Surrogatmodeller för snabbare hydrodynamisk modellering

Surrogate models for faster hydrodynamic modeling

Elsa Delshammar [1], Adina Hellström [2], Freja Petersen[3], Lars Jonasson[4]

[1]Institutionen för matematiska vetenskaper, Chalmers tekniska högskola, Göteborg, DHI Sverige, Göteborg, elsadelshammar@hotmail.se
[2]Institutionen för matematiska vetenskaper, Chalmers tekniska högskola, Göteborg, DHI Sverige, Göteborg, adinahellstrom@hotmail.com
[3]DHI Sverige, Göteborg, frtp@dhigroup.com
[4]DHI Sverige, Göteborg, lajo@dhigroup.com

Sammanfattning

Numeriska modeller är centrala för att förstå och förutse väderhändelser, men deras beräkningsintensitet begränsar möjligheterna till snabba prognoser och scenarioanalyser. Denna studie undersöker potentialen hos data-drivna surrogatmodeller, det vill säga maskininlärningsbaserade approximationer av numeriska simuleringar, för att minska beräkningstiden utan att kompromissa med träffsäkerheten. Studien bygger vidare på ett tidigare föreslaget ramverk för surrogatmodellering och syftar till att (1) förbättra modellens prestanda vid modellering av tillfälligt höga havsnivåer genom alternativa metoder för dimensionsreduktion och regression, samt (2) testa modellens överförbarhet till urbana miljöer genom tillämpning på översvämningar orsakade av skyfall. Resultaten visar att tekniker baserade på djupa neurala nätverk, som Autoencoder och LSTMs, förbättrar prediktionen för variabler av icke-linjär karaktär med mer än 20 %. Dessutom kunde ramverket tillämpas på en urban översvämningsmodell, och prediktioner av vattendjup efter skyfall visade acceptabel träffsäkerhet i majoriteten av fallen med ett genomsnittsfel på 2,6 cm. Instabilitet i den urbana modellen indikerar att datamängden var otillräcklig samt att andra metoder kan vara att föredra. I helhet visar studien på fortsatt framtida potential för ramverket som ett effektivt komplement till numeriska modeller. Resultaten är betydelsefulla eftersom surrogatmodellering möjliggör exempelvis snabb utvärdering av flera klimatscenarier samt realtidssimuleringar.

Abstract

Numerical models are central to understanding and predicting weather events, but their computational cost limits the possibilities for rapid forecasts and scenario analyses. This study explores the potential of data-driven surrogate models, which are machine learning-based approximations of numerical simulations, to reduce computation time without compromising accuracy. Building on a previously proposed framework for surrogate modeling, the study aims to (1) improve model's performance in simulating temporarily high sea levels through alternative methods for dimensionality reduction and regression, and (2) test the framework's transferability

to urban environments for application to flash floods. The results show that techniques based on deep neural networks, such as Autoencoders and LSTMs, improve the prediction of variables of non-linear nature by more than 20%. Moreover, the framework could be applied to an urban flood model, and predictions of water depth after cloudbursts showed acceptable accuracy in the majority of cases with an average error of 2.6 cm. Overall, the study demonstrates the continued potential of the framework as an effective complement to numerical models. The findings are important because surrogate modeling enables, for example, rapid evaluation of multiple climate scenarios and real-time simulations.

Keywords: Cloudbursts, Temporarily high sea levels, Data-driven surrogate modeling, Machine learning

Inledning

Naturens system är ofta komplexa och påverkas av ett stort antal samverkande processer. Dessa system kan approximeras och beräknas med hjälp av numeriska modeller, som är särskilt viktiga inom klimatforskning eftersom de gör det möjligt att förutsäga framtida effekter och ta fram strategier för att minska skador. För att modellera komplexa system krävs ofta stora beräkningsresurser, särskilt när hög upplösning, flera fysikaliska processer eller stora geografiska områden ingår. Den höga beräkningskostnaden begränsar därför möjligheterna att utforska olika scenarier eller göra snabba prognoser i realtid.

