

## Högfrekvent data i modellering

Användning, utmaningar och nytta vid modellering av flöde- och vattenkemi

Emma E. Lannergård, Martyn Futter, Jens Fölster

SLU, Vatten och miljö, Rapport 2023:8

Referera gärna till rapporten på följande sätt:

Lannergård, E.E., Futter, M., Fölster, J. (2023) Högfrekvent data i modellering -  
Användning, utmaningar och nytta vid modellering av flöde- och vattenkemi, SLU,  
Vatten och miljö, Rapport 2023:8

Omslagsfoto: Emma Lannergård

Kontakt

[emma.lannergard@slu.se](mailto:emma.lannergard@slu.se)

[www.slu.se/](http://www.slu.se/)

# Innehåll

Förord.....	1
Sammanfattning .....	2
Summary .....	3
1 Introduktion .....	4
2 Bakgrund.....	4
2.1 Mätning av olika parametrar med sensorer .....	4
2.2 Behov av högfrequent flödesdata.....	5
2.3 C-Q analys.....	5
2.4 Vattenkvalitetsmodellering .....	6
2.5 Syfte .....	7
3 Studieområden .....	7
4 Modellering högfrequent vattennivådata .....	8
4.1 PERSiST .....	8
4.2 Modelluppsättning och data .....	9
4.3 Vattennivå till vattenföring – tre testcase.....	9
5 C-Q analys (högfrequent turbiditet och flöde).....	11
5.1 Identifiering av episoder.....	11
5.2 Hysteresisanalys .....	12
5.2.1 Vad betyder de olika mönstren?.....	12
5.2.2 Dominerande respons för de olika vattendragen.....	14
5.2.3 Fördjupad analys i Sävjaån .....	15
5.2.4 Högfrequent vattennivå för hysteresisanalys i Hågaån .....	16
6 Högfrequent data i modellering .....	17
6.1 INCA-PEco .....	17
6.2 Dataset för kalibrering.....	17
6.3 Användning av låg- och högfrequent data .....	18
6.3.1 Överensstämmelse modellerad och observerad data.....	18
6.3.2 Koncentrationer och belastning.....	19
6.3.3 Processer för mobilisering av material (TSS och TP).....	20
7 Tillämpning i förvaltningen .....	21
8 Slutsatser.....	21
Bilaga 1 Högfrequent väderdata för modellering av vattenflöde.....	23
Bilaga 2 Episoder .....	24

Bilaga 3 Exempel hysteresismönster .....	25
Referenser .....	26

## Förord

Denna rapport utgör en leverans till EU Life-IP projektet Rich Waters, aktivitet C8. Inom delprojektet ingick att undersöka i vilken mån högfrekventa mätningar av vattenkvalitet med sensorer kan användas i vattenförvaltningen, framför allt i effektuppföljning av åtgärder mot näringsläckage från jordbruksmark. I en tidigare rapport inom projektet, "Sensorer för vattenkvalitet i miljöövervakning av vattendrag - Hur användbara är de i praktiken?" av Fölster m.fl. (2019), fokuserades på de praktiska och kvalitetsmässiga aspekterna av mätningar med sensorer i vattendrag samt hur man med sensorer kan få mer tillförlitliga beräkningar av ämnestransporter. I denna rapport presenteras olika möjligheter att med fördjupad analys att öka värdet av de stora mängderna data som sensorerna producerat genom att ta fram underlag för vattenförvaltningen. Arbetet bygger på författarnas pågående forskning inom ett nytt område. Man kan därför inte förvänta sig att resultaten i nuläget ska kunna användas direkt, utan ska mer ses som exempel på vad man kan förvänta sig i framtiden av hur sensordata kan komma att användas.

## Sammanfattning

Användning av in-situ sensorer för insamling av data med hög frekvens (exempelvis var 15:e min) kan ge bättre förståelse för biogeokemiska och hydrologiska processer i specifika vattendrag. I denna rapport har beskrivits tre olika sätt att med fördjupad analys av sensordata generalisera och skala upp resultaten från mätningarna.

I det första exemplet används vattennivå, som exempelvis kan mätas med sensorer, i modellen PERSiST för att ta fram tidsserier för vattenföring. Genom modellen skapas en ”syntetisk avbördningskurva” utan tidsödande manuella mätningar och kostsamma installationer. Detta kan göras med hög frekvens (exempelvis per timme) då tillgänglig nederbörds- och temperaturdata finns, men alternativet finns även att använda ett dagligt tidssteg. Kvaliteten på nederbörds- och temperaturdata hade stor betydelse för resultatet, men metoden verkar lovande. Hur väl detta fungerar i olika typer av vattendrag och under olika förhållanden behöver undersökas ytterligare.

