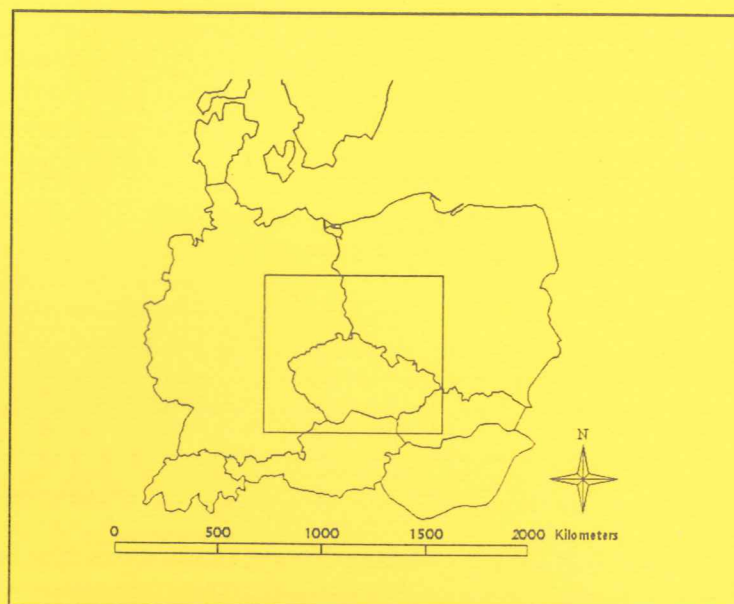


Lunds Universitets Naturgeografiska Institution

Seminarieuppsatser Nr. 50

**Kartering av markanvändning med meteorologisk satellitdata för
förbättring av en atmosfärisk spridningsmodell**



**TILLHÖR REFERENSBIBLIOTEKET
UTLÅNAS EJ**

Andreas Persson



Department of Physical Geography,
Lund University
Sölvegatan 13, S-221 00 Lund,
Sweden

1998



LUNDS UNIVERSITET
GEOBIBLIOTEKET

Innehållsförteckning

ABSTRACT.....	2
FÖRORD.....	3
1. INLEDNING.....	4
2. BAKGRUND.....	4
2.1 MODELLEN.....	4
2.2 SATELLITDATA.....	5
3. SYFTE.....	6
4. OMRÅDESBESKRIVNING.....	6
5. MATERIAL.....	7
5.1 SATELLITDATA.....	7
5.2 TRÄNINGSDATA OCH UTVÄRDERINGSDATA.....	8
5.3 KARTOR OCH ANNAN DATA.....	8
5.4 SPRIDNINGSMODELLEN.....	8
5.5 DATORUTRUSTNING.....	8
6. METODER.....	9
6.1 PRINCIPALKOMPONENT ANALYS FÖR ATT MINSKA DATAMÄNGDEN.....	9
6.2 TRÄNINGSYTOR OCH UTVÄRDERINGSYTOR MED KLUSTERANALYS.....	9
6.3 KLASSERNAS SEPARABILITET.....	10
6.4 MAXIMUM LIKELIHOOD KLASSNING.....	11
6.5 FILTRERING AV DATA.....	11
6.6 UTVÄRDERINGAR.....	11
6.7 IMPLEMENTERING I SPRIDNINGSMODELLEN.....	12
7. RESULTAT.....	12
7.1 PRINCIPALKOMPONENT ANALYS.....	12
7.2 SEPARABILITETSANALYS.....	14
7.3 MAXIMUM LIKELIHOOD KLASSNING OCH DESS UTVÄRDERING.....	14
7.4 RESULTAT FRÅN KÖRNINGAR MED SPRIDNINGSMODELLEN.....	21
8. DISKUSSION.....	23
8.1 PRINCIPALKOMPONENTANALYSEN.....	23
8.2 TRÄNING- OCH UTVÄRDERINGSDATA.....	24
8.3 SEPARABILITETSANALYS MED BHATTACHARYYA DISTANCE.....	25
8.4 MAXIMUM LIKELIHOOD KLASSNINGARNA.....	25
8.5 FILTRERINGAR.....	25
8.6 SPRIDNINGSMODELLEN.....	25
9. SLUTSATSER.....	26
10. SAMMANFATTNING.....	26
11. REFERENSER.....	28

LUNDS UNIVERSITET
GEOBIBLIOTEKET

Abstract

Landuse mapping with meteorological satellite data to enhance an atmospheric dispersal model.

Sulphur emissions during the last century has led to major acidification of the environment. The acidity of soil and water is a threat to health and economic interests of man, e.g. the food and paper/wood production in the agricultural and silvicultural industries. The Black Triangle region suffers from severe damage caused by acidification and actions to decrease the acid rain over fields and forests must continue.

A useful tool when making forecasts, discussing sensitive areas and sources of pollution is an atmospheric dispersal model. One model has been developed in department of Meteorology and Environmental Protection at Karl's University, Prague. The model did not use roughness parameters for different land use. Deposition of airborne pollutants occur at different rates over different land use. The aim was therefore set to create land use data and to enhance the model precision by use roughness parameters for each land use.

Since the model covers a large part of Europe, a land use data base was established by analyzing data from the NOAA AVHRR sensor. Eros data center, USA, supplied the 10-day channel and vegetation index composites.

To reduce the amount of data a standardized principal component analysis (sPCA) was performed. The standardization of the PCA makes the channels equal and minimizes signal to noise ratio. The PCA also presents variations in the data, e.g. seasons.

During the sPCA the number of occasions that could be used were reduced. Cloud contaminated 30 of the 36 occasions that were available. The 10-day composites are put together of the pixels that have the highest NDVI-value (Normalized Differentiated Vegetation Index). This does not guarantee that the pixels are free from clouds but they have the lowest amount of cloudiness during the 10-day period.

A maximum likelihood classification of the chosen data resulted in a land use data base with three major classes; agricultural land, coniferous forest and deciduous forest. Evaluations showed that the total certainty were up to 90% in some classifications. The classes Cities and Water were added from a digital map. Training areas for regions as large as this cannot be handled by field studies. Instead, data registered with Landsat TM as well as maps over the region were used to locate training areas.

The dispersal model was run with and without the land use data and the results were compared. Results showed a decrease in deposition specially in the mountainous areas.

One of the explanations is the high general roughness the model uses when run without land use data. The model will be calibrated with deposition data from gauges in the Czech republic.

Förord

Ett stort tack till min handledare Dr. Lars Eklundh.

Vidare vill jag tacka Jonas Ardö för att ha introducerat mig till ämnet och hjälpt mig med kontakter och data.

Tack också till min Tjeckiske handledare och kontakt vid Institutionen för Meteorologi och Miljöskydd vid Karls Universitet i Prag, Dr Josef Brechler och hans assistent Jan Holpuch som hjälpt oss med programmering vid körningarna av spridningsmodellen.

Examensarbetet har finansierats av Svenska Institutet utan vars bidrag resorna inte hade kunnat genomföras. Tack!

Lisa, tack för ditt stöd, du är mitt allt.

1. Inledning

Antropogena svavelutsläpp har funnits så länge människan har eldat men det har i större skala förekommit under ett sekel. Svavel bildar i luften olika föroreningar som svaveldioxid och svaveltrioxid som senare bildar svavelsyra som är kraftigt försurande för mark och vatten (Elvingson 1992). Eftersom försurningen är ett problem som uppmärksammas och visats vara ett stort hot mot människans närmiljö, skogsbruk, jordbruk och flera andra viktiga näringar behövs det forskning om de komponenter som styr försurning och andra atmosfäriska föroreningar.

Sådan forskning förekommer idag med spridningsmodeller. Dessa modeller beräknar med hjälp av ingångsdata hur mycket nedfall av t.ex. svavel en punkt tar emot under de förhållanden som modellen beskriver. Ingångsdata i modellerna är väderförhållanden i form av nederbörd och vindar samt utsläppsdata från fabriker och andra källor. Datorn beräknar sedan mängden svavel som faller ner med nederbörd och genom torrdeposition längs den väg som föroreningarna tar i lufthavet (Brechler, muntligen).

I takt med att datorkraften ökat har man kunnat förbättra modellerna vilket ger ett säkrare underlag till beslutsfattare både på nationell och internationell nivå. Problemen med luftföroreningar är på intet sätt bundna till nationsgränser. Intresset bör med anledning av detta vara stort även för länder med gränser mot de modellerade områdena samt för länder som stöder länder med förbättringar av miljöskydd och miljöhänsyn. Många av de hårdast drabbade områdena finns just i ekonomier som redan är hårt belastade. Ett sådant område är den så kallade "Svarta triangeln" som ligger i området där Tjeckiens, Tysklands och Polens gränser går ihop.

Under flera år har man vid institutionen för Meteorologi och Miljöskydd vid Karls Universitets Fysiska fakultet utvecklat en modell som behandlar såväl svavel- som kväveföroreningar (Bednár et al. opubl.). Man har under lång tid med datorernas utveckling och informationens åtkomlighet kunnat förbättra modellens underlag.

Ett sådant förbättrat underlag är markanvändningen. Man har visat att deposition av partiklar sker med olika hastighet över olika underlag (Sehmel 1980).

För att ytterligare förbättra modellen vill man alltså ha en metod för markanvändningskartering som är både enkel, snabb och billig. Priset och datatillgängligheten över stora områden väckte således intresset för att skapa markanvändningsdata med satellitburen fjärranalys.

2. Bakgrund

Länderna i och kring "svarta triangeln" har sedan flera år samarbetat med forskning och åtgärder för de hårt drabbade områdena i mellan Europa. Modellerandet av luftburna föroreningar är viktig forskning där prioriterade mål är att försöka svara på är vilken påverkan de olika föroreningarna har på miljön. Vidare vill man undersöka hur mycket av föroreningarna på en bestämd plats en specifik källa svarar för.

2.1 Modellen

Modellen som utvecklats vid Karls Universitet i Prag (KUP-modellen) är en Gaussisk modell. I de olika boxar som tidsintervallen bildar beräknas riktning och transport av föroreningarna med hjälp av data från vindrosor och nederbördsdata (Bednár et al. Opubl., Bednár et al. 1994). De luftföroreningar som förs ut ur systemet under varje tidsintervall är den deposition av föroreningar som sker.

En viktig del i depositionen av partiklar är vindhastigheten. Den avtar med lägre höjd över marken eftersom vegetation och landformationer påverkar vindens hastighet. Olika ytor har olika skrovlighet vilket innebär att tiden som ett luftpaket har för att deponera partiklar varierar med marktypen (Oke 1995). Med de olika marktyperna kartlagda kan parametrar som beskriver skrovligheten sättas in i modellen och på så vis öka modellens noggrannheten. KUP-modellen har använt sig av en generell skrovlighetsparameter och bara räknat ut markens generella inverkan på vinden (Bednář et al. 1994).