För att adressera detta kan surrogatmodeller användas. Det är en etablerad metod där maskininlärning, en gren inom artificiell intelligens, används för att efterlikna numeriska modellers beteende. Surrogatmodeller tränas på simulerade data, det vill säga resultat från en numerisk modell baserad på givna indata. Genom att lära sig sambandet mellan indata och den simulerade responsen kan surrogatmodellen efterlikna den numeriska modellen och därmed förutsäga systemets respons betydligt snabbare, samtidigt som en hög grad av träffsäkerhet bevaras.

Data-drivna surrogatmodeller har tillämpats inom flera vetenskapliga områden, bland annat designoptimering (Liu et al., 2025) och miljömodellering (Feng et al. 2025). Begrepp som digitala tvillingar och grafbaserade surrogatmodeller har visat sig framgångsrika i att ge tidiga varningar och förbättrade prognoser för extrema väderhändelser som tropiska cykloner, atmosfäriska floder och extremvärme (Taylor et al., 2012). Med dessa modeller kan resultat med hög träffsäkerhet levereras på bara några sekunder i stället för timmar eller dagar.

I en tidigare studie har ett ramverk för surrogatmodellering föreslagits, som bygger på en kombination av dimensionsreduktion och en regressionsmodell. Ramverket utvärderades genom fallstudier för att modellera tillfälligt höga havsnivåer. Av de tre implementeringar som testades visade en särskild version störst potential, denna kallas i fortsättningen för "referensmodellen". Det är viktigt att poängtera att referensmodellen enbart avser surrogatmodellering av tillfälligt höga havsnivåer. Referensmodellen uppnådde lovande resultat: upp till 1 000 gånger snabbare beräkningar med bibehållen träffsäkerhet på 90 % (Petersen et al., 2025). Trots detta motiverar det begränsade antalet testade implementeringar vidare undersökningar. Ramverket beskrivs som anpassningsbart, men har hittills endast testats på kustmodeller.

Liknande modeller har använts i urbana tillämpningar, till exempel prognoser för temperatur (Gojo Cruz et al., 2025) och översvämningar i kuststäder (Xu & Gao, 2024), men saknar ofta koppling till numeriska modeller eller hanterar endast ett fåtal utdata-punkter snarare än för utdata för en hel domän.

Detta examensprojekt syftade till att förbättra en surrogatmodell baserad på ett befintligt ramverk (Petersen et al., 2025) och applicera det i nya kontexter. Målet var att minska modellens prediktionsfel jämfört med data från en numerisk modell, samt att testa modellen på en urban modell för att utvärdera modellens flexibilitet och anpassningsförmåga till andra domäner.

För att uppnå syftet behandlades följande frågeställningar:

1. Kan surrogatmodellen förbättras genom att använda en alternativ teknik för dimensionsreduktion och en alternativ regressionsmodell?

2. Kan ramverket tillämpas på en urban modell?

Artikeln bygger på ett examensarbete (Delshammar & Hellström, 2025) utfört vid Chalmers tekniska högskola i samarbete med DHI, under handledning av Lars Jonasson och Freja Petersen.

Metod

Metodkapitlet är uppdelat i två huvuddelar, som var och en svarar mot en av studiens två frågeställningar, samt en inledande genomgång av det ramverk som båda frågeställningarna utgår ifrån.

Ramverket FMROM för surrogatmodellering

Ramverket som studien utgår ifrån är framtaget av Freja Petersen, Rocco Palmitessa och Jesper Sandvig Mariegaard på DHI. En schematisk figur över ramverket visas i figur 1. Det utgör grunden för att implementera datadrivna surrogatmodeller och syftet är att förutsäga ett systems framtida utveckling baserat på dess historiska beteende i kombination med externa faktorer som påverkar systemets dynamik. Ramverket kan beskrivas med tre steg:

1. Transformation: Genom dimensionsreduktion transformera data från en högupplöst till en lågupplöst domän.
2. Prediktion: Förutsäga systemets framtid i den lågupplösta domänen.
3. Återtransformation: Genom omvänd dimensionsreduktion skala upp data till den ursprungliga, högupplösta domänen.

