


BEARBETNING AV MULTIMETODMODELLENS STATISTISKA METOD FÖR FÖRBÄTTRAD PRESTANDA

RAPPORT 2018:515



HYDROLOGISKT
UTVECKLINGSARBETE



Bearbetning av multimetodmodellens statistiska metod för förbättrad prestanda

KEAN FOSTER OCH MARIA RASMUSSEN

ISBN 978-91-7673-515-2 | © Energiforsk juli 2018

Energiforsk AB | Telefon: 08-677 25 30 | E-post: kontakt@energiforsk.se | www.energiforsk.se

Förord

Motivet till att genomföra projektet har varit att implementera och utvärdera multimetodmodellen även kallad "Hydrological Seasonal Forecast System". Modellen har i tidigare projekt visat sig ha potential att förbättra vårflodsprognosernas precision jämfört med dagens prognosmodeller. Därmed finns ett stort värde för Vattenkraftbolagen att kunna nyttja modellen i daglig drift.

Rapporten sammanfattar de förbättringar som SMHI identifierade i multimetodmodellen under projektets gång då modellen tillämpades för år 2017. Syftet har varit att undersöka om ett förfinat urval av prediktorvariabeldata förbättrar multimetodmodellens prestanda. Resultatet av studien visar att det förfinade urvalet leder till blandade resultat för multimetodmodellens prognostiseringsförmåga och inte entydligt kan sägas ge en förbättrad precision. Ett av de viktigaste resultaten från projektet som helhet är dock att modellen nu kan nyttjas mer effektivt.

Rapporten har genomförts av Kean Foster på SMHI och Lunds tekniska och Maria Rasmusson på SMHI. Rapporten ingår som en av två inom projektet. Den andra rapporten inom projektet är "Utvärdering av multimetodmodellens säsongsprognoser 2017" Energiforskrapport, 2018:516.

Projektet har ingått i HUVA - Energiforsks arbetsgrupp för Hydrologiskt UtvecklingsArbete vars huvudinriktning är att förbättra precisionen i vattenkraftindustrins tillringsmodeller. HUVA innehåller utvecklingsprojekt, omvärldsbevakning, utbildning inom vattenkraftshydrologi (HUVA-kursen), HUVA- dagen och standardisering. I HUVA-gruppen ingår: Peter Calla, Vattenregleringsföretagen (ordf.), Stefan Busse, Sydkraft Hydropower AB, Lars Pettersson, Skellefteälvens Vattenregleringsföretag, Björn Norell, Vattenregleringsföretagen, Susanne Nyström, Vattenfall Vattenkraft AB, Mikael Sundby, Vattenfall AB, Johan Andersson, Fortum Generation AB, Emma Wikner, Statkraft Sverige AB, Knut Sand, Statkraft Sverige AB, Magnus Jämtning, Jämtkraft AB, Jörgen Berglund, Skellefteå Kraft AB och Fredrik Martinsson, Energiforsk (adj)

Vattenfall AB Vattenkraft, Fortum Generation AB, Sydkraft Hydropower AB, Statkraft Sverige AB, Skellefteå Kraft AB, Holmen Energi AB, Jämtkraft AB, Umeå Energi AB, Tekniska Verken i Linköping AB, Mälarenergi AB, Sollefteåforsens AB, Karlstads Energi AB, Jönköping Energi AB deltar i HUVA för etappen 2016-2018.

Här redovisas resultat och slutsatser från ett projekt inom ett forskningsprogram som drivs av Energiforsk. Det är rapportförfattaren/-författarna som ansvarar för innehållet.

Sammanfattning

I denna rapport presenteras en studie som syftar till att förbättra prestandan hos multimetodmodellen även kallad "Hydrological Seasonal Forecast System" (Foster et al., 2015; Olsson et al., 2011) genom bearbetning av dess statistiska metod. Den statistiska metoden använder samband mellan vårflodsvolymer och flera olika atmosfäriska prediktorvariabler samt snö. Studien syftar till att undersöka om ett förfinat urval av den prediktorvariabeldata som används kan förbättra prediktionsförmågan av vårflodsvolymer.

Multimetodmodellen (Foster et al., 2015; Olsson et al., 2011) genererar säsongs- och vårflodsprognoser baserade på flera olika prognosmetoder. Dess statistiska metod, s.k. statistisk nedskalning av ackumulerat vårflöde, använder samband mellan flera atmosfäriska prediktorvariabler (tryckfälls-, temperatur-, strålning- och fuktvariabler), snö och ackumulerat vårflöde (Olsson et al., 2011). Statistiska samband tas fram för varje prediktorvariabel, prognosmånad och prognosregion (s.k. cluster). I sin nuvarande form använder den statistiska metoden atmosfärisk prediktorvariabeldata med en upplösning av $1^{\circ} \times 1^{\circ}$ inom den geografiska domänen 75°W till 75°E och 80°N till 30°N .

Studien syftar till att undersöka om ett förfinat urval av prediktorvariabeldata förbättrar multimetodmodellens prestanda. Urval (filtrering) av beräkningspunkter för prediktorvariabler sker genom användningen av ett relativt tröskelvärde (baserade på korrelationkoefficienter).

Resultatet av studien visar att filtrering av prediktorvariabeldata leder till blandade resultat för multimetodmodellens prognostiseringsförmåga; en minskning av prognosvolymfelet med i genomsnitt 1%, samtidigt som frekvensen för vilken multimetodmodellen presterar bättre än traditionella långtidsprognoser med IHMS¹ reduceras med ~9%.

¹ Gränssnitt vid HBV-modellering

Summary

In this study the statistical method of the multimethod-model or "Hydrological Seasonal Forecast System" (Foster et al., 2015; Olsson et al., 2011) was further developed in order to improve on the models' forecasting skill. The statistical method uses correlations between the spring flood volume, several atmospheric predictors and snow. The study aim was to investigate if a refined selection of predictor data improves the models' forecasting skill.

The multimethod-model (Foster et al., 2015; Olsson et al., 2011) combines three different approaches to seasonal forecasting into a seasonal- and spring flood ensemble forecast. One of the methods is statistical downscaling of accumulated inflow. The method uses statistical relationships to relate several atmospheric predictors (pressure-field, temperature, radiation- and moisture variables) and snow to accumulated inflow (Olsson et al., 2011). Statistical relationships are developed for each predictor, forecasting month, and forecasting region (cluster). Currently, the statistical model uses atmospheric predictor data with a resolution of $1^\circ \times 1^\circ$ within the domain 75°W till 75°E och 80°N till 30°N .

