALFA=0,85	VARIANS=	226,0511513	MEDELFEL=	-2,2452618
PREDIKTIONSSSTE	ALFA=0,90	VARIANS=	224,7826920	MEDELFEL=	-2,2575914
PREDIKTIONSSSTE	ALFA=0,95	VARIANS=	223,6926079	MEDELFEL=	-2,2689463
PREDIKTIONSSSTE	ALFA=1,00	VARIANS=	267,7096329	MEDELFEL=	-2,7146340

Tabell 8. Varians och medelfel vid 3-stegsprediktion av Flygdata

För $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG= 3	ALFA=0, 00	VARIANS=	425, 8340759	MEDELFEL=	-8, 0334569
PREDIKTIONSSTEG= 3	ALFA=0, 05	VARIANS=	361, 1845321	MEDELFEL=	-4, 1460991
PREDIKTIONSSTEG= 3	ALFA=0, 10	VARIANS=	353, 3988037	MEDELFEL=	-2, 6967649
PREDIKTIONSSTEG= 3	ALFA=0, 15	VARIANS=	325, 7397003	MEDELFEL=	-2, 2351679
PREDIKTIONSSTEG= 3	ALFA=0, 20	VARIANS=	302, 0040512	MEDELFEL=	-2, 0729805
PREDIKTIONSSTEG= 3	ALFA=0, 25	VARIANS=	284, 3607712	MEDELFEL=	-1, 9900730
PREDIKTIONSSTEG= 3	ALFA=0, 30	VARIANS=	271, 3015976	MEDELFEL=	-1, 9303298
PREDIKTIONSSTEG= 3	ALFA=0, 35	VARIANS=	264, 5698700	MEDELFEL=	-1, 8830824
PREDIKTIONSSTEG= 3	ALFA=0, 40	VARIANS=	254, 2470932	MEDELFEL=	-1, 8473617
PREDIKTIONSSTEG= 3	ALFA=0, 45	VARIANS=	248, 6601105	MEDELFEL=	-1, 8228360
PREDIKTIONSSTEG= 3	ALFA=0, 50	VARIANS=	244, 3289452	MEDELFEL=	-1, 8082792
PREDIKTIONSSTEG= 3	ALFA=0, 55	VARIANS=	240, 9176369	MEDELFEL=	-1, 8019187
PREDIKTIONSSTEG= 3	ALFA=0, 60	VARIANS=	238, 1903725	MEDELFEL=	-1, 8018329
PREDIKTIONSSTEG= 3	ALFA=0, 65	VARIANS=	235, 9794312	MEDELFEL=	-1, 8063322
PREDIKTIONSSTEG= 3	ALFA=0, 70	VARIANS=	234, 1629715	MEDELFEL=	-1, 8140679
PREDIKTIONSSTEG= 3	ALFA=0, 75	VARIANS=	232, 6527290	MEDELFEL=	-1, 8240137
PREDIKTIONSSTEG= 3	ALFA=0, 80	VARIANS=	231, 3859901	MEDELFEL=	-1, 8354705
PREDIKTIONSSTEG= 3	ALFA=0, 85	VARIANS=	230, 3216133	MEDELFEL=	-1, 8479007
PREDIKTIONSSTEG= 3	ALFA=0, 90	VARIANS=	229, 4388123	MEDELFEL=	-1, 8609444
PREDIKTIONSSTEG= 3	ALFA=0, 95	VARIANS=	228, 7370377	MEDELFEL=	-1, 8743403
PREDIKTIONSSTEG= 3	ALFA=1, 00	VARIANS=	269, 4913254	MEDELFEL=	-2, 6674773

Tabell 9. Varians och medelfel vid 6-stegsprediktion av Flygdata
för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG= 6	ALFA=0,00	VARIANS=	367,1605682	MEDELFEL=	-7,0432049
PREDIKTIONSSTEG= 6	ALFA=0,05	VARIANS=	325,3514404	MEDELFEL=	-3,6406797
PREDIKTIONSSTEG= 6	ALFA=0,10	VARIANS=	352,1179428	MEDELFEL=	-2,0247145
PREDIKTIONSSTEG= 6	ALFA=0,15	VARIANS=	346,5470352	MEDELFEL=	-1,4571017
PREDIKTIONSSTEG= 6	ALFA=0,20	VARIANS=	335,1997528	MEDELFEL=	-1,2932029
PREDIKTIONSSTEG= 6	ALFA=0,25	VARIANS=	325,5701752	MEDELFEL=	-1,2462941
PREDIKTIONSSTEG= 6	ALFA=0,30	VARIANS=	317,6664886	MEDELFEL=	-1,2163624
PREDIKTIONSSTEG= 6	ALFA=0,35	VARIANS=	311,0924148	MEDELFEL=	-1,1766027
PREDIKTIONSSTEG= 6	ALFA=0,40	VARIANS=	305,6662979	MEDELFEL=	-1,1253480
PREDIKTIONSSTEG= 6	ALFA=0,45	VARIANS=	301,2201614	MEDELFEL=	-1,0679199
PREDIKTIONSSTEG= 6	ALFA=0,50	VARIANS=	297,5561066	MEDELFEL=	-1,0101198
PREDIKTIONSSTEG= 6	ALFA=0,55	VARIANS=	294,4867172	MEDELFEL=	-0,9562637
PREDIKTIONSSTEG= 6	ALFA=0,60	VARIANS=	291,8680038	MEDELFEL=	-0,9086815
PREDIKTIONSSTEG= 6	ALFA=0,65	VARIANS=	289,6100006	MEDELFEL=	-0,8681842
PREDIKTIONSSTEG= 6	ALFA=0,70	VARIANS=	287,6686478	MEDELFEL=	-0,8344930
PREDIKTIONSSTEG= 6	ALFA=0,75	VARIANS=	286,0357285	MEDELFEL=	-0,8067029
PREDIKTIONSSTEG= 6	ALFA=0,80	VARIANS=	284,7309036	MEDELFEL=	-0,7837508
PREDIKTIONSSTEG= 6	ALFA=0,85	VARIANS=	283,7957458	MEDELFEL=	-0,7644793
PREDIKTIONSSTEG= 6	ALFA=0,90	VARIANS=	283,2986298	MEDELFEL=	-0,7479730
PREDIKTIONSSTEG= 6	ALFA=0,95	VARIANS=	283,3354263	MEDELFEL=	-0,7335631
PREDIKTIONSSTEG= 6	ALFA=1,00	VARIANS=	274,0671081	MEDELFEL=	-2,4691986

Tabell 10. Varians och medelfel vid 12-stegsprediktion av Flygdata
för $\phi = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG=12	ALFA=0,00	VARIANS=	319,6696930	MEDELFEL=	-5,9117930
PREDIKTIONSSTEG=12	ALFA=0,05	VARIANS=	284,2349930	MEDELFEL=	-3,4453954
PREDIKTIONSSTEG=12	ALFA=0,10	VARIANS=	386,3242340	MEDELFEL=	-1,4224464
PREDIKTIONSSTEG=12	ALFA=0,15	VARIANS=	453,3921814	MEDELFEL=	-0,3154970
PREDIKTIONSSTEG=12	ALFA=0,20	VARIANS=	481,1171112	MEDELFEL=	0,1687079
PREDIKTIONSSTEG=12	ALFA=0,25	VARIANS=	494,0881424	MEDELFEL=	0,3087609
PREDIKTIONSSTEG=12	ALFA=0,30	VARIANS=	502,4555511	MEDELFEL=	0,2693502
PREDIKTIONSSTEG=12	ALFA=0,35	VARIANS=	508,4114685	MEDELFEL=	0,1376038
PREDIKTIONSSTEG=12	ALFA=0,40	VARIANS=	512,2977753	MEDELFEL=	-0,0396830
PREDIKTIONSSTEG=12	ALFA=0,45	VARIANS=	514,5090179	MEDELFEL=	-0,2357854
PREDIKTIONSSTEG=12	ALFA=0,50	VARIANS=	515,6703494	MEDELFEL=	-0,4347298
PREDIKTIONSSTEG=12	ALFA=0,55	VARIANS=	516,4526062	MEDELFEL=	-0,6272343
PREDIKTIONSSTEG=12	ALFA=0,60	VARIANS=	517,4300232	MEDELFEL=	-0,8080580
PREDIKTIONSSTEG=12	ALFA=0,65	VARIANS=	519,0346985	MEDELFEL=	-0,9748006
PREDIKTIONSSTEG=12	ALFA=0,70	VARIANS=	521,5689697	MEDELFEL=	-1,1267427
PREDIKTIONSSTEG=12	ALFA=0,75	VARIANS=	525,2391816	MEDELFEL=	-1,2641066
PREDIKTIONSSTEG=12	ALFA=0,80	VARIANS=	530,2051086	MEDELFEL=	-1,3878259
PREDIKTIONSSTEG=12	ALFA=0,85	VARIANS=	536,6137238	MEDELFEL=	-1,4988612
PREDIKTIONSSTEG=12	ALFA=0,90	VARIANS=	544,6556397	MEDELFEL=	-1,5984125
PREDIKTIONSSTEG=12	ALFA=0,95	VARIANS=	554,6065064	MEDELFEL=	-1,6876724
PREDIKTIONSSTEG=12	ALFA=1,00	VARIANS=	286,4089126	MEDELFEL=	-2,5272812

Tabell 11. Varians och medelfel vid 24-stegs prediktion av Flygdata
för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG=24	ALFA=0,00	VARIANS=	436,8837967	MEDELFEL=	-6,6117158
PREDIKTIONSSTEG=24	ALFA=0,05	VARIANS=	479,1484070	MEDELFEL=	-6,8811295
PREDIKTIONSSTEG=24	ALFA=0,10	VARIANS=	713,1915893	MEDELFEL=	-6,4053379
PREDIKTIONSSTEG=24	ALFA=0,15	VARIANS=	948,5600281	MEDELFEL=	-5,5965728
PREDIKTIONSSTEG=24	ALFA=0,20	VARIANS=	1130,5643921	MEDELFEL=	-4,7570163
PREDIKTIONSSTEG=24	ALFA=0,25	VARIANS=	1268,9879151	MEDELFEL=	-4,0728512
PREDIKTIONSSTEG=24	ALFA=0,30	VARIANS=	1372,3819885	MEDELFEL=	-3,5869790
PREDIKTIONSSTEG=24	ALFA=0,35	VARIANS=	1445,1348267	MEDELFEL=	-3,2869781
PREDIKTIONSSTEG=24	ALFA=0,40	VARIANS=	1492,0857239	MEDELFEL=	-3,1401192
PREDIKTIONSSTEG=24	ALFA=0,45	VARIANS=	1519,3039551	MEDELFEL=	-3,1080629
PREDIKTIONSSTEG=24	ALFA=0,50	VARIANS=	1533,0293580	MEDELFEL=	-3,1549096
PREDIKTIONSSTEG=24	ALFA=0,55	VARIANS=	1538,7063904	MEDELFEL=	-3,2514208
PREDIKTIONSSTEG=24	ALFA=0,60	VARIANS=	1540,5691113	MEDELFEL=	-3,3752038
PREDIKTIONSSTEG=24	ALFA=0,65	VARIANS=	1541,7738647	MEDELFEL=	-3,5105065
PREDIKTIONSSTEG=24	ALFA=0,70	VARIANS=	1544,4322510	MEDELFEL=	-3,6466309
PREDIKTIONSSTEG=24	ALFA=0,75	VARIANS=	1550,0686035	MEDELFEL=	-3,7765757
PREDIKTIONSSTEG=24	ALFA=0,80	VARIANS=	1559,7921753	MEDELFEL=	-3,8964140
PREDIKTIONSSTEG=24	ALFA=0,85	VARIANS=	1574,5026855	MEDELFEL=	-4,0036553
PREDIKTIONSSTEG=24	ALFA=0,90	VARIANS=	1595,1212769	MEDELFEL=	-4,0974406
PREDIKTIONSSTEG=24	ALFA=0,95	VARIANS=	1622,7589722	MEDELFEL=	-4,1778278
PREDIKTIONSSTEG=24	ALFA=1,00	VARIANS=	533,4962158	MEDELFEL=	-6,2537439

Tabell 12. Varians och medelfel vid 48-stegsprediktion av Flygdata
för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG=48	ALFA=0,00	VARIANS=	1001,9298095	MEDELFEL=	-12,8485789
PREDIKTIONSSTEG=48	ALFA=0,05	VARIANS=	886,2574463	MEDELFEL=	-12,4519963
PREDIKTIONSSTEG=48	ALFA=0,10	VARIANS=	966,3211670	MEDELFEL=	-11,9614058
PREDIKTIONSSTEG=48	ALFA=0,15	VARIANS=	1287,3744507	MEDELFEL=	-13,0677102
PREDIKTIONSSTEG=48	ALFA=0,20	VARIANS=	1649,8432312	MEDELFEL=	-14,4137526
PREDIKTIONSSTEG=48	ALFA=0,25	VARIANS=	1959,7087402	MEDELFEL=	-15,5173388
PREDIKTIONSSTEG=48	ALFA=0,30	VARIANS=	2193,7823486	MEDELFEL=	-16,3872738
PREDIKTIONSSTEG=48	ALFA=0,35	VARIANS=	2355,0409546	MEDELFEL=	-17,1059394
PREDIKTIONSSTEG=48	ALFA=0,40	VARIANS=	2458,3837280	MEDELFEL=	-17,7298503
PREDIKTIONSSTEG=48	ALFA=0,45	VARIANS=	2522,5059813	MEDELFEL=	-18,2866106
PREDIKTIONSSTEG=48	ALFA=0,50	VARIANS=	2564,5643309	MEDELFEL=	-18,7875047
PREDIKTIONSSTEG=48	ALFA=0,55	VARIANS=	2597,9258422	MEDELFEL=	-19,2375789
PREDIKTIONSSTEG=48	ALFA=0,60	VARIANS=	2631,9948120	MEDELFEL=	-19,6392698
PREDIKTIONSSSTEGER=48	ALFA=0,65	VARIANS=	2672,9915160	MEDELFEL=	-19,9952354
PREDIKTIONSSSTEGER=48	ALFA=0,70	VARIANS=	2724,9924927	MEDELFEL=	-20,3083677
PREDIKTIONSSSTEGER=48	ALFA=0,75	VARIANS=	2790,8139647	MEDELFEL=	-20,5816283
PREDIKTIONSSSTEGER=48	ALFA=0,80	VARIANS=	2872,8358764	MEDELFEL=	-20,8188667
PREDIKTIONSSSTEGER=48	ALFA=0,85	VARIANS=	2973,5947875	MEDELFEL=	-21,0228510
PREDIKTIONSSSTEGER=48	ALFA=0,90	VARIANS=	3096,4057615	MEDELFEL=	-21,1967111
PREDIKTIONSSSTEGER=48	ALFA=0,95	VARIANS=	3246,0577392	MEDELFEL=	-21,3435063
PREDIKTIONSSSTEGER=48	ALFA=1,00	VARIANS=	895,5457306	MEDELFEL=	-13,1710601




Fig. 5.2 Prediktionen av Flygdata med heuristiska metoden med $k=1$ och $\alpha=0.95$. Flygdata = I, Prediktion av Flygdata = \hat{I} .




Fig. 5.3 Prediktionen av Flygdata med heuristiska metoden med $k=12$ och $\alpha=0.05$. Flygdata = I, Prediktion av Flygdata = \hat{x} .




Fig. 5.4 Prediktionen av Flygdata med heuristiska metoden med $k=48$ och $\alpha=0.05$. Flygdata = I, Prediktion av Flygdata = \hat{x} .




Fig. 5.5 Prediktionsfellet vid prediktion av Flygdata med heuristiska metoden med $k=1$ och $\alpha=0.95$.




Fig. 5.6 Summa prediktionsfel i kvadrat vid prediktion av Flygdata med heuristiska metoden med $k=1$ och $\alpha=0.95$.

5.2 Företagsdata.

Denna prediktion gjordes enligt punkt 2 (Se kap. 3.1) d.v.s. ingen trend drogs ifrån innan prediktionen gjordes. Beräkningar utfördes för prediktionsstegen 1, 2, 3, 6, 12, 24 och 48 månader. Utjämningskoefficienter, α , från 0.0 till 1.0 i steg om 0.05 undersöktes. Värdena på medelfel och varians framgår av tabellerna 13 - 19. Minima för medelfel och varians är understrykna.

Prediktionen vid prediktionsstegen 1 och 12 månader visas i figurerna 5.7 och 5.8. Som synes ligger prediktionen tidsmässigt rätt och utseendet följer relativt bra, men ligger hela tiden något lågt. Anmärkningsvärt är hur bra prediktionen följer julidipparna.

Prediktionsfelet för prediktionssteget 1 månad visas i figur 5.9 och här framgår det att felet blir större ju längre fram i tiden man kommer. Detta framgår även av den ökade stigningen för summa prediktionsfel i kvadrat, figur 5.10, mot slutet av tidsperioden. Detta gäller även för övriga prediktionssteg.

Tabell 13. Varians och medelfel vid 1-stegsprediktion av Företags-data för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG= 1	ALFA=0,00	VARIANS=	32177101,0011434	MEDELFEL=	7320,0231934
PREDIKTIONSSTEG= 1	ALFA=0,05	VARIANS=	6289709,3747742	MEDELFEL=	1759,0599976
PREDIKTIONSSTEG= 1	ALFA=0,10	VARIANS=	6089941,2496946	MEDELFEL=	1508,0181885
PREDIKTIONSSTEG= 1	ALFA=0,15	VARIANS=	5751821,7498436	MEDELFEL=	1444,1499939
PREDIKTIONSSTEG= 1	ALFA=0,20	VARIANS=	5431940,0000385	MEDELFEL=	1413,8716736
PREDIKTIONSSTEG= 1	ALFA=0,25	VARIANS=	5188942,1250671	MEDELFEL=	1396,0404663
PREDIKTIONSSTEG= 1	ALFA=0,30	VARIANS=	5018449,6250003	MEDELFEL=	1384,8449402
PREDIKTIONSSTEG= 1	ALFA=0,35	VARIANS=	4902332,1249987	MEDELFEL=	1377,5943908
PREDIKTIONSSTEG= 1	ALFA=0,40	VARIANS=	4823919,7498187	MEDELFEL=	1372,7584839
PREDIKTIONSSTEG= 1	ALFA=0,45	VARIANS=	4770880,2500274	MEDELFEL=	1369,4228515
PREDIKTIONSSTEG= 1	ALFA=0,50	VARIANS=	4734741,6249103	MEDELFEL=	1367,0343933
PREDIKTIONSSTEG= 1	ALFA=0,55	VARIANS=	4709848,6248869	MEDELFEL=	1365,2550354
PREDIKTIONSSTEG= 1	ALFA=0,60	VARIANS=	4692463,7500196	MEDELFEL=	1363,8765870
PREDIKTIONSSTEG= 1	ALFA=0,65	VARIANS=	4680118,8748795	MEDELFEL=	1362,7679138
PREDIKTIONSSTEG= 1	ALFA=0,70	VARIANS=	4671179,4999428	MEDELFEL=	1361,8464050
PREDIKTIONSSTEG= 1	ALFA=0,75	VARIANS=	4664566,2500523	MEDELFEL=	1361,0585937
PREDIKTIONSSTEG= 1	ALFA=0,80	VARIANS=	4659572,7498643	MEDELFEL=	1360,3681336
PREDIKTIONSSTEG= 1	ALFA=0,85	VARIANS=	4655746,5000078	MEDELFEL=	1359,7514039
PREDIKTIONSSTEG= 1	ALFA=0,90	VARIANS=	4652815,1249513	MEDELFEL=	1359,1902160
PREDIKTIONSSTEG= 1	ALFA=0,95	VARIANS=	4650632,1250926	MEDELFEL=	1358,6712036
PREDIKTIONSSTEG= 1	ALFA=1,00	VARIANS=	5016177,6249296	MEDELFEL=	1468,7564393

Tabell 14. Varians och medelfel vid 2-stegsprediktion av Företags-
data för $\alpha=0.05$, $\beta=0.05$, $n=100$

PREDIKTIONSSTEG= 2	ALFA=0,00	VARIANS=	31924399,4983844	MEDELFEL=	7304,2818601
PREDIKTIONSSTEG= 2	ALFA=0,05	VARIANS=	6035515,9998871	MEDELFEL=	1692,4333191
PREDIKTIONSSTEG= 2	ALFA=0,10	VARIANS=	5975503,7496797	MEDELFEL=	1427,6277466
PREDIKTIONSSTEG= 2	ALFA=0,15	VARIANS=	5708937,4996721	MEDELFEL=	1358,5972595
PREDIKTIONSSTEG= 2	ALFA=0,20	VARIANS=	5399395,3750468	MEDELFEL=	1324,2691040
PREDIKTIONSSTEG= 2	ALFA=0,25	VARIANS=	5135238,4998463	MEDELFEL=	1302,7025756
PREDIKTIONSSTEG= 2	ALFA=0,30	VARIANS=	4931690,7499451	MEDELFEL=	1288,2879028
PREDIKTIONSSTEG= 2	ALFA=0,35	VARIANS=	4780875,6248559	MEDELFEL=	1278,4497376
PREDIKTIONSSTEG= 2	ALFA=0,40	VARIANS=	4670851,9998937	MEDELFEL=	1271,6279297
PREDIKTIONSSTEG= 2	ALFA=0,45	VARIANS=	4591082,7498883	MEDELFEL=	1266,8132934
PREDIKTIONSSTEG= 2	ALFA=0,50	VARIANS=	4533451,2498229	MEDELFEL=	1263,3466186
PREDIKTIONSSTEG= 2	ALFA=0,55	VARIANS=	4492022,1248175	MEDELFEL=	1260,7937316
PREDIKTIONSSTEG= 2	ALFA=0,60	VARIANS=	4462540,1250086	MEDELFEL=	1258,8698121
PREDIKTIONSSTEG= 2	ALFA=0,65	VARIANS=	4441979,4999994	MEDELFEL=	1257,3838196
PREDIKTIONSSTEG= 2	ALFA=0,70	VARIANS=	4428185,7497990	MEDELFEL=	1256,2091370
PREDIKTIONSSTEG= 2	ALFA=0,75	VARIANS=	4419630,5000223	MEDELFEL=	1255,2615661
PREDIKTIONSSTEG= 2	ALFA=0,80	VARIANS=	4415243,3748822	MEDELFEL=	1254,4836426
PREDIKTIONSSTEG= 2	ALFA=0,85	VARIANS=	4414301,8750473	MEDELFEL=	1253,8397216
PREDIKTIONSSTEG= 2	ALFA=0,90	VARIANS=	4416376,3748947	MEDELFEL=	1253,3047790
PREDIKTIONSSTEG= 2	ALFA=0,95	VARIANS=	4421286,8749164	MEDELFEL=	1252,8621826
PREDIKTIONSSTEG= 2	ALFA=1,00	VARIANS=	5048750,0000745	MEDELFEL=	1468,7871093

