



LUNDS UNIVERSITET
Statistiska Institutionen

Sambanden mellan inandningsbara, grova och fina partiklar i luften och strokeanfall i Malmö

Jenny Hillström & Joselyne Nsabimana

Uppsats i Statistik
15 högskolepoäng
Nivå 61-90 högskolepoäng
Februari 2008

Handledare: Mats Hagnell

ETT STORT TACK TILL

Fredrik Nilsson, Emelie Stroh, Kristina Jakobsson och Ralf Rittner på Yrkes- och miljömedicin vid Universitetssjukhuset i Lund och Susanna Gustafsson på Miljöförvaltningen i Malmö.

ABSTRACT

In the western world, strokes are the third most common cause of death, hitting mainly the elderly population. Smoking, high blood pressure, diabetes and overweight are known risk factors for causing strokes. Previous studies show that an increased level of particulate matter, PM, is also related to an increased number of strokes.

The population in this study consists of patients over 65 years old who live in Malmö. Levels of particulate matter were measured from October 2004 to April 2005 at a central outdoor monitoring site in Malmö. The data is divided according to the cold and to the warm season. The cold season ranges from October to April and the warm season from May to September.

The purpose of this study is to build models which describe the short-term association between the number of strokes recorded and PM_{10} , $PM_{2.5}$ and $PM_{10}-PM_{2.5}$ respectively. A short-term association means that the incidence of strokes is related to the content of PM in the air that was present up to seven days prior to the stroke. Some meteorological variables may affect the level of PM in the air; therefore, it is possible that these variables might have an indirect association with having a stroke. Taking that into consideration, we have also analysed the association between meteorological variables and the occurrence of strokes in this study. Univariate ARIMA-models and transfer function models are used to find these associations.

The results from the analysis show that there is a positive association between PM_{10} , $PM_{2.5}$ and $PM_{10}-PM_{2.5}$ and having a stroke, but only during the cold season. There is no evidence of any connection between meteorological variables and the occurrence of strokes.

INNEHÅLLSFÖRTECKNING

1 INLEDNING	1
1.1 SYFTE	2
1.2 TIDIGARE STUDIER	2
1.3 AVGRÄNSNINGAR	3
2 DATA	4
2.1 STROKEDATA	4
2.2 PARTIKELDATA	4
2.3 METEOROLOGISKA DATA	6
2.4 BESKRIVANDE STATISTIK	7
2.5 EXTREMVÄRDEN	7
3 TEORI.....	9
3.1 VAL AV METOD	9
3.2 DEN ALLMÄNNA BOX-JENKINS METODOLOGIN FÖR UNIVARIATA MODELLER	9
3.2.1. Tillvägagångssättet i identifiering av en Box-Jenkins modell	9
3.2.2 Parameterskattning	11
3.2.3. Modellutvärdering	11
3.2.4 Prognos	11
3.3 TRANSFERFUNKTIONSMODELLEN	12
4. RESULTAT	13
4.1 IDENTIFIERING AV UNIVARITA ARIMA-MODELLER	13
4.2 IDENTIFIERING AV TRANSFERFUNKTIONSMODELLER	14
4.3 PROGNOSEN	16
5. SLUTSATS	17
REFERENSER.....	18
BILAGOR	

1 INLEDNING

Luftkvaliteten i Sverige har förbättrats de senaste årtionden tack vare omfattande satsningar både på nationell och på internationell nivå för att minska luftföroreningarna. Striktare lagstiftning och lägre gränsvärden för utsläpp har lett till bland annat effektivare reningsfilter och renare bränsle. Fastän det varit en kraftig trafiktillväxt har det totala utsläppet av flera ämnen ändå minskat eftersom nya bilar släpper ut betydligt mindre än gamla (Vägverket 2006). Men dessa förbättringar till trots överskrider ofta de uppsatta miljömålen och årligen söker många människor läkarvård på grund av förorenad luft. Det kan röra sig om allt ifrån astmabesvär till hjärt-kärlsjukdomar.

Studier har visat på att det finns samband mellan strokeanfall och höga halter av luftföroreningar i form av partiklar. På uppdrag av Yrkes- och miljömedicin vid Universitetssjukhuset i Lund ämnar denna uppsats undersöka sambandet mellan strokeanfall och partikelhalten i luften i Malmö. Men då partikelhalten i luften påverkas av en del meteorologiska faktorer antas väderförhållandena ha ett indirekt samband med stroke och därför studeras även dessa samband.

Stroke innebär att man får skador på hjärnan i samband med en blodpropp eller en blödning i hjärnan. Det är den tredje vanligaste dödsorsaken i västvärlden och varje år drabbas ungefär 30 000 svenskar av stroke. Ungefär var fjärde person som insjuknar dör av stroke. De flesta som drabbas är över 65 år och det är vanligare att män drabbas i tidigare ålder än kvinnor. Medelåldern bland män som får stroke är 73 år och densamma för kvinnor är 77 år. Förutom hög ålder så ökar även följande faktorer riskerna för ett anfall; högt blodtryck, hjärt- och kärlsjukdomar i familjen, diabetes, rökning, för lite motion, hög alkoholkonsumtion och höga blodfetter som ökar risken för åderförkalkning. (Sjukvårdsrådgivningen 2006) Även partikelhalten i luften förmodas vara en riskfaktor. I en studie från Helsingfors antas sambandet mellan luftföroreningar och stroke utgå ifrån inflammation i blodkärlen. Personer som utsätts för höga partikelhalter får ökat blodtryck och plasmaviskositet, dvs. blodet tjocknar. Detta är indikatorer på hemodynamiska störningar och en ökning av inflammationsmarkörer i cirkulationen, vilka i sin tur är riskfaktorer för stroke (Kettunen et al. 2007). I en annan studie från New York undersöks sambandet mellan strokeanfall och väder, luftföroreningar och säsongeffekter där kopplingen tros vara alveolär inflammation (Low et al. 2006).

Det är framförallt de inandningsbara, fina och ultrafina partiklarna som tros ha samband med stroke eftersom de kommer in långt ned i andningsvägarna jämfört med större partiklar. I denna studie används data på de inandningsbara partiklarna PM_{10} , de fina partiklarna $PM_{2.5}$ och de grova partiklarna $PM_{10}-PM_{2.5}$. Data på de ultrafina partiklarna $PM_{<0.1}$ saknas. PM står för materia i form av partiklar och beteckningarna PM_{10} och $PM_{2.5}$ betyder att partiklarna har en diameter mindre än 10 μm respektive 2.5 μm . Av de inandningsbara partiklarna kommer en stor del från gatudamm och de fina partiklarna är till största delen avgaspartiklar bland annat ifrån trafik, energiproduktion och vedeldning. Då de fina partiklarna även kan komma in i inomhusluften blir personer bosatta nära trafiktäta områden extra utsatta. (SAD 2007)

Partikelhalten i luften är också beroende av vissa meteorologiska faktorer. Det är inte bara svenska utsläpp som drabbar Sverige utan även andra länders utsläpp. Beroende på vindriktning och vindhastighet kan partiklar transporteras mycket lång väg. Temperaturen kan också inverka på hur hög koncentrationen av partiklar blir. Bland annat finns ett fenomen som kallas markinversion vilket innebär att luften och dess föroreningar binds vid marknivå. Vid

inversion stiger temperaturen med ökande höjd, marken kyls ned och så också luften vid markytan. Den kalla luften är tyngre och kan därför inte blanda sig med den varmare luften högre upp. Koncentrationen av partiklar och föroreningar blir därför högre när de inte kan ventileras bort. Inversion uppstår oftast på nätterna och när det är svaga vindar (SMHI 2006). Regn och vind hjälper till att effektivt rena luften från partiklar.

1.1 Syfte

Syftet med denna uppsats är att med hjälp av tidsserieanalys ta fram modeller som beskriver det kortsiktiga sambandet mellan partikelhalten i luften och antalet strokeanfall per dygn. Med det kortsiktiga sambandet menas hur antalet strokeanfall en given dag påverkas av partikelhalten på den dagen och upp till sju dagar innan.

1.2 Tidigare studier

Det har gjorts liknande studier tidigare där samband mellan partikelhalten och strokeanfall studerats. Till exempel gjordes en undersökning i Helsingfors i Finland 2006 där sambandet mellan inandningsbara, fina partiklar och stroke med dödlig utgång studerades. Metoden som användes i den studien var poissonregression, då sannolikheten att få ett strokeanfall är liten. Även i den modellen ingick en del meteorologiska variabler såsom temperatur, relativ luftfuktighet och barometriskt tryck. De använde sig också av dummy-variabler för veckoslut och allmänna helgdagar. Resultaten av denna studie visade att det fanns ett samband mellan partiklar och stroke under den varma säsongen (maj-september) men inte under den kalla säsongen (oktober-april) eller för hela året. $PM_{2.5}$ visade sig signifikant vid lag 0 och lag 1, alltså på insjukningsdagen och dagen innan. PM_{10} hade signifikant samband endast på lag 0. När $PM_{2.5}$ och PM_{10} - $PM_{2.5}$ studerades tillsammans i en modell erhöles ett signifikant samband på lag 1. (Kettunen et al. 2007)

I Sverige har undersökningar gjorts där sambandet mellan partikelhalten och luftvägs-sjukdomar studerats. Samtliga av de tre undersökningar vi har tagit del av har använt liknande metoder som i Helsingfors med poissonregression (Segerstedt et al. 2002), (Forsberg et al. 2003) och (Fahlén et al. 2005). Men till skillnad från Helsingfors-studien nämner ingen av de svenska studierna att de tagit hänsyn till autokorrelation i residualerna.

En studie i Frankrike (Henrotin et al. 2007) och en i Kanada (Villeneuve et al. 2006) använder sig av villkorlig logistik regression. Den franska studien undersöker sambandet mellan stroke och luftföroreningar. I regressionsmodellen inkluderades också meteorologiska faktorer, influensaperioder och helgdagar. Resultatet visar på ett samband mellan stroke och ozonhalten. I Kanada undersöktes också sambandet mellan stroke och luftföroreningar men här användes även logistisk regression för att beräkna oddskvoterna och deras konfidensintervall. Enligt denna studie finns inget samband mellan stroke och luftföroreningar däremot visar oddskvoterna på en signifikant ökad risk mellan luftföroreningar och strokeanfall under varm säsong.