This study focuses on investigating if a refined use of predictor data could improve the forecasting skill of the multimethod-model. The selection (pre-filtering) of spatially and temporally distributed predictor data was made based on relative thresholds (based on the value of correlation coefficients).

The study results show that pre-filtering of predictor data yields mixed results with regards to the forecasting skill of the multimethod-model, e.g. the volume error of the forecast can be reduced by 1% on average but the frequency with which the multimethod-model outperforms IHMS is reduced by ~9%.

Innehåll

1	Inledning	7
1.1	Multimetodmodellen och dess statistiska metod	7
1.1.1	Statistisk nedskalning av ackumulerat vårflöde	7
2	Metodik och data	10
2.1	Data	10
2.2	Val av geografisk domän	12
2.3	Korsvalidering	12
2.4	Bootstrapping	12
2.5	Prestandautvärdering	13
2.5.1	Utvärderingsmått för medelabsolutfel (MAESS)	13
2.5.2	Frekvens för överpresterande år (FY*)	13
2.5.3	Nash–Sutcliffe modelleffektivitetsmått (NSE)	14
2.5.4	Utvärderingsmått för relativ operativ egenskap (ROCSS)	14
3	Resultat	16
4	Diskussion och slutsatser	18
5	Referenser	19
6	Appendix I	20
7	Appendix II	21
8	Appendix III	24
9	Appendix IV	32
10	Appendix V	34
11	Appendix VI	36

1 Inledning

Multimetodmodellen även kallad "Hydrological Seasonal Forecast System" (Foster et al., 2015; Olsson et al., 2011) genererar säsongs- och vårflodsprognoser baserade på flera olika prognosmetoder. I denna rapport presenteras en studie som genomförts för att förbättra multimetodmodellens statistiska metod. Den statistiska metoden använder samband mellan vårflodsvolymer och flera olika prediktorvariabler (tryckfälts-, temperatur-, strålnings- och fuktvariabler). Studien syftar till att förbättra prestandan hos den statistiska metoden, och därmed multimetodmodellen, genom att förfinas urvalet av prediktorvariabeldata.

1.1 MULTIMETODMODELLEN OCH DESS STATISTISKA METOD

1.1.1 Statistisk nedskalning av ackumulerat vårflöde

Statistiska metoder för hydrologiska säsongsprognoser använder empiriska samband för att prediktera vårflodsvolymer, utifrån en eller flera förklarande variabler s.k. prediktorvariabler. I multimetodmodellens statistiska metod är prediktorvariablerna snö samt tryckfälts-, temperatur-, strålnings- och fuktvariabler som representerar storskalig atmosfärisk cirkulation (Olsson et al., 2011). Samtliga atmosfäriska prediktorvariabler som tillämpas anges i Appendix I, Tabell 3 (Foster et al., 2015). Eftersom metoden utgår från storskalig atmosfärisk cirkulation för att prediktera vårflodsvolymer för kraftverksmagasin kallas den för statistisk nedskalning.


Den statistiska metodens geografiska domän

Prediktorvariabeln snö erhålls från HBV-modellens beräknade snömagasin på prognosdagen (Foster et al., 2015). Värden för de atmosfäriska prediktorvariablerna (i form av månadsmedelvärden) erhålls från det europeiska vädercentret ECMWF² och dess säsongsprognoser genererade med ECMWFs säsongsprognossystem, version 4 (Molteni et al., 2011). I nutid består säsongsprognoserna av 51 stycken ensemble medlemmar (prognosutfall) för varje prediktorvariabel. Sparade och återskapade prognoser innehåller endast 15 medlemmar, och därför användes 15 ensemble medlemmar per prediktorvariabel för utveckling och tester. Månadsmedelvärdena för de atmosfäriska prediktorvariablerna beräknas för perioden från prognosdatum till sista juli, och med en upplösning av $1^{\circ} \times 1^{\circ}$ inom den geografiska domänen (75°W till 75°E och 80°N till 30°N) som visas i Figur 1.

Statistiska samband mellan ackumulerat vårflöde och prediktorvariabler tas fram (kalibreras/tränas) för varje prediktorvariabel, prognosmånad och region (cluster). Figur 1 visar den geografiska regionsindelning som används för statistisk regression. En lista över regionstillhörighet för enstaka prognosområden finns i

² European Centre for Medium-Range Weather Forecasts

Appendix II, Tabell 4. Prognosområdena som ingår i denna studie är indelade i tre grupper definierade av Foster & Uvo (2012), samt Foster et al. (2016), som cluster 1 (S^1), cluster 2 (S^2) och cluster 3 (S^3). Antalet prognosområden inom dessa cluster är 25, 19, respektive 40. Dessa tre cluster utgör den "nordliga gruppen" för den regionsindelning av Sverige i fem storregioner (två sydliga och tre nordliga regioner) identifierade utifrån liknande flödesvariabilitet (Foster & Uvo, 2012; Foster et al., 2016). För den nordliga gruppen är påverkan av nederbörd i form av snö dominerade för de hydrologiska processerna, medan den sydliga gruppen påverkas mer av regn. I namngivningen avspeglas detta beroende med S (för snö) för den nordliga gruppens cluster, och ett superskript som anger den relativa inverkan av snö på de hydrologiska processerna inom den nordliga gruppen. Under vintermånaderna faller nederbörd mestadels i form av snö och lagras i snötäcket utan direkt bidrag till vattenföringen. Under de varmare vårmånaderna när temperaturen stiger över noll grader börjar snötäcket smälta. Detta sker vanligtvis omkring mitten till slutet av april, och resulterar i en period med hög vattenföring s.k. vårflöde. Prognostisering av det ackumulerade flödet under denna period, d.v.s. vårflodsvolymen är i fokus.



Figur 1– (Till vänster) domän för prediktorvariabler, (till höger) prognosområden och regionindelning; blåmarkerade prognosområden (cluster 1), grönmärkade prognosområden (cluster 2) och rödmärkade prognosområden (cluster 3).

