


MIdAS version 0.1

framtagande och utvärdering av ett nytt verktyg för biasjustering

Peter Berg, Thomas Bosshard, Wei Yang och Klaus Zimmermann



Pärmbild.

Bilden visar grundkonceptet för så kallad quantile mapping biasjustering.

ISSN: 1654-2258 © SMHI

KLIMATOLOGI NR 63,2021

MIdAS version 0.1

framtagande och utvärdering av ett nytt verktyg för biasjustering

Peter Berg, Thomas Bosshard, Wei Yang och Klaus Zimmermann

Granskad och Godkänd av: Renate Wilcke

Funktion: Forskare, Rossby Centre

Denna sida är avsiktligt blank

Sammanfattning

Biasjustering används för att anpassa resultaten från klimatmodeller så att de blir användbara för effektmodellering och beräkning av klimatindikatorer.

Klimatmodeller uppvisar nämligen regionala och säsongsbetonade systematiska avvikelser från observerat klimat, vilket leder till problem för effektmodeller som är kalibrerade mot observationer. Biasjusteringen består i grunden av en algoritm som beskriver hur olika värden av till exempel temperatur eller nederbörd justeras för att återskapa en långsiktig statistisk beskrivning av klimatet enligt observationerna.

Metoden MIdAS (Multi-scale bias AdjuStment) har tagits fram för biasjustering inom SMHI. En avdelningsöverskridande arbetsgrupp har genom litteraturstudie tagit fram de metoder som ligger närmast en internationell "state-of-the-art" inom biasjustering. Fokus har varit på justering av de huvudsakliga parametrar som används inom SMHI för att producera klimatindikatorer och för effektmodellering inom främst hydrologi. En utvärderingsmetodik har tagits fram för att studera olika metoders resultat för historiska och framtida data, i Sverige och olika regioner i världen. Resultaten av studien visar på att enkla metoder fungerar likvärdigt eller bättre än de mer komplexa metoderna, förutom en större påverkan på klimatsignalers magnitud i vissa situationer. Implementeringen av MIdASv0.1 är likvärdig och ofta bättre än andra metoder.

Summary

Bias adjustment is commonly applied to adjust results from climate models to make them compatible with impact models and for calculations of climate indicators. The issues arise from systematic deviations at regional and seasonal scales in climate model compared to observations. The core of a bias adjustment is an algorithm that transfers the model values toward a reference, often using a distribution of values.

The MIdAS (Multi-scale bias AdjuStment) method has been developed for bias adjustment at SMHI. A literature study was performed by a core group of researchers in different fields within SMHI to define the state-of-the-art in bias adjustment. With a focus on the main disciplines of SMHI (meteorology, hydrology and oceanography) and the parameters involved, a method for evaluation of historical and future performance was designed and applied to regions within Sweden and in several regions around the globe. The evaluation of multiple common bias adjustment methods showed that relatively simple methods perform equally well or even better than more intricate methods, besides a larger impact on the magnitude of climate change signals in some cases. The implementation of MIdASv0.1 performs generally equally and sometimes better than other analysed methods.

Innehållsförteckning

1	BAKGRUND / PROBLEMSTÄLLNING	4
2	SYFTE	5
3	METODIK	5
3.1	Urval av metoder för biasjustering	5
3.2	Utvärderingsscheman	9
3.2.1	Korsvalidering	9
3.2.2	Pseudo-reality	10
3.2.3	Utvärderingsparametrar	10
3.2.4	Rankningsmetoder	11
4	RESULTAT	12
4.1	Litteraturstudie	12
4.2	Korsvalidering	12
4.3	Pseudo-reality	14
4.3.1	Justering av regndagar	14
4.3.2	Kaskadvis biasjustering	15
4.4	Metodjämförelse	17
5	SLUTSATSER	22
6	FÖRFATTARNAS TACK	22
7	REFERENSER	22

1 Bakgrund / Problemställning

Ett ofrånkomligt faktum är att klimatmodeller av både global och regional skala uppvisar olika grader av bias; det vill säga systematiska avvikelser från en observation. Bias är ett resultat av en ofullständig beskrivning eller injustering av fysikaliska processer i modellen. Klimatsimuleringar är det främsta verktyget för att beskriva en framtida utveckling av klimatet och även med bias ger de värdefull information på global och lokal skala.

Effektmodeller är oftast kalibrerade med ett observationsdataset. När dessa modeller ska drivas av klimatmodeller för att studera framtiden kan en konsekvens av bias bli att effektmodellen felaktigt hamnar i ett visst fysikaliskt tillstånd som påverkar resultatet. Som exempel kan nämnas en hydrologisk modell som drivs av en för våt klimatmodell (som ger för mycket nederbörd med för hög frekvens) aldrig får en rimlig upptorkning av markskikten och därför ger för snabb och stor avrinning.

En biasjustering anpassar klimatmodellens tidsserier så att de följer vissa utvalda statistiska fördelningar hos observationerna. Det finns idag många olika metoder för att utföra detta. Inom SMHI har under många år metoden DBS (Distribution Based Scaling; Yang et al. 2010) använts inom allt från hydrologisk produktion, länsvisa klimatrappporter, internationella forskningsprojekt och klimattjänster. DBS bygger på en så kallad *quantile mapping*-metod där en variabls hela fördelningsfunktion, till exempel olika nederbördsintensiteter, justeras. Även om DBS presterar bra i de flesta fall, har produktionsproblem uppstått i vissa klimat och för vissa typer av bias. Delvis har problemen uppstått genom att DBS anpassar en fördelningsfunktion till data, och denna funktion kan variera kraftigt i vissa klimat eller säsonger och ge en dålig passning till det data den ska beskriva. I olika forskningssammanhang har även andra metoder för biasjustering använts, till exempel empirisk quantile mapping (EQM; Themessl et al. 2012, Wilcke et al. 2013).

I samband med produktion av klimatscenarier vid SMHI har det nya verktyget MIdAS (Multi-scale bias AdjuStment) arbetats fram som en plattform för biasjustering. Fördelen med MIdAS är att det har utvecklats för att vara flexibelt för påbyggnad med olika metoder för biasjustering, samt för att kunna hantera biasjustering på olika tids- och rumsskalor. Utvecklingen av klimatmodeller går mot allt högre rumslig upplösning, som i många fall är högre än den upplösning som lokala observationer kan ge över ett område. Det blir därför allt viktigare att kunna utföra biasjustering endast på de skalor som har stöd av observationer för att låta modellerna beskriva de finare tid och rumsskalorna. Till exempel, om en modell har upplösningen 1 km och de griddade observationerna bara 10 km, vill vi inte ”kasta bort” modellens högupplösta information om vad som sker ”mellan” gridpunkterna i observationerna. Därför utförs biasjusteringen i det fallet på 10 km, och modellens 1 km information bibehålls genom att läggas till efter biasjusteringen.

Den här rapporten beskriver

- framtagandet av grundmetodiken för MIdAS
- valet av biasjusteringsmetodik från dagens state-of-the-art
- utvärdering av metoden i olika klimat runt om i världen.

2 Syfte

Syftet med det här arbetet är att definiera vilken metodik som ska vara förstahandsval för biasjustering inom SMHI. Metodiken som tas fram ska stå på vetenskaplig grund, vara väl dokumenterad och motiverad, anpassad till SMHI:s verksamhetsområden, robust implementerad, samt utgöra en plattform för fortsatt forskning och utveckling inom biasjustering. Det är också viktigt att metodiken kan användas av hela SMHI för att skapa en konsistens i de produkter och den information och beslutsunderlag vi producerar till samhället.

Arbetet har följt två huvudspår:

- i. ny implementering från grunden av ramverket MIdAS som utvecklats på hydrologiska forskningsavdelningen
- ii. granskning och utvärdering av olika metoder för biasjustering.

Arbetet fokuserar på två tidshorisonter: På kort sikt ska ramverket och dess ingående metoder vara tillräckligt väl dokumenterat och utvärderade för att användas i produktion av de produkter som under 2021 ska publiceras på scenariotjänsten på smhi.se.

Långsiktigt ska den strategiska vidareutvecklingen av ramverket och dess ingående metoder följa ny utveckling inom klimatmodellering och biasjustering för att bibehålla state-of-the-art.