Depositionshastigheten av partiklarna SO_2 och SO_4^{2-} bestäms i modellen genom formler för hastigheterna vid våt respektive torrdeposition (Bednář et al. 1994).

Depositionen påverkas av hur mäktigt luftpaketet är, temperaturen och vilken omblandning som sker i luftpaketet. Dessa parametrar har man tagit hänsyn till i modellen tidigare men skrovlighetsparametern har varit konstant över alla ytor.

Depositionshastigheten är olika för olika partiklar samtidigt som den är olika över olika ytor (Sehmel 1980).

Genom att markanvändningsdata för området skapas kan man börja använda sig av olika depositionshastigheter för olika marktyper. Ekvationerna för depositionshastigheterna för de olika föreningar som modellen behandlar uppdateras med data som beskriver hur hastigheten förändras med markanvändningen. Det förväntade resultatet är att värdena ska minska något med markanvändningsdata eftersom den generella markanvändningen är satt så att den ger ett lite för högt resultat.

2.2 Satellitdata

För att skapa markanvändningsdatan över så stora områden som behövs till KUP-modellen är de satellitburna sensorerna ett praktiskt hjälpmedel. Sensorerna registrerar spektrala signaturer från marken. Eftersom de kan vara lika varandra för vissa marktyper uppstår problem. Man kan lösa dessa genom att använda data från flera tillfällen av året. Denna temporala data visar då på skillnader i fenologin hos olika marktyper (Reed et al. 1994). EROS Data Center i USA har byggt upp en databas med 10-dagarskompositer över hela kontinenterna. Tidsserien, som är gratis, sträcker sig från 1992 och ska byggas ut allteftersom. Datan är registrerad av NOAA-satelliterna som är uppsända av National Oceanic and Atmospheric Administration i USA. De använder sig av sensorn Advanced Very High Resolution Radiometer (AVHRR).

Åtta satelliter finns i omloppsbanan med en omloppsperiod på 102 minuter (Lillesand och Kiefer 1994). Upprepningscykeln är 4-9 dagar. Upplösningen på markytan är 1.1 km vid nadir. De spektrala banden som registreras är fyra eller fem beroende på vilken satellit det är. De fem våglängdsbanden är:

- NOAA AVHRR Kanal 1: 0.58-0.68 μm (synligt ljus mellan rött och grönt)
- NOAA AVHRR Kanal 2: 0.72-1.10 μm (NIR)
- NOAA AVHRR Kanal 3: 3.55-3.93 μm (Termal IR)
- NOAA AVHRR Kanal 4: 10.30-11.30 μm (10.5-11.50 μm , för NOAA -6, -8, -10 och -12) (Termal IR)
- NOAA AVHRR Kanal 5: 11.50-12.50 μm (Termal IR)

NOAA-satelliternas primära ändamål var att tjäna som meteorologiska satelliter men de våglängdsband som sensorn registrerar passar även mycket bra för olika studier av vegetation

med klorofyll. De termala banden har sin stora uppgift att fylla för temperaturmätningar på moln.

I ett projekt att skapa en databas med global 1-kilometers AVHRR-data har US Geological Survey, EROS Data Center och European Space Agency gått samman och distribuerar data bland annat via internet. Datan som har använts i detta arbete har gått igenom fem steg innan den har släppts ut (Eidenshink et al. 1994). Stegen är:

1. Radiometrisk kalibrering
2. Atmosfärisk korrigerig
3. Beräkning av NDVI (Normalized Difference Vegetation Index)
4. Geometrisk likriktning
5. Skapande av komposit

Den radiometriska korrektionen är genomförd med metoden som Teillet och Holben har beskrivit (Eidenshink et al. 1994). Dels har man för att kalibrera sensordrift i tiden använt sig av öknars yta för jämförande studier. För att kalibrera nära infraröda band och termala band har man använt sig av en svartkropp och rymden som referens. Den atmosfäriska korrektionen beskrivs av Teillet 1991 (Eidenshink et al. 1994). Man korrigerar framförallt för Rayleigh-spridning och ozon. NDVI beräknas enligt :

$$\text{channel 2} - \text{channel 1} / \text{channel 1} + \text{channel 2}.$$

Geometrisk likriktning av bilderna innebär att man projicerar om dem till en projektion som klarar av att beskriva hela kontinentytan. Goodes homolosin projektion är en sådan projektion (Steinwand 1994). Man skapar komposit för att minska ner på molnmängden i datan. Detta görs genom att man väljer ut de tillfällen under en 10-dagarsperiod som har det största NDVI-värdet. Varje pixel jämförs med de motsvarande 10 andra pixlarna och man tar sedan den mest molnfria (Eidenshink et al. 1994).

Data kan hämtas via internet (Webbplatsens adress finns i referenslistan).

NDVI-värdet har visats stämma väl överens med produktionen av biomassa varför de kanaler som ingår i NDVI valdes att utföra markanvändningskarteringen på.

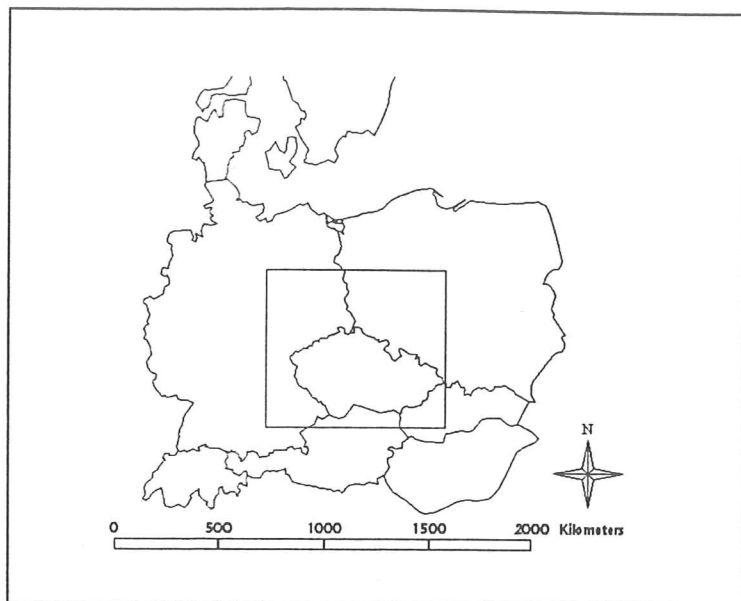
3. Syfte

Syftet med arbetet är att skapa markanvändningsdata för att förbättra en spridningsmodell för luftföroreningar. Detta med en metod som gör att uppdateringar kan ske med jämna mellanrum och med en låg kostnad. Från detta syfte kan man urskilja tre delar i arbetet:

1. Att välja ut de tillfällen i stor datamängd av multitemporala satellitdata som representerar de största variationerna
2. Att klassa data för dessa tillfällen och utvärdera resultaten
3. Att använda markanvändningsdata i spridningsmodellen och undersöka om det sker förändringar från tidigare resultat.

4. Områdesbeskrivning

Området utgörs av stora delar av Centraleuropa och täcker östra Tyskland, västra Polen, hela Tjeckien, delar av Slovakien och delar av Österrike (figur 4.1).



Figur 4.1. Rektangeln visar satellitbildernas utbredning.

Terrängen består till stor del av slättlandskap med moränryggar och åsar som bryter av landskapet. Slättlandskapet övergår i det bäcken som omger Tjeckien och återgår sedan den slätt som den Böhmska platån utgör. Bergsmassiven som till exempel Krusne Hory i nordvästra Tjeckien är de områden som är mest skogsklädda. De bergiga trakterna är bevuxna med främst barrträd som gran (*Picea Abies*) och tall (*Pinus Sylvestris*) (Cerný och Paces 1995). Ungefär en tredjedel av Tjeckiens yta är skogsmark. Förhållandet är likt i övriga Europa men i undersökningsområdet är det främst jordbruksbygder som finns med utanför Tjeckien (Nationalencyklopedin 1996).

Jordbruksmarken som i dag utgör en tredjedel av ytan var tidigare till stor del ek- och blandskogar. Vissa blandskogar finns kvar på slätterna men den största delen är nu jordbruksmark. De vanligaste grödorna i Tjeckien är råg, vete, majs och humle. I hela området är råg, potatis och havre de karaktäristiska grödorna. Förutom skogs- och jordbruksmark förekommer det många samhällen. Området ingår i en tätbefolkad öst-västlig zon, befolkningen i denna är mer än 200 invånare per km² (Nationalencyklopedin 1996). Speciella storstadsområden i området är Prag, Berlin och Dresden.

5. Material

5.1 Satellitdata

Data från NOAA-AVHRR-kanal 1 och 2 har använts i den här studien. Tidsrymden bilderna täcker är från augusti 1992 till och med augusti 1993. Områdets koordinater är i decimala grader:

- 53.2 Max Norr
- 9.9 Max Väster
- 48.2 Max Söder
- 19.4 Max Öster

5.2 Träningsdata och utvärderingsdata

Data för att hitta och jämföra marktyper i NOAA-datan har varit två stycken Landsat TM-scener från 9 juli och 7 augusti 1992. Samma scener användes för att utvärdera klassificeringarna dock andra områden, se metoder kap.5.2. Den geografiska utbredningen för respektive scen är presenterad i tabell 5.1.

Tabell 5.1. Path/Row för TM-scenerna som användes för träningsytor och utvärderingsytor.

Datum	Path/Row
1992-07-09	191/24
1992-08-07	192/24

Thematic Mapper-sensorn (TM) på Landsat satelliterna har en upplösning på 30 meter på markytan för kanalerna 1-5 och 7. De kanaler som användes vid träningstillfället var 1-4. De TM-kanaler som användes har våglängdsbanden:

- Landsat TM Kanal 1: 0.45-0.52 μm (blå)
- Landsat TM Kanal 2: 0.52-0.60 μm (grön)
- Landsat TM Kanal 3: 0.60-0.69 μm (röd)
- Landsat TM Kanal 4: 0.76-0.90 μm (NIR)

Satelliten har en omloppstid på 99 minuter och upprepningscykeln är på ca 16 dygn (Lillesand och Kiefer 1994)

5.3 Kartor och annan data

För att orientera sig i satellitbilderna användes flygkartor över Europa.

Dessutom har en markanvändningsklassning över skogsområdena i Krusne Hory –massivet använts (Flodmark et al. 1996)

Digital Chart of the World (DCW, 1992) har använts för att lägga in tätorter och vattendrag exakt.

5.4 Spridningsmodellen

Till modellen har man bland annat utsläppsdata och meteorologisk data som vindriktningar, vindhastighet och nederbördsdata. Man beräknar vindrosor för källorna och från dessa dras en centrumlinje runt vilken det byggs upp en plym vars utbredning och livslängd avgörs av vindhastighet, utsläppsmängd och depositionen (Bednár et al. 1994). Depositionen är uppdelad i torr och våtdeposition. Våtdepositionen avgörs av nederbördsdata och torrdepositionen bestäms av beräkningar gjorda på olika marktyper (Sehmel 1980).