I en studie från USA har man studerat sambandet mellan stroke och väderförhållanden, luftburna allergener, luftföroreningar, övre luftvägsinfektioner, säsonger, astmaanfall, den 11 september 2001 och veckodag. Metoden som används är tidsserieanalys och sambandet illustreras med hjälp av en transferfunktionsmodell (TF-modell). Studiens resultat visar att det finns signifikanta samband mellan stroke och temperatur, torr luft, övre luftvägsinfektioner,

gräspollen, svaveldioxid och partiklar < 10 µm. Effekterna är ökningarna på 0.6, 0.6, 2.4, 1, 0.9 och 0.7 strokeanfall per dag på respektive signifikant variabel. (Low et al. 2006)

1.3 Avgränsningar

Studien begränsas till att undersöka patienter över 65 år som bor i Malmö och som mellan oktober 2004 och september 2005 uppsökt läkare på grund av strokeanfall. Vi väljer sedan att dela in den aktuella perioden i kall och varm säsong. Den kalla säsongen sträcker sig från oktober till och med april medan den varma säsongen löper från maj till och med september. Flera tidigare studier har också haft en uppdelning på säsonger och anledningen till det är temperaturvariationerna. Av de meteorologiska variablerna väljer vi att ta med temperatur, vindhastighet och luftfuktighet. Vindriktning har vi bortsett ifrån då vi inte vet i vilken riktning från mätstationen patienterna bor. För global strålning har vi inte funnit någon förklaring till hur den kan påverka stroke. Regn har uteslutits på grund av att variabeln inte är särskilt kvantitativ. Det regnar oftast ingenting och enstaka dagar har extrema toppar. Inte heller har de utelämnade variablerna tagits med i liknande studier som vi har tagit del av.

2 DATA


Tre olika datamaterial ligger till grund för den här studien. Två av dem har tillhandahållits från Yrkes- och miljömedicin på Universitetssjukhuset i Lund, ett som visar alla personer i Skåne som sökt läkarhjälp för stroke och ett över dagliga halter av partiklar i luften. Det tredje kommer från miljöförvaltningen i Malmö med data över meteorologiska faktorer.

2.1 Strokedata

Data över strokepatienterna har samlats in från tolv olika sjukhus i region Skåne och sammanställts via sjukhusens patientregistrering. Materialet används i studien efter av-identifiering. Data innehåller uppgifter om patienternas insjukningsdatum, kön, om de har haft stroke tidigare, om de har haft förmaksflimmer, om de har diabetes, om de tar blodtrycksmedicin, om de röker, vilket typ av stroke de fått och om de bor i Malmö. I denna studie används kvantitativa metoder och därför väljer vi att utesluta de kvalitativa variablerna som t.ex. kön.

Inledningsvis sorteras patienterna efter om de är bosatta i Malmö eller inte. Sedan väljs Malmö-gruppen eftersom det är oklart var de andra bor. Ytterligare en indelning görs på ålder, personer upp till 64 år placeras i gruppen yngre och gruppen äldre innehåller de personer som är 65 år och uppåt. Skälen till åldersindelningen är att de flesta som drabbas är över 65 år och att tidigare studier har gjort en liknande uppdelning. Då gruppen yngre endast består av 16 % av Malmö-patienterna bortser vi från dem i denna studie. När gruppen som ska studeras valts ut sorteras data om för att bli dygnsdata istället för att som från början baseras på insjukningsdatum. Totalt tas 1894 patienter med i studien utav de 11304 som ingick i det ursprungliga datamaterialet.

I figur 2.1 visas diagram över strokedata uppdelat på kall och varm säsong. På varm säsong kan man ana att det finns ett extremvärde, en s.k. uteliggare, på näst sista observationen. En uteliggare är en observation som ligger mer än ett och ett halvt kvartilsavstånd till vänster om första kvartilen eller lika långt till höger om tredje kvartilen. (Körner et al. 2002).




Figur 2.1 Tidsseriediagram över Stroke för kall och varm säsong

2.2 Partikeldata


Partikeldata kommer från en mätstation som finns på rådhuset i Malmö och partiklarna är mätta i mikrogram per kubikmeter. Det ursprungliga datamaterialet på mätningarna av $PM_{2.5}$ och PM_{10} bestod av observationer per timme under åren 2001-2005. För att studera sambandet med stroke beräknas timobservationerna om till dygnsmedelvärden för att få samma mått som

på strokedata. Detta görs dock endast på de dagar där det finns ett uppmätt värde på minst 75 % av timmarna. När en dag saknar för många timvärden sätts hela dagen som saknad. Efter att alla dygnsmedelvärden beräknats stryks de dagar som saknar medelvärde på både PM_{2.5} och PM₁₀, vilket blir totalt 71 dagar. Det är särskilt under 2003 som många dagar saknas och för att minska osäkerheten i materialet väljs därför endast ett år ut för att användas i studien. Eftersom vi vill undersöka om det finns något samband på varm och kall säsong väljs perioden oktober 2004 till september 2005 till studeringsperiod. Under denna period är det endast en dag, 12 oktober, som inte har något uppmätt dygnsmedelvärde på vare sig PM_{2.5} eller PM₁₀.


Eftersom PM₁₀ omfattar PM_{2.5} bildar vi också en extra variabel, PM₁₀-PM_{2.5}, över grova partiklar. I figur 2.2-2.4 nedan visas tidsseriediagram över de tre variablerna och en del extremvärden anas på både kall och varm säsong på respektive variabel.



Figur 2.2 Tidsseriediagram över PM_{2.5} för kall och varm säsong



Figur 2.3 Tidsseriediagram över PM₁₀ för kall och varm säsong




Figur 2.4 Tidsseriediagram över PM₁₀-PM_{2.5} för kall och varm säsong


2.3 Meteorologiska data

Det meteorologiska datamaterialet kommer från en mätstation i Malmö. De uppmätta variablerna är temperatur (°C), vindriktning (°), vindhastighet (m/s), global strålning (W/m²), relativ luftfuktighet (%) och regn (mm/Dygn). Alla variablerna har dygnsvärden och mätenheten står inom parentes. I denna studie har vi valt att inte ta med variablerna vindriktning, global strålning och regn. Variabeln temperatur saknar uppmätta värden under datumen 29 november till 4 december, 2004 och 6 december till 14 december samma år. Dessa saknade värden ersätts med motsvarande värden år 2005.


Tidsseriediagram över de meteorologiska variablerna som tas med i denna uppsats finns i figur 2.5-2.7.



Figur 2.5 Tidsseriediagram över Temperatur för kall och varm säsong



Figur 2.6 Tidsseriediagram över Vindhastighet för kall och varm säsong



Figur 2.7 Tidsseriediagram över Luftfuktighet för kall och varm säsong

2.4 Beskrivande Statistik

Beskrivande statistik på datamaterialet som studien avser presenteras säsongsvis i tabell 2.1. Det totala antalet dagar som ingår i kall och varm säsong är 211 respektive 153, men för den beroende variabeln stroke sparas de 15 sista dagarna för att användas som jämförelse och kontroll av prognoserna. Det högsta antalet strokeanfall per dygn är fem och sex på kall respektive varm säsong. I genomsnitt får drygt en person per dygn ett strokeanfall under båda säsongerna, det låga medelvärdet beror på att det är många dagar då det inte inträffar ett enda anfall. Det är också ytterst få dagar med antal strokeanfall högre än två.

Av figur 2.2 och figur 2.3 framgår att februari månad har den högsta halten av PM_{2.5} och PM₁₀. Under perioden som studeras har inga extremt kalla dagar eller varma dagar noterats. Den lägsta temperatur som uppmätts är -5.67 °C i mars och den högsta 24.02 °C i juli.

Vindhastigheten har inga stora variationer mellan dagarna på varm säsong medan det finns en del dagar med hög vindhastighet under kall säsong. Luftfuktigheten har lite högre värden under kall säsong än under varm säsong.

Variabel	Antal dagar	Medel-värde	Medel-fel	Standard-avvikelse	Minimum	Q1	Median	Q3	Maximum
KALL SÄSONG									
PM _{2.5}	211	11,14	0,39	5,68	4,89	7,43	9,8	12,68	42,4
PM ₁₀	211	16,86	0,51	7,41	6,41	12,01	15,72	20,16	51,1
PM ₁₀ -PM _{2.5}	211	5,54	0,22	3,17	0,36	3,05	4,82	7,35	17,1
TEMPERATUR	211	4,64	0,29	4,24	-5,67	1,82	4,86	7,71	14,4
VINDHASTIGHET	211	3,83	0,1	1,49	1,42	2,71	3,66	4,55	9,57
LUFTFUKTIGHET	211	78,64	0,8	11,62	41,45	71,69	80,06	87,34	96,3
STROKE	196	1,13	0,07	1,04	0	0	1	2	5
VARM SÄSONG									
PM _{2.5}	153	10,06	0,32	3,92	4,53	7,47	9,3	11,3	29,84
PM ₁₀	153	17,2	0,48	5,89	7,94	12,94	15,83	20,91	39,46
PM ₁₀ -PM _{2.5}	153	7,14	0,27	3,28	0,77	4,97	6,53	8,86	17,93
TEMPERATUR	153	15,78	0,27	3,35	8,25	13,81	15,94	18,01	24,02
VINDHASTIGHET	153	3,29	0,09	1,06	1,51	2,37	3,21	3,89	5,67
LUFTFUKTIGHET	153	73,24	0,96	11,91	41,45	65,23	75	81,6	94,65
STROKE	138	1,14	0,1	1,16	0	0	1	2	6

Tabell 2.1 Beskrivande statistik, kall och varm säsong

2.5 Extremvärden

Extremvärden i denna studie har identifierats enligt definitionen i avsnitt 2.1. Observationer som därefter betraktas som extrema ersätts med gränsvärdet för uteliggare. Gränsvärdena beräknas enligt formlerna 2.1 och 2.2.

$$\text{Undre gränsen} = Q_1 - 1.5 * (Q_3 - Q_1) \quad (2.1)$$


$$\text{Övre gränsen} = Q_3 + 1.5 * (Q_3 - Q_1) \quad (2.2)$$

Tabell 2.2 visar de övre gränsvärdena och hur många observationer som har ersatts. Det är endast fyra stycken låga extremvärden och samtliga finns på luftfuktighet under kall säsong.


	Övre gränsen för uteliggare		Antal ersatta observationer	
Variabler	Kall säsong	Varm säsong	Kall säsong	Varm säsong
PM _{2,5}	20,56	17,04	14	7
PM ₁₀	32,39	32,85	9	4
PM ₁₀ -PM _{2,5}	13,8	14,7	3	6
TEMPERATUR	16,55	24,31	0	0
VINDHASTIGHET	7,31	6,16	6	0
LUFTFUKTIGHET	110,82	106,14	0	0
STROKE	5	5	0	1

Tabell 2.2 Extremvärden


Även spridningsdiagram kan användas för att identifiera uteliggare med hänsyn på den beroende variabeln. Observationer som inte ligger inom en tänkt ellips med 45 graders lutning betraktas som uteliggare. Spridningsdiagram över partiklarna finns i figur 2.8-2.10 nedan.