Syftet med att transformera datan innan prediktion är att filtrera bort brus i datan och öka surrogatmodellens beräkningshastighet. Både statistiska och maskininlärningsbaserade metoder kan användas för såväl transformation som prediktion. Det är viktigt att transformationsmodellen lyckas fånga de mest relevanta attributen i datan, så att prediktionen blir så tillförlitlig som möjligt. Surrogatmodellens prestanda utvärderas genom att jämföra prediktionen i den högupplösta domänen med resultat från den fullständiga numeriska modellen.

Förbättra surrogat för tillfälligt höga havsnivåer

För att undersöka om surrogatmodellen kan förbättras genom att använda alternativa metoder för dimensionsreduktion och regression, användes data från en numerisk kustmodell över Öresund gjord i MIKE 21 (DHI, 2017). Kustmodellen simulerar och predikterar havets ytrörelser i ett diskret antal cellelement över en tvådimensionell domän, baserat på ett antal parametrar och randvillkor. Domänen som studerades bestod av 3 320 element, där varje element representeras av tre tillståndsvariabler över tid: havsnivå samt strömhastighet i X- respektive Y-led. För att göra en surrogatmodell av den numeriska modellen användes dessa tillståndsvariabler, samt parameterdata som representerar externa faktorer, i detta fall lufttryck, vindhastighet samt havsnivå vid domänens norra och södra havsgränser.

Referensmodellen använde Principal Component Analysis (PCA) för transformation och återtransformation av datan, samt linjär regression för prediktion (Petersen et al., 2025). PCA är linjär dimensionsreduktion som identifierar de riktningar i vilka datan

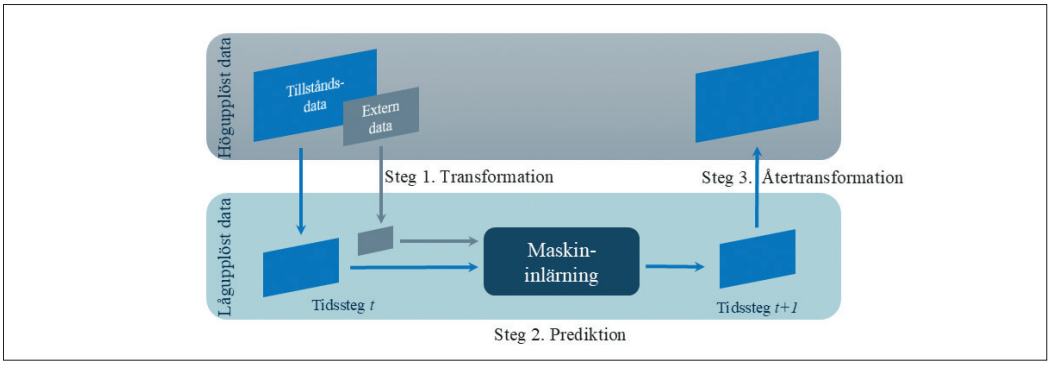

Figur 1. Schematisk bild över ramverket FMROM, inspirerad av (Petersen et al., 2024).

varierar mest och projicerar den längs dessa. På så sätt kan man minska antalet dimensioner utan att förlora den mest betydelsefulla informationen. Linjär regression estimerar sambandet mellan variabler genom att anpassa ett hyperplan som beskriver deras relation. För att göra en prediktion används detta hyperplan för att uppskatta framtida värden baserat på ny data.

I denna studie användes i stället en icke-linjär surrogatmodell, med en autoencoder för transformation och återtransformation av data, i kombination med en Long Short-Term Memory (LSTM)-modell för prediktion. Både autoencodern och LSTM-modellen är typer av neurala nätverk som tränas genom att iterativt anpassa sig till mönster i datan. Autoencodern är särskilt effektiv för att transformera och återtransformera icke-linjär data, medan LSTM-modellen är väl lämpad för att göra prediktioner baserade på tidsseriedata. Denna implementering av ramverket jämfördes med referensmodellen.

