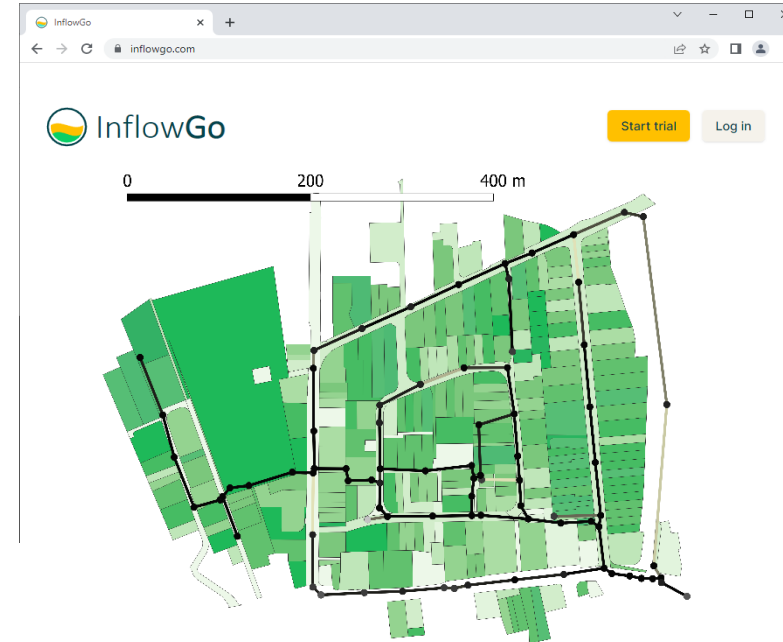
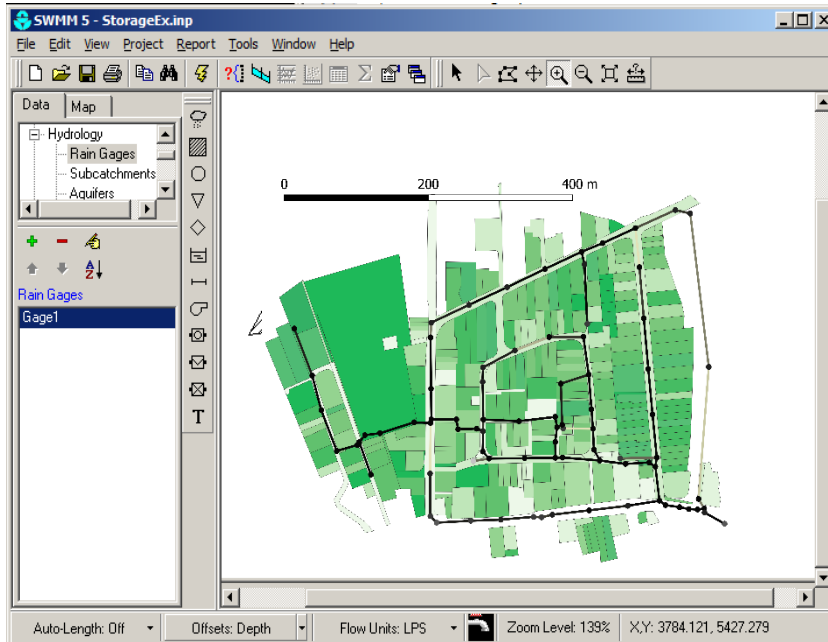


# Nye muligheder for simulering af vandsystemer ved hjælp af scientific machine learning - og hvorfor vi har brug for både hydrologisk og matematisk ekspertise

Roland Löwe, [rolo@dtu.dk](mailto:rolo@dtu.dk)

med bidrag fra Morten Grum, Franca Bauer, Frederik Tinus Jeppesen, Phillip Aarestrup, Rocco Palmitessa, Allan P. Engsig-Karup

