



Norges miljø- og
biovitenskapelige
universitet

Masteroppgave 2023 30 stp
Fakultet for realfag og teknologi

Kalibrering av en overvannsmo- dell ved bruk av maskinl ring. SWMM- modell for Sandsli i Bergen

Frank Andersen
Vann- og Milj teknikk

Forord

Denne masteroppgaven er skrevet ved fakultet for realfag og teknologi ved Norges Miljø- og Biovitenskapelige Universitet (NMBU), og er avsluttende oppgave i forbindelse med mitt to-årig studie ved linjen Vann- og Miljøteknikk på NMBU. Oppgaven tar for seg kalibrering av en overvannsmodell ved å bruke maskinlæring. Hensikten med oppgaven var å utforske muligheter til å lette arbeidet, og begrense nødvendighet tidsbruk i forbindelse med kalibrering av en slik modell.

Takk til min veileder Kim Aleksander Haukeland Paus ved NMBU for meget god veiledning, støtte, og tilbakemeldinger gjennom arbeidet med oppgaven.

Sammendrag

Urbanisering og klimaendringer fører til behov for hydrologiske modeller som kan beskrive urban avrenning. Parametere i hydrologiske modeller er ofte ikke nøyaktig kjent, eller kan være usikre, og må derfor estimeres ved å utføre kalibrering. Manuell kalibrering ved å «prøve og feile» kan være avhengig av at den som utfører modelleringsarbeidet gjør subjektive vurderinger og valg på bakgrunn av erfaring. Prosessen kan være svært tidkrevende. En alternativ metode å kalibrere på for å imøtekomme disse utfordringene er å bruke maskinlæring.

I denne oppgaven er det forsøkt å kalibrere en eksisterende overvannsmodell for Sandsli i Bergen ved å bruke maskinlæring, og det er brukt differensiell evolusjon (DE) for å lete etter de optimale parameter verdiene under kalibrering. Kling Gupta Efficiency (KGE) er brukt som målfunksjon ved kalibreringen. Ved validering er både KGE, PEAK and totalt volum undersøkt. Modellen er bygget i US EPAs Storm Water Management Model (SWMM). Kalibreringen og valideringen er «automatisert» ved å lage kode i R for både å kjøre SWMM, evaluere resultater og justere variabler som brukes til å kalibrere.

Antall variabler det kalibreres med, og antall iterasjoner (videre omtalt som antall generasjoner) som brukes ved kalibrering kan ha betydning for resultatet både ved kalibrering og validering. I tillegg kan det ha innvirkning på nødvendig tidsbruk. Hovedformålet med oppgaven er å utforske mulighetene for å begrense nødvendig tidsbruk i forbindelse med kalibrering og validering av en kompleks nedbør-avløpsmodell når DE brukes i kombinasjon med KGE som målfunksjon.

Resultater i oppgaven indikerer at antall variabler å kalibrere med bør begrenses til et fåtall, samt at valg av variabler bør gjøres basert på resultater fra en sensitivitetsanalyse (SA), det taler for at det ikke er hensiktsmessig å utelate SA for å spare tid og ressurser. Den «automatiserte» metoden å utføre kalibrering og validering på som er brukt i denne oppgaven, viste seg å være tidsbesparende i forbindelse med å finne en god kombinasjonen av variabler å bruke til kalibrering, dette fordi det ble enkelt å teste ulike kombinasjoner, og det gikk stort sett bare på bekostning av mer simuleringstid.

Sammenhengen mellom antall generasjoner og oppnådd KGE var avhengig av hvilke variabler som ble benyttet til kalibrering, og ved å bruke en god kombinasjon av variabler ble trenden at bedre KGE ved kalibrering, medførte bedre KGE ved validering. Det ble også observert at det kan være verdt den ekstra tidsbruken det tar å bruke flere generasjoner (og da flere simuleringer), selv om endringene i KGE ved kalibrering kunne se ut til å ha stoppet opp, eller være liten. Dette fordi en forbedring i KGE under kalibrering på ca. 1%, medførte en forbedring i KGE under validering på ca. 28%. Ved denne endringen i KGE, så man også at totalt volum gikk fra å underestimeres med ca. 22% til å overestimeres med ca. 2%.

Derimot så man at sammenhengen mellom KGE og PEAK i dette tilfellet for flere av de største toppene, generelt ble en overestimering ved lavere KGE, og underestimering ved høyeste oppnådde KGE. Siden underestimering i mange tilfeller er noe man ikke ønsker kunne det i en slik situasjon være hensiktsmessig å ikke bruke like mange generasjoner (stoppe ved en lavere KGE), og dermed kunne spare tid pga. færre generasjoner i dette tilfellet ville bety færre simuleringer.

Summary

Urbanization and climate change lead to a need for hydrological models that can describe urban runoff. Parameters in hydrological models are often not known, or may be uncertain and must therefore be estimated by calibration. Manual calibration by "trial and error" can depend on the subjective assessments and choices based on experience by the modeler. This process can be very time-consuming. An alternative method to calibrate that can meet these challenges, is to use machine learning.

In this study, an attempt has been made to calibrate an existing rainfall-runoff model for Sandsli in Bergen by using machine learning, and differential evolution (DE) has been used to search for the optimal parameter values during calibration. Kling Gupta Efficiency (KGE) have been used to measure the quality of the model during calibration. For validation both KGE, PEAK and total volume have been calculated. The model is built in the US EPA's Storm Water Management Model (SWMM). The calibration and validation are "automated" by creating a code in R that run SWMM, evaluate results and adjust the variables used for calibration.

The number of variables that is used when calibrating, and the number of iterations (from now on referred to as number of generations) during calibration, can have an effect on the result both during calibration and validation. In addition, it may have an impact on time needed in connection with the calibration process. The main purpose of this study is to explore the possibility to reduce the necessary time spent in connection with calibration and validation of a complex rainfall-runoff model when using DE, and KGE is used as the measure of quality.

Results in this study suggests that the number of variables used to calibrate with should be limited to a few, and choosing variables should be made based on results from a sensitivity analysis (SA), and therefor SA may not be omitted in order to save time and resources. The "automated" method of performing calibration and validation used in this study proved to be time-saving when trying to find a good combination of variables to use for calibration, this because it became easy to test different combinations, and mostly just at the expense of more time used for simulations.

The relationship between the number of generations and KGE was dependent on which variables that was used for calibration, and by using a good combination of variables one could see a trend that better KGE during calibration led to better KGE during validation. It was also observed that it may be worth the extra time it takes to use more generations (and thus more simulations), even though the changes in KGE during calibration could appear to have stopped, or be small. This because it was observed that an improvement in KGE during calibration of about 1%, resulted in an improvement in KGE during validation of about 28%. With this change in KGE, it was also seen that total volume went from being underestimated by about 22%, to be overestimated by about 2%.

On the other hand the relationship between KGE and PEAK was in this case for many of the biggest observed flow peaks, generally overestimation at lower KGE, and underestimation at the highest achieved KGE. Since underestimation in many cases is something you don't want, it could be beneficial in such a scenario to use less generations (stop at a lower KGE), and thus one could save time since less generations in this case would mean less simulations.

Innhold

FORORD	I
SAMMENDRAG	II
SUMMARY	III
INNHold	IV
FORKORTELSER	V
1 INTRODUKSJON	1
1.1 PROBLEMSTILLING	1
1.2 FORSKNINGSSPØRSMÅL	2
1.3 STRUKTUR I OPPGAVEN	3
2 METODE	3
2.1 BESKRIVE AV CASE-OMRÅDET.	3
2.2 SWMM	5
2.3 OBSERVASJONER.....	6
2.4 SENSITIVITETSANALYSE.....	6
2.5 KALIBRERING OG VALIDERING	8
2.5.1 Målfunksjoner.....	8
2.5.2 Differensiell evolusjon (DE).....	10
2.5.3 Kalibreringsprosedyrer.....	10
2.6 PROGRAMMERING I R.....	11
2.6.1 Pakkene DEoptim og Swmmr	11
3 RESULTATER OG DISKUSJON	12
3.1 SENSITIVITETSANALYSE.....	12
3.2 KGE VED HVER GENERASJON.	13
3.3 FAKTORER FOR BESTE MODELL	18
3.4 PEAK OG BIAS	18
3.5 DISKUSJON.....	21
4 KONKLUSJONER	27
4.1 VIDERE ARBEID	28
REFERANSER	29
VEDLEGG A – KODE I R	31
VEDLEGG B - HYDROGRAMMER FRA SA	35

Forkortelser

DE - Differensiell evolusjon

Dstore-Imp - Grop magasinering impermeable flater

Dstore-Perm - Grop magasinering permeable flater

KGE – Kling Gupta Efficiency

MaxInf - Max infiltrasjonsrate

MinInf - Minste infiltrasjonsrate

N-Imperv - Mannings n for impermeable flater

N-Perv - Mannings n for permeable flater

NVE - Norges vassdrags- og energidirektorat

OV – Overvann

SA – Sensitivitets analyse

SP – Spillvann

%imp - Prosent impermeable flater

%Slope - Prosent helning

%Zero - Prosent av impermeable flater uten gropmagasinering

2VAR1 - Modell kalibrert ved å justere areal og %slope

2VAR2 - Modell kalibrert ved å justere N-Perv og MinInf.

4VAR - Modell kalibrert ved å justere areal, %slope, N-Perv og MinInf

7VAR - Modell kalibrert ved å justere areal, %slope, N-Perv, MinInf, MaxInf, %imp og delfeltets bredde.

8VAR - Modell kalibrert ved å justere areal, %slope, N-Perv, MinInf, MaxInf, %imp, delfeltets bredde og ledningsruhet.

12VAR - Modell kalibrert ved å justere areal, %slope, N-Perv, MinInf, MaxInf, %imp, delfeltets bredde, ledningsruhet, Dstore-Imp, Dstore-Perm, N-Imperv og %Zero.

1 Introduksjon

1.1 Problemstilling

Økende urbanisering og endringer i klima fører til behov for urbanhydrologiske modeller som kan beskrive urban avrenning (Lawrence et al., 2020). Modeller som kan simulere overvannsavrenning i urbane strøk kan bygges i flere ulike programmer, blant annet model for urban sewers (Mouse) (Alamdari, 2016), DDDurban (Lawrence et al., 2020), MIKE-modeller (Wigestrands & Mathiesen, 2020) og storm water management model (SWMM) (Rossman & Simon, 2022).

SWMM er en dynamisk nedbør- avløpsmodell (Barco et al., 2008), og er en av de mest brukte modellene for å simulere urban avrenning, både mengde og kvalitet (Behrouz et al., 2020). I SWMM trenger man å spesifisere et stort antall stedsspesifikke parametere for å gi en tilstrekkelig beskrivelse av den komplekse sammenhengen mellom nedbør og avrenning. En modell kan inneholde hundrevis eller tusener av delfelt, og mer enn 20 parametere assosiert med seks ulike fysiske prosesser for hvert delfelt. Samtidig er detaljert informasjon om parameterne ofte ikke tilgjengelig, eller de kan være mer eller mindre usikre. Og som en følge er kalibrering av modellen nødvendig for å estimere parameterne (Behrouz et al., 2020).

En mye brukt metode for å kalibrere en modell er å manuelt «prøve og feile» (Behrouz et al., 2020), og denne metoden kan være avhengig av at den som utfører kalibreringsarbeidet tar subjektive valg basert på erfaring (Eckhardt & Arnold, 2001). Prosessen kan være arbeidskrevende, spesielt for store og komplekse modeller, og metoder for automatisk kalibrering har blitt utforsket med mål om å forenkle arbeidet med kalibreringen (Barco et al., 2008).

En alternativ metode å utføre kalibrering på kan være å benytte maskinlæring. Det finnes ulike typer algoritmer som potensielt kan brukes til dette formålet, og en av dem er differensiell evolusjon (DE) (GebreEgziabher & Demissie, 2020; Storn & Price, 1997).

Viktig aspekt ved å bruke DE til å lete etter optimal løsning, er at det må angis antall parametere for optimering, hvor stor populasjonen skal være for parameterne, og hvor mange generasjoner (iterasjoner) som skal brukes for å lete etter optimal løsning (Ardia et al., 2011; Mullen et al., 2011; Fleetwood, u.å.). Hvordan dette angis har blant annet betydning for tidsbruken. Når DE skal benyttes i lag med kalibrering av en SWMM modell er en mulig tilnærming å utføre simulering, deretter bruke resultatet fra simuleringen i forbindelse med evalueringene gjort med DE. Med denne arbeidsgangen vil antall simuleringer øke når populasjon og/eller antall generasjoner øker.

Hvor stor populasjon og generasjon som bør brukes kan variere. Det finnes en generell anbefaling om å bruke en populasjon på minst 10 ganger antall variabler, og minst 200 generasjoner (Ardia et al., 2011; Mullen et al., 2011). Summen av dette kan bli at man trenger å utføre mange simuleringer for å oppnå en god modell. Dette kan bli tidkrevende, spesielt for større og mer komplekse modeller. Det kan derfor være av interesse å undersøke valg av antall variabler, generasjoner, og hvor raskt man kan oppnå en god modell. Kanskje er det mulig for et problem av denne typen å benytte langt færre generasjoner og/eller mindre populasjon, og fremdeles oppnå tilstrekkelig gode resultater.

Ved kalibrering kan det være nødvendig å utføre en sensitivitetsanalyse (SA) for å bestemme hvilke parametere som skal brukes som variabler ved kalibrering av modellen. Prosessen kan være tidkrevende, da det kan innebære å endre en og en parameter, og se hvordan responsen på modellen er (Barco et al., 2008). Samtidig kan parametere være avhengig av hverandre, og denne

avhengigheten får man ikke nødvendigvis et bilde av ved å gjøre manuelle vurderinger med en og en parameter (Multiconsult, 2020). Ved å bruke DE kan det hende at SA kan utelates, og da heller bruke flere variabler med algoritmen, med den fordel at man kan spare seg tiden det hadde tatt å utføre SA. En ulempe er at dette kan medføre at det blir vanskeligere for algoritmen å finne frem til de optimale verdiene for variablene, og derfor nødvendig med flere simuleringer/evalueringer, som igjen vil kreve mer tid (Ardia et al., 2011; Mullen et al., 2011). Et annet fare moment ved å bruke for mange variabler er at modellen kan bli overtilpasset situasjonen ved kalibrering, som vil si at modellen ikke klarer gjenskape observasjoner utenfor situasjonen som kalibreringen beskriver (Herrera et al., 2021).

For å unngå overtilpasning kan man for kalibrering velge ut ulike hendelser som beskriver forskjellig nedbørsituasjoner og/eller initialtilstander i feltet. Samtidig kan det også være tidkrevende og vanskelig å velge ut representative hendelser. Et alternativ kan være å kalibrere for lange perioder, men da på bekostning av simuleringstid. For å kontrollere at modellen ikke er overtilpasset er det nødvendig å utføre validering av modellen. (Patil & Stieglitz, 2015; Razavi & Tolson, 2013).