Statistisk nedskalning

Den statistiska nedskalningsmetoden som multimetodmodellen använder sig av för hydrologiska säsongsprognoser är singularvärdesfaktorisering även kallad singularvärdesuppdelning, SVD³ (Foster et al., 2015). Den statistiska metoden relaterar vårflodsvolymen till förändringar i prediktorfältvariablerna. Vid SVD av korskovariansmatriserna för responsvariabelns och prediktorvariabelns fält erhålls två matriser av singulara vektorer och en uppsättning av singularvärden. Singularvektorerna beskriver rumsliga förändringar inom varje fält, vars kovarians anges av singularvärdet. Från ett singularvektorpar kan tidsförändringar för varje fält erhållas genom att projicera data på lämplig singular vektor (Bretherton et al., 1992). Sambanden mellan responsvariabel och prediktorvariabler erhålls genom att

³ Singular Value Decomposition

beräkna regressionskoefficienter som relaterar värden för prediktorvariabelns fält i tiden till beräkningspunkterna för responsvariabeln. Prognoser för responsvariabeln erhålls genom att genomföra matrismultiplikation mellan den aktuella prediktorvariabeln och regressionsmatrisen.

De prognostiserade volymerna utifrån prediktorvariabeln snö och de tre atmosfäriska prediktorvariabler som uppvisar störst prediktionsförmåga viktas sedan samman till en prognos. Vikternas värden baseras på multipel linjär regression (Foster et al., 2015).

Inom det utvecklingsprojekt som denna rapport redogör för, har syftet varit att förbättra prognostiseringsförmågan, d.v.s. prestandan, hos den statistiska metoden genom att förfina urvalet av den prediktorvariabeldata som används. I den nuvarande utformningen används prediktorvariabeldata för beräkningspunkter inom en vidsträckt geografisk domän (75°W till 75°E och 80°N till 30°N). Genom att förfina urvalet av prediktorvariabeldata, d.v.s. eliminera beräkningspunkter som uppvisar en låg korrelation till responsvariabeln (vårflodsvolym), och endast använda de beräkningspunkter som uppvisar ett högt prediktivt värde erhålls ett mer representativt statistiskt underlag och modellens prestanda förväntas höjas.

2 Metodik och data

Arbetsgången för studien beskrivs översiktligt i punkterna nedan, för mer detaljerad beskrivning av enskilda arbetssteg finns hänvisningar till efterföljande avsnitt:

- Val av ett relativt tröskelvärde (avsnitt 2.2).
- Framtagande av korrelationskartor.
- Prognosberäkningar med historisk data:
 - Särskiljning av data (avsnitt 2.1) som träningsdata och valideringsdata (LOOCV, avsnitt 2.3). Data från perioden 1981-2015 minus ett år (som är valideringsdata) väljs ut som träningsdata. Steget upprepas för samtliga år inom perioden.
 - Framkörning av prognoser för samtliga månader och år (1981-2015) baserad på vald träningsdata i föregående steg.
 - Från resultatet i föregående steg plockas 35 prognoser slumpmässigt ut för perioden 1981-2015 (Bootstrapping, avsnitt 2.4). Utifrån dessa 35 beräknas flera prestandautvärderingsmått (definierade i avsnitt 2.5). Detta steg upprepas 10000 gånger för att kunna beräkna verifieringsmått för en viss signifikansnivå.
- Beräkning av medianvärden för respektive utvärderingsmått, baserat på de 10000 värdena beräknade i föregående steg.

2.1 DATA

I studien ingår 84 prognosområden, fördelade över sju älvar belägna i norra Sverige (Figur 1). Vattenföringsdata för dessa prognosområden finns tillgänglig i SMHI:s arkiv för tidsperioden 1961 till och med senast föregående hydrologiska år. För studien användes vattenföringsdata från tidsperioden 1961-2015. Tillrinning, Q_{in} beräknas genom att addera lokal tillrinning, Q_{lokal} , till förändringen i magasinet, ΔS , och subtrahera inflödet från uppströms prognosområden, $Q_{uppströms}$, enligt Formel 1.

Formel 1

$$Q_{in} = \Delta S + Q_{lokal} - Q_{uppströms}$$

Då vattenföringsdata saknades beräknades dessa med multipel linjär regression, med modellerad vattenföringsdata för det aktuella prognosområdet och observerad vattenföringsdata för närliggande prognosområden som prediktorvariabler. Av de 84 prognosområden som ingick i studien var databortfallet; <1% för 68 av dessa (varav 50 med fullständig data), 1-10% för fyra av dessa, 20-30% för fem av dessa, 30-40% för fyra av dessa, samt 61%, 63%, respektive 71% för tre av dessa. Trots ett relativt stort databortfall för vissa områden inkluderades alla prognosområden i studien eftersom de ingår i det operationella prognossystemet. NSE-medelvärde för den data som beräknades

med multipel linjär regression var 0.70, vilket indikerade att detta tillvägagångssätt var godtagbart.

Daglig nederbörds- och temperaturdata som användes i studien hämtades från SMHIs databas PTHBV (Johansson, 2002). PTHBV är en griddad databas för nederbörds- och temperaturdata (från 1961- nutid) med upplösningen 4x4 km som erhållits genom optimal interpolation med höjd- och vindkorrektion (Johansson, 2002). I Tabell 1 visas karaktäristik för prognosområden tillhörande olika cluster, statistik för vårflodsvolym, och mått för den prediktiva förmågan (vid HBV-modellering). Tabell 1 visar en statistisk ökning av vårflodsvolymen för cluster S³ jämfört med för cluster S² och cluster S¹. Den ökande vårflodsvolymen beror av inverkan av höjd och breddgrad som styr snöns påverkan på de hydrologiska processerna. Prognosområden som tillhör cluster S¹ ligger generellt på en lägre breddgrad eller höjd jämfört med de som tillhör cluster S², och detsamma gäller för prognosområden som tillhör cluster S² jämfört med prognosområden som tillhör cluster S³. De värden för NSE⁴ och rMAE⁵ som anges i Tabell 1 indikerar att HBV-modellen generellt är väl kalibrerad och ger bra resultat för de flesta prognosområden, men att lägre prestanda för vissa prognosområden kan bero på behov av omkalibrering, eller osäkerhet i vattenförings-, nederbörds- eller temperaturdata.