Figur 2.8 Spridningsdiagram för stroke och PM_{2,5}, kall och varm säsong



Figur 2.9 Spridningsdiagram för stroke och PM₁₀, kall och varm säsong



Figur 2.10 Spridningsdiagram för stroke och PM₁₀-PM_{2,5}, kall och varm säsong

3 TEORI

Datamaterialet som ligger till grund för denna studie är tidsseriedata och därför är det lämpligt att använda en tidsserieregessionsmodell för att hitta sambandet mellan partikelhalten i luften och antalet strokeanfall.

3.1 Val av metod

För att välja metoder som passar data och syfte i denna uppsats granskas de metoder som använts i tidigare studier från avsnitt 1.2. Tre olika metoder har använts och det visar på att det hittills inte finns någon enhetlig metod på området.

I tidigare studier där regressionsmodeller använts har man behövt ta med många variabler som t.ex. influensaperioder, väderförhållanden och trendfunktioner för att eliminera långtidsvariationen då luftföreningar beror på årstidsvariationer. Dessa variabler tas med eftersom det är det kortsiktiga sambandet som vill studeras. När flera variabler tas med i modellen fås en högre förklaringsgrad men frihetsgraderna blir färre och man riskerar problem med multikolinjäritet. Dessutom behöver hänsyn tas till autokorrelation i residualerna när regressionsmodeller används på tidsseriedata. För att komma till rätta med dessa problem används Box-Jenkins metodologin i denna studie. Box-Jenkins metodologin väljs dessutom för att grundidén i metodologin är att få enklare modeller med bättre prognoser än modeller med många variabler (Enders 2004).

Inom Box-Jenkins metodologin är en transferfunktions-modell (TF-modell), den modell som används för att prognostisera värdena av en beroende tidsserie med hjälp av en eller flera oberoende variabler. TF-modellen används i denna uppsats till att beskriva sambandet mellan stroke och partikelhalten i luften. I den amerikanska studien insågs också efter preliminära analyser att TF-modeller behövdes för att undvika underskattningar av strokeprognoserna. I denna uppsats görs även prognoser på antalet strokeanfall och de används till att utvärdera hur bra modellerna är. Ingen av de nämnda tidigare studierna har gjort en sådan utvärdering.

I följande avsnitt presenteras den allmänna Box-Jenkins metodologin för univariata modeller och tillvägagångssättet i skapandet av en transferfunktionsmodell. Dessa metoder är i första hand hämtade från läroboken *Forecasting, Time Series and Regression* (Bowerman et al. 2005) men även en del från *Time Series Analysis, Univariate and Multivariate Methods* (Wei 1990).

3.2 Den allmänna Box-Jenkins metodologin för univariata modeller

Box-Jenkins metodologin utförs i fyra steg. I det första steget används tidsseriedata för att försöka identifiera en Box-Jenkins modell som beskriver tidsserien. I det andra steget används data för att skatta parametrarna i modellen. I det tredje steget används olika metoder för att kontrollera den anpassade modellens lämplighet och om modellen behöver förbättras. När väl den slutliga modellen identifierats blir det sista steget att använda modellen för att skatta framtida observationer.

3.2.1. Tillvägagångssättet i identifiering av en Box-Jenkins modell

En tidsserie betraktas som stationär om väntevärdet, μ , och variansen, σ^2 , är konstanta över tiden. Då Box-Jenkins modeller beskriver stationära serier måste man först undersöka om serien som ska prognostiseras är stationär.

Först görs en noggrann undersökning av tidsseriediagrammen. Tidsseriediagrammen visar om data innehåller extremvärden, icke-konstant varians, en tydlig trend, säsongvariationer eller andra tecken på icke-stationäritet.

Om icke-konstant variation anas utförs en predifferens-transformation. Vilken predifferens-transformation som är bäst lämpad för data fås antingen med hjälp av Box-Cox transformation i Minitab eller genom att pröva sig fram med olika transformationer. Vid prövning av olika transformationer tas även hänsyn till vilken transformation som har ett p-värde på mer än 5 % för normalitetstestet.

Sedan tittar man också på autokorrelationsfunktionerna (ACF) och de partiella autokorrelationsfunktionerna (PACF). Om ACF avtar långsamt och PACF bryter efter lag 1, är det tecken på att en transformation behövs. Två vanliga transformationer för data utan säsongvariation är första differensen respektive andra differensen.

Den generella stationäritetstransformationen för data utan säsongvariation ges av formeln:

$$z_t = \nabla^d y_t^* = (1 - B)^d y_t^* \quad (3.1)$$

I ekvationerna står B för bakåtoperatoren, d för graden av icke-säsongdifferens, d antar värdet ett och två för första respektive andra differensen och y_t^* betyder att tidsserien predifferens-transformerats.

En tumregel är att ta differensen tills standardavvikelsen inte längre minskar. Den stationära serien är oftast den med minst standardavvikelse.

När det är klart vilken transformation som är stationär går man vidare med att identifiera en lämplig modell för den stationära serien genom att bestämma ordningen av p och q för följande ARMA (p,q)-modell:

$$\phi_p(B)z_t = \theta_q(B)a_t \quad \text{där} \quad (3.2)$$

$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ är den autoregressiva operatoren (AR),

$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$ är den löpande medelvärdesoperatoren (MA)

och feltermerna, a_t , är $N(0, \sigma_a^2)$

Den lämpliga modellen identifieras genom att undersöka autokorrelationsfunktionen och den partiella autokorrelationsfunktionen. Först tittar man på vilken av de två som har en klar brytning.

Om ACF har en klar brytning och PACF avtar väljs en MA(q)-modell och om ACF avtar och PACF har en klar brytning väljs en AR(p)-modell. Skulle både ACF och PACF bryta provar man med en MA(q)-modell respektive en AR(p)-modell och sedan väljs den modell som har de bästa skattningarna och de högsta p-värdena på Ljung-Box testet. Om både ACF och PACF avtar bildas en ARMA(p,q)-modell. Det finns ingen lämplig Box-Jenkins modell för serier vars ACF och PACF inte har några signifikanta laggar.

Innan parametrerna skattas ska det bestämmas i fall det behövs en konstant i modellen eller inte. En konstant tas med i modellen om det beräknade absoluta t-värdet överstiger två, vilket betyder att konstanten är signifikant skild från noll med ett 95 % konfidensintervall. Här följer formeln för t-värdet:

$$t_{\bar{z}} = \frac{\bar{z}}{s_{\bar{z}}} \quad \text{där } \bar{z} \text{ är tidsseriens medelvärde och } s_{\bar{z}} \text{ är medelfelet.} \quad (3.3)$$

3.2.2 Parameterskattning

För att parametrarna ska kunna skattas ställs stationaritets- och invertibilitetskrav på den valda modellen. På MA-modellen ställs invertibilitetskrav, på AR-modellen ställs stationaritetskrav och på den blandade ARMA-modellen ställs båda kraven. Punktskattningarna måste utöver stationaritets- och invertibilitetskraven även vara signifikant skilda från noll och inte starkt korrelerade.

3.2.3. Modellutvärdering

Modellutvärdering innebär att man kontrollerar om feltermerna är vitt brus. Vitt brus betyder att de skattade residualerna har ett väntevärde ungefär lika med noll och att de är okorrelerade, likafördelade och normalfördelade. För att kontrollera om kraven för vitt brus är uppfyllda görs en autokorrelationscheck genom att utföra ett Ljung-Box test. Ljung-Box test prövar hypotesen att de k ($k=6,12,18,24,30$) första autokorrelationerna av residualerna är ungefär lika med noll.

Även om Ljung-Box test indikerar att modellen är bra, granskas också autokorrelationsfunktionerna av residualerna (RACF) och de partiella autokorrelationsfunktionerna av residualerna (RPACF) för att kontrollera om det finns några laggar som är signifikanta. Finns det signifikanta autokorrelationer eller partiella autokorrelationer ska de användas för att modellera feltermerna, så att modellen förbättras.

3.2.4 Prognos

För att kontrollera hur väl modellerna skattar antalet strokeanfall per dygn, görs prognoser för stroke med hjälp av både en univariat modell och TF-modeller. De prognostiserade värdena jämförs sedan med de 15 sparade observationerna på stroke. Dessutom jämförs prognosmodellerna med varandra för att få fram vilken prognosmodell som bäst prognostiserar antalet strokeanfall per dygn. För att göra prognoserna används en enstegsprognos-metod. För att jämföra modellerna används följande utvärderingsmått:

$$PME = \frac{\sum_{t=1}^n e_t}{n} \quad \text{Medelvärde av de skattade residualerna} \quad (3.4)$$

$$PMSE = \frac{\sum_{t=1}^n e_t^2}{n} \quad \text{Medelvärde av de skattade residualerna i kvadrat} \quad (3.5)$$

PME ger prognosfelen i medeltal och visar om prognosmodellen i genomsnitt över- eller underskattar antalet strokeanfall per dygn. Den bästa prognosmodellen är den där PME är så nära noll som möjligt i absoluta värden och med det minsta värdet på PMSE.

3.3 Transferfunktionsmodellen

Om en beroende serie och en oberoende serie beskrivs med y_t respektive x_t ser formeln för den generella transferfunktionsmodellen ut på följande sätt:

$$z_t = \mu + \frac{Cw(B)}{\delta(B)} B^b z_t^{(x)} + \varepsilon_t \quad (3.6)$$

I ovanstående formel representerar z_t de stationära y_t -värdena, och $z_t^{(x)}$ de stationära x_t -värdena. C är en skalparameter som skattas och b är antalet perioder innan x_t börjar påverka y_t .