# Planlægning af vandhåndtering i byer

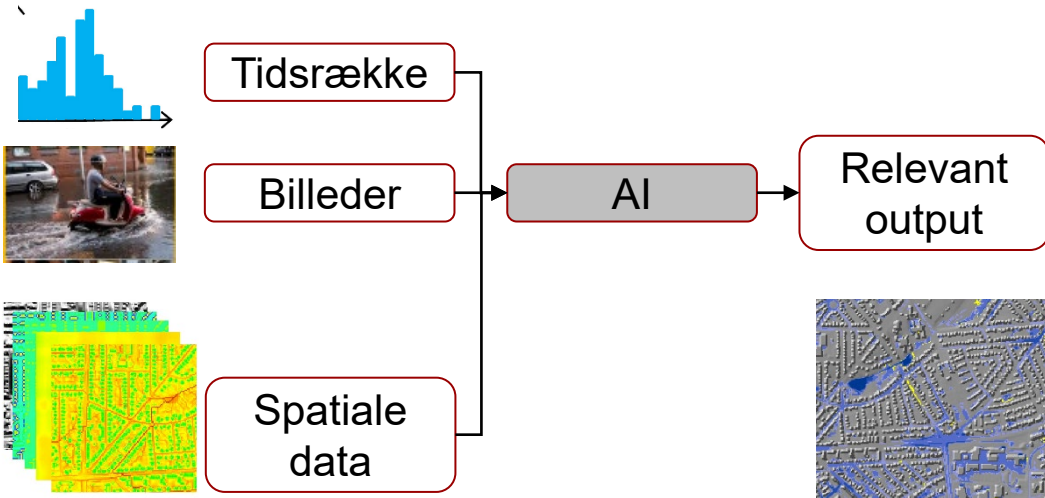


- Desktop modelberegninger (timer, dage, måneder)
- Løsningsscenarier analyseres typisk af eksterne konsulenter

- Interaktive modelberegninger (sekunder, minutter)
- Kvalificering af løsningsrummet som skal undersøges i detaljer

# AI vs. dynamisk simulering

## Statisk (Input – output)



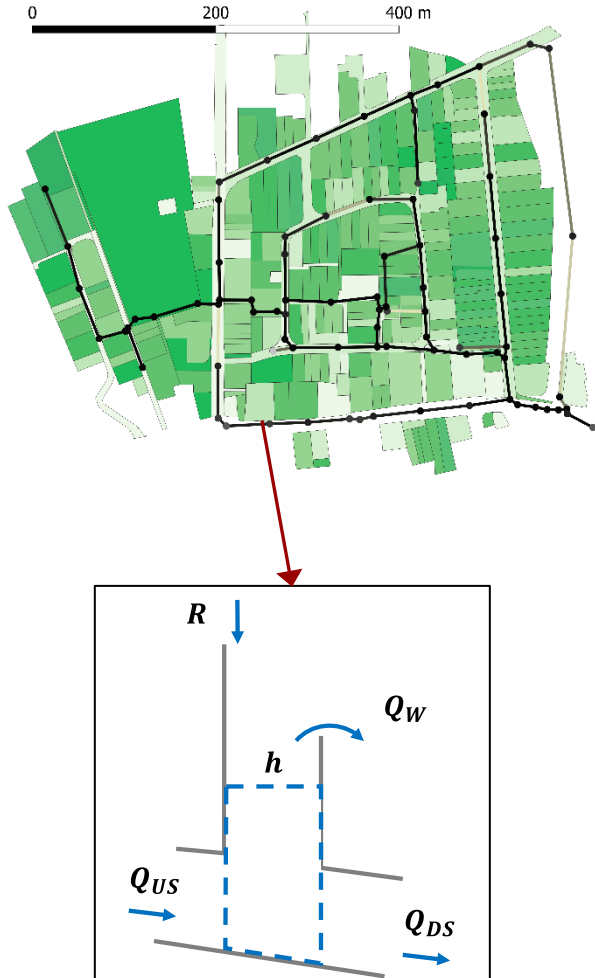
## Dynamisk (Input – output)

$$x_{t+\Delta t} = \Phi_{\Delta t}(x_t)$$

$\Phi$  – neuralt netværk som lærer hvordan systemet ændrer sig over tid

Scientific Machine Learning = integration mellem scientific computing (teoretisk funderet) og maskinlæring (databaseret)