Tabell 1 – Allmän information om prognosområden tillhörande olika regioner (cluster) och HBV-modellens prestanda för dessa

Region (cluster)		Area (km ²)	Höjd (möh)	Vårflodsvolym (m ³ x10 ⁸)			HBV	
				min	medel	max	NSE (%)	rMAE
S ¹	min	233	135	0,21	0,42	0,82	-0,47	3,9
	medel	1827	282	1,27	3,23	5,30	0,74	11,2
	max	6258	584	18,95	34,36	44,36	0,95	44,5
S ²	min	184	429	0,40	0,81	1,68	-0,69	6,2
	medel	1166	598	2,49	3,80	4,77	0,66	10,2
	max	4272	666	9,99	13,56	18,17	0,83	70,1
S ³	min	270	212	0,67	1,12	1,54	0,22	3,8
	medel	1309	586	2,96	5,41	7,95	0,74	7,3
	max	13177	776	19,39	37,76	48,50	0,92	20,0

⁴ Nash–Sutcliffe modelleffektivitetsmått (avsnitt 2.5.3)

⁵ Relativt medelabsolutfel (avsnitt 2.5.1)

2.2 VAL AV GEOGRAFISK DOMÄN

Kovariansanalyser, d.v.s. analyser av samvariationen mellan en specifik prediktorvariabel och vårflödesvolymen, genomfördes för alla prediktorvariabler (för samtliga beräkningspunkter med $1^{\circ} \times 1^{\circ}$ upplösning inom den geografiska domänen i Figur 1). Kovariansanalysen visade om en linjär relation existerar mellan en specifik prediktorvariabels beräkningspunkt och vårflödesvolymen. Från kovariansanalys erhålls korrelationskoefficienter för samtliga beräkningspunkter som varierar i värde mellan 1 och -1, där 0 tyder på att inget linjärt samband existerar, 1 visar på ett mycket stark (maximal) positiv samvariation, och -1 visar på ett mycket stark (maximal) negativ samvariation mellan prediktorvariabeln och vårflödesvolymen. Resultaten från kovariansanalyserna åskådliggjordes i korrelationskartor⁶. Ett urval (filtrering) av beräkningspunkter gjordes därefter genom att eliminera de beräkningspunkter som uppvisade korrelationskoefficienter, ρ , under ett visst tröskelvärde beräknat enligt Formel 2.

Formel 2

$$\text{tröskelvärde} = \frac{\max|\rho|}{2}$$

2.3 KORSVALIDERING

En utmaning i studien var att genomföra en robust modellutvärdering på en begränsad datamängd (35 vårflöden mellan år 1981-2015) och minimera risken för instabilitet och överparametrisering hos modellen. Således användes LOOCV (leave-one-out cross-validation) som modellutvärderingsmetod. LOOCV är en modellutvärderingsmetod som (för en datamängd av n) använder $n-1$ data för kalibrering och den återstående för validering. Processen återupprepas n gånger, vilket ger ett datamängd av längd n . Eftersom det inte är möjligt att omkalibrera HBV-modellen inför varje steg i LOOCV-processen används samma perioder för träning som för kalibrering och validering av HBV-modellen. LOOCV möjliggör en mer robust utvärdering vid begränsad datamängd och ger ett bredare träningsintervall än vid traditionell kalibrering/validering. Detta är speciellt fördelaktigt för den statistiska nedskalningsmetoden som kan bli instabil för förhållanden som inte ingått i träningsintervallet.

För att utvärdera olika prognosmånader, utvärderades historiska modellframkörningar⁷ med start från den första januari, första februari, första mars, första april och första maj (och fram till och med sista juli) för vårflöden mellan år 1981-2015. Utvärderingen avser hur väl vårflödesvolymen prognostiseras.

2.4 BOOTSTRAPPING

På grund av studiens begränsade datamängd användes bootstrap-metoden för att verifiera statistiskt signifikanta resultatförändringar vid beräkning av verifieringsmått (angivna i avsnitt 2.5). Detta för att erhålla ett bestämt intervall inom vilket

⁶ Exempel på korrelationskartor före och efter urval av beräkningspunkter visas i Appendix III.

⁷ Hindcast, d.v.s. modellframkörningar som simulerade prognoser för historiska år.

resultatet infaller med viss statistisk säkerhet. För beräkning av verifieringsmått samplades de korsvaliderade historiska modellframkörningarnas⁸ ensemble 10000 gånger. En restriktiv signifikansnivå på 0,1 valdes även beroende av detta, vilket resulterade i 90% konfidensintervall mellan de 5:e och 95:e percentilerna. En förändring i resultat definierades som signifikant om den 5:e (95:e) percentilen av den utvalda bootstrappade ensemblen som utvärderades inte överlappade den 95:e (5:e) percentilen av den bootstrappade referensensemblen.

2.5 PRESTANDAUTVÄRDERING

För att studera förändring i prestanda hos den statistiska metodens prestanda och därmed multimetodmodellens prognostiseringsförmåga vid val av en specifik geografisk domän användes flera olika statistiska utvärderingsmått. De olika utvärderingsmåten speglar olika aspekter av prestandan och ger tillsammans en mer heltäckande bild av allmänprestandan.

2.5.1 Utvärderingsmått för medelabsolutfel (MAESS)

Val av utvärderingsmått grundas på att studien baseras på en begränsad datamängd, 35 stycken (antal vårflöden mellan år 1981-2015) korsvaliderade historiska modellframkörningar⁸ för varje prognosområde. På grund av den begränsade datamängden valdes som utvärderingsmått för prognosens medelabsolutfel det s.k. MAESS (Mean Absolute Error Skill Score). Genom att anta att den deterministiska prognosen är lika med medelvärdet för ensemblen beräknas MAESS enligt Formel 3.

Formel 3

$$MAESS = 1 - \frac{MAE_f}{MAE_r}$$

Där f och r betecknar prognos, respektive referens och MAE definieras enligt Formel 4.

Formel 4

$$MAE = \frac{1}{n} \sum_{y=1}^n \left| \frac{SFV_o^y - SFV_f^y}{SFV_o^y} \right|$$

Där y betecknar år, n betecknar det totala antalet år, och o betecknar observationer. Värdet för MAESS varierar mellan $-\infty$ och 1, där positiva värden indikerar förbättrad prediktionsförmåga jämfört med referensprognosen och ett värde lika med ett indikerar en perfekt prognos.