Först görs en förblekning av z_t och $z_t^{(x)}$ för att ta reda på sambandet mellan dem. Förblekning innebär att man anpassar en ARMA-modell för $z_t^{(x)}$ enligt:

$$\phi_p^{(x)} z_t^{(x)} = \theta_q^{(x)} a_t \quad (3.7)$$

Parameterskattningarna i ovanstående modell används sedan för att beräkna de filtrerade värdena för variablerna $z_t^{(x)}$ respektive z_t enligt följande formler:

$$\alpha_t = \frac{\phi_p^{(x)}}{\theta_q^{(x)}} z_t^{(x)} \quad \text{och} \quad \beta_t = \frac{\phi_q^{(x)}}{\theta_p^{(x)}} z_t \quad (3.8)$$

Nästa steg blir att skatta $r_k(\alpha_t, \beta_t)$, korskorrelationsfunktionen (CCF) mellan α_t och β_t . Analysen börjar med att identifiera var den första signifikanta korskorrelation förekommer på positiva laggar. Denna lag är lika med parametern b , den tid det tar innan x_t börjar påverka y_t . Vidare bestäms ordningen av $w(B)$:

$$w(B) = (1 - w_1 B - w_2 B^2 - \dots - w_s B^s) \quad (3.9)$$

$w(B)$ kallas täljaroperatoren för B av ordning s och s representerar antalet tidigare observationer av $z_t^{(x)}$ som påverkar z_t . Värdet av s ges av antalet laggar som finns mellan den första signifikanta laggen och tills ett tydligt avtagande mönster börjar. Till sist identifieras ordningen för $\delta(B)$:

$$\delta(B) = (1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r) \quad (3.10)$$

$\delta(B)$ kallas nämnaroperatoren för B av ordning r , där r står för antalet av sina egna tidigare observationer som z_t är relaterat till. r bestäms genom att studera vilket avtagande mönster den skattade CCF följer på laggar efter lag $(b+s)$. Om CCF avtar som en dämpad exponentiell kurva sätts r lika med ett och om CCF avtar i en dämpad sinusvåg sätts r till två.

I det här läget har man en preliminär TF-modell som sedan används för att skatta residualerna. Det som sedan kvarstår att göra är en modellutvärdering. Först kontrolleras om korskorrelationscheck av residualer och oberoende variabel ger höga p-värden på de k första korskorrelationerna. Ifall p-värdena är höga går man vidare och tittar om autokorrelationscheck av residualer visar en bra modell. Om residualerna är autokorrelerade identifieras modellerna för feltermerna från RACF och RPACF. Därefter kan den slutliga TF-modellen etableras och prognoserna göras.

4. RESULTAT

Redovisningen av resultaten kommer att följa ordningen i teoriavsnittet och resultaten finns i bilaga A till E.

4.1 Identifiering av univarita ARIMA-modeller

Första steget är att undersöka om variablerna är stationära och bestämma vilken transformation som behövs. I bilaga A anges de predifferens-transformationer som tycks lämpade för respektive variabel på kall och varm säsong. Därtill indikerar * den transformation som anses vara stationär. De valda stationära serierna är de med lägst standardavvikelse, högt p-värde för normalitetstest och snabbt avtagande ACF och PACF. Men alla transformationer har inte entydigt uppfyllt de fyra kraven och därför har vissa bedömningar gjorts för att välja de stationära serierna. I de flesta fall är ACF och PACF avgörande, de finns i bilaga B.

På kall säsong är det inversen av roten ur $PM_{2.5}$ som har högst p-värde men då den transformationen vänder på sambandet väljs istället $\ln PM_{2.5}$. $\ln PM_{2.5}$ väljs trots att den har lågt p-värde eftersom det är den vanligaste transformationen. Anledningen till att $\ln PM_{2.5}$ väljs framför första differensen är att det inte skiljer mycket mellan standardavvikelserna och den ger en bättre modell. Även för $PM_{10}-PM_{2.5}$ väljs roten ur $PM_{10}-PM_{2.5}$ framför första differensen trots att standardavvikelsen är högre och p-värdet är lägre. Det beror på att ACF och PACF avtar snabbare. På varm säsong har liknande bedömningar gjorts på $PM_{2.5}$ och luftfuktighet som inte är entydiga.

Andra steget blir att identifiera univariata ARIMA-modeller genom att analysera hur ACF och PACF avtar. För $\ln PM_{2.5}$, $\ln PM_{10}$, roten ur $PM_{10}-PM_{2.5}$ och \ln vindhastighet är det PACF som har tydlig brytning på kall säsong och därför väljs AR-modeller. För luftfuktighet är det ACF som bryter och således väljs en MA-modell. För stroke bryter både ACF och PACF och efter att ha provat med båda väljs en MA-modell. På varm säsong är det $\ln PM_{2.5}$, $\ln PM_{10}$ och luftfuktigheten i kvadrat som följer AR-modeller och $\ln PM_{10}-PM_{2.5}$, roten ur temperatur och \ln vindhastighet följer MA-modeller. För stroke under varm säsong går det inte få någon modell överhuvudtaget då den saknar signifikanta laggar. Modellerna finns i bilaga C.

Vidare tas en konstant med i respektive modell om t-värdet överstiger två, t-värdet finns i bilaga A. På kall säsong är det endast temperatur och luftfuktighet som inte har med en konstant och på varm säsong är det temperatur och vindhastighet. Alla parametrar för de slutliga modellerna är signifikant skilda från noll. Även korrelationen mellan parametrarna och autokorrelationscheck visar på bra modeller. På stroke, under kall säsong, behövs dock även feltermerna modelleras för att hitta en bra modell.

Av de 13 univariata ARIMA-modeller som anges i bilaga C skrivs två av dem ut i formler nedan. Det är ett specialfall av en MA(6)-modell för luftfuktighet på kall säsong (4.1) och ett specialfall av en AR(14)-modell med konstant för luftfuktighet på varm säsong (4.2).

$$z_t = (1 - \theta_1 B - \theta_2 B^2 - \theta_4 B^4 - \theta_6 B^6) a_t \quad \text{där } z_t = (1 - B) y_t^* \quad (4.1)$$

$$(1 - \phi_1 B - \phi_6 B^6 - \phi_{14} B^{14}) z_t = \delta + a_t \quad \text{där } z_t = y_t^* \quad (4.2)$$

4.2 Identifiering av transferfunktionsmodeller

De valda univariata modellerna i föregående avsnitt används sedan för att beräkna värdena på α_t och β_t enligt formeln 3.8, därefter skattas CCF mellan α_t och β_t . Det är enbart partikelvariablerna på kall säsong som har positiva signifikanta laggar på korskorrelationsfunktionen med stroke, se bilaga D. De övriga variablerna visar antingen inget eller negativt samband.

Enligt figur D.1 förekommer den första positiva korskorrelationen mellan $\ln PM_{2.5}$ och stroke vid lag 0, vilket ger $b=0$ i formeln 3.6. $w(B)$ får ordningen 7 med endast lag 1 och 7 signifikanta i formeln 3.9. Det tycks inte finnas något tydligt avtagande mönster och därför sätts r till 0 i formeln 3.10. Den preliminära transferfunktionsmodellen för $\ln PM_{2.5}$ ges av följande formel:

$$z_t = C(1 - w_1 B - w_7 B^7) z_t^{(x)} + \varepsilon_t \quad (4.3)$$

Från den preliminära TF-modellen skattas residualerna och från dess ACF och PACF modelleras feltermerna. Feltermerna följer ett specialfall av en AR(6)-modell med signifikanta laggar på 1 och 6. Den slutliga transferfunktionsmodellen i figur E.1 får därför följande formel:

$$z_t = C(1 - w_1 B - w_7 B^7) z_t^{(x)} + (1 - \phi_1 B - \phi_6 B^6) \varepsilon_t + a_t \quad (4.4)$$

och med insatta värden:

$$z_t = 0,498(1,341B + 0,641B^7 - 1) z_t^{(x)} + (1 + 0,160B - 0,150B^6) \varepsilon_t + a_t \quad (4.5)$$

Av formeln framgår att antalet strokeanfall påverkas av $PM_{2.5}$ i luften upp till sju dagar innan. Antalet strokeanfall en given dag ges av 32 % av $\ln PM_{2.5}$ sju dagar innan plus 67 % av $\ln PM_{2.5}$ dagen innan minus 50 % av $\ln PM_{2.5}$ samma dag plus feltermerna.

Första positiva korskorrelationen mellan $\ln PM_{10}$ och stroke är vid lag 1, vilket ger $b=1$. Som ses i figur D.2 tillhör den signifikanta laggen det avtagande mönstret därför blir $s=0$ i formeln 3.9. Eftersom det inte finns något tydligt avtagande mönster sätts $r=0$. Den preliminära transferfunktionsmodellen ges av följande formel:

$$z_t = CB z_t^{(x)} + \varepsilon_t \quad (4.6)$$

Från den preliminära TF-modellen skattas residualerna och de följer ett specialfall av AR(10)-modell med signifikanta laggar på 1, 4 och 10. Den slutliga transferfunktionsmodellen i figur E.2 får därför följande formel:

$$z_t = CB z_t^{(x)} + (1 - \phi_1 B - \phi_4 B^4 - \phi_{10} B^{10}) \varepsilon_t + a_t \quad (4.7)$$

och med insatta värden:

$$z_t = 0,410B z_t^{(x)} + (1 + 0,169B + 0,155B^4 - 0,162B^{10}) \varepsilon_t + a_t \quad (4.8)$$

Av modellen framgår att risken för att få ett strokeanfall påverkas av partikelhalten av PM₁₀ dagen innan. Antalet strokeanfall blir lika med 41 % av ln PM₁₀ dagen innan plus den slumpmässiga faktorn.

För roten ur PM₁₀-PM_{2.5} är det endast lag 1 som är signifikant. Den preliminära transfersfunktionsmodellen blir som formel 4.6 plus en konstant. Av den preliminära TF-modellen skattas residualerna och de följer ett specialfall av en AR(7)-modell med signifikanta laggar på 1 och 7. Den slutliga TF-modellen i figur E.3 får följande formel:

$$z_t = \mu + CBz_t^{(x)} + (1 - \phi_1 B - \phi_7 B^7)\varepsilon_t + a_t \quad (4.9)$$

och med insatta värden:

$$z_t = 0,575 + 0,237Bz_t^{(x)} + (1 + 0,157B + 0,170B^7)\varepsilon_t + a_t \quad (4.10)$$

Modellen visar att antalet strokeanfall en given dag är lika med 0.575 plus 24 % av roten ur PM₁₀-PM_{2.5} plus slumpfaktorn.