Ved kalibrering og validering trenger man å angi et kvalitetsmål (hvor godt simuleringer stemmer med observasjoner). Mye brukte mål på dette er Nash Sutcliffe Efficiency (NSE) og Kling Gupta Efficiency (KGE) (Clark et al., 2021; Gupta et al., 2009). Det er vanlig å regne med at jo nærmere KGE kommer verdien 1, jo mer optimal er modellen til å gjenskape observasjoner. $KGE = 1$ skal være et perfekt resultat (Knoben et al., 2019; Rygh, 2022).

Det kan være nødvendig med mange evalueringer/generasjoner (og da mange simuleringer) for få KGE nærmest mulig 1, samtidig kan det hende modellen blir overtilpasset jo nærmere KGE kommer 1 ved kalibrering, og da ikke blir brukbar utenfor situasjonen ved kalibrering. Det kan hende det finnes en bedre løsning (ikke overtilpasset) for modellen ved en lavere KGE, og i så tilfelle kan det være bortkastet å bruke tid og ressurser på å oppnå en KGE så nære som mulig 1.

I denne oppgaven forsøkes det å kalibrere en eksiterende overvannsmoell i SWMM for Sandsli feltet i Bergen. Dette er et felt som er benyttet i tidligere masteroppgaver, blant annet om grunnvannets betydning for urbanavrenning (Rygh, 2022) hvor det ble gjort kalibrering av en moell i programvaren DDDurban. Videre er det valgt å bruke KGE som målfunksjon da denne har vist seg til tider å kunne prestere bedre enn NSE når gjelder estimat av vannføringstopper (Mizukami et al., 2019).

1.2 Forskningspørsmål

Hovedformålet med oppgaven er å utforske mulighetene for å begrense nødvendig tidsbruk i forbindelse med kalibrering og validering av en kompleks nedbør-avløpsmoell når DE brukes i kombinasjon med KGE som målfunksjon. For å tilnærme seg det overordnede målet er følgende forskningspørsmål definert:

1. Hva er sammenhengen mellom KGE, antall variabler og antall generasjoner?
2. Hva er sammenhengen mellom KGE, PEAK og BIAS?

1.3 Struktur i oppgaven

Oppgaven tar for seg en eksisterende manuelt kalibrert modell, og videreutvikler denne via maskinlæring. Det gis først informasjon om den manuelt kalibrerte modellen, deretter beskrives metoden og de ulike verktøyene som benyttes. Så fremstilles og drøftes både resultater og besvarelse av forskningsspørsmålene.

2 Metode

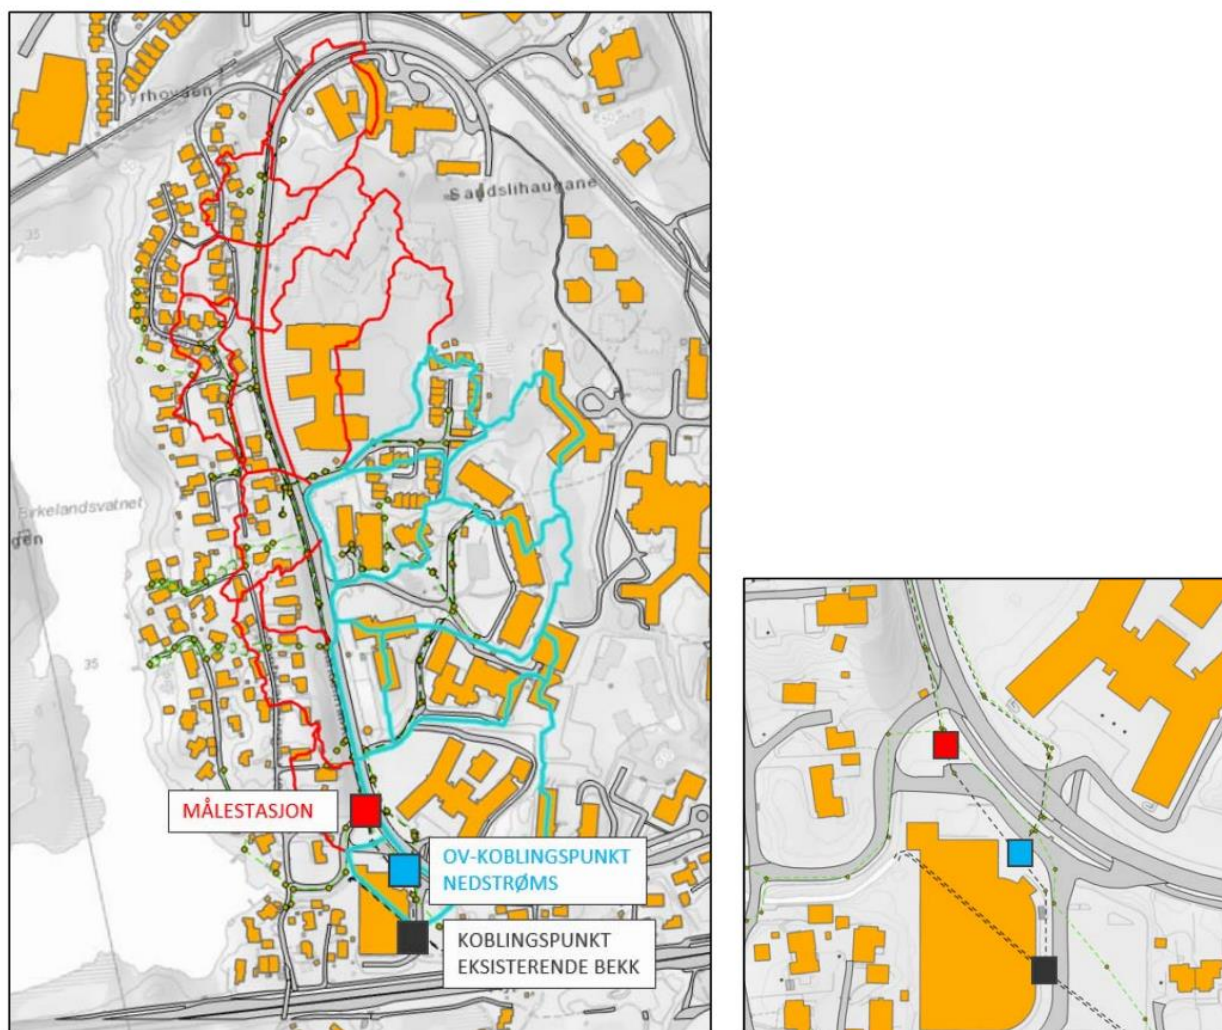
2.1 Beskrive av case-området.

Modellen i oppgaven prøver å gjenskape avrenning for Sandsli-feltet i Bergen. Feltet kan beskrives som urbant med boligfelt, og annen bebyggelse. Det er etablert separat anlegg for spillvann (SP) og overvann (OV). I Sandsli-feltet er det spesielt blitt lagt til rette for å håndtere overvannet ved hjelp av infiltrasjon. For dette feltet er det blitt gjort måling av blant annet nedbør, vannføring og lufttemperatur siden 1982, og nedbørsfeltet knyttet til målestasjonen i Sandsli-feltet er på ca. 9 ha (Multiconsult, 2020). Venstre del av Figur 1 viser en illustrasjon av Sandsli-feltet i grønt, og plassering i Norge til høyre i figuren.



Figur 1. Nedbørsfeltet til målestasjonen i Sandsli-feltet merket med grønt til venstre i figuren, plassering av Sandsli-feltet i Norge til høyre i figuren merket med oransje. (SCALGO Live, 2023)

Den manuelt kalibrerte modellen er laget av Multiconsult i 2020 på oppdrag fra Norges vassdrags- og energidirektorat (NVE), og omtales heretter som referansemodellen. Her er det blitt modellert et større felt enn bare de 9 ha som renner til målestasjonen. Dette er ifølge Multiconsult (2020) gjort for å kunne beregne/ta hensyn til hydrauliske grensebetingelser nedstrøms målestasjonen, da det er antatt at nedstrøms forhold ved større regnhendelser kan ha innvirkning på målestasjonen. I Figur 2 er feltene som ligger oppstrøms målestasjonen (ca. 9 ha) avgrenset med rødt, og de «ekstra» feltene som ligger nedstrøms målestasjonen (ca. 8 ha) avgrenset med blått. Avrenning fra de blå feltene ledes til en overvannsledning som er koblet på ca. 50 meter nedstrøms målestasjonen. Videre er modellen forlenget til påkoblingspunktet i en eksisterende bekk, som går i kulvert, omtrent 160 meter nedstrøms målestasjonen (Multiconsult, 2020).




Figur 2. Avgrensning i SWMM modell, og plassering av målestasjon (Multiconsult, 2020)

I 2017 skjedde det en utbygging i feltet som medførte at et gammelt myrområde ble erstattet med bebygging (Multiconsult, 2020; Rygh, 2022). Modellen laget av Multiconsult inneholder et magasin som har til hensikt å etterligne dette myrområdet. Magasinet kan fremdeles være beskrivende for situasjonen i dag da det innen dette tidligere myrområdet nå skal eksistere et fordrøyningsanlegg iform av en sprengsteinfylling (Rygh, 2022). Ellers er modellen bygget med kummer, delfelt og ledninger for både SP og OV. (Multiconsult, 2020). I denne oppgaven sees det kun på overvann, og derfor er SP nettet fjernet, med den hensikt å redusere simuleringstiden. Videre er komponentene i modellen renumrert og/eller gitt annet navn for å unngå problemer ved kjøring av modellen via koden i R.

2.2 SWMM

SWMM er en urbanhydrologisk dynamisk modell, som er utviklet i regi av det amerikanske miljødirektoratet - Environmental Protection Agency (EPA). Modellen beregner avrenning via ligninger som benytter prinsippene med bevaring av masse, energi og moment. Modellen kan blant annet beregne avrenningsmengde og vannkvalitet gjennom prosesser som overflateavrenning, grunnvannsstrømning, infiltrasjon, snøsmelting og fordrøyning. Modellen kan også simulere fordampning (Multiconsult, 2020).

Ved beregning av avrenningen fra overflaten blir nedbørsfeltene behandlet som ikke-lineære reservoarer med en maksimum gropmagasinering (depression storage, d_s). Avrenning fra overflaten forekommer hvis infiltrasjonkapasiteten blir overskredet og gropmagasineringen samtidig er full (Multiconsult, 2020). Figur 3 viser en forenkling av oppførselen til et nedbørsfelt.



Figur 3. Forenklet illustrasjon av oppførselen til nedbørsfelt i SWMM (Multiconsult, 2020)

Avrenning fra overflaten beregnes med Mannings formel, og det antas uniform strømning over nedslagsfeltets overflate. Nedslagsfeltet er videre antatt å ha rektangulær form. Vanddybden på overflaten (d) blir oppdatert kontinuerlig iløpet av simuleringen. Inputverdier som må oppgis for beregning av overflateavrenning er nedslagsfeltets areal, bredde, gjennomsnittlige helning, andel tette flater, Mannings n for impermeable og permeable flater, samt maksimal gropmagasinering for tette og permeable flater (d_s). For permeable flater vil overvannet infiltrere til grunnen (Multiconsult, 2020).

I SWMM kan det velges ulike infiltrasjonsmetoder, og i modellen laget av Multiconsult brukes Hortons infiltrasjonsmetode. I Hortons metode er infiltrasjonsraten størst i starten av nedbørshendelsen, for deretter å avta til den når en bestemt minimums infiltrasjonsrate. Inputverdier er maks- og minimal infiltrasjonsrate, samt en reduksjonskonstant som bestemmer hvor raskt infiltrasjonsraten faller fra maks til minimum. Det er også mulig å angi en verdi for tiden det tar for grunnen å gå fra mettet til umettet tilstand, og dette kan være nødvendig å angi ved kontinuerlige beregninger (Multiconsult, 2020).

Ved beregning av strømning gjennom ledningene er utgangspunktet bevaring av masse og moment ved å løse St. Venant strømningsligninger. Det kan velges mellom tre metoder for beregning av strømning: stabil-, kinematisk- og dynamisk strømning. Stabil strømning antar uniform og laminær strømning, og gir kortest simuleringstid, men metoden håndterer ikke ledninger med motfall. Kinematisk strømning bruker kontinuitetsligningen og en forenklet versjon av momentligningen. Dynamisk strømning bruker St. Venant strømningsligninger i en dimensjon med bevaring av masse og moment. Dynamisk strømning kan simulere oppstuvning i ledningsnett, men krever lengre beregningstid/simuleringstid enn de to andre alternativene (Multiconsult, 2020).

Valg i denne oppgaven:

I denne oppgaven ses det på avrenningsmengde som følge av overflateavrenning, og det simuleres uten fordampning og snøsmelting.

Det brukes dynamisk strømming i ledninger.

For beregning av infiltrasjon brukes Hortons infiltrasjonsmetode.

Oppløsning på nedbørdata er 15 min, og det brukes intensitet (mm/time).

Reporting step, Runoff step dry Weather og wet weather er valgt til 15 minutter.

Routing step er valgt til 1 minutt.

2.3 Observasjoner

Nedbør og vannføringsdata er hentet fra Sildre.

Det er brukt med 15 minutters oppløsning for både nedbør og vannføring.

2.4 Sensitivitetsanalyse

For å undersøke hvilke parametere modellen er sensitiv på er det utført en sensitivitetsanalyse. Dette er gjort ved å justere en parameter om gangen, simulere, og deretter plote hydrogrammet for å studere responsen. Det er for hver parameter simulert med 30 verdier blant nedre og øvre verdi som vist i tabellene under. Disse 30 verdiene er fordelt jevnt mellom øvre og nedre verdi. Selve analysen er gjort ved å lage et script i R som både endrer verdier i SWMM-modellen, utfører simulering, lagrer resultater, og til slutt plotter hydrogrammene.

I Tabell 1 ser man øvre og nedre verdi brukt ved SA for parametere hvor alle verdier er like i SWMM, samt hva verdien er i referansemodellen (referanse verdi).

Tabell 1. Referanseverdier, samt nedre- og øvre intervallverdi brukt under simulering ved SA, der alle verdier er like for den spesifikke parameteren.

