



UPPSALA
UNIVERSITET

UPTEC W 16016

Examensarbete 30 hp
Maj 2016

Starttillståndets inverkan på hydrologisk prognososäkerhet i HYPE-modellen

The Impact of the Initial State on Hydrologic
Forecast Uncertainty in the HYPE Model

Elinor Andersson

REFERAT

Starttillståndets inverkan på hydrologisk prognososäkerhet i HYPE-modellen

Elinor Andersson

SMHI:s hydrologiska prognos- och varningstjänst använder sig av meteorologiska ensembleprognoser som indata i hydrologiska modeller. De hydrologiska ensembleprognoserna tar därmed hänsyn till framtida osäkerhet i temperatur och nederbörd och används som underlag vid utfärdandet av risker och varningar för höga flöden. För närvarande beaktas dock inte osäkerheten i modellens starttillstånd, vilket består av de tillståndsvariabler i modellen som beskriver bland annat markvattenhalt och snötäcke. I denna studie undersöktes hur starttillståndet i den hydrologiska modellen HYPE inverkar på prognoser i syfte att kvantifiera osäkerheten och på sikt möjliggöra säkrare prognoser.

Studien hade tre mål: 1) Ta fram ett förslag på hur starttillståndet kan varieras för att ge en god uppskattning av prognososäkerheten relaterat till det hydrologiska starttillståndet. 2) Undersöka sambandet mellan starttillståndets spridning och det hydrologiska prognosfelet. 3) Analysera hur årstider, avrinningsområdets area, sjöprocent, skogsprocent och höjd över havet inverkar på prognososäkerheten. En central hypotes var att mindre skillnad mellan starttillståndets vattenföring och den observerade vattenföringen vid prognosstart resulterar i mer träffsäkra prognoser. Studien begränsades av att starttillstånden endast genererades med hjälp av störningar i drivdata.

Indata till HYPE-modellen var femton temperatur- och nederbördsserier som manipulerats i syfte att skapa en ensemble av olika starttillstånd. Denna ensemble användes sedan för att göra vattenföringsprognoser med observerad temperatur och nederbörd som drivdata. Studien omfattade 76 avrinningsområden från hela Sverige med data för perioden 1999-2008. Prognoser utfördes varje dygn och ensemblespridningen utvärderades 2, 4 och 10 dygn in i prognosen. Samma utvärderingar utfördes även på autoregressiva prognoser, vilket innebär att modellerad rättas utefter observerad vattenföring.

Resultaten indikerade ett samband mellan ensemblespridning och prognosfel, vilket innebär att spridning kan användas som ett mått på starttillståndets osäkerhet. Prognosfelet korrelerade positivt med skogsprocent och negativt med avrinningsområdets area, sjöprocent och höjd över havet. Samma samband uppvisades mellan dessa områdesvariabler och spridning. Spridningen var störst på vintern och våren då normalisering skett med medelvattenföring över tio år, och under vår och sommar då normalisering skett med medelvattenföring per månad. Hypotesen att mindre skillnad mellan starttillståndets vattenföring och den observerade vattenföringen vid prognosstart resulterar i mer träffsäkra prognoser bekräftades av resultaten. Implementering av en ensemble av olika starttillstånd i operationella prognoser vid SMHI:s hydrologiska prognos- och varningstjänst föreslås i syfte att kvantifiera osäkerheten och därigenom utöka bedömningsunderlaget vid utfärdande av risker och varningar.

Nyckelord: hydrologisk modellering, starttillstånd, ensembleprognoser, prognososäkerhet, HYPE-modellen

ABSTRACT

The Impact of the Initial State on Hydrologic Forecast Uncertainty in the HYPE Model

Elinor Andersson

The Hydrological Forecast and Warning Service of The Swedish Meteorological and Hydrological Institute (SMHI) use meteorological ensemble forecasts as input in hydrological models. The hydrological ensemble forecasts take the uncertainty of future temperature and precipitation into account and serve as the basis of issued risks and warnings of high flows. Currently not considered is the uncertainty of the initial state, which consists of state variables in the model describing for instance soil water content and snow pack. This study assessed the impact of the initial state on forecasts in the hydrological model HYPE aiming to quantify the uncertainty and eventually enable more accurate forecasts.

There were three aims of this study: 1) Evaluate a suggestion about how the initial state can be varied to give a good estimation of forecast uncertainty related to the hydrological initial state. 2) Examine the relationship between the spread of initial states and the hydrological forecast error. 3) Analyze the impact of seasons, catchment area, lake percentage, forest percentage and elevation on forecast uncertainty. A central hypothesis was that a smaller difference between the discharge of the initial state and the observed discharge results in more accurate forecasts. A restriction of the study was that the initial states only could be generated by disturbances of forcing data in before the forecast.

Input data to the HYPE model were fifteen temperature and precipitation series, manipulated to generate an ensemble of different initial states. This ensemble was then used to make discharge forecasts with observed temperature and precipitation as forcing data. The study was performed on 76 catchments all over Sweden with data from the time period 1999-2008. Forecasts were made every day and the ensemble spread was evaluated 2, 4 and 10 days into the forecast. Autoregressive forecasts where the modelled discharge is corrected after the observed discharge were executed and evaluated as well.

The results indicated a relationship between ensemble spread and forecast error, which implies that the spread can be used as a measure of the uncertainty of the initial state. The forecast error and ensemble spread correlated positively to forest percentage and negatively to catchment area, lake percentage and elevation. The same trend was detected between spread and catchment characteristics. The spread was biggest in winter and spring when normalization was made with mean discharge for the ten-year period and in spring and summer when normalization was done with mean discharge per month. The hypothesis that a smaller difference between the discharge of the initial state and the observed discharge results in more accurate forecasts was confirmed by the results. An implementation of an ensemble of different initial states in operational forecasts at SMHI's Hydrological Forecast and Warning Service is suggested in order to further quantify the uncertainty of hydrological forecasts, and thereby improve the basis of judgment when issuing risks and warnings.

Keywords: hydrological modelling, initial states, ensemble forecasts, forecast uncertainty, HYPE model

FÖRORD

Det här examensarbetet omfattar 30 hp och är det avslutande momentet på civilingenjörsprogrammet i miljö- och vattenteknik (300 hp) vid Uppsala universitet och Sveriges lantbruksuniversitet. Handledare var Sara-Sofia Asp, gruppchef på SMHI:s hydrologiska prognos- och varningstjänst och ämnesgranskare var Jan Seibert, professor i hydrologi vid Zürich universitet och gästprofessor vid Institutionen för geovetenskaper vid Uppsala universitet. Examinator var Fritjof Fagerlund, universitetslektor vid Institutionen för geovetenskaper vid Uppsala universitet.

Jag vill rikta ett stor tack till min handledare Sara-Sofia som bidragit med stöd, återkoppling och idéer genom hela arbetet. Jag vill även tacka Judith Olofsson på hydrologiska prognos- och varningstjänsten och Göran Lindström på forskningsenheten som tagit sig tid att hjälpa mig och bidragit med sina expertkunskaper. Tack även till Jan Seibert som varit närvarande genom hela examensarbetet och bidragit med idéer och värdefull återkoppling. Jag vill även tacka Simon Eriksson, SMHI:s hydrologiska prognos- och varningstjänst, som tagit sig tid att svara på mina frågor och hjälpt mig med dataunderlaget.

Jag vill rikta ett stort tack till Ola Pettersson, gruppchef på Enheten för information och statistik inom SMHI:s avdelning Samhälle och säkerhet, som hjälpte mig att hitta detta examensarbete. Jag vill även tacka personalen på Siv, Sik och Sph som har bidragit till att jag trivts under min tid på SMHI.

Jag vill även tacka Göran Lindström för tillåtelsen att använda hans figurer.

Slutligen vill jag tacka min familj och mina vänner för det ovärderliga stödet jag fått under utbildningen och under examensarbetets gång. Jag vill rikta ett särskilt tack till mina föräldrar Åsa och Sören som jag bott hos under examensarbetet och till min sambo Gustav, vars kritiska korrekturläsning och nattliga MATLAB-driftservice möjliggjort detta examensarbete.

Elinor Andersson

Norrköping, maj 2016

POPULÄRVETENSKAPLIG SAMMANFATTNING

Starttillståndets inverkan på hydrologisk prognososäkerhet i HYPE-modellen

Elinor Andersson

Under de senaste årtiondena har meteorologiska och hydrologiska prognoser förbättrats avsevärt. Dagens meteorologiska 6-dygnsprognoser presterar lika bra som 2- till 3-dygnsprognoser gjorde på 70-talet (Laloyaux & Bengtsson, 2015). Det finns dock inte någon perfekt prognos, något som de flesta fått erfara under regniga picknickar utan paraply eller på skidsemestrar utan nysnö. Trots det sätter många sin tillit till prognoser som är ett viktigt planeringsverktyg för den enskilda medborgaren såväl som företag, kommuner och statliga myndigheter.

Att i förväg kunna förutsäga översvämningar och torka är en nödvändighet om förebyggande åtgärder ska kunna utföras. Det är därför viktigt att de varningar som SMHI:s hydrologiska prognos- och varningstjänst går ut med är så korrekta som möjligt; en missad varning för högt flöde skulle kunna få förödande konsekvenser. Det räcker dock inte att alltid vara på den säkra sidan och ge ut ett överflöd av varningar som sällan representerar verkligheten. Risken är då att allmänheten slutar ta varningarna på allvar vilket kan leda till allvarliga skador på såväl fastigheter som människor.

I denna studie undersöktes hur starttillståndet inverkar på vattenföringsprognoser i den hydrologiska modellen HYPE, som används av SMHI:s hydrologiska prognos- och varningstjänst. Starttillståndet innehåller information om exempelvis hur mycket vatten som finns i marken, hur mycket snö som ligger lagrad och vad sjöarnas vattenstånd är. Ett starttillstånd med mycket snö kommer att leda till större flöden vid plusgrader än ett starttillstånd utan. Idag används dock bara ett starttillstånd på SMHI:s hydrologiska prognos- och varningstjänst, och det är okänt hur det inverkar på hydrologiska prognoser. Om det vid prognosstart finns för lite snö i modellen jämfört med verkligheten kan exempelvis vårfloden underskattas vid snösmältningen.

Genom att ändra i HYPE-modellens temperatur- och nederbördsdata inför prognoser genererades femton olika starttillstånd. Detta innebär att starttillstånden baserades på alternativa historiska scenarion; det togs hänsyn till vad starttillståndet hade varit om det varit både varmare och kallare med mer och mindre nederbörd innan prognosen. På dessa starttillstånd utfördes sedan hydrologiska prognoser med samma observerade nederbörd och temperatur som indata. Det enda som skilde prognoserna åt var således starttillstånden. Skillnaden mellan prognosernas vattenföring utvärderades för att få information om hur känslig modellen var vid olika flöden och årstider och på vilket sätt olika områden påverkades. De prognoser som utfördes på starttillstånd med mindre nederbörd och högre temperatur innebar ofta lägre vattenföring, och de prognoser som baserades på prognoser med mer nederbörd och lägre temperatur gav ofta högre vattenföring. Effekten varierade dock med avseende på både områdesegenskaper och tid på året.

Resultaten visar att starttillståndet har en stor inverkan på prognoser. Ett samband mellan starttillståndens spridning och prognosfel påvisades, vilket innebär att en mängd starttillstånd kan användas för att uppskatta osäkerheten i vattenföringsprognoser. Om starttillståndens vattenföring skiljer sig åt mycket innebär det ofta att prognosen är osäker. Om starttillståndens vattenföring istället är nära varandra är prognosen ofta relativt säker.

Starttillståndens spridning visade sig vara större för avrinningsområden med stor andel skog och mindre för stora, högt belägna områden. Samma trend upptäcktes mellan prognosfel och de tidigare nämnda områdesvariablerna. För att kunna jämföra områdenas spridning med varandra delades de med respektive områdes medelvattenföring. Då spridningen delades med medelvattenföringen för de tio undersökta åren var den störst under vår och vinter. Delades spridningen istället med medelvattenföring per månad var spridningen störst under vår och sommar. Detta kan tolkas som att vår och vinter är mest känsliga för fel i starttillståndet totalt sett, men att vår och sommar är känsligast i förhållande till hur stor vattenföringen är.

Det visade sig även att prognoserna gynnades av att hänsyn togs till vilket starttillstånd som valdes. Starttillstånd med vattenföring som låg nära den observerade vattenföringen vid prognosstart hade i genomsnitt ett lägre prognosfel än kontrollprognoserna.

Sambandet mellan starttillståndsspridning och prognosfel kan användas för att ge ytterligare information om säkerheten i hydrologiska prognoser. Osäkerheten i det hydrologiska starttillståndet blir då en styrka istället för en svaghet, och skulle ge ännu ett verktyg för vakthavande hydrolog att göra en korrekt bedömning av det hydrologiska läget. Vid avrinningsområden som kontinuerligt rapporterar in vattenföring kan prognoser även förbättras genom användning av starttillstånd som stämmer närmare överens med verkligheten. Detta är dock ett område som behöver fler studier och undersökningar för att garantera att tekniken utnyttjas på optimalt sätt.