2.5.2 Frekvens för överpresterande år (FY⁺)

Olsson et al. (2016) föreslog användning av FY⁺ (frequency of years) som ett komplement till MAESS (avsnitt 2.5.1). Utvärderingsmåten kompletterar varandra då MAESS indikerar hur mycket bättre prognosutfallet är än referensprognosen utfall, medan FY⁺ indikerar frekvensen, hur ofta prognosutfallet är bättre, d.v.s.

⁸ Modellframkörning med observerad indata eller prognosdata för jämförelse av modellens utdata och observation.

hur ofta det absoluta felet är lägre. Värden för FY^+ varierar från 0 till 100%. Värden över 50% indikerar att multimetodmodellens prognosutfall generellt överträffar referensprognosens utfall. Genom att anta att den deterministiska prognosen är lika med medelvärdet för ensemblen beräknas FY^+ enligt Formel 5.

Formel 5

$$FY^+ = \frac{100}{n} \sum_{y=1}^n H^y$$

Där H är enhetsstegfunktionen (eller Heaviside-funktionen) definierad enligt Formel 6 där AE är det absoluta felet.

Formel 6

$$H^y = \begin{cases} 0, & AE_r^y < AE_f^y \\ 1, & AE_r^y > AE_f^y \end{cases}$$

2.5.3 Nash–Sutcliffe modelleffektivitetsmått (NSE)

NSE (Nash–Sutcliffe model Efficiency) är ett normaliserat mått som anger den relativa storleken mellan residual varians och varians för observerad mätdata (Nash & Sutcliffe, 1970). Värden för NSE varierar mellan $-\infty$ och 1, där 1 är en perfekt prognos och värden över 0 indikerar att prognosutfallet är bättre än för en historisk ensemble prognos. För denna studie kan måttet tolkas som hur väl prognostiserad vårflodsvolym (SFV^y) överensstämmer med observerad vårflodsvolymer år till år och är således ett komplement till MAESS och FY^+ . Genom att anta att den deterministiska prognosen är lika med medelvärdet för ensemblen beräknas NSE enligt Formel 7.

Formel 7

$$NSE = 1 - \frac{\sum_{y=1}^n (SFV_o^y - SFV_f^y)^2}{\sum_{y=1}^n (SFV_o^y - \overline{SFV_o})^2}$$

För att utvärdera prediktionsförmågan för multimetodmodellen, jämfört med den för historiska (referens) ensemblen, beräknas skillnaden i NSE enligt Formel 8.

Formel 8

$$\Delta NSE = NSE_f - NSE_r$$

Värden för $\Delta NSE > 0$ indikerar att prediktionsförmåga för multimetodmodellens prognos är bättre än för referensprognosen.

2.5.4 Utvärderingsmått för relativ operativ egenskap (ROCSS)

ROCSS (relative operating characteristic skill score) är ett utvärderingsmått som baseras på arean under kurvan, den s.k. AUC, i ett relativt operativ egenskapsdiagram. Värden för ROCSS < 0 indikerar att prognosutfallet är sämre än för en historisk ensemble prognos, medan värden > 0 indikerar att prognosutfallet är bättre, och 1 indikerar en perfekt prognos. Diagrammet visar förmågan hos prognosensemblen att särskilja en händelse och icke-händelse givet ett specifikt

⁹ Spring Flood Volume

tröskelvärde. I denna studie beräknades ROCSS för den övre tertilen ($x \geq 66.7\%$), mitten tertilen ($66.7\% < x \leq 33.3\%$) och den nedre tertilen ($x < 33.3\%$). Dessa värden anger förmågan hos ensembleprognoser att särskilja händelser som är under normal (BN¹⁰), nära normal (NN¹¹), och över normal (AN¹²). ROCSS beräknas enligt Formel 9.

Formel 9

$$ROCSS = 2 \cdot AUC - 1$$

Där AUC beräknas enligt Formel 10 (Hamill & Juras, 2006) och representerar arean under den kurva som skapas när antal korrekt prognostiserade händelser (s.k. HR=hit rate) plottas mot felaktigt prognostiserade händelser (FAR = false alarm rate). I definitionen för felaktigt prognostiserade händelser ingår både positiva och negativa prognoser, även kallade typ I- och typ II-fel.

Formel 10

$$AUC = \sum_{y=1}^{n+1} \frac{(FAR_y - FAR_{y-1})(HR_y - HR_{y-1})}{2}$$

¹⁰ Below Normal

¹¹ Near Normal

¹² Above Normal

3 Resultat

Vid urval (filtrering) av prediktorvariablernas beräkningspunkter kan absoluta tröskelvärden användas, men detta innebär antingen att ett tillräckligt lågt tröskelvärde måste väljas för att garantera ett urval av adekvat antal beräkningspunkter, eller att olika tröskelvärden väljs för olika prediktorvariabler och prognosmånader. I denna studie tillämpades istället ett relativt tröskelvärde (avsnitt 2.2, Formel 2), som visade sig ge en bra avvägning mellan modellprestation och modellstabilitet. Korrelationskartor (före och efter filtrering av prediktorvariablernas beräkningspunkter) har tagits fram för varje prediktorvariabel, prognosmånad och cluster. I Appendix III visas ett urval av dessa korrelationskartor.

Studiens resultat visar att samtaget för cluster 1-3 resulterade användning av filtrerad (jämfört med samtlig) prediktorvariabeldata i en blygsam förbättring av multimetodmodellens allmänna prestanda i avseende på volymfel och förmåga att fånga årliga variationer. Däremot visar resultaten att användning av filtrerad prediktorvariabeldata ger en minskad frekvens för när multimetodmodellen är bättre än IHMS. Resultaten i Tabell 2 indikerar att vid användning av filtrerad (jämfört med samtlig) prediktorvariabeldata erhålls:

- En minskning (~9%) i den frekvens med vilken multimetodmodellen är bättre än IHMS (kolumn 1).
- En ytterligare minskning av volymfelet med 1% jämfört med då samtliga beräkningspunkter används (kolumn 2).
- En generell förbättring av multimetodmodellens förmåga att fånga den årliga variationen (kolumn 3).
- En svag försämring i multimetodmodellens förmåga att särskilja vårflöden under det normala (kolumn 4).
- En svag förbättring i multimetodmodellens förmåga att särskilja vårflöden nära det normala (kolumn 5).
- En svag försämring i multimetodmodellens förmåga att särskilja vårflöden som är över det normala (kolumn 6).