Parameter	Referanse verdi	Nedre verdi	Øvre verdi
Minste infiltrasjonsrate (MinInf) (mm/t)	1,2	0,12	12
Max infiltrasjonsrate (MaxInf) (mm/t)	70	7	700
Prosent av impermeable flater uten gropmagasinerings (%Zero) (%)	25	2,5	100
Grop magasinerings impermeable flater (Dstore-Imp) (mm)	2	0,2	20
Grop magasinerings permeable flater (Dstore-Perm) (mm)	3	0,3	30
Mannings n for permeable flater (N-Perv) (-)	1,2	0,12	12
Mannings n for impermeable flater (N-Imperv) (-)	0,009	0,0045	0,09
Ledningsruhet (-)	0,011	0,0055	0,11

I Tabell 2 ser man øvre og nedre verdier brukt ved SA, samt referanseverdier, for parametere hvor verdiene varierer blant delfeltene. Ved SA er nedre og øvre intervall verdi justert som:

- **Areal, prosent impermeable flater (%imp) og prosent helning (%Slope):**

Nedre verdi = referanse verdi * 0,1 og øvre verdi = referanse verdi * 10

(Prosent impermeable flater justeres til maks 100%)

- **Bredde:** Nedre verdi = referanse verdi * 0,4 og øvre verdi = referanse verdi * 10

Tabell 2. Referanse verdier, samt nedre- og øvre intervallverdi brukt under simulering ved SA, for parametere som har varierende verdi blant delfeltene.

Delfelt	Areal (ha)			Prosent impermeable flater (%imp)			Bredde (m)			Prosent helning (%Slope)		
	A*	B*	C*	A*	B*	C*	A*	B*	C*	A*	B*	C*
A	0,438	0,0438	4,38	65	6,5	100	13	5,2	130	0,07	0,007	0,7
B	0,504	0,0504	5,04	35	3,5	100	13	5,2	130	2,98	0,298	29,8
C	2,415	0,2415	4,15	31	3,1	100	36	14,4	360	0,65	0,065	6,5
D	0,764	0,0764	7,64	32	3,2	100	11	4,4	110	3,63	0,363	36,3
E	0,499	0,0499	4,99	35	3,5	100	12	4,8	120	2,62	0,262	26,2
F	1,062	0,1062	0,62	39	3,9	100	18	7,2	180	1,43	0,143	14,3
G	0,436	0,0436	4,36	8	0,8	80	13	5,2	130	3,8	0,38	38
H	1,844	0,1844	8,44	23	2,3	100	31	12,4	310	1,23	0,123	12,3
I	0,660	0,0660	6,60	8	0,8	80	18	7,2	180	2,15	0,215	21,5
J	1,029	0,1029	0,29	30	3	100	26	10,4	260	1,64	0,164	16,4
K	1,074	0,1074	0,74	19	1,9	100	21	8,4	210	2,39	0,239	23,9
L	0,556	0,0556	5,56	8	0,8	80	17	6,8	170	2,47	0,247	24,7
M	0,531	0,0531	5,31	10	1	100	9	3,6	90	1,09	0,109	10,9
N	1,784	0,1784	7,84	6	0,6	60	19	7,6	190	1,1	0,11	11
O	1,089	0,1089	0,89	6	0,6	60	16	6,4	160	1,44	0,144	14,4
P	0,625	0,0625	6,25	8	0,8	80	10	4	100	0,97	0,097	9,7
Q	0,425	0,0425	4,25	7	0,7	70	11	4,4	110	2,99	0,299	29,9
R	0,554	0,0554	5,54	6	0,6	60	12	4,8	120	1,49	0,149	14,9
S	0,295	0,0295	2,95	8	0,8	80	7	2,8	70	0,22	0,022	2,2
T	0,517	0,0517	5,17	8	0,8	80	7	2,8	70	0,22	0,022	2,2
U	0,328	0,0328	3,28	19	1,9	100	10	4	100	1,39	0,139	13,9
V	0,408	0,0408	4,08	6	0,6	60	10	4	100	1,39	0,139	13,9

A: Referanse verdi

B: Nedre verdi

C: Øvre verdi

Verdiene er i dette tilfellet valgt med tanke på at DE skal finne den optimale løsningen uten at det trenger å være «fysisk» korrekt, og verdiene kan derfor være utenfor erfaringstall for parametere vist i Tabell 1, samt kart og GIS info for parametere i Tabell 2. I SWMM er det antatt at dybden på overflate strømmingen er veldig liten sammenlignet med bredden på delfeltet, og man må være påpasselig med å ikke justere bredden på delfeltene så liten at denne antagelsen ikke lenger blir gyldig. Blir bredden for liten oppstår feil ved beregning av avrenningen (Barco et al., 2008).

Fremgangsmåten for å utføre sensitivitetsanalysen ble gjort i samarbeid med en annen masteroppgave som skrives nå våren 2023, og har tittel «Kalibrering og validering av SWMM-modell for grønt tak på Vega Scene ved bruk av maskinlæring».

2.5 Kalibrering og validering

Periode brukt til kalibrering er:
15.09.2021 til 28.11.2021

Periode brukt til validering er:
09.03.2022 til 17.11.2022

2.5.1 Målfunksjoner

Som nevnt i problemstillingen brukes KGE i denne oppgaven som mål på hvor godt simuleringer og observasjoner samsvarer. KGE (-) beregnes i denne oppgaven med ligning (1) (Knoben et al., 2019):

$$KGE = 1 - \sqrt{(r - 1)^2 + \left(\frac{Q_{avg,sim}}{Q_{avg,obs}} - 1\right)^2 + \left(\frac{SD_{sim}}{SD_{obs}} - 1\right)^2} \quad (1)$$

Hvor :

- r = Pearsons korrelasjonskoeffisient. (Lineær korrelasjon mellom observeringer og simulering)
- $Q_{avg,sim}$ = gjennomsnittlig simulert vannføring
- $Q_{avg,obs}$ = gjennomsnittlig observert vannføring
- SD_{sim} = standardavviket til simulert vannføring
- SD_{obs} = standardavviket til observert vannføring

KGE har verdier i intervallet -uendelig til 1 (Bigiarini, 2020). Som nevnt under problemstillingen skal KGE nærmere og nærmere 1, føre til bedre og bedre samsvar mellom observert og simulert vannføring. KGE = 1 skal være et perfekt resultat.

For å vurdere hvor godt modellen gjengir totalt avrent volum benyttes i dette tilfellet BIAS som forholdet mellom simulert og observert volum, og beregnes i denne oppgaven med ligning (2) som:

$$BIAS = \frac{\sum Q_{sim}}{\sum Q_{obs}} \quad (2)$$

Hvor:

- $\sum Q_{sim}$ = Sum av simulert vannføring ved Sandsli stasjon pr tidssteg (15 min)
- $\sum Q_{obs}$ = Sum av observert vannføring ved Sandsli stasjon pr tidssteg (15 min)

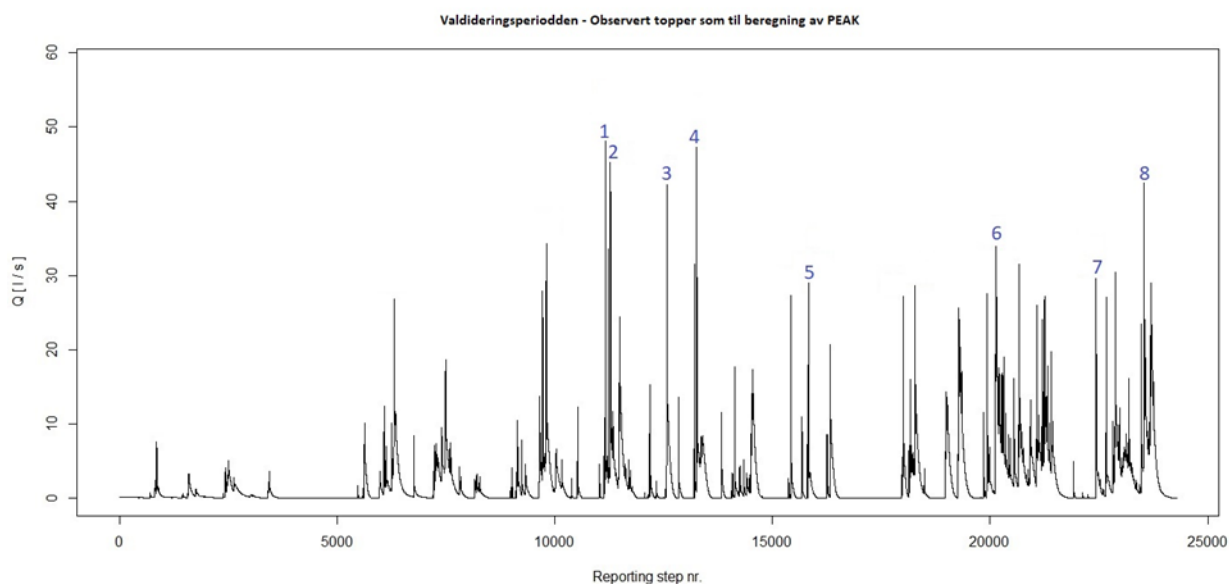
For å vurdere hvor godt modellene presterer når det kommer til størrelse på topper/maks vannføring studeres og presenteres et utvalg av hydrogrammer. I tillegg er det valgt ut 8 topper (Figur 4), hvor PEAK beregnes med ligning (3) som:

$$PEAK = \frac{Q_{sim,maks}}{Q_{obs,maks}} \quad (3)$$

Hvor:

- $Q_{obs,maks}$ = Observert vannføring ved top 1 til 8 (Figur 4) ved Sandsli stasjon for valideringsperioden.
- $Q_{sim,maks}$ = Simulert vannføring ved top 1 til 8 (Figur 4) som svarer til $Q_{obs,maks}$. Det gjøres ikke en vurdering av om simulert top intreffer ved samme tidspunkt (reporting step nr.) som observert top. Simulert top kan derfor intreffe med mer enn 15 minutter feil.

Figur 4 viser hydrogrammet for observert vannføring til valideringsperioden, samt 8 topper det beregnes PEAK for ved validering.



Figur 4. Observert vannføring ved valideringsperioden. Toppene som beregnes PEAK for er nummerert 1-8.

2.5.2 Differensiell evolusjon (DE)

Differensiell evolusjon (DE) er en stokastisk, populasjons-basert optimerings algoritme introdusert av Storn og Price i 1996, som kan være aktuell å bruke til å finne tilnærmede løsninger på problemer som er vanskelig, eller kanskje umulig å løse analytisk (Fleetwood, u.å.). DE er spesielt egnet til å finne globalt minimum til funksjoner med reelle verdier av reelle parameter verdier, og krever ikke at funksjonen må være hverken kontinuerlig eller differensierbar (Ardia et al., 2011; Mullen et al., 2011)

DE blir klassifisert som en genetisk algoritme som bruker operasjonene «crossover», mutasjon og utvalg på en populasjon for å minimere en objektiv funksjon over et satt antall generasjoner (Ardia et al, 2011; Mullen et al, 2011).

Det må angis størrelse på populasjonen, defineres parametervektor, samt øvre og nedre grense for hver parameter (Fleetwood, u.å.). Initialisering innebærer at det gjettes på de første parameter verdiene innenfor øvre og nedre grense, eller at verdiene angis av brukeren. Hver generasjon involverer å lage en ny populasjon utifra de nåværende medlemmene i populasjonen, og hver parameter går gjennom mutasjon, crossover og utvalg, som innebærer at algoritmen prøver å finne de parameterverdiene som vil minimere angitt objektiv funksjon. Etersom populasjonen beveger seg nærmere globalt minimum vil distribusjonen til populasjonen minke mer og mer, og dette fortsetter inntil et satt stopp kriterie er nådd (Ardia et al., 2011; Mullen et al., 2011). Stopp kriteriet i denne oppgaven blir antall generasjoner, og objektivfunksjonen blir den negative verdien av KGE beregnet med ligning (1) i avsnitt 2.5.1 .

2.5.3 Kalibreringsprosedyrer

For å drøfte forskningsspørsmål 1 kalibreres modeller ved å bruke ulike kombinasjoner av variabler. Det vil brukes variabler som både er sensitive og lite/ikke sensitive. Kombinasjon gjøres basert på resultater fra sensitivitetsanalysen, se avsnitt 3.1.

For å drøfte forskningsspørsmål 2 velges modellen som får høyest KGE under kalibrering, og undersøker denne videre for hvordan PEAK og BIAS henger sammen ved ulike KGE.

Det benyttes observert nedbør- og vannføringsdata til å utføre kalibreringen mot, se avsnitt 2.3. R brukes til å kjøre SWMM-modellen, beregne KGE, beregne med DE, oppdatere modellen. Og deretter gjentas samme steg for et bestemt antall iterasjoner (generasjoner). Koden skrevet i R finnes i Vedlegg A – Kode i R.

2.6 Programmering i R

2.6.1 Pakkene *DEoptim* og *Swmmr*

For å utføre DE brukes pakken *DEoptim* (Ardia et al., 2011; Mullen et al., 2011). I denne oppgaven er det angitt følgende argumenter:

fn: Objektivfunksjonen som skal optimeres (minimeres). Funksjonen i denne oppgaven gjør følgende:

- Justerer alle verdiene i SWMM modellen for valgt parameter ved å multiplisere dem med en faktor. Det brukes en faktor pr SWMM parameter som skal justeres.
- Utfører simulering av SWMM modellen med de justerte parameter verdiene.
- Henter ut simulert resultater og bruker dem sammen med observeringer til å beregne KGE.
- Returner den negative verdien til KGE (siden DE søker etter minimum som optimal verdi).

Algoritmen DE vil her prøve å finne de faktorene som justerer SWMM parameterne slik at den negative verdien av KGE kommer nærmest mulig -1.

lower, upper:

To vektor hvor man spesifiserer en øvre og nedre grense for hver parameter, i parameter vektoren (som nevnt i avsnitt 2.5.2), som i dette tilfellet er faktorene som brukes til å justere verdiene til parameterne som brukes til å kalibrere SWMM modellen. Grensene er satt lik grensene det er gjort SA innen, se Tabell 1 og 2 under avsnitt 2.4 om Sensitivitetsanalyse.

Under **control = DEoptim.control()** er det valgt å angi CR = 0,9, F = 0,8, populasjon (NP) = 5 og antall generasjoner (itermax) = 50.

Verdiene for CR og F er valgt på bakgrunn av at det er en generell anbefaling (Ardia et al., 2011; Mullen et al., 2011), mens valgt populasjon er gjort med bakgrunn å begrense antall simuleringer pr generasjon. Ved å benytte flere generasjoner kan det være mulig å oppnå bedre resultat (KGE nærmere 1), men antall generasjoner forlenger simuleringstiden og derfor begrenset til 50 i denne oppgaven, som med pc til rådighet tilsvarer en simuleringstid på ca. 24 timer (når populasjonen er valgt lik 5).

Pakken *swmmr* (Leutnant & Doering, 2018) er brukt både for å kjøre simulering av SWMM og hente ut simuleringresultatene via koden i R, og pakken *zoo* (Zeileis & Grothendieck, 2005) for å lese SWMM resultater. Det er brukt pakkene *readxl* (Wickham & Bryan, 2023) og *openxlsx* (Schauberger et al., 2023) for å skrive resultater i R over til excel fil.