I det andra exemplet analyseras sensordata tillsammans med vattenföringsdata (C-Q analys) för att skapa en bättre förståelse för processer i vattendragen, exempelvis erosion av suspenderat material. Genom att undersöka dynamiken i turbiditet under episoder med högre vattenföring, kan vi se att de fyra undersökta vattendragen reagerar på olika sätt på ökat flöde. När klimatdata läggs till i analysen, exempelvis regn/snö, snösmältning, markfuktighet, kan responsen i vattendragen kopplas till olika processer och säsonger. Resultaten kan användas som stöd för val av åtgärder mot näringsförluster från jordbruksmark och även visa vilka vattendrag som är mest känsliga för ökad förekomst av extrem nederbörd och snabba flödesförändringar till följd av klimatförändringen.

Vidare har högfrekvent data använts i vattenkvalitetsmodellering. Den betydande variationen i högfrekvent kalibreringsdata gjorde det svårare att uppnå hög samstämmighet mellan modellerade och observerade värden. Användning av den högfrekventa datan i modellen gav generellt både högre koncentrationer (mg/l) och belastning (kg/dag) av suspenderat material och totalfosfor (kg/dag) i jämförelse med den lågfrekventa datan. I takt med att kunskapen om användningen av högfrekvent data i modeller ökar kommer det visa sig i vilken mån de kommer kunna användas i förvaltningen.

Vi har här gett några exempel på hur olika typer av fördjupad analys av sensordata kan öka användningen, med potential att ge underlag för vattenförvaltningen så att värdet av datan ökar ytterligare. Arbetet med att skala upp användning av data från in-situ sensorer är dock ännu i ett tidigt skede, och mycket arbete kvarstår innan applikationer kan användas direkt i förvaltningen.

## Summary

The use of in-situ sensors to generate high-frequency data sets (e.g. every 15th min) can give insights into biogeochemical and hydrological processes in specific streams. In this report, we are giving three examples of how these data sets can be upscaled and the conclusions generalised.

In the first example water level, which can be monitored with in-situ sensors (pressure transducers), was used to predict discharge with the rainfall-runoff model PER-SiST. An “artificial rating curve” was created without costly installations or time consuming field work. The set-up was tested with high-frequency data (hourly) with available precipitation and temperature data, and on a daily time step. The result depends a lot on the input precipitation and temperature data series, but looks promising. The quality of data and applicability in different streams need to be further investigated before this method could be used by water managers.

In the second example sensor and discharge data was analysed together (C-Q analysis) to improve understanding about processes affecting the stream, e.g. particle mobilisation. Analysis of turbidity dynamics during high flow events showed that the four studied streams reacted differently to the higher discharge. When additional environmental conditions are added (snow melt, rain/snow, soil moisture) the response in the streams can be attributed to specific processes and/or seasons. This information can guide mitigation measures in streams, and identify streams that are especially vulnerable to impacts of climate change (intense rainfall, fast changes in discharge).

Furthermore, high-frequency sensor data was used for calibration in a catchment scale water quality model (INCA-PEco). The large variation in sensor data made it harder to calibrate the model and make observed and modelled concentrations fit. Using high-frequency sensor data (daily) in the model resulted in both higher concentrations (mg/l) and loads (kg/day) compared to low-frequency data (monthly). More experience is needed to evaluate the applicability of sensor data in modelling within water management.

A few examples have been given on how we can increase the usability, and by that also the value of sensor data. If sensor data can be used by water managers, be upscaled and generalised it will be easier to motivate why we need it. This work is still in an early stage, and more experience is needed to understand how to apply it in Swedish water management.

# 1 Introduktion

Användning av in-situ sensorer för insamling av data med hög frekvens (exempelvis var 15:e min) kan ge bättre förståelse för biogeokemiska och hydrologiska processer i specifika vattendrag. In-situ betyder ”på plats” och innebär att sensorn finns installerad i vattendraget dygnet runt, för att fånga variation över tid. In-situ sensorer kan användas för många olika syften, exempelvis för att öka förståelse för variation i vattenföring, transport av näring och suspenderade partiklar, kartlägga algblooming, surstötter, koldioxid i vatten och biologiska processer (Lannergård & Fölster, 2023).

Användning av in-situ sensorer för att förstå biogeokemiska processer inom forskning blir allt vanligare (Bierzoza m.fl., 2023), och användningen ingår i vissa länder i den nationella miljöövervakningen som ett komplement till mer traditionell månadsvis provtagning (Skarbøvik m.fl., 2023). Andra former av övervakning in-situ är betydligt vanligare, exempelvis mätning av vattennivå, vilket är den vanligaste metoden för att uppskatta vattenföring (SMHI, 2023).