3 Metodik

En SMHI-intern arbetsgrupp med experter inom olika ämnesområden (meteorologi, hydrologi, oceanografi och klimat) och med tidigare erfarenhet av biasjustering eller inom effektmodellering skapades. Under tre diskussionsmöten (ett i person och två online) har ett antal metoder valts ut, diskuterats i detalj, samt utvärderats. Grunden i arbetet är internationellt publicerad peer-review litteratur, samt utforskande av existerande klimattjänster och metoder för biasjustering som används av kommersiella aktörer. Detta gjordes för att identifiera state-of-the-art inom både metoder för och utvärdering av biasjustering.

Utgångspunkterna för metodiken är att den ska:


- Justera över hela variabelns fördelning av värden, det vill säga för mer än bara till exempel medelvärdet.
- Den ska kunna hantera flera olika fördelningsfunktioner och även avvikelser från medelvärdet (anomalier).
- Ha en stor produktionssäkerhet, det vill säga att den ska klara att producera rimliga resultat även under extrema förhållanden som till exempel små värdemängder.

Dessa grundkrav styr urvalet av metodik att studera närmare.

3.1 Urval av metoder för biasjustering

Quantile mapping består i grunden av att skapa en transferfunktion som mappar modellens värden längs tidsserien på så sätt att modellens fördelning sedan stämmer överens med det använda referensdatasettet. För att beskriva metoderna utgår vi från följande matematiska notation: Sannolikhetsfördelningsfunktionen, F , är en funktion som beskriver sannolikheten för ett givet värde av en variabel, x , till exempel nederbörd eller temperatur en given dag. Den nedsänkta notationen anger datakälla och tidsperiod för variabeln, eller för den uppbyggda sannolikhetsfördelningen: *refh* – referens historisk, *reff* – referens framtid, *modh* – modell historisk, *modf* – modell framtid, *ba* - biasjusterad.

Standardversionen av quantile mapping beskrivs i Figur 1. Metoden kalibreras för den historiska perioden där en mappning byggs upp som översätter enskilda värden i modellen enligt referensen så att modellen efter justeringen reproducerar referensens sannolikhetsfördelning. Det finns olika sätt att implementera mappningen, vilket utgör den främsta skillnaden mellan de olika metoder som studeras här. Nedan följer en beskrivning av de utvärderade metoderna. När metoderna appliceras för utvärderingen är samtliga implementerade så att de appliceras på enskilda kalendermånader, till exempel samtliga januari i kalibrerings eller valideringssteget. Endast implementation av MIDASv0.1 avviker genom att använda ett löpande tidsfönster (se beskrivning av *midas* sist i det här kapitlet).




Figur 1. Standard quantile mapping, som används i EQM, *qmapQ*, *DQM*, *ISIMIP3* och *midas*.

Följande metoder är inkluderade i utvärderingen:

EQM (empirical quantile mapping) tar hänsyn till varje enskilt värde i fördelningsfunktionen genom att mappa de empiriska fördelningarna. Det fungerar väl i den centrala delen av fördelningen där det finns stort dataunderlag, men mot svansen (eller svansarna) på en fördelning blir metoden känslig för statistiska osäkerheter och hanteringen av dess osäkerheter kan kraftigt påverka resultaten. Till exempel visade Switanek m.fl. (2017) att om inte osäkerheten hanteras kan extrema värden justeras alltför kraftigt, vilket kan ge stor påverkan när metoden appliceras i ett förändrat klimat. För att hantera osäkerheter vid svansen av fördelningen har olika statistiska anpassningar till data föreslagits. För metodikutvärderingen studerades en version av EQM från R-paketet "qmap" (Gudmundsson 2016) som vi kallar **qmapQ**. Den utgör en förenkling av den empiriska fördelningsfunktionen genom att den delar upp fördelningen i sektioner av en-percentiler, det vill säga att varje sektion av fördelningen kommer att innehålla 1% av den totala värdemängden. Användandet av percentiler gör att det finns en större datamängd och lika många värden i varje sektion, vilket ger robusthet i statistiken för att skalera om värdena. Däremot gör metoden avkall på precision.

ISIMIP3 (Lange, 2019) anpassar först parametriska fördelningsfunktioner som är förbestämda för varje variabel och använder sig av samma princip som EQM. För nederbörd används en gammafördelning till värden över 0,1 mm/dag och för temperatur en normalfördelning. För temperatur tas först en eventuell trend bort genom att anpassa en linjär funktion till årliga medelvärden. Efter biasjustering läggs trenden på tidsserien igen. För att bibehålla klimatmodellens trender skapar ISIMIP3 en *pseudo-observation*


för framtiden genom att lägga på en trend för olika kvantiler av referensdatats fördelning, med trenden tagen från den klimatmodell som ska justeras. På det sättet skapar ISIMIP3 en observationsreferens för framtiden, vilket ger en trendbevaring över hela fördelningsfunktionen.



Figur 2. QDM - Quantile delta mapping

QDM (Cannon et al., 2015) följer samma grundlogik som EQM, men istället för att utgå från värdet, skalerar den efter kvantilen (Figur 2). Jämför det ”vertikala” steget (steg 1) i Figur 1 för EQM, med det ”horisontella” (Δ) i Figur 2 för QDM. För den historiska perioden blir det samma resultat som för EQM, men för att kunna justera ett värde måste metoden alltid beräkna värdets kvantil. Den måste alltså känna till hur värdet förhåller sig till en fördelning. I den här studien applicerar vi justeringen på olika perioder och den framtida fördelningen baseras på just de perioderna. Andra tänkbara lösningar är att använda löpande tidsfönster för att beräkna fördelningen. QDM utför även en inbyggd trendsjustering på så sätt att en linjär trend tas bort före biasjusteringssteget för att sedan läggas tillbaka efter mappningen för att bibehålla den ursprungliga klimatförändringssignalen.

CDF-t (Michelangeli et al., 2009) är mer komplicerad och använder sig av en beräknad framtida referensfördelning att mappa mot. I ett första steg använder den sig av en justering efter den historiska periodens kvantil, i likhet med QDM, och den producerar också pseudo-observationer i likhet med ISIMIP3. Mappningens huvuddrag illustreras i Figur 3. Vi använder R-paketet ”CDFt”.



Figur 3. CDF-t

Kaskadvis korrigering introducerades av Haerter m.fl. (2010) och innebär att man delar upp en tidsserie i olika tidsupplösningar. Bias kan se olika ut för dygnsvärden och månadsmedelvärden, och en standardjustering av dygnsvärden kan i vissa fall ha negativa sideoffekter på bias i månadsmedel (Haerter m.fl., 2010). Här utforskar vi hur en uppdelning på månadsmedel och dygnsanomalier med separat qmapQ-justering påverkar resultaten och vi kallar den nya metoden **qmapQ_casc**. Detta är en metod som använts i tidigare implementering av MIdAS där den också generaliserats till att hantera uppdelning på olika rumsskalor. Det är därmed en attraktiv metod för applikationer där klimatmodellen har högre upplösning än referensdata, vilket kommer att bli mer vanligt när regionala klimatmodeller blir tillgängliga på kilometerskala och med högre tidsupplösning.

Våtdagsjustering används ofta för nederbörd för att justera antalet våta dagar i en tidsserie. Här studeras två olika metoder: numwet och ssr. Numwet (Yang et al., 2010) justerar endast när det är för många våta dagar i modellen jämfört med referensen, vilket ofta är fallet för klimatmodeller. Först beräknas antal våta dagar (nederbörd över 0.1mm/dag) och sedan beräknas vilken nederbördsnivå i modellen som motsvarar det antal våta dagar. Alla nederbördsvärden under den beräknade nivån sätts därefter till 0 för hela modellens tidsserie (historisk och framtid). Den andra metoden, ssr (Singularity Stochastic Removal; Vrac m.fl., 2016), justerar även för fall då modellen är torrare än referensen. Det lägsta nederbördsvärdet, tröskelvärdet, i modellen eller referensen beräknas. Sedan sätts alla tillfällen då nederbörden är lika med 0 till ett slumpvis genererat värde mellan 0 och det lägsta värdet. Efter biasjustering kommer värdena att tillskrivas andra värden för att matcha referensen. När hela processen är klar återställs alla värden under tröskelvärdet till 0 igen.

midas kallar vi här den metod som slutligen implementeras i MIdAS och har versionsnamn v0.1. Vi skriver metodens namn i gemener för att skilja den från grundverktyget MIdAS som kan inkludera olika typer av biasjusteringsmetoder. I grunden använder midas en EQM liknande qmapQ, fast istället för att dela in fördelningsfunktionen i percentiler används en splineanpassning till en quantile-quantile plot, det vill säga en parvis fördelning av referens och modelldata. De anpassade noderna sätts till lika många som antalet datapunkter i referensperioden. För att undvika påverkan av outliers i fördelningarnas extremvärden, anpassas en linjär funktion till de 90% centrala punkterna i fördelningen. Vikter till splinefunktionen sätts sedan enligt

punkternas avvikelse från den linjära anpassningen, med ett minimum at 1% vikt per punkt för att inte ge enskilda punkter för stor vikt.