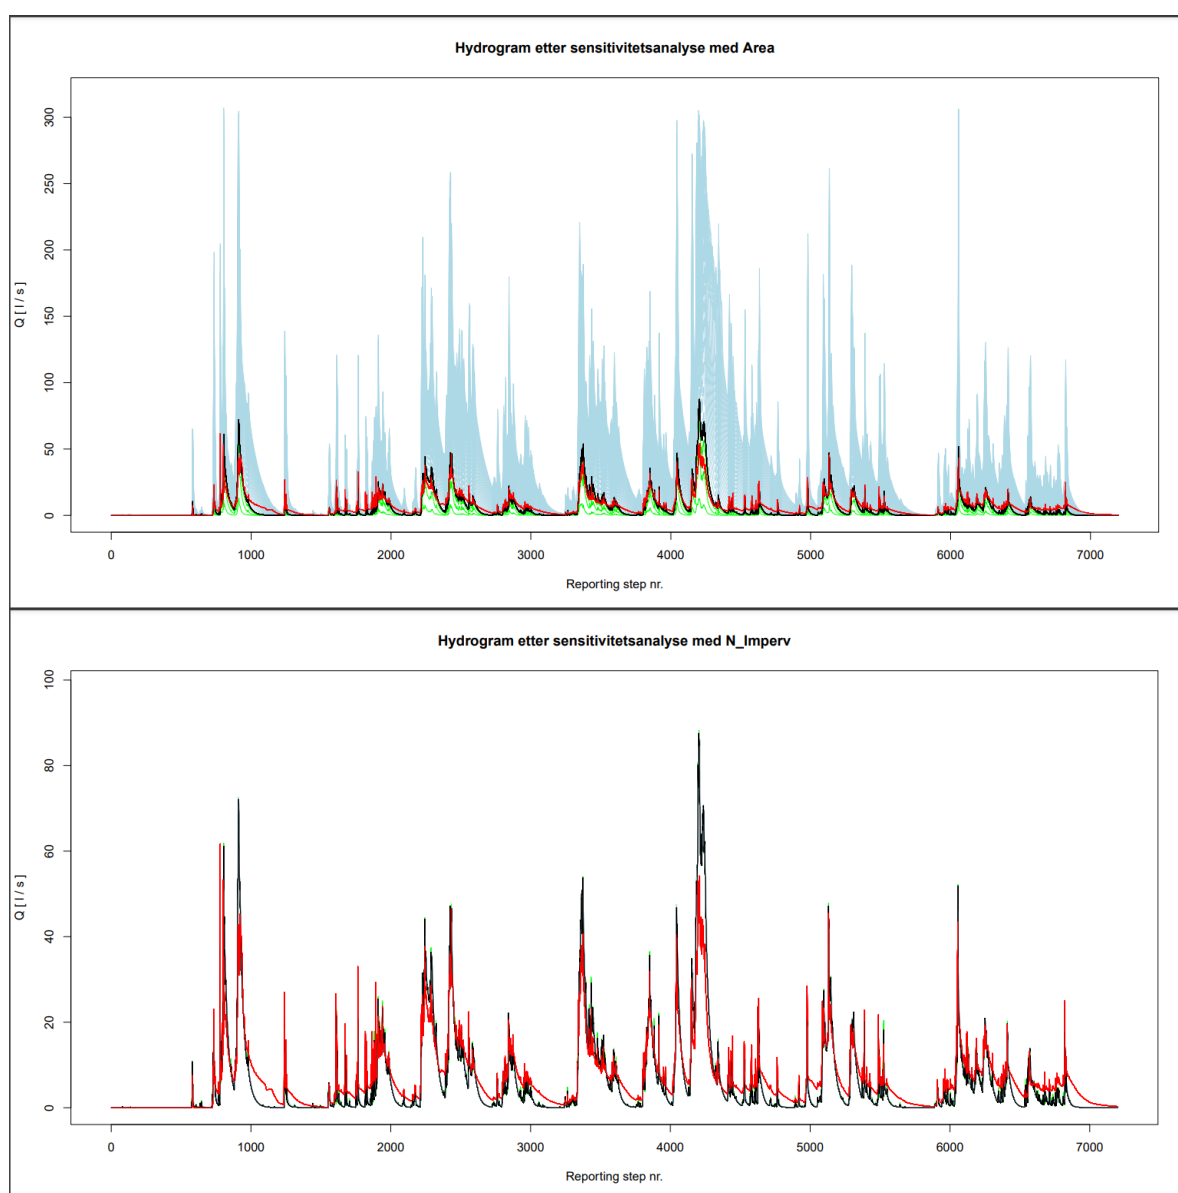
Koden som er brukt for kalibrering og validering finnes i Vedlegg A – Kode i R.

3 Resultater og diskusjon

3.1 Sensitivitetsanalyse

Analysen viste at parameterne areal, prosent helning, prosent impermeable flater, delfeltets bredde, minste infiltrasjonsrate og mannings n for permeable flater var sensitive parametere. Areal viser seg å gi størst utslag på toppene, og samtidig gode utslag ellers i hydrogrammet. Som eksempel vises resultat for parameterne areal og mannings n for impermeable flater på Figur 5. Alle hydrogrammer fra analysen finnes i Vedlegg B - Hydrogrammer fra SA.

Figur 5 viser hydrogrammene fra sensitivitetsanalysen med areal øverst (sensitiv) og N-Imperv nederst (lite sensitiv). Lyseblå er hydrogrammene hvor justert parameter verdi er større enn ref. verdiene, og grønt er hydrogrammene hvor justert parameter verdi er mindre en ref. verdiene. Sort er hydrogrammet til ref. verdiene. Rødt er observert hydrogram. Sensitiv parameter tilsvarer at man kan se større utslag av grønt og/eller blått i figurene. Merk vertikal aksen er ulik pr parameter.



Figur 5. hydrogrammer fra sensitivitetsanalysen plottet sammen med observasjoner (rødt). Sort = referanse verdier. Grønt justert parameter < referanseverdi, og lyseblå justert parametere > referanse verdi.

3.2 KGE ved hver generasjon.

I dette avsnittet presenteres KGE ved ulike generasjoner med den hensikt å studere om det var nødvendig å bruke alle generasjoner for å oppnå KGE nærest 1, samt hvilken kombinasjon av parametere det oppnås høyest KGE ved for kalibrering og validering.

Basert på hydrogrammene fra resultatene etter SA er det utført følgende kombinasjoner av simuleringer for kalibrering og validering.


Kombinasjon av kun sensitive parametere:

- To parametere: Areal og prosent helning (2VAR1)
- To parametere: Mannings n for permeable flater og Minste infiltrasjonsrate (2VAR2)
- Fire parametere: 2VAR1 + 2VAR2 (4VAR)

Kombinasjon av både sensitive og lite/ikke sensitive parametere:

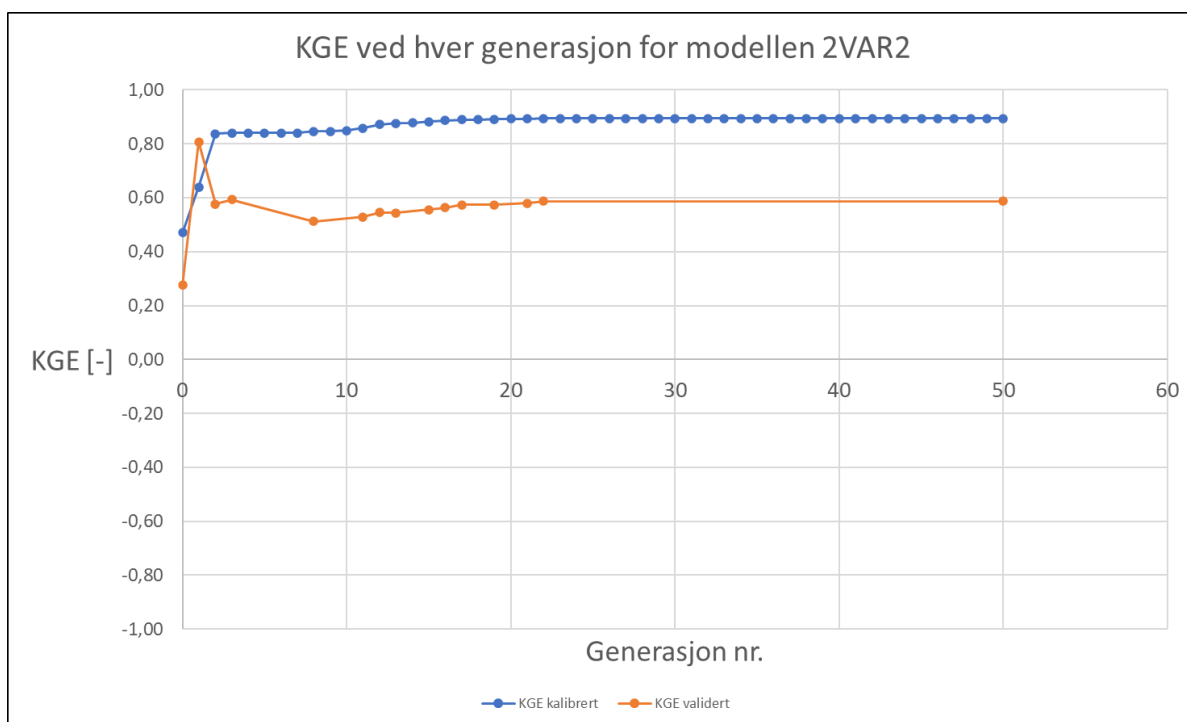
- Syv parametere: 4VAR + max infiltrasjonsrate, bredde og prosent impermeable flater (7VAR)
- Åtte parametere: 7VAR + ledningsruhet (8VAR)
- Tolv parametere: 8VAR + gropmagasinerings permeable flater, gropmagasinerings impermeable flater, prosent impermeable flater uten gropmagasinerings og mannings n for impermeable flater (12VAR). Dette er alle parameterne brukt i SA analysen

Figur 6 viser KGE kalibrert og validert ved ulike generasjoner for modellen 2VAR1. Man ser det ble oppnådd en KGE på ca. 0,7 ved kalibrering og ca. 0,56 ved validering



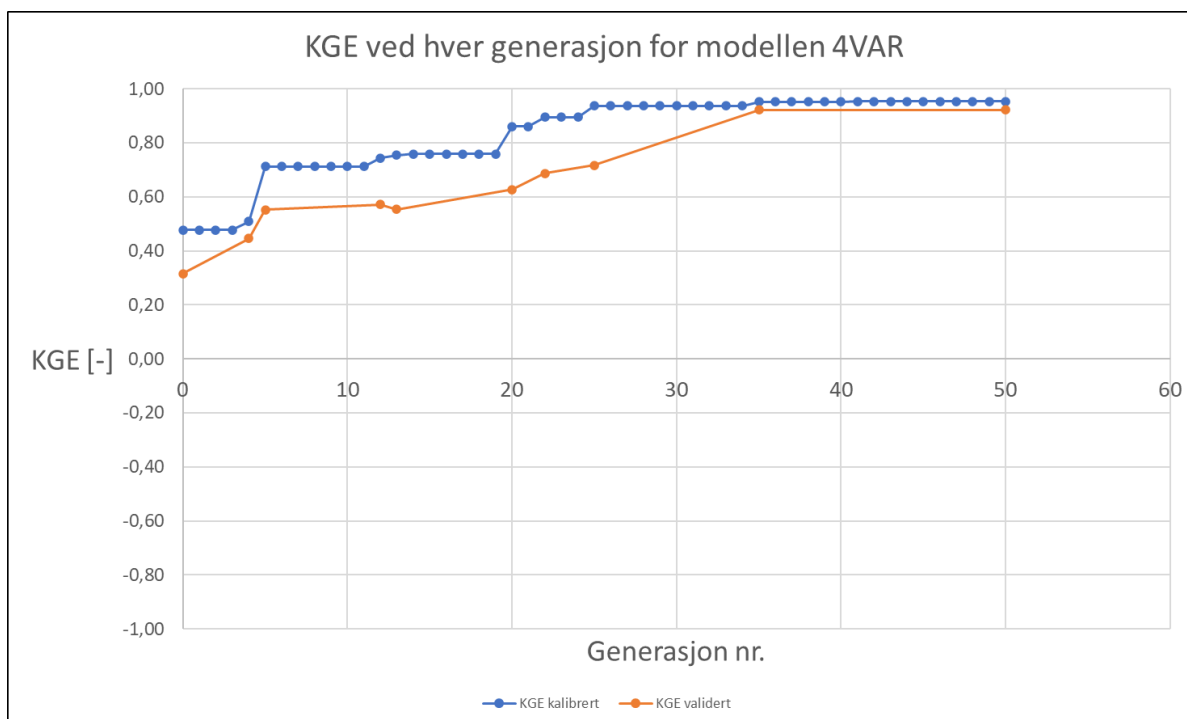
Figur 6. KGE og generasjoner for modellen 2VAR1.

Figur 7 viser KGE kalibrert og validert ved ulike generasjoner for modellen 2VAR2. Man ser det ble oppnådd en KGE på ca. 0,89 ved kalibrering og ca. 0,59 ved validering




Figur 7. KGE og generasjoner for modellen 2VAR2.

Figur 8 viser KGE kalibrert og validert ved ulike generasjoner for modellen 4VAR. Man ser det ble oppnådd en KGE på ca. 0,95 ved kalibrering og ca. 0,92 ved validering




Figur 8. KGE og generasjoner for modellen 4VAR.

Figur 9 viser KGE kalibrert og validert ved ulike generasjoner for modellen 7VAR. Man ser det ble oppnådd en KGE på ca. 0,73 ved kalibrering og ca. 0,61 ved validering




Figur 9. KGE og generasjoner for modellen 7VAR.

Figur 10 viser KGE kalibrert og validert ved ulike generasjoner for modellen 8VAR. Man ser det ble oppnådd en KGE på ca. 0,66 ved kalibrering og ca. 0,31 ved validering



Figur 10. KGE og generasjoner for modellen 8VAR.

Figur 11 viser KGE kalibrert og validert ved ulike generasjoner for modellen 12VAR. Man ser det ble oppnådd en KGE på ca. 0,86 ved kalibrering og ca. 0,50 ved validering.



Figur 11. KGE og generasjoner for modellen 12VAR.