Tabell 15. Varians och medlefel vid 3-stegsprediktion av Företags-
data för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG= 3	ALFA=0,00	VARIANS=	31752495,5002591	MEDELFEEL=	7284,8477762
PREDIKTIONSSTEG= 3	ALFA=0,05	VARIANS=	5765030,2499718	MEDELFEEL=	1623,7534179
PREDIKTIONSSTEG= 3	ALFA=0,10	VARIANS=	5869610,1247332	MEDELFEEL=	1345,4608459
PREDIKTIONSSTEG= 3	ALFA=0,15	VARIANS=	5700939,6250359	MEDELFEEL=	1271,9582214
PREDIKTIONSSTEG= 3	ALFA=0,20	VARIANS=	5428642,7497863	MEDELFEEL=	1234,0864562
PREDIKTIONSSTEG= 3	ALFA=0,25	VARIANS=	5164457,6247781	MEDELFEEL=	1208,8808899
PREDIKTIONSSTEG= 3	ALFA=0,30	VARIANS=	4941895,8749156	MEDELFEEL=	1190,9933777
PREDIKTIONSSTEG= 3	ALFA=0,35	VARIANS=	4763789,8749671	MEDELFEEL=	1178,9959472
PREDIKTIONSSTEG= 3	ALFA=0,40	VARIANS=	4624083,4998898	MEDELFEEL=	1168,7112426
PREDIKTIONSSTEG= 3	ALFA=0,45	VARIANS=	4515331,4999770	MEDELFEEL=	1161,8109131
PREDIKTIONSSTEG= 3	ALFA=0,50	VARIANS=	4430942,3749800	MEDELFEEL=	1156,6731872
PREDIKTIONSSTEG= 3	ALFA=0,55	VARIANS=	4365646,8749977	MEDELFEEL=	1152,7903442
PREDIKTIONSSTEG= 3	ALFA=0,60	VARIANS=	4315416,9998597	MEDELFEEL=	1149,8063659
PREDIKTIONSSTEG= 3	ALFA=0,65	VARIANS=	4277236,3750264	MEDELFEEL=	1147,4663696
PREDIKTIONSSTEG= 3	ALFA=0,70	VARIANS=	4248856,6248212	MEDELFEEL=	1145,5881347
PREDIKTIONSSTEG= 3	ALFA=0,75	VARIANS=	4228601,8750164	MEDELFEEL=	1144,0414124
PREDIKTIONSSTEG= 3	ALFA=0,80	VARIANS=	4215220,1249264	MEDELFEEL=	1142,7298584
PREDIKTIONSSTEG= 3	ALFA=0,85	VARIANS=	4207800,3748320	MEDELFEEL=	1141,5902710
PREDIKTIONSSTEG= 3	ALFA=0,90	VARIANS=	4205736,8748355	MEDELFEEL=	1140,5775146
PREDIKTIONSSTEG= 3	ALFA=0,95	VARIANS=	4208750,7499381	MEDELFEEL=	1139,6622620
PREDIKTIONSSTEG= 3	ALFA=1,00	VARIANS=	5079676,5000559	MEDELFEEL=	1465,1428633

Tabell 16. Varians och medelfel vid 6-stegsprediktion av företags-
data för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG= 6	ALFA=0,00	VARIANS=	31031776,4990031	MEDELFEL=	7232,6295166
PREDIKTIONSSTEG= 6	ALFA=0,05	VARIANS=	4867045,3750528	MEDELFEL=	1418,7940674
PREDIKTIONSSTEG= 6	ALFA=0,10	VARIANS=	5387470,1252207	MEDELFEL=	1101,0150147
PREDIKTIONSSTEG= 6	ALFA=0,15	VARIANS=	5652194,6252323	MEDELFEL=	1019,8680420
PREDIKTIONSSTEG= 6	ALFA=0,20	VARIANS=	5664705,8748640	MEDELFEL=	978,0387573
PREDIKTIONSSTEG= 6	ALFA=0,25	VARIANS=	5563674,7498065	MEDELFEL=	947,0368195
PREDIKTIONSSTEG= 6	ALFA=0,30	VARIANS=	5427589,3750600	MEDELFEL=	921,7326660
PREDIKTIONSSTEG= 6	ALFA=0,35	VARIANS=	5289931,2498047	MEDELFEL=	900,8282013
PREDIKTIONSSTEG= 6	ALFA=0,40	VARIANS=	5163457,9999372	MEDELFEL=	883,5759583
PREDIKTIONSSTEG= 6	ALFA=0,45	VARIANS=	5052500,2498179	MEDELFEL=	869,3161773
PREDIKTIONSSTEG= 6	ALFA=0,50	VARIANS=	4957989,0000168	MEDELFEL=	857,4669342
PREDIKTIONSSTEG= 6	ALFA=0,55	VARIANS=	4879383,3749368	MEDELFEL=	847,5449372
PREDIKTIONSSTEG= 6	ALFA=0,60	VARIANS=	4815467,9997824	MEDELFEL=	839,1809388
PREDIKTIONSSTEG= 6	ALFA=0,65	VARIANS=	4764747,4999539	MEDELFEL=	832,0985565
PREDIKTIONSSTEG= 6	ALFA=0,70	VARIANS=	4725729,8750337	MEDELFEL=	826,0989532
PREDIKTIONSSTEG= 6	ALFA=0,75	VARIANS=	4697167,8750123	MEDELFEL=	821,0402527
PREDIKTIONSSTEG= 6	ALFA=0,80	VARIANS=	4678310,6247894	MEDELFEL=	816,8105469
PREDIKTIONSSTEG= 6	ALFA=0,85	VARIANS=	4669169,2499443	MEDELFEL=	813,3320770
PREDIKTIONSSTEG= 6	ALFA=0,90	VARIANS=	4670801,2497983	MEDELFEL=	810,5371704
PREDIKTIONSSTEG= 6	ALFA=0,95	VARIANS=	4685650,5000032	MEDELFEL=	808,3734284
PREDIKTIONSSTEG= 6	ALFA=1,00	VARIANS=	5135988,6247664	MEDELFEL=	1460,8344726

Tabell 17. Varians och medelfel vid 12-stegsprediktion av Företags-data för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG=12	ALFA=0,00	VARIANS=	29930426,0010831	MEDELFEL=	7152,0573729
PREDIKTIONSSTEG=12	ALFA=0,05	VARIANS=	3779052,9998019	MEDELFEL=	1034,8290405
PREDIKTIONSSTEG=12	ALFA=0,10	VARIANS=	4371355,4998394	MEDELFEL=	614,9596252
PREDIKTIONSSTEG=12	ALFA=0,15	VARIANS=	5324826,4999128	MEDELFEL=	519,4403687
PREDIKTIONSSTEG=12	ALFA=0,20	VARIANS=	6151061,8748143	MEDELFEL=	490,0465088
PREDIKTIONSSTEG=12	ALFA=0,25	VARIANS=	6741812,8750286	MEDELFEL=	474,9838791
PREDIKTIONSSTEG=12	ALFA=0,30	VARIANS=	7139941,5000341	MEDELFEL=	461,5837936
PREDIKTIONSSTEG=12	ALFA=0,35	VARIANS=	7413887,2497715	MEDELFEL=	447,1052017
PREDIKTIONSSTEG=12	ALFA=0,40	VARIANS=	7618359,5000766	MEDELFEL=	431,3209839
PREDIKTIONSSTEG=12	ALFA=0,45	VARIANS=	7789814,6249353	MEDELFEL=	414,5418930
PREDIKTIONSSTEG=12	ALFA=0,50	VARIANS=	7950862,0002306	MEDELFEL=	397,1034927
PREDIKTIONSSTEG=12	ALFA=0,55	VARIANS=	8115215,3750881	MEDELFEL=	379,2416534
PREDIKTIONSSTEG=12	ALFA=0,60	VARIANS=	8294387,7498358	MEDELFEL=	361,1101913
PREDIKTIONSSTEG=12	ALFA=0,65	VARIANS=	8485075,5003280	MEDELFEL=	342,7821960
PREDIKTIONSSTEG=12	ALFA=0,70	VARIANS=	8700689,5001977	MEDELFEL=	324,2829432
PREDIKTIONSSTEG=12	ALFA=0,75	VARIANS=	8942267,5003297	MEDELFEL=	305,6054840
PREDIKTIONSSTEG=12	ALFA=0,80	VARIANS=	9214169,0002754	MEDELFEL=	286,7061615
PREDIKTIONSSTEG=12	ALFA=0,85	VARIANS=	9521665,5000112	MEDELFEL=	267,5443802
PREDIKTIONSSTEG=12	ALFA=0,90	VARIANS=	9871527,4995192	MEDELFEL=	248,0571938
PREDIKTIONSSTEG=12	ALFA=0,95	VARIANS=	10273041,9998988	MEDELFEL=	228,1753426
PREDIKTIONSSTEG=12	ALFA=1,00	VARIANS=	5224657,8746803	MEDELFEL=	1476,4068908

Tabell 18. Varians och medelfel vid 24-stegsprognos för företags-
data för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG=24	ALFA=0, 00	VARIANS#=	30403898, 5003717	MEDELFEL=	7689, 3638917
PREDIKTIONSSTEG=24	ALFA=0, 05	VARIANS#=	5135906, 6246077	MEDELFEL=	1661, 5756836
PREDIKTIONSSTEG=24	ALFA=0, 10	VARIANS#=	4789171, 7499587	MEDELFEL=	976, 7054901
PREDIKTIONSSTEG=24	ALFA=0, 15	VARIANS#=	5095310, 4998916	MEDELFEL=	699, 8252564
PREDIKTIONSSTEG=24	ALFA=0, 20	VARIANS#=	5611271, 6249190	MEDELFEL=	557, 2888642
PREDIKTIONSSTEG=24	ALFA=0, 25	VARIANS#=	6205816, 1250315	MEDELFEL=	477, 9746551
PREDIKTIONSSTEG=24	ALFA=0, 30	VARIANS#=	6826164, 3750593	MEDELFEL=	430, 8590698
PREDIKTIONSSTEG=24	ALFA=0, 35	VARIANS#=	7445933, 4998391	MEDELFEL=	400, 4499817
PREDIKTIONSSTEG=24	ALFA=0, 40	VARIANS#=	8056586, 3749943	MEDELFEL=	378, 5496292
PREDIKTIONSSTEG=24	ALFA=0, 45	VARIANS#=	8660900, 4996716	MEDELFEL=	360, 7032242
PREDIKTIONSSTEG=24	ALFA=0, 50	VARIANS#=	9267682, 2496578	MEDELFEL=	344, 4779663
PREDIKTIONSSSTE	ALFA=0, 55	VARIANS#=	9888402, 2496640	MEDELFEL=	328, 5486832
PREDIKTIONSSSTE	ALFA=0, 60	VARIANS#=	10535505, 9998109	MEDELFEL=	312, 2561264
PREDIKTIONSSSTE	ALFA=0, 65	VARIANS#=	11221739, 9994842	MEDELFEL=	295, 2955170
PREDIKTIONSSSTE	ALFA=0, 70	VARIANS#=	11960259, 0003050	MEDELFEL=	277, 5667267
PREDIKTIONSSSTE	ALFA=0, 75	VARIANS#=	12765087, 7498090	MEDELFEL=	259, 0718994
PREDIKTIONSSSTE	ALFA=0, 80	VARIANS#=	13652321, 0001178	MEDELFEL=	239, 8073921
PREDIKTIONSSSTE	ALFA=0, 85	VARIANS#=	14641720, 9994979	MEDELFEL=	219, 7860069
PREDIKTIONSSSTE	ALFA=0, 90	VARIANS#=	15759154, 4999741	MEDELFEL=	198, 9579239
PREDIKTIONSSSTE	ALFA=0, 95	VARIANS#=	17040313, 4999796	MEDELFEL=	177, 2068901
PREDIKTIONSSSTE	ALFA=1, 00	VARIANS#=	6659306, 7501671	MEDELFEL=	2631, 4135130

Tabell 19. Varians och medelfel vid 48-stegsprediktion av Företags-
data för $\alpha = 0.0, (0.05), 1.0$

PREDIKTIONSSTEG=48	ALFA=0,00	VARIANS= 28126123,4986595	MEDELFEL= 8963,8723144
PREDIKTIONSSTEG=48	ALFA=0,05	VARIANS= 7716107,1249283	MEDELFEL= 3293,1872557
PREDIKTIONSSTEG=48	ALFA=0,10	VARIANS= 8703515,4998302	MEDELFEL= 2504,3002930
PREDIKTIONSSTEG=48	ALFA=0,15	VARIANS= 9413047,2503602	MEDELFEL= 2240,8584595
PREDIKTIONSSTEG=48	ALFA=0,20	VARIANS= 10146175,5000054	MEDELFEL= 2094,9390869
PREDIKTIONSSTEG=48	ALFA=0,25	VARIANS= 10916901,2499041	MEDELFEL= 1997,4015503
PREDIKTIONSSTEG=48	ALFA=0,30	VARIANS= 11686952,9993273	MEDELFEL= 1925,3173524
PREDIKTIONSSTEG=48	ALFA=0,35	VARIANS= 12459583,4994688	MEDELFEL= 1867,8970336
PREDIKTIONSSTEG=48	ALFA=0,40	VARIANS= 13263953,2489702	MEDELFEL= 1819,3127137
PREDIKTIONSSTEG=48	ALFA=0,45	VARIANS= 14135487,7492412	MEDELFEL= 1776,1352539
PREDIKTIONSSTEG=48	ALFA=0,50	VARIANS= 15108134,7502768	MEDELFEL= 1736,1794434
PREDIKTIONSSTEG=48	ALFA=0,55	VARIANS= 16214053,2503835	MEDELFEL= 1697,9114380
PREDIKTIONSSTEG=48	ALFA=0,60	VARIANS= 17486549,4994446	MEDELFEL= 1660,2497558
PREDIKTIONSSTEG=48	ALFA=0,65	VARIANS= 18963743,0002912	MEDELFEL= 1622,3709412
PREDIKTIONSSTEG=48	ALFA=0,70	VARIANS= 20692691,9999532	MEDELFEL= 1583,6449585
PREDIKTIONSSTEG=48	ALFA=0,75	VARIANS= 22733400,9995684	MEDELFEL= 1543,6034546
PREDIKTIONSSTEG=48	ALFA=0,80	VARIANS= 25163380,0007402	MEDELFEL= 1501,8117066
PREDIKTIONSSTEG=48	ALFA=0,85	VARIANS= 28083682,9985491	MEDELFEL= 1457,9642029
PREDIKTIONSSTEG=48	ALFA=0,90	VARIANS= 31626281,9990515	MEDELFEL= 1411,7617798
PREDIKTIONSSTEG=48	ALFA=0,95	VARIANS= 35965793,0000685	MEDELFEL= 1362,9081116
PREDIKTIONSSTEG=48	ALFA=1,00	VARIANS= 41158623,7493902	MEDELFEL= 5197,7523192




Fig. 5.7 Prediktionen av Företagsdata med heuristiska metoden med $k = 1$ och $\alpha = 0.95$. Företagsdata = I, Prediktionen av Företagsdata = \hat{x} .




Fig. 5.8 Prediktionen av Företagsdata med heuristiska metoden med $k = 12$ och $\alpha = 0.05$. Företagsdata = I, Prediktionen av Företagsdata = E.




Fig. 5.9 Prediktionsfelet vid prediktion av Företagsdata med heuristiska metoden med $k = 1$ och $\alpha = 0.95$.




Fig. 5.10 Summa prediktionsfel i kvadrat vid prediktion av Företagsdata med heuristiska metoden med $k = 1$ och $\alpha = 0.95$.

5.3 Kommentar till heuristiska metoden.

Vid prediktering med den heuristiska metoden på Flygdata och Företagsdata med prediktionsstegslängderna, $k=1,2,3$ och 6 månader erhölls variansmin för ett högt värde på utjämningskoefficienten α , d.v.s. stor hänsyn tas till senaste uppmätta värdet. Vid längre prediktionssteg, såsom $k=12, 24$ och 48 månader erhölls minimat för ett lågt värde på α , d.v.s. stor hänsyn tas till gamla uppmätta värden. Att hoppet sker vid prediktionssteget k , lika med tolv månader kan bero på att **prediktionen då sträcker sig över en säsong**, men kan även bero på den långa prediktionslängden.

De branta stigningarna i figurerna över summa prediktionsfel i kvadrat orsakas av att modellen ej är tillräckligt dynamisk. En mer dynamisk modell skulle eventuellt kunna ge en varians som motsvaras av de flacka stigningarna i figurerna.

6. VAL AV METOD ATT VÄLJA A-PARAMETRAR TILL GENERELL EXPONENTIELL
UTJÄMNING

Modellerna DAT1A - DAT1F och DAT2A - DAT2F enligt nedan är byggda på 400 av de 500 data som finns i DAT1 resp. DAT2.

6.1 Trenddata

Trenden befanns vara $10.0 + 0.05 t$ vilket var lika med den som användes vid genereringen (se kapitel 4.1.1). Beroende efter vilken metod vi väljer att använda vid bestämmandet av a-parametrar, fås nedan redovisade f-vektor, a-vektor och L-matris.

DAT1A - DAT1F betecknar att data har utseendet enligt DAT1 i datapresentationen (se kapitel 4.1.1) och att a-parametrarna har valts enligt punkterna C:a - C:f i kapitel 3.3. Således innebär DAT1A och DAT1B att parametrarna valts enligt punkt C:a resp. C:b. Analogt gäller för DAT1C - DAT1F.

DAT1A

Anpassningsfunktioner:	a-parametrar:	L-matris:
$f_1(t) = 1$	$a_1(0) = 10.0$	1.0 0.0
$f_2(t) = t$	$a_2(0) = 0.05$	1.0 1.0

DAT1B

Anpassningsfunktioner:	a-parametrar:	L-matris:
$f_1(t) = 1$	$a_1(0) = 0.0$	1.0 0.0
$f_2(t) = t$	$a_2(0) = 0.0$	1.0 0.0

DAT1C

Anpassningsfunktion:	a-parameter:	L-matris:
$f_1(t) = 1$	$a_1(0) = 10.0$	1.0

DAT1D

Anpassningsfunktion:	a-parameter:	L-matris:
$f_1(t) = 1$	$a_1(0) = 0.0$	1.0

DAT1E

Anpassningsfunktioner:	a-parametrar:	L-matris:
$f_1(t) = 1$	$a_1(0) = 10.0$	1.0 0.0 0.0
$f_2(t) = t$	$a_2(0) = 0.05$	1.0 1.0 0.0
$f_3(t) = t(t-1)/2$	$a_3(0) = 0.0$	0.0 1.0 1.0

DAT1F

Anpassningsfunktioner:	a-parametrar:	L-matris:
$f_1(t) = 1$	$a_1(0) = 0.0$	1.0 0.0 0.0
$f_2(t) = t$	$a_2(0) = 0.0$	1.0 1.0 0.0
$f_3(t) = t(t-1)/2$	$a_3(0) = 0.0$	0.0 1.0 1.0

Vid körning erhöll vi de i tabell 20 redovisade resultaten på medelfel och varians för olika prediktionssteg, k , och olika viktfaktorer, β .

En genomgående tendens för de olika typerna av data, är att om prediktionssteget är litet skall låg viktfaktor, β , väljas. Däremot om prediktionssteget är stort, bör en viktfaktor, β , med högt värde väljas.

I tabell 21 redovisas medelfelsminimum och variansminimum för prediktionsstegen 1, 2, 3, 6 och 12 månader.

Tabell 20.