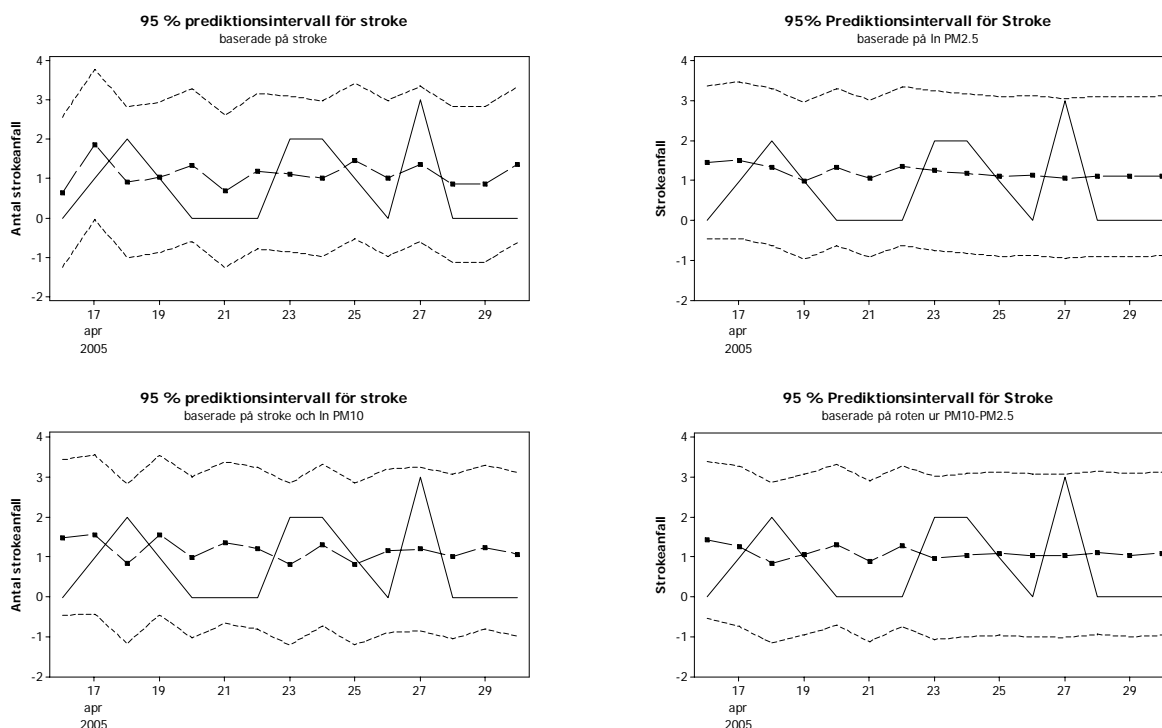
4.3 Prognos

Av tabell 4.1 och figur 4.1 följer att både den univariata modellen och transferfunktionsmodellerna underskattar antalet strokeanfall per dygn. Roten ur PM_{10} - $PM_{2.5}$ har lägst PME medan den univariata modellen har lägst PMSE. Men det är inga stora skillnader mellan värdena vilket gör det svårt att avgöra vilken modell som bäst prognostiserar antalet strokeanfall. Med hänsyn till figuren verkar prognoserna baserade på stroke vara bäst. För samtliga prognoser ligger de skattade värdena inom prediktionsintervallen och de fluktuerar kring medelvärdet ett strokeanfall.

Variabel som prognoserna baseras på	PME	PMSE
Stroke	-0,312	1,000
Ln PM2.5	-0,410	1,173
Ln PM10	-0,381	1,254
Roten ur PM_{10} - $PM_{2.5}$	-0,304	1,202

Tabell 4.1 PME och PMSE av prognoserna, av Stroke kall säsong

De streckade linjerna med punkter på i figuren är punktskattningarna, den heldragna är de sparade observationerna och de prickade linjerna är prediktionsintervallen.



Figur 4.1 Prognoser för stroke med 95 % prediktionsintervall

5. SLUTSATS

Syftet med denna uppsats var att ta fram modeller som beskriver hur stroke påverkas av partikelhalten i luften. Det sammanfattande resultatet är att det endast finns positiva signifikanta samband på kall säsong. Resultatet är delvis väntat men innan studien påbörjades förväntades signifikanta samband även på varm säsong med tanke på tidigare studiers resultat.

I denna studie gjordes prognoser baserade på de skattade modellerna för att se hur bra de är, vilket tidigare studier inte har gjort. Alla prognoser ligger inom prediktionsintervallen men dessvärre lyckas modellerna inte prognostisera värden som avviker mycket från medelvärdet. Det kan förklaras av att den beroende variabeln stroke inte är särskilt kvantitativ. Den antar oftast värdet noll, ett eller två och i genomsnitt är det drygt en person per dygn som får ett strokeanfall. Stroke tycks följa en poissonfördelning och det hade möjligtvis blivit bättre prognoser om metoder anpassade för poissonfördelning använts. I bland annat *Regression Models for Time Series Analysis* av Kedem och Fokianos från 2002 beskrivs poissonmodellen.

De valda metoderna hade emellertid givit mycket bättre prognoser om vi hade haft tillgång till data över en större population med ett medelvärde på minst fem strokeanfall per dygn. Anledningen till att metoderna som använts ändå valts framför andra är att det är de metoderna som vi behärskar. Den beroende variabeln hade också blivit mer kvantitativ om allt data hade gjorts om till vecko- eller månadsdata. Men det hade i så fall uppstått problem med att hitta de kortsiktiga sambanden.

Extremvärden för varje variabel har ersatts enligt definitionen för uteliggare medan de bivariata uteliggarna som upptäckts i spridningsdiagrammen inte har ersatts. Det beror på att det skulle vara ett omfattande arbete som inte ryms inom tidsramen för denna uppsats. Således kan de kvarvarande uteliggarna ha förvrängt resultatet och givit ett negativt samband. Att en ökning av partikelhalten i luften medför en minskning av strokeanfall är inte det förväntade resultatet.

I denna uppsats har den ökade risken för stroke som alla äldre i Malmö utsätts för vid en ökning av partikelhalten i luften analyserats. Det skulle vara intressant att i vidare studier ta med även socioekonomiska faktorer, livsstilsfaktorer och andra riskfaktorer för att se hur risken för stroke vid en ökning av partikelhalten skiljer sig mellan människor.

REFERENSER

Tryckta källor

- Bowerman, B., O'Connell, R. & Koehler, A. (2005). *Forecasting, Time Series, and Regression*. 4 uppl. Belmont: Thomson. Brooks/Cole.
- Enders, W. (2004). *Applied Econometric Time Series*. 2 uppl. Hoboken: Wiley.
- Fahlén, J., Meister, K. & Segerstedt, B. (2005). *Partiklar och akuta luftvägseffekter – fördjupade analyser av data från BHM*. Umeå: Energimyndigheten.
- Forsberg, B. & Segerstedt, B. (2003). *Luftföroreningshalter och sjukhusinläggningar för luftvägssjukdomar i Stockholm, Göteborg, Malmö och Helsingborg 1997-1999*. Umeå: Naturvårdsverket.
- Kedem, B. & Fokianos, K. (2002). *Regression Models for Time Series Analysis*. Hoboken: Wiley.
- Kettunen, J., Lanki, T., Tiittanen, P., Aalto, P., Koskentalo, T., Kulmala, M., Salomaa, V. & Pekkanen, J. (2006). "Associations of fine and ultrafine particulate air pollution with stroke mortality in an area of low air pollution levels". *Stroke, AHA Journals, Vol 38, s. 918-922*.
- Körner, S. & Wahlgren, L. (2002). *Praktisk statistik*. 3 uppl. Lund: Studentlitteratur.
- Low, R., Bielory, L., Qureshi, A., Dunn, V., Stuhlmiller, D. & Dickey, D. (2006). "The relation of stroke admissions to recent weather, airborne allergens, air pollution, seasons, upper respiratory infections, and asthma incidence, september 11, 2001, and day of the week". *Stroke, AHA Journals, Vol 37, s. 951-957*.
- Segerstedt, B. & Forsberg, B. (2002). *Partiklar i omgivningsluften och akuta fall av lungsjukdom i Lycksele*. Umeå: Energimyndigheten.
- Villeneuve, PJ., Chen, L., Stieb, D. & Rowe, BH. (2006). "Associations between outdoor air pollution and emergency department visits for stroke in Edmonton, Canada". *European Journal of Epidemiology, Vol 21, s. 689-700*.
- Wei, W. S. (1990). *Time Series Analysis. Univariate and Multivariate Methods*. Addison Wesley Publishing Company.

Otryckta källor

OEM Online, Occupational and Environmental Medicine (2007)

Henrotin, JB., Besancenot, JP., Benatru, I. & Giroud, M.. *Short-term effects of ozone air pollution on ischemic stroke occurrence: a case-crossover analysis from a 10-year population-based study in Dijon, France.*

<http://oem.bmj.com/cgi/rapidpdf/oem.2006.029306v1>, hämtad 2008-02-10

SAD (2000). *Trafikens spår. Information om trafikens inverkan på luftkvaliteten och bullret i boendemiljön,*

www.ytv.fi/NR/rdonlyres/20DE9576-DECC-4900-BEEC-C8DAFACA5B1A/0/traf.pdf, hämtad 2007-12-21