Innehållsförteckning

1	Inledning.....	1
1.1	Syfte och mål.....	2
1.2	Frågeställningar och hypoteser	2
1.3	Avgränsningar	2
2	Bakgrund	3
2.1	HYPE-modellen.....	3
2.2	Prognoskorrektion	4
2.3	Tidigare studier.....	5
3	Material och metoder	7
3.1	Områdesbeskrivning.....	7
3.2	Data.....	9
3.3	Ensemblegenerering	10
3.4	Utvärdering av ensembleprognoser	13
3.4.1	Spridning-utfall-analys.....	13
3.4.2	Spearman's rangkorrelation.....	15
3.4.3	Årstidsvariation	16
3.4.4	Dataassimilation av observerad vattenföring	17
4	Resultat.....	20
4.1	Spridning-utfall-analys	21
4.2	Spearman's rangkorrelation	22
4.3	Årstidsvariation	24
4.4	Dataassimilation av observerad vattenföring	26
5	Diskussion	35
6	Slutsatser	38
7	Referenser.....	39

Appendix A	Tabell över undersökta områden
Appendix B	Beräkningskod
Appendix C	P-värden för Spearman's rangkorrelation

Ordlista


AR-prognos (autoregressiv prognos)	Metod för att korrigera hydrologiska prognoser med avseende på observerad vattenföring
Dataassimilation	Metod där systemobservationer assimileras i simuleringar i prognosförbättringssyfte
Drivdata	Data som används för att driva modeller, i HYPE-modellens fall nederbörds- och temperaturdata
ECMWF (European Centre for Medium-range Weather Forecasts)	En oberoende organisation som förser många av Europas länder med meteorologiska ensembleprognoser
Ensemblemedlem	En enskild prognos som med de andra ensemblemedlemmarna bildar en ensembleprognos
Ensembleprognos	En mängd prognoser som tillsammans bildar en ensemble av möjliga framtida utvecklingar
Framkörning	Simulering inför prognos i syfte att skapa representativa tillståndsvariabler
HBV-modellen (Hydrologiska Byråns Vattenbalansavdelnings modell)	Hydrologisk modell som är föregångaren till HYPE-modellen
HYPE-modellen (a model for HYdrological Predictions for the Environment)	Hydrologisk vattenbalans- och vattenkvalitetsmodell
S-HYPE (Sverige-HYPE)	Modelluppsättning av HYPE-modellen för hela Sverige
MAE (Mean Absolute Error)	Medelvärde av en prognos absolutfel. Detta mått används för att kvantifiera prognosfel

RMAE (Relative Mean Absolute Error)	Det relativa medelvärdet av en prognos absolutfel. Det beräknas genom division av MAE med områdets medelvattenföring och beräknas för att möjliggöra jämförelser mellan olika områden
RMSE (Root Mean Squared Error)	Roten av en prognos medelkvadratfel. Detta mått används för att kvantifiera prognosfel
RRMSE (Relative Root Mean Squared Error)	Den relativa roten av en prognos medelkvadratfel. Det beräknas genom division av RMSE med områdets medelvattenföring och beräknas för att möjliggöra jämförelser mellan olika områden
Perfekt prognos	Vattenföringsprognos utförd på observerad nederbörd och temperatur
Områdesvariabel	I denna studie avrinningsområdesegenskaperna area, sjöprocent, skogsprocent och höjd över havet
Operationella prognoser	Prognoser som automatiskt och kontinuerligt utförs av SMHI
PTHBV	Nationell klimatologisk databas med interpolerade nederbörds- och temperaturdata
Realtids-PTHBV	Version av PTHBV endast baserad på stationer som rapporterar i realtid
Spridning-utfall-analys	Analys av sambandet mellan ensemblespridning och prognosfel

1 INLEDNING

I takt med att tekniken och kunskapen utvecklas blir vi bättre på att göra meteorologiska och hydrologiska prognoser (Laloyaux & Bengtsson, 2015; Arheimer et al., 2011). Kraftfullare datorer gör det möjligt att öka data- och modellupplösning och därigenom uppnå större prognossäkerhet. Den hydrologiska prognos- och varningstjänsten på Sveriges meteorologiska och hydrologiska institut (SMHI) använder sig av HYPE-modellen (HYdrological Predictions for the Environment) och HBV-modellen (Hydrologiska Byråns Vattenbalansavdelnings modell) för att skapa vattenföringsprognoser. Denna information används för att bedöma risken för höga flöden i Sverige. Utförda varningar och risker används sedan av en mängd andra aktörer och beslutsfattare för att på ett effektivt sätt fördela samhällets resurser dit de gör mest nytta. Varningar utfärdas 0-48 timmar innan och riskinformation utfärdas 0-96 timmar innan en förväntad händelse (SMHI, 2015) (Asp, 2016).

Atmosfärens kaotiska natur gör det dock svårt att förutsäga hur vädret kommer att bli; en liten ändring i atmosfärstillståndet kan innebära stor skillnad i väderutveckling (Lorenz, 1969). Därför använder sig SMHI sedan 2004 av meteorologiska ensembleprognoser skapade av ECMWF (European Centre for Medium-range Weather Forecasts) som indata i hydrologiska modeller (Olsson & Lindström, 2008). De meteorologiska prognoserna skapas genom små ändringar i starttillståndet hos en atmosfärsmodell (Persson, 2015). På grund av atmosfärens icke-linearitet så används denna teknik endast för korttidsprognoser på maximalt 10 dygn (Olsson et al., 2006). ECMWF skapar totalt 50 möjliga temperatur- och nederbördsserier som alla antas ha lika stor chans att inträffa (Persson, 2015). De individuella serierna kallas ensemblemedlemmar och utgör tillsammans ensembleprognosen. En fördel med meteorologiska ensembleprognoser är att storleken på prognosernas spridning korrelerar med prognossäkerheten (Olsson & Lindström, 2008). En stor spridning indikerar hög prognossäkerhet, medan en liten spridning indikerar att prognosen är relativt säker (Persson, 2015) (Figur 1).



Figur 1. Exempel på en hydrologisk ensembleprognos med 50 ensemblemedlemmar. Den röda streckade linjen är observerad vattenföring, och de ljusgrå och mörkgrå områdena representerar ensamblespridning. Spridningen är störst vid högflödet den 8:e och 9:e augusti vilket indikerar att prognossäkerheten är större där. Figurkälla: Olsson et al. (2006).

De meteorologiska ensambleprognoserna används som indata till HYPE-modellen för att generera en ensemble av möjlig framtida vattenföring. Prognosstart definieras i detta fall som tidpunkten då simuleringen inte har tillgång till observerad nederbörds- och temperaturdata, utan endast drivs med en meteorologisk ensembleprognos. Inför prognoser skapas ett starttillstånd i HYPE-modellen med hjälp av historiska nederbörds- och temperaturdata från 1960-talet och framåt. Starttillståndet innehåller information om modellens tillståndsvariabler, exempelvis markvattenhalt och snötäcke. Simuleringen som sker innan prognosstart kallas framkörning, och anledningen till dess längd är att starttillståndet behöver tid att genereras för att bli så representativt som möjligt. Vid operationella prognoser - prognoser som automatiskt och kontinuerligt utförs av SMHI - används av resursskäl tidigare sparade framkörningar. Endast den sista delen av framkörningen behöver därmed utföras inför prognosen.

I nuläget används endast ett och samma hydrologiska starttillstånd för samtliga ensembledlemmar, och hur detta inverkar på prognoskvaliteten är inte känt. Felaktigheter i nederbörds- och temperaturdata, i modellen och i parameteruppsättningen under framkörningsprocessen kan resultera i ett icke-representativt starttillstånd vid prognosstart, vilket bidrar till en felaktig prognos. Det finns därför ett intresse att identifiera och kvantifiera starttillståndets bidragande osäkerhet i hydrologiska prognoser.

1.1 SYFTE OCH MÅL

Examensarbetets syfte var att undersöka hur hydrologiska prognoser påverkas av olika starttillstånd, för att ge en ökad kunskap och förståelse i ämnet och på sikt möjliggöra säkrare hydrologiska prognoser. Målen var att:

1. ta fram ett förslag på hur starttillståndet kan varieras för att ge den hydrologiska prognosen en god osäkerhetsuppskattning med avseende på starttillstånd med hjälp av hydrologiska simuleringar.
2. undersöka sambandet mellan prognososäkerhet och osäkerhet kopplat till det hydrologiska starttillståndet genom statistiska analyser.
3. undersöka starttillståndets inverkan på avrinningsområden med avseende på olika årstider samt områdenas area, sjöprocent, skogsprocent och höjd över havet med korrelationsanalys.

1.2 FRÅGESTÄLLNINGAR OCH HYPOTESER

För att uppnå målen formulerades följande frågeställningar:

- Hur känslig är den hydrologiska modellen för olika starttillstånd?
- Hur ska starttillståndet varieras för att ge en god osäkerhetsuppskattning?
- Hur varierar prognososäkerheten för olika årstider?
- Inverkar avrinningsområdenas area, sjöprocent, skogsprocent eller höjd över havet på prognososäkerheten?

Följande hypoteser undersöktes:

- Det finns ett samband mellan ensemblespridning och prognosfel.
- Avrinningsområdenas egenskaper korrelerar med prognososäkerheten.
- Ett starttillstånd med vattenföring nära den uppmätta vattenföringen resulterar i en träffsäkrare prognos.

1.3 AVGRÄNSNINGAR

På grund av HYPE-modellens komplexa struktur ändrades parametrar inte direkt i modellen för att generera olika starttillstånd. Istället manipulerades temperatur- och nederbördsdata för att åstadkomma en realistisk ensemble av olika starttillstånd.

2 BAKGRUND

I detta avsnitt presenteras HYPE-modellens historik och en översiktlig beskrivning av dess hydrologiska processer. Därefter beskrivs en autoregressiv modell som används för prognoskorrektion vid vattenföringsstationer. Slutligen beskrivs tidigare studier relevanta för denna studies mål, frågeställningar och hypoteser.


2.1 HYPE-MODELLEN

HYPE-modellen är en dynamisk, konceptuell vattenbalans- och vattenkvalitetsmodell med integrerade kväve- och fosforprocesser som skapades på SMHI 2005-2007 (Lindström et al., 2010). Syftet var att komplettera den äldre HBV-modellen med en modell med högre spatial upplösning som även kunde hantera näringstransporter. S-HYPE (Sverige-HYPE) är namnet på den modelluppsättning som används av SMHI för hydrologiska prognoser i Sverige (Strömqvist et al., 2012).

Modellen är semidistribuerad, vilket i hydrologiska sammanhang innebär att den består av en mängd delområden med olika egenskaper som tillsammans bildar ett landskap.

Delavrinningsområdena består i sin tur av olika klasser som definieras av vilken jordart som dominerar, markanvändning och vilka grödor som odlas. Klasserna behandlas på olika sätt beroende på om de är land- eller sjöklasser. Landklasser kan bestå av upp till tre lager med olika tjocklek och markvattenhalt. Parametrarna i modellen är antingen globala eller kopplade till områdets markanvändning eller jordart.

Drivdata till S-HYPE är nederbörds- och temperaturdata som interpoleras till uppsättningens delområden utefter SMHI:s meteorologiska stationer. Nederbörd som tillförs landklasserna infiltrerar det första lagret och rör sig vidare ner mot grundvattnet. Om inkommande nederbörd och markvattenhalt i det övre jordlagret överstiger vissa tröskelvärden blir delar av nederbörden ytavrinning och makroporflöde (Figur 2). Makroporeerna kan vid intensiv nederbörd leda vattnet direkt till grundvattnet.



Figur 2. Schematisk beskrivning av en modellstruktur i HYPE-modellen för en landklass med tre olika markskikt. Det finns fyra vägar för vatten att ta: ytavrinning, makroporflöde, dränering och utflöde från individuella lager (blå pilar). I figuren beskrivs även näringsretention (gröna, streckade pilar), processer som studien ej tar hänsyn till. Figurkälla: Lindström et al. (2010).

Lufttemperaturen i modellen beror av delavrinningsområdenas höjd över havet. Vid ett tröskelvärde nära noll grader Celsius tolkar modellen nederbörd som snö istället för regn. Snö ackumuleras då på jordlagret tills temperaturen överstiger tröskelvärdet och avsmältning sker. Evapotranspirationen antas vara potentiell (maximal) då jorden överstiger en viss markvattenhalt, som beror av lufttemperatur och vilken säsong modellen simulerar. Det antas exempelvis ske mer evapotranspiration på våren jämfört med hösten vid samma temperatur. Vatten kan endast evapotranspirera från lager 1 och 2, och den potentiella evapotranspirationen avtar med djupet.


Sjöar och vattendrag benämns som interna eller som utloppssjöar och utloppsvattendrag beroende på avrinnings ursprung. Interna baseras på avrinning som endast härstammar från det egna delavrinningsområdet. Externa sjöar och vattendrag får sin avrinning från lokala sjöar och vattendrag men också från avrinningsområden högre upp.

2.2 PROGNOSEKORREKTION

I början av flödesprognoser för områden med hydrologiska mätstationer justeras den modellerade vattenföringen så att den matchar den observerade. Därefter korrigeras den framtida prognoser med hjälp av en autoregressiv modell (AR-modell) (1) (Carlsson & Lindström, 2001). Syftet är att med hjälp av kunskap om tidigare fel reducera prognosfelet (Li et al., 2015). Den modellerade vattenföringen korrigeras med skillnaden mellan modellerad och observerad vattenföring vid tiden $t = 1$ multiplicerat med en parameter.

$$Q_{m,t} = Q_{m,t} - p^t(Q_{m,1} - Q_{o,1}) \quad (1)$$

$Q_{m,t}$ är modellerad vattenföring vid tiden t , $Q_{o,t}$ är observerad vattenföring vid tiden t och p är en korrelationsparameter som bestämmer under hur lång tid AR-prognosen ska ge effekt. Parametern kan ha ett värde mellan 0 och 1, och ju större den är desto större effekt har korrektionen över tid (Figur 3). Prognoser där denna metod tillämpats benämns i fortsättningen som AR-uppdaterade prognoser.



Figur 3. Exempel på en hydrologisk ensembleprognos på nio dygn. De blå linjerna är ensemblemedlemmar och den svarta linjen är den observerade vattenföringen. Den begränsade spridningen i AR-prognosen indikerar att korrektionsparametern har ett värde nära 1.

2.3 TIDIGARE STUDIER

Det finns många olika sätt att klassificera källorna till osäkerhet i hydrologiska prognoser. För konceptuella hydrologiska modeller är det vanligt att osäkerhetskällorna delas in i klasserna indata, starttillstånd, modellstruktur och parametrar (Zappa et al., 2011; Wood & Lettenmaier, 2008). Demirel et al. (2013) undersökte vilken effekt olika osäkerhetskällor hade på 10-dygnsprognoser för låga flöden med två olika hydrologiska modeller, GR4J och HBV. Studien fann att parameterosäkerhet var den största bidragande faktorn och att starttillstånd var den minst bidragande faktorn till prognososäkerhet.

Flera studier visar att det tar lång tid innan starttillståndet slutar inverka på hydrologiska prognoser. I en studie med HBV-modellen på 21 avrinningsområden i Schweiz tog det från 50 dygn upp till ett år innan effekten av ett felaktigt starttillstånd försvann (Staudinger & Seibert, 2014). Resultaten indikerade att starttillståndet hade längst kvarvarande inverkan på de avrinningsområden som var högt belägna, vilket indikerar att snö spelar en stor roll i hur osäkert starttillståndet är. En studie av 29 oreglerade floder i USA fann en större osäkerhet i prognoser utfärdade innan första april, vilket också antogs bero på snö (Pagano et al., 2004).

Dataassimilation är en metod som kombinerar simuleringar med aktuella systemobservationer. Detta för att ta hänsyn till osäkerheter i de båda teknikerna som används för att skapa hydrologiska starttillstånd (DeChant & Moradkhani, 2011). Exempel på data som tidigare assimilerats är satellitobservationer av snödjup och markvattenhalt (Andreadis & Lettenmaier, 2006). Gustafsson et al. (2014) använde ett Ensemble-Kalmanfilter (EnKf) för att med hjälp av fjärranalys assimilera observerat snötäcke i vattenföringsprognoser i HYPE-modellen, vilket förbättrade prognoserna i vissa områden men försämrade dem i andra. Ett Ensemble-Kalmanfilter är en variant av Kalman-filtret: en algoritm som med hjälp av imperfekta mätningar uppskattar ett systemtillstånd. Även sjöytetemperatur- och istäckedata har assimilerats i prognoser utförda med HYPE-modellen (Gustafsson et al., 2012). EnKf har även använts för att assimilera observerad vattenföring vid uppdatering av hydrologiska modellers starttillstånd (Clark et al., 2008; Aubert et al., 2003).