# Modelkonfiguration



## Hydrodynamisk surrogatmodel for afløbssystemer

$$\begin{bmatrix} h \\ Q \\ Q_w \end{bmatrix}_{t+\Delta t} = \theta \begin{bmatrix} h \\ Q \\ Q_w \end{bmatrix}_t + N(h_t, Q_t, Q_{w,t}, R_t)$$

Euler løsning af ligningsystemet, med  $\Delta t$  10-20 gange større end numerisk model

Træn model imod kort hydrodynamisk beregning

# Hydrologisk systemforståelse

## Data-drevet model

$$\begin{bmatrix} h \\ Q \\ Q_w \end{bmatrix}_{t+\Delta t} = \theta \begin{bmatrix} h \\ Q \\ Q_w \end{bmatrix}_t + N(h_t, Q_t, Q_{w,t}, R_t)$$

- Oversvømmelser / opstuvning  $Q_w$  sker kun meget sjældent, så det er svært at træne dynamikken

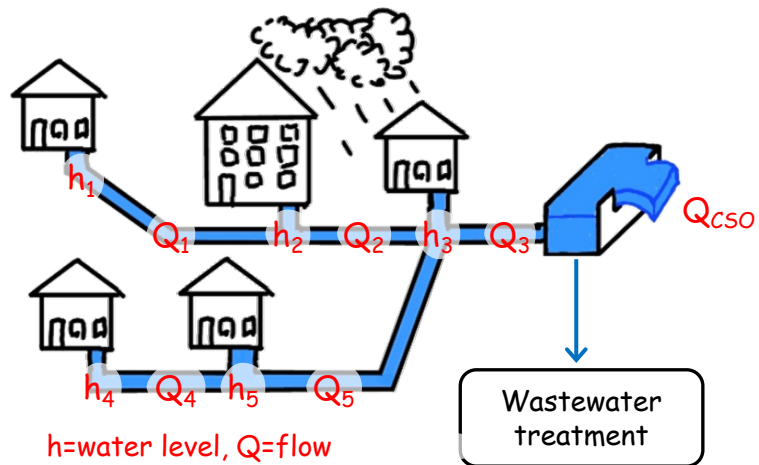
## Med hydrologiske begrænsninger

$$\begin{bmatrix} h \\ Q \end{bmatrix}_{t+\Delta t} = \theta \begin{bmatrix} h \\ Q \end{bmatrix}_t + N(h_t, Q_t, R_t)$$

$$Q_{w,t+\Delta t} = R_t + Q_{in,t+\Delta t} - Q_{out,t+\Delta t}$$

- $Q_w$  opstår kun når rør og knudepunkter er fyldt med vand og kan derfor udregnes i simpel massebalance for hver knudepunkt

# Hvorfor kan vi regne hurtigere?




- Numerisk løser: iteration igennem alle links og nodes
- Surrogatmodel: udnytter korrelation mellem naboer i systemet og forudsiger næste tidsskridt fra "regressionsfunktion"