	$\beta = 0.97$		$\beta = 0.94$		$\beta = 0.91$		$\beta = 0.88$		
	Var.	Medf.	Var.	Medf.	Var.	Medf.	Var.	Medf.	
k=1	DAT1A	0.861	-0.049	0.774	-0.050	0.677	-0.051	0.569	-0.052
	DAT1B	2.539	0.056	1.591	-0.026	1.217	-0.041	0.969	-0.046
	DAT1C	0.966	1.471	0.864	0.714	0.812	0.448	0.762	0.313
	DAT1D	2.954	2.118	2.160	1.028	1.740	0.651	1.478	0.460
	DAT1E	0.823	-0.050	0.687	-0.051	0.529	-0.052	0.353	-0.052
	DAT1F	2.051	-0.050	1.289	-0.051	0.924	-0.052	0.647	-0.052
k=2	DAT1A	0.983	-0.048	1.037	-0.049	1.103	-0.050	1.185	-0.050
	DAT1B	2.702	0.044	1.894	-0.041	1.692	-0.058	1.644	-0.063
	DAT1C	1.022	1.522	0.983	0.765	0.999	0.500	1.021	0.645
	DAT1D	3.039	2.171	2.309	1.080	1.958	0.703	1.771	0.512
	DAT1E	1.014	-0.049	1.117	-0.050	1.259	-0.051	1.465	-0.050
	DAT1F	2.306	-0.069	1.796	-0.071	1.750	-0.071	1.877	-0.071
k=3	DAT1A	0.976	-0.050	1.027	-0.051	1.093	-0.052	1.176	-0.053
	DAT1B	2.652	0.028	1.838	-0.060	1.643	-0.078	1.605	-0.085
	DAT1C	1.025	1.569	0.980	0.813	0.991	0.548	1.009	0.412
	DAT1D	2.994	2.219	2.253	1.128	1.896	0.751	1.704	0.560
	DAT1E	1.006	-0.051	1.111	-0.053	1.269	-0.053	1.514	-0.053
	DAT1F	2.280	-0.092	1.791	-0.093	1.784	-0.094	1.976	-0.093
k=6	DAT1A	0.985	-0.051	1.049	-0.052	1.144	-0.054	1.276	-0.056
	DAT1B	2.684	-0.013	1.886	-0.112	1.758	-0.134	1.808	-0.143
	DAT1C	1.033	1.718	0.988	0.963	1.000	0.698	1.020	0.562
	DAT1D	2.996	2.372	2.243	1.280	1.883	0.902	1.691	0.711
	DAT1E	1.023	-0.052	1.184	-0.054	1.472	-0.057	1.973	-0.059
	DAT1F	2.430	-0.155	2.110	-0.157	2.376	-0.160	2.975	-0.162
k=12	DAT1A	0.984	-0.048	1.062	-0.047	1.212	-0.047	1.469	-0.048
	DAT1B	2.838	-0.092	2.139	-0.211	2.268	-0.238	2.691	-0.250
	DAT1C	1.029	2.021	0.982	1.266	0.992	1.002	1.010	0.868
	DAT1D	3.048	2.682	2.275	1.587	1.907	1.209	1.719	1.018
	DAT1E	1.033	-0.048	1.311	-0.046	2.031	-0.049	3.588	-0.052
	DAT1F	3.003	-0.280	3.444	-0.278	5.072	-0.281	7.864	-0.284

TABELL 21

<u>k</u>	<u>Varians</u>	<u>Medelfel</u>	<u>B</u>	<u>DAT1()</u>
1	<u>0.353</u>	-0.052	0.88	E
1	1.591	<u>-0.028</u>	0.91	B
2	<u>0.983</u>	-0.048	0.97	A
2	1.894	<u>-0.041</u>	0.94	B
3	<u>0.976</u>	-0.050	0.97	A
3	2.653	<u>0.028</u>	0.97	B
6	<u>0.985</u>	-0.051	0.97	A
6	2.684	<u>-0.013</u>	0.97	B
12	<u>0.982</u>	1.266	0.94	C
12	1.311	<u>-0.046</u>	0.94	E

De understrukna värdena i tabellen ovan betecknar minima-värdena.

6.2 Svängningsdata

Nivån befanns vara 20.0 vilket var lika med den som användes vid genereringen (se kapitel 4.1.2). Periodens längd befanns vara 24 månader.

P.s.s. som vid trenddata (DAT1-data) fås nedanstående redovisade f-vektor, a-vektor och L-matris.

Beteckningarna DAT2A - DAT2F följer samma mönster som redovisades för DAT1A - DAT1F tidigare, men med det undantaget att DAT2 betecknar att data har utseendet enligt DAT2 i datapresentationen (se kapitel 4.1.2).

DAT2A

Anpassningsfunktioner:	a-parametrar:	L-matris:
$f_1(t) = 1$	$a_1(0) = 20.0$	1.0 0.0 0.0
$f_2(t) = \sin(\frac{2\pi \cdot t}{24})$	$a_2(0) = 10.0$	0.0 0.9659 0.2588
$f_3(t) = \cos(\frac{2\pi \cdot t}{24})$	$a_3(0) = 0.0$	0.0 -0.2588 0.9659

DAT2B

Anpassningsfunktioner:	a-parametrar:	L-matris:
$f_1(t) = 1$	$a_1(0) = 0.0$	1.0 0.0 0.0
$f_2(t) = \sin(\frac{2\pi \cdot t}{24})$	$a_2(0) = 0.0$	0.0 0.9659 0.2588
$f_3(t) = \cos(\frac{2\pi \cdot t}{24})$	$a_3(0) = 0.0$	0.0 -0.2588 0.9659

DAT2C

Anpassningsfunktion:	a-parameter:	L-matris:
$f_1(t) = 1$	$a_1(0) = 20.0$	1.0

DAT2D

Anpassningsfunktion:	a-parameter:	L-matris:
$f_1(t) = 1$	$a_1(0) = 0.0$	1.0

DAT2E

Anpassningsfunktioner:

$$\begin{aligned}f_1(t) &= 1 \\f_2(t) &= \sin\left(\frac{2\pi t}{24}\right) \\f_3(t) &= \cos\left(\frac{2\pi t}{24}\right) \\f_4(t) &= \sin\left(\frac{2\pi t}{48}\right) \\f_5(t) &= \cos\left(\frac{2\pi t}{48}\right)\end{aligned}$$

a-parametrar:

$$\begin{aligned}a_1(0) &= 20.0 \\a_2(0) &= 10.0 \\a_3(0) &= 0.0 \\a_4(0) &= 0.0 \\a_5(0) &= 0.0\end{aligned}$$

L-matris:

$$\begin{matrix}1.0 & 0.0 & 0.0 & 0.0 & 0.0 \\0.0 & 0.9659 & 0.2588 & 0.0 & 0.0 \\0.0 & -0.2588 & 0.9659 & 0.0 & 0.0 \\0.0 & 0.0 & 0.0 & 0.9914 & 0.1305 \\0.0 & 0.0 & 0.0 & -0.1305 & 0.9914\end{matrix}$$

DAT2F

Anpassningsfunktioner:

$$\begin{aligned}f_1(t) &= 1 \\f_2(t) &= \sin\left(\frac{2\pi t}{24}\right) \\f_3(t) &= \cos\left(\frac{2\pi t}{24}\right) \\f_4(t) &= \sin\left(\frac{2\pi t}{48}\right) \\f_5(t) &= \cos\left(\frac{2\pi t}{48}\right)\end{aligned}$$

a-parametrar:

$$\begin{aligned}a_1(0) &= 0.0 \\a_2(0) &= 0.0 \\a_3(0) &= 0.0 \\a_4(0) &= 0.0 \\a_5(0) &= 0.0\end{aligned}$$

L-matris:

$$\begin{matrix}1.0 & 0.0 & 0.0 & 0.0 & 0.0 \\0.0 & 0.9659 & 0.2588 & 0.0 & 0.0 \\0.0 & -0.2588 & 0.9659 & 0.0 & 0.0 \\0.0 & 0.0 & 0.0 & 0.9914 & 0.1305 \\0.0 & 0.0 & 0.0 & -0.1305 & 0.9914\end{matrix}$$

Vid körsning erhöll vi de i tabell 22 redovisade resultaten på medelfel och varians för olika prediktionssteg, k, och olika viktfaktorer, β .

En genomgående tendens för de olika typerna av data, är att om prediktionssteget är litet skall en låg viktfaktor, β , väljas. Om prediktionssteget däremot är stort, skall en viktfaktor, β , med högt värde väljas.

Tabell 22.

		$\beta = 0.97$		$\beta = 0.94$		$\beta = 0.91$		$\beta = 0.88$	
		Var.	Medf.	Var.	Medf.	Var.	Medf.	Var.	Medf.
k=1	DAT2A	3.81	0.026	3.88	0.026	3.81	0.026	3.69	0.025
	DAT2B	16.32	1.266	9.59	0.585	7.04	0.352	5.80	0.233
	DAT2C	49.35	-0.041	45.43	-0.046	40.12	-0.048	33.91	-0.047
	DAT2D	62.55	1.254	53.20	0.582	45.85	0.357	38.52	0.247
	DAT2E	3.76	0.026	3.78	0.025	3.62	0.024	3.51	0.023
	DAT2F	13.77	1.166	6.88	0.454	5.19	0.219	4.84	0.117
k=2	DAT2A	3.99	0.023	4.29	0.024	4.49	0.023	4.73	0.023
	DAT2B	17.89	1.340	11.32	0.657	8.81	0.419	7.69	0.294
	DAT2C	52.62	-0.052	51.89	-0.058	49.47	-0.063	45.51	-0.065
	DAT2D	65.60	1.246	59.53	0.571	55.17	0.343	50.19	0.230
	DAT2E	4.09	0.023	4.59	0.022	5.20	0.022	6.36	0.020
	DAT2F	16.68	1.316	9.19	0.580	7.66	0.311	8.59	0.174
k=3	DAT2A	3.97	0.017	4.24	0.017	4.43	0.018	4.66	0.018
	DAT2B	18.88	1.401	12.37	0.719	9.70	0.481	8.36	0.353
	DAT2C	55.71	-0.070	58.34	-0.078	59.15	-0.085	57.99	-0.089
	DAT2D	65.16	1.231	65.48	0.553	64.45	0.322	62.38	0.206
	DAT2E	4.05	0.017	4.54	0.017	5.25	0.018	6.78	0.019
	DAT2F	19.27	1.461	10.88	0.710	8.69	0.413	9.93	0.248
k=6	DAT2A	4.01	0.011	4.25	0.011	4.38	0.011	4.55	0.011
	DAT2B	20.24	1.503	14.82	0.844	12.50	0.622	10.92	0.502
	DAT2C	62.81	-0.128	74.49	-0.137	85.39	-0.148	94.37	-0.158
	DAT2D	73.21	1.181	79.62	0.497	88.85	0.261	97.16	0.139
	DAT2E	4.08	0.010	4.50	0.010	5.41	0.008	8.30	0.006
	DAT2F	27.49	1.834	18.74	1.103	14.48	0.768	16.36	0.531
k=12	DAT2A	4.01	0.034	4.25	0.035	4.33	0.035	4.37	0.035
	DAT2B	14.47	1.252	10.59	0.657	10.23	0.507	10.25	0.457
	DAT2C	58.44	-0.181	69.72	-0.179	85.02	-0.180	102.96	-0.183
	DAT2D	66.03	1.143	71.52	0.463	84.86	0.235	102.03	0.117
	DAT2E	4.09	0.034	4.32	0.034	4.59	0.034	6.16	0.035
	DAT2F	33.11	2.005	32.42	1.518	29.49	1.348	28.22	1.181

I tabell 23 redovisas medelfelsminimum och variansminimum för prediktionsstegen 1, 2, 3, 6 och 12 månader.

TABELL 23

k	Varians	Medelfel	β	DAT2()
1	<u>3.509</u>	0.023	0.88	E
1	3.509	<u>0.023</u>	0.88	E
2	<u>3.993</u>	0.023	0.97	A
2	6.360	<u>0.020</u>	0.88	E
3	<u>3.973</u>	0.017	0.97	A
3	4.054	<u>0.017</u>	0.97	E
6	<u>4.009</u>	0.011	0.97	A
6	8.296	<u>0.006</u>	0.88	E
12	<u>4.014</u>	0.034	0.97	A
12	4.014	<u>0.034</u>	0.97	A

De understrukna värdena i tabellen ovan betecknar minimavärdena.

6.3 Metod för att bestämma parametrar i modellen

Trenddata (DAT1)

Om man startar med startparametrar som erhållits ur dataprogrammet MINKO (se appendix A2) kommer prediktionen hela tiden att variera med liten avvikelse kring trenden (se figur 6.1). Väljer man däremot alla startparametrar till noll, behöver prediktionen en viss tid för att svänga in sig, vilket framgår av figur 6.2. När den gjort detta, kommer prediktionen även här att fluktuera med liten avvikelse kring trenden.

Ökningen av summa prediktionsfel i kvadrat är i båda fallen lika. Detta framgår av figurerna 6.3 och 6.4. Detta har till följd, att om startparametrarna väljs lika med noll får totalt högre varians, trots att variansen under de sista 300 tidpunkterna är lika.

Svängningsdata (DAT2)

Då startparametrarna är valda till noll (DAT2B) beror insvängningstiden av valet av viktfaktorn, β . Detta framgår i figurerna 6.5 och 6.6 där $\beta = 0.97$ resp. 0.88 .

Även här är variansen lika efter insvängningen för de båda fallen (se figurerna 6.7 och 6.8).

Slutsats

Då vi för den fortsatta användningen av dataprogrammet GEEP behöver ett sätt att välja a-parametrar, studerade vi varians- och medelfelsminimum för de olika prediktionsstegen, k , vilka framgår av tabellerna 22 och 24.

Av dessa två tabeller kan man erhålla följande sammanställning:

Modell	VARIANSMINIMUM		MEDELFELSMINIMUM		
	Antal		Antal		
Modell	DAT1	DAT2	Modell	DAT1	DAT2
A	= 4	+ 3 = 7	A	= 1	+ 0 = 1
B	=	= 0	B	= 0	+ 4 = 4
C	= 0	+ 1 = 1	C	=	= 0
D	=	≈ 0	D	=	= 0
E	= 1	+ 1 = 2	E	= 4	+ 1 = 5
F	=	= 0	F	=	= 0

I tabellen ovan framgår det att för att erhålla variansminimum, bör man välja metod A och för att få medelfelsminimum metod E. Eftersom det är svårt att i metod E bestämma den extra anpassningsfunktionen (ev. anpassningsfunktioner), har vi endast använt metod A.




Fig. 6.1 Prediktionen av trenddata (DAT1) med generell exponentiell utjämnning då startparametrarna erhållits ur dataprogrammet MINKO. $k=1$ och $\beta = 0.91$. Trenddata = I, Prediktionen av trenddata = \hat{x} .




Fig. 6.2 Prediktionen av trenddata (DAT1) med generellt exponentiell utjämning då startparameterna sätts lika med noll. $k=1$ och $\beta = 0.91$. Trenddata = I, Prediktionen av trenddata = \bar{x} .




Fig. 6.3 Summa prediktionsfel i kvadrat vid prediktion av trenddata med generell exponentiell utjämning med $k=1$ och $\beta=0.91$. Startparametrarna har erhållits ur dataprogrammet MINKO.




Fig. 6.4 Summa prediktionsfel i kvadrat vid prediktion av trenddata med generell exponentiell utjämnning med $k=1$ och $\beta=0.91$. Startparametrarna har satts till noll.




Fig. 6.5 Prediktionen av svängningsdata (DAT2) med generell exponentiell utjämning då startparametrarna satts lika med noll. $k=3$ och $S = 0.97$. Svängningsdata = I, Prediktionen av svängningsdata = \bar{x} .




Fig. 6.6 Prediktionen av svängningsdata (DAT2) med generell exponentiell utjämning då startparametra satts lika med noll. $\lambda=3$ och $\beta = 0.88$. Svängningsdata = I, Prediktionen av svängningsdata = \hat{x} .




Fig. 6.7 Summa prediktionsfel i kvadrat vid prediktion av svängningsdata med generell exponentiell utjämning då startparameterna sätts lika med noll. $k=3$ och $\beta = 0.97$.




Fig. 6.8 Summa prediktionsfel i kvadrat vid prediktion av svängningsdata med generell exponentiell utjämning då startparametrarna satts lika med noll. $k=3$ och $\beta = 0.88$

7. PREDIKTIONSRESULTAT MED GENERELL EXPONENTIELL UTJÄMNING

7.1 Företagsdata

Redan vid projektarbetet / 2 / framkom att dessa data har en årligen återkommande tidpunkt, juli månad, vars värde starkt avviker från övriga. Detta medförde att det uppstod svårigheter vid prediktering av dessa data.

För att undersöka denna månads inverkan, modifierades data genom att julivärdet ersattes med samma års junivärdet, i avsikt att kunna bedömma julimånadernas inverkan på prediktionen.

Först kommer de ursprungliga data att behandlas och därefter de modifierade, där julivärdet ersatts med junivärdet.

För att ha ett facit, byggdes modellen endast på de 96 första data.

7.1.1 Okorrigerade Företagsdata

Med hjälp av IDPAC / 5 / bestämdes 1:a, 2:a och 3:e ordningens trend (se figur 7.1). Härvid framgick det att det knappast kunde löna sig att använda en 3:e ordningens modell. Om vi skulle använda en 1:a eller 2:a ordningens modell, bestämdes genom att testa dessa i MINKO (se appendix A2).

För att bestämma periodicitet beräknas kovariansfunktionen för residualerna (se figur 7.2).

Följande modeller testades i MINKO:

1.

Anpassningsfunktioner:

$$f_1(t) = 1$$

$$f_2(t) = t$$

$$f_3(t) = \sin\left(\frac{2\pi \cdot t}{6}\right)$$

$$f_4(t) = \cos\left(\frac{2\pi \cdot t}{6}\right)$$

$$f_5(t) = \sin\left(\frac{2\pi \cdot t}{12}\right)$$

$$f_6(t) = \cos\left(\frac{2\pi \cdot t}{12}\right)$$

Detta medförde att a-parametrarna blev:

$$a_1(0) = 4459.59$$

$$a_2(0) = 102.74$$

$$a_3(0) = -1872.37$$

$$a_4(0) = -846.40$$

$$a_5(0) = 11.27$$

$$a_6(0) = 731.31$$

Följande förlustfunktionsvärdet erhölls, $F = 1.573 \cdot 10^9$

2.

Anpassningsfunktioner:

$$f_1(t) = 1$$

$$f_2(t) = t$$

$$f_3(t) = \sin\left(\frac{2\pi \cdot t}{6}\right)$$

$$f_4(t) = \cos\left(\frac{2\pi \cdot t}{6}\right)$$

$$f_5(t) = \sin\left(\frac{2\pi \cdot t}{12}\right)$$

$$f_6(t) = \cos\left(\frac{2\pi \cdot t}{12}\right)$$

$$f_7(t) = \sin\left(\frac{2\pi \cdot t}{5}\right)$$

$$f_8(t) = \cos\left(\frac{2\pi \cdot t}{5}\right)$$

$$f_9(t) = \sin\left(\frac{2\pi \cdot t}{7}\right)$$

$$f_{10}(t) = \cos\left(\frac{2\pi \cdot t}{7}\right)$$

Detta medförde att a-parametrarna blev:

$$a_1(0) = 4461.27$$

$$a_2(0) = 102.70$$

$$a_3(0) = -1870.66$$

$$a_4(0) = -859.87$$

$$a_5(0) = 11.47$$

$$a_6(0) = 726.97$$

$$a_7(0) = 245.20$$

$$a_8(0) = -43.32$$

$$a_9(0) = -129.87$$

$$a_{10}(0) = 34.98$$

Följande förlustfunktionsvärdet erhölls, $F = 1.566 \cdot 10^9$

3.

Anpassningsfunktioner:

$$f_1(t) = 1$$

$$f_2(t) = t$$

$$\begin{aligned}
 f_3(t) &= t(t-1)/2 \\
 f_4(t) &= \sin\left(\frac{2\pi \cdot t}{12}\right) \\
 f_5(t) &= \cos\left(\frac{2\pi \cdot t}{12}\right) \\
 f_6(t) &= \sin\left(\frac{2\pi \cdot t}{3}\right) \\
 f_7(t) &= \cos\left(\frac{2\pi \cdot t}{3}\right) \\
 f_8(t) &= \sin\left(\frac{2\pi \cdot t}{6}\right) \\
 f_9(t) &= \cos\left(\frac{2\pi \cdot t}{6}\right)
 \end{aligned}$$

Detta medförde att a-parametrarna blev:

$$\begin{aligned}
 a_1(0) &= 6457.88 \\
 a_2(0) &= 55.07 \\
 a_3(0) &= 0.19 \\
 a_4(0) &= 151.17 \\
 a_5(0) &= 720.31 \\
 a_6(0) &= -913.98 \\
 a_7(0) &= 316.96 \\
 a_8(0) &= -1225.33 \\
 a_9(0) &= -448.37
 \end{aligned}$$

Följande förlustfunktionsvärde erhölls, $F = 1.257 \cdot 10^9$

Eftersom förlustfunktionsvärdet för alternativ 3 är lägre än för övriga alternativ, väljer vi att använda detta alternativ.

L-matrisen för alternativ 3 har utseendet:

$$\begin{matrix}
 1.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 \\
 1.0 & 1.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 \\
 0.0 & 1.0 & 1.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 \\
 0.0 & 0.0 & 0.0 & 0.866 & 0.500 & 0.0 & 0.0 & 0.0 & 0.0 \\
 0.0 & 0.0 & 0.0 & -0.500 & 0.866 & 0.0 & 0.0 & 0.0 & 0.0 \\
 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & -0.500 & 0.866 & 0.0 & 0.0 \\
 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & -0.866 & -0.500 & 0.0 & 0.0 \\
 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.500 & 0.866 \\
 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & 0.0 & -0.866 & 0.500
 \end{matrix}$$

Vid körning i dataprogrammet GEXP, erhöll vi följande resultat på medelfel och varians för prediktionsstegen, k , lika med 1, 2, 3, 6 och 12 och viktfaktorerna, β , lika med 0.97, 0.94 och 0.91.