Studier som behandlar sensordata är ofta fokuserade på ett eller några få vattendrag, där målet är att studera specifika processer för just det vattendraget eller vattenförekomsten oavsett vattenkvalitetsparameter (Wallin m.fl., 2020, Lannergård m.fl., 2019, Jones m.fl., 2011; Husic m.fl., 2023, Rogora m.fl., 2023). En viktig fråga för kommande användning av data från in-situ sensorer är hur vi kan skala upp resultaten, dvs hur kunskapen och insikterna från specifika vattendrag kan generaliseras och generera förståelse på större skala.

## 2 Bakgrund

### 2.1 Mätning av olika parametrar med sensorer

Tekniken för mätning av vattenkemi med in-situ sensorer är ofta baserad på ljus i olika våglängder (ex. turbiditet, fDOM, cyanobakterier-phyco cyanin, ett av flera sätt att mäta löst syre), spänning (konduktivitet), eller jonselektiva elektroder (pH, nitrat) (YSI, 2023). I dagsläget är det mer komplicerat att mäta exempelvis totalfosfor (TP) då det kräver kemiska processer, vilket resulterar i en mer komplicerad typ av sensor i en annan prisklass (ex. WIZ probe, Systea 2023). Tekniken kan även baseras på tryck, vilket är vanligt vid mätning av vattennivå (YSI, 2023).

När sambanden mellan turbiditet och TP eller suspenderat material (TSS) är goda, kan turbiditet användas som en proxy för nämnda parametrar (Villa m.fl., 2019, Lannergård m.fl., 2019). Dessa samband är dock platsspecifika, på grund av ursprung, partikelstorlekskomposition, färg och form hos materialet som är orsaken till vattnets



grumlighet (Gippel m.fl., 1995; Pfannkuche & Smith, 2003; Yao m.fl., 2014). Försök har gjorts att generalisera dessa samband. Vid en jämförelse av turbiditet-TSS förhållandet mellan vattendrag i Nordeuropa är sambandet bättre vid högre värden på turbiditet och TSS, samt i jordbruksområden med finare jordar (Skarbøvik m.fl., 2023). I ett annat fall visar en studie i USA att en generell regressionskvation kunde tas fram för en region med varierande markanvändning och avrinningsområdesstorlek. Där var lutningen i regressionskvationen inte signifikant annorlunda för fyra av fem vattendrag vilket indikerar att den skulle kunna användas för dessa fyra vattendragen (Steffy & Shank, 2018). Exempel finns också på studier som använt maskininlärning för att förbättra och generalisera sambanden mellan olika proxys och med detta lyckats minska prediktionsfelet (RMSE) med upp till 60% (Castrillo & Garcia, 2020). När ett bra samband finns mellan turbiditet och TP eller TSS kan högfrekventa mätningar vara värdefulla för att identifiera kritiska perioder för transport, exempelvis vid högflöde (Lannergård m.fl., 2019).

## 2.2 Behov av högfrekvent flödesdata

För att förstå den kortsiktiga variationen vi ser i den högfrekventa datan, behövs likvärdiga dataset för flödesvariationen i vattendraget. Högfrekvent flödesdata behövs exempelvis för belastningsberäkningar, och även för C-Q analys (se rubrik 2.3). Vattennivå är enklare att mäta jämfört med vattenföring. Ofta mäts därför vattennivå (även av SMHI) som sedan relateras till vattenföring genom en så kallad avbördningskurva (SMHI, 2023). Avbördningskurvan baseras på mätningar av vattennivån och vattenflödet vid olika tidpunkter och under olika förhållanden. Vattennivå baserat på tryck är även en parameter som ofta är inkluderad vid mätning av vattenkemi in-situ. Därav finns ett motiv att genom modellering skapa en ”syntetisk avbördningskurva” för att generera vattenföring från vattennivå. Det skulle möjliggöra tillgång till vattenföringsdata utan kompletterande utrustning i vattendraget och tidsödande manuella mätningar av hastigheten i vattendraget. Modellering av vattenföring från vattennivå är möjligt då högfrekvent temperatur och nederbördsdata finns tillgänglig i närområdet, vilket i Sverige tillhandahålls stationsspecifikt av SMHI (per timme) (SMHI, 2023). Vid modellering av vattenföring från vattennivå, upprättas ingen traditionellt uppmätt avbördningskurva, men samma ekvationer används för beräkningarna i modellen (ex. PERSiST).