Tabell 2 – Förändring av multimetodmodellens prestanda vid användning av filtrerad jämfört med samtlig prediktorvariabeldata

	ΔFY^+ (%)	$\Delta MAESS$ (-)	ΔNSE (-)	ROCSS		
				ΔBN (-)	ΔNN (-)	ΔAN (-)
jan	-7,5	0,02	0,03	-0,01	0	-0,02
feb	-8,7	0,01	0,02	-0,02	0,01	-0,02
mar	-8,6	0,01	0,01	-0,02	0,03	-0,02
apr	-8,7	-0,01	-0,02	-0,07	0,01	-0,03
maj	-13,1	0	0	-0,05	0	-0,02

Beräknade värden för utvärderingsmått FY^+ , medelabsolutfel (MAESS) och ΔNSE redovisas i Appendix IV för enskilda cluster. I Appendix V redovisas beräknade värden för $\Delta ROCSS$ för enskilda cluster. I Appendix VI redovisas förändringen för de olika utvärderingsmått vid användning av filtrerad jämfört med samtlig prediktorvariabeldata.

Att endast använda ett urval av beräkningspunkter hade ett blandat resultat på multimetodmodellens förmåga att särskilja mellan under-, nära- och övernormala vårflöden (avsnitt 2.5.4). För cluster 1 visar resultatet i Tabell 5 (Appendix VI) att en allmän förbättring av förmågan att diskriminera mellan under-, nära- och övernormala vårflöden erhålls. En liknande förbättring uppvisas för nära normala händelser för cluster 1 och 2 medan en allmän minskning av förmågan att prediktera under- och övernormala förhållanden erhålls. För detta ändamål finns det följaktligen inget mervärde i att använda det begränsade urvalet av beräkningspunkter för prognosområden i cluster 2 eller 3.

Studiens resultat presenteras för enskilda s.k. cluster (regioner) och inte för enskilda älvar. Detta betyder att resultatet för enstaka prognosområden inom ett cluster kan särskilja sig från det generella resultatet. Analysen ger dock en överblick av det mervärde som urval av prediktorvariablers beräkningspunkter har för multimetodmodellens prognostiseringsförmåga.

4 Diskussion och slutsatser

Den statistiska metod som multimetodmodellen tillämpar, s.k. statistisk nedskalning av ackumulerat vårflöde, använder samband mellan flera atmosfäriska prediktorvariabler (tryckfälts-, temperatur-, strålnings- och fuktvariabler angivna i Appendix I, Tabell 3), snö och ackumulerat vårflöde (Olsson et al., 2011) för säsons- och vårflodsprogoser. De statistiska sambanden tränas för varje prediktorvariabel, prognosmånad och cluster (regionsindelning av prognosområden). För nuvarande används atmosfärisk prediktorvariabeldata med en upplösning av $1^{\circ} \times 1^{\circ}$ inom den geografiska domänen 75°W till 75°E och 80°N till 30°N . Resultatet av denna studie visar att en begränsning (filtrering) av antalet beräkningspunkter för prediktorvariabeldata har en blandad inverkan på multimetodmodellens prestanda. Vid filtrering av prediktorvariabeldata jämfört med utan filtrering erhöles en minskning av prognosvolymfelet med 1%. Samtidigt förbättrades multimetodmodellens förmåga att fånga den årliga variationen, d.v.s. NSE förbättrades med ungefär 1%. Däremot minskade frekvensen för vilken multimetodmodellen var bättre än IHMS (HBV-modellens) prognosutfall med i genomsnitt 9%. Filtrering av prediktorvariabeldata gav multimetodmodellen en ökad förmåga att särskilja näranormala vårflöden från under- och övernormala, men en minskad förmåga att särskilja icke-normala.

Sammantaget kan konstateras att filtrering av den statistiska metodens prediktorvariabeldata inte ger en klar förbättring av multimetodmodellens allmänprestanda, dock förbättras vissa aspekter av prestandan. Den förbättrade prognostiseringsförmågan i avseende på volymfel är en genomsnittlig förbättring för samtliga cluster (regioner), resultatet för enskilda prognosområden inom ett cluster kan särskilja sig från det generella resultatet. För enskilda prognosområden kan filtrering av prediktorvariabeldata innebära en förbättring, men för att optimera och dra nytta av förbättringar behövs individuella modelluppsättningar för prognosområdena, d.v.s. istället för att de statistiska sambanden tränas för varje prediktorvariabel, prognosmånad och cluster bör sambanden tränas för varje prediktorvariabel, prognosmånad och prognosområde.

Urvalet (filtreringen) av beräkningspunkter för prediktorvariablerna baserades på användning av ett relativt tröskelvärde. Användning av ett relativt tröskelvärde visade sig ge en bra avvägning mellan modellprestation och modellstabilitet. Fortsatt utvecklingsarbete skulle dock kunna syfta till att ytterligare förfinas och verifiera tröskelvärden för urval av beräkningspunkter. Även en analys av hela det norra halvklotet som startdomän istället för den nuvarande Atlanten-Europeiska domänen (75°W till 75°E och 80°N till 30°N) är av intresse.

5 Referenser

- Bretherton, C. S., Smith, C., & Wallace, J. M. (1992). An intercomparison of methods for finding coupled patterns on climate data. *J. Clim.* 5, 541-560.
- Foster, K., & Uvo, C. B. (2012). Regionalisation of Sweish hydrology. *XXVII Nordic Hydrology Conference*. Oulu.
- Foster, K., Uvo, C. B., & Olsson, J. (2016). The spatial and temporal effect of selected teleconnection phenomena on Swedish hydrology. *Submitted to Clim. Dyn.*, 2016.
- Foster, K., Uvo, C., Olsson, J., & Södling, J. (2015). *Hydrological seasonal forecast system - a prototype multi-model system for forecasting the spring flood*. Energiforsk, Report 2015:206.
- Hamill, T. M., & Juras, J. (2006). Measuring forecast skill: is it real skill or is it the varying climatology? *Q. J. R. Meteorol. Soc.* 132, 2905-2923.
- Johansson, B. (2002). *Estimation of areal precipitation for hydrological modelling*, PhD thesis, Earth Sciences Centre, Report no. A76. Göteborg University, Göteborg.
- Molteni, F., Stockdale, T., Balmaseda, M., Balsamo, G., Buizza, R., Ferranti, L., . . . Vitart, F. (2011). *The new ECMWF seasonal forecast system (System 4)*, ECMWF tech. Memo., 656, 49 pp. Hämtat från <http://www.ecmwf.int/sites/default/files/elibrary/2011/11209-new-ecmwf-seasonal-forecast-system-system-4.pdf> den 29 Augusti 2016
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I - A discussion of principles. *Journal of Hydrology*, 10(3), 282-290. doi:10.1016/0022-1694(70)90255-6.
- Olsson, J., Uvo, C. B., Foster, K., & Yang, W. (2016). Technical Note: Initial assessment of a multi-method approach to spring-flood forecasting in Sweden. *Hydrology and Earth System Sciences*, 20(2), 659-667.
- Olsson, J., Uvo, C. B., Foster, K., Yang, W., Södling, J., German, J., & Johansson, B. (2011). *A multi-model system for spring flood forecasts*. Elforsk, Report 11:72.