Sjukvårdsrådgivningen (2006). *Stroke-slaganfall/Vad händer i kroppen?*,

www.sjukvardsradgivning.se/artikel.asp?CategoryID=19927, hämtad 2007-12-21

SMHI (2003). *Temperaturökning vid markinversion,*

www.smhi.se/sgmain/vinter/inversion.htm, hämtad 2007-12-21

Vägverket (2006). *Luftkvalitet i tätorter,*

http://www.vv.se/templates/page3____15702.aspx, hämtad 2007-12-21

BILAGA A

Variabel	Medelvärde	Medelfel	Standard- avvikelse	t-värde	P-värde för normalitetstest
KALL SÄSONG					
*Ln $PM_{2.5}$	2,301	0,025	0,368	92,040	<0,005
1-diff ln $PM_{2.5}$	0,005	0,024	0,351	-0,208	<0,005
2-diff ln $PM_{2.5}$	-0,003	0,038	0,543	0,079	<0,005
*Ln PM_{10}	2,733	0,026	0,377	105,506	0,433
1-diff ln PM_{10}	0,004	0,025	0,357	0,174	0,021
2-diff ln PM_{10}	-0,002	0,039	0,557	-0,044	0,008
*Roten ur $PM_{10}-PM_{2.5}$	2,252	0,046	0,666	49,054	0,075
1-diff roten ur $PM_{10}-PM_{2.5}$	-0,004	0,044	0,641	-0,088	0,916
2-diff roten ur $PM_{10}-PM_{2.5}$	-0,003	0,071	1,024	-0,047	0,357
Temperatur	4,64	0,292	4,242	15,89	0,766
*1-diff temperatur	0,01	0,14	2,031	0,071	0,241
2-diff temperatur	0,008	0,2	2,89	0,04	0,056
*Ln Vindhastighet	1,265	0,027	0,383	47,743	0,078
1-diff ln vindhastighet	0,002	0,03	0,438	0,07	0,237
2-diff ln vindhastighet	-0,004	0,05	0,721	-0,082	0,049
Luftfuktighet i kvadrat	6319	119	1725	53,101	0,012
*1-diff luftfuktighet i kvadrat	-9	88,5	1282,2	-0,102	0,543
2-diff luftfuktighet i kvadrat	-10	136	1959	-0,074	0,117
VARM SÄSONG					
*Ln $PM_{2.5}$	2,237	0,025	0,312	88,399	0,041
1-diff ln $PM_{2.5}$	-0,005	0,023	0,279	-0,233	0,007
2-diff ln $PM_{2.5}$	0	0,036	0,436	-0,008	0,081
*Ln PM_{10}	2,788	0,026	0,321	107,246	0,332
1-diff ln PM_{10}	-0,002	0,024	0,296	-0,1	0,007
2-diff ln PM_{10}	0	0,037	0,448	-0,003	0,171
*Ln $PM_{10}-PM_{2.5}$	1,855	0,039	0,479	47,93	0,06
1-Diff ln $PM_{10}-PM_{2.5}$	0,004	0,044	0,54	0,084	< 0,005
2-diff ln $PM_{10}-PM_{2.5}$	0	0,07	0,863	0,003	< 0,005
Roten ur Temperatur	3,949	0,035	0,434	112,504	< 0,005
*1-diff roten ur temperatur	0	0,017	0,206	0,006	0,867
2-diff roten ur temperatur	-0,002	0,022	0,267	-0,069	0,244
Ln Vindhastighet	1,138	0,027	0,328	42,925	0,009
*1-diff ln vindhastighet	0,003	0,032	0,389	0,095	0,693
2-diff ln vindhastighet	-0,007	0,05	0,615	-0,136	0,829
*Luftfuktighet i kvadrat	5504	136	1685	40,471	0,406
1-diff luftfuktighet i kvadrat	-14	109	1338	-0,128	0,2
2-diff luftfuktighet i kvadrat	18	161	1982	0,112	0,616

Tabell A.1 Beskrivande statistik på transformerade tidsserier, kall och varm säsong

BILAGA B

Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error	
0	0.134850	1.00000																						0	
1	0.072277	0.53598										.													0.068843
2	0.034451	0.25547									.	.													0.086385
3	0.011594	0.08597									.	.	.												0.089894
4	-0.013922	-.10324									.	**	.												0.090283
5	-0.016353	-.12127									.	**	.												0.090841
6	-0.0068477	-.05078									.	*	.												0.091605
7	-0.0061718	-.04577									.	*	.												0.091738
8	0.0047710	0.03538									.	.	*	.											0.091846
9	0.013109	0.09721									.	.	**	.											0.091911
10	0.021345	0.15829									.	.	***	.											0.092397
11	0.0085157	0.06315									.	.	*	.											0.093673
12	0.0050934	0.03777									.	.	*	.											0.093875
13	0.0040511	0.03004									.	.	*	.											0.093947
14	0.0016240	0.01204																			0.093992
15	0.0035976	0.02668									.	.	*	.											0.093999
16	0.0048732	0.03614									.	.	*	.											0.094035
17	-0.0053712	-.03983									.	.	*	.											0.094101
18	-0.0038933	-.02887									.	.	*	.											0.094181
19	0.0019062	0.01414																			0.094223
20	-0.0005441	-.00403																			0.094233
21	-0.0056015	-.04154									.	.	*	.											0.094234
22	-0.012853	-.09531									.	.	**	.											0.094320
23	-0.015286	-.11336									.	.	**	.											0.094776
24	-0.0047435	-.03518									.	.	*	.											0.095416

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1		
1	0.53598										.													
2	-0.04462										.	*	.											
3	-0.04660										.	*	.											
4	-0.17116										.	***	.											
5	0.02412										.	.	.											
6	0.06387										.	.	*	.										
7	-0.04362										.	.	*	.										
8	0.07024										.	.	*	.										
9	0.04781										.	.	*	.										
10	0.11243										.	.	**	.										
11	-0.13178										.	.	***	.										
12	0.04524										.	.	*	.										
13	0.03740										.	.	*	.										
14	0.03199										.	.	*	.										
15	0.01176																			
16	-0.00415																			
17	-0.07125										.	.	*	.										
18	0.01447																			
19	0.05375										.	.	*	.										
20	-0.04409										.	.	*	.										
21	-0.05542										.	.	*	.										
22	-0.10109										.	.	**	.										
23	-0.00274																			
24	0.07362										.	.	*	.										

Figur B.1 ACF och PACF för ln PM_{2.5} kall säsong

Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error
0	0.141346	1.00000												*****	*****	*****	*****	*****	*****	*****	*****	*****	*****	0
1	0.077153	0.54584										.		*****	*****	*****	*****	*****	*****	*****	*****	*****	*****	0.068843
2	0.040630	0.28745										.		*****	*****	*****	*****	*****	*****	*****	*****	*****	*****	0.086968
3	0.015587	0.11028										.		**	0.091360
4	-0.0098225	-0.06949										.	*	0.091989
5	-0.012250	-0.08667										.	**	0.092237
6	0.00070333	0.00498										0.092622
7	0.0025938	0.01835										0.092624
8	0.0090442	0.06399										.	*	0.092641
9	0.011565	0.08182										.	**	0.092850
10	0.011107	0.07858										.	**	0.093191
11	0.0026883	0.01902										0.093505
12	0.0028491	0.02016										0.093523
13	0.0030914	0.02187										0.093544
14	-0.0011079	-0.00784										0.093568
15	-0.0069713	-0.04932										.	*	0.093571
16	-0.011625	-0.08225										.	**	0.093694
17	-0.015020	-0.10626										.	**	0.094036
18	-0.021780	-0.15409										.	***	0.094603
19	-0.010654	-0.07538										.	**	0.095785
20	-0.0017260	-0.01221										0.096066
21	-0.0009166	-0.00649										0.096073
22	-0.0070125	-0.04961										.	*	0.096075
23	-0.0075340	-0.05330										.	*	0.096197
24	-0.0017280	-0.01223										0.096336

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
1	0.54584												*****	*****	*****	*****	*****	*****	*****	*****	*****	*****	*****
2	-0.01495										
3	-0.05814											.	*
4	-0.14827											.	***
5	0.03370											.	*
6	0.11833											.	**
7	-0.02456										
8	0.03317											.	*
9	0.01414										
10	0.04212											.	*
11	-0.05792											.	*
12	0.03651											.	*
13	0.02742											.	*
14	-0.03168											.	*
15	-0.07026											.	*
16	-0.05247											.	*
17	-0.01982										
18	-0.10435											.	**
19	0.07297											.	*
20	0.02267										
21	-0.03281											.	*
22	-0.11629											.	**
23	0.01347										
24	0.11265											.	**

Figur B.2 ACF och PACF för ln PM₁₀, kall säsong

Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error
0	0.441861	1.00000												*****	*****	*****	*****	*****	*****	*****	*****	*****	*****	0
1	0.234322	0.53031										.		*****										0.068843
2	0.142734	0.32303										.		*****										0.086052
3	0.074759	0.16919										.		***										0.091619
4	0.015516	0.03511										.		*										0.093088
5	0.0075433	0.01707										.		.										0.093151
6	0.016290	0.03687										.		*										0.093166
7	0.0023624	0.00535										.		.										0.093235
8	0.029918	0.06771										.		*										0.093236
9	0.0046376	0.01050										.		.										0.093469
10	-0.030893	-0.06992										.	*	.										0.093475
11	-0.0025418	-0.00575										.	.	.										0.093722
12	0.00018558	0.00042										.	.	.										0.093724
13	-0.010441	-0.02363										.	.	.										0.093724
14	-0.0085484	-0.01935										.	.	.										0.093752
15	-0.046359	-0.10492										.	**	.										0.093771
16	-0.076059	-0.17213										.	***	.										0.094326
17	-0.033870	-0.07665										.	**	.										0.095803
18	-0.073541	-0.16643										.	***	.										0.096093
19	-0.037123	-0.08401										.	**	.										0.097450
20	0.016208	0.03668										.	*	.										0.097792
21	-0.0068762	-0.01556										.	.	.										0.097858
22	-0.0014468	-0.00327										.	.	.										0.097869
23	-0.0065587	-0.01484										.	.	.										0.097870
24	-0.030991	-0.07014										.	*	.										0.097880

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
1	0.53031													*****									
2	0.05816											.	*	.									
3	-0.03210											.	*	.									
4	-0.07917											.	**	.									
5	0.03592											.	*	.									
6	0.05212											.	*	.									
7	-0.04003											.	*	.									
8	0.08644											.	**	.									
9	-0.07530											.	**	.									
10	-0.09517											.	**	.									
11	0.09781											.	**	.									
12	0.01477											.	.	.									
13	-0.05090											.	*	.									
14	-0.02578											.	*	.									
15	-0.10289											.	**	.									
16	-0.10148											.	**	.									
17	0.11474											.	**	.									
18	-0.14555											.	***	.									
19	0.05207											.	*	.									
20	0.10936											.	**	.									
21	-0.08678											.	**	.									
22	-0.00281											.	.	.									
23	-0.00785											.	.	.									
24	-0.02877											.	*	.									

Figur B.3 ACF och PACF för roten ur PM₁₀-PM_{2.5}, kall säsong

Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error
0	1.070465	1.00000												*****										0
1	-0.174516	-.16303										***		.										0.071429
2	0.0052744	0.00493										.		.										0.073302
3	-0.070688	-.06604										.	*	.										0.073304
4	-0.126243	-.11793										.	**	.										0.073607
5	-0.0083284	-.00778										.	.	.										0.074565
6	0.200121	0.18695										.		****										0.074569
7	-0.161556	-.15092										.	***	.										0.076923
8	0.102366	0.09563										.	**	.										0.078419
9	-0.078787	-.07360										.	*	.										0.079012
10	0.120109	0.11220										.	**	.										0.079361
11	-0.0081757	-.00764										.	.	.										0.080166
12	-0.024216	-.02262										.	.	.										0.080170
13	-0.095727	-.08943										.	**	.										0.080203
14	0.073208	0.06839										.	*	.										0.080710
15	-0.0027549	-.00257										.	.	.										0.081005
16	0.201244	0.18800										.		****										0.081005
17	-0.220356	-.20585										.	****	.										0.083201
18	0.059522	0.05560										.	*	.										0.085761
19	0.054337	0.05076										.	*	.										0.085944
20	0.070211	0.06559										.	*	.										0.086097
21	-0.020407	-.01906										.	.	.										0.086352
22	0.0094712	0.00885										.	.	.										0.086373
23	-0.096453	-.09010										.	**	.										0.086378
24	0.122852	0.11476										.	**	.										0.086856

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
1	-0.16303											***	.										
2	-0.02224											.	.										
3	-0.07075											.	*	.									
4	-0.14504											.	***	.									
5	-0.05759											.	*	.									
6	0.17489											.		***									
7	-0.11860											.	**	.									
8	0.03844											.	*	.									
9	-0.03532											.	*	.									
10	0.13644											.		***									
11	0.00695											.	.	.									
12	-0.04749											.	*	.									
13	-0.05500											.	*	.									
14	0.04758											.	*	.									
15	0.04555											.	*	.									
16	0.13403											.		***									
17	-0.16175											.	***	.									
18	0.02943											.	*	.									
19	0.13235											.		***									
20	0.08782											.		**									
21	-0.05080											.	*	.									
22	-0.04066											.	*	.									
23	0.06611											.	*	.									
24	0.08126											.	**	.									