Metoden midas använder två kaskader för temperatur (31-dagarsmedel och dagliga anomalier från detsamma) men utför endast justering av dagliga värden för nederbörd. Dessutom skiljer sig midas från de andra metodernas implementering genom att den utför justering efter en *day-of-year*-kalender, det vill säga att kalibrering och justering sker separat för varje dag på året, men tar med information inom ett 31-dagars tidsfönster centrerat på den aktuella dagen. Skottdagar, vilka tekniskt definieras som den sista dagen på året (dag 366) tas ej med i beräkningen, utan justeras med parametervärden från dag 365. Värden utanför referensdatats intervall justeras med en konstant additiv faktor som får sitt värde från den relevanta ändpunkten av intervallet. Det utförs ingen explicit våtdagsjustering i den här versionen av midas, men den empiriska fördelningen innehåller en implicit justering eftersom även datapunkter utan nederbörd tas med.


3.2 Utvärderingsscheman

Två olika utvärderingsscheman har använts. Korsvalidering utforskar hur väl metoderna fungerar i nuvarande klimat jämfört med observationer, medan pseudo-reality-metoden utvärderar modeller mot varandra och kan därmed även användas för att utvärdera metoden för framtida klimat.

3.2.1 Korsvalidering

Korsvalidering är en metod som används för att utvärdera hur bra en modell hanterar perioder utanför dess kalibreringsperiod och är den rekommenderade metodiken för utvärdering av biasjusteringsmetoder. I det här projektet utförs det genom att dela upp perioden 1981–2010 i sex block à fem år vardera. I tur och ordning används fem block sammansatta till en 25-årsperiod till kalibrering och ett femårsblock till validering. I slutändan har varje femårsintervall i perioden använts som validering och alla intervallen sätts samman till en komplett period för utvärdering.

Korsvalidering appliceras endast för den först utvärderingen av metoder. Som referensdata har vi valt att använda det griddade datasetet E-OBS (Cornes et al., 2018) i version v20.0e på 0.11 graders (12,5 km) upplösning. En begränsning med korsvalideringsmetoden är att dataseten måste vara väl synkroniserade på ”väderskala”, det vill säga att en dag i modellen behöver beskriva samma dag i observationerna (Maraun och Widmann 2018). För att uppfylla det kravet kan de regionala klimatmodellerna användas till att nedskalera återanalysdata som beskriver det faktiska vädret med tillräcklig noggrannhet. I det här projektet drivs modellerna av ERA-Interim och fyra olika regionala klimatmodeller för Europa (SMHI-RCA4, CNRM-ALADIN63, GERICS-REMO2015, KNMI-RACMO22E) används. Resultaten utvärderas för tre olika områden (se Figur 4): SE_1 – svenska västkusten, SE_2 – Svenska fjällen och S_1 – Spaniens sydostkust. De representativa områdena har valts ut för att belysa ett kallt och ett varmt område i Sverige, samt ett torrt och varmt område i södra Europa. Områdena är relativt små för att minska beräkningstid.



Figur 4. Karta över alla domäner som används för utvärdering i de två utvärderings-experimenten.

3.2.2 Pseudo-reality

Pseudo-reality är en metodik som används för att utvärdera klimatmodeller utan att blanda in observationer (Maraun, 2012, Räisänen och Rätty, 2013). Istället definieras en av modellerna som en pseudo-observation och används som referens till kalibrering och utvärdering av de andra modellerna. Valet av referens roteras tills alla modeller agerat som referens. Kalibrering sker för perioden 1971–2000 och applicering på perioderna 1971–2000, 2011–2040, 2041–2070, 2071–2100. Eftersom pseudo-observationerna även har värden för framtiden är det fullt möjligt att utvärdera hur biasjusteringsmetodiken presterar under ett framtida klimat, vilket är styrkan med metoden.

För utvärderingen används fem globala klimatmodeller från CMIP5-ensemblen (CSIRO-BOM-ACCESS1-0, NorESM1-M, IPSL-IPSL-CM5A-MR, Inmcm4, MPI-M-MPI-ESM-MR). Ett urval av domäner har gjorts baserat på arbetsgruppens tidigare erfarenheter av problem med biasjustering på global skala i flera forskningsprojekt och utveckling av klimattjänster. De utvalda regionerna (se Figur 4) är (förkortning – beskrivning; motivering):

- NAM_1 – Klippiga bergen; Inflation av temperaturvarians.
- EUR_1 – Sweden, Sverigefokus.
- AFR_1 – Afrika-Sahel zon, torrt, tydliga säsongsvariationer och svag nederbörd.
- AFR_2 – Afrika-tropisk zon, kraftig nederbörd.
- WAS_1 – Himalayas yttre region, monsunklimat.
- EAS_1 – Polynesien, stark kontrast sjö-land.
- SAM_1 – Chiles kust, komplex topografi, stark kontrast sjö-land.
- SAM_2 – Amazonas, kraftig nederbörd, upplevda problem i DBS-metodiken.
- ARC_1 – Sibirien, kontinentalt arktiskt klimat.
- AUS_1 – Australien, för klimatmodeller utmanande regioner.

3.2.3 Utvärderingsparametrar

All statistik beräknas för varje månad i årscykeln över en 30-årsperiod enligt WMOs rekommendationer för klimatologiska perioder.

- Medel
- Percentiler: 0p (min), 1p, 99p och 100p (max)
- Antal våta dagar (dagar med nederbörd >0)
- PDF skill score (pdfSS) – andel överlappande area av två sannolikhetsfördelningar, F. Ett värde mellan 0 (dåligt) och 1 (perfekt matchning).

För alla statistiska mått (STAT) förutom pdfSS beräknas bias enligt följande ekvation per gridpunkt, z:

$$BIASz(m, i) = STAT_{modh,z(m,i)} - STAT_{refh,z(m)},$$

där m anger månad och i klimatmodellen.

En sammanfattning av bias ges även som:

$$BIAS = \langle abs(BIASz(m, i)) \rangle_z ,$$

där medelvärdesoperatoren " $\langle \rangle_z$ " opererar på alla gridpunkter.

För pdfSS beräknas ingen bias eftersom pdfSS redan jämför modell med referens.

Såväl i korsvalidering som i pseudo-reality förväntas per definition att BIAS är nära 0 i kalibreringsperioden. Däremot brukar BIAS öka när valideringsperioder analyseras. pdfSS har det omvända beteendet, det vill säga nära 1 i kalibrering och lägre värden i valideringsperioder.

Biasjusteringens påverkan på klimatförändringssignalen, CCz, beräknas här genom att jämföra klimatförändringssignalen i originaldata med biasjusterade data enligt:

$$CCz = STAT_{modf,z(m,i)} - STAT_{modh,z(m,i)} ,$$

och

$$CC = \langle CCz(m, i) \rangle_z .$$

3.2.4 Rankningsmetoder

Hela analysen innehåller en stor mängd data och därför tillämpades tre olika rankningsmetoder för att sammanfatta skillnader mellan metoderna (Tabell 1).

Tabell 1: Beskrivning av rankningsmetoder.

Metod	Beskrivning
1	Rankning enligt metodvis statistik-medelvärde av alla ensemblemedlemmar, alla regioner, perioder och månader.
2	Rankning enligt regions- och metodvis statistik-medelvärde av alla ensemblemedlemmar, perioder och månader. Sedan medelrankning över alla regioner.
3	Rankning enligt regions- och metodvis statistik-medelvärde av ensemble-median, alla perioder och månader.

Statistiken kan antingen vara bias (ju lägre desto bättre), pdfSS (ju högre desto bättre) eller klimatförändringssignalens modifikation. Vi noterar att det inte finns ett enkelt svar för vad den sistnämnda modifikationen ska eftersträva och det finns studier som visar på att biasjusteringsmetoden i vissa fall bör påverka klimatsignalen (Ivanov et al., 2018), men att det är svårt att utvärdera utan att gå

in i detalj på hur olika klimatprocesser beskrivs i modellen och på så sätt avgöra om biasjusteringen justerar bias i en given process på ett rimligt sätt (Maraun et al., 2017). När detaljstudier av processbeskrivning före och efter biasjustering utförs, är en rimlig nollhypotes att en ringa påverkan på en klimatförändrings-signal bör eftersträvas.