**MEN - model bliver systemspecifikt**

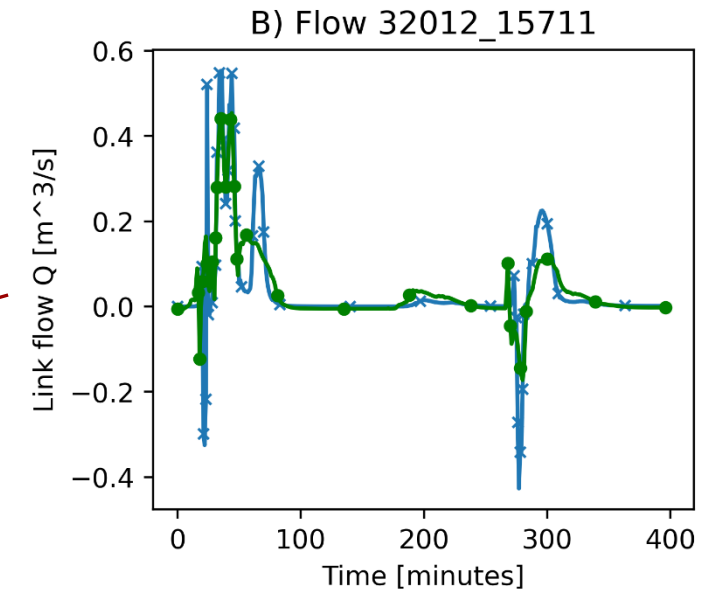

# Resultater

# Hydrographer





# NSE i to testsystemer



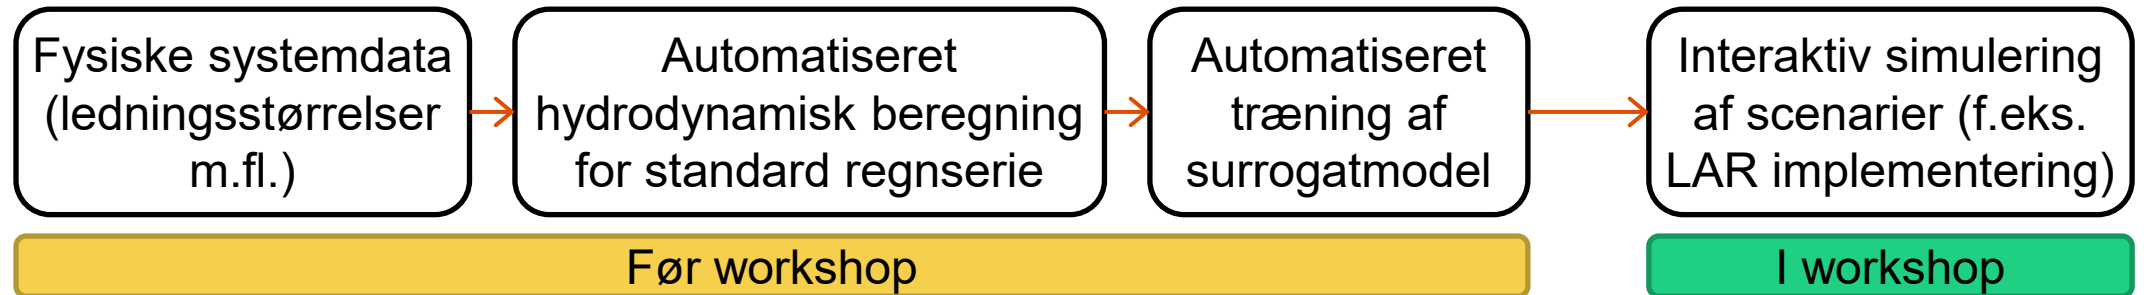
# Beregningstid (1 CPU)

	Generering af træningsdata i MIKE+	Træning af surrogatmodel	Simulering af 40 års regnserie (uden tørvejrperioder)
<b>Opland 1</b>			
MIKE+	-	-	6,200s [5s tidsskridt]
Surrogatmodel	450s	4,000s	75s
<b>Opland 2</b>			
MIKE+			11,400s
Surrogatmodel	670s	6,000s	110s

# Anvendelser + forbedringer

# Anvendelser

## Workshops



## Realtidsovervågning

- Automatisk konfiguration af data assimilering i hydrauliske beregninger

# Samarbejde med compute miljøer

# Samarbejde - Deep learning løser kun de spørgsmål vi stiller

## Domænekendskab

- Hvilke modeller findes
- Hvad skal vi egentlig modellere
- Hvor præcis behøver resultaterne at være
- Hvad er en god testcase
- Hvilke data er fejlbehæftede

## Software engineering

- Effektive data flows
- Håndtering af store data mængder i træningen

## Matematik

- Hvilke andre metoder er relevante
- Hvor godt fungerer det virkelig ned i detaljerne
- Hvordan tackler man fejl i data

# Tak for opmærksomheden!

Tak til Miljøstyrelsen / MUDP  
programmet for finansiering af Clacos  
projektet.



Tak til Stadt Bochum for data +  
samarbejde.



Water Research  
Volume 223, 1 September 2022, 118972



Accelerating hydrodynamic simulations of urban  
drainage systems with physics-guided machine  
learning

Rocco Palmitessa <sup>a</sup>, Morten Grum <sup>b</sup>, Allan Peter Engsig-Karup <sup>c</sup>, Roland Löwe <sup>a</sup>  

<https://doi.org/10.1016/j.watres.2022.118972>