Surrogatmodellerna tränades på data från ett år och utvärderades på data från det efterföljande året. På så vis inkluderades säsongsvariationer i både tränings- och testdata. För att utvärdera modellens träffsäkerhet beräknades felet mellan de predikterade värdena och resultaten från den fullständiga numeriska modellen, det vill säga testdatan, för samtliga tre tillståndsvariabler. Felmåttet som användes var RMSE (eng: Root Mean Squared Error). Genom att testa modellen på tidigare osedd data erhålls en indikation på hur modellen förväntas prestera i ett verkligt scenario.

Surrogat för urban översvämning till följd av skyfall

För att applicera en surrogatmodell enligt ramverket på en urban miljö användes data från simuleringar av en numerisk översvämningsmodell över Kungsbacka gjord i MIKE+ (DHI, 2025). Översvämningsmodellen simulerar och predikterar vattenflöden baserat på ett antal parametrar och randvillkor. Domänen bestod av 147 350 element där varje element representerades av en tillståndvariabel över tid: vattendjup. Till surrogatmodellen användes tillståndsvariabeln samt nederbörd som extern variabel. Simuleringarna omfattade 13 tidsserier som representerade olika skyfallshändelser, där nederbördens intensitet varierade mellan 14 och 240 millimeter per timme, och varaktighet mellan fem minuter och sex timmar. Under simuleringarna nådde vattendjupet ett maxdjup på cirka tre meter. All data hade en tidsupplösning på två minuter.

Datasetet var relativt litet, vilket medförde utmaningar i att fånga liknande variationer i både tränings- och testdata. För att hantera detta tillämpades en leave-one-out-korsvalidering, där modellen tränades på samtliga skyfallshändelser utom en, som användes för testning. Denna procedur upprepades tills varje skyfallshändelse hade använts som testdata en gång, vilket gav en mer robust utvärdering av modellens prestanda.

Eftersom resultaten från denna typ av översvämningsmodellering i första hand används för att identifiera riskområden vid kraftiga regn, exkluderades celler där vattennivån aldrig översteg fem centimeter under något av skyfallen.

För att transformera resterande celler till en lågupplöst domän, användes PCA och för att prediktera vattendjup jämfördes två regressionsmodeller: en enkel, så kallad, naiv modell som predikterade medelvärdet av de två senaste tidsstegen, samt en linjär regressionsmodell. Eftersom detta är ett nytt appliceringsområde är den tidigare definierade referensmodellen inte tillämplig. I stället används den naiva modellen som referens för att bedöma ifall den linjära modellen kunde identifiera mönster mellan in- och utdata som överträffar en naiv gissning.

För att utvärdera surrogatmodellens träffsäkerhet beräknades felet mellan de predikterade vattennivåerna och de tidigare numeriskt modellerade värdena i testdatan. Beräkningen gjordes för varje element i den högupplösta domänen där vattennivån översteg fem centimeter vid minst ett tidssteg. Som felmått användes RMSE.

Resultat

Förbättra surrogat för tillfälligt höga havsnivåer

Tabell 1. RMSE som ett medelvärde över tid och domän för surrogatmodellens implementering för kustmodellen. Enhet: Havsnivå [cm] samt strömhastighet i X- och Y-led [cm/s].

Variabel	PCA-Linjär regression *(referensmodellen)*	Autoencoder-LSTM	Procentuell skillnad
Havsnivå	1,47	3,31	125 %
Strömhastighet (X)	1,66	1,30	-21.7 %
Strömhastighet (Y)	2,64	2,02	-23.5 %

Tabell 1 visar att den icke-linjära surrogatmodellen (Autoencoder-LSTM) presterar bättre för strömhastigheterna, med en felminskning på mer än 20%, medan den linjära referensmodellen (PCA-Linjär regression) ger bättre resultat för havsnivådata. Detta tyder på att havsnivån uppvisar en mer linjär dynamik, medan variationerna i strömhastigheten är mer icke-linjära.