Utgångsläget innan man kör modellen med markanvändningsdata är att man använder endast en marktyp i modellen, detta kan jämföras med ett landskap helt täckt med snö.

5.5 Datorutrustning

Datorer och program som använts för att genomföra arbetet har varit

PC Pentium-90

PCI EASI/PACE

IDRISI

ARC/INFO och ArcView 3

Annan mjukvara som använts har varit ordbehandlingsprogram, kalkylprogram databashanterare och kartprogram.

6. Metoder

6.1 Principalkomponent analys för att minska datamängden

Vid stora datamängder kan principalkomponent analys (PCA) förtydliga mönster i data. PCA har använts inom fjärranalysen bland annat för att söka geologiska strukturer, för att sträcka bilder (Richards 1995) och undersöka multitemporal dimensionalitet (Eklundh och Singh 1993). Metoden är en multidimensionell transformation av data där man börjar med att skapa en kovarians- eller korrelationsmatris. Man söker sedan en vektor som skär genom datamängden så att korrelationen maximeras för alla våglängdsband. För att få en förklaring på variationen i alla dimensionerna söker man en ny vektor vinkelrätt mot den föregående så kallade egenvektorn. Detta fortgår tills man har skapat en egenvektor för alla dimensionerna. Varje principalkomponents egenvärde beräknas och dess andel av den totala variansen beräknas.

Den principalkomponentanalys som använder korrelationsmatrisen kallas standardiserad PCA (sPCA) (Eastman et al. 1993). Eklundh och Singh (1993) har visat att man genom att använda sPCA kan minska riskerna för att SNR (signal to noise ratio) ska påverka data. Detta innebär att våglängdsband viktas lika mycket. Loadings är en korrelationskoefficient mellan principalkomponenten och den ursprungliga datan för ett tillfälle eller våglängdsband. I sPCA presenterar man loadings istället för egenvektorena.

Eastman och Fulk (1993) visade även att sPCA är ett lämpligt verktyg att isolera säsongseffekter. Man studerade då principalkomponenternas relation till olika säsongsbundna företeelser som framträder vid temporala data. Eastman och Fulk (1993) visar för varje komponent vad de representerar. Den första komponenten visar på skillnader i reflektans mellan de olika delarna av datasetet. Det kan till exempel vara kontraster som finns i all data, vatten och land kan ge dessa kontraster. Den andra komponenten representerar något som skiljer sig från den första komponenten, en cyklisk förändring. Detta är den första komponenten som representerar en säsongsvariation.

I den tredje komponenten förekommer även där en cyklisk variation som står för ytterligare säsongsvariationer. Eastman och Fulk (1993) går systematiskt igenom de åtta första komponenterna i analys och hittar variationer som inte bara är årsbundna utan även har en cyklisitet som sträcker sig över flera år. I komponent 8 menar man att man spårar ENSO (El Niño/Southern Oscillation).

För att urskilja vilka av de satellitbilder som representerar den största variationen över perioden utfördes en sPCA på den temporala datan. De tillfällen som representerade den största variationen togs ut för att vara med i en maximum likelihood klassificering.

6.2 Träningsytor och utvärderingsytor med klusteranalys

För att hitta stora områden inom datan som kunde tjänstgöra som tränings- respektive utvärderingsområden så gjordes en *unsupervised classification* på NOAA-data. Metoden är som namnet antyder inte övervakad av operatören utan är en metod där en algoritm undersöker data för att hitta lika värden. Dessa bildar kluster och blir specifika klasser i en klassning. Den använda algoritmen är "k-means" (PCI 1994) som ger operatören utrymme att ange hur många klasser som algoritmen ska hitta.

De ytor som var homogena enligt klusteranalysen jämfördes med ytor i TM-scenerna för att få operatörens erfarenhet kopplad till klasserna. I de fall där ytorna verkligen kunde hänföras till endast en klass digitaliserades polygoner.

De klasser som har använts är:

1. Jordbruksmark
2. Lövskog
3. Barrskog
4. Städer
5. Vatten/Vattendrag

I en omgång av klassningarna visade det sig att städer och vattendrag har tendens att bli förda till andra klasser. Därför användes data från Digital Chart of the World för att skapa en mask som tog bort vattendrag samt tätorter. Dessa lades sedan till efter det att klassningarna genomförts med de tre första klasserna. Man var från de Tjeckiska meteorologernas sida även osäker på om man behövde ha uppdelningen mellan lövskog och barrskog då dessa inte skiljer sig speciellt vad gäller depositionshastighet under den tid träden bär löv. Därför lades klasserna barrskog och lövskog ihop och tränades till en klass "skog" som användes i vissa klassningar.

TM-scenerna som användes täcker ett mindre område än den NOAA-AVHRR scen som klassades. Varje TM-scen täcker ett område på 31820 km² medan NOAA-datan täcker ett område på 327680 km². Den ena TM-scenen täcker i den nordöstra delen av Tjeckien medan den andra täcker södra Tjeckien. De ytor som skulle användas till tränings- och utvärderingsytor kontrollerades i TM-scenerna samt tillhörande utskrifter. Storleken på tränings respektive utvärderingsytorna presenteras i tabell 6.1

Tabell 6.1. Storleken på tränings- och utvärderingsytorna i NOAA-data.

Klass	Träningsyta, antal ytor (Σ pixlar)	Utvärderingsyta, antal ytor (Σ pixlar)
Barrskog	2.82 * 10 ⁶ ha, 11 st (168 st)	4.90 * 10 ⁵ ha, 5 st (70 st)
Lövskog	2.02 * 10 ⁶ ha, 8 st (142 st)	4.49 * 10 ⁵ ha, 7 st (67 st)
Jordbruksmark	15.29 * 10 ⁶ ha, 15 st (391 st)	11.01 * 10 ⁶ ha, 13 st (333 st)

Ytorna är valda så att det inte ska råda något tvivel om vilken klass de tillhör. Områden som klusteranalysen fört till samma klass behöver inte komma med bland ytorna om operatören anser att de är för svåra att skilja eller rent av är för blandade.

6.3 Klassernas separabilitet

När träningsytorna är utvalda skapas så kallade signaturer av alla de pixlar som ligger bland träningsytorna i en klass. För att avgöra hur skilda två klasser är från varandra används en separabilitetsanalys. Bhattacharyya distance är en av metoderna man kan använda (Richards 1995). Bhattacharyya distance beräknar utifrån densitetsfunktioner för varje klass vilken sannolikhet det är för en pixel att tillhöra en viss klass. Densitetsfunktionerna är värden på utbredningen av de spektrala klasserna i ett flerdimensionellt rum. Värdet från beräkningarna är ett mått på hur stort avståndet mellan densitetsfunktionerna är. Värdena varierar mellan 0 och 2 där noll är fullständigt överlappande signaturer och värden som är större än 1.9 representerar helt skilda klasser (Richards 1995).

6.4 Maximum likelihood klassning

Maximum likelihood (ML) -klassificeringen är en klassningsalgoritm som tar hänsyn till hur stor sannolikhet det är för en pixel att tillhöra en speciell klass (Lillesand och Kiefer 1994). Man skapar med sina träningsytor en mall, mot vilken alla pixlar jämförs och pixeln förs till den klassen som det är störst sannolikhet att pixeln tillhör (Richards 1995). Mallen beskriver utbredningen av varje klass i det multispektrala rum som kanalerna, eller i detta fall tillfällena, utgör. Beroende på hur man valt sina träningsytor kommer klassernas storlek att variera. Det är viktigt att man har ett stort antal pixlar i varje klass träningsyta. Vidare gäller antagandet att träningsytorna är normalfördelade (Richards 1995). Antalet träningsytor för ett multispektralt rum med N dimensioner bör inte vara mindre än $N+1$ för att undvika att covariansmatrisen blir singulär (Richards 1995). För att undvika att någon klass blir sämre representerad när dimensionaliteten ökar bör man minst använda $10N$ pixlar per spektral klass (Swain and Davis 1978).

6.5 Filtrering av data

Den klassade datan visar en del heterogeniteter i stora områden som borde vara homogena. Genom en modefiltrering så filtreras enstaka pixlar som tillhör en annan klass bort och tillförs det värde som de angränsande pixlarna i huvudsak har (PCI 1994). Modefiltreringen genomförs genom att ett 3×3 fönster undersöker mittpixelns omgivande pixlars värden och ger mittpixeln det värdet som ett visst antal av grannpixlarna har.

6.6 Utvärderingar

Alla klassningar har utvärderats med klassningsnoggrannhet, objektsnoggrannhet och total noggrannhet. Objektsnoggrannheten beräknas enligt:

$$\frac{A}{C} * 100$$

där A är antalet rätt klassade punkter i klassen och C är antalet punkter, klassnings- och utvärderingspunkter, för klassen. Objektsnoggrannheten beskriver hur stor sannolikhet det är att klassningen stämmer överens med utvärderingsmaterialet. Klassningsnoggrannheten beräknas enligt:

$$\frac{A}{B} * 100$$

där B är antalet punkter i utvärderings materialet. Resultatet beskriver sannolikheten för att utvärderingsmaterialet ska stämma med klassningen. Totalnoggrannheten beräknas genom att en medelnoggrannhet först beräknas för varje klass enligt:

$$\frac{2A}{C + B} * 100$$

för att sedan få totalnoggrannheten i en klassning adderas alla medelnoggrannheter och divideras med antalet klasser, n ,

$$\frac{\Sigma A}{n}$$

Totalnoggrannheten ger ett mått så att olika klassningar kan jämföras med ett värde.

6.7 Implementering i spridningsmodellen

Att kartera de olika marktyperna så att man kan skilja på olika grödor och växtslag behövs inte för att förbättra spridningsmodellen utan de klasser som blev aktuella bestämdes utifrån studier som gjorts på hur olika luftburna partiklars deposition genom luften sker över olika marktyper (Sehmel 1980). De marktyper som ansågs ligga nära varandra slogs samman till en klass, till exempel slogs betesmarker och de odlade områdena med stråsäd och annan gröda samman eftersom de dels ger lika deposition och dels har lika spektrala egenskaper.

För att köra spridningsmodellen med markanvändningsdata lades algoritmer för depositionshastigheter (Sehmel 1980) till för de marktyper som markanvändningsdata beskriver. Upplösningen i modellen ställdes till 5x5 km, en programslinga skrevs som utifrån markanvändningsdatan beräknar den medeldepositionshastighet som förekommer inom de 25 kvadratkilometrarna. Beräkningstiden om man skulle ha en upplösning på 1x1 km skulle vara alltför lång för att använda vid de initiala körningarna (Holpuch och Brechler, personlig kontakt). Modellen kördes två gånger med samma förutsättningar, en gång med markanvändningsdata och en gång utan. Dessa körningars resultat jämfördes sedan.