Rankningsmetod 1 ger en rankning enligt medelbias/medel-pdfSS/medelmodifikation över alla data som står bakom vardera figuren. Den gör en implicit viktning om storleksordning i bias/pdfSS/modifikation skiljer sig mellan regionerna. Rankningsmetod 2 undviker en implicit viktning genom att separat beräkna en rankning för varje region och sedan beräkna en medelrankning på alla regioner. Rankningsmetod 3 slutligen rankar också utan implicit viktning separat för varje region, men rankningen baseras på medianvärdet som visas i själva figuren.

4 Resultat

4.1 Litteraturstudie

Arbetsgruppen som utförde litteraturstudien fann att

- Det finns ingen etablerad state-of-the-art inom biasjustering som pekar på en specifik metod som bör väljas framför andra.
- Inom effektmodellering används oftast någon typ av quantile mapping för att justera hela statistiska fördelningar, vilket kan anses komma närmast en state-of-the-art.
- Många metoder inom quantile mapping-familjen är mycket lika och skiljer sig främst genom olika val och varianter inom samma metodik.
- Några metoder fokuserar på bevarande av utvalda delar av klimatmodellernas ursprungliga klimatsignal, medan andra tillåter att biasjusteringen påverkar signalen.

MIDAS bygger på att biasjustering kan utföras som en kaskad av korrektioner på olika tids- och/eller rums-upplösningar. Haerter m.fl. (2010) visade att en sådan metod minskar risken för att introducera nya bias på andra tidsskalor än den som man justerar på. Det är en intressant metodik som också kommer att bli mer och mer användbar längre fram eftersom klimatmodeller får högre upplösning i både tid och rum än vad observationerna har. Utvecklingen av separat biasjustering för olika upplösningar kommer att bli mer användbar i framtiden, vilket också beaktades vid implementering av metoderna, främst genom att parameterfri implementering valdes framför att anpassa funktioner till data.

Arbetsgruppen har tagit fram en lista på kandidater för närmare utvärdering, se Sektion 3.1.

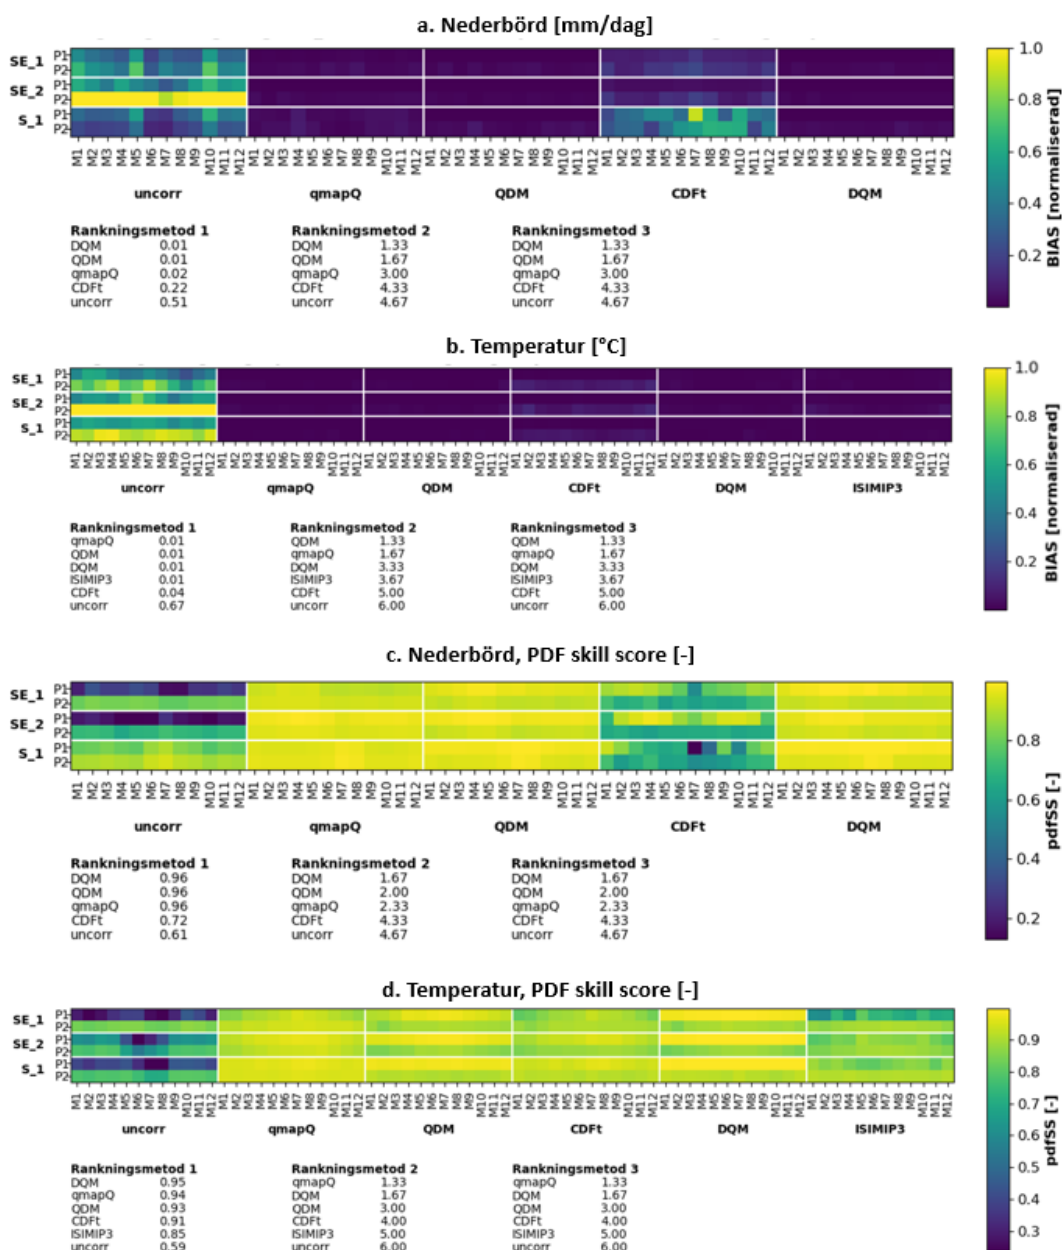
4.2 Korsvalidering

Korsvalidering testar metodernas förmåga att korrigera oberoende valideringsdata som på grund av naturlig variabilitet skiljer sig i sin karakteristik från kalibreringsdata. Valideringen visar därför på metodens förmåga att justera data som inte har använts vid kalibreringen av metoden. Som beskrivs i Sektion 3.2.1, delades tidsperioden för de fyra klimatmodellerna upp i fem delar som korsvaliderades mot observerade referensdata.


Figur 5 visar medianvärdet av BIAS beräknad för alla fyra projektioner, alltså *median(BIAS)*. För BIAS är ett värde nära noll bra och för pdfSS eftersträvas ett värde nära 1. Resultaten visar att alla metoder klarar av att minska bias i kalibreringsdata (P1) till nära 0 eller höja pdfSS till nära 1 med undantag för CDFt pdfSS (både temperatur och

nederbörd) och ISIMIP3 pdfSS (temperatur). CDFt har generellt störst problem att minska bias i P1. Vid granskning av valideringsdata (P2) så förstärks bilden från kalibreringsperioden. DQM, QDM och qmapQ klarar sig bäst medan CDFt och ISIMIP3 har stora bias och låga pdfSS. QDM presterar inte heller lika bra som de andra metoderna när det gäller pdfSS av temperatur.

Samtliga metoder har svårigheter med 99:e percentilen av nederbörd, men i utvärderingen klarar sig qmapQ bäst för höga och låga percentiler (Figur 6). I qmapQ hanteras extrapolering bortom värdeområdet i kalibreringsdata på ett annat sätt än i de andra metoderna. Det kan leda till skillnader vi ser i både låga och höga percentiler.



Figur 5. Korsvalidering av nederbörd och temperatur per kalendermånad (M1 – Januari, ..., M12 – December). uncorr visar original modelldata följt av de olika biasjusteringsmetoderna. De tre regionerna (se Figur 4) visas till vänster med vardera kalibrerings- (P1) och valideringsperiod (P2). Rankningsmetod 1 har samma enhet enligt panelens titel. Panel a (c) och b (d) visar medianbias (median PDF skill score) av alla fyra ensemble-medlemmar i korsvalideringsexperimentet för nederbörd och temperatur, respektive.



Figur 6. Som Figur 5a, men för 99:e percentilen av nederbörd.