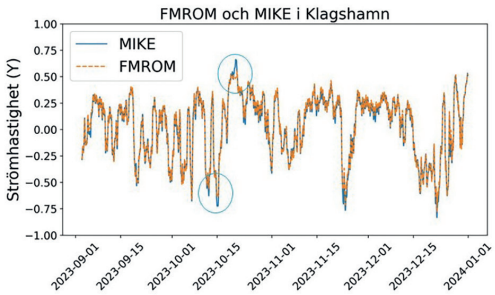

Figur 2. Resultat från numerisk modell (MIKE) samt resultat från surrogatmodell (FMROM) i ett element över tid.

I figur 2 visas prediktionen av strömhastigheten i Y-led från den icke-linjära surrogatmodellen (FMROM) tillsammans med resultatet från den fullständiga numeriska modellen (MIKE) i ett element i domänen, precis utanför Klagshamn, över tid. Figuren visar att surrogatmodellen följer de tidigare, numeriskt modellerade värdena väl, men har något svårare att återge extremvärdena, vilka är markerade i figuren. Samma mönster går igen även för de andra tillståndsvariablerna i modellen.

Figur 3 visar hur felet är fördelat över den rumsliga dimensionen för samtliga tillståndsvariabler. För strömhastigheterna i X- och Y-led följer det rumsliga felet ett liknande mönster, vilket överensstämmer med de områden där datan uppvisar störst varians. Felet för havsnivån är däremot mer jämnt fördelat över domänen, vilket sannolikt beror på att denna variabel uppvisar en mer linjär dynamik.

Surrogat för urban översvämning till följd av skyfall

Tabell 2. RMSE som ett medelvärde över tid och domän för surrogatmodellens implementering för den urbana modellen. Fallen representerar genomsnittet på alla testfall, det testfall som gav lägst fel samt det testfall som gav högst fel. Enhet: Vattendjup [cm].

Fall	PCA-Naiv regression	PCA-Linjär regression
Medelvärde	18,70	2,59
Lägsta	8,34	1,02
Högsta	30,40	7,10

Från tabell 2 kan resultaten från surrogatmodellens prediktering av vattennivåer utläsas. För alla fall överträffade den linjära regressionsmodellen den naiva, vilket indikerar att underliggande mönster i datan kunde identifieras och utnyttjas.

Resultaten visar stora variationer beroende på vilket regn modellen testades på. Det lägsta felet ligger på 1,02 cm och det högsta på 7,10, vilket tydligt visar

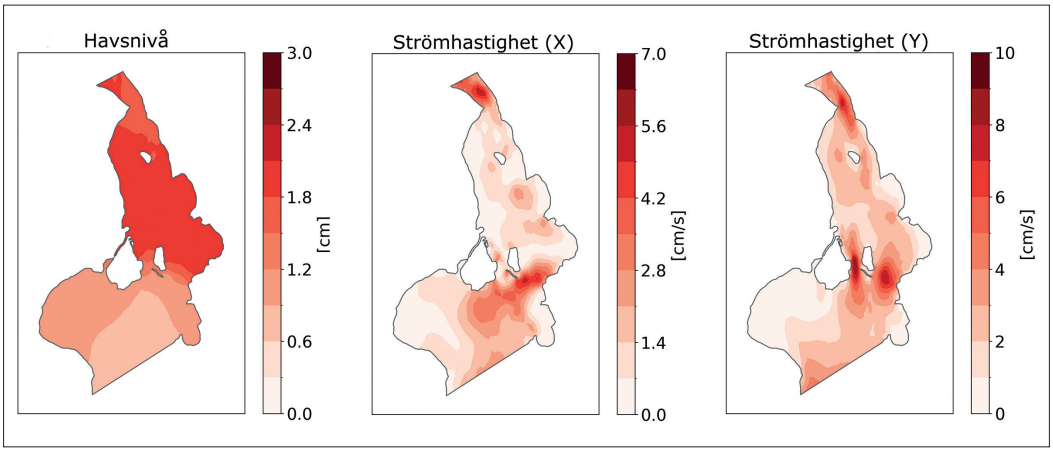

Figur 3. Avvikelsen mellan den numeriska modellen och surrogatmodellen, uttryckt som RMSE, för samtliga tillståndsvariabler, fördelat över den rumsliga domänen som omfattar Öresund. Från vänster: Havsnivå [cm], strömhastighet i X-led [cm/s] och strömhastighet i Y-led [cm/s].

modellens sensitivitet. Modellen PCA-Linjär regression presterade sämst vid det kortaste och mest intensiva skyfallet. Medelvärdet för PCA-Linjär regression på 2,59 cm kan anses relativt lågt med tanke på den maximala vattennivån runt tre meter.