7. Resultat

7.1 Principalkomponent analys

Till en början gjordes en principalkomponentanalys på NOAA kanal 1 för alla 36 tillfällen med en ostandardiserad PCA. En efterföljande sPCA skulle följa men resultaten visade på något fel i datan. Enligt resultaten för principalkomponentanalysen så har de olika komponenterna väldigt liten varians vilket inte stämmer överens med det förväntade värdet. Det samma gäller för principalkomponentanalysen som är gjord på NOAA kanal 2. Vid en närmare undersökning visade det sig att 30 av de 36 tillfällena inte var molnfria utan molndelen i bilderna varierade mellan ett par procent av bilden upp till 100%.

På de sex molnfria tillfällena gjordes en ny sPCA vars resultat sedan låg till grund för de olika klassningarna. De sex tillfällena presenteras i tabell 7.1.

Tabell 7.1. De sex molnfria tillfällena som upptäcktes i och med den första principalkomponentanalysen

92083	Sista tredjedelen av augusti 1992
93043	Sista tredjedelen av april 1993
93051	Första tredjedelen av maj 1993
93052	Andra tredjedelen av maj 1993
93062	Andra tredjedelen av juni 1993
93071	Första tredjedelen av juli 1993

Principalkomponentanalyserna som gjordes på dessa sex tillfällena gjordes med sPCA. De resultat som togs fram finns presenterade för de båda AVHRR-kanalerna i tabell 7.2 och 7.3.

Tabell 7.2. Komponenternas förklaringsgrad samt de olika tillfällenas loadings för varje komponent. Resultaten avser AVHRR-kanal 1.

	<u>Komponent 1</u>	<u>Komponent 2</u>	<u>Komponent 3</u>	<u>Komponent 4</u>	<u>Komponent 5</u>	<u>Komponent 6</u>
Varians (%)	94,93	1,64	1,16	0,95	0,78	0,53
Loadings :						
<u>Tillfälle</u>	<u>Komponent 1</u>	<u>Komponent 2</u>	<u>Komponent 3</u>	<u>Komponent 4</u>	<u>Komponent 5</u>	<u>Komponent 6</u>
92083	0,97	-0,13	-0,10	-0,16	-0,05	-0,01
93043	0,97	-0,09	-0,07	0,17	-0,09	0,02
93051	0,96	0,26	-0,09	-0,02	-0,02	-0,01
93052	0,98	-0,04	-0,01	0,04	0,14	-0,11
93061	0,98	-0,03	0,03	-0,01	0,10	0,14
93071	0,97	0,02	0,22	-0,02	-0,08	-0,02

Tabell 7.3. Komponenternas förklaringsgrad samt de olika tillfällenas loadings för varje komponent. Resultaten avser AVHRR-kanal 2.

	<u>Komponent 1</u>	<u>Komponent 2</u>	<u>Komponent 3</u>	<u>Komponent 4</u>	<u>Komponent 5</u>	<u>Komponent 6</u>
Varians (%)	80,59	7,50	3,87	3,56	2,60	1,88
Loadings :						
<u>Tillfälle</u>	<u>Komponent 1</u>	<u>Komponent 2</u>	<u>Komponent 3</u>	<u>Komponent 4</u>	<u>Komponent 5</u>	<u>Komponent 6</u>
92083	0,93	-0,04	-0,11	-0,18	-0,31	-0,03
93043	0,91	-0,21	-0,24	-0,15	0,22	-0,09
93051	0,91	-0,09	-0,10	0,40	-0,05	-0,04
93052	0,94	-0,12	0,10	-0,03	0,05	0,28
93061	0,91	-0,07	0,38	-0,03	0,04	-0,15
93071	0,79	0,61	-0,04	-0,01	0,06	0,01

Resultaten tolkas utifrån de olika loadings varje tillfälle bidrar till en komponent med. Alla sex komponenterna får anses vara av intresse i det här fallet. Variationen kan bero på flertalet orsaker, skillnader mellan till exempel vatten och land, snö och barmark och utslagen växtlighet och växtlighet i sitt vinterstadie. Principalkomponentanalysen genomfördes för att detektera de tillfällen som visar på de största variationerna. Med de sex tillfällena så försvann risken för snö i bilderna men samtidigt den stora variationen mellan bilderna.

De tillfällen som valts ut för att göra klassningar med fyra tillfällen var:

9208-1, 9305-2, 9306-1, 9307-1. Dessa tillfällen har för de båda kanalerna höga loadings i framförallt första komponenten men även i de lägre. Tillfället 93051 har valts bort trots sitt höga värde i andra komponenten eftersom den dels har lägre värden i första men inte heller utmärker sig i de andra komponenterna. Tillfälle 92083 utmärker sig med högt värde i tredje komponenten i AVHRR-kanal 2, dessutom är denna viktig för att bibehålla lite fenologisk variation så att alla tillfällena inte hamnar på våren.

De tillfällen som valdes ut för att göra en klassning på med tre tillfällen var:

9208-3, 9305-2, 9306-1. Dessa tillfällen valdes ut med samma kriterier som de fyra tillfällena. Även här har tillfällena tagits ut under samma kriterier som ovan och för att behålla den fenologiska variationen så har augustitillfället från 1992 tagits med.

7.2 Separabilitetsanalys

Separabilitetsanalysen utfördes på signaturerna från 6, 4 och 3 tillfällen. De tillfällen som ingick i respektive separabilitetsanalys var de som tagits ut i principalkomponentanalysen. Separabiliteten, som redovisas i tabell 7.4-7.6, undersöktes för både två och tre klasser på alla sammanslagningarna.

Tabell 7.4. Bhattacharyya distance värde då signaturerna gjordes på data från 6 tillfällen. Klassen Skog är den sammanslagning som gjorts när klassningar med två klasser gjorts.

	Lövskog	Barrskog	Skog
Barrskog	1.69	-	-
Jordbruksmark	1.74	1.92	1.85

Tabell 7.5. Bhattacharyya distance värde då signaturerna gjordes på data från 4 tillfällen. Klassen Skog är den sammanslagning som gjorts när klassningar med två klasser gjorts.

	Lövskog	Barrskog	Skog
Barrskog	1.43	-	-
Jordbruksmark	1.59	1.83	1.72

Tabell 7.6. Bhattacharyya distance värde då signaturerna gjordes på data från 3 tillfällen. Klassen Skog är den sammanslagning som gjorts när klassningar med två klasser gjorts.

	Lövskog	Barrskog	Skog
Barrskog	1.28	-	-
Jordbruksmark	1.48	1.75	1.64

7.3 Maximum likelihood klassning och dess utvärdering

Klassificeringarna genomfördes på den molnfria data som fanns, sex tillfällen. Klassningarna gjordes dels med alla sex 10-dagarskompositerna, dels med de fyra som uppvisade störst andel av variationen och dels med de tre som visade på störst andel i variationen. Klassningar gjordes med två och tre klasser, barrskog, lövskog och jordbruksmark respektive skog och jordbruksmark. Resultaten för de olika klassningarna redovisas i tabell 7.7-7.12. Observera att stad och vatten inte är med i beräkningarna utan andel av bilden är endast andel av det som är skog eller jordbruksmark.

Tabell 7.7. Resultat från klassningar med data från sex tillfällen med tre klasser (klassning 1).

Klass	Andel av bilden (%)	Underlag för klassningen
Barrskog	37.99	9208-3, 9304-3,
Lövskog	16.42	9305-1, 9305-2,
Jordbruksmark	45.59	9306-1, 9307-1

Tabell 7.8 Resultat från klassningar med data från sex tillfällen med två klasser (klassning 2).

Klass	Andel av bilden (%)	Underlag för klassningen
Skog	46.75	9208-3, 9304-3,
Jordbruksmark	53.25	9305-1, 9305-2,
		9306-1, 9307-1

Tabell 7.9. Resultat från klassningar med data från fyra tillfällen med tre klasser (klassning 3).

Klass	Andel av bilden (%)	Underlag för klassningen
Barrskog	35.88	9208-3, 9305-2, 9306-1, 9307-1
Lövskog	23.03	
Jordbruksmark	41.09	

Tabell 7.10. Resultat från klassningar med data från fyra tillfällen med två klasser (klassning 4).

Klass	Andel av bilden (%)	Underlag för klassningen
Skog	49.91	9208-3, 9305-2, 9306-1, 9307-1
Jordbruksmark	50.09	


Tabell 7.11. Resultat från klassningar med data från tre tillfällen med tre klasser (klassning 5).

Klass	Andel av bilden (%)	Underlag för klassningen
Barrskog	38.32	9208-3, 9305-2, 9306-1
Lövskog	19.85	
Jordbruksmark	41.83	

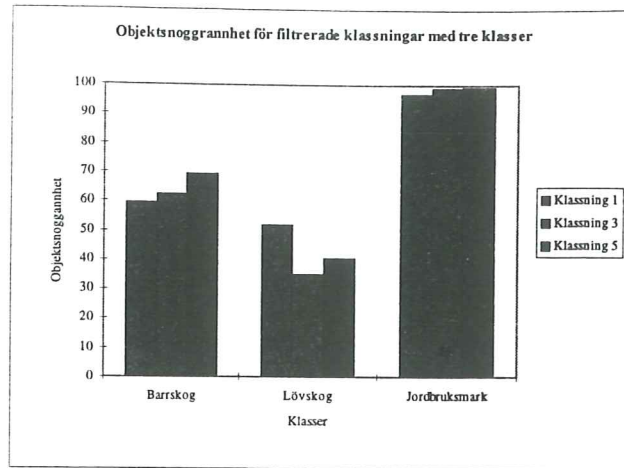
Tabell 7.12. Resultat från klassningar med data från tre tillfällen med två klasser (klassning 6).

Klass	Andel av bilden (%)	Underlag för klassningen
Skog	47.32	9208-3, 9305-2, 9306-1
Jordbruksmark	52.68	

Objektsnoggrannheten för klassningar med tre klasser och två klasser, ofiltrerad och filtrerad data presenteras i figur 7.1-7.4.




Figur 7.1. Objektsnoggrannhet för klassning 1, 3 och 5.




Figur 7.2. Objektnoggrannhet för filtrerad data med tre klasser.

Filtreringen har gjort att objektnoggrannheterna över lag har blivit bättre, ett undantag förekommer i den filtrerade klassning 1 där noggrannheten har sjunkit.