4.3 Pseudo-reality


I pseudo-reality valideringen är det intressant att granska hur bias förändras över tid och hur klimatförändringssignalen påverkas av biasjusteringsmetodiken. Pseudo-reality metoden ger bättre möjligheter för utvärdering genom större statistisk robusthet och tillgången till ”framtida observationer”. Inledningsvis utvärderas de två vådagsjusteringsmetoderna och ett val av metod görs inför det sista utvärderingssteget. Sedan utvärderas potentialen för kaskadjustering med de metoder där det enkelt kan implementeras. Det sista steget är en utvärdering av de olika metoderna, inklusive av den slutgiltiga implementeringen av MIDAS.

4.3.1 Justering av regndagar

Alla tester genomfördes med biasjusteringsmetoden qmapQ. Vi testade två olika metoder:

- Wetday-threshold (wd_numwet)
- Singularity Stochastic Removal (wd_ssr)

Av de två metoderna i jämförelsen är resultatet tydligt att wd_ssr klarar sig bäst (se Figur 7). Den andra metoden wd_numwet visar tydliga svagheter och leder i vissa fall till och med till ökade bias jämfört med okorrigerade data. Det beror dels på att wd_numwet inte kan korrigera antal regndagar om det finns för få regndagar i modelldata jämfört med referensdata (observera att referensdata här också är modelldata), och dels på att den tillämpar först en fast regndagströskel på 0.1mm/d innan antal regndagar korrigeras. wd_ssr minskar bias i nästan alla testade fall. Ena undantaget är augusti i AFR_1. AFR_1 är dock en region där vi vet att bias i antal regndagar kan vara stor och svår att korrigera på grund av det torra klimatet. Bias för wd_ssr ligger i kalibreringsperioden (P1) nära 0, men ökar i framtida perioder och kan då vara mellan 100–200 dagar. Jämfört med 900 dagar, som är det totala antal dagar per månad under en 30-årsperiod, är det alltså en inte försumbar bias. Ökningen av bias över tid (från P1 till P4) beror på icke stationär bias. Eftersom stationaritet av bias, det vill säga att bias är tidsberoende och lika stor i framtiden som historiskt, kommer inte korrigeringsparametrarna, som kalibreras i perioden 1971–2000 (P1) och tillämpas över hela tidsserien, kunna ta bort hela bias i framtiden.



Figur 7: Bias i antal regndagar för olika regioner och perioder (y-axel) och metoder och månader (x-axeln). Perioderna benämns som P1 (1971–2000), P2 (2011–2040), P3 (2041–2070) och P4(2071–2100) och månaderna med M1 till M12 för januari till december.


4.3.2 Kaskadvis biasjustering

En central fråga i biasjustering är hur bias på olika skalor i rum och tid påverkar varandra. Vanligtvis utförs biasjustering utan särskild hänsyn till tid- och rumsskalor eftersom dygnsdata på referens- eller annan målupplösning används för att justera modellen. Beroende på karaktären för bias på olika skalor kan en så kallad kaskadvis justering ge goda resultat. I det här projektet utvärderas en kaskadvis biasjustering där månadsmedel (enligt kalendermånad) och dygnsanomalier justeras separat, och jämför med standard biasjustering av dygnsvärden. Tester utfördes på tre olika biasjusteringsmetoder: QDM, DQM och qmapQ. Den parametriserade metoden ISIMIP3 utelämnades eftersom det är komplicerat och tidsödande att hitta fördelningsfunktioner som passar de olika tidsskalorna. För alla metoder tillämpades wd_ssr metoden för justering av antal regndagar.


Utvärderingar för höga och låga percentiler, medelvärden och pdf-skillscores för alla metoder studerades. Resultaten var likvärdiga och därför presenteras endast figurer för medelvärden av nederbörd (Figur 8) och temperatur (Figur 9). De flesta

metoduppsättningarna ger liknande resultat, förutom QDM_casc som uppvisar stora återkommande problem för nederbörd. Rankningen handlar om mycket små skillnader, men qmapQ och qmapQ_casc rankar högst för nederbörd medan QDM, QDM_casc och qmapQ_casc toppar metoderna för medeltemperatur. DQM sluter upp i toppen för andra temperaturstatistik som pdfSS och 99e percentilen medan QDM_casc tappar (ej presenterat).

Det kan konstateras att kaskadimplementeringar av de tre testade biasjusteringsmetoderna inte ger stort genomslag i tydliga förbättringar i bias-utvärdering. QDM_casc och DQM_casc visar också tecken på instabiliteten som syns i höga bias-värden för medelnederbörd. Om fokus läggs på qmapQ, ligger standard- och kaskadvarianten nära varandra för nederbörd, och kaskadvarianten är något bättre för temperatur.



Figur 8. Kaskad-korrigeringsutvärdering, nederbörds månadsmedel: medianbias av alla 12 ensemble-medlemmar i pseudo-reality experimentet. Regioner och perioder på y-axeln, biasjusteringsmetoder och månader i årscykeln (M1 till M12) på x-axeln. Bias är normaliserad för att kunna se alla regionernas resultat. Perioderna är definierade som 1971–2000 (P1), 2011–2040 (P2), 2041–2070 (P3), 2071–2100 (P4). Rankningsmetoder beskrivs i texten. Observera att värdena i Rankningsmetod avser medelbias över hela datasettet per metod, här med enhet mm/d.



Figur 9. Samma som i Figur 8 men för medeltemperatur. Enhet i rankning 1 är °C.

Genom kaskadbiasjustering justeras data med olika karaktär, i till exempel varians, separat. Det kan potentiellt ge en fördel vid granskning av modifikation av klimatförändringssignalen. Återigen ger metoderna liknande resultat (ej presenterat), med vissa större avvikelser för QDM_casc och särskilt DQM_casc jämfört med de andra. Ett starkt resultat är att qmapQ_casc presterar konsistent bättre än qmapQ och båda är ibland bättre än övriga metoder (till exempel för medelnederbörd) men ibland bidrar endast kaskadjusteringen till att avståndet till QDM och DQM minskar så att den svaga påverkan på klimatförändringssignalen blir än mindre.

4.4 Metodjämförelse


Här presenteras en sammanfattning av metodjämförelsen. Alla metoder som beskrivs i kapitel 3.1. **Fel! Hittar inte referenskälla.** är med, samt en version av kaskadvis korrigerig (qmapQ_casc; se kapitel 4.3.2 för en utvärdering av kaskadvis korrigerig). Samtliga biasjusterade nederbördsdata använder sig av regndagskorrigeringsmetoden Singularity Stochastic Removal (wd_ssr) som visade sig vara klart bättre än numwet för regndagskorrigerig (se kapitel 4.3.1), med undantag för CDFt som har sin egen interna korrigerig för antal regndagar och därför inte kombinerades med wd_ssr, samt midas som i nuvarande implementation endast implicit hanterar antalet våta dagar.

Notera att midas ursprungligen inte var med i analysen, utan har implementerats som ett resultat av utvärderingen. I rankningen som presenteras här har all statistik räknats om så att midas är med i beräkningarna. Observera att på grund av det löpande tidsfönstret som används i midas får metoden systematiskt en avvikelse jämfört referensdata vilket ger lägre prestation enligt den beräknade statistiken och rankningen. Detta behöver beaktas i jämförelsen med de andra metoderna.


Utvärderingen sker genom ett antal figurer med sammanfattning av kvarvarande bias i varje region och kalendermånad för vardera metoden. Figur 10 visar en sådan utvärderingsplott för medelnederbörd och Figur 11 för medeltemperatur. Värden i figurerna har normaliserats regionvis för att ge jämförbara resultat över hela figuren utan

att någon region dominerar färgskalan. Det framgår i båda figurerna tydligt att bias minskar för alla metoder (jämför med första kolumnen för okorrigerade data - *uncorr*), med enda undantagen för CDFt och DQM i AFR_1 som är en mycket torr region. Det framgår också stora likheter i mönster över perioder och månader för de olika metoderna och det är tydligt att de alla presterar på liknande nivå, med få undantag av avvikande värden.

I valideringsperioderna P2-P4 observeras en successiv ökning av bias och minskning av pdfSS med klimatförändringens magnitud hos samtliga modeller. Det innebär att bias är föränderlig med tiden, vilket är problematiskt eftersom ett av projektets grundantaganden är att bias är konstant. Ökningen av bias är olika stor för olika regioner, med EUR_1 (Skandinavien), ARC_1 och AFR_1 som visar störst ökning för medeltemperatur och medelnederbörd. Vid granskning av den 99:e percentilen sällar sig också NAM_1 till regionerna med stor ökning av bias. Trots biasökningar i valideringsperioderna är bias i de allra flesta fall markant mindre än i ojusterade data ("uncorr" i figurerna), vilket betyder att det ändå finns en systematisk bias-komponent om man kalibrerar på P1 och tillämpar bias-justering på P2-P4.