En etablerad metod för att undersöka förhållandet mellan spridning och prognosfel är att göra en spridning-utfall-analys (Spread-skill analysis) (Scherrer et al., 2004). Denna metod förklaras vidare i kapitel 3.4.1. Meteorologiska ensembleprognoser som indata i HBV-modellen har tidigare utvärderats av SMHI med spridning-utfall-analys (Olsson et al., 2006). Studien visade att det fanns ett samband mellan spridning och prognosfel: ju större ensemblespann desto sämre flödesprognos. En metod för att undvika statistiskt brus är att dela in spridningen i olika grupper utefter magnitud (Wang & Bishop, 2003). Därefter beräknas ett medelvärde av prognosfelet för respektive spridningsgrupp.

En studie av avrinningsområden kring Östersjön fann att prognosfelet (RMSE, Root Mean Squared Error) generellt var störst under våren i april och maj, och att det följde samma trend som vattenföring över året (Lyon et al., 2015). En studie vid floden Donau uppvisade små avrinningsområden generellt större prognosfel än stora (Gericke & Smithers, 2014). En fallstudie på 43 avrinningsområden i Tyskland och Österrike visade att prognoser för större avrinningsområden uppvisade lägre prognosfel relaterat till både fel i meteorologiska drivdata och fel relaterat till den hydrologiska modellen (Nester et al., 2012).

Seibert (1999) undersökte hur parametrar i HBV-modellen korrelerade med elva svenska avrinningsområdens area, skogsprocent samt sjöprocent och fann att sjöprocent korrelerade med parametrar relaterade till en mer dämpad och jämn hydrograf. En dämpad och jämn hydrograf innebär att avrinningsområdets vattenföring svarar relativt långsamt på regn och att dess flödestopp är utjämnad. Skogsprocent korrelerade med snöparametrar, vilket antogs bero på att evaporering av snö från skogsmark inte simuleras i modellen trots att den ibland kan vara signifikant.


3 MATERIAL OCH METODER

Detta avsnitt inkluderar områdesbeskrivning, genomgång av data och datakällor som använts i studien, beskrivning av starttillståndsgenerering samt beskrivning av hur utvärderingen av ensembleprognoser utfördes.

3.1 OMRÅDESBESKRIVNING


Indikatorområden kallas de avrinningsområden som valts ut av SMHI i syfte att fungera som indikatorer vid högflöden i HBV-modellen. Områdena finns över hela Sverige och används av SMHI:s prognos- och varningstjänst för att ge en uppfattning om det hydrologiska läget i landet och hur väl modellerad och observerad vattenföring stämmer överens (Granström, 2005). De valdes ut i syfte att representera olika geografiska regioner och områdesareor, men merparten av indikatorområdena består av mindre avrinningsområden som snabbt svarar på förändringar i meteorologiska drivdata (Olsson & Lindström, 2008) (Figur 4). Områdenas relativt höga sjöprocent innebär dock en längre responstid än för motsvarande sjölösa områden.

I denna studie undersöktes de indikatorområden som hade fullständiga temperatur-, nederbörds- och vattenföringsserier under perioden 1999-2008 i S-HYPE, totalt 76 stycken områden (Figur 5) (Appendix A). I flödesprognoser för dessa områden används AR-prognoser, och då tillgänglig data funnits har områdeskalibrerade parametrar använts.



Figur 4. Histogram som visar fördelning av area, sjöprocent, skogsprocent och höjd över havet för de undersökta indikatorområdena.

Storleken på områdena varierar mellan 7 och 16748 km², men majoriteten av områdena är mindre än 5000 km². Sjöprocenten varierar mellan 0 och 13,8 %, och de flesta områden har en skogsprocent på 50 % eller mer. Merparten av områdena är belägna under 300 meter över havet.



Figur 5. Indikatorområden som undersökts i studien. © Lantmäteriet 2014, I2014/00601. Karta skapad av Elinor Andersson, Uppsala universitet. Koordinatsystem: SWEREF99. Projektion: SWEREF99 TM.

3.2 DATA

Indata till HYPE-modellen i denna studie härstammar från SMHI:s modelluppsättning S-HYPE 2012 (SMHI, 2012). Data är hämtad från Vattenwebb (SMHI), den nationella klimatologiska databasen PTHBV (SMHI), Svenskt vattenarkiv (SVAR, SMHI), Geografiska Sverigedata (GSD, Lantmäteriet), Sveriges geologiska undersöknings (SGUs) jordartsdatabas, Corine Land Cover 2000 (Lantmäteriet), SJV Blockdatabas (Jordbruksverket) och SMHI:s prognos- och varningstjänst (Tabell 1).

Tabell 1. Indata till HYPE-modellen som användes i studien, med källhänvisning och tidsperiod

Data	Källa	Tidsperiod
Vattenföring	Vattenwebb (SMHI)	1961-2008
Nederbörd	PTHBV (SMHI)	1961-2008
Temperatur	PTHBV (SMHI)	1961-2008
Höjd över havet	GSD (Lantmäteriet)	2012
Lutning	GSD (Lantmäteriet)	2012
Jordarter	SGUs jordartsdatabas	2012
Markanvändning	Corine Land Cover 2000 (Lantmäteriet)	2012
Jordbruksmarksareal	SJV Blockdatabas (Jordbruksverket)	2012
Områdesareal och sjöinformation	SVAR (SMHI)	2012
Områdesspecifika AR-parametrar	SMHI:s prognos- och varningstjänst	2015

Vid operationella prognoser används den nationella klimatologiska databasen PTHBV, ett dataarkiv med griddade dygnsmedelvärden från SMHI:s meteorologiska stationer (Olsson et al., 2006). Nederbörds- och temperaturdata från mätstationer interpoleras till ett rutnät med upplösning 4x4 km (Johansson & Chen, 2003). En konsekvens av interpoleringen är att de högsta nederbördstopparna jämnas ut och fördelas över tid och rum. Delavrinningsområdena tilldelas interpolerade väderdata som motsvarar ytmedelvärdet.


På grund av att endast vissa stationer rapporterar in data i realtid är de sista 35 dyggen i framkörningen baserat på ett sämre dataunderlag än tidigare historiska data. Data från Realtids-PTHBV, som är baserad på data från stationer som kontinuerligt rapporterar in, används därför under de 35 sista dyggen i framkörningen vid operationella prognoser. Dessa data har till skillnad från vanliga PTHBV inte korrigerats för mätförluster. I denna studie användes dock endast PTHBV.

3.3 ENSEMBLEGENERERING

Eftersom intresset låg i starttillståndets påverkan på hydrologiska prognoser användes inte meteorologiska ensembleprognoser från ECMWF i denna studie. Istället skapades en ensemble av olika starttillstånd genom störningar av drivdata med hjälp av MATLAB (Appendix B).

För att skapa olika starttillstånd i HYPE gjordes störningar i historiska drivdata under 35 dygn inför prognosstart. Prognosstart i denna studie definierades som tidpunkten då drivdatastörningarna slutade och simuleringen inte hade någon observerad vattenföring att rätta prognosen med. Det representeras av en streckad svart linje i figurer (Figur 7). Därefter gjordes tio dygn långa prognoser som utvärderades efter 2, 4 och 10 dygn. Framkörningen definierades som hela perioden från 1960-talet fram till prognosstart, och inkluderar perioden då drivdata störs för att generera starttillståndsensemblen. Ensemblemedlemmarnas starttillstånd definieras som tillståndsvariablernas värden vid prognosstart. Tidsintervallet 35 dygn valdes för att motsvara de dygn då framkörningen i prognosen är baserat på Realtids-PTHBV i operationella prognoser. Som tidigare nämnts användes dock den kompletta PTHBV-databasen med samtliga stationer i denna studie. HYPE version 4.10.6 med modelluppsättning S-HYPE 2012 version 3.0.0 användes i simuleringarna.

Temperaturstörningar gjordes genom att addera eller subtrahera 2 °C i drivdata 35 dygn innan prognosstart. Störningar i nederbörd åstadkoms genom att multiplicera datan med en faktor 0,5, 0,75, 1,25 eller 1,5. Dessa störningar kombinerade med ostörda temperatur- och nederbördsdata användes sedan för att skapa 15 ensemblemedlemmar (Figur 6; Tabell 2). Innan dessa störningar valdes experimenterades det med slumpgenererade temperatur- och nederbördsstörningar. Detta skulle dock krävt betydligt fler ensemblemedlemmar för att möjliggöra jämförelser mellan prognoser, och metoden valdes därför bort.



Figur 6. Drivdata i form av temperatur (T) och nederbörd (P) manipulerades och en mängd drivdataserier skapades. Dessa serier användes sedan som indata till HYPE-modellen för att skapa hydrologiska prognoser med och utan AR-uppdatering.


Tabell 2. Störningar i HYPE-modellens starttillstånd genereras genom manipulering av temperatur- och nederbördsdata 35 dygn innan prognosstart. Nederbördsdata multipliceras med 0,5, 0,75, 1, 1,25 eller 1,5 och kombineras sedan med temperaturdata, ostörd eller störd med ± 2 °C

	P•0,5	P•0,75	P	P•1,25	P•1,5
T – 2	1 (T ₁ ,P ₁)	4 (T ₄ ,P ₄)	7 (T ₇ ,P ₇)	10 (T ₁₀ ,P ₁₀)	13 (T ₁₃ ,P ₁₃)
T ± 0	2 (T ₂ , P ₂)	5 (T ₅ ,P ₅)	8 (T ₈ ,P ₈)	11 (T ₁₁ ,P ₁₁)	14 (T ₁₄ ,P ₁₄)
T + 2	3 (T ₃ ,P ₃)	6 (T ₆ ,P ₆)	9 (T ₉ ,P ₉)	12 (T ₁₂ ,P ₁₂)	15 (T ₁₅ ,P ₁₅)

Syftet med störningarna var inte enbart att de skulle representera mät- och interpolationsfel; de skulle även ta hänsyn till fel i modellstruktur och parametrar. Störningar i nederbörd skapades genom multiplikation istället för addition och subtraktion för att undvika negativ nederbörd. De prognoser som haft en regnig framkörningsperiod får därigenom större störningar i starttillstånden jämfört med de som skapats under torra episoder.

Starttillstånd 1 skapades således genom subtraktion av 2 °C per dygn från historiska temperaturdata i 35 dygn och genom multiplikation av historiska nederbördsdata med en faktor 0,5 i 35 dygn. Antal ensemblemedlemmar begränsades till 15 på grund av studiens tidsram då simuleringstiden ökade med antal ensemblemedlemmar. Prognoser utförda med ostört starttillstånd är de operationella standardprognoserna.

Studien utfördes på prognoser gjorda under 1999-2008 eftersom HYPE-modellen kalibrerats utefter de åren (Arheimer & Lindström, 2015). 10-dygnsprognoser utfördes varje dygn, vilket resulterade i 3653 ensembleprognoser och 54 795 ensemblemedlemmar per område. Totalt skapades 277 628 ensembleprognoser med tillhörande 4 164 420 ensemblemedlemmar för samtliga 76 indikatorområden. 10-dygnsprognoserna gjordes både med och utan AR-uppdatering och utvärderades två, fyra och tio dygn efter prognosstart (hädanefter benämnda 2-, 4- och 10-dygnsprognoser) (Figur 7).



Figur 7. Illustrering av skapandet av de olika starttillstånden. Denna prognos är gjord vid mätstationen Kringlan (34) i september 2006. De röda punkterna representerar den ostörda prognosen, den heldragna svarta linjen (Q_{obs}) representerar den observerade vattenföringen, de blå streckade linjerna representerar ensembleprognoserna och den lodräta streckade linjen utmärker prognosstarten den 9:e. Notera skillnaden i spridningsstorlek med och utan AR-uppdatering.

3.4 UTVÄRDERING AV ENSEMBLEPROGNOSER

Samtliga utvärderingar gjordes för 2-, 4- och 10-dygnsprognoser med och utan AR-korrigerig. De mått på prognosfel som använts i denna studie är etablerade och valdes för att möjliggöra jämförelser med tidigare studier.

3.4.1 Spridning-utfall-analys

Spridning-utfall-analys tillämpades för att utvärdera om det fanns något samband mellan spridning och prognosfel.

Starttillståndens spridning definierades som skillnaden mellan ensemblemedlemmarnas högsta och lägsta vattenföring. Relativ spridning beräknades genom division av spridning med respektive områdes observerade medelvattenföring år 1999-2008 för att möjliggöra jämförelser mellan områden (2).

$$S_{rel} = \frac{(Q_{max,t} - Q_{min,t})}{\overline{Q_o}} \quad (2)$$

S_{rel} är relativ spridning, $Q_{max,t}$ är den högsta vattenföringen i ensemblen vid tiden t , $Q_{min,t}$ är den lägsta vattenföringen i ensemblen vid tiden t och $\overline{Q_o}$ är observerad medelvattenföring för området.

Utfallet, prognosfelet, representerades med hjälp av Mean Absolute Error (MAE), absolutbeloppet av skillnaden mellan modellerat och observerat flöde (3). För att kunna jämföra områdena beräknades även relativ MAE, RMAE, som är absolutbeloppet av skillnaden mellan modellerat och observerat flöde delat på områdets medelvattenföring år 1999-2008 (4).

$$\epsilon_{MAE} = \frac{1}{n} \sum_{t=1}^n |Q_{o,t} - Q_{m,t}| \quad (3)$$


$$\epsilon_{RMAE} = \frac{\frac{1}{n} \sum_{t=1}^n |Q_{o,t} - Q_{m,t}|}{\overline{Q_o}} \quad (4)$$

ϵ_{MAE} är Mean Absolute Error, ϵ_{RMAE} är Relative Mean Absolute Error, $Q_{m,t}$ är modellerad vattenföring vid tiden t , $Q_{o,t}$ är observerad vattenföring vid tiden t , $\overline{Q_o}$ är områdets medelvattenföring och n är antal tidssteg som utvärderas.