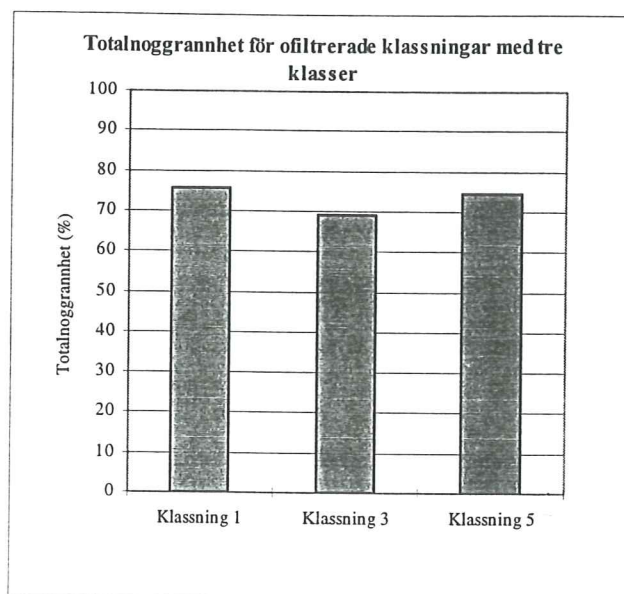


Figur 7.3. Objektnoggrannhet för klassning 2, 4 och 6.




Figur 7.4. Objektnoggrannhet för filtrerad data med två klasser.

Även för klassningarna med två klasser ligger objektsnoggrannheten högre efter filtrering. Sammanslagningen av klasserna lövskog och barrskog till klassen skog ger en avsevärd förbättring i noggrannhet för skogsmarkerna. Totalnoggrannheten visar på bäst noggrannhet för den filtrerade datan med endast två klasser. Totalnoggrannheterna redovisas i figur 7.5-7.8.




Figur 7.5. Totalnoggrannhet för klassningarna 1, 3 och 5.




Figur 7.6. Totalnoggrannhet för klassningarna 1, 3 och 5 efter filtrering.

Totalnoggrannheten ökar efter filtrering eftersom en ökning förekommer både i objektsnoggrannheten och i klassningsnoggrannheten. Totalnoggrannheten i datan med tre klasser (figur 7.5) ökar med 5-6% efter det att den blivit filtrerad med ett modelfilter (figur 7.6)

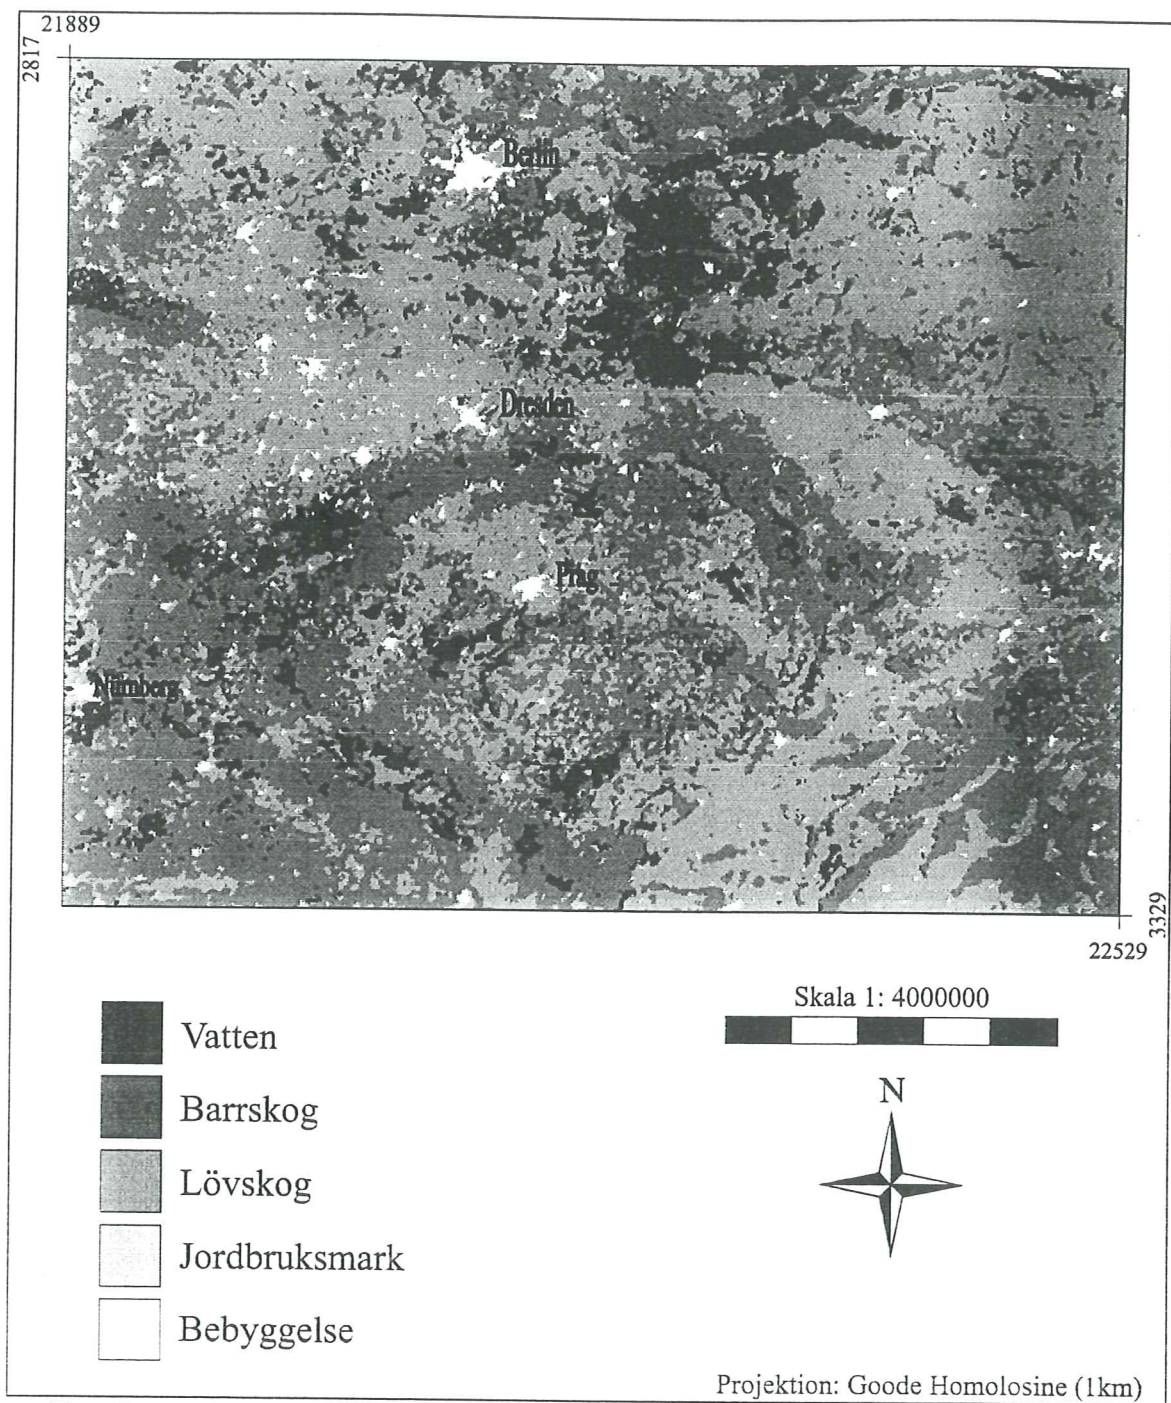


Figur 7.7. Totalnoggrannheter för klassningarna 2, 4 och 6.

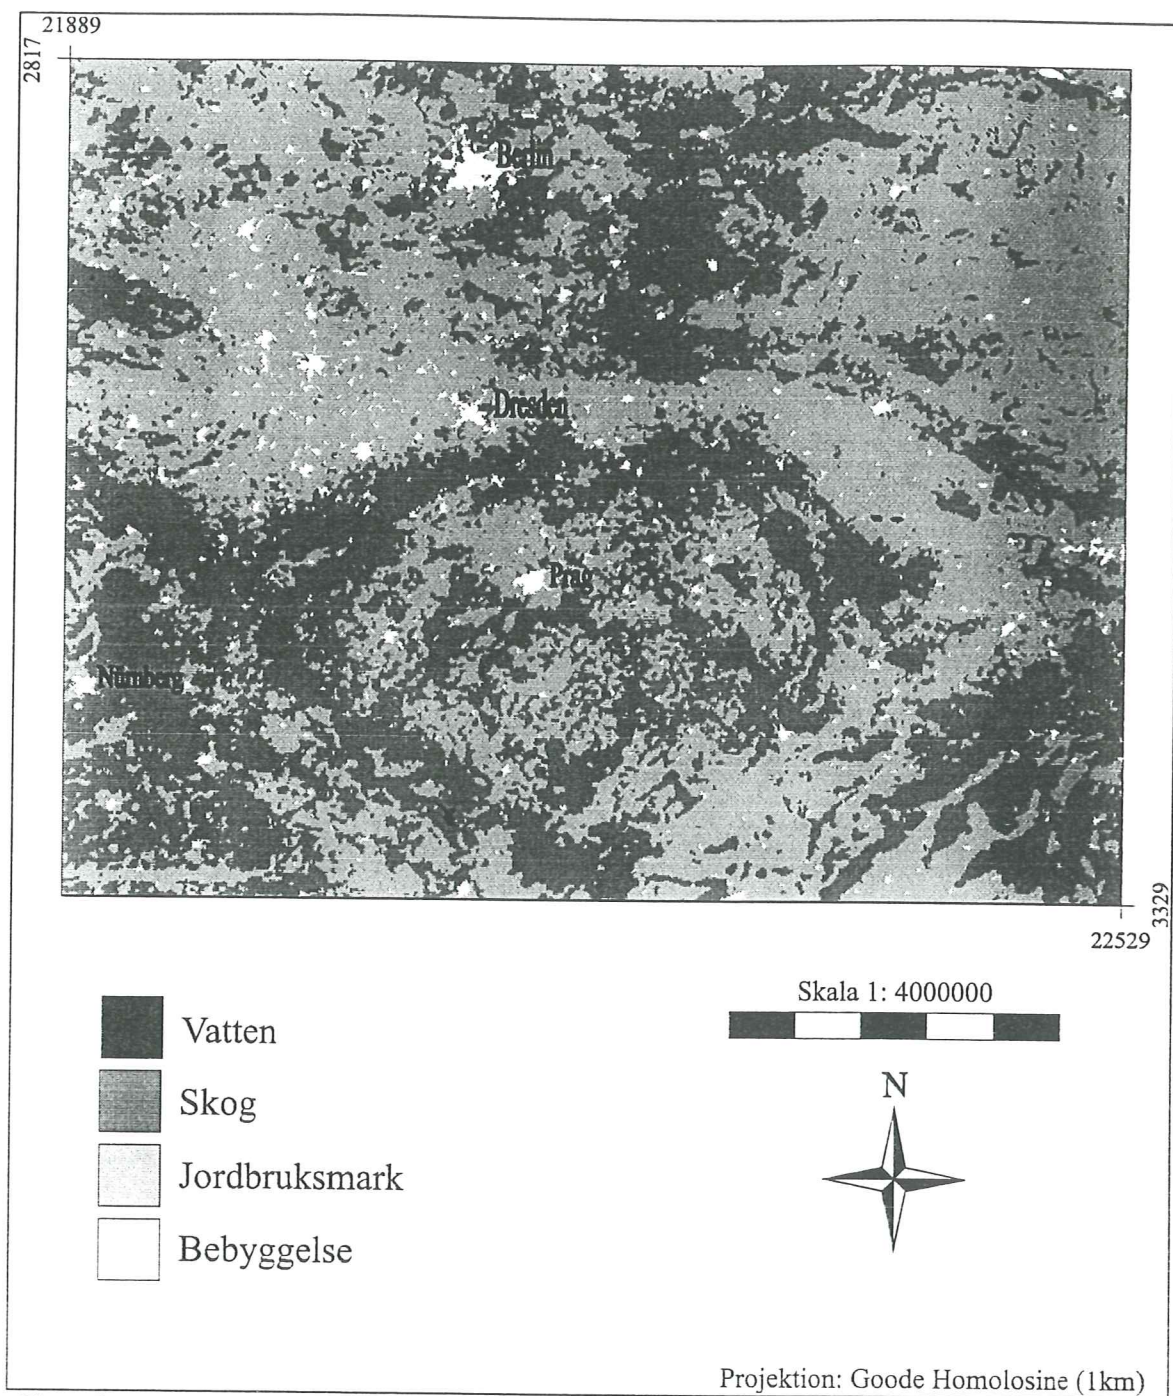


Figur 7.8. Totalnoggrannheter för klassningarna 2, 4 och 6 efter filtrering.