Figur 10. Nederbörd - månadsmedel: medianbias av alla 12 ensemble-medlemmar i pseudo-reality experimentet. Regioner och perioder på y-axeln, biasjusteringsmetoder och månader i årscykeln (M1 till M12) på x-axeln. Bias är normaliserad för att kunna se alla regionernas resultat tillsammans. Perioderna är definierade som 1971–2000 (P1), 2011–2040 (P2), 2041–2070 (P3), 2071–2100 (P4). Rankningsmetoder beskrivs i texten. Observera att värdena i Rankningsmetod 1 avser medelbias över hela datasettet per metod, här med enhet mm/d.



Figur 11. Samma som Figur 10 men för månadsmedeltemperatur. Enhet i ranking 1 är °C.


Tabell 2 sammanfattar statistiken genom att presentera värden från rankningsmetod 1, samt indikera en aggregerad rankning över alla tre rankningsmetoderna som en färgskala där mörkast färg anger den överlag bäst presterande biasjusteringsmetoden och gradvis svagare nyanser för metod nummer 2 och 3. Observera att de oftast är mycket små skillnader som avgör rankningen och att de flesta metoder får godkänt resultat. QDM är den överlag bästa metoden i utvärderingen, men den uppvisar något sämre resultat för nederbörd i den historiska perioden, där både qmapQ och midas presterar bättre.

Tabell 2: Bias för alla regioner, månader och perioder (P1—P4). Rankning 1 presenteras i siffror och en viktad sammanställning av de tre bäst presterande metoderna anges i gradvis mörkare nyans ju bättre modellen presterar. "inf" markerar att metoden uppvisar kraftiga outliers i en eller flera gridpunkter i någon eller några domäner.


Variabel (statistik)	uncorr	midas	qmapQ	qmapQ_casc	QDM	CDft	DQM	ISIMIP3
Nederbörd (min)	0,08	0,05	0,04	0,03	0,04	0,44	inf	NA
Nederbörd (medel)	1,39	0,48	0,43	0,43	0,53	0,56	inf	NA
Nederbörd (99p)	7,99	3,13	4,14	3,08	3,27	3,66	inf	NA
Nederbörd (max)	17,69	10,25	14,31	9,41	11,12	10,43	inf	NA
Nederbörd (pdfSS)	0,75	0,89	0,89	0,89	0,88	0,81	0,87	NA
Temperatur (min)	3,83	1,89	1,51	1,4	1,55	1,77	1,47	1,51
Temperatur (1p)	3,44	1,23	1,09	1,11	1,01	1,1	1,06	1,06
Temperatur (medel)	2,88	0,82	0,83	0,93	0,8	0,82	0,82	0,8
Temperatur (99p)	2,86	1,35	1,29	1,16	1,04	1,12	1,06	1,13
Temperatur (max)	2,96	1,76	1,6	1,26	1,23	2,69	1,15	1,31
Temperatur (pdfSS)	0,5	0,78	0,78	0,76	0,78	0,78	0,78	0,78

Biasjusteringens påverkan på klimatförändringssignaler analyseras i liknande plottar. För medelnederbörd (Figur 12) kan man se liknande mönster i flera olika metoder, till exempel midas, qmapQ, QDM och DQM. CDF-t avviker distinkt och uppvisar förhållandevis kraftig påverkan på klimatförändringssignalen.

För temperatur (Figur 13) är det tydligt att QDM och ISIMIP3 och till viss del DQM utför en initial avtrendning som sedan läggs på efter all processering. Det tar effektivt bort all påverkan på klimatsignalen och ger dem per definition mycket bra rankning eftersom utgångspunkten i rankningen är nollhypotesen att klimatsignalen inte ska ändras (se kommentar om detta i metoddelen). Övriga metoder hanterar inte bevarande av klimatförändringssignaler explicit, men avviker ändå endast med omkring en halv grad Celsius mot slutet av århundradet under RCP8.5, utan systematik kring över eller underskattning. I de flesta regioner är det en svag signal jämfört med klimatförändringssignaler, som till exempel i Sverige ligger kring 5 °C. Dessutom är trenden i modifikation över tid (P1-P3) inte lika utpräglad som den ökande bias vi noterade i bias-utvärderingen. I vissa fall är en trend synlig (till exempel i medeltemperatur för qmapQ i AUS_1 och CDFt i NAM_1), men ofta är mönstren ganska heterogena vilket kan betyda att det finns en icke-försumbar andel brus som syns i resultaten.



Figur 12. Nederbörd - månadsmedel: median av alla 12 ensemble-medlemmars modifikation av klimatförändringssignalen i pseudo-reality experimentet. Positiva (negativa) värde betyder att biasjustering förstörar (minskar) klimatförändringssignalen som finns i okorrigerade data. Regioner och perioder på y-axeln, biasjusteringsmetoder och månader i årscykeln (M1 till M12) på x-axeln. Modifikationen är normaliserad för att kunna se alla regionernas resultat trots olika storleksordningar. Perioderna är definierade som 2011–2040 (P1), 2041–2070 (P2), 2071–2100 (P3). Rankningsmetoder beskrivs i texten. Observera att värdena i Rankningsmetod 1 avser medelvärde över hela datasettet per metod, här med enhet mm/d.



Figur 13. Samma som Figur 12 men för medeltemperatur. Enhet i ranking 1 är °C.

Tabell 3 listar rankningen av olika metoder för deras påverkan på klimatförändringssignalen. Resultaten är liknande de för bias som presenterades i Tabell 2, med QDM som den generellt bästa metoden, förutom för nederbörd där den ibland är likvärdig med CDFt, qmapQ och midas. Överlag framträder ingen större påverkan på klimatförändringssignalerna. Resultaten av kaskadkorrigeringen (qmapQ_casc och midas) minskar påverkan på klimatförändringssignalen av temperaturen jämfört med standard quantile mapping (qmapQ), helt enligt förväntningarna (Haerter et al., 2010).

Tabell 3: Bias i klimatförändringssignal för alla regioner, månader och perioder (P2—P4). Rankning 1 presenteras i siffror och en viktad sammanställning av de tre bäst presterande metoderna anges i gradvis mörkare nyans ju bättre modellen presterar. "inf" markerar att metoden uppvisar kraftiga outliers i en eller flera gridpunkter i någon eller några domäner.

Variabel (statistik)	uncorr	midas	qmapQ	qmapQ_casc	QDM	CDFt	DQM	ISIMIP3
Nederbörd (min)		0,06	0,04	0,04	0,03	0,46	inf	NA
Nederbörd (medel)		0,17	0,14	0,17	0,22	0,15	inf	NA
Nederbörd (99p)		1,52	1,32	1,6	1,17	1,16	inf	NA
Nederbörd (max)		2,57	3,31	1,41	5,22	2,32	inf	NA
Temperatur (min)		0,67	0,7	0,99	0,07	0,83	0,53	0,35
Temperatur (1p)		0,54	0,57	0,79	0,03	0,35	0,25	0,1
Temperatur (medel)		0,42	0,43	0,58	0	0,1	0	0
Temperatur (99p)		0,41	0,33	0,42	0,02	0,26	0,21	0,07
Temperatur (max)		0,51	0,33	0,02	0,17	2,24	0,66	0,2

5 Slutsatser

Ett flertal publicerade metoder för biasjustering har utvärderats med olika utvärderingsmetoder (korsvalidering och pseudo-reality), för olika delar av världen och för olika statistik som täcker hela variablernas fördelningsfunktion. En jämförande utvärdering av de tidigare publicerade metoderna qmapQ_casc, qmapQ, QDM, CDFt, DQM och ISIMIP3 visar på icke-robusthet för DQM, med frekventa kraftiga avvikelser, samt generellt sämre resultat för CDFt i många fall. QDM presterar mycket bra för temperatur, och ligger även högt i rankingen för nederbörd. qmapQ presterar bäst för nederbörd, men har störts påverkan på klimatförändringssignalen för temperatur.