Simuleringsresultaten delades in i grupperna mycket liten, liten, medel, stor och mycket stor relativ spridning. Därefter beräknades medelprognosfelet för varje grupp. Sambandets lutning beräknades för varje område genom att subtrahera stor relativ spridning med liten (5) (Figur 8).

$$L = \varepsilon_{\text{medel-RMAE, stor spridning}} - \varepsilon_{\text{medel-RMAE, liten spridning}} \quad (5)$$

L är lutning, $\varepsilon_{\text{medel-RMAE, stor spridning}}$ är medel-RMAE för gruppen med näst störst relativ spridning $\varepsilon_{\text{medel-RMAE, liten spridning}}$ är medel-RMAE för gruppen med näst minst relativ spridning. En positiv lutning indikerar att större spridning innebär större prognosfel.




Figur 8. Lutning definieras som skillnaden i medel-RMAE för grupperna stor och liten relativ spridning.

Spearman's rangkorrelation, vilket beskrivs närmare i kapitel 0, beräknades för att ytterligare undersöka sambandet mellan spridning och prognosfel och dess statistiska signifikans. Relativt prognosfel (RMAE) och relativ spridning användes i korrelationsberäkningen utan medelvärdesbildning och indelning i spridningsgrupper. Relationen mellan lutning och områdesvariabler undersöktes även för att undersöka vilken typ av avrinningsområde sambandet var starkast för.

3.4.2 Spearmans rangkorrelation

Spearmans rangkorrelation är ett icke-parametrisk mått på det monotona sambandet mellan två rangordnade observationsserier (Artusi et al., 2008). En monoton funktion är antingen strängt växande eller strängt avtagande: en ökning av variabel a följs antingen alltid av en ökning av variabel b (strängt växande) eller alltid en minskning av variabel b (strängt avtagande).

Spearmans korrelationskoefficient (r_s) anger hur nära den undersökta serien är en monoton funktion. Om $r_s = \pm 1$ innebär det att sambandet är strikt monotont, och $r_s = 0$ innebär att sambandet inte är monotont alls (Figur 9). För att bevisa att korrelationen är signifikant behöver null-hypotesen motbevisas. Null-hypotesen är att det inte finns någon korrelation mellan de undersökta variablerna, att $r_s = 0$. Hypotesen testas genom beräkning av sambandets p-värde, som är ett mått på hur stor sannolikheten är att den beräknade korrelationskoefficienten r_s är en slump. Ett p-värde på 0,05 innebär ett konfidensintervall på 95 %.



Figur 9. Från vänster till höger: strängt växande monoton funktion ($r_s = 1$), strängt avtagande monoton funktion ($r_s = -1$) och icke-monoton funktion ($-1 < r_s < 1$).

För att undersöka om det fanns något samband mellan relativ spridning och indikatorområdenas area, sjöprocent, skogsprocent och höjd över havet beräknades Spearmans rangkorrelation. Testet valdes eftersom det går att tillämpa på icke-normalfördelade data (Conover & Iman, 1981). Även prognosfelsmåttet RRMSE, som förklaras i kapitel 3.4.4, inkluderades i analysen för att undersöka om det fanns någon korrelation med avrinningsområdenas egenskaper. Eftersom data ej var normalfördelat användes median istället för medelvärde för relativ spridning och RRMSE. Spearmans rangkorrelation beräknades även mellan avrinningsområdenas medellutning och area, sjöprocent, skogsprocent och höjd över havet för att undersöka om det fanns några signifikanta samband. För att testa om korrelationen var signifikant undersöktes om p-värdet var mindre än 0,05.

3.4.3 Årstidsvariation

Sambandet mellan spridning och årstid undersöktes med hjälp av relativ spridning (2) och en annan variant av den relativa spridningen med medelvattenföring per månad istället för medelvattenföring över året (6). Månader undersöktes eftersom de meteorologiska årstiderna inträffar olika tider olika år och beror på var i Sverige avrinningsområdet ligger.


$$S_{rel,månad} = \frac{(Q_{max,t} - Q_{min,t})}{Q_{o,månad}} \quad (6)$$

$S_{rel,månad}$ är relativ spridning per månad, $Q_{max,t}$ är den högsta vattenföringen i ensemblen vid tiden t , $Q_{min,t}$ är den lägsta vattenföringen i ensemblen vid tiden t och $Q_{o,månad}$ är observerad medelvattenföring för området och den undersökta månaden.

Spridning för alla indikatorområden och månader beräknades för samtliga 2-, 4- och 10-dygnsprognoser. Normalisering av spridningen utfördes med två olika observerade medelvattenföringar: medelvärdet av vattenföringen 1999-2008 och medelvärdet av vattenföringen 1999-2008 uppdelat i månader. Spridningen i augusti 1999 för område 1 normaliserades således med medelvattenföringen för område 1 augusti 1999-2008.

3.4.4 Dataassimilation av observerad vattenföring

Dataassimilation är en teknik som kombinerar simuleringar och systemobservationer i prognosförbättringssyfte. För att testa hypotesen att ett starttillstånd med vattenföring nära den uppmätta vattenföringen resulterar i en mer korrekt prognos delades ensemblemedlemmarna upp i olika grupper beroende på hur nära Q_{obs} de var vid prognosstart. I detta fall var ensemblemedlemmens vattenförings relativa närhet till observerad vattenföring systemobservationen. Den ensemblemedlem som låg närmast Q_{obs} vid prognosstart hamnade i *grupp A*, den som låg näst närmast hamnade i *grupp B* och så vidare fram till *grupp O* där ensemblemedlemmen längst bort från Q_{obs} hamnade (Figur 10). Denna enkla metod utformades för den här studien, men liknar andra dataassimieringsmetoder (Moradkhani et al., 2005).



Figur 10. Denna prognos är gjord vid mätstationen Karlslund (40) i september 2006. De tio ensemblemedlemmarna närmast den observerade vattenföringen visas. De röda punkterna representerar den ostörda prognosen, den heldragna svarta linjen (Q_{obs}) representerar den observerade vattenföringen, de blå streckade linjerna representerar ensembleprognoserna och den lodräta streckade linjen utmärker prognosstart. Ensemblemedlem A är närmast den observerade vattenföringen vid starttillståndet, ensemblemedlem B är näst närmast och så vidare ända till ensemblemedlem O som är längst bort från den.

Prognosfel för varje grupp (A till O), område (1- 76) och prognoslängd (2-, 4- och 10-dygnsprognoser) beräknades och jämfördes med ostörda prognoser som kontroll. RMSE (Root Mean Squared Error) användes som mått på prognosfelet (7).

$$\varepsilon_{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Q_{o,t} - Q_{m,t})^2} \quad (7)$$


ε_{RMSE} är Root Mean Squared Error, $Q_{m,t}$ är modellerad vattenföring vid tiden t, $Q_{o,t}$ är observerad vattenföring vid tiden t och n är antal tidssteg som utvärderas.

För att kunna jämföra områdenas prognosfel med varandra beräknades Relative Root Mean Squared Error (RRMSE), RMSE delat på områdets observerade medelvattenföring år 1999-2008 (8).

$$\varepsilon_{RRMSE} = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (Q_{o,t} - Q_{m,t})^2}}{\overline{Q_o}} \quad (8)$$

ε_{RRMSE} är Relative Root Mean Squared Error, $Q_{m,t}$ är modellerad vattenföring vid tiden t , $Q_{o,t}$ är observerad vattenföring vid tiden t , $\overline{Q_o}$ är områdets medelvattenföring och n är antal utvärderade tidssteg.

Med hjälp av grupp A till O beräknades även medelvärden av de undersökta grupperna (Figur 11). Medelvärdesbildningen utfördes för att undersöka om prognoserna skulle prestera bättre jämfört med prognoser utförda på grupp A-O, och metoden utformades för den här studien. *Grupp m1* är ekvivalent med grupp A, *grupp m2* är summan av vattenföringsprognoserna för grupp A och B delat på två, och *grupp m3* är summan av vattenföringsprognoserna för grupp A, B och C delat på tre. Samma mönster gäller fram till *grupp m15* som är medelvärdet av alla ensemblemedlemmars vattenföringsprognoser.



Figur 11. Här visas hur vattenföringsprognoserna för grupp A, B och C medelvärdesbildas vid en prognos utförd vid mätstationen Karlslund (40) i september 2006. De röda punkterna representerar prognos utförd på ostört starttillstånd, den heldragna svarta linjen (Q_{obs}) representerar den observerade vattenföringen, de blå streckade linjerna representerar ensemblemedlem A, B samt C, de blå punkterna representerar de medelvärdesbildade prognoserna m1, m2 och m3 och den lodräta streckade linjen utmärker prognosstart.

Den ensemblemedlem som presterade bäst från respektive grupp A-O och m1-m15 jämfördes slutligen med den ostörda prognosen. Effekten av dataassimilationen i procent beräknades även per område (9). Därefter beräknades Spearmans korrelationskoefficient r_s i syfte att undersöka sambandet mellan effekten av dataassimilationen per område och avrinningsområdenas area, sjöprocent, skogsprocent och höjd över havet.


$$E = \frac{\epsilon_{median-RRMSE,ostörd} - \epsilon_{median-RRMSE,dataassimilation}}{\epsilon_{median-RRMSE,ostörd}} \quad (9)$$

E är effekt, $\epsilon_{median-RRMSE,ostörd}$ är median-RRMSE för ostörda prognoser och $\epsilon_{median-RRMSE,dataassimilation}$ är median-RRMSE för prognoser gjorda med den dataassimilationsgrupp som utvärderas. En positiv effekt innebär att median-RRMSE för dataassimilerade prognoser är lägre än prognoser utförda på ostörda starttillstånd.


4 RESULTAT

I detta avsnitt beskrivs resultatet av de simuleringar och utvärderingar som beskrivits i föregående avsnitt.

Den ensemblemedlem var vattenföring oftast var närmast den observerade vattenföringen vid prognosstart var nummer 3, som skapats med hjälp av minskad nederbörd ($P-0,5$) och ökad temperatur ($T+2\text{ °C}$) (Figur 12). Näst mest frekvent var nummer 8, som skapats med ostörda drivdata ($P-0,5$; $T\pm 0\text{ °C}$). Under prognosdygn 1 var den observerade vattenföringen inkluderad under nästan 77 % av fallen, men andelen sjönk kontinuerligt fram till prognosdygn 10 då drygt 70 % av den observerade vattenföringen inkluderades i ensemblen (Figur 13). Att den observerade vattenföringen inkluderades innebar att den låg mellan högsta och lägsta vattenföring i ensemblen.




Figur 12. Histogram över hur ofta respektive ensemblemedlem haft starttillståndet närmast den observerade vattenföringen.



Figur 13. Andel observerad vattenföring som inkluderats i ensemblen vid olika prognosdygn.

4.1 SPRIDNING-UTFALL-ANALYS

Spridning-utfall-analysen visade att prognosfelet ökade med starttillståndens spridning för 2-, 4- och 10-dygnsprognoser (Figur 14). Korrelationskoefficienten r_s var störst för 4-dygnsprognoser och alla undersökta prognoser uppvisade en signifikant korrelation mellan spridning och prognosfel (Tabell 3). Områdenas medel-RRMSE varierade mycket för stora spridningar men inte för små.




Figur 14. Spridning-utfall-analys för prognoser på 2 dygn (a), 4 dygn (b) och 10 dygn (c). Spridningen är indelad i fem grupper beroende på magnitud, och ett medel-RRMSE har beräknats för varje område och grupp. Spridningsintervallet per grupp visar hur medel-RRMSE varierar för områdena.

Tabell 3. Korrelationskoefficienten r_s och p-värdet för 2-, 4- och 10-dygnsprognoser

Prognoslängd [dygn]	Korrelationskoefficient r_s	p-värde
2	0,56	<0,0001
4	0,57	<0,0001
10	0,54	<0,0001

4.2 SPEARMANS RANGKORRELATION


Korrelationstestet visade fem signifikanta samband mellan områdesvariabler och spridning, tolv signifikanta korrelationer mellan områdesvariabler och prognosfel (RRMSE) samt tre signifikanta korrelationer mellan spridning och prognosfel (Figur 15) (Appendix C).



Figur 15. Spearman-korrelation mellan de 10 undersökta variablerna. S står för spridning och numret efter S och RRMSE är prognoslängd i dygn. Numret visar korrelationskoefficienten för de undersökta variablerna. Blå kvadrater indikerar positiv korrelation och röda, streckade kvadrater indikerar negativ korrelation. Styrkan på korrelationen beror på nyans enligt skala. Saknad färg innebär att korrelationen är icke-signifikant ($p > 0,05$).

De starkaste korrelationerna var de interna mellan spridning för olika prognosdygn samt RRMSE för olika prognosdygn. De starkaste positiva korrelationerna mellan områdesvariabler och prognososäkerhet var mellan spridning och skogsprocent, och de starkaste negativa korrelationerna var de mellan area och RRMSE. De signifikanta korrelationerna mellan spridning och områdesvariabler samt prognosfel och områdesvariabler uppvisade samma trend i fråga om signifikanta positiva och negativa korrelationer.

Områdenas lutning från spridning-utfall-analysen korrelerade negativt med area, sjöprocent och höjd över havet för samtliga prognoslängder (Figur 16). Endast skogsprocent saknade signifikant korrelation av områdesvariablerna. Lutningen för 2-, 4- och 10-dygnsprognoser hade en stark intern korrelation.




Figur 16. Spearman-korrelation mellan områdenas lutning (från spridning-utfall-analysen) och avrinningsområdenas area, sjöprocent, skogsprocent och höjd över havet. L står för spridningens lutning och numret efter är prognoslängd i dygn. Numret visar korrelationskoefficienten för de undersökta variablerna. Blå kvadrater indikerar positiv korrelation och röda, streckade kvadrater indikerar negativ korrelation. Styrkan på korrelationen beror på nyans enligt skala. Saknad färg innebär att korrelationen är icke-signifikant ($p > 0,05$).

4.3 ÅRSTIDSVARIATION


I det här och nästföljande delkapitel redovisas resultaten med lådagram som tolkas enligt följande beskrivning: Lådorna utgörs av avståndet mellan första och tredje kvartil, den 25:e och 75:e percentilen, och utgör 50 % av prognoserna. Den svarta, horisontella linjen är den andra kvartilen (50:e percentilen), medianen. Den streckade linjen representerar de prognoser som ligger utanför lådan men som inte är uteliggare. Uteliggare som är markerade med svarta punkter definieras som de värden som ligger utanför 1,5 gånger den övre eller undre kvartilen. Av visualiseringsskäl har de största och minsta 5 % av prognoserna avlägsnats från samtliga lådagram. Alla statistiska beräkningar är dock baserade på det fullständiga datasetet.

När medelvärdet av den observerade vattenföringen användes för att beräkna den relativa spridningen var spridningsmedianen störst i april för samtliga prognoslängder (Figur 17). Näst störst var spridningsmedianen i december för 2- och 4-dygnsprognoser och i november för 10-dygnsprognoser. Tredje största spridningsmedian var i januari för samtliga prognoslängder.