TABELL 24

	$\beta = 0.97$		$\beta = 0.94$		$\beta = 0.91$	
k	Varians	Medelfel	Varians	Medelfel	Varians	Medelfel
1	$9.179 \cdot 10^6$	158.46	$7.773 \cdot 10^6$	-28.50	$20.341 \cdot 10^6$	-80.03
2	$11.651 \cdot 10^6$	200.43	$13.160 \cdot 10^6$	-8.42	$17.169 \cdot 10^6$	-88.40
3	$11.480 \cdot 10^6$	233.43	$12.289 \cdot 10^6$	24.79	$18.281 \cdot 10^6$	-83.68
6	$12.150 \cdot 10^6$	305.42	$13.411 \cdot 10^6$	108.93	$18.830 \cdot 10^6$	9.31
12	$13.904 \cdot 10^6$	425.11	$20.922 \cdot 10^6$	289.40	$60.527 \cdot 10^6$	220.65

Figurerna 7.3 - 7.5 visar prediktionen för prediktionssteget, k, lika med en månad för viktfaktorerna, β , 0.97, 0.94 och 0.91. En viss förbättring av varians och medelfel kan iaktagas, då viktfaktorn, β , minskas från 0.97 till 0.94. En ytterligare minskning till 0.91 medför en kraftig ökning av variansen. Då $\beta = 0.88$ blir variens och medelfel oändligt stort.

Figur 7.6 visar prediktionsfelet för viktfaktorn, β , lika med 0.94 och prediktionssteget k lika med en månad. Summa preeiktionsfel i kvadrat för viktfaktorn $\beta = 0.94$ och prediktionssteget k=1 framgår av figur 7.7.

Då prediktionssteget ökar måste viktfaktorn, β , minskas för att erhålla medelfelsminimum och ökas för att få minsta varians.




Fig. 7.1 Okorrigerade Företagsdata med inlagd 2:a ordningens trend.




Fig. 7.2 Kovariansfunktionen för residualerna.




Fig. 7.3 Prediktionen av okorrigerade Företagsdata med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta = 0.97$.




Fig. 7.4 Prediktionen av okorrigerade Företagsdata med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta=0.94$.




Fig. 7.5 Prediktionen av okorrigerade Företagsdata med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta = 0.91$.




Fig. 7.6 Prediktionsfelet vid prediktion av okorrigerade Företagsdata med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta=0.94$.




Fig. 7.7 Summa prediktionsfel i kvadrat vid prediktering av okorrigerade Företagsdata med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta=0.94$.

7.1.2 Korrigrade Företagsdata

Trenden av 1:a, 2:a och 3:e ordningen bestämdes m.h.a. IDPAC / 5 / (se figur 7.8). Härvid framgick det att dataserien hade en 2:a ordningens trend.

Genom att beräkna kovariansfunktionen för residualerna (se figur 7.9) bestämdes periodiciteten.




Fig. 7.9 Kovariansfunktionen för residualerna.

I MINKO användes anpassningsfunktionerna:

$$f_1(t) = 1$$

$$f_2(t) = t$$

$$f_3(t) = t(t-1)/2$$

$$f_4(t) = \sin\left(\frac{2\pi \cdot t}{3}\right)$$

$$f_5(t) = \cos\left(\frac{2\pi \cdot t}{3}\right)$$

$$f_6(t) = \sin\left(\frac{2\pi \cdot t}{6}\right)$$

$$f_7(t) = \cos\left(\frac{2\pi \cdot t}{6}\right)$$

$$f_8(t) = \sin\left(\frac{2\pi \cdot t}{12}\right)$$

$$f_9(t) = \cos\left(\frac{2\pi \cdot t}{12}\right)$$

Detta medförde att a-parametrarna blev:

$$a_1(0) = 4532.35$$

$$a_2(0) = 112.73$$

$$a_3(0) = -0.03$$

$$a_4(0) = 95.83$$

$$a_5(0) = 0.04$$

$$a_6(0) = -489.80$$

$$a_7(0) = -64.10$$

$$a_8(0) = -750.43$$

$$a_9(0) = -645.14$$

Förlustfunktionsvärdet, F, blev: $8.583 \cdot 10^8$

L-matrisen har utseendet enligt nedan:

1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
0.0	0.0	0.0	-0.500	0.866	0.0	0.0	0.0	0.0	0.0
0.0	0.0	0.0	-0.866	-0.500	0.0	0.0	0.0	0.0	0.0
0.0	0.0	0.0	0.0	0.0	0.500	0.866	0.0	0.0	0.0
0.0	0.0	0.0	0.0	0.0	-0.866	0.500	0.0	0.0	0.0
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.866	0.500	0.0
0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.500	0.866	0.0

Vid körning i dataprogrammet GEXP erhölls de värden på medelfel och varians, som finns redovisade i tabell 25, för prediktionsstegen, $k=1, 2, 3, 6$ och 12 månader och viktfaktorerna, $\beta=0.97, 0.94$ och 0.91 .

TABELL 25

	$\beta = 0.97$		$\beta = 0.94$		$\beta = 0.91$	
k	Varians	Medelfel	Varians	Medelfel	Varians	Medelfel
1	$2.652 \cdot 10^6$	138.37	$1.679 \cdot 10^6$	-49.03	$3.550 \cdot 10^6$	-98.54
2	$3.795 \cdot 10^6$	171.63	$4.152 \cdot 10^6$	-31.34	$6.263 \cdot 10^6$	-135.62
3	$3.997 \cdot 10^6$	183.61	$4.386 \cdot 10^6$	-13.89	$6.679 \cdot 10^6$	-121.28
6	$4.390 \cdot 10^6$	208.80	$4.739 \cdot 10^6$	20.50	$6.185 \cdot 10^6$	-107.80
12	$5.468 \cdot 10^6$	288.02	$7.038 \cdot 10^6$	189.05	$16.165 \cdot 10^6$	126.64

Då prediktionsstegget, k, är lika med en månad och viktfaktorn, β , är 0.97, följer prediktionen bra stora systematiska förändringar, men ändå inte alls små variationer (se figur 7.10). Då viktfaktorn, β , minskas till 0.94 fås en förbättring av prediktionen då även små variationer följs (se figur 7.11). Prediktionen blir ej bra om viktfaktorn, β , väljs till 0.91, vilket framgår av figur 7.12.

Den omtalade fusionen som inträffade månad 153, framgår tydligt av figurerna 7.13 och 7.14.

För att erhålla medelfelsminimum måste viktfaktorn, β , minskas, men denna måste ökas om variansminimum önskas.

7.1.3 Problem med generell exponentiell utjämning på Företagsdata

Vid prediktering med generell exponentiell utjämning av Företagsdata, speciellt okorrigerade data, är det svårt att bestämma anpassningsfunktionerna och därfor blir prediktionsresultatet ganska dåligt.

När man bestämt anpassningsfunktionerna, går det ej att ändra dessa under predikteringen, vilket medför att om dataserien ändrar utseende, blir prediktionen dålig. Denna nackdel finns också i den heuristiska metoden. Vidare kan instabilitet vid lägre viktfaktorer, β , iaktagas. Orsaken till detta är att om ett relativt stort prognosfel uppkommer, korrigeras ingående parametrar kraftigt och nästa prediktion kommer att avvika ännu mer från sitt rätta värde.




Fig. 7.8 Korrigrade Företagsdata med inlagd 2:a ordningens trend.




Fig. 7.10 Prediktionen av korrigersde Företagsdata med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta = 0.97$.




Fig. 7.11 Prediktionen av korrigrade Företagsdata med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta = 0.94$.




Fig. 7.12 Prediktionen av korrigrade Företagsdata med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta=0.91$.




Fig. 7.13 Prediktionsfelet vid prediktion av korrigerade Företags-data med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta=0.94$.




Fig. 7.14 Summa prediktionsfel i kvadrat vid korrigerade Företags-data med generell exponentiell utjämning med prediktionssteget, $k=1$ och $\beta=0.94$.

7.2 Flygdata.

Med hjälp av IDPAC / 5 / bestämdes 1:a, 2:a och 3:e ordningens trend. Härvid framgick det att 2:a ordningens trend (Se figur 7.15) var den som bäst överensstämde med dataseriens utseende. Periodiciteten fastställdes genom att beräkna kovariansfunktionen för residualerna (Se figur 7.16).




Fig. 7.16 Kovariansfunktionen för residualerna.

Följade modell testades i MINKO :

Anpassningsfunktioner:

$$f_1(t) = 1$$

$$f_2(t) = t$$

$$f_3(t) = t(t-1)/2$$

$$f_4(t) = \sin\left(\frac{2\pi}{12}t\right)$$

$$f_5(t) = \cos\left(\frac{2\pi}{12}t\right)$$




Fig. 7.15 Flygdata med inlagd 2:a ordningsens trend.

Detta medförde att a-parametrarna blev:

$$a_1(0) = 118.77$$

$$a_2(0) = 1.23$$

$$a_3(0) = 0.03$$

$$a_4(0) = -9.10$$

$$a_5(0) = -29.45$$

Följade förlustfunksvärde erhölls, $F = 3.846 \cdot 10^4$.

Denna modell valdes som indata till GEXP.

Modellens L-matris har utseendet:

$$\begin{matrix} 1.0 & 0.0 & 0.0 & 0.0 & 0.0 \\ 1.0 & 1.0 & 0.0 & 0.0 & 0.0 \\ 0.0 & 1.0 & 1.0 & 0.0 & 0.0 \\ 0.0 & 0.0 & 0.0 & 0.866 & 0.500 \\ 0.0 & 0.0 & 0.0 & -0.500 & 0.866 \end{matrix}$$

Vid körning erhölls följande resultat på medelfel och varians för prediktionsstegen, $k=1, 2, 3, 6$ och 12 och viktfaktorerna, $\beta=0.97, 0.94, 0.91$ och 0.88 .

Tabell 26.

	$\beta=0.97$		$\beta=0.94$		$\beta=0.91$		$\beta=0.88$	
k	Var.	Medf.	Var.	Medf.	Var.	Medf.	Var.	Medf.
1	778.9	-2.91	560.3	-2.16	383.6	-2.02	346.2	-2.01
2	1027.1	-3.27	1048.4	-2.44	1132.8	-2.23	1239.0	-2.03
3	1170.4	-3.66	1361.9	-2.84	1759.4	-2.77	2277.4	-2.70
6	1169.7	-3.76	1164.3	-2.63	1222.4	-2.49	1639.8	-2.70
12	992.7	-4.03	922.3	-2.30	1272.5	-1.72	2937.4	-1.95

Prediktionen för prediktionssteget lika med en månad ($k=1$) och för viktfaktorerna $\beta=0.97$ och $\beta=0.88$ visas i figurerna 7.17 och 7.18. Här framgår att $\beta=0.88$ ger en betydligt bättre prediktion beroende på att den kan anpassa den antagna sinusformade svängningen i data till verkliga data bättre än $\beta=0.97$.

Prediktionsfelet för $k=1$ och $\beta=0.88$ framgår av figur 7.19. Felet uppvisar tydlig sinusform med ökande amplitud, vilket antyder att anpassningsfunktioner av typ $t \cdot \sin(\frac{2\pi t}{12})$ borde ha medtagits.

Den trappstegsformade branta ökningen i figur 7.20, som visar summa prediktionsfel i kvadrat, beror på prediktionsfelets ökande amplitud.

Jämfört med prediktion med den heuristiska metoden, på dessa data, fås här med den generella exponentiella utjämningen högre varians. Detta beror på, trots datas ökande amplitud, att en månads andel av säsongsvärdet är relativt konstant, oberoende vilken säsong som betraktas, vilket medför att den heuristiska metoden kan prediktera både toppar och dalar bra. Generell exponentiell utjämning kan ej följa med amplitudökningen så bra, vilket medför att variansen blir högre än för den heuristiska metoden.

Prediktionen för prediktionsstegen, $k=6$ och 12 månader med viktfaktorn, $\beta = 0.94$ visas i figurerna 7.21 och 7.22.

För Flygdata skall man för att få varians- och medelfelsminimum, öka viktfaktorn, β , för längre prediktionssteg.




Fig. 7.17 Prediktionen av Flygdata med generellt exponentiell utveckling med $k=1$, och $\beta=0.97$. Flygdata = I, Prediktionen är Flygdata = \hat{x} .




Fig. 7.18 Prediktionen av Flygdata med generellt exponentiell utjämning med $k=1$ och $\beta=0.88$. Flygdata = I, Prediktionen av Flygdata = π .




Fig. 7.19 Prediktionsfellet vid prediktion av Flygdata med generell exponentiell utjämning med $k=1$ och $\beta=0.88$.




Fig. 7.20 Summa prediktionsfel i kvadrat vid prediktion av Flygdata med generell exponentiell utjämning med $k=1$ och $\beta=0.88$.




Fig. 7.21 Prediktionen av Flygdata med generellt exponentiell utjämnning med $k=6$ och $\beta=0.94$. Flygdata = I, Prediktionen av Flygdata = π .




Fig. 7.22 Prediktionen av Flygdata med generell exponentiell utjämning med $k=12$ och $\beta=0.94$. Flygdata = I, prediktionen av Flygdata = \hat{I} .

7.3 Skogsdata.

Genom att använda IDPAC / 5 / bestämdes 1:a, 2:a och 3:e ordningens trend (Se figur 7.23). Första ordningens trend överensstämde bäst med dataseriens utseende.

Periodiciteten fastställdes genom att beräkna kovariansfunktionen för residualerna (Se figur 7.24).




Fig. 7.24 Kovariansfunktion för residualerna.

Följande modell testades i MINKO:

Anpassningsfunktionerna:

$$f_1(t) = 1$$

$$f_2(t) = t$$

$f_3(t)$

$$f_3(t) = \sin\left(\frac{2\pi t}{12}\right)$$




Fig. 7.23 Skogsdata med inlagd 1:a ordningens trend.

$$f_4(t) = \cos\left(\frac{2\pi t}{12}\right)$$

$$f_5(t) = \sin\left(\frac{2\pi t}{6}\right)$$

$$f_6(t) = \cos\left(\frac{2\pi t}{6}\right)$$

Detta medförde att a-parametrarna fick värdena:

$$a_1(0) = 327.85$$

$$a_2(0) = 3.37$$

$$a_3(0) = -43.08$$

$$a_4(0) = 19.08$$

$$a_5(0) = -43.69$$

$$a_6(0) = -0.90$$

$$\text{Förlustfunktionsvärdet } F = 7.402 \cdot 10^4$$

Denna modell valdes som indata till GEXP.

Modellens L-matris har utseendet:

1.0	0.0	0.0	0.0	0.0	0.0	1.0
1.0	1.0	0.0	0.0	0.0	0.0	0.0
0.0	0.0	0.866	0.500	0.0	0.0	0.0
0.0	0.0	-0.500	0.866	0.0	0.0	0.0
0.0	0.0	0.0	0.0	0.499	0.866	0.0
0.0	0.0	0.0	0.0	-0.866	0.499	0.0

Följande resultat på medelfel och varians erhölls för prediktionsstegen, $k=1,2,3,6$ och 12 och viktfaktorerna, $\beta=0.97, 0.94, 0.91$ och 0.88.

Tabell 27.

k	$\beta = 0.97$		$\beta = 0.94$		$\beta = 0.91$		$\beta = 0.88$	
	Var.	Medf.	Var.	Medf.	Var.	Medf.	Var.	Medf.
1	2434.7	-0.13	2243.4	-4.07	1853.7	-4.14	2133.8	-4.00
2	3092.1	-0.37	3569.3	-4.43	3930.9	-4.64	4723.2	-4.06
3	3199.0	-0.11	3766.5	-5.52	4143.2	-6.12	4862.2	-5.69
6	3287.1	-0.30	3941.4	-6.28	4362.1	-7.34	4899.7	-7.26
12	3288.7	1.49	4142.0	-6.45	4982.2	-9.08	7273.6	-9.89

Figur 7.25 visar prediktionen vid prediktionssteget tre månader och med viktfaktorn $\beta = 0.97$

Prediktionsfelet har ökande amplitud (Se fig. 7.26) vilket medför att summa prediktionsfel i kvadrat (Se fig. 7.27) får en ökande lutning.

För alla prediktionssteg utom ett fås minsta varians och medelfel för $\beta=0.97$, d.v.s. stor hänsyn tas till gamla uppmätta data.




Fig. 7.25 Prediktionen av Skogsdata med generell exponentiell utjämning med $k=3$ och $\beta=0.97$. Skogsdata = I, Prediktionen av Skogsdata = *.




Fig. 7.26 Prediktionsfelet vid prediktion av Skogsdata med generell exponentiell utjämning med $k=3$ och $\beta=0.97$.




Fig. 7.27 Summa prediktionsfel i kvadrat vid prediktion av Skogsdata med generell exponentiell utjämning med $k=3$ och $\beta=0.97$.

8. PREDIKTIONSRESULTAT MED MINIMALVARIANS PREDIKTION DÅ KÄND
DEL ÄR FRÅNDRAGEN

Med denna metod behandlade vi Flygdata. Tillvägagångssättet redovisades i kapitel 3.4.1.

8.1 Flygdata

Den kända delen, $y_d(t)$ (se kapitel 7.2), som är baserad på de 96 första data, befanns vara

$$y_d(t) = 118.77 + 1.23 \cdot t + 0.03 \cdot t(t-1)/2 - 9.10 \sin\left(\frac{2\pi \cdot t}{12}\right) - \\ - \cos\left(\frac{2\pi \cdot t}{12}\right)$$

Vid projektarbetet i prognosmetoder / 2 / konstaterades, att en tredje ordningens modell var den som var mest signifikant. Det fastlades också att modellen innehöll en tolvmånaderssvängning.

Vi har i detta arbete valt en femte ordningens modell (se nedanstående hypotestest). Vid kontroll av denna modells poler, får man fram att den innehåller en 12- och en 19-månaderssvängning.

I figur 8.1 finns ursprungsdata och med funktionen genererade data inlagd.

Funktionen $y_d(t)$ subtraherades från ursprungsdata och på återstoden blev modellen m.h.a. ML-identifiering (Se appendix A8) (Se fig. 8.2).

$$y(t) \left[1 - 1.35q^{-1} + 1.80q^{-2} - 0.17q^{-3} + 0.38q^{-4} + 0.06q^{-5} \right] = \\ = 12.43 \left[1 - 0.82q^{-1} + 1.18q^{-2} + 0.46q^{-3} - 0.29q^{-4} + 0.65q^{-5} \right] \cdot e(t)$$

Kovariansfunktionen för residualerna för denna modell framgår av figur 8.3.

Genom identifiering (se kapitel 3.4) erhölls G^* - och F^* -polynom-en enligt nedan

$$\underline{k=1} \quad F(q^{-1}) = 1$$

$$G(q^{-1}) = 0.538 - 0.620q^{-1} + 1.176q^{-2} - 0.662q^{-3} + 0.590q^{-4}$$

$$\underline{k=2} \quad F(q^{-1}) = 1 + 0.538q^{-1}$$

$$G(q^{-1}) = 0.109 + 0.208q^{-1} - 0.277q^{-2} + 0.393q^{-3} - 0.034q^{-4}$$

$$\underline{k=3} \quad F(q^{-1}) = 1 + 0.538q^{-1} + 0.109q^{-2}$$

$$G(q^{-1}) = 0.355 - 0.473q^{-1} + 0.470q^{-2} - 0.074q^{-3} - 0.007q^{-4}$$

$$\underline{k=6} \quad F(q^{-1}) = 1 + 0.538q^{-1} + 0.109q^{-2} + 0.355q^{-3} + 0.008q^{-4} - \\ - 0.157q^{-5}$$

$$G(q^{-1}) = -0.048 + 0.151q^{-1} + 0.138q^{-2} + 0.057q^{-3} + 0.010q^{-4}$$

$$\underline{k=12} \quad F(q^{-1}) = 1 + 0.538q^{-1} + 0.109q^{-2} + 0.355q^{-3} + 0.008q^{-4} - \\ - 0.157q^{-5} - 0.048q^{-6} + 0.086q^{-7} + 0.065q^{-8} - 0.044q^{-9} - \\ - 0.086q^{-10} - 0.021q^{-11}$$

$$G(q^{-1}) = 0.067 - 0.012q^{-1} + 0.020q^{-2} + 0.013q^{-3} + 0.001q^{-4}$$

Sammanfattnings av hypotestesten för val av modellens ordning.

<u>Ordn. (i)</u>	<u>Förlustfunktion (v_i)</u>
1	$1.23 \cdot 10^4$
2	$1.01 \cdot 10^4$
3	$0.93 \cdot 10^4$
4	$0.78 \cdot 10^4$
5	$0.74 \cdot 10^4$

<u>Steget för förlustfunktionen</u>	<u>Testkvantitet</u>	<u>Tabellerat värde</u>
1 → 2	10.0	3.10
2 → 3	3.9	3.10
3 → 5	5.5	2.48
4 → 5	2.3	3.10

C-polynomen i 4:e och 6:e ordningens modeller blev instabila.

5:e ordningens modell valdes, eftersom steget för förlustfunktionen från 4:e till 5:e ordningens modell måste vara mindre eller lika med $V_5 - V_4$ och då detta steg ej är signifikant, kan steget till högre ordning från 5:e ordningen, ej vara signifikant.