För implementation i MidAS stod valet mellan en blandning av qmapQ och qmapQ_casc, för att täcka in både nederbörd och temperatur, och QDM. Eftersom QDM kräver att man känner fördelningsfunktionen även för perioder utanför kalibreringsperioden blir den beräkningsmässigt långt mer krävande än de andra metoderna. MidAS kommer att appliceras på stora data set, till exempel har en tidigare version applicerats på hela Europa på 5 km upplösning (ca 1 miljon gridpunkter), och en effektiv och enkel kod är av stor vikt. Därför togs beslutet att implementera en quantile mapping-variant i MidAS med möjlighet att även utföra kaskaduppdelning.

Från nuvarande implementation av MidASv0.1, i analysen kallad midas, kan slutsatsen dras midas presterar likvärdigt eller bättre än flertalet utvärderade metoder. Dess relativa svaghet ligger i en viss påverkan på klimatförändringssignalen för temperatur, men här presterar den bättre än de vanligt använda quantile mapping metoderna genom sin kaskadmetod.

6 Författarnas tack

Medarbetare från flera avdelningar på SMHI har hjälp till genom diskussioner av metoder och vetenskaplig kodning av metoden. Vi tackar särskilt Yeshewatesfa Hundecha, Magnus Hieronymus, Marco Kupiainen, Grigory Nikulin, Elin Sjökvist och Renate Wilcke för deras bidrag.

7 Referenser

- Cannon, A. J., Sobie, S. R., & Murdock, T. Q. (2015). Bias correction of GCM precipitation by quantile mapping: How well do methods preserve changes in quantiles and extremes?. *Journal of Climate*, 28(17), 6938-6959.
- Cornes, R., G. van der Schrier, E.J.M. van den Besselaar, and P.D. Jones. (2018). An Ensemble Version of the E-OBS Temperature and Precipitation Datasets, *J. Geophys. Res. Atmos.*, 123. doi:10.1029/2017JD028200
- Gudmundsson, L. 2016: qmap: Statistical transformations for post-processing climate model output. R package version 1.0-4.
- Haerter, J. O., Hagemann, S., Moseley, C., & Piani, C. (2011). Climate model bias correction and the role of timescales. *Hydrology and Earth System Sciences*, 15(3), 1065-1079.
- Ivanov, M. A., Luterbacher, J., & Kotlarski, S. (2018). Climate model biases and modification of the climate change signal by intensity-dependent bias correction. *Journal of Climate*, 31(16), 6591-6610.
- Lange, S. (2019). Trend-preserving bias adjustment and statistical downscaling with ISIMIP3BASD (v1. 0). *Geoscientific Model Development*, 12(7), 3055-3070.

- Maraun, D. (2012). Nonstationarities of regional climate model biases in European seasonal mean temperature and precipitation sums. *Geophysical Research Letters*, 39(6).
- Maraun, D., Shepherd, T. G., Widmann, M., Zappa, G., Walton, D., Gutiérrez, J. M., ... & Mearns, L. O. (2017). Towards process-informed bias correction of climate change simulations. *Nature Climate Change*, 7(11), 764-773.
- Maraun, D., & Widmann, M. (2018). Cross-validation of bias-corrected climate simulations is misleading. *Hydrology and Earth System Sciences*, 22(9), 4867-4873.
- Michelangeli, P. A., Vrac, M., & Loukos, H. (2009). Probabilistic downscaling approaches: Application to wind cumulative distribution functions. *Geophysical Research Letters*, 36(11).
- Räisänen, J., & Räty, O. (2013). Projections of daily mean temperature variability in the future: cross-validation tests with ENSEMBLES regional climate simulations. *Climate dynamics*, 41(5-6), 1553-1568.
- Switanek, M. B., Troch, P. A., Castro, C. L., Leuprecht, A., Chang, H. I., Mukherjee, R., & Demaria, E. (2017). Scaled distribution mapping: a bias correction method that preserves raw climate model projected changes. *Hydrology and Earth System Sciences*, 21(6), 2649-2666.
- Themeßl, M. J., Gobiet, A., & Heinrich, G. (2012). Empirical-statistical downscaling and error correction of regional climate models and its impact on the climate change signal. *Climatic Change*, 112(2), 449-468.
- Vrac, M., Noël, T., & Vautard, R. (2016). Bias correction of precipitation through Singularity Stochastic Removal: Because occurrences matter. *Journal of Geophysical Research: Atmospheres*, 121(10), 5237-5258.
- Wilcke, R. A. I., Mendlik, T., & Gobiet, A. (2013). Multi-variable error correction of regional climate models. *Climatic change*, 120(4), 871-887.
- Yang, W., Andréasson, J., Phil Graham, L., Olsson, J., Rosberg, J., & Wetterhall, F. (2010). Distribution-based scaling to improve usability of regional climate model projections for hydrological climate change impacts studies. *Hydrology Research*, 41(3-4), 211-229.

SMHIs publiceringar

SMHI ger ut sju rapportserier. Tre av dessa, R-serierna är avsedda för internationell publik och skrivs därför oftast på engelska. I de övriga serierna används det svenska språket.

Seriernas namn	Publiceras sedan
RMK (Report Meteorology and Climatology)	1974
RH (Report Hydrology)	1990
RO (Report Oceanography)	1986
METEOROLOGI	1985
HYDROLOGI	1985
OCEANOGRAFI	1985
KLIMATOLOGI	2009

I serien KLIMATOLOGI har tidigare utgivits:

1. Lotta Andersson, Julie Wilk, Phil Graham, Michele Warburton (University KwaZulu Natal) (2009)
Local Assessment of Vulnerability to Climate Change Impacts on Water Resources in the Upper Thukela River Basin, South Africa – Recommendations for Adaptation
2. Gunn Persson, Markku Rummukainen (2010)
Klimatförändringarnas effekter på svenskt miljömålsarbete
3. Jonas Olsson, Joel Dahné, Jonas German, Bo Westergren, Mathias von Scherling, Lena Kjellson, Fredrik Ohls, Alf Olsson (2010)
En studie av framtida flödesbelastning på Stockholms huvudavloppssystem
4. Markku Rummukainen, Daniel J. A. Johansson, Christian Azar, Joakim Langner, Ralf Doescher, Henrik Smith (2011)
Uppdatering av den vetenskapliga grunden för klimatarbetet. En översyn av natur-vetenskapliga aspekter
5. Sten Bergström (2012)
Framtidens havsnivåer i ett hundraårsperspektiv – kunskapssammanställning 2012
6. Jonas Olsson och Kean Foster (2013)
Extrem korttidsnederbörd i klimatprojektioner för Sverige
7. FNs klimatpanel – Sammanfattning för beslutsfattare. Effekter, anpassning och sårbarhet. Bidrag från arbetsgrupp 2 (WG 2) till den femte utvärderingen (AR 5) från Intergovernmental Panel on Climate Change, IPCC (2014)
8. Att begränsa klimatförändringar. FNs klimatpanel – Sammanfattning för beslutsfattare. Bidrag från arbetsgrupp 3 (WG 3) till den femte utvärderingen (AR 5) från Intergovernmental Panel on Climate Change (2015)
9. Erik Kjellström SMHI. Reino Abrahamsson, Pelle Boberg, Eva Jernbäcker Naturvårdsverket. Marie Karlberg, Julien Morel
Energimyndigheten och Åsa Sjöström SMHI (2014)
Uppdatering av det klimatvetenskapliga kunskapsläget
10. Risker och konsekvenser för samhället av förändrat klimat – en kunskapsöversikt (2014)
11. Gunn Persson (2015)
Vägledning för användande av klimatscenarier
12. Lotta Andersson, Anna Bohman, Lisa van Well, Anna Jonsson, Gunn Persson och Johanna Farelus (2015)
Underlag till kontrollstation 2015 för anpassning till ett förändrat klimat
13. Gunn Persson (2015)
Sveriges klimat 1860-2014. Underlag till Dricksvattenutredningen