Figur 17. Spridning (utan AR-uppdatering) för de 76 undersökta områdena fördelat över månader. Den relativa spridningen beräknades genom division med respektive områdes observerade medelvattenföring år 1999-2008. Ljusblå lådagram är utvärderade för 2-dygnsprognoser, mellanblå lådagram är utvärderade för 4-dygnsprognoser och mörkblå lådagram är utvärderade för 10-dygnsprognoser.

När spridningen normaliserats med observerad vattenföring per månad var spridningsmedianen störst i augusti för 2-, 4- och 10-dygnsprognoser (Figur 18). Näst störst var spridningsmedianen i april för 2- och 4-dygnsprognoser och i september 10-dygnsprognoser. Tredje största var i juli för 2- och 4-dygnsprognoser och i mars för 10-dygnsprognoser.




Figur 18. Spridning (utan AR-uppdatering) för de 76 undersökta områdena fördelat över månader. Den relativa spridningen beräknades genom division med respektive områdes observerade månadsmedelvattenföring år 1999-2008. Ljusblå lådagram är utvärderade för 2-dygnsprognoser, mellanblå lådagram är utvärderade för 4-dygnsprognoser och mörkblå lådagram är utvärderade för 10-dygnsprognoser.

4.4 DATAASSIMILATION AV OBSERVERAD VATTENFÖRING


Alla 76 områden användes vid utvärderingen av prognoser utan AR-uppdatering. På grund av simuleringsfel tillämpades AR-uppdatering endast på prognoser i 60 områden.

Resultatet av dataassimilationen visade en tydlig trend med större prognosfel ju större differensen mellan starttillståndets och den observerade vattenföringen var. Utan AR-prognos fanns en tydlig skillnad mellan prognoser baserade på det ostörda starttillståndet och prognoser baserade på grupp A (Figur 19).




Figur 19. Förhållandet mellan RRMSE och ensemblemedlemmar utvalda efter hur nära Q_{obs} de var vid prognosstart (utan AR-uppdatering). Grupp A innehåller de ensemblemedlemmar som legat närmast, grupp B de som legat näst närmast och grupp O de som legat längst ifrån Q_{obs} . Det ostörda starttillståndet (os) användes som kontroll. Ljusblå lådagram är utvärderade för 2-dygnsprognoser, mellanblå lådagram är utvärderade för 4-dygnsprognoser och mörkblå lådagram är utvärderade för 10-dygnsprognoser.

Med AR-prognos var skillnaden inte lika tydlig, men prognoser utförda med grupp A presterade bättre än ostörda prognoser till medianen sett (Figur 20). Grupp A hade lägst median för samtliga prognoslängder med och utan AR-uppdatering.




Figur 20. Förhållandet mellan RRMSE och ensemblemedlemmar utvalda efter hur nära Q_{obs} de var vid prognosstart (AR-uppdatering). Grupp A innehåller de ensemblemedlemmar som legat närmast, grupp B de som legat näst närmast och grupp O som legat längst ifrån Q_{obs} . Det ostörda starttillståndet (os) användes som kontroll. Ljusblå lådagram är utvärderade för 2-dygnsprognoser, mellanblå lådagram är utvärderade för 4-dygnsprognoser och mörkblå lådagram är utvärderade för 10-dygnsprognoser.

Utan AR-uppdatering uppvisade de medelvärdesbildade prognoserna inte ett lägre prognosfel än grupp A (m1) för 2- och 4-dygnsprognoser (Figur 21). Medelflödet av grupp A och B (m2) presterade dock bättre än grupp A (m1) för 10-dygnsprognoser.




Figur 21. Förhållandet mellan RRMSE och medelvärden av ensemblemedlemmar utvalda efter hur nära Q_{obs} de var vid prognosstart (utan AR-uppdatering). Grupp m1 är ekvivalent med grupp A och innehåller de ensemblemedlemmar som legat närmast Q_{obs} , grupp m2 är medelvärdet av grupp A och B och grupp m15 är medelvärdet av grupp A-O. Det ostörda starttillståndet (os) användes som kontroll. Ljusblå lådagram är utvärderade för 2-dygnsprognoser, mellanblå lådagram är utvärderade för 4-dygnsprognoser och mörkblå lådagram är utvärderade för 10-dygnsprognoser.

För AR-uppdaterade prognoser resulterade medelvärdesbildade prognoser i lägre prognosfel för samtliga prognoslängder till medianen sett (Figur 22). Vilken grupp som hade lägst median skilde sig mellan prognosgrupperna: 2-dygnsprognoser fick lägst median med grupp m8, 4-dygnsprognoser fick lägst median med grupp m9 och 10-dygnsprognoser fick lägst median med grupp m12.



Figur 22. Förhållandet mellan RRMSE och medelvärden av ensemblemedlemmar utvalda efter hur nära Q_{obs} de var vid prognosstart (AR-uppdatering). Grupp m1 är ekvivalent med grupp A och innehåller de ensemblemedlemmar som legat närmast Q_{obs} , grupp m2 är medelvärdet av grupp A och B och grupp m15 är medelvärdet av grupp A-O. Det ostörda starttillståndet (os) användes som kontroll. Ljusblå lådagram är utvärderade för 2-dygnsprognoser, mellanblå lådagram är utvärderade för 4-dygnsprognoser och mörkblå lådagram är utvärderade för 10-dygnsprognoser.

Utan AR-uppdatering hade medelvärdesbildade prognoser lägst median följt av prognoser gjorda på grupp A för samtliga prognoslängder (Figur 23). Standardavvikelsen var lägre hos grupp A och medelvärdesbildade prognoser vid 2-dygnsprognoser och högre vid 4- och 10-dygnsprognoser (Tabell 4).




Figur 23. Jämförelse mellan median-RRMSE för ostört starttillstånd (os), prognoser från grupp A och medelvärdesbildade prognoser (AR-uppdatering). Ljusblå lådagram är utvärderade för os, mellanblå lådagram är utvärderade för grupp A och mörkblå lådagram är utvärderade för respektive medelvärdesbildad prognos. 2- och 4-dygnsprognoserna baserades på grupp m1 (ekvivalent med grupp A) och 10-dygnsprognoserna baserades på grupp m2.

Tabell 4. Median och standardavvikelse för prognosfelet (RRMSE) för 2-, 4- och 10-dygnsprognoser (utan AR-uppdatering). 2- och 4-dygnsprognoserna baserades på grupp m1 (ekvivalent med grupp A) och 10-dygnsprognoserna baserades på grupp m2

		Ostört starttillstånd	Grupp A	Medelvärdesbildad
2-dygnsprognoser				
RRMSE [%]	Median	13,6	5,55	5,55
	Standardavvikelse	37,2	32,8	32,8
4-dygnsprognoser				
RRMSE [%]	Median	14,5	7,38	7,38
	Standardavvikelse	36,8	36,9	36,9
10-dygnsprognoser				
RRMSE [%]	Median	16,5	11,1	11,1
	Standardavvikelse	35,6	40,7	38,0

För AR-prognoser hade medelvärdesbildade prognoser lägst median följt av prognoser gjorda på grupp A för samtliga prognoslängder (Figur 24). Den ostörda prognosen hade dock lägst standardavvikelse följt av medelvärdesbildade prognoser för samtliga prognoslängder (Tabell 5).




Figur 24. Jämförelse mellan median-RRMSE för ostört starttillstånd (os), prognoser från grupp A och medelvärdesbildade prognoser (AR-uppdatering). Ljusblå lådagram är utvärderade för os, mellanblå lådagram är utvärderade för grupp A och mörkblå lådagram är utvärderade för respektive medelvärdesbildad prognos. 2-dygnsprognoserna baserades på grupp m8, 4-dygnsprognoserna baserades på grupp m9 och 10-dygnsprognoserna baserades på grupp m11.

Tabell 5. Median och standardavvikelse för prognosfelet (RRMSE) för 2-, 4- och 10-dygnsprognoser (AR-uppdatering). 2-dygnsprognoserna baserades på grupp m8, 4-dygnsprognoserna baserades på grupp m9 och 10-dygnsprognoserna baserades på grupp m11


		Ostört starttillstånd	Grupp A	Medelvärdesbildad
2-dygnsprognoser				
RRMSE [%]	Median	4,22	3,98	3,87
	Standardavvikelse	26,0	31,8	27,7
4-dygnsprognoser				
RRMSE [%]	Median	6,57	6,31	6,07
	Standardavvikelse	29,2	37,0	31,3
10-dygnsprognoser				
RRMSE [%]	Median	11,2	11,1	10,6
	Standardavvikelse	31,8	40,6	33,1

En jämförelse av median-RRMSE vid 2-dygnsprognoser visade att en övervägande majoritet av områdena presterat bättre med grupp A jämfört med det ostörda starttillståndet då AR-uppdatering ej använts (Figur 25). Undantagsområdena var Moholm (område 47) och Torsebro Krv (område 73) som presterade sämre.




Figur 25. Dataassimilationens effekt (E) på 2-dygnsprognoser per område (utan AR-uppdatering). Områdenas position och stationsnamn finns i områdesbeskrivningen (3.1). Jämförelser har gjorts mellan områdenas median-RRMSE för ostörda prognoser och för prognoser utförda med starttillståndet närmast den observerade vattenföringen (grupp A). Numren motsvarar områdenas nummer på kartan.

När samma undersökning gjordes för AR-prognoser presterade 38 områden bättre och 22 områden sämre för grupp A jämfört med de ostörda kontrollprognoserna (Figur 26).



Figur 26. Dataassimilationens effekt (E) på 2-dygnsprognoser per område (med AR-uppdatering). Områdenas position och stationsnamn finns i områdesbeskrivningen (3.1). Jämförelser har gjorts mellan områdenas median-RRMSE för ostörda prognoser och för prognoser utförda med starttillståndet närmast den observerade vattenföringen (grupp A). Numren motsvarar områdenas nummer på kartan.

Även de medelvärdesbildade prognoserna jämfördes med de ostörda prognoserna med avseende på median-RRMSE (Tabell 6). När 2-dygnsprognoser gjorda med grupp m11 jämfördes med ostörda 2-dygnsprognoser presterade 53 områden bättre och 7 områden sämre (Figur 27).




Figur 27. Dataassimilationens effekt (E) på 2-dygnsprognoser per område (med AR-uppdatering). Områdenas position och stationsnamn finns i områdesbeskrivningen (3.1). Jämförelser har gjorts mellan områdenas RRMSE för ostörda prognoser och för prognoser utförda med medelvattenföringen av prognoser utförda på de elva närmsta starttillstånden (grupp m11). Numren motsvarar områdenas nummer på kartan.

Tabell 6. Antal områden som förbättrats eller försämrats efter dataassimilation för de medelvärdesbildade prognoserna m1-m15 för AR-uppdaterade prognoser. raden med plustecken visar antal områden vars median-RRMSE förbättrats och raden med minustecken visar antal områden vars median-RRMSE försämrats


	m1	m2	m3	m4	m5	m6	m7	m8	m9	m10	m11	m12	m13	m14	m15
+	38	42	43	43	45	47	47	49	50	51	53	50	38	20	6
-	22	18	17	17	15	13	13	11	10	9	7	10	22	40	54

Sjöprocent korrelerade positivt med förbättringseffekten för prognoser utan AR-korrigerings. Två signifikanta samband observerades mellan effekten av dataassimilationen och områdesvariablerna för AR-uppdaterade prognoser (Figur 28). Effekten korrelerade negativt med area och sjöprocent.




Figur 28. Spearmans rangkorrelation mellan effekt och områdesvariabler. Numret visar korrelationskoefficienten för de undersökta variablerna. Blå kvadrater indikerar positiv korrelation och röda, streckade kvadrater indikerar negativ korrelation. Styrkan på korrelationen beror på nyans enligt skala. Saknad färg innebär att korrelationen är icke-signifikant ($p > 0,05$).

RRMSE för AR-uppdaterade 2-dygnsprognoiser logaritmerades för att möjliggöra visuella jämförelser mellan prognoser utförda på ostörda starttillstånd, prognoser utförda på starttillstånd från grupp A och prognoser utförda på starttillstånd från grupp m11 (Figur 29; Figur 30).



Figur 29. Jämförelse mellan prognoser utförda på ostörda starttillstånd och prognoser utförda på starttillstånd från grupp A. Den relativt stora standardavvikelsen hos prognoser i grupp A går att urskilja i form av en mer utjämnad topp.



Figur 30. Jämförelse mellan prognoser utförda på ostörda starttillstånd och prognoser utförda på starttillstånd från grupp m11. Prognosernas standardavvikelser är snarlika, men prognoser utförda på starttillstånd från grupp m11 har en lägre median.

5 DISKUSSION

Resultatet av de hydrologiska simuleringarna visar att den observerade vattenföringen låg mellan ensemblens högsta och lägsta vattenföring i nästan 77 % av fallen prognosdygn 1 och i drygt 70 % av fallen prognosdygn 10. Även om störningarna i indata som användes i analysen var stora fanns det fortfarande observerad vattenföring som inte inkluderades i ensemblespannet. Den intressantaste tidpunkten är de tidigaste prognosdygnen, eftersom meteorologiska ensembleprognoser från ECMWF ytterligare kommer öka spridningen efter det. Att 77 % av den observerade vattenföringen inkluderades prognosdygn 1 kan därmed räknas som en rimlig siffra, då 100 % skulle innebära en spridning så stor att det finns risk att den slutar vara informativ. Störningarna i drivdata skulle eventuellt kunna ökas för att komma upp i 90 % inkludering av observerad vattenföring prognosdygn 1.

Ett intressant resultat var att den ensemblemedlem som oftast var närmast den observerade vattenföringen vid prognosstart var nummer 3 och inte den ostörda prognosen. Ensemblemedlem 3 skapades med minskad nederbörd ($P=0,5$) och ökad temperatur ($T+2\text{ °C}$). Detta står i kontrast till den korrektion som görs på data i PTHBV, där nederbörden ökas för att kompensera för mätförluster. Något som bör noteras är dock att ensemblemedlem 2 ($P=0,5$; $T\pm 0\text{ °C}$) och 6 ($P=0,75$; $T\pm 2\text{ °C}$) som låg nära ensemblemedlem 3 till temperatur och nederbörd sett hade lägst och näst lägst frekvens. Detta indikerar att den reativt höga frekvens ensemblemedlem 3 hade både skulle kunna vara en slump och bero på något systematiskt. Vilken ensemblemedlem som oftast låg närmast den observerade vattenföringen varierade mellan områden, så det är svårt att dra någon slutsats för hela datasetet.