Tabell 3 oppsummerer Figur 6 til Figur 11, og viser høyeste oppnådde KGE ved kalibrering for hver modell, samt ved hvilken generasjon det ble oppnådd, og hvilken KGE det ga ved validering. (Se begynnelsen av avsnittet eller Forkortelser for modellbetegnelse)

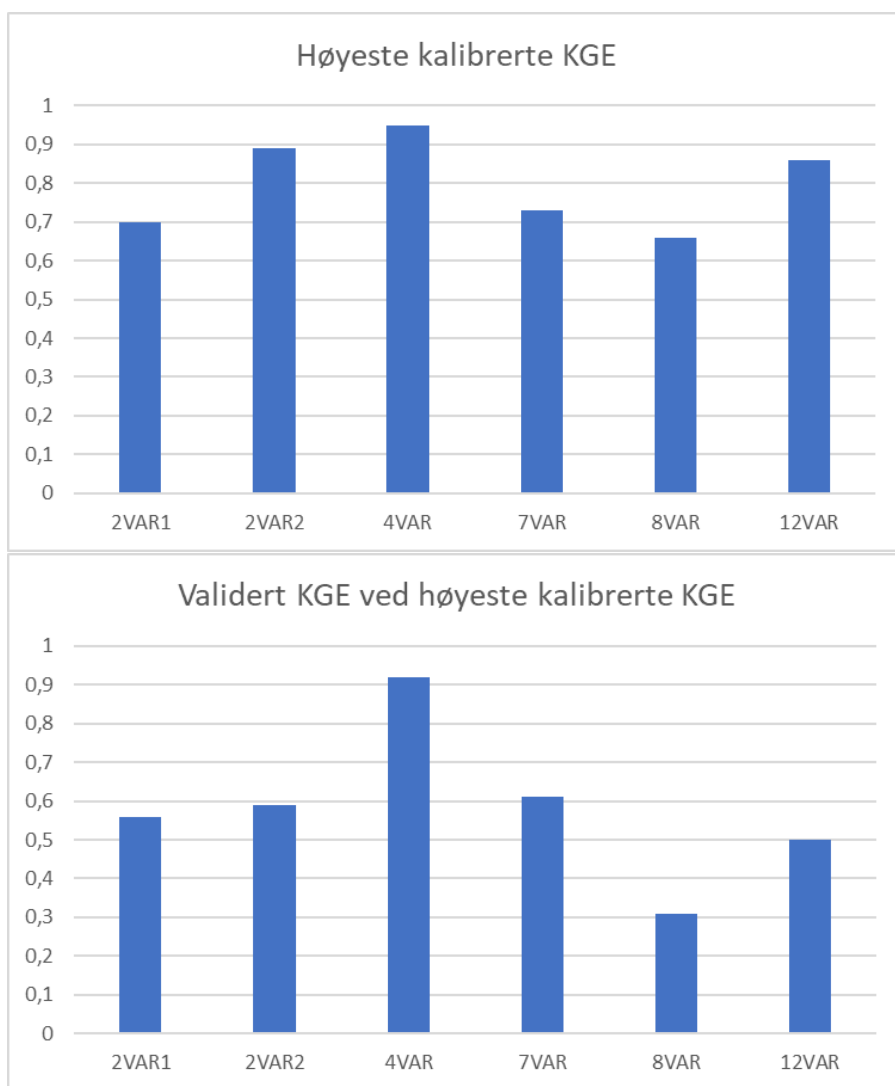
Tabell 3. Høyestes oppnådde KGE ved kalibrering, samt generasjon og KGE ved validering.

Modell	Høyeste oppnådde KGE ved kalibrering	Oppnådd ved generasjon nr	KGE ved validering	Figur
2VAR1	0,70	35	0,56	Figur 6
2VAR2	0,89	16	0,59	Figur 7
4VAR	0,95	35	0,92	Figur 8
7VAR	0,73	47	0,61	Figur 9
8VAR	0,66	44	0,31	Figur 10
12VAR	0,86	49	0,50	Figur 11

Kommentar høyest oppnådde KGE

I Tabell 3 ser man at ved å bruke 2 sensitive parametere hver for seg (2VAR1 og 2VAR2) ble det oppnådd ganske forskjellig KGE (0,70 og 0,89), men ved validering ble det mindre forskjell i KGE (0,56 og 0,59). Ved å kombinere 2VAR1 og 2VAR2 til modellen 4VAR, fikk man oppnådd høyest KGE av alle modeller, både ved kalibrering (0,95) og validering (0,92). Ved å øke til 7 og 8 parametere (7VAR og 8VAR) ser man det blir nedgang i KGE både ved kalibrering og validering. Derimot ser man at ved å øke til 12 parametere blir det en økning i kalibrert KGE fra 0,66 ved 8VAR til 0,86 ved 12VAR. Og 0,31 til 0,5 for validert KGE.

Figur 12 illustrere at det i dette tilfellet var best å gjøre et utvalg blant sensitive parameteren for å oppnå best KGE både ved kalibrering og validering.



Figur 12. KGE for de ulike modellene.

3.3 Faktorer for beste modell

Tabell 4 viser (optimerte) faktorer fra DE, samt referanseverdier og nye verdier for modellen 4VAR, som fikk best KGE i denne oppgaven (0,95 kalibrert og 0,92 validert).

Tabell 4. Faktorer og nye verdier

	Areal	Helning	N-Perv	Min. Infil. Rate
Faktorer (-)	0,59	6,02	5,63	0,27
Referanse verdi	Forskjellig pr delfelt. Ny verdier er referanseverdier som vist i Tabell 2 under avsnitt 2.4 om SA, multiplisert med faktor.		1,2 (-)	0,5 (mm/t)
Ny verdi			6,76 (-)	0,135 (mm/t)

Man kan se at arealet reduseres med ca. 41%, mens helningen på delfeltene økes ca. seks ganger, og N-Perv er over 5 ganger større enn referanseverdiene, og minste infiltrasjonsrate er redusert med hele 73 %.

3.4 PEAK og BIAS

I avsnitt 3.2 så man at modellen med 4VAR var mulig å kalibrere godt når det gjelder å oppnå en KGE nærmest mulig 1. Det er derimot ikke sikkert en høy KGE svarer til gode resultater for PEAK og BIAS. I dette kapitlet presenteres derfor resultater for disse målfunksjonene ved ulike KGE for modellen 4VAR, og det undersøkes hva som er sammenhengen mellom KGE, PEAK og BIAS for denne modellen.

Figur 13 på neste side viser tre hydrogrammer fra valideringsperioden med modellen 4VAR. På figuren er rød graf simulert hydrogram og sort observert hydrogram. I hydrogrammene vises også PEAK beregnet for de 8 toppene vist i Figur 4 under avsnitt 2.5.1 .


Man kan av øverste hydrogram se at ved høyeste KGE er BIAS svært god (1,02), mens toppene generelt blir underestimert.

På midtre hydrogram kan man se at ved en «middels» KGE er BIAS blitt dårligere (0,63), men samtidig at toppene stort sett ikke er underestimert i samme grad.


På nederst hydrogram kan man se at ved laveste KGE (0,32) blir toppene stort sett overestimert, samtidig er BIAS god (1,05)

Fra de tre hydrogrammene ser det ut til at det er en trend at PEAK går fra å overestimeres ved lavere KGE til å underestimeres ved høyeste oppnådde KGE.


Validering - 4VAR - Modell med høyest KGE under kalibrering (0,95)



Validering - 4VAR - Modell med "middels" KGE under kalibrering (0,71)

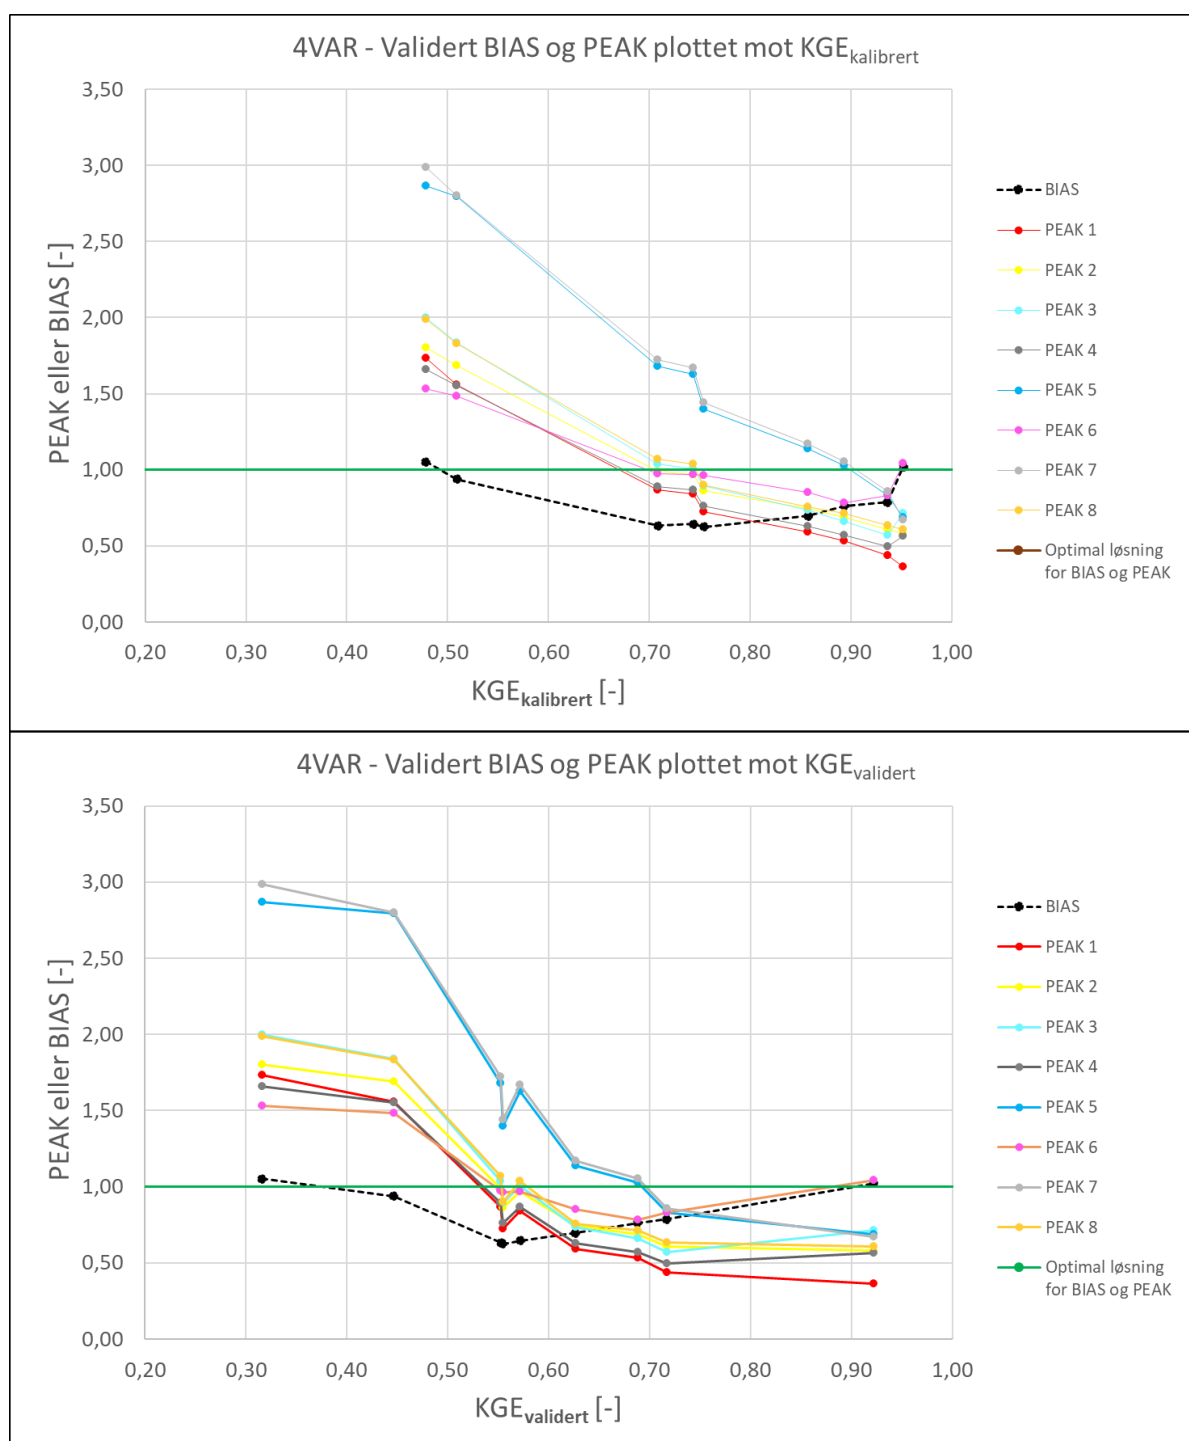


Validering - 4VAR - Modellen med lavest KGE under kalibrering (0,48)



Figur 13. Hydrogrammer fra valideringsperioden for modellen 4VAR, plottet sammen med observasjoner. Små bokser viser PEAK for top 1-8.

Figur 14 viser BIAS og PEAK 1 til 8 på Figur 4 (fra valideringen), plottet mot KGE kalibrert (øverst), og KGE validert (nederst).



Figur 14. BIAS og PEAK 1-8 ved ulike KGE kalibrert (øverst), og validert (nederst)

Man ser man at de ved laveste KGE er BIAS nær 1, mens PEAK overestimeres. Ettersom KGE øker så ser man at PEAK starter en «nedadgående» trend. Det samme skjer for BIAS, og man kan observere at ved «duppen» på BIAS kurven (sort stiplet graf) har flere av PEAK har sin beste løsning. Ved videre økning i KGE, ser man derimot at BIAS starter å gå mot 1 igjen, mens PEAK nå fortsetter sin «nedadgående» trend, og blir underestimert ved høyere KGE. Unntaket er PEAK 6 (rosa graf) som kommer nær 1.


3.5 Diskusjon

Sammenligning med andre caser for Sandsli

Modellen med fire variabler lot seg kalibrere godt når det gjelder KGE og BIAS. Resultater oppnådd i denne oppgaven står i stil med en tidligere masteroppgave av Rygh (2022) hvor det ble utført kalibrering av en DDDurban modell for Sandsli feltet. For omtrent samme kalibreringsperiode, som brukt i denne oppgaven, ble det oppnådd en KGE på 0,87 og BIAS 1,01 (under kalibrering, oppgaven utførte ikke validering). Også her ble det justert på areal for å kalibrere modellen. Selv om det tradisjonelt ikke er vanlig å endre på areal ved kalibrering siden dette er en parameter man ofte kan få god info om fra kart og GIS data, er dette noe også NVE har benyttet seg av ved kalibrering i ulike prosjekter (Rygh, 2022). Man kan nå se at to modeller for Sandsli, ved ulike programmer, oppnådde høy KGE og BIAS ved å justere på arealet til feltet.

Når det gjelder PEAK har man sett i denne oppgaven at en høy KGE førte til underestimering av flere av de største toppene (Figur 13). En mulig årsak til at PEAK resultatene ikke ble så gode kan undersøkes ved å sammenligne med resultater fra referansemodellen.

I Figur 15 er hydrogrammet for referansemodellen plottet for valideringsperioden.



Figur 15. Hydrogram etter validering med referansemodellen plottet sammen med observasjoner.