Värden på medelfel och varians erhölls enligt nedan
 $\sum_{i=k+4}^{96} (x_i - \hat{x}_i)^2$

<u>k</u>	<u>Medelfel</u>	<u>Varians</u>	<u>Förväntad varians</u>	<u>92-k</u>
1	-3.9	599.8	154.6	438
2	-5.9	725.6	199.3	345
3	-6.2	768.2	201.2	352
6	-6.9	807.3	224.5	230
12	-7.2	796.6	228.1	244

Prediktionen, prediktionsfelet och summa prediktionsfel i kvadrat för prediktionssteget, $k=1$ månad framgår av figureerna 8.4 - 8.6. Figur 8.7 visar prediktionen för prediktionssteget, $k=12$ månader.




Fig. 8.1 Flygdata med den kända delen, $y_d(t)$, inlaggd.




Fig. 8.2 Data som ligger till grund för ML-identifiering
av Flygdata.




Fig. 8.3 Kovariansfunktionen för residualerna för 5:e ordningens modell.




Fig. 8.4 Prediktionen av Flygdata med minimalvariansprediktion
med $k=1$. ——— = prediktionen.




Fig. 8.5 Prediktionsfelet vid prediktion av Flygdata med mini-
malvariansprediktion med $k=1$.




Fig. 8.6 Summa prediktionsfel i kvadrat vid prediktion av Flygdata med minimalvariansprediktion med $k=1$.




Fig. 8.7 Prediktionen av Flygdata med minimalvariansprediktion med $k=12$. ——— = prediktionen.

8.2 Test av hur komplex den kända delen skall vara

För att bestämma den metod, enbart trendavdragning eller känd del fråndragen, som med minimalvariansprediktion ger den bästa prediktionen, testas dessa på genererade data.

Vi har antagit att modellens utseende är

$$y(t) = x(t) + e(t)$$

där $e(t)$ är en stokastisk process med medelvärde noll.

Vi vill jämföra de två redovisade tillvägagångssätten att prediktera med minimalvariansprediktion, på data som har ovanstående utseende.

Konstruktion av data

Vi genererade en serie data, vars utseende var

$$\begin{aligned} y(t) = & -1.20 \cdot y(t-1) + 0.72 \cdot y(t-2) + 1.00 \cdot e(t) - 0.60 \cdot e(t-1) + \\ & + 0.13 \cdot e(t-2) \end{aligned}$$

Denna modell genererar data med en 8-månaderssvängning. Här är $e(t)$ vitt brus tillhörande $N(0,1)$. Till dessa data adderas sedan en nivå, 20.0, och en svängning, $10 \sin\left(\frac{2\pi t}{12}\right)$, (se figur 8.8).

Metod 1. Enbart identifiera trend och därefter göra minimalvariansprediktion

Vi testade en 0:e och en 1:a ordningens trend på de 96 första värdena. Vi valde 0:e ordningens trend med nivån 20.01. Återstoden visas på figur 8.9.

Kovariansfunktionen för residualerna över dessa data framgår av figur 8.10. På dessa data, som visas i figur 8.9, gjordes en 3:e-, 4:e- och 5:e ordningens ML-identifiering (Se appendix A8). Med hjälp av hypotestest undersöktes om någon signifikant förbättring i modellerna erhölls, när ordningen ökades. Vid utförandet av testen utnyttjades förlustfunktionen.




Fig. 8.8 Den genererade dataserien med adderad nivå, 20.0, och en svängning, $10 \sin\left(\frac{2\pi \cdot t}{12}\right)$.




Fig. 8.9 Data som ligger till grund för ML-identifiering enligt metod 1.




Fig. 8.10 Kovariansfunktionen för residualerna för indata.

Sammanfattning av hypotestesten:

<u>Ordn. (i)</u>	<u>Förlustfunktion (V_i)</u>	<u>Steget för förlustfunktionen</u>	<u>Testkvantitet</u>	<u>Tabellerat värde</u>
3	397.07			
4	308.70			
5	308.66			
		$3 \rightarrow 4$	12.60	3.10
		$4 \rightarrow 5$	0.01	3.10

Av tabellen framgår att ingen signifikant förbättring fås, för steget för förlustfunktionen från 4:e till 5:e ordningens modell. En 4:e ordningens modell valdes således.

Kovariansfunktionen för residualerna till modellen framgår av figur 8.11.

Modellen fick följande utseende

$$y(t) \left[1 - 0.53q^{-1} - 0.37q^{-2} - 0.04q^{-3} + 0.72q^{-4} \right] = 2.54 \left[1 - 0.90q^{-1} + 0.71q^{-2} - 0.32q^{-3} + 0.10q^{-4} \right] e(t)$$

Vid kontroll av modellens poler, framkom det att modellen innehöll svängningar med periodicteten tolv och åtta månader. Tolvmånaderssvängningen härrör från den pålagda tolvmånaders sinussvängning och åttamånaderssvängningen från det pålagda dynamiska bruset.

Genom identifiering (se kapitel 3.4) erhölls G^* - och F^* -polynomen, för olika prediktionsstegslängder, k , enligt nedan

$$\begin{aligned} k=1 \quad F^*(q^{-1}) &= 1 \\ G^*(q^{-1}) &= -0.37 + 1.08q^{-1} - 0.28q^{-2} - 0.62q^{-3} \end{aligned}$$

$$\begin{aligned} k=2 \quad F^*(q^{-1}) &= 1 - 0.37q^{-1} \\ G^*(q^{-1}) &= 0.88 - 0.42q^{-1} - 0.63q^{-2} + 0.27q^{-3} \end{aligned}$$

$$\begin{aligned} k=3 \quad F^*(q^{-1}) &= 1 - 0.37q^{-1} + 0.88q^{-2} \\ G^*(q^{-1}) &= 0.05 - 0.31q^{-1} + 0.30q^{-2} - 0.64q^{-3} \end{aligned}$$

$$k=6 \quad F^*(q^{-1}) = 1 - 0.37q^{-1} + 0.88q^{-2} + 0.05q^{-3} - 0.28q^{-4} + 0.17q^{-5}$$

$$G(q^{-1}) = -0.65 + 0.02q^{-1} + 0.21q^{-2} - 0.12q^{-3}$$

k=12 $F(q^{-1}) = 1 - 0.37q^{-1} + 0.88q^{-2} + 0.05q^{-3} - 0.28q^{-4} + 0.17q^{-5} - 0.65q^{-6} - 0.32q^{-7} - 0.20q^{-8} - 0.37q^{-9} + 0.19q^{-10} + 0.19q^{-11}$

$$G(q^{-1}) = 0.29 + 0.35q^{-1} - 0.13q^{-2} - 0.13q^{-3}$$

Värden på varians och medelfel:

$$\frac{\sum_{i=k+4}^{96} (x_i - \bar{x}_i)^2}{92-k}$$

<u>k</u>	<u>Medelfel</u>	<u>Varians</u>	<u>Förväntad varians</u>	
1	-0.03	3.72	6.45	3.60
2	-0.06	6.30	7.33	6.56
3	-0.01	9.07	12.33	9.40
6	-0.03	9.61	13.04	9.80
12	0.01	11.10	18.03	10.95

Figurerna 8.12 – 8.14 visar prediktionen, prediktionsfelet och summa prediktionsfel i kvadrat för prediktionssteget, k=1 månad.




Fig 8.11 Kovariansfunktionen för residualerna till 4:e ordningens modell.




Fig. 8.12 Prediktionen av data enligt metod 1 med minimalvariansprediktion med $k=1$. —— = prediktionen.




Fig. 8.13 Prediktionsfelet vid prediktion av data enligt metod med minimalvariansprediktion med $k=1$.




Fig. 8.14 Summa prediktionsfel i kvadrat av data enligt metod
1 med minimalvariansprediktion med $k=1$.

Metod 2 Identifiera trend och svängning och därefter görs minmalvariansprediktion

Från metod 1 framgick att det fanns en nivå och av figur 8.10 framgick det att det fanns en tolvåraderssvängning. Parametrarna för dessa bestämdes i dataprogrammet MINKO (se appendix A2).

Funktionens utseende blev

$$20.01 + 10.01 \sin\left(\frac{2\pi t}{12}\right) + 0.08 \cos\left(\frac{2\pi t}{12}\right)$$

Denna funktion dras ifrån den genererade dataserien och återstoden visas i figur 8.15. Kovariansfunktionen för residualerna över dessa data framgår av figur 8.16.

På de data som visades i figur 8.15 gjordes en 1:a, 2:a och 3:e ordningens ML-identifiering (Se appendix A8).

P.s.s. som i metod 1 gjordes m.h.a. hypotestest en undersökning, om någon signifikant förbättring i modellerna erhölls, då ordningen ökades. Även här utnyttjades förlustfunktionen vid utförandet av testen.

Sammanfattning av hypotestesten:

<u>Ordn. (i)</u>	<u>Förlustfunktionen (v_i)</u>
1	87.77
2	42.07
3	41.92

<u>Steget för förlustfunktionen</u>	<u>Testkvantitet</u>	<u>Tabellerat värde</u>
1 → 2	49.8	3.10
2 → 3	1.4	3.10

Andra ordningens modell valdes, eftersom ingen signifikant förbättring erhölls för steget för förlustfunktionen från 2:a till 3:e ordningens modell.

Kovariansfunktionen för residualerna till modellen framgår av figur 8.17.




Fig. 8.15 Data som ligger till grund för ML-identifiering enligt metod 2.




Fig. 8.16 Kovariansfunktionen för residualerna för indata.




Fig. 8.17 Kovariansfunktionen för residualerna till 2:a ordningens modell.

Modellen fick utseendet

$$y(t) \left[1 + 1.26q^{-1} + 0.74q^{-2} \right] = 0.94 \left[1 - 0.72q^{-1} + 0.17q^{-2} \right] e(t)$$

Vid kontroll av modellens poler, då 12-månaderssvängningen dragits ifrån, konstaterades att endast 8-månaderssvängningen från det dynamiska bruset återstod.

Genom identifiering (se kapitel 3.4) blev $\hat{F}(q^{-1})$ och $\hat{G}(q^{-1})$ polynomen för olika prediktionsstegslängder, k.

$$\begin{aligned} k=1 \quad \hat{F}(q^{-1}) &= 1 \\ \hat{G}(q^{-1}) &= -1.98 - 0.57q^{-1} \end{aligned}$$

$$\begin{aligned} k=2 \quad \hat{F}(q^{-1}) &= 1 - 1.98q^{-1} \\ \hat{G}(q^{-1}) &= 1.94 + 1.46q^{-1} \end{aligned}$$

$$\begin{aligned} k=3 \quad \hat{F}(q^{-1}) &= 1 - 1.98q^{-1} + 1.94q^{-2} \\ \hat{G}(q^{-1}) &= -0.99 - 1.43q^{-1} \end{aligned}$$

$$\begin{aligned} k=6 \quad \hat{F}(q^{-1}) &= 1 - 1.98q^{-1} + 1.94q^{-2} - 0.99q^{-3} - 0.17q^{-4} + 0.95q^{-5} \\ \hat{G}(q^{-1}) &= -1.07 - 0.70q^{-1} \end{aligned}$$

$$\begin{aligned} k=12 \quad \hat{F}(q^{-1}) &= 1 - 1.98q^{-1} + 1.94q^{-2} - 0.99q^{-3} - 0.17q^{-4} + 0.95q^{-5} - \\ &\quad - 1.07q^{-6} + 0.66q^{-7} - 0.07q^{-8} - 0.43q^{-9} + 0.57q^{-10} - \\ &\quad - 0.41q^{-11} \\ \hat{G}(q^{-1}) &= 0.10 + 0.30q^{-1} \end{aligned}$$

Följande värden på varians och medelfel erhölls:

<u>k</u>	<u>Medelfel</u>	<u>Varians</u>	<u>Förväntad varians</u>	$\frac{\sum_{i=k+4}^{96} (x_i - \bar{x}_i)^2}{92-k}$
1	-0.93	1.01	0.88	0.88
2	0.04	4.88	4.35	4.67
3	-0.05	8.14	7.67	8.10
6	-0.06	9.69	9.36	9.63
12	0.01	10.72	10.35	10.05

För prediktionssteget, $k=1$ månad visas, prediktionen, prediktionsfel och summa prediktionsfel i kvadrat, i figurerna 8.18 – 8.20.




Fig. 8.18 Prediktionen av data enligt metod 2 med minimalvariansprediktion med $k=1$. ----- = prediktionen.




Fig. 8.19 Prediktionsfelet vid prediktion av data enligt metod 2 med minimalvariansprediktion med $k=1$.




Fig. 8.20 Summa prediktionsfel i kvadrat vid prediktion av data enligt metod 2 med minimalvariansprediktion med $k=1$.

Den kända delens komplexitet

Den bästa variansen fås då den kända delen dras ifrån innan ML-identifiering och minimalvariansprediktion görs. Vid minimalvariansprediktion av Flygdata efter trendavdragning / 2 / erhölls, med prediktionssteget en månad, variansen 599.5 och vid prediktion med känd del fråndragen erhölls, för samma prediktionsstegslängd, variansen 599.8. Dock bör påpekas att modell i / 2 / är byggd på 132 data, medan den senare metodens modell är baserad på 96 data. Om den förra modellen / 2 / vore byggd på samma antal data, skulle dess varians blivit större, varför iaktagelsen vid predikteringen ovan av genererade data, antagligen även gäller för verkliga data.

Allmänt bör gälla, att man bör dra av så mycket som möjligt, av den kunskap om datas utseende, som man kan.

9. SAMMANFATTNING AV PREDIKTIONSRESULTATET FÖR DE OLIKA DATA-SERIerna

För varje dataserie redovisas resultaten på varians och medelfel för de olika prediktionsmetoderna. Dessutom kommer vi att kommentera hur strukturella förändringar och steg påverkar prediktionen.

9.1 Företagsdata

Resultaten för de olika prediktionsmetoderna framgår av tabell 28.

TABELL 28

Glidande medelvärde

N = antalet data vid prediktion.

	<u>k=1</u>		<u>k=6</u>	
	<u>VARIANS</u>	<u>MEDELFEL</u>	<u>VARIANS</u>	<u>MEDELFEL</u>
Variansminimum (N=5)	$11.3 \cdot 10^6$	700.2	$11.7 \cdot 10^6$	1330.1
Medelfelsminimum (N=20)	$11.8 \cdot 10^6$	394.9	$12.0 \cdot 10^6$	1022.5

Exponentiell utjämning

α_i = utjämningskoefficienten för prediktionsstegslängden, k=i

<u>Enkel</u>	<u>k=1</u>		<u>k=6</u>	
Medelfelsminimum o.	<u>VARIANS</u>	<u>MEDELFEL</u>	<u>VARIANS</u>	<u>MEDELFEL</u>
Variansminimum ($\alpha_1 = \alpha_6 = 0.17$)	$11.3 \cdot 10^6$	666.9	$11.1 \cdot 10^6$	1279.0

Dubbel

Variansminimum ($\alpha_1 = 0.04, \alpha_6 = 0.05$)	$10.7 \cdot 10^6$	681.8	$10.8 \cdot 10^6$	828.6
Medelfelsminimum ($\alpha_1 = \alpha_6 = 0.17$)	$12.7 \cdot 10^6$	82.8	$11.7 \cdot 10^6$	283.0

Generell exponentiell utjämningOkorrigerade data

β_i = viktfaktorn för prediktionssteget, $k=i$.

	<u>k=1</u>		<u>k=6</u>	
	<u>VARIANS</u>	<u>MEDELFEL</u>	<u>VARIANS</u>	<u>MEDELFEL</u>
Variansminimum $(\beta_1=0.94, \beta_6=0.97)$	$7 \cdot 7 \cdot 10^6$	-28.5	$12.1 \cdot 10^6$	305.42
Medelfelsminimum $(\beta_1=0.94, \beta_6=0.91)$	$7 \cdot 7 \cdot 10^6$	-28.5	$18.8 \cdot 10^6$	9.3

Korrigerade data, där julivärdet = junivärdet.

Variansminimum $(\beta_1=0.94, \beta_6=0.97)$	$1 \cdot 7 \cdot 10^6$	-49.0	$4 \cdot 4 \cdot 10^6$	208.8
Medelfelsminimum $(\beta_1=\beta_6=0.94)$	$1 \cdot 7 \cdot 10^6$	-49.0	$4 \cdot 7 \cdot 10^6$	20.5

Heuristisk metod

α_i = utjämningsfaktorn på säsongsprediktionen för prediktionssteget, $k=i$.

	<u>k=1</u>		<u>k=6</u>	
	<u>VARIANS</u>	<u>MEDELFEL</u>	<u>VARIANS</u>	<u>MEDELFEL</u>
Variansminimum $(\alpha_1=0.95, \alpha_6=0.85)$	$4 \cdot 7 \cdot 10^6$	1358.7	$4 \cdot 7 \cdot 10^6$	813.3
Medelfelsminimum $(\alpha_1=0.95, \alpha_6=0.95)$	$4 \cdot 7 \cdot 10^6$	1358.7	$4 \cdot 7 \cdot 10^6$	808.3

Av tabell 28 framgår det om man med okorrigerade företagsdata önskar prediktera för att erhålla minsta varians, skall heuristiska metoden väljas och om minsta medelfel önskas, skall generell exponentiell utjämning väljas.

Vid korrigerade företagsdata skall generell exponentiell utjämning väljas vid båda tillfällena.

Eftersom prediktering med generell exponentiell utjämning på korrigrade företagsdata har lägre värden på varians och medelfel, bör denna prediktionsmetod väljas och avvikande månad predikteras för sig själv med enkel exponentiell utjämning.

De prediktionsmetoder som kan svara mot förändringar i data (adaptiva metoder) är de som har längsta varians. Av de metoder som vi har studerat, har den heuristiska metoden och den generella exponentiella utjämningen i någon mån denna egenskap.

9.2 Flygdata

Resultaten för de olika prediktionsmetoderna framgår av tabell 29.

TABELL 29

Glidande medelvärde

N_i = antalet data vid prediktion, för prediktionsstegslängden, $k=i$.

	<u>$k=2$</u>		<u>$k=6$</u>	
	VARIANS	MEDELFEL	VARIANS	MEDELFEL
Variansminimum ($N_2=15$, $N_6=10$)	2254.0	27.9	1920.0	27.4
Medelfelsminimum ($N_2=2$, $N_6=10$)	2989.0	5.2	1920.0	27.4

Exponentiell utjämning

α_i = utjämningskoefficient för prediktionsstegslängden, $k=i$.

<u>Enkel</u>	<u>$k=2$</u>		<u>$k=6$</u>	
	VARIANS	MEDELFEL	VARIANS	MEDELFEL
Variansminimum ($\alpha_2=0.10$)	2549.0	26.6	-	-
Medelfelsminimum ($\alpha_2=0.80$)	2696.0	4.6	-	-

Dubbel

Variansminimum

($\alpha_2=0.05$) 2536600 9.5 - -

Medelfelsminimum

($\alpha_2=0.20$) 3985.0 -0.2 - -

Minimalvariansprediktion

	<u>k=1</u>		<u>k=2</u>		<u>k=6</u>	
VARIANS	MEDELFEL	VARIANS	MEDELFEL	VARIANS	MEDELFEL	
599.5	-0.59	-	-	-	-	-

Minimalvariansprediktion med känd del fråndragen

	<u>k=1</u>		<u>k=2</u>		<u>k=6</u>	
VARIANS	MEDELFEL	VARIANS	MEDELFEL	VARIANS	MEDELFEL	
599.8	-3.9	725.6	-5.9	807.3	-6.9	

Generell exponentiell utjämning

β_i = viktfaktorn för prediktionsstegslängden, k=i.

		<u>k=2</u>		<u>k=6</u>	
		VARIANS	MEDELFEL	VARIANS	MEDELFEL
Variansminimum					
($\beta_2=0.97$, $\beta_6=0.94$)		1027.1	-3.3	1164.3	-2.6
Medelfelsminimum					
($\alpha_2=0.88$, $\alpha_6=0.91$)		1239.0	-2.0	1222.4	-2.5

Heuristisk metod

α_i = utjämningsfaktorn på säsongsprediktering för prediktionsstegslängden, k=i.

		<u>k=2</u>		<u>k=6</u>	
		VARIANS	MEDELFEL	VARIANS	MEDELFEL
Variansminimum					
($\alpha_2=0.95$, $\alpha_6=1.00$)		223.7	-2.3	274.1	-2.5
Medelfelsminimum					
($\alpha_2=0.45$, $\alpha_6=0.95$)		246.3	-2.2	283.3	-0.7

För dessa data, som har en stark säsongsvariation, visar det sig att den heuristiska metoden ger minsta varians. Om minsta medelfel eftersträvas, är det likgiltigt vilken metod av de redovisade, som används, eftersom medelfelet för alla metoderna är mycket litet.

9.3 Skogsdata

Resultaten för de olika prediktionsmetoderna framgår av tabell 30.

TABELL 30

Glidande medelvärde

N = antal data vid prediktion

	<u>k=1</u>		<u>k=6</u>	
	<u>VARIANS</u>	<u>MEDELFEL</u>	<u>VARIANS</u>	<u>MEDELFEL</u>
Variansminimum				
(N=13)	3828.0	25.2	-	-
Medelfelsminimum				
(N=10)	4938.0	20.5	-	-

Exponentiell utjämning

α_i = utjämningskoefficienten för prediktionsstegslängden, $k=i$.