Spridning-utfall-analysen visade att det fanns ett statistiskt signifikant samband mellan spridning och prognososäkerhet. Det bekräftade hypotesen att det finns ett samband mellan ensemblespridning och prognosfel, vilket innebär att en stor spridning ofta innebär större prognososäkerhet medan en liten spridning ofta innebär mindre prognososäkerhet. Analys av medelfel för respektive flödesgrupp visade att en stor spridning indikerar ett stort hydrologiskt prognosfel för 2-, 4- och 10-dygnsprognoser. Den stora variationen mellan områden och det låga värdet på Spearmans korrelationskoefficient r_s indikerar att ett sannolikhetsperspektiv lämpar sig då slutsatser om prognosfel dras utefter spridningens storlek. En liten spridning garanterar inte att prognosfelet är litet, men sannolikheten är större än för en stor spridning. Förhållandet mellan spridning och utfall liknar sambandet mellan meteorologiska prognoser och utfall i HBV-modellen (Olsson et al., 2006). Lutningen för spridning-utfall-analysen korrelerade negativt med area, sjöprocent och höjd över havet. Detta indikerar att sambandet är starkast för små, lågt belägna områden med liten sjöprocent.

Hypotesen att avrinningsområdenas egenskaper korrelerar med prognososäkerheten bekräftas av resultaten. Den negativa korrelationen mellan avrinningsområdenas area och prognosfel stämmer väl överens med tidigare studier, och innebär att stora områden hade lägre relativt prognosfel. Dock var inte sambandet mellan spridning och area lika starkt och var endast signifikant för 2-dygnsprognoser. Även avrinningsområdenas sjöprocent korrelerade negativt med prognosfel för samtliga prognoslängder, ett resultat som stämmer väl med teorin gällande sjöars flödesdämpande förmåga. Det fanns dock ingen signifikant korrelation mellan spridning och sjöprocent. Detta resultat indikerar att små, lågt belägna områden med liten sjöprocent och stor skogsprocent är mest känsliga för fel i starttillståndet vid denna typ av störning. Detta är samma typ av område som hade tydligast spridning-utfall-samband. Faktumet att prognosfel och spridning uppvisar samma typ av korrelation i relation till områdesvariablerna stärker uppfattningen om ett spridning-utfall-samband.

Skogsprocent korrelerade positivt med både prognosfel och spridning, och en möjlig förklaring är hur modellen hanterar evapotranspiration från skogsmark. Seibert (1999) fann i en studie av HBV-modellen att områden med hög skogsprocent korrelerade med parametrar relaterade till snöprocesser. Vintermånadernas stora relativa spridning i undersökningen av årstidsvariationen indikerar att perioder då snöprocesser är aktuella är känsliga för starttillståndsstörningar. En annan tänkbar förklaring är den dynamiska hydrologin i produktiv skogsmark, som upptar cirka 57 % av Sveriges landareal (SLU, 2015). Skogsavverkning innebär minskad evapotranspiration och ökad snöackumulation vilket bidrar till höjd grundvattennivå och ökad avrinning (Ring et al., 2008), något HYPE-modellens statistiska modellbeskrivning inte tar hänsyn till.

En problematisk faktor som även noterades av Seibert (1999) är områdesvariablers interna korrelation. Korrelationsanalysen påvisade att det fanns ett statistiskt signifikant positivt samband mellan area och sjöprocent, area och höjd över havet samt sjöprocent och höjd över havet. Dessa interna korrelationer kan ha bidragit till att alla dessa områdesvariabler korrelerade negativt med prognosfel och lutning. Det måste således vägas in i tolkningen av resultatet.

Spridning och prognosfel uppvisade ingen signifikant korrelation förutom vid 2-dygnsprognoiser. Som tidigare redovisats i spridning-utfall-analysen var sambandet inte särskilt monotont, så den relativt lilla mängd områden som undersökts kanske inte räckte för att påvisa ett signifikant samband (Bonett & Wright, 2000). Detta kan jämföras med spridning-utfall-analysen vars signifikanta resultat baserades på 3653 simuleringsresultat istället för 76.

Spridningsvariationen över året skiljde sig åt beroende på vilken vattenföring spridningen normaliserats med. Då den relativa spridningen beräknats genom division av den observerade vattenföringen under tio år liknade resultatet fördelning av vattenföring över året. Störst var spridningen vid vårflödet och lägst under sommaren. Spridningen under vintern var dock betydligt högre i relation till vattenföringen. Normaliserades spridningen istället med medelvattenföring per månad uppvisades störst spridning i augusti. Detta resultat kan tolkas som att vår och vinter är mest känsliga för fel i starttillståndet totalt sett, men att vår och sommar är känsligast i förhållande till medelvattenföring den undersökta perioden. Den relativt låga vattenföringen på sommaren innebar att den relativa spridningen blev låg när den normaliserats med medelvattenföring för hela tioårsperioden 1999-2008. När spridning istället normaliserades med medelvattenföring för respektive sommarmånad – som är betydligt lägre än medelvattenföring över året – resulterade det i en större relativ spridning.

Att ett starttillstånd med vattenföring nära den uppmätta vattenföringen resulterade i en mer träffsäker prognos bekräftades delvis av resultaten. Att dataassimilationen inte gav lika stor effekt på AR-prognoiser var väntat då även AR-uppdateringen tar hänsyn till observerad vattenföring. Det är möjligt att inkluderandet av fler ensemblemedlemmar hade resulterat i en större förbättring, eftersom det ibland var stor skillnad mellan starttillståndens vattenföring och observerad vattenföring. Detta går att se i histogrammet över hur ofta ensemblemedlemmarna låg närmast den observerade vattenföringen. Även fast störningarna för ensemblemedlem 1-3 och 13-15 var stora så låg de ändå ofta närmast den observerade vattenföringen.

Median-prognosfelet (RRMSE) var lägre för de dataassimilerade AR-prognoserna men standardavvikelsen var större för både grupp A och för de medelvärdesbildade prognoserna. Risken för stora uteliggare ökar därmed vid användandet av denna typ av dataassimilerade prognoser. Det betyder att många prognoser får ett mindre och många ett större prognosfel genom dataassimilation. Ett sätt att komma ifrån denna problematik är att använda medelvärden som är baserade på många olika starttillstånd. Det var förvånande att medelvärdet av de elva närmsta starttillstånden resulterade i ett lägre median-RRMSE för 53 av 60 undersökta områden, vilket innebär en förbättring av drygt 88 % av områdena.

Korrelationstestet mellan effekt av dataassimilationen med area, sjöprocent, skogsprocent och höjd över havet visade ett signifikant negativt samband mellan effekt och area samt ett signifikant negativt samband mellan effekt och sjöprocent för AR-prognoser. Detta indikerar att små områden med låg sjöprocent är bäst lämpade för den här typen av dataassimilation vid AR-uppdatering. Förbättringseffekten utan AR-uppdatering korrelerade positivt med sjöprocent, vilket innebär att prognoser utförda i områden med stor sjöandel förbättrades i högre grad än andra prognoser. På grund av tidigare nämnda internkorrelation mellan variabler bör dock detta resultat tolkas med försiktighet.

Det hade funnits ett stort värde i att använda fler definitioner av spridning och prognosfel för att ge studien ytterligare kredibilitet. Mängden simulerade prognoser, prognosvarianter och undersökta områden gjorde det svårt att överblicka och jämföra datan, och det finns utrymme för fler studier inom området. Det hade varit intressant att testa olika sätt att generera starttillstånd och jämföra dem med avseende på styrkan i spridning-utfall-relationen. Det hade även varit intressant att kvantifiera hur stor del av den totala osäkerheten som starttillståndet står för i hydrologiska prognoser.

Trots att dataassimilationen innebar en förbättring av AR-uppdaterade prognoser är en operationell inkorporering troligen olämplig. Skillnaden mellan prognosfelen var inte särskilt stor, och generering av starttillstånden kräver resurser. Standardavvikelsen ökade betydligt för dataassimilerade prognoser och tekniken kan endast användas på den begränsade mängd områden som dagligen rapporterar in observerad vattenföring. Om starttillstånd ändå genereras i syfte att inkludera osäkerheten finns dock ingen kostnad i att även tillämpa dataassimilation.

I och med sambandet mellan spridning och utfall finns det ett värde i att inkludera olika starttillstånd i operationella prognoser. Vidare studier krävs dock för att undersöka hur data ska assimileras på effektivast sätt.

6 SLUTSATSER

Utgångspunkten för denna studie var att undersöka hur vattenföringsprognoser i HYPE-modellen påverkas av olika hydrologiska starttillstånd. Femton olika starttillstånd genererades genom störningar i drivdata under 35 dygn innan prognosstart. Två olika temperaturstörningar ($T \pm 2$ °C) och fyra olika nederbördsstörningar ($P \cdot 0,5; 0,75; 1,25; 1,5$) kombinerades med ostörd drivdata i skapandet av starttillståndsensensiblen.

Ett av de mest betydelsefulla resultaten var fastställandet av sambandet mellan prognosfel och ensemblespridning, som representerar prognososäkerhet och osäkerhet kopplat till det hydrologiska starttillståndet. Det innebär att spridning i viss mån kan användas som mått på den delen av prognososäkerheten som starttillståndet står för.

Spearman's rangkorrelation visade en negativ korrelation mellan prognosfel och avrinningsområdenas area, sjöprocent och höjd över havet samt en positiv korrelation mellan prognosfel och skogsprocent. Samma trend observerades mellan områdesvariabler och spridning. Detta tyder på att små, lågt belägna områden med låg sjöandel och hög skogsandel är känsligast för störningar i starttillståndet. Att korrelationen mellan spridning och områdesvariabler var snarlik korrelationen mellan prognoser och områdesvariabler ger ytterligare belägg för ett spridning-utfall-samband.

Störst spridning inträffade under vår och vinter då normalisering skett med medelvattenföring över tio år. Då spridningen normaliserades med medelvattenföring per månad var den störst under våren och sommaren. Områdena är således i absoluta tal känsligast för fel i starttillståndet under vår och vinter och i relativa tal känsligast för fel i starttillståndet under vår och sommar.

Resultatet av dataassimilationen visade att det går att förbättra hydrologiska prognoser med hjälp av starttillstånd vars vattenföring ligger nära den observerade vattenföringen. Skillnaden mellan ostörda prognoser och prognoser förbättrade med dataassimilation var större för prognoser utan än med autoregressiv uppdatering. Genom att välja ett starttillstånd vars vattenföring är nära den observerade vattenföringen kan prognoser därmed presteras bättre.

Denna studie kan utgöra utgångspunkten till en implementering av starttillståndsgenerering i operationella prognoser i syfte att ge vakthavande hydrolog ytterligare information om prognososäkerheten. Den ger även en inblick i vilka områden och årstider som är extra känsliga för fel i starttillståndet. Studien öppnar även för möjligheten att assimilera observerad vattenföring i hydrologiska prognoser, men ytterligare studier behöver göras för att optimera tekniken. Studien begränsades av antalet ensemblemedlemmar som kunde genereras och den typ av indatastörning som utfördes.

7 REFERENSER

- Andreadis, K.M., Lettenmaier, D.P., (2006). "Assimilating remotely sensed snow observations into a macroscale hydrology model." *Adv. Water Resour.* 29, 872–886. doi:10.1016/j.advwatres.2005.08.004
- Arheimer, B., Lindström, G., (2015). "Climate impact on floods: Changes in high flows in Sweden in the past and the future" (1911–2100). *Hydrol. Earth Syst. Sci.* 19, 771–784. doi:10.5194/hess-19-771-2015
- Arheimer, B., Lindström, G., Olsson, J., (2011). "A systematic review of sensitivities in the Swedish flood-forecasting system." *Atmospheric Res.* 100, 275–284. doi:10.1016/j.atmosres.2010.09.013
- Artusi, R., Verderio, P., Marubini, E., (2008). "Bravais-Pearson and Spearman correlation coefficients: meaning, test of hypothesis and confidence interval." *Int. J. Biol. Markers* 17, 148–151. doi:10.5301/JBM.2008.2127
- Asp, S.-S., 2016. SMHIs hydrologiska prognos- och varningstjänst.
- Aubert, D., Loumagne, C., Oudin, L., (2003). "Sequential assimilation of soil moisture and streamflow data in a conceptual rainfall–runoff model." *J. Hydrol.* 280, 145–161. doi:10.1016/S0022-1694(03)00229-4
- Bonett, D.G., Wright, T.A., (2000). "Sample Size Requirements for Estimating Pearson, Kendall and Spearman Correlations." *Psychometrika* 65, 23–28. doi:10.1007/BF02294183
- Carlsson, B., Lindström, G., (2001). "HBV-modellen och flödesprognoser ", *Hydrologi.* 85, SMHI, Norrköping.
- Clark, M.P., Rupp, D.E., Woods, R.A., Zheng, X., Ibbitt, R.P., Slater, A.G., Schmidt, J., Uddstrom, M.J., (2008). "Hydrological data assimilation with the ensemble Kalman filter: Use of streamflow observations to update states in a distributed hydrological model." *Adv. Water Resour.* 31, 1309–1324. doi:10.1016/j.advwatres.2008.06.005
- Conover, W.J., Iman, R.L., (1981). "Rank Transformations as a Bridge between Parametric and Nonparametric Statistics." *Am. Stat.* 35, 124–129. doi:10.1080/00031305.1981.10479327
- DeChant, C.M., Moradkhani, H., (2011). "Improving the characterization of initial condition for ensemble streamflow prediction using data assimilation." *Hydrol Earth Syst Sci* 15, 3399–3410. doi:10.5194/hess-15-3399-2011
- Demirel, M.C., Booij, M.J., Hoekstra, A.Y., (2013). "Effect of different uncertainty sources on the skill of 10 day ensemble low flow forecasts for two hydrological models." *Water Resour. Res.* 49, 4035–4053. doi:10.1002/wrcr.20294
- Gericke, O.J., Smithers, J.C., (2014). "Review of methods used to estimate catchment response time for the purpose of peak discharge estimation." *Hydrol. Sci. J.* 59, 1935–1971. doi:10.1080/02626667.2013.866712
- Granström, C., (2005). "Utvärdering av SMHIs hydrologiska prognos- och varningstjänst under vårfloden i fjällen juni", *Hydrologi.* 99, SMHI, Norrköping.
- Gustafsson, D., Lindström, G., Pers, C., (2012). "Assimilation of lake surface temperature and ice cover data in a semi-distributed hydrological model - implications for water balance and water quality predictions in Sweden." Presented at the EGU General Assembly Conference Abstracts.
- Gustafsson, D., Strömbäck, L., Arheimer, B., Nagler, T., Metsämäki, S., Luojus, K., Solberg, R., Malnes, E., (2014). "Impact on runoff simulation by assimilation of remote sensing snow data in a multi-basin hydrological model for Sweden." Presented at the EGU General Assembly Conference Abstracts.