Figur B.4 ACF och PACF för Stroke, kall säsong

Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error	
0	0.096969	1.00000												*****										0	
1	0.057133	0.58919										.		*****											0.080845
2	0.033597	0.34647										.		*****											0.105232
3	0.017280	0.17820										.		****											0.112441
4	0.0077257	0.07967										.		**	.										0.114272
5	-0.0026166	-.02698									.	*		.											0.114634
6	-0.0025064	-.02585									.	*		.											0.114676
7	-0.013852	-.14285									.	***		.											0.114714
8	-0.018480	-.19058									.	****		.											0.115871
9	-0.023837	-.24582									.	*****		.											0.117902
10	-0.023628	-.24366									.	*****		.											0.121205
11	-0.023603	-.24341									.	*****		.											0.124366
12	-0.020158	-.20788									.	****		.											0.127441
13	-0.016673	-.17194									.	***		.											0.129638
14	-0.011317	-.11671									.	**		.											0.131120
15	-0.0089344	-.09214									.	**		.											0.131798
16	-0.0019190	-.01979									.	.		.											0.132218
17	0.0040044	0.04130									.	.	*	.											0.132237
18	0.0095792	0.09879									.	.	**	.											0.132322
19	0.013883	0.14317									.	.	***	.											0.132803
20	0.012827	0.13228									.	.	***	.											0.133808
21	0.0076665	0.07906									.	.	**	.											0.134660
22	0.0036681	0.03783									.	.	*	.											0.134963
23	0.0021885	0.02257																			0.135032
24	0.0043896	0.04527									.	.	*	.											0.135057

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
1	0.58919												*****										
2	-0.00103										.		.										
3	-0.03912									.	*		.										
4	-0.01536									.	.		.										
5	-0.08968									.	**		.										
6	0.05151									.	.	*	.										
7	-0.18647									.	****		.										
8	-0.05337									.	*		.										
9	-0.10750									.	**		.										
10	-0.05083									.	*		.										
11	-0.05757									.	*		.										
12	-0.05599									.	*		.										
13	-0.01462									.	.		.										
14	-0.02337									.	.		.										
15	-0.04156									.	*		.										
16	0.02819									.	.	*	.										
17	0.01863																		
18	0.02700									.	.	*	.										
19	0.03528									.	.	*	.										
20	-0.04483									.	*		.										
21	-0.05335									.	*		.										
22	-0.04857									.	*		.										
23	-0.00303									.	.		.										
24	0.04471									.	.	*	.										

Figur B.5 ACF och PACF för ln PM_{2.5}, varm säsong

Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error	
0	0.102509	1.00000												*****										0	
1	0.059003	0.57559										.		*****											0.080845
2	0.027534	0.26860									.			*****											0.104244
3	0.010887	0.10620									.			**	.										0.108673
4	0.0014887	0.01452									.			.											0.109349
5	0.0012448	0.01214									.			.											0.109362
6	0.0097076	0.09470									.			**	.										0.109371
7	0.0029158	0.02844									.			*	.										0.109905
8	-0.0089484	-.08729									.		**	.											0.109953
9	-0.021796	-.21262									.		****	.											0.110405
10	-0.022957	-.22395									.		****	.											0.113050
11	-0.014206	-.13859									.		***	.											0.115913
12	-0.0096537	-.09417									.		**	.											0.116991
13	-0.0054586	-.05325									.		*	.											0.117486
14	-0.0051747	-.05048									.		*	.											0.117643
15	-0.0096675	-.09431									.		**	.											0.117785
16	-0.0074129	-.07231									.		*	.											0.118277
17	-0.0009342	-.00911									.		.	.											0.118566
18	0.0067906	0.06624									.		*	.											0.118571
19	0.0097981	0.09558									.		**	.											0.118812
20	0.0074729	0.07290									.		*	.											0.119314
21	0.0023716	0.02314									.		.	.											0.119605
22	-0.0013840	-.01350									.		.	.											0.119634
23	-0.0006030	-.00588									.		.	.											0.119644
24	-0.0021423	-.02090									.		.	.											0.119646

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
1	0.57559												*****										
2	-0.09376										.	**	.										
3	-0.01347										.	.	.										
4	-0.03251										.	*	.										
5	0.04414										.	.	*	.									
6	0.11799										.	.	**	.									
7	-0.12947										.	**	.										
8	-0.11132										.	**	.										
9	-0.15060										.	**	.										
10	0.00057										.	.	.										
11	0.05136										.	.	*	.									
12	-0.07190										.	.	*	.									
13	0.00643																		
14	-0.02762										.	.	*	.									
15	-0.03178										.	.	*	.									
16	0.03597										.	.	*	.									
17	0.00702																		
18	0.05237										.	.	*	.									
19	-0.01138																		
20	-0.01347																		
21	-0.02052																		
22	-0.02781										.	.	*	.									
23	0.02096																		
24	-0.08448										.	.	**	.									

Figur B.6 ACF och PACF för ln PM₁₀, varm säsong

Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error	
0	0.227669	1.00000												*****										0	
1	0.083332	0.36602										.		*****											0.080845
2	0.017139	0.07528									.		**	.											0.091034
3	-0.027043	-.11878									.	**	.	.											0.091440
4	-0.033310	-.14631									.	***	.	.											0.092443
5	0.0085186	0.03742									.	*	.	.											0.093945
6	0.036006	0.15815									.	.	***	.											0.094042
7	0.048061	0.21110									.	.	****	.											0.095764
8	0.012111	0.05319									.	.	*	.											0.098759
9	-0.023946	-.10518									.	**	.	.											0.098946
10	-0.042592	-.18708									.	****	.	.											0.099674
11	-0.0058138	-.02554									.	*	.	.											0.101943
12	0.014127	0.06205									.	.	*	.											0.101985
13	0.021531	0.09457									.	.	**	.											0.102232
14	0.0060850	0.02673									.	.	*	.											0.102802
15	-0.016348	-.07181									.	.	*	.											0.102847
16	-0.027476	-.12068									.	**	.	.											0.103174
17	-0.033102	-.14539									.	***	.	.											0.104093
18	-0.016083	-.07064									.	*	.	.											0.105412
19	0.00004475	0.00020																			0.105721
20	0.026313	0.11558									.	.	**	.											0.105721
21	0.031752	0.13947									.	.	***	.											0.106544
22	0.0044993	0.01976																			0.107730
23	-0.018903	-.08303									.	**	.	.											0.107754
24	-0.030372	-.13340									.	***	.	.											0.108171

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
1	0.36602												*****										
2	-0.06777										.	*	.										
3	-0.14315										.	***	.										
4	-0.05655										.	*	.										
5	0.14300										.	.	***	.									
6	0.10468										.	.	**	.									
7	0.09528										.	.	**	.									
8	-0.07690										.	**	.	.									
9	-0.08453										.	**	.	.									
10	-0.07809										.	**	.	.									
11	0.11874										.	.	**	.									
12	-0.00229																		
13	-0.01949																		
14	-0.05287										.	*	.	.									
15	-0.01636																		
16	-0.02411																		
17	-0.07144										.	*	.	.									
18	-0.05089										.	*	.	.									
19	-0.01445																		
20	0.11606										.	.	**	.									
21	0.11251										.	.	**	.									
22	-0.05180										.	*	.	.									
23	-0.07180										.	*	.	.									
24	-0.04739										.	*	.	.									

Figur B.7 ACF och PACF för ln PM₁₀-PM_{2.5}, varm säsong

Autocorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error
0	1.336116	1.00000												*****										0
1	0.082356	0.06164										.	*	.										0.085126
2	-0.041233	-.03086										.	*	.										0.085448
3	-0.166554	-.12466										.	**	.										0.085529
4	-0.0000244	-.00002										.	.	.										0.086836
5	-0.0084058	-.00629										.	.	.										0.086836
6	0.160119	0.11984										.	**	.										0.086839
7	0.102011	0.07635										.	**	.										0.088029
8	0.020168	0.01509										.	.	.										0.088508
9	-0.0017089	-.00128										.	.	.										0.088526
10	-0.024583	-.01840										.	.	.										0.088527
11	-0.0039790	-.00298										.	.	.										0.088554
12	-0.040348	-.03020										.	*	.										0.088555
13	0.026727	0.02000										.	.	.										0.088630
14	0.055575	0.04159										.	*	.										0.088662
15	0.115404	0.08637										.	**	.										0.088804
16	-0.075134	-.05623										.	*	.										0.089410
17	-0.132245	-.09898										.	**	.										0.089666
18	-0.118887	-.08898										.	**	.										0.090454
19	-0.022826	-.01708										.	.	.										0.091087
20	-0.078939	-.05908										.	*	.										0.091110
21	-0.041847	-.03132										.	*	.										0.091387
22	-0.166170	-.12437										.	**	.										0.091465
23	0.0056098	0.00420										.	.	.										0.092682
24	0.011721	0.00877										.	.	.										0.092683

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
1	0.06164										.	*	.										
2	-0.03479										.	*	.										
3	-0.12115										.	**	.										
4	0.01432										.	.	.										
5	-0.01455										.	.	.										
6	0.10851										.	**	.										
7	0.06560										.	*	.										
8	0.01073										.	.	.										
9	0.02895										.	*	.										
10	-0.00592										.	.	.										
11	0.00313										.	.	.										
12	-0.04043										.	*	.										
13	0.00553										.	.	.										
14	0.03233										.	*	.										
15	0.07273										.	*	.										
16	-0.06060										.	*	.										
17	-0.08414										.	**	.										
18	-0.06112										.	*	.										
19	-0.02823										.	*	.										
20	-0.09065										.	**	.										
21	-0.06676										.	*	.										
22	-0.13867										.	**	.										
23	0.01999										.	.	.										
24	0.01809										.	.	.										