Efter det att en filtrering med modelfilter genomförts ökar totalnoggrannheten även för klassningar med två klasser (figur 7.7 och 7.8). Ökningen är mellan 2% och 5%. Resultaten av de filtrerade klassningarna 1 och 2 finns som kartor i figur 7.9 respektive figur 7.10.




Figur 7.9. Markanvändningskarta med fem klasser.




Figur 7.10. Markanvändningskarta med fyra klasser.

7.4 Resultat från körningar med spridningsmodellen

Vid de två körningarna av modellen får man resultat om depositionen av SO_2 och SO_4^{2-} , och hur stor del av depositionen som är våt- respektive torrdeposition. Dessa resultat vägs samman för att kunna ge ett resultat på det totala svavelnedfallet över området. Resultatet av körning med och utan markanvändningsdata presenteras i figur 7.11 och 7.12. Differensen mellan de olika körningarna presenteras i figur 7.13.

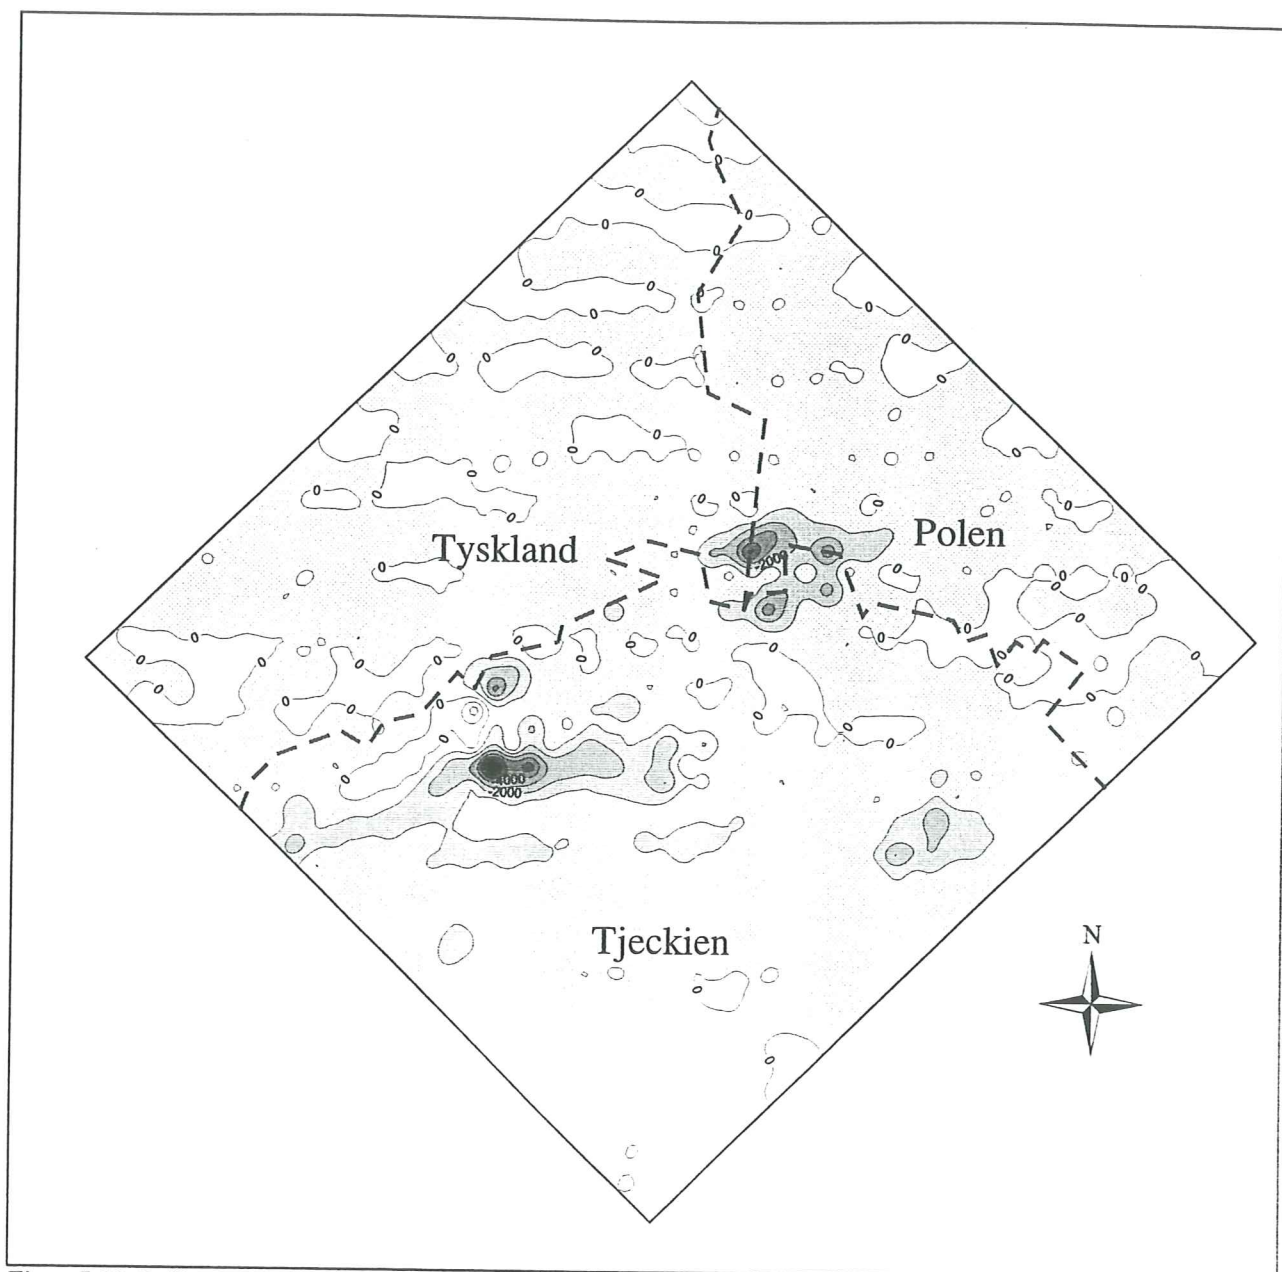


Figur 7.11. Svaveldeposition ($kg/km^2/år$) beräknad med markanvändningsdata.



Figur 7.12. Svaveldeposition ($\text{kg}/\text{km}^2/\text{år}$) beräknad utan markanvändningsdata.

Resultaten visar generellt på lägre värden när markanvändningen är med i modellen. Stora områden får ungefär 6% mindre nedfall i modellen om man använder sig av markanvändningsdatan, andra områden har upp till 50% eller $8000 \text{ kg}/\text{km}^2/\text{år}$ lägre nedfall. Ett litet område i Krusne Hory massivet har en liten ökning av nedfallet.



Figur 7.13. Differens av svaveldeposition ($\text{kg}/\text{km}^2/\text{år}$) mellan körningar med och utan markanvändningsdata

8. Diskussion

8.1 Principalkomponentanalysen

Principalkomponentanalysen var från början till för att kunna reducera datamängden till de tillfällen som innehöll den största variationen inom bilderna. Detta skulle innebära att bilder med snö skulle få sorteras bort för att man sedan skulle kunna hitta gränserna då vegetationens blad slår ut. På detta sätt kan man urskilja brukad mark från skog genom att jordbruksmark har en temporal gräns där marken först har en spektral signatur som visar den bara jorden och sedan en växande grödas signatur. Barr- och lövskog kan skiljas på liknande sätt genom att lövskogen får en annorlunda signatur när dess löv slår ut.

Ett problem var att den metod man använt för att skapa de kompositerna som använts till arbetet innebär att man väljer ut de dagar som visar på högst värde i NDVI under 10-dagarsperioden (Eidenshink et al. 1994). Man maskar alltså inte bort moln utan hoppas på att de tillfällena som har en topp i NDVI ska vara så molnfria som möjligt. Detta gör att det vid många tillfällen kan ligga moln av olika slag i bilderna. Bara för att man uppmätt ett högt NDVI innebär inte detta att kompositen är molnfri utan att den är uppbyggd på tillfällena där den underliggande marken slår igenom molnen mest. På grund av detta fick datamängden först reduceras manuellt genom att mäta in ett antal olika spektrala värden på moln och sedan undersöka alla kompositerna för att sortera ut de med moln. Ett sätt att komma till rätta med molnproblemen kan vara att man istället för att skapa kompositerna på en 10 dagars nivå använder sig av två- eller treveckorsperioder. Detta innebär dock sämre temporal upplösning (Moody et al. 1994). Problem med moln i satellitbilder är vanliga. För studier där man inte kan minska på den temporala upplösningen används olika algoritmer för att maska bort moln (Moody et al. 1994).

En standardiserad principalkomponentanalys genomfördes på de sex tillfällena som blev kvar efter att bilder med moln tagits ur datamängden. De tillfällena som blev kvar efter att kompositerna med moln tagits bort var de tillfällena där lövsprickning och grödor brukar ta fart. När en PCA genomförts visade det sig att de olika kompositernas loadings var mycket lika för alla komponenterna. Datamängden var redan reducerad så att klassningar kunde genomföras utan problem men ur de sex tillfällena valdes det ut fyra och tre tillfällena för att göra jämförande klassningar.

Klassningarna som utfördes på data med fyra respektive tre tillfällena gav sämre klassningar enligt utvärderingarna. Variationen av den fenologiska förändringen minskar med endast tre eller fyra tillfällena och klassningarna blir sämre.