Enkel

	<u>k=1</u>		<u>k=6</u>	
	<u>VARIANS</u>	<u>MEDELFEL</u>	<u>VARIANS</u>	<u>MEDELFEL</u>
Variansminimum				
($\alpha_1=0.10$, $\alpha_6=0.12$)	3973.0	35.3	4452.0	47.1
Medelfelsminimum				
($\alpha_1=0.15$, $\alpha_6=0.16$)	3984.0	24.4	4568.0	41.4

Dubbel

Variansminimum

($\alpha_1=0.02$, $\alpha_6=0.12$)	4039.0	55.6	5763.0	1.9
---------------------------------------	--------	------	--------	-----

Medelfelsminimum

($\alpha_1=0.15$, $\alpha_6=0.12$)	4329.0	2.4	5763.0	1.9
---------------------------------------	--------	-----	--------	-----

Minimalvariansprediktion

	<u>k=1</u>		<u>k=6</u>	
	<u>VARIANS</u>	<u>MEDELFEL</u>	<u>VARIANS</u>	<u>MEDELFEL</u>
	3390.0	-5.6	5026.0	-8.4

Generell exponentiell utjämning

β_i = viktfaktorn för prediktionsstegslängden, k=i.

	<u>k=1</u>		<u>k=6</u>	
	VARIANS	MEDELFEL	VARIANS	MEDELFEL
Variansminimum				
($\beta_1=0.91$, $\beta_6=0.97$)	1853.7	-4.1	3287.1	-0.3
Medelfelsminimum				
($\beta_1=0.97$, $\beta_6=0.91$)	2434.7	-0.1	3287.1	-0.3

På dessa data har inte den heuristiska metoden och inte heller minimalvariansprediktion med känd del fråndragen testats och av de övriga, i tabell 30 redovisade prediktionsmetoderna, ger generell exponentiell utjämning minsta värde på varians och medelfel.

9.4 Kommentar

Av de av oss behandlade metoderna har det visat sig att data som innehåller mest slumpmässiga variationer, nämligen Företagsdata och Skogsdata, bör predikteras med generell exponentiell utjämning. De data som innehåller mest markanta säsongsvariationer, såsom Flygdata, bör predikteras med den heuristiska metoden.

Generell exponentiell utjämning har visat sig vara arbetssam och tidskrävande och blir sämre ju längre fram i tiden man kommer.

En metod som är lätt att utföra och som kräver liten tid vid prediktionsarbetet och som dessutom ger ett bra resultat, är den heuristiska metoden. Denna metod är därför fördelaktig att använda.

Det har visat sig att metoder som är adaptiva, är att föredra, då de ger lägre varians och medelfel. Av de av oss studerade prognosmetoderna, har den heuristiska metoden och den generella exponentiella utjämningen i någon mån denna egenskap.

En annan iakttagelse är att, om kunskap om datas speciella utseende byggs in i modellen, ger prediktionen låg varians och lågt medelfel.

Kunskapen kan byggas in på olika sätt. I den heuristiska metoden byggs denna kunskap, om datas utseende, in i modellen genom att datas profil över säsongen ej förändras med tiden.

Vid generell exponentiell utjämning tages de termer, ur fourier-serien, som beskriver profilen, med som ger störst bidrag till profilen.

REFERENSER

1. Brown, R.G. Smoothing, Forecasting and Prediction of Discrete Time Series, Prentice-Hall, 1962.
2. Prognosmetoder, Projektarbete vid Institutionen för Reglerteknik, LTH, Rapport 7335 (c), 1973.
3. Åström, K.J. Introduction to Stochastic Control Theory, Academic Press, 1970.
4. Reichhelm, W. Möglichkeiten zur Beurteilung der kurzfristigen wirtschaftlichen Entwicklung in der Holzindustrie der Bundesrepublik Deutschland unter besonderer Berücksichtigung univariabler Modelle, Mitteilungen der Bundesforschungsanstalt für Forst- und Holzwirtschaft, Reinbeck bei Hamburg, Kommisionsverlag, Buchhandlung Max Wiedebusch, Hamburg, 1971.
5. Gustavsson, I. - IDPAC, Users Guide, Report 7331, Lund Institute Selander, TS. - of Technology, Division of Automatic Control. Wieslander, J.
6. Gustavsson, I. Parametric Identification of Time Series, Report 6803, Lund Institute of Technology, Division of Automatic Control.

APPENDIX A1Datagenereringsprogrammet GENE

Programmet behöver SUBROUTINERNA:

FILES = biblioteksprogram
 MNODI = biblioteksprogram
 AMP1 = innehåller störningens amplitudändring. (se nedan)
 AMP2 = innehåller svängningens amplitudändring. (se nedan)
 TREND = innehåller datas trend. (se nedan)

Variabler:

X(500) = vektor som innehåller genererade data.
 R(16,16) = kovariansfunktionsmatrisen för slumptalen.
 E(16) = vektor som innehåller slumptalen.
 FEL(512) = vektor som innehåller störningen.
 AA(10) = vektor som innehåller svängningarnas amplitud.
 T(10) = vektor som innehåller svängningarnas period.
 F(10) = vektor som innehåller svängningarnas fasförskjutning.
 IT(10) = vektor som innehåller information för inläsning på fil.
 VEC(1) = överför genererade data till fil.
 N = antal data.
 K = antal svängningar.
 IS = väljare, =1 vid inläsning.
 STEG = beloppet på ett eventuellt steg.
 ISTEG = tidpunkt då steget inträffar.
 C1,C2 = störningens trend.
 C3,C4 = svängningens trend.
 C5,C6 = basdatas trend.

```

001 C
002 C      DETTA PROGRAM GENERERAR DATA
003 C
004 C      LOGICAL LOG
005 C      DIMENSION AA(10),T(10),F(10),X(500),E(16),R(16,16),FEL(512),
006 C      6IT(10),VEC(1)
007 C      COMMON X
008 C      DO 500 JJ=1,16
009 C      DO 500 JK=1,16
010 500 R(JK,JJ)=0.0
011 C      DO 100 JJ=1,16
012 100 R(JJ,JJ)=1.0
013 C      WRITE(8,70)
014 C
015 C      N AR ANTALET DATA, K AR ANTALET SVANGNINGAR
016 C      OCH IS AR 1 VID INLASNING
017 C
018 70   FORMAT(' N=ANTAL DATA,K=ANTALET SVANGNINGAR',
019 C      6',IS=SWITCH=1=INLASNING')
020 I=1
021 N=RTTFF()
022 K=RTTFF()
023 IS=RTTFF()
024 IF(K,E0.0) GO TO 1
025 C      WRITE(8,71)
026 C
027 C      SVANGNINGSPARAMETRarna AA AR AMPLITUDEN, T AR
028 C      PERIODEN OCH F AR FASFORSKJUTNINGEN
029 C
030 71   FORMAT(' SVANGNINGSPARAMETRAR AA(),T(),F(),I=1,K')
031 DO 200 JJ=1,K
032 AA(JJ)=RTTFF()
033 T(JJ)=RTTFF()
034 200 F(JJ)=RTTFF()
035 1   WRITE(8,72)
036 C
037 C      C1 C2 AR TREND PA STÖRNINGEN, C3 C4
038 C      AR TREND PA SVANGNINGEN OCH C5 C6 AR
039 C      TRENDEN PA BASDATA
040 C
041 72   FORMAT(' C1 C2 STÖRNINGENS TREND,C3 C4 SVANGNINGENS TREND',
042 C      6',C5 C6 TREND')
043 C1=RTTFF()
044 C2=RTTFF()
045 C3=RTTFF()
046 C4=RTTFF()
047 C5=RTTFF()
048 C6=RTTFF()
049 C      WRITE(8,73)
050 C
051 C      ETT STEG MED BELOPPET STEG INTRAFFAR VID TID-
052 C      PUNKTEN ISTEG
053 C
054 73   FORMAT(' STEG,ISTEG=TIDPUNKTEN')
055 STEG=RTTFF()
056 ISTEG=RTTFF()
057 NI=16
058 IA=16
059 NODD=19
060 ILONG=0
061 DO 50 I=1,N
062 50  X(I)=0
063 C

```

```

064      C      GENERERING AV DATA
065      C
066          DO 10 I=1,N
067          IF(K,EQ,0) GOTO 12
068          DO 20 J=1,K
069          U=2.*3.1416*(FLOAT(I)-F(J))/T(J)
070      20      X(I)=X(I)+AA(J)*SIN(U)
071          CALL AMP2(Y,I,C3,C4)
072          X(I)=X(I)*Y
073      12      CALL TREND(Z,I,C5,C6)
074          IF(I.LT,ISTEG) GO TO 30
075          X(I)=X(I)+Z*STEG
076          GO TO 10
077      30      X(I)=X(I)+Z
078      10      CONTINUE
079          L=(N+15)/16
080          DO 7 IX=1,L
081          CALL MNOD1(E,R,NI,IA,NODD,ILOG,IND)
082          IM=(IX-1)*16+1
083          IN=IM+15
084          DO 7 I=IM,IN
085          M=MOD(I-1,16)+1
086      7      FEL(I)=E(M)
087          DO 40 I=1,N
088          CALL AMP1(XX,I,C1,C2)
089          FEL(I)=FEL(I)*XX
090      40      X(I)=X(I)+FEL(I)
091      C
092      C      UTSKRIFT AV DATAS UPPBYGGNAD
093      C
094          WRITE(6,956)N,K,C1,C2,C3,C4,C5,C6
095      956      FORMAT('1N=',I3,' K=',I2,' C1=',F10.5,' C2=',F10.5/
096                  6,' C3=',F10.5,' C4=',F10.5,' C5=',F10.5/
097                  6,' C6=',F10.5)
098          WRITE(6,600)K
099      600      FORMAT(10X,22HANTALET SVANGNINGAR K=,I1)
100          WRITE(6,700)(J,AA(J),F(J),T(J),J=1,K)
101      700      FORMAT(10X,17HSVANGNING NUMMER ,I1,2H =,F10.5,
102                  614H*SIN(2*3.1416*,3H(I-,F10.5,2H)/,F10.5,1H))
103          WRITE(6,800)C5,C6
104      800      FORMAT(10X,'TREND =',F10.5,'+',F10.5,'*T')
105          WRITE(6,960)C1,C2,C3,C4
106      960      FORMAT(10X,'AMPLITUD 1 =',F10.5,'+',F10.5,'*T'/
107                  610X,'AMPLITUD 2 =',F10.5,'+',F10.5,'*T')
108          WRITE(6,900)ISTEG,STEG
109      900      FORMAT(10X,'ETT STEG INTRAFFAR VID T=',I3,4X,'STEGET =',
110                  6F10.2)
111          WRITE(6,950)(I,X(I),I=1,N)
112      950      FORMAT(1H0,11X,1H1,11X,'X'//(10X,I3,6X,F8.2))
113          IF(IS.NE,1) GO TO 955
114          WRITE(9,951)
115      C
116      C      INLASNING KOMMER ATT SKE PA FILEN FNAM PA DK
117      C
118      951      FORMAT(' FNAM')
119          READ(8,952)FNAM
120      952      FORMAT(A5)
121          I=1
122          WRITE(8,957)
123      957      FORMAT(' IT-VEKTORN')
124          DO 953 J=1,10
125      953      IT(J)=RTTEF(I)
126      C
127      C      FILEN LASES IN

```

```
128      C
129      CALL FILES('ENTER',2,IT,FNAM,'BIN',LOG)
130      NNR=1
131      DO 954 J=1,N
132      VEC(1)=X(J)
133      954  CALL FILDAT('WRITE',2,VEC,NNR)
134      CALL FILES('CLOSE',2,IT,FNAM,'BIN',LOG)
135      955  CONTINUE
136      STOP
137      END
```

001 SUBROUTINE AMP1(X,I,C1,C2)
002 X1=I
003 X=C1+C2*X1
004 RETURN
005 END

001 SUBROUTINE AMP2(Y,I,C3,C4)
002 Y1=I
003 Y=C3+C4*Y1
004 RETURN
005 END

001 SUBROUTINE TREND(Z,I,C5,C6)
002 Z1=I
003 Z=C5+C6*Z1
004 RETURN
005 END

APPENDIX A2Dataprogrammet MINKO

Programmet behöver SUBROUTINERNA:

FLEPO	- biblioteksprogram (minimeringsprogram).
DOT	- biblioteksprogram (FUNCTION till FLEPO).
UPDOT	- biblioteksprogram (FUNCTION till FLEPO).
FU	- FUNCTION till FLEPO. (se nedan)
SYMINV	- biblioteksprogram (matrisinverteringsprogram).
FOGIX	- SUBROUTINE till FLEPO. (se nedan)

Variabler:

X(500)	- vektor som innehåller data.
H(210)	- vektor som innehåller inverterade andraderivatan till förlustfunktionen.
A(20)	- vektor som innehåller a-parametrarna.
AD(20,20)	- matris som innehåller förlustfunktionens andraderivata.
IT(10)	- vektor som innehåller information för läsning och inläsning av data på fil.
VEC(1)	- överför data från eller till fil.
M	- antal data.
N	- antal a-startvärdet.
EPS	- iterationen håller på tills delta förlustfunktionen är mindre än EPS.
LIMIT	- maximalt antal iterationer.
FNAM	- namn på datafilen.

```

001 C
002 C      DETTA PROGRAM ANPASSAR EN FUNKTION TILL GIVNA
003 C      DATA ,SA ATT FORLUSTFUNKTIONEN MINIMERAS,
004 C      MED HJALP AV PROGRAMMET FLEPO.
005 C
006      INTEGER CONV
007      DIMENSION A(20),H(210),X(500),L(2),IT(10),VEC(1),AD(20,20)
008      COMMON X,L
009      EXTERNAL FOGIX
010      WRITE(8,1)
011 C
012 C      N AR ANTALET A=STARTVARDEN
013 C
014      1 FORMAT(' N=ANTAL A=STARTVARDEN')
015      I=1
016      N=RTTFF(1)
017      L(1)=N
018      WRITE(8,2)
019      2 FORMAT(' A=STARTVARDEN')
020      DO 3 J=1,N
021      I=1
022      3 A(J)=RTTFF(1)
023      WRITE(8,4)
024 C
025 C      ITERATIONEN HALLER PA TILLS DELTA FORLUSTFUNKTIONEN
026 C      AR MINDRE AN EPS.
027 C
028      4 FORMAT(' EPS')
029      I=1
030      EPS=RTTFF(1)
031      WRITE(8,5)
032 C
033 C      MAXIMALT ANTAL ITERATIONER
034 C
035      5 FORMAT(' ANTAL ITERATIONER')
036      I=1
037      LIMIT=RTTFF(1)
038      WRITE(8,11)
039 C
040 C      DATA LASES FRAN FILEN FNAM PA DT1
041 C
042      11 FORMAT(' FNAM')
043      READ(8,12)FNAM
044      12 FORMAT(A5)
045      WRITE(8,13)
046      13 FORMAT(' IT-VEKTORN')
047      DO 14 J=1,10
048      I=1
049      14 IT(J)=RTTFF(1)
050      CALL FILES('SEEK',3,IT,FNAM,'BIN',LOG)
051      IF(LOG) GO TO 15
052      WRITE(8,16)
053      16 FORMAT(' FILEN EJ FUNNEN')
054      15 WRITE(8,25)
055 C
056 C      M AR ANTALET DATA VID MINIMERING
057 C
058      25 FORMAT(' M=ANTAL DATA VID MINIMERING')
059      I=1
060      M=RTTFF(1)
061      L(2)=M
062      NNR=1
063      DO 17 J=1,M

```

```

064      CALL FILDAT('READ',3,VEC,NNR)
065      17   X(J)=VEC(1)
066      CALL FILES('CLOSE',3,IT,FNAM,'BIN',LOG)
067      LOADH=0
068      10   DO 20 I=1,N
069      DO 20 K=1,N
070      20   AD(I,K)=0.
071      11=0
072      C
073      C      ANDRADERIVATAN TILL FORLUSTFUNKTIONEN BERAKNAS
074      C
075      DO 18 I=1,N
076      DO 18 K=1,N
077      DO 18 J=1,M
078      18   AD(I,K)=2.*FUC(I,J)*FUC(K,J)+AD(I,K)
079      C
080      C      ANDRADERIVATMATRISEN INVERTERAS
081      C
082      CALL SYMINV(N,N,IFAIL,AD)
083      IF(IFAIL.EQ.0) GOTO 21
084      WRITE(6,22)
085      22   FORMAT(' INVERTERINGEN MISSLYCKADES')
086      GO TO 23
087      C
088      C      OVRE HOGRA DELEN AV MATRISEN , SOM INNEHALLER
089      C      INVERSEN TILL ANDRADERIVATAN, LAGRAS RADVIS I EN
090      C      VEKTOR H,
091      C
092      21   DO 24 I=1,N
093      LL=I
094      DO 24 K=LL,N
095      II=II+1
096      24   H(II)=AD(I,K)
097      C
098      C      FORLUSTFUNKTIONEN MINIMERAS
099      C
100      CALL FLEPO(N,A,F,EPS,CONV,LIMIT,H,LOADH,FOGIX)
101      WRITE(6,6)
102      6    FORMAT(5X,'A-PARAMETRarna')
103      WRITE(6,7)(1,A(I),I=1,N)
104      7    FORMAT(7X,'A(1,12,1)=',F20.4)
105      WRITE(6,8)
106      8    FORMAT(7X,'FUNKTIONSVARDET')
107      WRITE(6,9)F
108      9    FORMAT(7X,'F=',F20.4)
109      IF(CONV.EQ.0) GO TO 10
110      23   CONTINUE
111      STOP
112      END

```

```
001 C
002 C      SUBROUTINE FOGIX(A,F,G) AR EN SUBROUTINE TILL
003 C      PROGRAMMET MINKO OCH BERAKNAR SUMMA AVVIKELSE
004 C      I KVADRAT SAMT FORLUSTFUNKTIONENS GRADIENT
005 C
006 C      A( )=AKOEFFICIENTER
007 C      F=ACKUMULERAD AVVIKELSE I KVADRAT
008 C      G( )=FORLUSTFUNKTIONENS GRADIENT
009 C
010 C      SUBROUTINE FOGIX(A,F,G)
011 C      DIMENSION X(500),G(1),A(1),L(1)
012 C      COMMON X,L
013 C      N=L(1)
014 C      M=L(2)
015 C      F=0.
016 C      DO 8 J=1,20
017 C      8   G(J)=0,
018 C      DO 9 J=1,M
019 C      B=0.
020 C      DO 10 K=1,N
021 C      10  B=A(K)*F(U,K,J)+B
022 C      F=(X(J)-B)*(X(J)-B)+F
023 C      DO 9 K=1,N
024 C      9   G(K)=-(X(J)-B)*2.*F(U,K,J)+G(K)
025 C      RETURN
026 C      END
```

```

001 C
002 C      FUNCTION FU(I,J) AR FUNCTION TILL PROGRAMMET
003 C      MINKO
004 C
005      FUNCTION FU(I,J)
006      T=FLOAT(J)
007      IF(I,NE,1) GOTO 2
008      FU=1.
009      GOTO 1
010      2      IF(I,NE,2) GOTO 3
011      FU=T
012      GOTO 1
013      3      IF(I,NE,3) GOTO 4
014      FU=SIN(2.*3.1416*T/12.)
015      GOTO 1
016      4      IF(I,NE,4) GOTO 5
017      FU=COS(2.*3.1416*T/12.)
018      GOTO 1
019      5      IF(I,NE,5) GOTO 6
020      FU=SIN(2.*3.1416*T/6.)
021      GOTO 1
022      6      IF(I,NE,6) GOTO 7
023      FU=COS(2.*3.1416*T/6.)
024      GOTO 1
025      7      IF(I,NE,7) GOTO 8
026      FU=SIN(2.*3.1416*T/6.)
027      GOTO 1
028      8      IF(I,NE,8) GOTO 9
029      FU=COS(2.*3.1416*T/6.)
030      GOTO 1
031      9      IF(I,NE,9) GOTO 10
032      FU=COS(2.*3.1416*T/5.)
033      GOTO 1
034      10     IF(I,NE,10) GOTO 11
035      FU=SIN(2.*3.1416*T/7.)
036      GOTO 1
037      11     IF(I,NE,11) GOTO 12
038      FU=COS(2.*3.1416*T/7.)
039      GOTO 1
040      12     IF(I,NE,12) GOTO 13
041      FU=SIN(2.*3.1416*T/1.)
042      GOTO 1
043      13     IF(I,NE,13) GOTO 14
044      FU=COS(2.*3.1416*T/1.)
045      GOTO 1
046      14     CONTINUE
047      1     CONTINUE
048      RETURN
049      END

```

APPENDIX A3Dataprogrammet ALBER

Programmet behöver SUBROUTINEN:

FILES = biblioteksprogram

Variabler:

x(500) = vektor som innehåller data.
 A(40) = vektor som innehåller a-parametrarna.
 L(40,40) = L-matrisen.
 AA(40) = vektor som innehåller svängningarnas amplitud.
 T(40) = vektor som innehåller svängningarnas period.
 F(40) = vektor som innehåller svängningarnas fasförskjutning.
 P(6) = vektor som innehåller polynomkoefficienterna.
 D(24) = vektor som innehåller autoregressionskoefficienterna.
 IT(10) = vektor som innehåller information för läsning och inläsning på fil.
 VEC(1) = vektor som överför data till eller från fil.
 IS = väljare, =1 medför inläsning på fil.
 IQ = väljare, =1 medför att andra a-parametrar kan väljas.
 IPO = antal polynomkoefficienter.
 IAS = antal svängningar.
 IAAK = antal autoregressionskoefficienter.
 C1,C2 = störningens trend.
 C3,C4 = svängningens trend.
 LL = antal a-parametrar som skall ändras.
 FNAM = namn på datafil.

```

001 C
002 C      DETTA PROGRAM ANPASSAR A-KOEFFICIENTERNA OCH
003 C      BERAKNAR L-MATRISEN TILL GEXP, SAMT LASER IN
004 C      DESSA TILLSAMMANS MED DATA PA EN FIL
005 C
006 C      LOGICAL LOG
007 C      REAL L
008 C      DIMENSION A(40),P(6),AA(40),T(40),F(40),D(24),L(40,40),
009 C      6VEC(1),IT(10),X(500)
010 C      COMMON X,A,L
011 C      WRITE(8,79)
012 C
013 C      IS LIKA MED 1 MEDFOR INLASNING PA FIL OCH
014 C      OM IQ AR LIKA MED 1 KAN ANDRA A-PARAMETRAR VALJAS
015 C
016 79   FORMAT(' IS=SWITCH,IS=1 MEDFOR INLASNING PA FIL'/
017 C      6' IQ=SWITCH, DA IQ=1 KAN ANDRA A-PARAMETRAR VALJAS')
018 C      I=1
019 C      IS=RTTFF(1)
020 C      IQ=RTTFF(1)
021 C      WRITE(8,80)
022 C
023 C      IPO AR ANTAL POLYNOMKOEFFICIENTER,IAS AR ANTAL
024 C      SVANGNINGAR OCH IAAK AR ANTAL AUTOREGRESION-
025 C      KOEFFICIENTER
026 C
027 80   FORMAT(' IPO,IAS,IAAK')
028 C      I=1
029 C      IPO=RTTFF(1)
030 C      IAS=RTTFF(1)
031 C      IAAK=RTTFF(1)
032 C      IF(IPO,EQ,0) GO TO 2
033 C      DO 1 J=1,6
034 1     P(J)=0
035 C      WRITE(8,81)
036 81   FORMAT(' POLYNOMKOEFFICIENTerna P(1),I=1,IPO')
037 C      I=1
038 C      DO 101 J=1,IPO
039 101  C      P(J)=RTTFF(1)
040 2     C      IF(IAS,EQ,0) GO TO 3
041 C      WRITE(8,82)
042 C
043 C      SVANGNINGSPARAMETRarna AA AR AMPLITUDEN, T AR
044 C      PERIODEN OCH F AR FASFOSKJUTNINGEN
045 C
046 82   FORMAT(' SVANGNINGSPARAMETRarna AA(1),T(1),F(1),I=1,IAS')
047 C      I=1
048 C      DO 102 J=1,IAS
049 C      AA(J)=RTTFF(1)
050 C      T(J)=RTTFF(1)
051 102  C      F(J)=RTTFF(1)
052 3     C      IF(IAAK,EQ,0) GO TO 4
053 C      WRITE(8,83)
054 C
055 C      D AR AUTOREGRESIONSKOEFFICIENTERNA
056 C
057 83   FORMAT(' AUTOREGRESIONSKOEFFICIENTERNA D(1),I=1,IAAK')
058 C      I=1
059 C      DO 103 J=1,IAAK
060 103  C      D(J)=RTTFF(1)
061 4     C      WRITE(8,84)
062 C
063 C      C1 C2 AR TRENDEN PA STORNINGEN, C3 C4 AR TRENDEN PA

```

```

064      C      SVANGNINGEN
065      C
066      84      FORMAT(' C1,C2 STORNINGENS TREND C3,C4 SVANGNINGENS TREND')
067      I=1
068      C1=RTTFF(1)
069      C2=RTTFF(1)
070      C3=RTTFF(1)
071      C4=RTTFF(1)
072      DO 38 I=1,40
073      DO 38 J=1,40
074      38      L(I,J)=0
075      I1=0
076      I=0
077      WRITE(6,105)
078      105     FORMAT(1H1,10X,'FITTING FUNCTIONS')
079      IF(IPO,EQ,0) GO TO 23
080      C
081      C      BERAKNING AV A-KOEFFICIENTERNA OCH DEN DEL AV
082      C      L-MATRISEN SOM BEROR AV POLYNOMKOEFFICIENTERNA
083      C
084      A1=P(1)
085      A2=P(2)+P(3)+P(4)+P(5)+P(6)
086      A3=2.*P(3)+6.*P(4)+14.*P(5)+30.*P(6)
087      A4=6.*P(4)+36.*P(5)+150.*P(6)
088      A5=24.*P(5)+240.*P(6)
089      A6=120.*P(6)
090      IC=100,*A1
091      IF(IC,EQ,0) GO TO 5
092      I=I+1
093      A(I)=A1
094      L(1,1)=1.
095      WRITE(6,106)
096      106     FORMAT(11X,'F',12,'=1')
097      5       IF(IPO,EQ,1) GO TO 23
098      IC=1000,*A2
099      IF(IC,EQ,0) GO TO 7
100      I=I+1
101      A(I)=A2
102      DO 6 J=1,I
103      6       L(I,J)=1.
104      WRITE(6,107)
105      107     FORMAT(11X,'F',12,'=T')
106      7       IF(IPO,EQ,2) GO TO 23
107      IC=10000,*A3
108      IF(IC,EQ,0) GO TO 11
109      I=I+1
110      A(I)=A3
111      IF(I,EQ,1) GO TO 9
112      K=I-1
113      DO 8 J=K,I
114      8       L(I,J)=1.
115      GO TO 10
116      9       L(1,1)=1.
117      10      WRITE(6,108)
118      108     FORMAT(11X,'F',12,'=T*(T-1,)/2,')
119      11      IF(IPO,EQ,3) GO TO 23
120      IC=10000,*A4
121      IF(IC,EQ,0) GO TO 15
122      I=I+1
123      A(I)=A4
124      IF(I,EQ,1) GO TO 13
125      K=I-1
126      DO 12 J=K,I
127      12      L(I,J)=1.

```

```

128      GO TO 14
129      13    L(1,1)=1,
130      14    WRITE(6,109)I
131      109   FORMAT(11X,'F',12,'=T*(T-1.)*(T-2.)/2./3.',)
132      15    IF(IPO,EQ.4) GO TO 23
133      IC=10000.*A5
134      IF(IC,EQ.0) GO TO 19
135      I=I+1
136      A(I)=A5
137      IF(I,EQ.1) GO TO 17
138      K=I-1
139      DO 16 J=K,I
140      16    L(I,J)=1,
141      GO TO 18
142      17    L(1,1)=1.
143      18    WRITE(6,110)I
144      110   FORMAT(11X,'F',12,'=T*(T-1.)*(T-2.)*(T-3.)/2./3./4.',)
145      19    IF(IPO,EQ.5) GO TO 23
146      IC=10000.*A6
147      IF(IC,EQ.0) GO TO 23
148      I=I+1
149      A(I)=A6
150      IF(I,EQ.1) GO TO 21
151      K=I-1
152      DO 20 J=K,I
153      20    L(I,J)=1,
154      GO TO 22
155      21    L(1,1)=1,
156      22    WRITE(6,111)I
157      111   FORMAT(11X,'F',12,'=T*(T-1.)*(T-2.)*(T-3.)*(T-4.)',,
158      6'2./3./4./5.',)
159      23    IF(IAS,EQ.0) GO TO 26
160      C
161      C      BERAKNING AV A-KOEFFICIENTERNA OCH DEN DEL AV
162      C      L-MATRISEN SOM BEROR AV SVANGNINGARNA
163      C
164      DO 25 K=1,IAS
165      X0=2.*3.14159265*F(K)/T(K)
166      X1=2.*3.14159265/T(K)
167      SX=SIN(X0)
168      CX=COS(X0)
169      SX1=SIN(X1)
170      CX1=COS(X1)
171      IC=100.*AA(K)*C3
172      IF(IC,EQ.0) GO TO 24
173      I=I+1
174      A(I)=AA(K)*C3*CX
175      WRITE(6,112)I,T(K)
176      112   FORMAT(11X,'F',12,'=SIN(2.*3.1416*T/',
177      6E4.1,')')
178      I=I+1
179      A(I)=-AA(K)*C3*SX
180      WRITE(6,113)I,T(K)
181      113   FORMAT(11X,'F',12,'=COS(2.*3.1416*T/',
182      6E4.1,')')
183      L(I-1,I-1)=CX1
184      L(I-1,I)=SX1
185      L(I,I-1)=-SX1
186      L(I,I)=CX1
187      I=I+1
188      24    IC=100.*AA(K)*C4
189      IF(IC,EQ.0) GO TO 25
190      I=I+1
191      A(I)=AA(K)*C4*CX

```

```

192      WRITE(6,114)I,T(K)
193      114  FORMAT(11X,'F',12,'=T*SIN(2.*3,1416*T/1,F4,1,1)')
194          I=I+1
195          A(I)=-AA(K)*C4*SX
196          WRITE(6,115)I,T(K)
197      115  FORMAT(11X,'F',12,'=T*COS(2.*3,1416*T/1,F4,1,1)')
198          L(I-1,I-1)=CX1
199          L(I-1,I)=SX1
200          L(I,I-1)=-SX1
201          L(I,I)=CX1
202          IF(I,I,EQ,0) GO TO 26
203          L(I-1,I-3)=CX1
204          L(I-1,I-2)=SX1
205          L(I,I-3)=-SX1
206          L(I,I-2)=CX1
207      25   I=0
208      26   IF(IAAK,EQ,0) GO TO 28
209      C
210      C     BERAKNING AV A-KOEFFICIENTERNA OCH DEN DEL AV
211      C     L-MATRISEN SOM BEROR AV AUTOREGRESSIONSKOEF-
212      C     FICIENTERNA
213      C
214          N=1
215          DO 27 J=1,IAAK
216          I=I+1
217          A(I)=D(J)
218          K=I-J+1
219          L(K,I)=D(J)
220          M=N+IAAK
221          IF((I+1),GT,M) GO TO 71
222          L(I+1,I)=1,
223      71   CONTINUE
224      27   WRITE(6,116)I,J
225      116  FORMAT(11X,'F',12,'=X(T-1,12,1,1)')
226      28   IF(IQ,NE,1) GO TO 50
227          JK=1
228          WRITE(8,72)
229      C
230      C     EVENTUELLA A-KOEFFICIENTER SOM SKALL ANDRAS
231      C
232      72   FORMAT(' ANTAL A-PARAMETRAR SOM SKALL ANDRAS')
233          LL=RTTFF(JK)
234          WRITE(8,56)
235      56   FORMAT(' NUMMER      VARDE')
236          DO 70 K=1,LL
237          JK=1
238          J=RTTFF(JK)
239          U=RTTFF(JK)
240          A(J)=U
241      70   WRITE(6,117)(J,A(J),J=1,1)
242      50   FORMAT(1H0/(11X,'A',12,'=',F15,8))
243          WRITE(6,118)
244      117  FORMAT(1H0/11X,'L-MATRISEN')
245          DO 29 J=1,1
246      29   WRITE(6,119)(L(J,K),K=1,1)
247      119  FORMAT(1X,10F12.8/(13X,9F12.8))
248          IF(S,NE,1) GO TO 44
249      C
250      C     DATA LASES FRAN FILLEN FNAM PA DK
251      C
252          WRITE(9,130)
253      130  FORMAT(' GAMMALT FNAM')
254          READ(8,131)FNAM
255          FORMAT(A5)

```

```

256          WRITE(9,132)
257      132  FORMAT(' IT-VEKTORN TILL DEN GAMLA FILEN')
258          I=1
259          DO 45 J=1,10
260      45   IT(J)=RTTFF(I)
261          LOG=.FALSE.,
262          CALL FILES('SEEK',2,IT,FNAM,'BIN',LOG)
263          IF(LOG) GO TO 135
264          WRITE(8,133)
265      133  FORMAT(' FILEN EJ FUNNEN')
266      135  NNR=1
267          M=IT(1)
268          DO 39 J=1,M
269          CALL FILDAT('READ',2,VEC,NNR)
270      39   X(J)=VEC(1)
271          CALL FILES('CLOSE',2,IT,FNAM,'BIN',LOG)
272          WRITE(8,49)
273          C
274          C     INLASNING AV DATA, A-KOEFFICIENTER OCH L-MATRIS
275          C     SKER PA FILEN FNAM PA DK
276          C
277      49   FORMAT(' NYTT FNAM')
278          READ(8,222)FNAM
279      222  FORMAT(A5)
280          WRITE(9,134)
281      134  FORMAT(' IT-VEKTORN TILL DEN NYA FILEN')
282          I=1
283          DO 40 J=1,10
284      40   IT(J)=RTTFF(I)
285          CALL FILES('ENTER',1,IT,FNAM,'BIN',LOG)
286          NNR=1
287          M=IT(8)
288          DO 41 J=1,M
289          VEC(1)=X(J)
290      41   CALL FILDAT('WRITE',1,VEC,NNR)
291          NNR=1
292          N=IT(9)
293          DO 42 J=1,N
294          DO 42 K=1,N
295          VEC(1)=L(K,J)
296      42   CALL FILDAT('WRITE',1,VEC,NNR)
297          NNR=1
298          N=IT(9)
299          DO 43 J=1,N
300          VEC(1)=A(J)
301      43   CALL FILDAT('WRITE',1,VEC,NNR)
302          WRITE(6,46)(I,X(I),I=1,M)
303      46   FORMAT(//,10X,'DATA'/11X,'T      X(T)"/(11X,13,2X,F14.7))
304          WRITE(6,47)((J,I,L(J,I),J=1,N),I=1,N)
305      47   FORMAT(//,10X,'L-MATRISEN"/(11X,'L(''1,12,''',12,'')''/14.7))
306          WRITE(6,48)(I,A(I),I=1,N)
307      48   FORMAT(//,10X,'A-PARAMETRarna"/(11X,'A(''1,12,''',12,'')''/14.7))
308          CALL FILES('CLOSE',1,IT,FNAM,'BIN',LOG)
309      44   CONTINUE
310          STOP
311          END

```

APPENDIX A4Dataprogrammet GEXP

Programmet behöver SUBROUTINERNA:

FILES = biblioteksprogram
 SYMINV = biblioteksprogram (matrisinverteringsprogram).
 FIT = SUBROUTINE till GEXP. (se nedan)
 RITA = SUBROUTINE. (se appendix A6)

Variabler:

X(500) = vektor som innehåller data.
 XP(500) = vektor som innehåller prediktionen.
 F(20,20) = stabila tillståndsmatrisen och dess invers.
 L(20,20) = L-matrisen.
 A(20) = vektor som innehåller a-parametrarna.
 FEL1(500) = vektor som innehåller prediktionsfelet.
 FEL2(500) = vektor som innehåller summa prediktionsfel i kvadrat.
 H(20) = vektor som innehåller viktfaktorerna.
 IT(10) = vektor som innehåller information för läsning och inläsning på fil.
 VEC(1) = vektor som överför data från fil.
 S(50) = vektor som innehåller data för konvergenstest.
 FNAM = namn på datafil.
 N = antal a-startvärden.
 M = antal data.
 IS = väljare, =1 medför uthoppar programmet.
 =2 medför fortsättning av programmet.
 IV = väljare, =1 om ny viktfaktor, β , önskas.
 =2 om gammal viktfaktor, β , vill behållas.
 JB = antal sparade värden för konvergenstest (mellan 1 och 50).
 IU = väljare, =1 ger utskrift.
 IRTT = väljare, =0 medför ingen uppritning på displayen.
 =1 medför uppritning av verkliga data, X(),
 och prediktionen, XP() på displayen.
 =2 medför uppritning av verkliga data, X(),
 prediktionen, XP(), och prediktionsfelet,
 FEL1().

=3 medför uppritning av verkliga data, $X()$,
prediktionen, $\hat{X}()$, prediktionsfelet, $FEL1()$,
och summa prediktionsfel i kvadrat, $FEL2()$.

- BETA = viktfaktor.
- K = prediktionsstegets längd.
- VAR = variansen.
- FMED = medelfelet.
- IAVS = antal värden per sida (bild) vid uppritning på displayen.

```

001 C
002 C      DETTA PROGRAM GOR EN PREDIKTION MED HJALP AV
003 C      GENERELL EXPONENTIELL UTJAMNING
004 C
005 C      LOGICAL LOG
006 C      REAL L
007 C      DIMENSION F(20,20),L(20,20),H(20),B(20),X(500),XP(500),
008 C      6A(20),S(50),FEL1(500),FEL2(500),VEC(1),IT(10),P(20)
009 C      COMMON L,X,A,F,H,B,XP,S,FEL1,FEL2,VEC,IT
010 C      WRITE(9,101)
011 101 FORMAT(' FNAM')
012 READ(8,102)FNAM
013 102 FORMAT(A5)
014 C
015 C      INLASNING AV DATA KOMMER ATT SKE FRAN FILEN FNAM PA DT1
016 C
017 C      WRITE(9,103)
018 103 FORMAT(' IT-VEKTORN')
019 I=1
020 DO 104 J=1,10
021 104 IT(J)=RTTFF(1)
022 LOG=.FALSE.
023 CALL FILES('SEEK',3,IT,FNAM,'BIN',LOG)
024 IF(LOG) GOTO 73
025 WRITE(9,105)
026 105 FORMAT(' FILEN EJ FUNNEN')
027 73 NNR=1
028 M=IT(8)
029 C
030 C      LASER IN DATA FRAN FILEN FNAM
031 C
032 DO 106 J=1,M
033 CALL FILDAT('READ',3,VEC,NNR)
034 106 X(J)=VEC(1)
035 N=IT(9)
036 C
037 C      LASER IN OVERFORINGSMATRISEN L FRAN FILEN FNAM
038 C
039 DO 107 J=1,N
040 DO 107 K=1,N
041 CALL FILDAT('READ',3,VEC,NNR)
042 107 L(K,J)=VEC(1)
043 C
044 C      LASER IN STARTKOEFFICIENTERNA I GEN.EXP.UTJ. FRAN FILEN FNAM
045 C
046 DO 108 J=1,N
047 CALL FILDAT('READ',3,VEC,NNR)
048 108 A(J)=VEC(1)
049 CALL FILES('CLOSE',3,IT,FNAM,'BIN',LOG)
050 DO 74 K=1,N
051 74 P(K)=A(K)
052 23 WRITE(8,71)
053 71 FORMAT(' IS=1=UTHOPP UR PROG., IS=2 FORTS., IV=1 VID NYTT BETA
054 6, IV=2 VID GAMMALT BETA')
055 I=1
056 IS=RTTFF(1)
057 IV=RTTFF(1)
058 C
059 C      M=ANTALET DATA   N=ANTALET KOEFFICIENTER I GEN.EXP.UTJ.
060 C      JB=ANTALET SPARADE VARDEN FOR KONVERGENSTEST (MELLAN
061 C      1 OCH 50)
062 C
063 WRITE(8,70)

```

```

064    70   FORMAT(' JB=ANTAL DATA I KONV.TEST, IU=1=UTSKRIFT, IRIT=0=EJ B
065      6/' IRIT=1=X,XP,,IRIT=2=X,XP,FEL2,,IRIT=3=X,XP,FEL2,FEL1')
066      I=1
067      JB=RTTFF(1)
068      IU=RTTFF(1)
069      IRIT=RTTFF(1)
070
071      C
072      C     IS,IV AR SWITCHAR . IS=1 AVSLUTAS PROGRAMMET, IS=2 FORT-
073      C     SATTER PROGRAMMET MED EFTERFOLJANDE SATS, IV=1 SKER
074      C     BERAKNING AV H(J). IV=2 SKER HOPP TILL PREDIKTIONSBERAK-
075      C     NINGEN,
076      C
077      25   GO TO(24,25),IS
078      72   WRITE(8,72)
079      72   FORMAT(' BETA,KSTEG=PRED.LANGD')
080      I=1
081      BETA=RTTFF(1)
082      C
083      C     KSTEG=VIKTAL, KSTEG=PREDIKTIONSSTEGETS LANGD,
084      C
085      21   GO TO(21,22),IV
086      C
087      C     BERAKNINGEN AV F SOM AVSLUTAS NAR ALLA INGAENDE ELEMENT
088      C     AR MINDRE AN ETT VISST VARDE ELLER DA BERAKNINGSSLINGAN
089      C     GENOMLOPTS 10000 GANGER.
090      C
091      21   DO 11 J=1,N
092      DO 11 KK=J,N
093      DD=0.
094      BD=1.
095      225  WRITE(6,225)KK,J
096      225  FORMAT(//,11X,1H1,11X,2HF(,12,1H,,12,1H))
097      DO 3 I=1,10000
098      BD=BD*BETA
099      CALL FIT(J,-I,Y)
100      CALL FIT(KK,-I,Z)
101      D=BD*Y*Z
102      DD=DD+D
103      II=MOD(I,20)
104      IF(II,NE,0) GO TO 4
105      WRITE(6,230)I,DD
106      230  FORMAT(9X,15,3X,F14.2)
107      4    JT=JB-1
108      DO 52 JP=1,JP
109      JS=JB-JP+1
110      52   S(JS)=S(JS-1)
111      S(1)=ABS(DD)
112      IF(I.LT.JB) GO TO 3
113      SMAX=0.
114      DO 53 JP=1,JB
115      53   SMAX=AMAX1(SMAX,S(JP))
116      SMIN=SMAX
117      DO 54 JP=1,JB
118      54   SMIN=AMIN1(SMIN,S(JP))
119      TEST=SMAX-SMIN-1.
120      IF(TEST.LT.1.E-3) GO TO 77
121      3    CONTINUE
122      77   WRITE(6,230)I,DD
123      F(KK,J)=DD
124      F(J,KK)=DD
125      WRITE(6,235)
126      235  FORMAT(//,10X,10HF=MATRISEN)
127      DO 98 I=1,N