Av figuren kan man se at BIAS (=0,68) er dårligere enn hva som ble oppnådd under denne oppgaven. Ifølge Multiconsult (2020) er modellen kalibrert mot ekstremhendelser, og ville derfor ikke være egnet for simulering av lange perioder der vannbalanse er viktig, så dette var forventet. Når det gjelder topper kan man derimot se at også referanse modellen i Figur 15, underestimerer flere av de samme toppene som vist i Figur 13. Ved å sette opp resultater i en tabell kan dette synliggjøres.

Tabell 5 viser PEAK 1 til 8 for referansemodellen, modellen med høyest kalibrerte KGE i denne oppgave (0,92), og en annen kalibrert modell i denne oppgaven som fikk KGE 0,63 (ca. samme som referanse modellen).

Tabell 5. Sammenligning av PEAK 1-8 mellom referansemodell og 4VAR.

KGE validert	Referanse -modell	Validert denne oppgaven (4VAR)		
	0,65	0,63	0,92	0,55
Peak 1	0,63	0,36	0,36	0,87
Peak 2	0,81	0,58	0,58	0,99
Peak 3	0,91	0,74	0,74	1,04
Peak 4	0,71	0,57	0,57	0,89
Peak 5	1,11	0,69	0,69	1,68
Peak 6	1,40	1,04	1,04	0,97
Peak 7	1,12	0,67	0,67	1,72
Peak 8	0,76	0,61	0,61	1,07
	Figur 15		Figur 13	Figur 13

I tabellen er toppene som underestimeres i hver modell merket med gult, og topper som overestimeres merket i grønt. Man kan se at det er mange av de samme toppene som underestimeres både i referansemodellen, og den kalibrerte modellen, og det samme for de få toppene som overestimeres. Dette til tross for at de er kalibrert for med forskjellige metoder, og nedbørhendelser.

Dette kan jo være tilfeldig, men et annet alternativ kan være relatert til metoden som er brukt til å justere parameterne referansemodellen ved kalibreringen utført i denne oppgaven. Som forklart i i avsnitt 2.6.1 er alle verdiene for en parameter skalert med en faktor under kalibreringen, det vil si at forholdet for den enkelte parameter ikke endres blant delfeltene, kun at forholdet mellom de ulike parameteren endres seg imellom. Ifølge Multiconsult (2020) blir kalibreringsprosessen enklere å utføre dersom parameteren justeres likt for alle delfelt, men samtidig at det er viktig å indentifisere felt som er betydelig ulike hydrologisk sett, og ikke justere dem på samme måte som de andre.

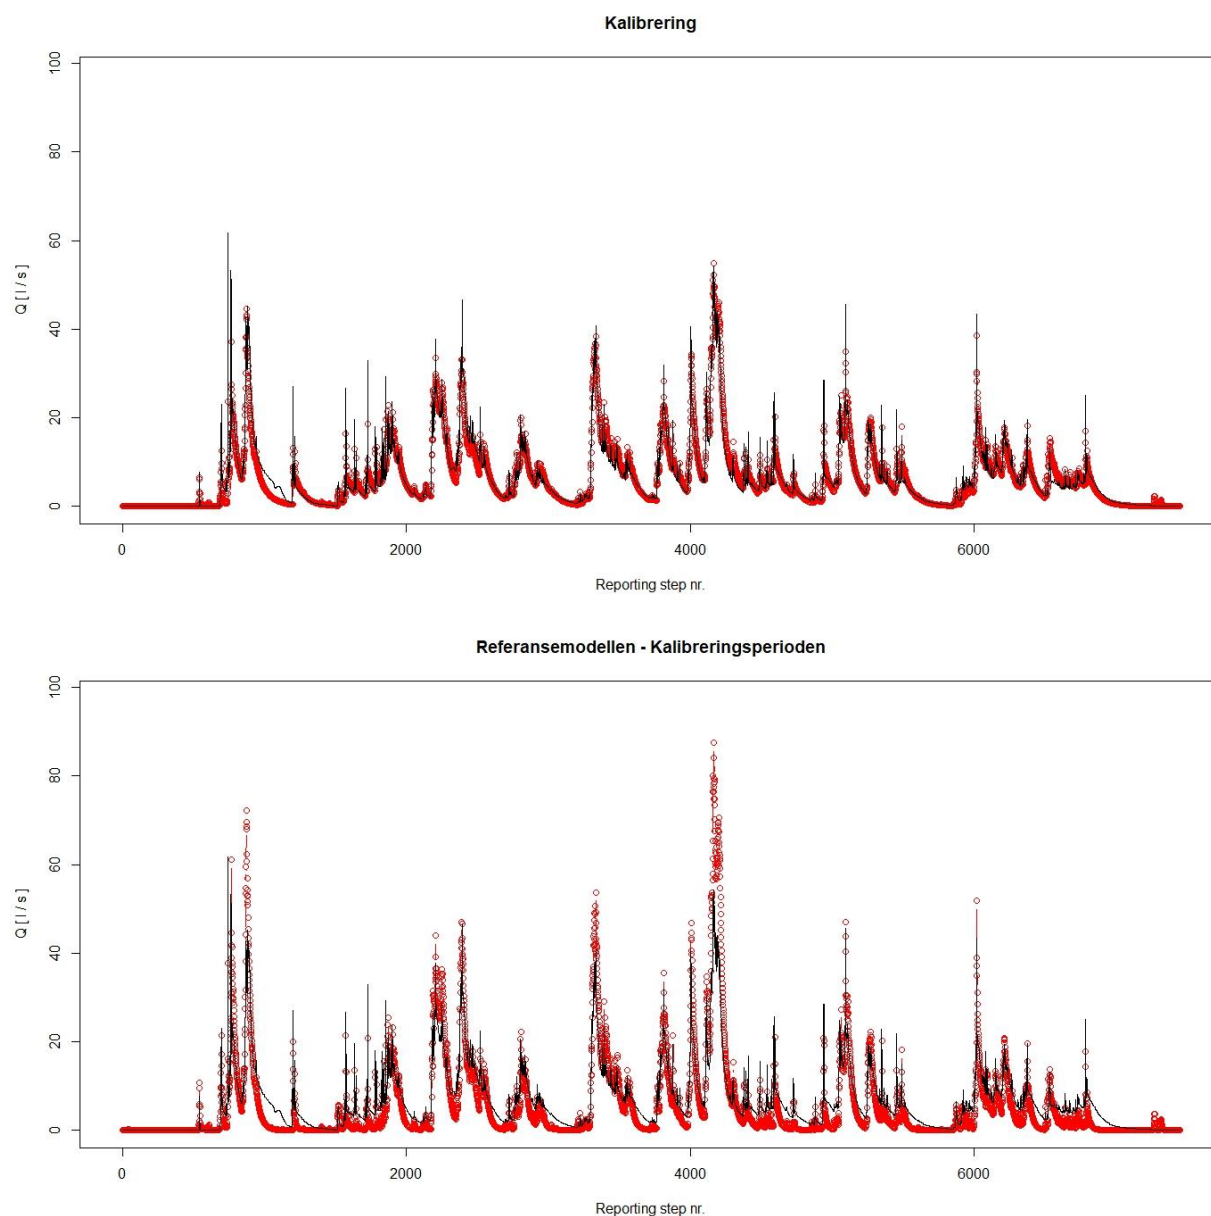
Sett i lys av dette kan det hende dette har medført at ved kalibrering har modellen blitt «låst» i det sporet det var før kalibrering med DE ble satt i gang. Dette kan ytterligere ha blitt forsterket fordi det i denne oppgaven er endret på areal til delfeltene under kalibrering, som igjen egentlig innebærer å endre på alle parametere i delfeltet under ett. Og når man i tillegg ser av hydrogrammet fra SA med areal (Figur 5), at dette er den mest sensitive parameteren av dem, alle kan det ytterligere tale for at dette kan ha skjedd.

Man kunne i stedet heller kanskje oppnådd bedre resultat hva gjelder PEAK, ved å ikke skalere alle parameterne likt. F.eks. kunne man kanskje latt andel impermeable flater varierer blant enkelte delfelt da dette er en parametere som ofte er av betydning for vannføringstopper (Multiconsult, 2020), og ser ut til å være sensitive for dette også i denne modellen, se hydrogrammet til %imp i Vedlegg B - Hydrogrammer fra SA. Samtidig vil hver slik «enkelt justering» bli en egen variabel som DE vil jobbe med å optimere, og da kan det hende det også vil være viktig å prøve finne de feltene som er betydningsfulle og ulike hydrologisk sett, for å kun justere dem. Dette fordi man har sett i denne oppgaven at å øke antall variabler ikke nødvendigvis vil gi noe bedre løsning, både hva gjelder oppnådd KGE ved kalibrering, og validering.

Det kan også pekes på at i SWMM modellen er det som nevnt lagt inn et basseng for å etterligne responsen fra et myrområde som ikke lenger eksiterer. Ifølge Multiconsult (2020) var det ikke mulig å etterligne forsinket avrenning fra myrområdet, og områdene som drenerer til det, uten dette bassenget. Altså skulle bassenget ha stor betydning for hvordan avrenningen i modellen skjer, og det kan muligens ha innvirkning på hvordan modellen lar seg kalibrere.

En annen mulighet er at det kan være usikkerhet ved nedbør og/eller vannføringsdata. Derfor kan det undersøkes hva som er tilfellet også ved kalibreringsperioden.

I Figur 16 er hydrogram for både referansemodellen og modellen (4VAR) som oppnådde høyest KGE ved kalibrering (0,95) vist i rødt, plottet mot observasjoner vist i sort.



Figur 16. Hydrogrammer fra kalibreringsperioden. 4VAR KGE 0,95 (øverst) og referansemodellen nederst begge i rødt. Sort er observasjoner.

Her man kan man se at det også er flere av de samme toppene som underestimeres, samtidig at også største toppen (like til høyre for reporting step nr. 4000), er størst i begge modeller (da betydelig overestimert for referansemodellen). Trenden ser altså nogenlunde lik ut for kalibreringsperioden, og valideringsperioden. Siden dette er ulike datasett for observasjon av

nedbør og vannføring, kan det tale for at årsaken til underestimeringen ikke er grunnet i direkte feil med data.

Derimot kan det hende at oppløsningen som er brukt i denne oppgaven (15 min) har innvirkning på resultatet. Rygh (2022) hevder det for Sandslifeltet vil være bedre å bruke data med en høyere tidsoppløsning pga. konsentrasjonstiden for avrenning fra impermeable flater i Sandslifeltet kan være lavere enn 15 min, og at det i så tilfelle medfører at spissavrenningen forårsaket av disse flatene ikke stemmer med virkeligheten, og kunne være betydelig høyere enn det kan fant ved valgt tidsoppløsning. Man kan se på Figur 16 at største observerte top (ca. ved reporting step nr. 800) ikke blir fanget opp hverken av referanse modellen eller den kalibrerte modellen i denne oppgaven.

Figur 16 viser også at modellen i kalibrert denne oppgaven ser ut til å treffe bedre på resesjonen, og dette kan muligens også være årsaken til at man fikk en bedre BIAS enn hva referansmodellen har. Dette kan være spesielt imponerende med tanke på at denne modellen ikke har noen grunnvannsmodul, og i Sandsli feltet er grunnvann antatt å ha stor betydning for avrenningsforløpet (Rygh, 2022).

Vurdering «nedadgående» trend for PEAK.

At PEAK overestimeres ved de laveste KGE kan muligens tilskrives tilfeldigheter, da DE i dette tilfellet har fått gjettet på start populasjonen. Når det gjelder den «nedadgående» trenden for PEAK ettersom KGE øker (PEAK går fra overestimering til underestimering), er det vanskelig å si hva som kan være årsaken. Det er iløpet av denne oppgaven ikke funnet tidligere studier som viser en slik trend, så med dette utgangspunktet kan det ikke sies om denne oppførselen kun gjelder dette tilfellet. Derimot utførte Behrouz et al. (2020) kalibrering av en modell i SWMM ved å bruke et objektiv for å minimere feil i estimert volum, og et objektiv for å minimere feil i estimert PEAK. Kalibreringen ble gjort med et objektiv om gangen, og det ble funnet at å minimere feil i estimert PEAK og feil i estimert volum kan være konkurrerende objektiver. Madsen (2000) utførte multiobjektiv kalibrering av en modell i MIKE, (objektiver var blant annet PEAK og avrent volum), og fant i sitt tilfelle at det ikke var noe unikt sett av parametere som ga optimal løsning for alle objektiver samtidig. På Figur 14 kan det se ut til at ved endring i PEAK også følger endring i BIAS, og derfor muligens det foregår en konkurrerende oppførsel i dette tilfellet også.

Det er derimot indikasjon på at trenden kan snu for flere av toppene. Av Figur 14 kan man observere at for flesteparten av de ulike KGE ser det ut til at alle toppene øker eller minker i takt, før ved høyere KGE begynner flere av toppene faktisk å endre «kurs», og man kan se at PEAK 3 og 4 også kommer nærmere verdien 1 ved siste «hopp» i KGE (0,94 til 0,95 for kalibreringsperioden), mens PEAK 6 (rosa) blir omtrent lik 1. Samtidig skjer også hoppet i BIAS. Det kan derfor hende at trenden ville snu ved hvis KGE ble enda nærere 1, som jo i teorien skulle skje da $KGE = 1$ er skulle være et perfekt resultat for både BIAS og PEAK, men samtidig kan det ikke utelukkes at modellen heller ville blitt overtilpasset om KGE skulle kommet enda nærere 1 under kalibrering.

Vurdering av egnethet til modellene

Uansett årsak så kan underestimering av topper være noe som sjeldent eller aldri er ønskelig, f.eks. kan det ha uheldige konsekvenser hvis modellen skulle vært brukt i forbindelse med å dimensjonere en ledningsdiameter eller lignende. For en slik situasjon ville modellen i denne oppgaven med høyest KGE kanskje vært minst egnet, da toppene var sterkest underestimert her, samtidig kan det se ut til at denne modellen er best egnet der man ønsker å estimere avrent volum, siden BIAS ble nær perfekt (1,02).

I tabell 4 under avsnitt 3.3, kan man se at modellen ikke lenger har noen god fysisk sammenheng med virkeligheten da det er gjort store endringer både i areal og helning, som jo skulle være ganske sikre parametere. Samtidig kan man se at N-Perv er veldig høy om man sammenligner med f.eks. verdier man kan finne i litteratur, f.eks. oppgitt av Rossmann og Simon (2022). Dette kan medføre at å videreutvikle modellen kan være vanskelig hvis det skulle skje endringer i feltet, og kan være en ulempe ved denne metoden å kalibrere på.