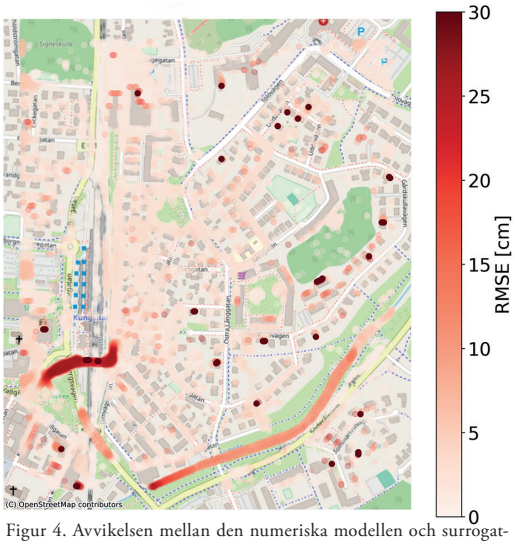

Figur 4. Avvikelsen mellan den numeriska modellen och surrogatmodellen, uttryckt som RMSE, för samtliga tillståndsvariabler, fördelat över den rumsliga domänen som omfattar Kungsbacka. Bilden visar testet som motsvarande det högsta felet. Enhet: vattendjup [cm].

I figur 4 visar felen fördelat över den rumsliga dimensionen, och de största felen hittas där det är mest klarröda markeringar på kartan. Dessa områden överlappar med de platser där vattennivåerna var som högst.

Diskussion och slutsats

Förbättra surrogat för tillfälligt höga havsnivåer

Surrogatmodeller för kustmiljöer, med fokus på tillfälligt förhöjda havsnivåer, visade fortsatt stor potential. Surrogatmodeller baserade på (icke-linjära) djupa neurala nätverk överträffade den linjära referensmodellen för tillståndsvariabler med mer icke-linjära mönster. Den icke-linjära modellen uppskattades vara cirka 30 gånger snabbare än den ursprungliga numeriska modellen, medan referensmodellen i tidigare studier visat sig vara upp till 1 000 gånger snabbare. Mot denna bakgrund blir det centralt att väga vinsterna i träffsäkerhet från mer avancerade metoder mot den ökade beräkningstiden de medför.

Samtidigt kan även måttliga tidsvinster få stor praktisk betydelse. Vid scenarioanalyser, där många simuleringar behöver genomföras, ackumuleras tidsbesparingen snabbt. Oavsett val av metod visar ramverket som helhet stor potential och fungerar som ett kraftfullt komplement till traditionella numeriska modeller.

Surrogatmodellen hade svårigheter att hantera extrema fall, något som även återkom i det urbana fallet. I de flesta tillämpningsområden är det just dessa extrema händelser som är särskilt viktiga att förutsäga korrekt, eftersom de ofta ligger till grund för exempelvis risk- och sårbarhetsanalyser samt beredskapsplanering. En fördel med neurala nätverk, som den icke-linjära surrogatmodellen är baserad på, är att de kan optimeras för mer specifika mål, exempelvis att förbättra prestandan vid just extrema händelser. Detta låg utanför ramen för detta projekt, men utgör ett naturligt och viktigt nästa steg i utvecklingen av mer tillförlitliga surrogatmodeller.

Surrogat för urban översvämning till följd av skyfall

Genom att tillämpa samma tekniker på en urban miljö, specifikt översvämningar orsakade av skyfall, visades att även detta hydrodynamiska system kan representeras av en surrogatmodell. Detta öppnar upp för nya möjligheter, men medför också vissa utmaningar. Prediktionerna visade sig i flera fall vara instabila och felen ackumulerades över tid. Detta beror troligen främst på den begränsade datamängden samt att den enda externa information som används är nederbördsdata. Annan extern data som skulle kunna öka träffsäkerheten är markens infiltrationsnivåer och domänens topografi.