```

A4:5

```

128      98      WRITE(6,240)(F(I,J),J=1,N)
129      240      FORMAT(11X,10F10.2/(21X,9F10.2))
130      1A=10
131      C
132      C      INVERTERAR F OCH LÄGGER RESULTATET I F
133      C
134      CALL SYMINV(N,IA,IFAIL,F)
135      IF(IFAIL.NE.1) GO TO 99
136      WRITE(6,280)IFAIL
137      280      FORMAT(1H0,11X,'IFAIL=',I3,14H INVERTERINGEN,
138                  633H MISSLYCKADES. KÖRNINGEN AVBRYTES)
139      GO TO 24
140      99      WRITE(6,245)
141      245      FORMAT(//,10X,'F=1-MATRISEN')
142      DO 97 I=1,N
143      97      WRITE(6,240)(F(I,J),J=1,N)
144      DO 13 I=1,N
145      13      H(I)=0
146      C
147      C      H(J) AR EN VEKTOR (VIKTVEKTOR) SOM VIKTAR FELETS BETYDELSE
148      C      VID BERÄKNING AV DE NYA A-PARAMETRarna.
149      C
150      DO 14 KK=1,N
151      DO 14 J=1,N
152      CALL FIT(KK,0,Y)
153      14      H(J)=F(J,KK)*Y+H(J)
154      WRITE(6,350)(H(J),J=1,N)
155      350      FORMAT(//,10X,4HH(J)/(11X,F14.6))
156      22      DO 76 K=1,N
157      76      A(K)=P(K)
158      75      WRITE(6,650)BETA
159      650      FORMAT(1H1,10X,'BETA=',F7.5)
160      IF(IU.NE.1) GOTO 65
161      WRITE(6,700)
162      700      FORMAT(//,1X,'TID      DATA          ',  
       6'KOEFFICIENTER           PREDIKTION',  
       6' PREDIKTIONS- SUM PREDIKTIONS-')
163      WRITE(6,800)KSTEG
164      800      FORMAT(3X,'T      X(T)      A1      A2      A3      A4      A5',  
       6'      A6      A7      A8      A9      A10     XP(T-1,12,  
       6')      FEL      FEL I KVADRAT')
165      WRITE(6,850)(A(J),J=1,N)
166      850      FORMAT(/15X,F9.2,9F7.2)
167      C
168      C      BERÄKNING AV A-PARAMETRarna
169      C
170      65      DO 27 K=1,M
171      XP(K)=0
172      FEL1(K)=0
173      27      FEL2(K)=0
174      IR=0
175      SUM=0
176      DO 26 I=1,M
177      IF(I.EQ.1) GO TO 78
178      C=0
179      DO 15 J=1,N
180      B(J)=0
181      DO 17 J=1,N
182      CALL FIT(J,1,Y)
183      C=A(J)*Y+C
184      15      E=X(I+1)-C
185      DO 18 J=1,N
186      DO 18 KK=1,N
187      17      B(J)=L(KK,J)*A(KK)+B(J)

```

```

192      DO 16 J=1,N
193      16      A(J)=B(J)+H(J)*E
194      C
195      C      BERAKNING AV PREDIKTIONEN
196      C
197      78      DO 20 KK=1,N
198      CALL FIT(KK,KSTEG,Y)
199      JJ=I+KSTEG
200      IF(JJ.GT.M) GO TO 26
201      20      XP(JJ)=A(KK)*Y+XP(JJ)
202      FEL1(JJ)=X(JJ)-XP(JJ)
203      IF(JJ.NE.1) GO TO 28
204      FEL2(JJ)=FEL1(JJ)**2
205      GO TO 29
206      28      FEL2(JJ)=FEL1(JJ)**2+FEL2(JJ-1)
207      29      SUM=SUM+FEL1(JJ)
208      IR=IR+1
209      IF(IU.NE.1) GOTO 26
210      WRITE(6,900) I,X(I),(A(IJ),IJ=1,10),XP(I),FEL1(I),FEL2(I)
211      900      FORMAT(2X,I3,1X,2F9.2,9F7.2,1X,F9.2,F9.2,F15.4)
212      IF(N.LE.10) GOTO 26
213      WRITE(6,901)(A(I),I=10,N)
214      901      FORMAT(15X,F9.2,9F7.2)
215      26      CONTINUE
216      C
217      C      BERAKNING AV VARIANS OCH MEDELFEL
218      C
219      VAR=(FEL2(M)-SUM**2/FLOAT(IR))/FLOAT(IR-1)
220      FMED=SUM/FLOAT(IR)
221      WRITE(6,950) KSTEG,VAR,FMED
222      950      FORMAT(//,10X,'PREDIKTIONSTEG=',12.5X,'VARIANS=',F20.7,
223      65X,'MEDELFEL=',F15.7)
224      IF(IRIT.EQ.0) GO TO 23
225      WRITE(8,64)
226      64      FORMAT('IAVS=ANTAL VARDEN PER SIDA')
227      I=1
228      IAVS=RTTFF(I)
229      CALL RITA(X,XP,M,IAVS)
230      PAUSE 1
231      IF(IRIT.EQ.1) GOTO 23
232      CALL RITA(FEL2,FEL2,M,IAVS)
233      PAUSE 2
234      IF(IRIT.EQ.2) GOTO 23
235      CALL RITA(FEL1,FEL1,M,IAVS)
236      GOTO 23
237      24      CONTINUE
238      STOP
239      END

```

```
001      SUBROUTINE FIT(I,J,Y)
002      T=J
003      GOTO(1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18,19,20),I
004      1      Y=1.
005      2      GOTO 21
006      2      Y=T
007      2      GOTO 21
008      3      Y=T*(T-1.)/2.
009      4      GO TO 21
010      4      Y=SIN(2.*3.1416*T/12.)
011      5      GOTO 21
012      5      Y=COS(2.*3.1416*T/12.)
013      6      GOTO 21
014      6      Y=SIN(2.*3.1416*T/3.)
015      7      GOTO 21
016      7      Y=COS(2.*3.1416*T/3.)
017      8      GOTO 21
018      8      Y=SIN(2.*3.1416*T/6.)
019      9      GOTO 21
020      9      Y=COS(2.*3.1416*T/6.)
021      10     GOTO 21
022      10     Y=SIN(2.*3.1416*T/7.)
023      11     GOTO 21
024      11     Y=COS(2.*3.1416*T/7.)
025      12     CONTINUE
026      13     CONTINUE
027      14     CONTINUE
028      15     CONTINUE
029      16     CONTINUE
030      17     CONTINUE
031      18     CONTINUE
032      19     CONTINUE
033      20     CONTINUE
034      21     CONTINUE
035      21     RETURN
036      21     END
```

APPENDIX A5Dataprogrammet SKATT

Programmet behöver SUBROUTINERNA:

FILES	→ biblioteksprogram
RITA	→ (se appendix A6)

Variabler:

X(200)	→ vektor som innehåller data.
AX(200)	→ vektor som innehåller eventuellt korrigrade X-data.
XP(200)	→ vektor som innehåller prediktionen.
SUM(200)	→ vektor som innehåller summan av AX-data under perioden.
SUMP(200)	→ vektor som innehåller prediktionen av SUM.
FEL1(200)	→ vektor som innehåller prediktionsfel.
FEL2(200)	→ vektor som innehåller summa prediktionsfel i kvadrat.
N	→ antal data.
K	→ prediktionsstegets längd.
ALFA	→ utjämningsfaktor.
VAR	→ varians.
FMED	→ medelfelet ($X(\) - XP(\)$).
IAVS	→ antal värden per sida vid uppritning på display.
IGEN	→ väljare, =1 medför att programmet tas om från början.

```

001 C
002 C      DETTA PROGRAM GOR EN PREDIKTION ENLIGT DEN
003 C      HEURISTISKA METODEN
004 C
005 C      DIMENSION X(200),AX(200),XP(200),SUM(200),SUMP(200),FEL1(200),
006 C      6FEL2(200)
007 C      WRITE(8,1)
008 1      FORMAT(' N=ANTALET DATA')
009 C
010 C      N AR ANTALET DATA
011 C
012 C      I=1
013 C      N=RTTFF(1)
014 C
015 C      LASER IN DATA FRAN REMSA
016 C
017 C      READ(5,2)(X(I),I=1,N)
018 2      FORMAT(F14.5)
019 C
020 C      HAR KAN EN GODTYCKLIG FUNKTION DRAS IFRAN DATA
021 C
022 C      DO 3 I=1,N
023 3      AX(I)=X(I)
024 4      WRITE(8,5)
025 5      FORMAT(' K,ALFA')
026 C
027 C      K AR PREDIKTIONSSTEGETS LANGD
028 C      ALFA AR UTJAMNINGSEFAKTOR
029 C
030 C      I=1
031 C      K=RTTFF(1)
032 C      ALFA=RTTFF(1)
033 C      L=N-K
034 C      DO 21 I=1,N
035 C      FEL1(I)=0.0
036 C      FEL2(I)=0.0
037 21      XP(I)=0.
038 C
039 C      PREDIKTIONEN BERAKNAS
040 C
041 6      DO 9 I=12,L
042 C      S=0.0
043 C      M=I-11
044 C      DO 7 J=M,I
045 7      S=AX(J)+S
046 C      SUM(I)=S
047 C      VIKT=AX(I-11+MOD(K-1,12))/SUM(I)
048 C      IF(I,GT,12) GOTO 8
049 C      S1=SUM(I)
050 C      S2=SUM(I)
051 8      B=1.-ALFA
052 C      S1=ALFA*SUM(I)+B*S1
053 C      S2=ALFA*S1+B*S2
054 C      A=(ALFA/B)*(S1-S2)
055 C      XT=2.*S1-S2
056 C      SUMP(I+K)=XT+A*FLOAT(K)
057 C
058 C      OM GODTYCKLIG FUNKTION DRAGITS IFRAN DATA MASTE DEN
059 C      LAGGAS TILL HAR IGEN
060 C
061 9      XP(I+K)=VIKT*SUMP(I+K)
062 C      LL=12+K
063 C      SU=0.0

```

```

064      IR=0
065      C
066      C      BERAKNING AV VRANS OCH MEDELFEL
067      C
068      DO 10 I=LL,N
069      FEL1(I)=X(I)-XP(I)
070      IF(I,NE,13) GOTO 11
071      FEL2(I)=FEL1(I)**2
072      GOTO 12
073      11      FEL2(I)=FEL1(I)**2+FEL2(I-1)
074      12      SU=SU+FEL1(I)
075      10      IR=IR+1
076      VAR=(FEL2(N)-SU**2/FLOAT(IR))/FLOAT(IR-1)
077      FMED=SU/FLOAT(IR)
078      WRITE(6,13)K,ALFA,VAR,FMED
079      13      FORMAT(//,10X,'PREDIKTIONSSTEG=',I2,5X,'ALFA=',F4.2,5X,'VAR'
080      6F20.7,5X,'MEDELFEL=',F15.7)
081      IAVS=150
082      C
083      C      HAR UPPRITAS DATA PLUS PREDIKTION, PREDIKTIONSFEJL
084      C      OCH SUMMA PREDIKTIONSFEJL I KVADRAT PA DISPLAYEN
085      C
086      CALL RITA(X,XP,N,IAVS)
087      PAUSE 1
088      CALL RITA(FEL2,FEL2,N,IAVS)
089      PAUSE 2
090      CALL RITA(FEL1,FEL1,N,IAVS)
091      15      WRITE(8,17)
092      17      FORMAT(' IGEN=1 IGEN')
093      I=1
094      IGEN=RTTFF(I)
095      IF(IGEN,EQ,1) GOTO 4
096      STOP
097      END

```

ANS='

APPENDIX A6

Dataprogrammet RITA, som ritar på displayen.

Programmet behöver SUBROUTINERNA:

MNMAX = biblioteksprogram
SCALE = biblioteksprogram
AXIS = biblioteksprogram
LINE = biblioteksprogram

Variabler:

X(1) = den ena vektorn som skall uppritas.
XP(1) = den andra vektorn som skall uppritas.
M = antal data.
IAVS = antal värden per sida vid uppritning på displayen.

```

001 C
002 C      SUBROUTINE RITA(X,XP,M,IAVS) RITAR TVA KURVOR
003 C      PA DISPLAYEN
004 C
005 C      SUBROUTINE RITA(X,XP,M,IAVS)
006 C      DIMENSION X(1),XP(1),TID(600),IX(500),IXP(500),ITID(600)
007 C      ITT=1
008 C      CALL MINMAX(X(1),M,UMIN,UMAX,ITT)
009 C      CALL MINMAX(XP(1),M,UMIN,UMAX,ITT)
010 C      MM=(M-1)/IAVS+1
011 C      K=MM*IAVS
012 C      DO 61 I=1,K
013   61 TID(I)=I
014 C      DO 66 KL=1,MM
015 C      KF=(KL-1)*IAVS+1
016 C      KS=KL*IAVS
017 C      CALL SCALE(TID(KF),ITID(KF),IAVS,22.,TID(KF),TID(KS),SMINT,D
018 C      DO 68 J=KF,KS
019   68 ITID(J)=ITID(J)+50
020 C      IF(KL.EQ.MM) GOTO 63
021 C      CALL SCALE(X(KF),IX(KF),IAVS,17.,UMIN,UMAX,SMINX,DSX,0)
022 C      CALL SCALE(XP(KF),IXP(KF),IAVS,17.,UMIN,UMAX,SMINXP,DSXP,0)
023 C      DO 69 L=KF,KS
024 C      IX(L)=IX(L)+150
025   69 IXP(L)=IXP(L)+150
026 C      GOTO 64
027   63 NN=MOD(M-1,IAVS)+1
028 C      CALL SCALE(X(KF),IX(KF),NN,17.,UMIN,UMAX,SMINX,DSX,0)
029 C      CALL SCALE(XP(KF),IXP(KF),NN,17.,UMIN,UMAX,SMINXP,DSXP,0)
030 C      KNN=KF+NN
031 C      DO 70 L=KF,KNN
032 C      IX(L)=IX(L)+150
033   70 IXP(L)=IXP(L)+150
034   64 ASSIGN 1000 TO IFMT
035   1000 FORMAT(7HMANADER)
036 C      ASSIGN 2000 TO IFMU
037   2000 FORMAT(8HX=1,XP=*)
038 C      CALL AXIS(50,150,22.,IFMT,7,0.,SMINT,DST)
039 C      CALL AXIS(50,150,17.,IFMU,8,90.,SMINX,DSX)
040 C      IF(KL.EQ.MM) GOTO 65
041 C      CALL LINE(ITID(KF),IX(KF),IAVS,1,40,7)
042 C      CALL LINE(ITID(KF),IXP(KF),IAVS,1,40,5)
043 C      PAUSE 4
044 C      GOTO 66
045   65 CALL LINE(ITID(KF),IX(KF),NN,1,40,7)
046 C      CALL LINE(ITID(KF),IXP(KF),NN,1,40,5)
047   66 CONTINUE
048 C      RETURN
049 C      END

```

APPENDIX A7Dataprogrammet MLDAT

Programmet behöver SUBROUTINERNA:

FILES = biblioteksprogram

Variabler:

X(500) = vektor som innehåller data.

IT(10) = vektor som innehåller information för senare inläsning till fil.

N = antal data.

DETTA PROGRAM GENERERAR DATA UTAN BRUS

```
001      DIMENSION X(500),IT(10)
002      WRITE(8,1)
003      1      FORMAT(' N')
004      I=1
005      N=RTTF(1)
006      DO 2 I=1,N
007      T=1
008      2      X(1)=118.7662+1.2320*T+0.0229*T*(T-1.)/2.
009      6-9.0959*SIN(2.*3.1416*T/12.)-29.4522*COS(2.*3.1416*T/12.)
010      WRITE(8,3)
011      3      FORMAT(' IT-VEKTORN')
012      I=1
013      DO 4 J=1,10
014      4      IT(J)=RTTF(1)
015      WRITE(7,5)(IT(J),J=1,10),(X(M),M=1,N)
016      5      FORMAT(1X,16/1X,16/1X,16/1X,16/1X,16/1X,16/
017      61X,16/1X,16/1X,16/(1X,F14.5))
018      STOP
019      END
```

APPENDIX A8

SAMMANFATTNING AV MAXIMUM LIKELIHOOD METODEN

ur K.Eklund: Linear drum boiler-turbine models

Rapport 7117, Nov. 1971

The identification problem is to estimate a number of unknown parameters in a model of known structure. The available information is a sequence of measured values of the input variable $\{u(t), t = 1, 2, \dots, N\}$ and the output variable $\{y(t), t = 1, \dots, N\}$ of the process under consideration. The sampling interval is fixed and normalized to 1.

Using the maximum likelihood method it is assumed that the process can be described by a linear model of n:th order and that the disturbance is a stationary gaussian process with rational power spectra. A general model under these assumptions is

$$A^*(q^{-1})y(t) = B_1^*(q^{-1})u(t) + \lambda C^*(q^{-1})e(t) \quad (2.1)$$

In eq. (2.1), $\{e(t)\}$ is a sequence of independent normal (0,1) random variables and q denotes the shift operator

$$qx(t) = x(t+1)$$

The polynomials A^* , B_1^* and C^* are defined as

$$\begin{aligned} A^*(z) &= 1 + a_1 z + \dots + a_n z^n \\ B_1^*(z) &= b_1 z + b_2 z^2 + \dots + b_n z^n \\ C^*(z) &= 1 + c_1 z + \dots + c_n z^n \end{aligned} \quad (2.2)$$

It is assumed that the polynomials $A(z) = z^n A^*(z^{-1})$ and $C(z) = z^n C^*(z^{-1})$ have all zeros inside the unit circle and that there are no factors in com-

mon to all polynomials $A(z)$, $B_1(z)$, $C(z)$.

The parameter λ in the model (2.1) controls the variance of the noise since $\text{var}[\epsilon(t)]$ is normalized to 1.

The problem is solved by establishing the maximum likelihood function for the estimation of the parameters

$$\theta^T = (a_1 a_2 \dots a_n b_1 \dots b_n c_1 \dots c_n)$$

and the parameter λ . The maximizing of the logarithm of the likelihood function

$$\log L(\theta, \lambda) = -\frac{1}{2\lambda^2} \sum_{t=1}^N \epsilon^2(t) - \frac{N}{2} \log \lambda - \frac{N}{2} \log 2\pi \quad (2.3)$$

is equivalent to minimizing the loss function

$$V(\theta) = \frac{1}{2} \sum_{t=1}^N \epsilon^2(t) \quad (2.4)$$

where the residuals $\epsilon(t)$ are obtained from

$$\hat{C}^{*-1}(q^{-1})\epsilon(t) = \hat{A}^{*-1}(q^{-1})y(t) - \hat{B}_1^{*-1}(q^{-1})u(t) \quad (2.5)$$

and \hat{A} , \hat{B}_1 and \hat{C} denotes the estimates of the polynomials A , B_1 and C . The estimation problem is thus equivalent to minimizing a function of several variables.

Knowing the estimate $\hat{\theta}$ and the minimal value $V(\hat{\theta})$ of the loss function the parameter λ is estimated as

$$\hat{\lambda}^2 = \frac{2}{N} V(\hat{\theta}) \quad (2.6)$$

It has been shown [52] that the maximum likelihood estimates are consistent, asymptotically normal and efficient under mild conditions.

The residuals $\epsilon(t)$ have a nice interpretation. It can be shown that the residuals equal the one-step ahead prediction error. Thus the maximum likelihood method tries to estimate the parameters of the model (2.1) in such a way that the sum of squared prediction errors is minimized.

An iterative technique is used to find the minimum of $V(\theta)$ and both the gradient V_{θ} and the matrix of second derivatives $V_{\theta\theta}$ are utilized in the recursive formula for improving the estimate $\hat{\theta}$. Apart from improving the rate of convergence the matrix $V_{\theta\theta}$ also gives the accuracy of the parameters since an estimate of the covariance matrix $\lambda^2 V_{\theta\theta}^{-1}$ then is available.

The order of the model is usually not known a priori. This problem is solved by repeated identification of the parameters in models of increasing order. A statistical test may then be applied to judge, if the loss function has decreased significantly, when model order is increased from n to $n+1$. Let V_i be the minimal value of the loss function for the i :th order model. The null hypothesis is that the model is of order n . Then the test variable

$$F_{n+1,n} = \frac{V_n - V_{n+1}}{V_{n+1}} \frac{N - 3(n+1)}{3} \quad (2.7)$$

has an $F[3, N - 3(n+1)]$ distribution under null hypothesis. When N is large $3F_{n+1,n}$ tends towards a χ^2 distribution with 3 degrees of freedom. Usually the risk level 5 % is used that is, if the test quantity is greater than 2.6 ($N > 100$) then the loss function has been decreased significantly and model order is at least $n+1$.

The material given above is somewhat simplified. The model (2.1) is easily extended to have more than one input. By shifting the time series $\{u(t), t = 1, \dots, N\}$ or $\{y(t), t = 1, \dots, N\}$ the model (2.1) can also be applied to processes where the $B_1^*(z)$ polynomial contains a constant term b_0 . In the same way processes described by the model

$$A^*(q^{-1})y(t) = B^*(q^{-1})u(t-k) + \lambda C^*(q^{-1})e(t) \quad (2.8)$$

where

$$B^*(z) = b_0 + b_1 z + \dots + b_n z^n = b_0 + B_1^*(z)$$

can be handled. The model can thus be extended to contain k time delays.