- Johansson, B., Chen, D., (2003). "The influence of wind and topography on precipitation distribution in Sweden: statistical analysis and modelling." *Int. J. Climatol.* 23, 1523–1535. doi:10.1002/joc.951
- Laloyaux, P., Bengtsson, L., (2015). "Forty years of improving global forecast skill." *ECMWF Newsl.* 145, 2–3.
- Li, M., Wang, Q.J., Bennett, J.C., Robertson, D.E., (2015). "A strategy to overcome adverse effects of autoregressive updating of streamflow forecasts." *Hydrol Earth Syst Sci* 19, 1–15. doi:10.5194/hess-19-1-2015
- Lindström, G., Pers, C., Rosberg, J., Strömqvist, J., Arheimer, B., (2010). "Development and testing of the HYPE (Hydrological Predictions for the Environment) water quality model for different spatial scales." *Hydrol. Res.* 41, 295–319. doi:10.2166/nh.2010.007
- Lorenz, E.N., (1969). "The predictability of a flow which possesses many scales of motion." *Tellus* 21, 289–307. doi:10.1111/j.2153-3490.1969.tb00444.x
- Lyon, S.W., Meidani, R., van der Velde, Y., Dahlke, H.E., Swaney, D.P., Mörtz, C.-M., Humborg, C., (2015). "Seasonal and Regional Patterns in Performance for a Baltic Sea Drainage Basin Hydrologic Model. JAWRA J." *Am. Water Resour. Assoc.* 51, 550–566. doi:10.1111/jawr.12268
- Moradkhani, H., Sorooshian, Gupta, (2005). "Dual State-Parameter Estimation of Hydrological Models Using Ensemble Kalman Filter." *Adv. Water Resour.* 28, 135–147. doi:10.1016/j.advwatres.2004.09.002
- Nester, T., Komma, J., Viglione, A., Blöschl, G., (2012). "Flood forecast errors and ensemble spread—A case study." *Water Resour. Res.* 48, W10502. doi:10.1029/2011WR011649
- Olsson, J., Lindström, G., (2008). "Evaluation and calibration of operational hydrological ensemble forecasts in Sweden." *J. Hydrol.* 350, 14–24. doi:10.1016/j.jhydrol.2007.11.010
- Olsson, J., Lindström, G., Johnell, A., Jacobsson, K., (2006). "Hydrologiska ensembleprognoser" *RH* 21. SMHI, Norrköping.
- Pagano, T., Garen, D., Sorooshian, S., (2004). "Evaluation of Official Western U.S. Seasonal Water Supply Outlooks, 1922–2002." *J. Hydrometeorol.* 5, 896–909. doi:10.1175/1525-7541(2004)005<0896:EOOWUS>2.0.CO;2
- Persson, A., (2015). *User guide to ECMWF forecast products*. European Centre for Medium-Range Weather Forecasts (ECMWF), Reading, UK.
- Ring, E., Löfgren, S., Sandin, L., Högbom, L., Goedkoop, W., (2008). "Skogsbruk och vatten: en kunskapsöversikt", *Skogforsk* 3, Skogforsk, Uppsala.
- Scherrer, S.C., Appenzeller, C., Eckert, P., Cattani, D., (2004). "Analysis of the Spread–Skill Relations Using the ECMWF Ensemble Prediction System over Europe." *Weather Forecast.* 19, 552–565. doi:10.1175/1520-0434(2004)019<0552:AOTSRU>2.0.CO;2
- Seibert, J., (1999). "Regionalisation of parameters for a conceptual rainfall-runoff model." *Agric. For. Meteorol.* 98–99, 279–293. doi:10.1016/S0168-1923(99)00105-7
- SLU, (2015). *Produktiv skogsmark* [webbsida]. URL <http://www.slu.se/sv/webbtjanster-miljoanalys/statistik-om-skog/produktiv-skogsmark/> (hämtad 5.14.16).
- SMHI, (2015). *SMHIs varningar* [webbsida]. URL <http://www.smhi.se/kunskapsbanken/meteorologi/smhis-varningar-1.83320> (hämtad 4.19.16).
- SMHI, (2012). *Indata för markanvändning i VattenWebb* [webbsida]. URL <http://www.smhi.se/professionella-tjanster/professionella-tjanster/miljo-och-klimat/vattenmiljo/indata-for-markanvandning-i-vattenwebben-1.22841> (hämtad 5.6.16).

- Staudinger, M., Seibert, J., (2014). "Predictability of low flow – An assessment with simulation experiments." *J. Hydrol.* 519, Part B, 1383–1393. doi:10.1016/j.jhydrol.2014.08.061
- Strömqvist, J., Arheimer, B., Dahné, J., Donnelly, C., Lindström, G., (2012). "Water and nutrient predictions in ungauged basins: set-up and evaluation of a model at the national scale." *Hydrol. Sci. J.* 57, 229–247. doi:10.1080/02626667.2011.637497
- Wang, X., Bishop, C.H., (2003). "A Comparison of Breeding and Ensemble Transform Kalman Filter Ensemble Forecast Schemes." *J. Atmospheric Sci.* 60, 1140–1158. doi:10.1175/1520-0469(2003)060<1140:ACOBAE>2.0.CO;2
- Wood, A.W., Lettenmaier, D.P., (2008). "An ensemble approach for attribution of hydrologic prediction uncertainty." *Geophys. Res. Lett.* 35, L14401. doi:10.1029/2008GL034648
- Zappa, M., Jaun, S., Germann, U., Walser, A., Fundel, F., (2011). "Superposition of three sources of uncertainties in operational flood forecasting chains." *Atmospheric Res., Uncertainty Propagation in Advanced Hydro-Meteorological Forecast Systems* 100, 246–262. doi:10.1016/j.atmosres.2010.12.005

APPENDIX A Tabell över undersökta områden

Undersökta indikatorområden (Tabell A).

Tabell A. Station, nummer, area, sjöprocent, skogsprocent och höjd över havet för de undersökta områdena. Numren motsvarar numren på kartan.

Station	NR	Area [km ²]	Sjö%	Skogs%	M.ö.h
Mertajärvi	1	391	5,2	47,9	393
Kallio	2	14500	3,86	53,2	398
Pajala Pumphus	3	16800	6,6	37,7	517
Karats	4	1170	8,94	54,3	647
Stenudden	5	2420	11,7	19,7	768
Ytterholmen	6	1020	2,6	71,6	103
Långsjön	7	42,6	6,33	86,6	156
Tängvattnet	8	195	8,97	18,5	743
Skirknäs	9	418	9,51	34,3	816
Sorsele	10	6030	4,8	47,9	691
Strömfors	11	679	7,81	70,5	380
Byske	12	3620	5,84	79,6	361
Mesjön Övre	13	330	3,11	38,9	689
Laiksjön	14	581	6	73,5	385
Granåker	15	11900	6,2	62,6	314
Rengen	16	1110	5,8	53,6	543
Dalkarlså	17	251	1,25	91	111
Fyrås	18	2430	5,25	71,6	456
Östra Norn	19	2390	7,05	30,2	757
Västersel	20	1470	4,24	86,7	263
Gimdalsby	21	2160	12,3	84,1	364
Risnäs	22	118	5,38	91,2	251
Tänndalen	23	227	7,26	24,5	910
Saras Fors	24	616	0,713	82	242
Skogsliden	25	229	6,59	88,4	147
Bössbo	26	773	1,16	85,8	604
Ersbo	27	1100	0,872	56	723
Konstdalsströmmen	28	998	5,43	87,9	94
Hyttingsheden	29	48,8	0,25	99,6	350
Grea	30	309	3,88	93,7	314
Vattholma	31	294	3,06	77,9	37
Nordmark	32	161	4,52	91,9	284
Ransta	33	197	1,02	70	53
Kringlan	34	294	7,38	90	201
Åkesta Kvarn	35	728	3,74	71,1	84
Dalkarlsyttan	36	1180	7,33	85,1	209
Kvarntorp	37	10,9	6,3	86	124
Hammarby	38	891	9,06	84,7	164
Skällnora	39	58,6	9,97	33,8	18
Karlslund	40	1290	6,89	73,6	118
Saxbro	41	80,7	4,32	72,7	50

Hallbosjön	42	1990	13,8	68,8	59
Krokfors Kvarn	43	115	2,05	77	145
Nolsjön Nedre	44	18,2	1,22	96,6	177
Krokbräcke	45	8,35	0	74,2	56
Mellankvarn	46	703	6,05	59,1	102
Moholm	47	1140	2,31	69,4	214
Göstad	48	85	2,42	72,9	73
Munkedal	49	1330	3,69	75,8	62
Rytttarbacken	50	7,33	0	36,8	128
Sundstorp	51	687	0,207	47,2	173
Melby	52	260	11,1	72,1	60
Nytorp	53	345	7,12	82,9	174
Brusafors	54	240	1,69	88	224
Hörsne	55	349	0,028	50,5	43
Liffedarve	56	95,8	0	64,6	43
Nissafors	57	826	3,93	84,1	230
Fryele	58	578	1,86	82,7	214
Åsbro	59	2160	5,67	75,2	118
Blankaström	60	4000	6,1	79	200
Pepparforsen	61	384	5,49	85,7	133
Getebro	62	1330	5,7	89,2	167
Lissbro	63	97,2	0,999	76,7	169
Simlången	64	260	4,67	84,4	141
Källstorp	65	342	1,14	88,3	133
Möckeln	66	1030	10,4	76,4	159
Boasjöbäck	67	56,6	5,84	85,5	136
Ärrarp	68	261	3,18	57,5	77
Gredeby	69	438	5,7	81,4	110
Mariefors	70	802	4,26	86,4	137
Mörrum	71	3360	12,6	73,3	178
Bivarödsmölla	72	209	1,45	85	82
Torsebro Krv	73	3660	5,25	75,7	97
Ellinge	74	151	0,047	14,6	108
Svedala	75	52,2	9,99	33,3	60
Tånemölla	76	102	0,238	10,8	69

APPENDIX B Beräkningskod

Huvudprogram

```
% Skript för att generera starttillstånd i HYPE-modellen
% Av Elinor Andersson, 22/2 2016
% Examensarbete Sph VT16

clear variables;
close all;
format short

% % Indata till datagenereringen
korningsfiler = 'C:\Users\Elinor\Documents\Exjobb\Korningsfiler';
modelluppsattning = 'C:\Users\Elinor\Documents\IndOmr';
output = 'C:\Users\Elinor\Documents\Exjobb\IndOmr';
dygn = 35; % Antal dygn som ska stötas under framkörningen
prognosdygn = 3653; % Antal dygn som prognoser ska göras på
TSpann = [-2 0 2 -2 0 2 -2 0 2 -2 0 2]; % vektor med siffror från 1 till x (antal
ensemblemedlemmar)
PSpann = [0.5 0.5 0.5 0.75 0.75 0.75 1 1 1.25 1.25 1.25 1.5 1.5 1.5]; % vektor med siffror
från 1 till x (antal ensemblemedlemmar)
x = length(TSpann); % Antal ensemblemedlemmar

addpath(korningsfiler,modeluppsattning,output);
cd(modeluppsattning);

Iniprognosdatum = '19990101'; % Datum där du vill att framkörningen ska sluta
Iniplotstart = '19990101';
Iniplotslut = '19990111';
IniState = '19981127';
IniStateSave = '19981128';
pla = datenum(Iniprognosdatum,'yyyymmdd');
plb = datenum(Iniplotstart,'yyyymmdd');
plc = datenum(Iniplotslut,'yyyymmdd');
pld = datenum(IniState,'yyyymmdd');
ple = datenum(IniStateSave,'yyyymmdd');
% %
% % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % % %
%
% Inläsning av avrinningsområdesnummer av intresse
fid = fopen('select.txt','r+');
Omr1 = textscan(fid,'%s');
fclose(fid);
Omr2 = [Omr1{1,1}];
Omr3 = sprintf('%s ', Omr2{19:end}); % 19 eftersom det är från och med där som
avrinningsområdesnummerna finns i filen
Omr = sscanf(Omr3,'%f ');

% Inläsning av observerad vattenföring
delimiterIn = '\t';
headerlinesIn = 1;
QCell = importdata('QobsOriginal.txt',delimiterIn,headerlinesIn);
QCellOrg = QCell;
slutdygnQ = find(QCell.data(:,1) == str2num(datestr(pla,'yyyymmdd')));
QCell.data(slutdygnQ:end,2:end) = -9999; % De observerade värdena efter prognosstart ersätts
med -9999, som HYPE tolkar som saknat värde

% Inläsning av observerad vattenföring för prognoskvalitetsberäkningar
Qobsstart = find(QCell.data(:,1) == str2num(datestr(pla,'yyyymmdd')));
Qobsslut = Qobsstart + prognosdygn;
Qobs(:,1) = QCellOrg.data(Qobsstart:Qobsslut,1);
for j = 1:length(Omr)
    QPos = find(strcmp(QCellOrg.textdata(1,:),num2str(Omr(j,1))));
    Qobs(:,j+1) = QCellOrg.data(Qobsstart:Qobsslut,QPos);
end

% Inläsning av observerad temperatur
delimiterIn = '\t';
headerlinesIn = 1;
TStruct = importdata('Tobs.txt',delimiterIn,headerlinesIn);

% Inläsning av observerad nederbörd
PStruct = importdata('Pobs.txt',delimiterIn,headerlinesIn);

% Förallokering av variabler
Forallokering;
```

```

for p = 1:prognosdygn
    p2a = addtodate(p1a, p-1, 'day');
    p2b = addtodate(p1b, p-1, 'day');
    p2c = addtodate(p1c, p-1, 'day');
    p2d = addtodate(p1d, p-1, 'day');
    p2e = addtodate(p1e, p-1, 'day');
    prognosdatum = str2num(datestr(p2a, 'yyyymmdd'));
    plotstart = str2num(datestr(p2b, 'yyyymmdd'));
    plotslut = str2num(datestr(p2c, 'yyyymmdd'));
    State = str2num(datestr(p2d, 'yyyymmdd'));
    StateSave = str2num(datestr(p2e, 'yyyymmdd'));
    NQ(p,1) = prognosdatum;
    NFUN{11,1}(p,1) = prognosdatum;

    % Generering av infofil
    infogen_func_0_2(plotstart,plotslut,State,StateSave)

    % Störningar i indata skapas
    indatagen_func_1_4(prognosdatum,modelluppsattning,dygn,x,TSpenn,PSpenn,p2a,QCell,QCellOrg,TStr
uct,PStruct,State,plotslut,p2c,p2d);

    % HYPE körs för angivet antal ensemblemedlemmar
    HYPE1 = '\HYPE_nobutton.exe .\' ; % Textfil med störd nederbördsdata får namn efter for-loopen.
    HYPE2 = fullfile(modelluppsattning, HYPE1);
    [status,result] = system(HYPE2);
    for g = 1:x
        HYPE1 = ['HYPE_nobutton.exe .\ -s ' num2str(g, '% 01.f')];
        HYPE2 = fullfile(modelluppsattning, HYPE1);
        [status,result] = system(HYPE2);
        if g == x-1 % Datum för ny framkörning
            infogenSTATE_func_0_1(plotstart,plotslut,State,StateSave)
        end
    end
end
% Utdata läses in och analyseras
[Qobs, NormQSpanntest, MAENP, MAEPP, RRMSE, MSE, RMSE, VAR, NQ, NFUN] =
utdatainl_func_1(prognosdatum,x,output,TSpenn,PSpenn,Omr,QCellOrg,p,prognosdygn,Qobs, NormQSpan
ntest, MAENP, MAEPP, RRMSE, MSE, RMSE, VAR, NQ, NFUN);
fclose('all')
end