Figur B.8 ACF och PACF för Stroke, varm säsong

BILAGA C

Variabel	Parameter	Skattning	Medelfel	t-värde	p-värde	Lag
KALL SÄSONG						
Ln PM2.5	KONSTANT	2,297	0,035	65,12	<0,0001	0
	AR1,1	0,555	0,058	9,57	<0,0001	1
	AR1,2	-0,153	0,060	-2,57	0,0109	4
Ln PM10	KONSTANT	2,729	0,038	72,010	<0,0001	0
	AR1,1	0,563	0,058	9,740	<0,0001	1
	AR1,2	-0,131	0,059	-2,220	0,028	4
Roten ur PM10-PM2.5	KONSTANT	2,250	0,063	35,440	<0,0001	0
	AR1,1	0,528	0,058	9,030	<0,0001	1
	AR1,2	-0,142	0,061	-2,330	0,021	18
1-diff temperatur	MA1,1	0,173	0,068	2,530	0,012	2
	MA1,2	0,159	0,069	2,320	0,021	4
	MA1,3	-0,207	0,068	-3,060	0,003	10
Ln vindhastighet	KONSTANT	1,262	0,038	33,450	<0,0001	0
	AR1,1	0,343	0,065	5,280	<0,0001	1
1-diff luftfuktighet i kvadrat	MA1,1	0,348	0,063	5,520	<0,0001	1
	MA1,2	0,277	0,072	3,860	0,000	2
	MA1,3	0,283	0,068	4,140	<0,0001	4
	MA1,4	-0,147	0,065	-2,270	0,024	6
Stroke	KONSTANT	1,125	0,067	16,740	<0,0001	0
	MA1,1	-0,208	0,069	-3,020	0,003	6
	MA1,2	-0,162	0,070	-2,300	0,022	16
	MA1,3	0,230	0,070	3,280	0,001	17
(Feltermen)	MA2,1	0,158	0,072	2,190	0,030	4
VARM SÄSONG						
Ln PM2.5	KONSTANT	2,239	0,036	61,570	<0,0001	0
	AR1,1	0,589	0,065	9,050	<0,0001	1
	AR1,2	-0,146	0,068	-2,140	0,034	7
Ln PM10	KONSTANT	2,788	0,034	82,150	<0,0001	0
	AR1,1	0,560	0,066	8,540	<0,0001	1
	AR1,2	-0,181	0,069	-2,620	0,010	9
Ln PM10-PM2.5	KONSTANT	1,855	0,053	35,150	<0,0001	0
	MA1,1	-0,321	0,076	-4,200	<0,0001	1
	MA1,2	-0,159	0,077	-2,070	0,040	7
1-diff roten ur temperatur	MA1,1	0,362	0,076	4,760	<0,0001	2
	MA1,2	0,192	0,076	2,530	0,013	3
1-diff ln vindhastighet	MA1,1	0,530	0,078	6,770	<0,0001	1
	MA1,2	0,283	0,078	3,610	0,000	2
Luftfuktighet i kvadrat	KONSTANT	7081,100	814,234	8,700	<0,0001	0
	AR1,1	0,612	0,058	10,510	<0,0001	1
	AR1,2	0,181	0,058	3,120	0,002	6
	AR1,3	0,189	0,059	3,180	0,002	14

Tabell C.1 Valda univariata ARIMA-modeller, kall och varm säsong

BILAGA D

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
0	-0.074980	-.19312											****	.									
1	0.083773	0.21576										.	****										
2	-0.029618	-.07628									.	**	.										
3	0.037206	0.09583									.	.	**	.									
4	-0.025695	-.06618									.	*	.										
5	-0.0073552	-.01894									.	.	.										
6	-0.030765	-.07924									.	**	.										
7	0.076074	0.19594									.	.	****										
8	-0.040443	-.10417									.	**	.										
9	0.0086170	0.02219									.	.	.										
10	0.011950	0.03078									.	.	*	.									

Figur D.1 Korskorrelation mellan ln PM_{2.5} och Stroke, kall säsong

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
0	-0.068256	-.17096											***	.									
1	0.084634	0.21199										.	****										
2	-0.024744	-.06198									.	*	.										
3	0.037802	0.09468									.	.	**	.									
4	-0.041605	-.10421									.	**	.										
5	-0.0074977	-.01878									.	.	.										
6	-0.020867	-.05227									.	*	.										
7	0.054709	0.13703									.	.	***										
8	-0.031939	-.08000									.	**	.										
9	0.0092102	0.02307									.	.	.										
10	0.0030547	0.00765									.	.	.										

Figur D.2 Korskorrelation mellan ln PM₁₀ och Stroke, kall säsong

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
0	-0.049360	-.07037											.	*	.								
1	0.088822	0.12663										.	.	***									
2	-0.032764	-.04671									.	*	.										
3	0.066826	0.09527									.	.	**	.									
4	-0.070145	-.10000									.	**	.										
5	-0.015290	-.02180									.	.	.										
6	0.0088931	0.01268									.	.	.										
7	0.0063890	0.00911									.	.	.										
8	-0.0075947	-.01083									.	.	.										
9	-0.0098516	-.01404									.	.	.										
10	-0.0096545	-.01376									.	.	.										

Figur D.3 Korskorrelation mellan roten ur PM₁₀-PM_{2.5} och Stroke, kall säsong

BILAGA E

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	-0.15987	0.07298	-2.19	0.0298	1	y	0
AR1,2	0.14939	0.07407	2.02	0.0452	6	y	0
SCALE1	-0.49771	0.21468	-2.32	0.0215	0	x1	0
NUM1,1	1.34054	0.32779	4.09	<.0001	1	x1	0
NUM1,2	0.64074	0.30044	2.13	0.0343	7	x1	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	3.88	4	0.4231	0.018	0.015	-0.006	-0.140	0.005	-0.009	
12	8.40	10	0.5898	-0.092	0.010	-0.025	0.089	0.051	-0.055	
18	20.63	16	0.1932	-0.048	0.026	0.046	0.154	-0.174	-0.000	
24	24.77	22	0.3081	0.081	0.044	-0.020	0.010	-0.032	0.097	
30	37.49	28	0.1084	0.141	-0.068	-0.044	-0.125	-0.104	0.069	

Crosscorrelation Check of Residuals with Input x1

To Lag	Chi-Square	DF	Pr > ChiSq	-----Crosscorrelations-----						
5	4.39	3	0.2224	-0.038	0.007	-0.065	0.068	-0.060	-0.098	
11	11.76	9	0.2275	-0.117	0.017	-0.043	-0.023	0.104	-0.112	
17	14.29	15	0.5034	-0.050	0.046	-0.054	-0.039	0.037	-0.056	
23	20.43	21	0.4940	0.143	0.013	-0.064	0.066	0.054	-0.031	
29	25.81	27	0.5292	0.043	0.005	-0.017	-0.069	0.101	0.109	

Figur E.1 Vald transferfunktionsmodell, Ljung-Box test och korskorrelationscheck för ln PM_{2.5} och Stroke, kall säsong

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	-0.16880	0.07078	-2.38	0.0181	1	y	0
AR1,2	-0.15528	0.07207	-2.15	0.0325	4	y	0
AR1,3	0.16227	0.07338	2.21	0.0282	10	y	0
SCALE1	0.41023	0.02247	18.25	<.0001	0	x1	1

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	3.47	3	0.3252	-0.023	-0.020	-0.048	-0.015	-0.019	0.116	
12	8.12	9	0.5217	-0.122	0.031	-0.045	0.010	0.069	0.006	
18	23.34	15	0.0771	-0.103	0.071	0.017	0.145	-0.184	0.034	
24	27.81	21	0.1458	0.078	0.069	-0.012	0.004	-0.044	0.087	
30	35.68	27	0.1225	0.078	-0.037	-0.022	-0.114	-0.078	0.086	

Crosscorrelation Check of Residuals with Input x1

To Lag	Chi-Square	DF	Pr > ChiSq	-----Crosscorrelations-----						
5	7.48	5	0.1870	0.010	-0.018	0.072	-0.092	-0.092	-0.129	
11	11.77	11	0.3816	0.058	-0.008	-0.001	0.052	-0.066	-0.109	
17	15.11	17	0.5875	0.026	-0.011	-0.049	0.066	-0.030	0.095	
23	20.74	23	0.5967	0.062	-0.050	0.023	0.135	-0.023	0.062	
29	22.90	29	0.7813	0.027	-0.041	-0.091	0.015	0.018	-0.001	

Figur E.2 Vald transferfunktionsmodell, Ljung-Box test och korskorrelationscheck för ln PM₁₀ och Stroke, kall säsong

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MU	0.57455	0.23271	2.47	0.0144	0	y	0
AR1,1	-0.15729	0.07205	-2.18	0.0303	1	y	0
AR1,2	-0.16982	0.07397	-2.30	0.0228	7	y	0
SCALE1	0.23719	0.10014	2.37	0.0189	0	x1	1

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.20	4	0.1255	-0.001	-0.050	-0.058	-0.134	-0.003	0.112
12	9.56	10	0.4795	0.004	0.017	-0.009	0.095	0.029	-0.034
18	21.22	16	0.1701	-0.068	0.006	0.041	0.134	-0.171	0.036
24	23.76	22	0.3598	0.062	0.059	-0.013	-0.019	-0.035	0.050
30	31.12	28	0.3116	0.135	-0.012	-0.018	-0.078	-0.064	0.062
36	41.41	34	0.1789	-0.085	0.015	-0.042	0.038	0.176	-0.042

Crosscorrelation Check of Residuals with Input x1

To Lag	Chi-Square	DF	Pr > ChiSq	-----Crosscorrelations-----					
5	4.28	6	0.6383	0.011	-0.001	0.095	-0.059	-0.085	-0.052
11	10.91	12	0.5363	-0.040	0.022	-0.025	-0.023	-0.003	-0.177
17	12.05	18	0.8445	-0.021	0.007	-0.055	0.047	0.015	0.001
23	15.83	24	0.8940	0.078	-0.034	-0.051	0.084	-0.013	0.052
29	22.36	30	0.8407	0.031	-0.019	-0.119	-0.070	-0.044	-0.109
35	28.49	36	0.8091	0.071	-0.140	-0.042	-0.036	0.067	-0.008

Figur E.3 Vald transferfunktionsmodell, Ljung-Box test och korskorrelationscheck för roten ur PM₁₀-PM_{2.5} och Stroke, kall säsong