6 Appendix I

I Tabell 3 nedan anges den statistiska metodens samtliga atmosfäriska prediktorvariabler och deras förkortningar.

Tabell 3 – Atmosfäriska prediktorvariabler

Prediktorvariabel	Förkortning
850 hPa geopotential höjd	q
temperatur vid 850 hPa	t
zonal vindkomponent vid 850 hPa	u
meridional vindkomponent vid 850 hPa	z
specifik fuktighet vid 850 hPa	m
sensibelt värme flöde	sshf
latent värme flöde	slhf
medelhavsytetryck	msl
zonal vindkomponent vid 10 m höjd	10v
meridional vindkomponent vid 10 m höjd	10u
temperatur vid 2 m höjd	2t
total nederbörd	tp

7 Appendix II

Älvar och prognosområdets regionstillhörighet visas i Tabell 4.

Tabell 4 – Älvarnas prognosområden och regiontillhörighet

Älv	Prognosområde	Region (cluster)
Luleälven	Sitasjaure	3
	Satishaure	3
	Suorva	3
	Porjus	3
	Messaure	3
	Tjaktjajaure	3
	Parki	3
	Letsi	3
	Boden	1
Skellefteälven	Sädvajaure	3
	Riebnesjaure	3
	Hornavan	3
	Uddjaur-Storavan	3
	Bergnäs-Vargfors	1
	Vargfors-Rengård	1
	Rengård-Kvistfors	1
Umeälven	Överuman	3
	Göuta-Ajaure	3
	Abelvattnet	3
	Gardiken	3
	Storuman	3
	Storjuktan	3
	Bålforsen	3
	Harrsele	1
	Laisvall	3
	Sorsele	3
	Vindeln	1
	Stornorrfors	3
	Ransaren	3
Ångermanälven	Kultsjön	3
	Malgomaj	3
	Stenkullafor	3
	Hällby	1
	Lasele	1


Älv	Prognosområde	Region (cluster)
Indalsälven	Rörströmssjön	3
	Borgasjön	3
	Dabbsjön	3
	Storsjouten	3
	Korsselet	3
	Tåsjön	3
	Flåsjön	3
	Lesjön	1
	Vängelsjön	1
	Kilforsen	1
	Ankarvattnet	3
	Blåsjön	3
	Jormsjön-Kycklingvattnet	3
	Limingen	3
	Kvarnbergsvattnet	3
	Bågede	3
	Lövön	3
	Ramsele	1
	Hjälta	1
	Sollefteå	1
	Torrön	2
	Anjan	2
	Kallsjön	2
	Östra Noren	2
	Liten	2
	Häckren	2
	Näkten	2
	Storsjön	2
	Stora Mjölkvattnet	2
	Övre Oldsjön	2
	Landösjön	2
	Rörvattnet	2
	Rengen	2
	Hotagen	2
	Midskog	2
	Gesunden	1
	Hammarforsen	1
	Oxsjön	1

Älv	Prognosområde	Region (cluster)
Ljungan	Bergeforsen	1
	Storsjön	2
	Flåsjön	2
	Lännässjön	1
	Torpshammar	1
	Viforsen	1
Ljusnan	Grundsjön	2
	Lossen	2
	Lofssjön	1
	Svegsjön	1
	Dönje	1
	Alfta	1


8 Appendix III

Nedan visas korrelationskartor före och efter urval av beräkningspunkter baserat på det tröskelvärde som definieras i avsnitt 2.2, Formel 2. Korrelationskartor har beräknats för varje prediktorvariabel, prognosmånad och cluster, här visas ett urval av dessa korrelationskartor.

I Figur 2-Figur 3 visas korrelationskartor för prediktorvariabeln 850 hPa geopotential höjd (q) för januari respektive mars månad och cluster 1. Förändringarna i korrelationskartorna mellan de olika månaderna är märkbara.




Figur 2 – (Ovan) initial korrelationskarta för prediktorvariabeln 850 hPa geopotential höjd (q) för januari månad och cluster 1, (nedan) korrelationskarta som visar utbredningen av filtrerade beräkningspunkter som överstiger tröskelvärde.




Figur 3 – (Ovan) initial korrelationskarta för prediktorvariabeln 850 hPa geopotential höjd (q) för mars månad och cluster 1, (nedan) korrelationskarta som visar utbredningen av filtrerade beräkningspunkter som överstiger tröskelvärde.

I Figur 4-Figur 5 visas korrelationskartor för prediktorvariabeln sensibelt värmefflöde (sshf) för april respektive maj månad och cluster 2. En stor förändring av utvalda beräkningspunkter är tydlig mellan månaderna.




Figur 4 – (Ovan) initial korrelationskarta för prediktorvariabeln sensibelt värmefflöde (sshf) för april månad och cluster 2, (nedan) korrelationskarta som visar utbredningen av filterade beräkningspunkter som överstiger tröskelvärde.




Figur 5 – (Ovan) initial korrelationskarta för prediktorvariabeln sensibelt värme flöde (sshf) för maj månad och cluster 2, (nedan) korrelationskarta som visar utbredningen av filterade beräkningspunkter som överstiger tröskelvärde.

I Figur 6-Figur 7 visas korrelationskartor för prediktorvariabeln meridional vindkomponent vid 850 hPa (z) för februari respektive maj månad och cluster 3.




Figur 6 – (Ovan) initial korrelationskarta för prediktorvariabeln meridional vindkomponent vid 850 hPa (z) för februari månad och cluster 3, (nedan) korrelationskarta som visar utbredningen av filtrerade beräkningspunkter som överstiger tröskelvärde.