```

Indatagenerering (funktion)

% Funktion för att generera störningar i indata till HYPE-modellen
 % Av Elinor Andersson, 20/1 2016
 % Examensarbete Sph VT16

```

function [] =
indatagen_func_1_4(prognosdatum,modelluppsattning,dygn,x,TSpenn,PSpenn,p2a,QCell,QCellOrg,TStr
uct,PStruct,State,plotslut,p2c,p2d)
delimiterIn = '\t';
headerlinesIn = 1;

% Inläsning av observerad vattenföring
slutdygnQ = find(QCell.data(:,1) == str2num(datestr(p2a, 'yyyymmdd'))); % Hittar var i indata
som prognosen börjar och störningarna ska sluta
QrunStart = find(QCell.data(:,1) == str2num(datestr(p2d, 'yyyymmdd')));
QrunSlut = find(QCell.data(:,1) == str2num(datestr(p2c, 'yyyymmdd')));
QCell.data((slutdygnQ-20):slutdygnQ,2:end) = QCellOrg.data((slutdygnQ-20):slutdygnQ,2:end); %
De observerade värdena efter prognosstart ersätts med -9999, som HYPE tolkar som saknat värde
QCell.data = QCell.data(QrunStart:QrunSlut,:);
QHeader = strjoin(QCell.textdata,delimiterIn);
Qfil = fullfile(modelluppsattning, 'Qobs.txt');
dlmwrite(Qfil,QHeader,'delimiter',' ','newline','pc');
dlmwrite(Qfil,QCell.data,'delimiter',delimiterIn,'precision',8,'newline','pc','-append');

Header = strjoin(TStruct.textdata,delimiterIn);

TrunStart = find(TStruct.data(:,1)==State); % Hittar var framkörningen slutar
Tslutdygn = find(TStruct.data(:,1)==prognosdatum); % Hittar var i indata som prognosen börjar
och störningarna ska sluta
Tstartdygn = Tslutdygn - dygn +1;
TrunSlut = find(TStruct.data(:,1)==plotslut); % Hittar var datautskrivningen slutar

PrunStart = find(PStruct.data(:,1)==State); % Hittar var framkörningen slutar
Pslutdygn = find(PStruct.data(:,1)==prognosdatum); % Hittar var i indata som prognosen börjar
och störningarna ska sluta
Pstartdygn = Pslutdygn - dygn +1;

```

```

PrunSlut = find(PStruct.data(:,1)==plotslut); % Hittar var dataautskrivningen slutar

% Indatastörning för alla avrinningsområden

% Temperatur
for k = 1:x
    TStruct2 = TStruct;
    TStruct2.data(Tstartdygn:Tslutdygn,2:end) = TStruct.data(Tstartdygn:Tslutdygn,2:end) +
TSpann(k);
    TStruct2.data = TStruct2.data(TrunStart:TrunSlut,:);
    Tfill = sprintf(['Tobs_' num2str(k,'% 04.f'), '.txt'], k); % Textfil med störd
Temperaturdata får namn efter for-loopen.
    Tfil = fullfile(modelluppsattning, Tfill);
    dlmwrite(Tfil,Header,'delimiter','', 'newline','pc');
    dlmwrite(Tfil,TStruct2.data,'delimiter',delimiterIn,'precision',8,'newline','pc','-
append');
end

% Nederbörd
for k = 1:x
    PStruct2 = PStruct;
    PStruct2.data(Pstartdygn:Pslutdygn,2:end) =
PStruct.data(Pstartdygn:Pslutdygn,2:end)*PSpann(k);
    PStruct2.data = PStruct2.data(PrunStart:PrunSlut,:);
    Pfill = sprintf(['Pobs_' num2str(k,'% 04.f'), '.txt'], k); % Textfil med störd
Nederbördsdata får namn efter for-loopen.
    Pfil = fullfile(modelluppsattning, Pfill);
    dlmwrite(Pfil,Header,'delimiter','', 'newline','pc');
    dlmwrite(Pfil,PStruct2.data,'delimiter',delimiterIn,'precision',8,'newline','pc','-
append');
end

```

Utdatainläsning (funktion)

```

% Funktion för att läsa in flödesdata från HYPE
% Av Elinor Andersson, 2/2 2016
% Examensarbete Sph VT16

function [Qobs, NormQSpanntest, MAENP, MAEPP, RRMSE, MSE, RMSE, VAR, NQ, NFUN] =
utdatainl_func_1(prognosdatum,x,output,TSpann,PSpann,Omr,QCellOrg,p,prognosdygn,Qobs,NormQSpan
ntest,MAENP,MAEPP,RRMSE,MSE,RMSE,VAR,NQ,NFUN)

for j = 1:length(Omr)
    % Ensemblemedlemmarna läses in
    for k = 1:x
        Tfill = sprintf([num2str(Omr(j,1),'% 08.f'), '_', num2str(k,'% 04.f'), '.txt'], k);
        Tfil = fullfile(output, Tfill);
        delimiterIn = '\t';
        headerlinesIn = 2;
        TStruct1 = importdata(Tfil,delimiterIn,headerlinesIn);
        cobcMat2(:,k) = TStruct1.data(:,2);
        coutMat2(:,k) = TStruct1.data(:,3);
        datum = TStruct1.data(:,1);
    end
    % Observerad vattenföring
    Qstart = find(QCellOrg.data(:,1) == datum(1,1));
    Qslut = find(QCellOrg.data(:,1) == datum(end,1));
    QPos = find(strcmp(QCellOrg.textdata(1,:),num2str(Omr(j,1))));
    routNum = QCellOrg.data(Qstart:Qslut,QPos);

    % Perfekt prognos, utan störning
    PPfill = sprintf([num2str(Omr(j,1),'% 08.f'), '.txt'], k);
    PPfil = fullfile(output, PPfill);
    headerlinesIn = 2;
    PPStruct = importdata(PPfil,delimiterIn,headerlinesIn);
    PPNum = PPStruct.data;
    for g = 1:3
        PPMat{j,g} = PPNum(:,g);
    end

    % Resultaten sparas i celler
    Resultat{j,1} = cobcMat2; %cobc
    Resultat{j,2} = coutMat2; %cout
    Resultat{j,3} = routNum; %Qobs

    % Position för prognosstart och prognosslut hämtas
    prognosstart = find(datum(:,1) == prognosdatum)+1;
    prognosslut = prognosstart + 9;

```

```

a1 = abs(Resultat{j,3}((prognosstart-1),1)-Resultat{j,1}((prognosstart-1),:));
[~,sortIndex] = sort(a1); % Sorterar ensemblemedlemmarna från närmsat till längst bort
NQ(p,j+1) = sortIndex(1);
for o = 2:11
    ovreL(o) = max(Resultat{j,1}(o,:));
    undreL(o) = min(Resultat{j,1}(o,:));
    if Resultat{j,3}(o,1) < ovreL(o) && Resultat{j,3}(o,1) > undreL(o)
        NFUN{o-1,1}(p,j+1) = 1;
    else
        NFUN{o-1,1}(p,j+1) = 0;
    end
end

% Kriterieberäkningar
for i = 1:3
    if i == 1
        progtyp = 1;
    elseif i == 2
        progtyp = 3;
    else
        progtyp = 9;
    end
    for s = 1:2
        if s == 1
            korr = 2;
        else
            korr = 1;
        end
        [NormQSpanntest{i,s}] =
        SPANNfun(prognosdatum,datum,Omr,PNum,Resultat,progtyp,korr,j,p,NormQSpanntest{i,s},Qobs);
        [Qobs,RRMSE{i,s},MSE{i,s},RMSE{i,s},VAR{i,s}] =
        NSEfun(Resultat,prognosstart,prognosdatum,progtyp,korr,Omr,x,j,p,sortIndex,Qobs,RRMSE{i,s},MSE
        {i,s},RMSE{i,s},VAR{i,s});
        [MAENP{i,s},MAEPP{i,s}] =
        RMSEfun(prognosstart,prognosdatum,Qobs,Omr,progtyp,korr,Resultat,sortIndex,x,j,p,MAENP{i,s},MA
        EPP{i,s});
    end
end
end
end

```

Spann-beräkning (funktion)

```

function [NormQSpann] =
SPANNfun(prognosdatum,datum,Omr,PNum,Resultat,progtyp,korr,j,p,NormQSpann,Qobs)
    datSpann = find(datum(:,1) == prognosdatum) + progtyp+1;
    Qval = Resultat{j,korr}(datSpann,:);
    NormQSpann{1}(p+1,1) = prognosdatum;
    NormQSpann{1}(1,2:length(Omr)+1) = Omr.';
    NormQSpann{1}(p+1,(j+1)) = (max(Qval)-min(Qval))/mean(PNum(:,korr+1));
    NormQSpann{2}(p+1,1) = prognosdatum;
    NormQSpann{2}(1,2:length(Omr)+1) = Omr.';
    NormQSpann{2}(p+1,(j+1)) = (max(Qval)-min(Qval))/mean(Qobs(:,j+1));
    NormQSpann{3}(p+1,1) = prognosdatum;
    NormQSpann{3}(1,2:length(Omr)+1) = Omr.';
    NormQSpann{3}(p+1,(j+1)) = (max(Qval)-min(Qval));

```

End

RRMSE-beräkning (funktion)

```

function [Qobs,RRMSE,MSE,RMSE,VAR] =
RMSEfun(Resultat,prognosstart,prognosdatum,progtyp,korr,Omr,x,j,p,sortIndex,Qobs,RRMSE,MSE,RMS
E,VAR)

```

```

Spann = (prognosstart:prognosstart+progtyp);
for y = 1:x
    MSE{y,1}(1,2:x+1) = 1:x;
    MSE{y,1}(p+1,1) = prognosdatum;
    iniVektor = zeros(length(Spann),3);
    iniVektor(:,1) = sum(Resultat{j,korr}(Spann,sortIndex(1:y)),2)/y;
    iniVektor(:,2) = Resultat{j,korr}(Spann,8);
    iniVektor(:,3) = Resultat{j,korr}(Spann,sortIndex(y));
    for b = 1:3
        for h = 1:progtyp
            diff = (iniVektor(:,b) - Resultat{j,3}(Spann)); %start after warmup period
            diffmeanflow = Resultat{j,3}(Spann) - (mean(Resultat{j,3}(Spann)));
            VAR{y,b}(p+1,j+1) = var(iniVektor(:,b));
        end
    end
end

```



```

        MSE{y,b}(p+1,j+1) = mean((iniVektor(:,b) - Resultat{j,3}(Spann)).^2);
        RMSE{y,b}(p+1,j+1) = sqrt(MSE{y,b}(p+1,j+1));
        RRMSE{y,b}(p+1,j+1) = RMSE{y,b}(p+1,j+1)/mean(Qobs(:,j+1));
    end
end
end

```

MAE-beräkning (funktion)

```

function [MAENP,MAEPP] =
MAEfun(prognosstart,prognosdatum,Qobs,Omr,progtyp,korr,Resultat,sortIndex,x,j,p,MAENP,MAEPP)

Spann = (prognosstart:prognosstart+progtyp);
for y = 1:x
    MAENP{y,1}(p+1,1) = prognosdatum;
    MAEPP{y,1}(p+1,1) = prognosdatum;
    MAENP{y,1}(1,2:length(Omr)+1) = Omr.';
    MAEPP{y,1}(1,2:length(Omr)+1) = Omr.';
    iniVektor(:,1) = Resultat{j,korr}(Spann,sortIndex(y));
    iniVektor(:,2) = Resultat{j,korr}(Spann,8);

    for k = (prognosstart+1):(prognosstart+progtyp)
        MASEnorm(k) = abs(Resultat{j,3}(k)-Resultat{j,3}(k-1));
    end
    eNP = 0;
    ePP = 0;
    for t = 1:length(Spann)
        eNP(t) = abs(iniVektor(t,1)-Resultat{j,3}(t));
        ePP(t) = abs(iniVektor(t,2)-Resultat{j,3}(t));
    end
    eNP = sum(eNP(1:length(Spann)));
    ePP = sum(ePP(1:length(Spann)));
    MAENP{y,1}(p+1,j+1) = (eNP/length(Spann)); % MAE
    MAENP{y,2}(p+1,j+1) = (eNP/length(Spann))/mean(Qobs(:,j+1)); % RMAE
end
MAEPP{2,1}(p+1,j+1) = (ePP/length(Spann)); % MAE PP
MAEPP{3,1}(p+1,j+1) = (ePP/length(Spann))/mean(Qobs(:,j+1)); % RMAE PP

```

APPENDIX C P-värden för Spearmans rangkorrelation

P-värden för undersökningen av sambandet mellan indikatorområdenas area, sjöprocent, skogsprocent och höjd över havet med spridning och prognosfel (Tabell B).

Tabell B. P-värden för sambanden mellan områdesvariabler, spridning och prognosfel (RRMSE). S står för spridning och numret efter S och RRMSE är prognoslängd i dygn. Ett p-värde under 0,05 innebär att sambandet är signifikant.

	Area	Sjö%	Skogs%	M.ö.h	S2	S4	S10	RRMSE2	RRMSE4	RRMSE10
Area										
Sjö%	0,0093									
Skogs%	0,1016	0,4373								
M.ö.h	0,0001	0,0342	0,5231							
S2	0,0009	0,0601	<0,0001	0,0216						
S4	0,0806	0,5702	0,0000	0,1257	<0,0001					
S10	0,7257	0,0865	0,0001	0,0794	<0,0001	0,0000				
RRMSE2	<0,0001	0,0032	0,0056	0,0101	0,0032	0,1138	0,8466			
RRMSE4	<0,0001	<0,0001	0,0080	0,0023	0,0060	0,1984	0,7035	<0,0001		
RRMSE10	<0,0001	<0,0001	0,0405	0,0005	0,0095	0,3025	0,3275	<0,0001	<0,0001	