14. Anna Eklund, Jenny Axén Mårtensson, Sten Bergström, Emil Björck, Joel Dahné, Lena Lindström, Daniel Nordborg, Jonas Olsson, Lennart Simonsson och Elin Sjökvist (2015) Sveriges framtida klimat. Underlag till Dricksvattensutredningen
15. Elin Sjökvist, Jenny Axén Mårtensson, Joel Dahné, Nina Köplin, Emil Björck, Linda Nylén, Gitte Berglöv, Johanna Tengdelius Brunell, Daniel Nordborg, Kristoffer Hallberg, Johan Södling, Steve Berggreen-Clausen (2015) Klimatscenarier för Sverige - Bearbetning av RCP-scenarier för meteorologiska och hydrologiska effektstudier
16. Elin Sjökvist, Gunn Persson, Jenny Axén Mårtensson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Linda Nylén, Alexandra Ohlsson och Håkan Persson (2015) Framtidsklimat i Dalarnas län – enligt RCP-scenarier
17. Linda Nylén, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Jenny Axén Mårtensson, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Värmlands län – enligt RCP-scenarier
18. Gunn Persson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Örebro län – enligt RCP-scenarier
19. Alexandra Ohlsson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Anna Johnell, Jenny Axén Mårtensson, Linda Nylén, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Västmanlands län – enligt RCP-scenarier
20. Elin Sjökvist, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Anna Johnell, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson (2015) Framtidsklimat i Uppsala län – enligt RCP-scenarier
21. Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Anna Johnell, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Stockholms län – enligt RCP-scenarier
22. Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Anna Johnell, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Södermanlands län – enligt RCP-scenarier
23. Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Anna Johnell, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Östergötlands län – enligt RCP-scenarier
24. Gitte Berglöv, Magnus Asp, Steve Berggreen-Clausen, Emil Björck, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Västra Götalands län – enligt RCP-scenarier
25. Alexandra Ohlsson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Anna Johnell, Jenny Axén Mårtensson, Linda Nylén, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Jönköpings län – enligt RCP-scenarier
26. Gunn Persson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015) Framtidsklimat i Kalmar län – enligt RCP-scenarier

27. Gitte Berglöv, Magnus Asp, Steve Berggreen-Clausen, Emil Björck, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Kronobergs län – Enligt RCP-scenarier
28. Gunn Persson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Hallands län – enligt RCP-scenarier
29. Alexandra Ohlsson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Anna Johnell, Jenny Axén Mårtensson, Linda Nylén, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Skåne län – enligt RCP-scenarier
30. Alexandra Ohlsson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Anna Johnell, Jenny Axén Mårtensson, Linda Nylén, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Blekinge län – enligt RCP-scenarier.
31. Gunn Persson, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Gotlands län – enligt RCP-scenarier
32. Gitte Berglöv, Magnus Asp, Steve Berggreen-Clausen, Emil Björck, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Norrbottens län – enligt RCP-scenarier
33. Gitte Berglöv, Magnus Asp, Steve Berggreen-Clausen, Emil Björck, Jenny Axén Mårtensson, Linda Nylén, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Västerbottens län – enligt RCP-scenarier
34. Linda Nylén, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Jenny Axén Mårtensson, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Jämtlands län – enligt RCP-scenarier
35. Linda Nylén, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Jenny Axén Mårtensson, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Västernorrlands län – enligt RCP-scenarier
36. Linda Nylén, Magnus Asp, Steve Berggreen-Clausen, Gitte Berglöv, Emil Björck, Jenny Axén Mårtensson, Alexandra Ohlsson, Håkan Persson, Elin Sjökvist (2015)
Framtidsklimat i Gävleborgs län – enligt RCP-scenarier
37. Jonas Olsson, Weine Josefsson (red.) (2015) Skyfallsuppdraget - ett regeringsuppdrag till SMHI
38. Gunn Persson, Linda Nylén, Steve Berggreen-Clausen, Peter Berg, David Rayner och Elin Sjökvist (2015)
Från utsläppsscenarier till lokal nederbörd och översvämningsrisker
39. Anna Eklund, Jenny Axén Mårtensson, Sten Bergström och Elin Sjökvist (2015)
Framtidens vattentillgång i Mälaren, Göta älv, Bolmen, Vombsjön och Gavleån. Underlag till Dricksvattenutredningen
40. Anna Bohman (Centrum för klimatpolitisk forskning, CSPR) vid Linköpings universitet, Lotta Andersson, SMHI och CSPR, Linköpings universitet samt Åsa Sjöström, SMHI. (2016)
Förslag till en metod för uppföljning av det nationella klimatanpassningsarbetet. Redovisning av ett regeringsuppdrag December 2016

- 41 (2017)
Karttjänst för framtida
medelvattenstånd längs Sveriges kust
- 42 Anna Eklund, Linda Tofeldt, Johanna
Tengdelius-Brunell, Anna Johnell,
Jonas German, Elin Sjökvist, Maria
Rasmusson, Elinor Andersson (2017)
Vattennivåer, tappningar,
vattentemperaturer och is i Vättern
Beräkningar för dagens och framtidens
klimatförhållanden
- 43 Anna Eklund, Anna Johnell, Linda
Tofeldt, Johanna Tengdelius-Brunell,
Maria Andersson, Cajsa-Lisa Ivarsson,
Jonas German, Elin Sjökvist och Elinor
Andersson (2017)
Vattennivåer, tappningar,
vattentemperaturer och is i Hjälmaren
Beräkningar för dagens och framtidens
klimatförhållanden
- 44 Anna Eklund, Linda Tofeldt, Anna
Johnell, Maria Andersson, Johanna
Tengdelius-Brunell, Jonas German,
Elin Sjökvist, Maria Rasmusson,
Ulrika Harbman, Elinor Andersson
(2017)
Vattennivåer, tappningar,
vattentemperatur och is i Väner
Beräkningar för dagens och framtidens
klimatförhållanden
- 45 Sofie Schöld, Cajsa-Lisa Ivarsson,
Signild Nerheim och Johan Södling
(2017) Beräkning av högsta
vattenstånd längs Sveriges kust
- 46 Katarina Stensen, Johanna Tengdelius-
Brunell, Elin Sjökvist, Elinor
Andersson, Anna Eklund (2017)
Vattentemperaturer och is i Mälaren
Beräkningar för dagens och framtidens
klimatförhållanden
- 47 Jonas Olsson, Peter Berg, Lennart
Wern, Johan Södling, Lennart
Simonsson,
Wei Yang, Anna Eronn (2017)
Extremregn i nuvarande och framtida
klimat – Analyser av observationer och
framtidsscenarier.
- 48 Signild Nerheim, Sofie Schöld, Gunn
Persson och Åsa Sjöström (2017)
Framtida havsnivåer i Sverige
- 49 Anna Eklund, Katarina Stensen,
Ghasem Alavi, Karin Jacobsson, Diala
Abdoush (2018)
Sveriges stora sjöar idag och i
framtiden. Klimatets påverkan på
Vänern, Vättern, Mälaren och
Hjälmaren. Kunskapssammanställning
januari 2018
- 50 Gunn Persson, Christina Wikberger,
Jorge Amorim (2018)
Klimatanpassa städer med grönska
- 51 Katarina Losjö, Lennart Wern, Johan
Södling (2019)
Uppföljning av riktlinjer för
bestämning av dimensionerande flöden
- 52 Sjökvist, Elin (2019)
Sommaren 2018 – en glimt av
framtiden?
- 53 Översättning av Summary for
Policymakers (2019)
FN:s klimatpanel – Sammanfattning
för beslutsfattare
Global uppvärmning på 1,5°C
- 54 Karin Hjerpe, Therése Sjöberg, Karin
Lundgren Kownacki, Lotta Andersson,
Åsa Sjöström (2020)
Myndigheters arbete med
klimatanpassning 2019
- 55 Therése Sjöberg, Karin Hjerpe, Karin
Lundgren Kownacki, Lotta Andersson
(2020)
Kommunernas arbete med
klimatanpassning 2019 - Analys av
statusrapportering till SMHI
- 56 Klimatförändringar och biologisk
mångfald – Slutsatser från IPCC och
IPBES i ett svenskt perspektiv (2020)
- 57 FN:s klimatpanel IPCC –
Sammanfattning för beslutsfattare
(2020)
Specialrapport om Klimatförändringar
och marken
- 58 FN:s klimatpanel IPCC –
Sammanfattning för beslutsfattare
(2020)
Specialrapport om Havet och
kryosfären i ett förändrat klimat
- 59 Erik Engström
(ej publicerad)

60 Karin Hjerpe, Åsa Sjöström (2020)
Förslag på system för uppföljning och
utvärdering av det nationella arbetet
med klimatanpassning

61 Erik Kjellström (2021)
Betydelsen av storskalig atmosfärisk
cirkulation för Sveriges temperatur-
och nederbörds klimat
En jämförelse av normalperioder

62 Karin Hjerpe, Therése Sjöberg, Bodil
Englund, Anna Jonsson (2021)
Myndigheters arbete med
klimatanpassning 2020

OBS ! Ingenting får raderas efter denna text, och den skall inte tas bort förrän
du är klar !

Denna sida är avsiktligt blank



Sveriges meteorologiska och hydrologiska institut
601 76 NORRKÖPING
Tel 011-495 80 00 Fax 011-495 80 01

ISSN