En standardiserad PCA är att föredra framför en ostandardiserad i en undersökning som den här då våglängdsbanden i datamängden får lika stor inverkan i principalkomponentanalysen (Eklundh och Singh 1993). Standardiseras inte värdena som de gör i en korrelationsmatris i motsats till en kovariansmatris, så kommer data med större variationsvidd också att påverka mer i principalkomponenterna.

8.2 Tränings- och utvärderingsdata

Träningssyftorna som användes kom från ett annat satellitbildsmaterial än de som klassades. I TM-data är det enklare att detektera olika marktyper eftersom upplösningen är ca 30x30 meter. Metoden blir subjektiv i stora avseenden men att hitta 4-5 olika klasser med hjälp av de homogena områden som klusterklassningen gav är inte svårt när man har erfarenhet av området från fältresor, flygfoton och litteratur. Att samla ett statistiskt godtagbart antal träningspunkter och utvärderingspunkter över ett så här stort område får anses omöjligt. Som jämförelse kan en studie av Townsend et al. (1987) användas där man gör en liknande kartering över Sydamerika med 16 klasser. Man använde sig av befintliga kartor och satellitdata för träning och utvärdering. Träningssyftor för de olika klasserna valdes så att de innehöll ett stort antal pixlar så att signaturerna var så breda att alla typer av subklasser som finns i de klasser som använts verkligen kom med i rätt klass. De marktyper som används i studien varierar lite inom området. De olika skogstyperna varierar mycket lite över den aktuella regionen då artsammansättningen är mycket lik i de skogar som är av löv- eller blandtyp. Barrskogarna består genomgående av samma arter. Jordbruksmarken är den klass som är mest divers, dess träningsyftor är dock ungefär 15 gånger större än skogsmarkens. I och med detta bör de flesta varianter av grödor och betesmarker komma med i klassen.

Även för utvärderingsytorna togs data ur kart och satellitmaterialet vilket gav problem så till vida om de olika polygonerna skulle föras till ett träningsdataset eller utvärderingsdataset, slumpen har fått avgöra här. Dock har både träningsdata och utvärderingsdata varit omfattande och man har kunnat genomföra de olika utvärderingarna utan problem med för få pixlar.

8.3 Separabilitetsanalys med Bhattacharyya distance

Bhattacharyya-distance värdena i tabell 7.4-7.6 visar på skillnader i separabilitet då signaturerna skapas med olika många tillfällen som grund. Separabiliteten minskar med antalet tillfällen som signaturerna skapas från. Från att vara i det närmaste separerbara med alla sex tillfällena så blir separabiliteten så dålig att man kan ifrågasätta om man över huvud taget bör göra klassningar med färre tillfällen.

Separabilitetsminskningen beror på att fenologin inte varierar tillräckligt mycket för att man ska kunna skilja olika markklasserna från varandra. Man kan endast spekulera i vilka förbättringar som kan göras med data från fler molnfria tillfällen.

8.4 Maximum likelihood klassningarna

Resultaten av klassningarna visar att den klassning som genomfördes med data från alla sex tillfällena var den bästa. När man tränar data har man för detta dataset fler värden att bygga den träningssignatur som sedan används i klassningen. Möjligen minskar variationen mellan de olika tillfällena när ett tillfälle tas bort, vilket skulle innebära att skillnaderna mellan områden där vegetation bär blad och inte bär blad suddas ut.

Skillnaderna mellan barrskog/lövskog klassningarna och klassningarna med endast en skogsklass är mycket små vad gäller skogsmarken. Detta visar på en svårighet att skilja mellan löv- och barrskog med det datamaterial som använts. Spridningsmodellen hanterade när alla algoritmer provkörts endast en klass för skog så ur den synvinkeln bidrog inte detta till några problem. Det verkar dock finnas variationer på jordbruksmarken mellan klassningarna av barrskog/lövskog och skog. Det verkar som delar av den ljusare lövskogen förs till jordbruksklassen vid sammanslagning av de två skogsklasserna. Detta kan bero på att föryngringsytor har spektrala signaturer som ligger på gränsen mellan lövskog och jordbruksmark.

8.5 Filtreringar

De filtreringar som genomförts på den klassade datan har ytterligare höjt noggrannheten på datan. Vid klassningarna har områden som i utvärderingsdatan är homogena inte blivit lika homogena utan först efter en filtrering fått liknande utseende. Överlag är det så att barr- och lövskog tar en lite för stor del av jordbruksmarken på den Tjeckiska högpåsen medan det verkar vara representativt för Tyskland och Polen. I Tjeckien är de flesta lantbruk familjelantbruk och man har ett ganska blandat landskap vilket gör det mycket heterogent och svårklassat.

8.6 Spridningsmodellen

Spridningsmodellens resultat kan inte utvärderas kvantitativt eftersom man inte har verkliga mätningar av depositionen och någon körning av modellen som representerar ett verkligt

tillfälle. Diskussionen kan därför endast röra en kvalitativ bedömning av resultaten. Man kan tydligt detektera förändringar mellan körningar med och utan markanvändningsdata. Förändringarna återfinns framförallt i områden med skog och kuperad terräng som i massiven längs Tjeckiens gränser. Modellen ger i dessa områden upp till 50% förändring vilket får anses som mycket. Det beror på att dessa områden ligger högt upp och dess skogsbestånd är mycket glest. Eventuellt bör man överväga en bergsklass för dessa områden. Dock förekommer mindre förändringar över de flesta områden, över jordbruksmarken som är den typ som stämmer bäst överens med den homogena typ man tidigare använt överallt.

Spridningsmodellen räknar från markanvändningsdatan ut ett värde som har sämre upplösning än markanvändningsdatan. Gränsområden kan då få ett resultat av deposition som blir något fel. Man arbetar för att öka upplösningen på modellen i framtiden. Vidare ska man söka finansiering för att kunna kalibrera modellen mot verkliga värden.

Det faktum att resultaten från modellen fick de förändringar man räknat med gör att man på Institutionen för Meteorologi och Miljöskydd på Karls Universitet i Prag, vill arbeta vidare med markanvändningsdata i sin spridningsmodell. Kalibrering och bättre upplösning blir de första stegen och i framtiden en uppdatering av markanvändningsdata. Metoden för att skapa markanvändningsdata för ett så här stort område är billig och snabb. Dessutom ligger upplösningen redan före modellens som först om några år beräknas kunna vara nere på 1x1 km. Detta gör att uppdateringar kommer att utföras med metodiken som använts i denna studie.

EROS Data Center kommer att fortsätta lägga ut NOAA AVHRR data som blir tillgänglig för allmänheten, när man kommer ikapp med tiden kan mycket snabba uppdateringar göras för att spridningsmodellen ska kunna ge ett med verkligheten överensstämmande resultat.

9. Slutsatser

Principalkomponentanalys är ett effektivt sätt att reducera stora datamängder till den data som innehåller den största variationen. Gränsen för nyttan med PCA går vid en större datamängd än vad den här studien slutade vid, sex dataset. Resultatet av klassningarna visar detta, både med tre och med två markanvändningsklasser var de klassningar som klassades med data från sex tillfällen bäst. Att skilja på lövskog och barrskog i AVHRR-data medför problem, den upplösning som data har innebär att endast stora homogena områden blir klassade rätt.

Lövskogarna som oftast är av blandtyp blir ofta underrepresenterade i klassningarna, detta till fördel för barrskog och i viss mån även jordbruksmark.

Spridningsmodellen gav nya resultat när markanvändningsdata användes. Resultaten ska utvärderas och kalibreras men metoden anses värdefull och markanvändningsdata kommer att användas i modellen i framtiden.

10. Sammanfattning

Markanvändningen spelar en stor roll för depositionshastigheten hos olika luftföroreningar. Spridningsmodeller för luftföroreningar har tidigare inte tagit hänsyn till detta mer än att all mark i modellerna har haft samma påverkan på depositionen. Genom att grovupplösande satellitdata finns tillgänglig gratis kan man nu skapa markanvändningsdata på ett mycket billigt sätt.

Metoden att minska datamängden till de tillfällen när variationen är som störst har uppenbara vinster när man behandlar data där man som i detta fall är ute efter gränsen som lövsprickningen innebär.

Data som användes var NOAA AVHRR tiodagars kompositier med 1 km pixelstorlek. De kanaler som användes var AVHRR kanal 1 och kanal 2.

Den standardiserade principalkomponentanalys som användes viktat alla kanal lika. De tillfällen som har de högsta värdena i olika loadings representerar den största variationen i datan. Variationerna i de olika loadings som förekommer tolkas och förs till säsongsvariationer och andra variationer i datan.

En klusteranalys användes för att hitta homogena och stora områden i NOAA-data. Dessa kontrollerades och jämfördes med data ur två Landsat TM-scener. Områden där markanvändningen kunde bestämmas fick tjäna som tränings och utvärderingsytor. Klassningen av data gjordes med en maximum likelihood algoritm. Klassningarna utvärderades mot utvärderingsytorna.

Data användes i spridningsmodellen som kördes med samma ingångsparametrar med och utan markanvändningsdata. Depositionshastigheterna över de olika ytorna beräknas med formler från försök. I körningarna utan markanvändningsdata sätts depositionshastigheten till konstant över hela regionen.

Klassningarna där tre och två klasser användes visar på hög noggrannhet i utvärderingarna. De klasser som användes var jordbruksmark, barrskog och lövskog. Skog och jordbruksmark var klasserna då två klasser användes. Flera av klassningarna visar på totala noggrannheter på 90% och mer.

Spridningsmodellens körningar med data visar på att skillnader förekommer över hela området. Förändringarna visade på upp till 50% differens mellan med och utan markanvändningsdata.

Den allmänna AVHRR data som finns tillgänglig är processad så att moln inte är bortmaskade. Ungefär 84% av 10-dagarskompositerna i datamaterialet som använts i den här studien var kontaminerat med moln.

Att använda PCA för att hitta variationer i små dataset har få fördelar när klassningsalgoritmerna och datorkraften är så stor som den är idag. Moln problemet var orsaken till att datamängden fick reduceras med 84% redan innan en PCA kunde genomföras.

Den standardiserade principalkomponentanalys som genomfördes på de tillfällen utan moln gav underlag för att prova om klassningarna med olika många tillfällen gav olika resultat. Utvärderingen visade att när man använde alla sex tillfällena så blev klassningarna bäst, både i skogsklasserna och i jordbruksklassen. Klassningar med två och tre klasser ger god noggrannhet i data med upplösningen 1x1 km.

Spridningsmodellens körningar visade att den tidigare satta generella depositionshastigheten var satt för högt, detta speciellt i bergstrakter där skogen ofta är trängd både av klimat och föroreningar.