Generasjoner, antall variabler og KGE

Resultatene i denne oppgaven har vist at i dette tilfellet, med valgte forutsetninger, var best å bruke færre variabler for å oppnå en god KGE ved kalibrering, men samtidig måtte man ha et visst antall. Fire variabler (4VAR) presterte bedre enn to variabler (2VAR1 og 2VAR2), se Figur 12. Man har også sett av figurene under avsnitt 3.2 at en høyere KGE under kalibrering ikke alltid gir en høyere KGE ved validering. Dette kan muligens være en følge av at det skjer en overtilpasning.

Perrin et al. (2001) tok for seg ulike lokalt kalibrerte modeller, og undersøkte om modeller med større antall parametere ville presterte bedre, og fant at flere parametere kunne gi en fordel under kalibreringen, men at denne trenden generelt forsvant ved validering. Herrera et al. (2021) nevner også at å bruke mange variabler ved kalibrering ofte leder til gode resultater ved kalibrering fordi modellen vil ha nok fleksibilitet til å kunne tilpasse seg observasjonene, men at det samtidig er risiko for at modellen blir overtilpasset.

Resultater i denne oppgaven viser at å bruke for få variabler ser ut til å lede til «platåer» hvor KGE ved kalibrering ikke ser ut til å bli særlig bedre over flere generasjoner. Det ser man godt fra modellene som er kalibrert med 2 variabler (Figur 6 og Figur 7), hvor det oppstår et «platå» for kalibrert KGE. Derimot modellen med 12 variabler (Figur 11) ser ut til å fremdeles finne frem til høyere KGE ved kalibrering, antagelig fordi den har flere mulige parametere å justere for å tilpasse seg observasjonene, altså ser ut til å samsvare med hva Herrera et al. (2021) nevner om at flere variabler gir større fleksibilitet ved kalibrering.

På Figur 9 og Figur 11 kan det observeres at KGE under kalibrering ser ut til å være stigende også ved siste generasjoner for modellene med 7 og 12 variabler, og derfor muligens disse modellene kunne oppnådd KGE enda nærere 1, hvis antall generasjoner ble økt. Videre er det spesielt tydelig for modellene kalibrert med 8 variabler (Figur 10) og 12 variabler (Figur 11) at det antagelig skjer en overtilpasning siden validert KGE er en del dårligere enn KGE ved kalibrering. Dette kan tale for at disse modellene kanskje ikke er skulle være verdt å utvikle videre ved å bruke flere generasjoner, selv om det ser ut til at KGE ved kalibrering skulle bli bedre. Derimot på Figur 8 for modellen med kalibrert med fire variabler, ser trenden ut til å være at en økende KGE under kalibrering, også gir en økende KGE ved validering. Videre ser man at mellom generasjon 24 til 35 øker kalibrert KGE fra 0,94 til 0,95, og ved samme generasjoner øker validert KGE fra 0,72 til 0,92. Dette tilsvarer ca. 1% og 28 % økning i henholdsvis kalibrert og validert KGE. Derfor kan man i dette tilfellet se at det utgjorde en ganske stor forskjell å fortsette kalibreringen over flere generasjoner selvom man når et «platå». Og derfor kan

betydningen av antall generasjoner, og endring i KGE, være avhengig av hvilke parametere det kalibreres med, og ikke nødvendigvis lede til overtilpasning.

I denne oppgaven ble det oppnådd en høy KGE ved kalibrering ved å bruke bare to variabler til kalibrering (2VAR2, kalibrert KGE 0,89). Faktisk høyere enn ved å bruke 7, 8 eller 12 variabler. Samtidig så man at overtilpasning antagelig også skjedde når det bare ble brukt to variabler til kalibrering. Dette var spesielt tydelig for modellen 2VAR2 (Figur 7) hvor kalibrert KGE ble 0,89 etter bare to generasjoner, men validert KGE ble kun 0,56. Høyeste validerte KGE (ca. 0,82) var for denne modellen ved generasjon en. Altså kunne det se ut til at denne modellen med to variabler ble overtilpasset raskt. Perrin et al. (2001) og Herrera et al. (2021) nevner at modeller med for få parametere kan ha problemer med å gjenskape observasjoner. Selv om modellen i denne oppgaven har ganske mange parametere/variabler, som både er «manuelt kalibrert» og basert på litteratur/erfaring (fra arbeidet Multiconsult gjorde ved å lage referansemodellen), viser resultatene at å velge for få parametere som variabler å kalibrere en modell med kan gi svakt resultat ved validering, selv om tilpasning til observasjoner ved kalibreringen kan være god.

At det ser ut til at det blir vanskeligere for DE algoritmen å finne løsning for KGE nærmere og nærmere 1 når man øker antall variabler å optimere, kan sies å være som forventet, siden det som tidligere nevnt for mange problemer finnes en generell anbefaling om å øke populasjonen i takt med antall variabler. Men man har også sett at det kan være viktigere å velge de «rette» variablene å kalibrere med, enn å velge en større populasjon i takt med antall variabler. Dette er illustrert ved å sammenligne resultater for 4VAR, 2VAR1 og 2VAR2, samt sammenligne resultater for 12VAR og 8 VAR. Hvor man kan se at 4VAR ga bedre resultat enn 2VAR, og 12VAR ga bedre resultat enn 8VAR. Se Figur 12.

Oppsummert ser det ut at det er nyttig å gjøre en SA ved også metoden til kalibrering som er brukt i denne oppgaven, derimot må man klare å velge ut variablene som gir best resultat, og for dette kan man se at det er nyttig å bruke DE i lag med å kjøre SWMM i kode og prøve forskjellige kombinasjoner med variablene. Da slipper man kanskje utføre særlig mye «manuelt» arbeid og vurderinger.

4 Konklusjoner

I denne oppgaven har man sett at antall variabler bør begrenses til de sensitive variablene, men samtidig at man ikke bør velge for få parametere eller for mange, da det kan lede til svake resultater ved validering. Dette muligens pga. «overfitting», som kan sies å være forventet, da samme problemet også sees ved den «manuelle» metoden å utføre kalibreringen på. Det ser derfor ut til at det er hensiktsmessig å bruke tid på å utføre en SA analyse, og begrense kalibreringsparametere til noen få sensitive parametere, også ved tilnærmingen til kalibrering som er brukt i denne oppgaven.

Sammenhengen mellom antall generasjoner og KGE var avhengig av hvilke variabler som brukes til kalibrering, og ved å finne de «rette» variablene (modellen 4VAR) ble trenden at bedre KGE ved kalibrering, også ga bedre KGE ved validering. Den «automatiserte» kalibreringen og valideringen utført i denne oppgaven (ved å lage kode i R for både å kjøre SWMM, evaluere resultater og justere variabler som brukes til å kalibrere), var spesielt nyttig i den sammenheng at det stort sett kun gikk på bekostning av mer simuleringstid å teste ulike kombinasjoner av variabler, for å finne en kombinasjon som ga god KGE ved kalibrering og validering.

Ved kalibrering av modellen som fikk best KGE (modellen 4VAR), ble det oppnådd et «platå» hvor det over flere generasjoner så ut til at man ikke ville få KGE noe særlig nærmere 1, men en liten forbedring i KGE under kalibrering fra ca. 0,94 til 0,95 (ca. 1%), medførte en forbedring i KGE under validering fra ca. 0,72 til 0,92 (ca. 28%). Samtidig med denne endringen i KGE, så man også forbedring i BIAS under validering fra ca. 0,79 til 1,02. Det var derfor verdt å fortsette simuleringene over flere generasjoner for å oppnå høyere KGE og BIAS.

Derimot har man også sett at ved de høyeste oppnådde KGE i denne oppgaven var flere av de større toppene underestimert, samtidig som BIAS var nær perfekt (1,02). Sammenhengen mellom KGE og PEAK ble i denne oppgaven for flere av de største toppene generelt en overestimering ved lavere KGE, for deretter å gå mot underestimering ved høyeste oppnådde KGE. Siden underestimering i mange tilfeller er noe man ikke ønsker kunne det i en slik situasjon være hensiktsmessig å bruke færre generasjoner (stoppe ved en lavere KGE), og dermed kunne spare tid pga. færre generasjoner i dette tilfellet ville bety færre simuleringer.

4.1 Videre arbeid

Videre arbeid:

- Eksperimentere med verdier for F og C i DEoptim (se avsnitt 2.6) for å sjekke om det finnes verdier som gjør at man raskere finner frem til en god KGE.
- Prøve utføre kalibreringen ved å benytte større populasjon, og undersøke om det gir bedre resultater med tanke på antall simuleringer som er nødvendig å bruke for å oppnå lignende KGE.
- Prøve å utføre kalibrering av modellen ved å benytte en vekting av de ulike leddene i rotuttrykket til KGE, for å se om dette eventuelt kan gi bedre samsvar for simulert og observerte topper.

Referanser

- Alamdari, N. (2016). Development of a Robust Automated Tool for Calibrating a SWMM Watershed Model. I C. S. Pathak & D. Reinhart (Red.), *World Environmental and Water Resources Congress 2016: Professional Development, Innovative Technology, International Perspectives, and History and Heritage* (s. 221-228). American Society of Civil Engineers. <https://doi.org/10.1061/9780784479841.025>
- Ardia, D., Boudt, K., Carl, P., Mullen, K. M. & Peterson, B. G. (2011). Differential Evolution with DEoptim: An Application to Non-Convex Portfolio Optimization. *R Journal*, 3, 27–34. <https://doi.org/10.32614/RJ-2011-005>
- Barco, J., Wong, K. M. & Stenstrom, M. K. (2008). Automatic Calibration of the U.S. EPA SWMM Model for a Large Urban Catchment. *Journal of Hydraulic Engineering*, 134(4), 355-508. [https://doi.org/10.1061/\(ASCE\)0733-9429\(2008\)134:4\(466\)](https://doi.org/10.1061/(ASCE)0733-9429(2008)134:4(466))
- Behrouz, M. S., Zhu, Z., Matott, L. S. & Rabideau, A. J. (2020). A new tool for automatic calibration of the Storm Water Management Model (SWMM). *Journal of Hydrology*, 581, Artikkel 124436. <https://doi.org/10.1016/j.jhydrol.2019.124436>
- Bigiarini, M. Z. (2020). *Kling-Gupta Efficiency*. R Documentation. Hentet 2. mars 2023 fra <https://search.r-project.org/CRAN/refmans/hydroGOF/html/KGE.html>
- Clark, M. P., Vogel, R. M., Lamontagne, J. R., Mizukamo, N., Knoben, W. J. M., Tang, G., Gharari, S., Freer, J. E., Whitfield, P. H., Shook, K. R. & Papalexioiu, S. M. (2021). The Abuse of Popular Performance Metrics in Hydrologic Modeling. *Water Resources Research*, 57(9), Artikkel e2020WR029001. <https://doi.org/10.1029/2020WR029001>
- Eckhardt, K. & Arnold, J. G. (2001). Automatic calibration of a distributed catchment model. *Journal of Hydrology*, 251(1-2), 103-109. [https://doi.org/10.1016/S0022-1694\(01\)00429-2](https://doi.org/10.1016/S0022-1694(01)00429-2)
- Fleetwood, K. (u.å). *An Introduction to Differential Evolution*. Hentet 8. april 2023 fra <https://www.maths.uq.edu.au/MASCOS/Multi-Agent04/Fleetwood.pdf>
- GebreEgziabher, M. & Demissie, Y. (2020). Modeling Urban Flood Inundation and Recession Impacted by Manholes. *Water*, 12(4), 1160. <https://doi.org/10.3390/w12041160>
- Gupta, H. V., Kling, H., Yilmaz, K. K. & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of hydrology*, 377(1-2), 80-91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Herrera, P. A., Marazuela, M. A. & Hofmann, T. (2021). Parameter estimation and uncertainty analysis in hydrological modeling. *WIREs Water*, 9, Artikkel e1569. <https://doi.org/10.1002/wat2.1569>
- Knoben, W. J. M., Freer, J. E & Woods, Ross. A. (2019). Technical note: Inherent benchmark or not? Comparing Nash-Sutcliffe and Kling-Gupta efficiency scores. *Hydrology and Earth System Sciences*, 23(10), 4323–4331. <https://doi.org/10.5194/hess-23-4323-2019>
- Lawrence, D., Ortega, R. Z & Skaugen, T. (2020). DDDUrban, ny urbanhydrologisk modell, – resultater fra SURF-prosjektet. *VANN*, 55(4), 271-287. <https://hdl.handle.net/11250/2830871>
- Leutnant, D. & Doering, A. (2018) *swmmr: R Interface for US EPA's SWMM*. The Comprehensive R Archive Network. <https://cran.r-hub.io/web/packages/swmmr/swmmr.pdf>
- Madsen, H. (2000). Automatic calibration of a conceptual rainfall–runoff model using multiple objectives. *Journal of Hydrology*, 235(3-4), 276-288. [https://doi.org/10.1016/S0022-1694\(00\)00279-1](https://doi.org/10.1016/S0022-1694(00)00279-1)
- Mizukami, N., Rakovec, O., Newman, A. J., Clark, M. P., Wood, A. W, Gupta, H. V. & Kumar, R. (2019). On the choice of calibration metrics for «high flow» estimation using hydrologic models. *Hydrology and Earth System Sciences*, 23(6), 2601-2614. <https://doi.org/10.5194/hess-23-2601-2019>

-
- Mullen, K., Ardia, D., Gil, D., Windover, D., Cline, J. (2011). DEoptim: An R Package for Global Optimization by Differential Evolution. *Journal of Statistical Software*, 40(6), 1–26. <https://doi.org/10.18637/jss.v040.i06>
- Multiconsult (2020). *Urbanhydrologisk modellering Sandsli*. Oslo: Multiconsult.
- Patil, S. D. & Stieglitz, M. (2015). Comparing spatial and temporal transferability of hydrological model parameters. *Journal of Hydrology*, 525, 409-417. <https://doi.org/10.1016/j.jhydrol.2015.04.003>
- Perrin, C., Michel, C. & Andréassian, V. (2001). Does a large number of parameters enhance model performance? Comparative assessment of common catchment model structures on 429 catchments. *Journal of Hydrology*, 242(3-4), 275-301. [https://doi.org/10.1016/S0022-1694\(00\)00393-0](https://doi.org/10.1016/S0022-1694(00)00393-0)
- Razavi, S. & Tolson, B. A. (2013). An efficient framework for hydrologic model calibration on long data periods. *Water Resources Research*, 49(12), 8418-8431. <https://doi.org/10.1002/2012WR013442>
- Rossman, L. A. & Simon, M. A. (2022). *Storm Water Management Model User's Manual Version 5.2*. United States Environmental Protection Agency. <https://www.epa.gov/system/files/documents/2022-04/swmm-users-manual-version-5.2.pdf>
- Rygh, J. I. (2022). *Grunnvannets betydning for urban avrenning*. [Masteroppgave, Norges miljø- og biovitenskapelige universitet]. Brage NMBU. <https://hdl.handle.net/11250/3037460>
- Schauberger, P., Walker, A., Braglia, L., Sturm, J., Garbuszus, J. M. & Barbone J. M. (2023). *openxlsx: Read, Write and Edit xlsx Files*. The Comprehensive R Archive Network. Hentet 10. mai 2023 fra <https://cran.r-project.org/package=openxlsx>
- Storn, R. & Price, K. (1997). Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. *Journal of Global Optimization*, 11, 341–359. <http://dx.doi.org/10.1023/A:1008202821328>
- Wickham, H. & Bryan, J. (2023). *readxl: Read Excel Files*. The Comprehensive R Archive Network. Hentet 10. mai 2023 fra <https://cran.r-project.org/package=readxl>
- Wigestrånd, M. L., & Mathiesen, R. J. A. (2020). *Modellering av urban overvannsfloem : en analyse av bruksområdet til MIKE FLOOD*. [Masteroppgave, Norges miljø- og biovitenskapelige universitet]. Brage NMBU. <https://hdl.handle.net/11250/2673218>
- Zeileis, A. & Grothendieck, G. (2005). zoo: S3 Infrastructure for Regular and Irregular Time Series. *Journal of Statistical Software*, 14(6), 1–27. <https://doi.org/10.18637/jss.v014.i06>