Figur 7 – (Ovan) initial korrelationskarta för prediktorvariabeln meridional vindkomponent vid 850 hPa (z) för maj månad och cluster 3, (nedan) korrelationskarta som visar utbredningen av filterade beräkningspunkter som överstiger tröskelvärde.

I Figur 8-Figur 9 visas korrelationskartor för prediktorvariabeln temperatur vid 2 m höjd (2t) för februari respektive april månad och cluster 3.




Figur 8 – (Ovan) initial korrelationskarta för prediktorvariabeln temperatur vid 2 m höjd (2t) för februari månad och cluster 3, (nedan) korrelationskarta som visar utbredningen av filtrerade beräkningspunkter som överstiger tröskelvärde.



Figur 9 – (Ovan) initial korrelationskarta för prediktorvariabeln temperatur vid 2 m höjd (2t) för april månad och cluster 3, (nedan) korrelationskarta som visar utbredningen av filterade beräkningspunkter som överstiger tröskelvärde.


9 Appendix IV

I Figur 10 visas ett legendschema där informationen i den typ av graf som används beskrivs.




Figur 10 – Legendschema.


I Figur 11-Figur 13 visas de beräknade värdena för utvärderingsmåten FY^+ , medelabsolutfel (MAESS) och ΔNSE för multimetodmodellens enskilda cluster vid användning av filterad prediktorvariabeldata.



Figur 11 – Beräknade värden för utvärderingsmåten FY^+ , medelabsolutfel (MAESS) och ΔNSE för olika prognosmånader för Cluster 1 vid användning av filterad prediktorvariabeldata.




Figur 12 – Beräknade värden för utvärderingsmåten FY^+ , medelabsolutfel (MAESS) och ΔNSE för olika prognosmånader för Cluster 2 vid användning av filtrerad prediktorvariabeldata.




Figur 13 – Beräknade värden för utvärderingsmåten FY^+ , medelabsolutfel (MAESS) och ΔNSE för olika prognosmånader för Cluster 3 vid användning av filtrerad prediktorvariabeldata.

10 Appendix V


I Figur 14-Figur 16 visas de beräknade $\Delta ROCS$ -värdena för multimetodmodellens enskilda cluster vid användning av filterad prediktorvariabeldata.



Figur 14 – Beräknade $\Delta ROCS$ -värden för olika prognsmånader för Cluster 1 vid användning av filterad prediktorvariabeldata.



Figur 15 – Beräknade $\Delta ROCS$ -värden för olika prognsmånader för Cluster 2 vid användning av filterad prediktorvariabeldata.



Figur 16 – Beräknade $\Delta ROCS$ -värden för olika prognsmånader för Cluster 3 vid användning av filterad prediktorvariabeldata.

11 Appendix VI

I Tabell 5 redovisas förändringen i multimetodmodellens prestanda vid användning av filtrerad jämfört med samtlig prediktorvariabeldata.

Tabell 5 – Förändring i multimetodmodellens prestanda

					ROCSS	
	ΔFY^+	$\Delta MAESS$	ΔNSE	ΔBN	ΔNN	ΔAN
Cluster 1						
jan	-6,6	0,02	0,02	0,04	0,09	0,12
feb	-6,9	0,02	0,01	0,02	0,07	0,1
mar	-9,3	0,01	0,02	0,02	0,04	0,08
apr	-6	0,01	0,03	0,04	0,07	0,12
maj	-12,8	0,01	0,03	0,01	0,33	0,1
Cluster 2						
jan	-6,3	0,03	0,03	-0,02	0,04	-0,02
feb	-12	0,01	0,01	0,06	0,05	-0,02
mar	-9,8	0,04	0,07	0,2	0,01	-0,05
apr	-12	0,02	0,04	0,16	-0,03	-0,04
maj	-15,5	0,01	0,02	0,01	0	0,01
Cluster 3						
jan	-8,8	0,02	0,03	-0,06	-0,02	-0,22
feb	-8,9	0,02	0,03	-0,14	0	-0,13
mar	-9,2	0	-0,01	-0,3	0,06	-0,05
apr	-7	-0,03	-0,06	-0,17	0,04	-0,05
maj	-11,4	0	-0,01	-0,04	-0,01	-0,02
Samtliga						
jan	-7,5	0,02	0,03	-0,01	0	-0,02
feb	-8,7	0,01	0,02	-0,02	0,01	-0,02
mar	-8,6	0,01	0,01	-0,02	0,03	-0,02
apr	-8,7	-0,01	-0,02	-0,07	0,01	-0,03
maj	-13,1	0	0	-0,05	0	-0,02

BEARBETNING AV MULTIMETOD- MODELLENS STATISTISKA METOD FÖR FÖRBÄTTRAD PRESTANDA

Multimetodmodellen även kallad "Hydrological Seasonal Forecast System" genererar prognoser för säsons- och våfloder baserat på flera olika prognosmetoder. En av dessa är en statistisk nedskalning av ackumulerat våflöde, en metod som utnyttjar sambandet mellan atmosfäriska prediktorvariabler (tryckfälts-, temperatur-, strålnings- och fuktvariabler), snö och ackumulerat våflöde.

I sin nuvarande form använder den statistiska metoden atmosfärisk prediktorvariabeldata med en upplösning av $1^{\circ} \times 1^{\circ}$ inom den geografiska domänen $75^{\circ}W$ till $75^{\circ}E$ och $80^{\circ}N$ till $30^{\circ}N$.

Resultatet av studien visar att en filtrering av prediktorvariabeldata leder till blandade resultat för multimetodmodellens prognostiseringsförmåga. Det betyder en förändrad allmänprestanda för multimetodmodellen; en minskning av prognosvolymfelet med 1 procent, samtidigt som frekvensen för vilken multimetodmodellen presterar bättre än traditionella långtidsprognoser med IHMS reduceras med 79 procent.

Ett nytt steg i energiforskningen

Energiforsk är en forsknings- och kunskapsorganisation som samlar stora delar av svensk forskning och utveckling om energi. Målet är att öka effektivitet och nyttiggörande av resultat inför framtida utmaningar inom energiområdet. Vi verkar inom ett antal forskningsområden, och tar fram kunskap om resurseffektiv energi i ett helhetsperspektiv – från källan, via omvandling och överföring till användning av energin. www.energiforsk.se