11. Referenser

- Bednář, J., Brechler, J., Halenka, T., Kopáček, J., 1995. Modelling of nitrogen pollution in the Czech Republic. Opubl.
- Bednář, J., Brechler, J., Halenka, T., Kopáček, J., 1994. Sulphur air-pollution assessment based on Charles University model. *Meteorol. Zeitschrift*. N.F. **3**. 4-10.
- Cerný, J., Paces, T., 1995. *Acidification in the black triangle region. Acid reign '95? Excursion guide*. Czech Geological Survey, Prague, Czech Republic.
- Derrien, M., Farki, B., Legléau, H., Sairouni A., 1992. Vegetation cover mapping over France using NOAA-11/AVHRR. *International Journal of Remote Sensing*. **13**, 1787-1795.
- Elvingson, P., 1992. *Skogsutsikter, luftföroreningarna och skogen – effekter, åtgärder, framtiden*. Bokskogen, Göteborg.
- Flodmark, A., Kolmert, S., Lundgren, Y., Persson, A., 1996. Skogsinventering i Norra Böhmen, Tjeckien. Opubl.
- Eastman, R.J., Fulk, M., 1993. Long sequence time series evaluation using standardized principal components. *Photogrametric Engineering & Remote Sensing*. **59**, 991-996.
- Eklundh, L., Singh, A., 1993. A comparative analysis of standardized and unstandardized Principal Components Analysis in remote sensing. *International Journal of Remote Sensing*. **14**, 1359-1370.
- Eidenshink, J.C., Faundeen, J.L., 1994. The 1-km AVHRR global land data set: first stages in implementation. *International Journal of Remote Sensing*. **15**, 3443-3462.
- Lillesand, T.M., Kiefer, R.W., 1994. *Remote sensing and image interpretation*. 3rd edition. John Wiley & Sons, New York.
- Moody, A., Strahler, A.H., 1994. Characteristics of composited AVHRR data and problems in their classification. *International Journal of Remote Sensing*. **15**, 3473-3491.
- Nationalencyklopedin*, 1996. Bokförlaget Bra Böcker, Sverige
- Oke, T. R., 1995. *Boundary layer climates*, 2nd edition. Routledge, London.
- PCI. 1994. *Using PCI Software. Version 5.3 EASI/PACE*. PCI Inc. Richmond Hill.
- Reed, B.C., Brown, J.F., VanderZee, D., Loveland, T.R., Merchant, J.W., Ohlen, D.O., 1994. Measuring phenological variability from satellite imagery. *Journal of Vegetation Science* **5**, 703-714.
- Richards, J.A., 1995. *Remote sensing and digital image analysis*, 2nd edition. Springer Verlag, Berlin.

Sehmel, G.A., 1980. Particle and gas dry deposition: a review. *Atmospheric Environment*. **14**, 983-1011

Steinwand, D.R., 1994. Mapping raster imagery to the Interrupted Goode Homolosine Projection. *International Journal of Remote Sensing*. **15**, 3463-3471.

Swain, P.H., Davis, S.M., 1978. *Remote Sensing: The Quantitative Approach*, N.Y., McGraw-Hill.

Teillet, P.M., 1991, Radiometric and atmospheric correction procedures for AVHRR preprocessing in the solar reflective channels. *Proceedings of the Fifth International Colloquium on Spectral Signatures of Objects in Remote Sensing*, Courchevel, France, 1991, 511-516.

Townshend, J.R.G., Justice, C.O., Kalb, V., 1987. Characterization and classification of South American land cover types using satellite data. *International Journal of Remote Sensing*. **8**, 1189-1207.

Voldner, E.C., Barrie, L.A., Sirois, A., 1986. A literature review of dry deposition of oxides of sulphur and nitrogen with emphasis on long-range transport modelling in North America. *Atmospheric Environment*. **20**, 2101-2123.

Kartor:

DCW 1992. Digital Chart of the World, ed 1. Defence Map Agency. USA.

ONC E-2 Scale 1: 1000000. Produced under the direction of the Director of Military Survey, Ministry of Defence, U.K.

ONC E-3 Scale 1:1000000. Prepared and published by the Defence Map Agency Aerospace Center, St. Louis, Missouri, USA.

NOAA-AVHRR 10-dagarskompositer är hämtade på webbplatsen:

<http://edcwww.cr.usgs.gov/landdaac/1KM/comp10d.html>

Datan nås via EROS Data Center eller US Geological Survey

Lunds Universitets Naturgeografiska institution. Seminarieuppsatser. Uppsatserna finns tillgängliga på Naturgeografiska institutionens bibliotek, Sölvegatan 13, 223 62 LUND.

The reports are available at the Geo-Library, Department of Physical Geography, University of Lund, Sölvegatan 13, S-223 62 Lund, Sweden.

1. Pilesjö, P. (1985): Metoder för morfometrisk analys av kustområden.
2. Ahlström, K. & Bergman, A. (1986): Kartering av erosionskänsliga områden i Ringsjöbygden.
3. Huseid, A. (1986): Stormfällning och dess orsakssamband, Söderåsen, Skåne.
4. Sandstedt, P. & Wällstedt, B. (1986): Krankesjön under ytan - en naturgeografisk beskrivning.
5. Johansson, K. (1986): En lokalklimatisk temperaturstudie på Kungsmarken, öster om Lund.
6. Estgren, C. (1987): Isälvsstråket Djurfälla-Flädermo, norr om Motala.
7. Lindgren, E. & Runnström, M. (1987): En objektiv metod för att bestämma läplanteringsläverkan.
8. Hansson, R. (1987): Studie av frekvensstyrd filtringsmetod för att segmentera satellitbilder, med försök på Landsat TM-data över ett skogsområde i S. Norrland.
9. Matthiesen, N. & Snäll, M. (1988): Temperatur och himmelsexponering i gator: Resultat av mätningar i Malmö.
- 10A. Nilsson, S. (1988): Veberöd. En beskrivning av samhällets och bygdens utbyggnad och utveckling från början av 1800-talet till vår tid.
- 10B. Nilsson, G., 1988: Isförhållande i södra Öresund.
11. Tunving, E. (1989): Översvämning i Murcia-provinsen, sydöstra Spanien, november 1987.
12. Glave, S. (1989): Termiska studier i Malmö med värmebilder och konventionell mätutrustning.
13. Mjölbo, Y. (1989): Landskapsförändringen - hur skall den övervakas?
14. Finnander, M-L. (1989): Vädrets betydelse för snöavsmältningen i Tarfaladalen.
15. Ardö, J. (1989): Samband mellan Landsat TM-data och skogliga beståndsdata på avdelningsnivå.
16. Mikaelsson, E. (1989): Byskeälvens dalgång inom Västerbottens län. Geomorfologisk karta, beskrivning och naturvärdesbedömning.
17. Nhilen, C. (1990): Bilavgaser i gatumiljö och deras beroende av vädret. Litteraturstudier och mätning med DOAS vid motortrafikled i Umeå.
18. Brasjö, C. (1990): Geometrisk korrektion av NOAA AVHRR-data.
19. Erlandsson, R. (1991): Vägbanetemperaturer i Lund.
20. Arheimer, B. (1991): Näringsläckage från åkermark inom Brååns dräneringsområde. Lokalisering och åtgärdsförslag.
21. Andersson, G. (1991): En studie av transversalmoräner i västra Småland.
- 22A. Skillius, Å., (1991): Water harvesting in Bakul, Senegal.
- 22B. Persson, P. (1991): Satellitdata för övervakning av höstsådda rapsfält i Skåne.
23. Michelson, D. (1991): Land Use Mapping of the That Luang - Salakham Wetland, Lao PDR, Using Landsat TM-Data.
24. Malmberg, U. (1991): En jämförelse mellan SPOT- och Landsatdata för vegetationsklassning i Småland.
25. Mossberg, M. & Pettersson, G. (1991): A Study of Infiltration Capacity in a Semi-arid Environment, Mberengwa District, Zimbabwe.
26. Theander, T. (1992): Avfallsupplag i Malmöhus län. Dränering och miljöpåverkan.
27. Osaengius, S. (1992): Stranderosion vid Löderups strandbad.
28. Olsson, K. (1992): Sea Ice Dynamics in Time and Space. Based on upward looking sonar, satellite images and a time series of digital ice charts.
29. Larsson, K. (1993): Gully Erosion from Road Drainage in the Kenyan Highlands. A Study of Aerial Photo Interpreted Factors.
30. Richardson, C. (1993): Nischbildningsprocesser - en fältstudie vid Passglaciären, Kebnekaise.
31. Martinsson, L. (1994): Detection of Forest Change in Sumava Mountains, Czech

- Republic Using Remotely Sensed Data.
32. Klintonberg, P. (1995): The Vegetation Distribution in the Kärkevagge Valley.
 33. Hese, S. (1995): Forest Damage Assessment in the Black Triangle area using Landsat TM, MSS and Forest Inventory data.
 34. Josefsson, T. och Mårtensson, I. (1995). A vegetation map and a Digital Elevation Model over the Kapp Linné area, Svalbard -with analyses of the vertical and horizontal distribution of the vegetation
 35. Brogaard, S och Falkenström, H. (1995). Assessing salinization, sand encroachment and expanding urban areas in the Nile Valley using Landsat MSS data.
 36. Krantz, M. (1996): GIS som hjälpmedel vid växtskyddsrådgivning.
 37. Lindegård, P. (1996). VINTERKLIMAT OCH VÅRBAKSLAG. Lufttemperatur och kådflödessjuka hos gran i södra Sverige.
 38. Bremberg, P. (1996). Desertification mapping of Horqin Sandy Land, Inner Mongolia, by means of remote sensing.
 39. Hellberg, J. (1996). Förändringsstudie av jordbrukslandskapet på Söderslätt 1938-1985.
 40. Achberger, C. (1996): Quality and representability of mobile measurements for local climatological research.
 41. Olsson, M. (1996): Extrema lufttryck i Europa och Skandinavien 1881-1995
 42. Sundberg, D. (1997): En GIS-tillämpad studie av vattenerosion i sydsvensk jordbruksmark.
 43. Liljeberg, M. (1997): Klassning och statistisk separabilitetsanalys av marktäckningsklasser i Halland, analys av multivariata data Landsat TM och ERS-1 SAR.
 44. Roos, E. (1997): Temperature Variations and Landscape Heterogeneity in two Swedish Agricultural Areas. An application of mobile measurements.
 45. Arvidsson, P. (1997): Regional fördelning av skogsskador i förhållande till mängd SO₂ under vegetationsperioden i norra Tjeckien.
 46. Akselsson, C. (1997): Kritisk belastning av aciditet för skogsmark i norra Tjeckien.
 47. Carlsson, G. (1997): Turbulens och supraglacial meandring.
 48. Jönsson, C. (1998): Multitemporala vegetationsstudier i nordöstra Kenya med AVHRR NDVI.
 49. Kolmert, S. (1998): Evaluation of a conceptual semi-distributed hydrological model – A case study of Hörbyån
 50. Persson, A. (1998): Kartering av markanvändning med meteorologisk satellitdata för förbättring av en atmosfärisk spridningsmodell.