Resultaten tyder på att andra metoder kan vara bättre lämpade för detta sammanhang. Vid risk- och sårbarhetsanalyser är ofta det maximala vattendjupet i varje element ett av de viktigaste resultaten från en skyfallskartering. Därför kan det vara mer effektivt att koppla ett skyfall direkt till det maximala vattendjupet i varje element, i stället för att förutsäga vattennivåerna vid varje tidssteg. Detta visar att surrogatmodellering har stor potential, men att ett annat ramverk kan vara mer ändamålsenligt.

Slutsats och tillämpningsområden

Sammanfattningsvis visar studien att surrogatmodeller baserade på maskininlärning kan fungera som ett effektivt komplement till traditionella numeriska modeller inom hydrodynamisk modellering, både för tillfälligt höga havsnivåer och skyfallsrelaterade översvämningar. Eftersom surrogatmodeller tränas på data från numeriska simuleringar är de i grunden beroende av dessa, och kan därför inte överträffa den underliggande numeriska modellens noggrannhet. Trots detta erbjuder de flera betydande fördelar. I ett framtidsperspektiv kan surrogatmodellering användas för att snabbt simulera effekterna av olika klimatscenarier, vilket kan bidra till planering och dimensionering av framtida infrastruktur. Genom att analysera ett stort antal scenarier kan beslutsfattare få bättre insikt i både potentiella risker och den osäkerhet som finns i hydrodynamiska system. Detta kan ligga till grund för mer informerade investerings- och beredskapsbeslut. Dessutom visar surrogatmodellering potential för realtidsapplikationer, exempelvis som en komponent i system för tidig varning vid översvämningsrisk, där snabba och tillförlitliga prediktioner kan spela en avgörande roll.

Referenser

DHI. (2017). MIKE FLOOD 1D–2D modelling user manual. DHI. https://manuals.mikepoweredbydhi.help/latest/Coast_and_Sea/MIKE_FM_HD_2D.pdf

DHI. (2025). MIKE+ user manual. DHI. https://manualsmikepoweredbydhi.help/latest/Cities/MIKE_Plus_2DOverland.pdf

Feng, J., Tian, Y., Li, P., Xie, Z., & Wang, H. (2025). Short-term water quality prediction of reclaimed water plant effluent and key measurement sections based on a surrogate prediction model. Journal of Environmental Management, 380, 125147. https://doi.org/10.1016/j.jenvman.2025.125147

Delshammar, E., Hellström, A. (2025). Towards More Accurate and Adaptable Surrogate Models. Examensarbete vid institutionen för matematiska vetenskaper, Chalmers tekniska högskola, Göteborg.

Liu, L., et al. (2025). Review of surrogate model assisted multi-objective design optimization of electrical machines: New opportunities and challenges. Renewable and Sustainable Energy Reviews, 215, 115609. https://doi.org/10.1016/j.rser.2025.115609

Taylor, K. E., Stouffer, R. J., & Meehl, G. A. (2012). An over view of CMIP5 and the experiment design. Bulletin of the American Meteorological Society, 93(4), 485–498. https://doi.org/10.1175/BAMS-D-11-00094.1

Petersen, F., Mariegaard, J. S., & Palmitessa, R. (2024). A framework for building fast reduced order surrogates for flexible mesh coastal-ocean models [opubliserat manuskript].

Gojo Cruz, J., de Vera, J. M. L., & Pilario, K. E. (2025). Machine learning-driven analysis of agro-climatic data for temperature modeling and forecasting in Philippine urban areas. Urban Climate, 60, 102339. https://doi.org/10.1016/j.uclim.2025.102339

Xu, L., & Gao, L. (2024). A hybrid surrogate model for real-time coastal urban flood prediction: An application to Macao. Journal of Hydrology, 642, 131863. https://doi.org/10.1016/j.jhydrol.2024.131863