Vedlegg A – Kode i R

Kode kalibrering og validering

Koden som her er vedlagt er for 4 variabler (beste modell i denne oppgaven). Ved annet antall variabler er koden justert til å endre på ønskede variabler.

```
# Pakker og wd-----
library(DEoptim); library(swmmr) ;library(zoo); library(readxl) ;library(openxlsx)

setwd("C:/Users/frank/Desktop/Master/SWMM_Sandsli") # Working directory

##### Kalibrering #####

# Leser inn SWMM referansemodellen, og lager kopi -----
inp      <- read_inp(x = "model_uten_SP.inp")
write_inp(inp, "tempmodel.inp")
inp      <- read_inp(x = "tempmodel.inp")

# Diverse observeringsberegninger for kalibreringsperioden -----
obs      <- read.delim("obs_kalibrering.txt")
Qobs     <- as.numeric(obs[[1]])
Qobs_avg <- mean(Qobs)
s_obs    <- sd(Qobs)

# Definerer fitness function (fn) -----
fitness   <- function(x){

  # Skalerer variablene i SWMM med en faktor, x[faktor nummer]
  # Dette er faktorene DE vil endre på for å prøve minimere den negative verdien av KGE
  # Faktoren endrer alle verdiene til angitt parameter i hele modellen (alle delfelt eller alle
  # ledninger)

  inp$subareas$`N-Perv`      <- x[1] * inp$subareas$`N-Perv`
  inp$infiltration$MinRate   <- x[2] * inp$infiltration$MinRate
  inp$subcatchments$Area     <- x[3] * inp$subcatchments$Area
  inp$subcatchments$Perc_Slope <- x[4] * inp$subcatchments$Perc_Slope

  write_inp(inp, "tempmodel.inp")
  inp <- read_inp(x = "tempmodel.inp")
  files <- run_swmm("tempmodel.inp",
  exec="C:/Users//frank//Desktop//Master//SWMM_Sandsli//swmm5.exe")

  # Henter simulerte resultater fra SWMM
  out <- read_out(
    file      = files$out, # sti til out fil
    iType     = 1,        # Angir at skal ha resultater ved en node
    object_name = "2",   # Angir navn på noden
    vIndex    = 4        # Angir at skal ha vannføring i noden
  )["2"]$total_inflow
```

```

# Beregner med simulerte resultater fra SWMM
Qsim      <- coredata(out)
Qsim_avg  <- mean(Qsim)
s_sim     <- sd(Qsim)
r         <- 0

if (s_sim > 0) {
  r <- cor(Qsim,Qobs)
}

#Beregner KGE ved å bruke simulerte resultater, sammen med observeringsberegningene
kge <- 1 - ((r - 1)^2 + (s_sim/s_obs - 1)^2 + (Qsim_avg/Qobs_avg - 1)^2 )^0.5

# Returnerer negative av KGE, pga. DE vil prøve finne minimum
f1 <- -kge

return(f1)
}

# DEoptim -----
set.seed(123)      # For at skal kunne gjenskape resultatene.
populasjon <- 5
generasjoner <- 50

test = DEoptim(fn = fitness,
              lower = c(0.1, 0.1 ,0.1 ,0.1),
              upper = c(10, 10, 10, 10),
              DEoptim.control(NP = populasjon,
                              itermax = generasjoner,
                              F = 0.8,
                              CR = 0.9))

# Etter DEoptim er ferdig med samtlige generasjoner finnes faktorene
# og KGE pr generasjon under:
test

##### Valdidering #####

# Diverse observeringsberegninger for valideringsperioden-----
obs      <- read.delim("obs_validering.txt")
Qobs     <- as.numeric(obs[[1]])
Qobs_avg <- mean(Qobs)
s_obs    <- sd(Qobs)

# Leser inn excell fil med valgte faktorer fra DEoptim-----
modeller <- read_excel("Kalibrerte_modeller.xlsx")
# Excell filen er laget manuelt, ved å plukke ut ønsket
# info fra DEoptim resultatene, i denne koden lagret under "test"
# Dette er gjort fordi DEoptim ikke alltid finner bedre løsning pr generasjon
# og derfor mange får lik eller nesten identisk KGE.

```

```

# Lager en dataframe for å lagre alle simulerte resultater fra valideringen-----
df_Qsim_hyd_validert <- setNames(data.frame(matrix( ncol= length(modeller$Modellnummer)
          , nrow = length(Qobs)))
          , paste0(modeller$Modellnavn,modeller$KGE_kalibrert))

# Simulerer hver modell-----
for (f in seq(from=1, to= length(modeller$Modellnummer), by = 1)) {

  inp    <- read_inp(x = "model_uten_SP_validering.inp") # modelfilen som skal endres med
  kalibrerte faktorer

  # Dette er faktorene fra DEoptim
  faktor_N_Perv    <- as.numeric(modeller$faktor_N_Perv[f])
  faktor_MinRate   <- as.numeric(modeller$faktor_MinRate[f])
  faktor_Area      <- as.numeric(modeller$faktor_Area[f])
  faktor_Perc_Slope <- as.numeric(modeller$faktor_Perc_Slope[f])

  #Endrer modelfilen med faktorene fra DEoptim
  inp$subareas$`N-Perv`      <- faktor_N_Perv      * inp$subareas$`N-Perv`
  inp$infiltration$MinRate   <- faktor_MinRate    * inp$infiltration$MinRate
  inp$subcatchments$Area     <- faktor_Area        * inp$subcatchments$Area
  inp$subcatchments$Perc_Slope <- faktor_Perc_Slope * inp$subcatchments$Perc_Slope

  #Lager og simulerer SWMM modellen med de nye (kalibrerte) verdiene.
  write_inp(inp, "cal_model.inp")
  files_validert_DEoptim <- run_swmm("cal_model.inp",
  exec="C:/Users/frank/Desktop/Master/SWMM_Sandsli/swmm5.exe")

  out <- read_out(
    file          = files_validert_DEoptim$out,
    iType         = 1,
    object_name   = "2",
    vIndex        = 4
    )["2"]$total_inflow

  Qsim_validert <- coredata(out)
  df_Qsim_hyd_validert[,f] <- Qsim_validert

  # Beregner og lagrer validert KGE
  r_validert      <- cor(Qobs, Qsim_validert)
  Qsim_avg_validert <- mean(Qsim_validert)
  s_sim_validert  <- sd(Qsim_validert)
  kge_validert    <- round(1 - ((r_validert - 1)^2 + (s_sim_validert / s_obs - 1)^2 +
  (Qsim_avg_validert/Qobs_avg - 1)^2 )^0.5, 7)
  modeller$KGE_validert[f] <- kge_validert

  # Beregner og lagrer validert BIAS
  bias_validert   <- round(sum(Qsim_validert)/sum(Qobs),3)
  modeller$BIAS_validert[f] <- bias_validert

  # Beregner og lagrer peak
  modeller$peak1_validert[f] <- max(Qsim_validert[11155 :11167]) / Qobs[11161]

```



```
modeller$peak2_validert[f] <- max(Qsim_validert[11274 :11286]) / Qobs[11280]
modeller$peak3_validert[f] <- max(Qsim_validert[12579 :12591]) / Qobs[12585]
modeller$peak4_validert[f] <- max(Qsim_validert[13245 :13277]) / Qobs[13261]
modeller$peak5_validert[f] <- max(Qsim_validert[15821 :15833]) / Qobs[15827]
modeller$peak6_validert[f] <- max(Qsim_validert[20137 :20149]) / Qobs[20143]
modeller$peak7_validert[f] <- max(Qsim_validert[22428 :22448]) / Qobs[22438]
modeller$peak8_validert[f] <- max(Qsim_validert[23526 :23538]) / Qobs[23532]
```

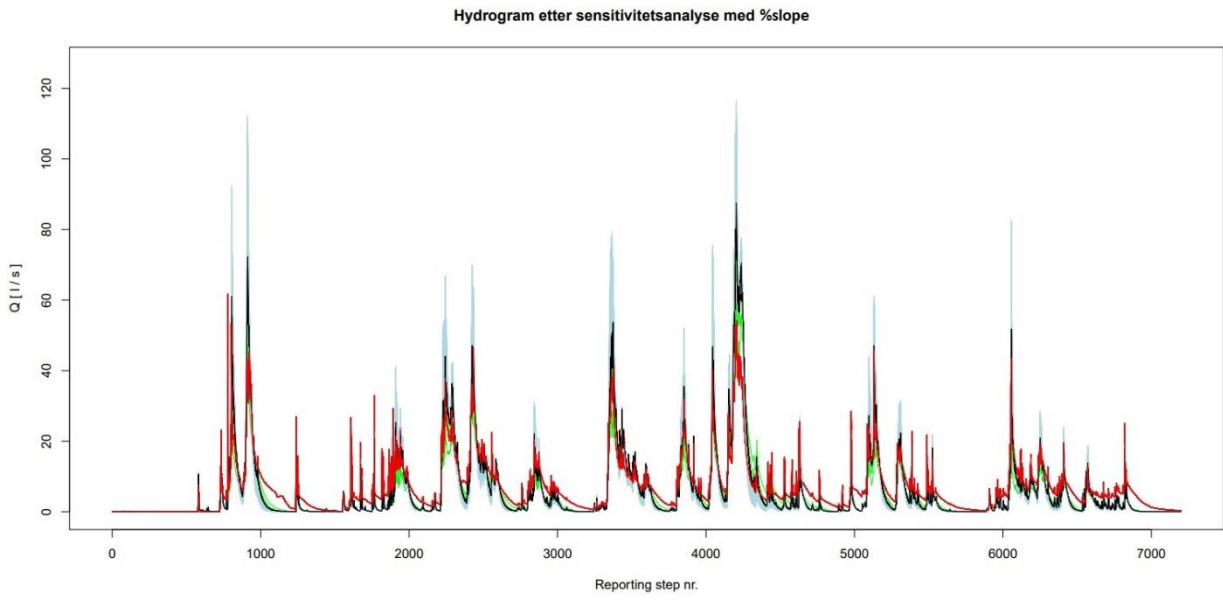

```
}
```

```
# Skriver validerte resultatene til excel fil-----
write.xlsx(modeller,"Validerte_resultater.xlsx")
```


Vedlegg B - Hydrogrammer fra SA

Vedlegget viser hydrogrammer etter sensitivitetsanalyse med 12 ulike parametere. I figurene er lyseblå hydrogrammene hvor justert parameter verdi er større enn ref. verdiene, og grønt er hydrogrammene hvor justert parameter verdi er mindre en ref. verdiene. Sort er hydrogrammet til ref. verdiene. Rødt er observert hydrogram. Sensitiv parameter tilsvarer at man kan se større utslag av grønt og/eller blått i figurene. Merk vertikal akse er ulik for noen av parametrene.






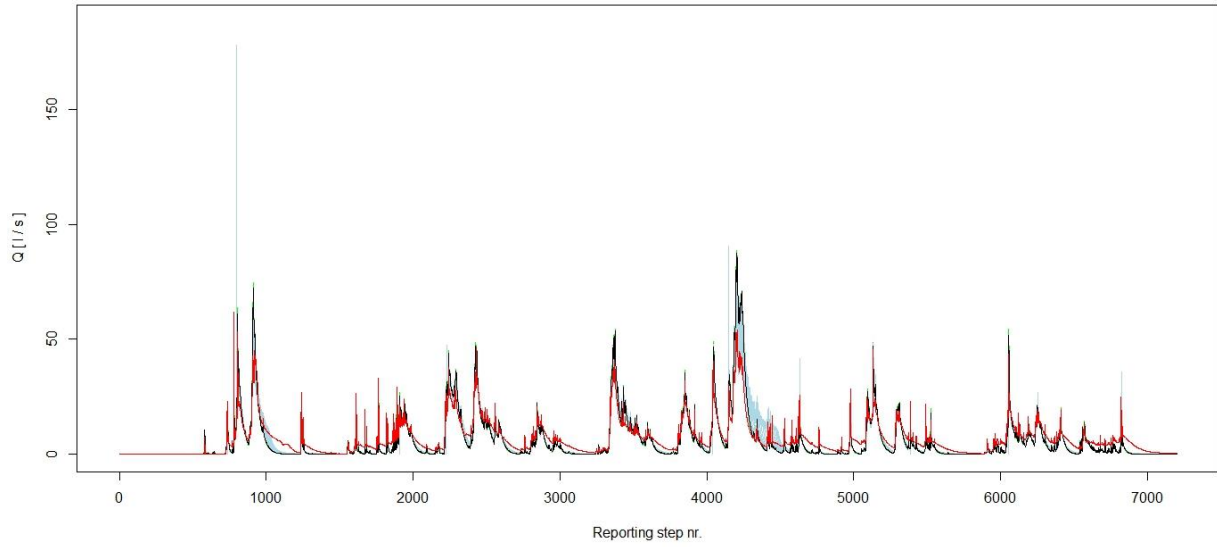
Hydrogram etter sensitivitesanalyse med bredde




Hydrogram etter sensitivitesanalyse med %imp




Hydrogram etter sensitivitesanalyse med Ledningsruhet




Hydrogram etter sensitivitesanalyse med N_Imperv




Hydrogram etter sensitivetsanalyse med %Zero




Hydrogram etter sensitivetsanalyse med Dstore-Perm



Hydrogram etter sensitivetsanalyse med Dstore-Imp



Hydrogram etter sensitivetsanalyse med max infiltrasjonsrate (MaxInf)





Norges miljø- og biovitenskapelige universitet
Noregs miljø- og biovitenskapelige universitet
Norwegian University of Life Sciences

Postboks 5003
NO-1432 Ås
Norway