## 2.3 C-Q analys

Ett sätt att förstå hur hydrologi och biogeokemi kontrollerar processer är att analysera vattenkemikoncentrationer tillsammans med flöde, så kallade C-Q analyser (Lloyd m.fl., 2016). Denna typ av analys kan användas under specifika flödestoppar (episoder) eller göras på hela dataserier, då för att förstå generella mönster. Heathwaite & Bieroza (2020) använde högfrekvent data för att ta fram olika index som beskriver respons hos olika vattenkemiska parametrar, exempelvis parametrar som påverkas av högflöden/erosion (TP, TSS) och parametrar som domineras av cykler

(ex. dygnszykler, löst syre, redox potential och temperatur). Hur vattenkemin varierar i relation till flödet kan ge information om systemet reagerar snabbt eller långsamt på det ökade flödet. Det i sin tur kan vara informativt för att förstå exempelvis var partiklarna som mobiliserats kommer ifrån (Lannergård m.fl., 2021).

## 2.4 Vattenkvalitetsmodellering

Ett annat sätt att använda högfrekvent data på större skala är genom användning i vattenkvalitetsmodeller, det är dock ännu inte vanligt förekommande (Piniewski m.fl., 2019). Modelleringsprocessen innefattar många olika steg (Figur 1) där modellen kalibreras och anpassas för att simulera observerad data. Den observerade datan kan vara högfrekvent (HF) eller lågfrekvent (LF). Modellen kalibreras först manuellt och sedan automatiskt med en så kallad Monte Carlo-analys. Monte Carlo-analys är en statistisk metod som beräknar resultatet av olika parameterkombinationer (som utvärderas enligt specifika anpassade intervall) (Fitzpatrick, 2018). Sedan utvärderas resultatet där modellerad och observerad data jämförs, olika utvärderingsstatistik finns för detta exempelvis Nash-Sutcliffe Efficiency (NSE, Nash & Sutcliffe, 1970) eller Kling-Gupta Efficiency (KGE, Gupta m.fl., 2009). KGE är vanligen använt då det kombinerar olika mått på överensstämmelsen, exempelvis (1)  $r^2$ -värdet vilket utvärderar den kollineariteten mellan observerade och modellerade värden, (2) jämför medelvärden för observerade och modellerade data samt (3) variationsration mellan observerade och modellerade data (Gupta m.fl., 2009). Ett eller flera parameterset kan användas för att utvärdera resultatet.

I samband med modelleringen görs ofta en så kallad känslighetsanalys av olika parametrar, då vi undersöker hur mycket specifika parametrar i modellen påverkar resultatet. Detta görs genom undersöka vilka parametrar som ändras mest före och efter optimeringen av modellen (Spear & Hornberger, 1980). Ofta testas även modellen på olika sätt för att avgöra om resultatet är robust eller inte.



Figur 1. Ett exempel på hur arbetet med en modell kan utföras. Lågfrekvent data (LF) eller högfrekvent data (HF) kan användas för kalibrering. Ett eller en grupp parameterset kan användas för att visualisera resultatet.

För att modellerna ska fungera på ett bra sätt behövs längre tidsserier som beskriver både blöta och torra år. Då det fortfarande är relativt ovanligt med långa tidsserier från in-situ sensorer kan det vara en av förklaringarna till att detta område ännu är

relativt outforskat. Några exempel på studier som använt högfrekvent data för bättre förståelse av processer på avrinningsområdesnivå modellering av  $\text{NO}_3\text{-N}$  (Jiang m.fl., 2019, Kämäri m.fl., 2019, Ullrich & Volk, 2010, Piniewski m.fl., 2019), TP (Me m.fl., 2015; Jackson-Blake m.fl., 2015, Taylor m.fl., 2016; Hollaway m.fl., 2018; Piniewski m.fl., 2019). Det är även ovanligt att använda turbiditet som en proxy för TP eller TSS i modellering på avrinningsområdesnivå. Detta har hittills endast gjorts i en publicerad studie (Piniewski m.fl., 2019). I befintlig litteratur beskrivs vissa fördelar med högfrekvent data, exempelvis genom att fånga mer variation i datan som modellerna kalibreras mot, kan processerna simuleras på ett mer tillförlitligt sätt (Ullrich & Volk, 2010). I Piniewski m.fl. (2019) visades att en fördubbling av kalibreringsdata (från 12 till 26 observationer i månaden) förbättrade modellens utförande.

## 2.5 Syfte

Syftet med denna rapport är att sammanfatta arbetet med att skala upp användning av högfrekvent data från in-situ sensorer inom projektet EU Life-IP projektet Rich Waters. Följande frågeställningar har behandlats:

- Kan högfrekvent vattennivå användas för modellering av vattenflöde?
- Kan C-Q analys under högflödesepisoder användas för att förstå processer som orsakar grumlighet (partikeltransport)? Kan resultaten användas för att särskilja olika vattendrag från varandra?
- Kan högfrekvent data användas i vattenkvalitetsmodellen INCA-PEco? Vilka utmaningar har identifierats vid användning av högfrekvent data och hur varierar resultatet jämfört med kalibrering mot ett dataset baserat på månadsvis (lågfrekvent) data?

## 3 Studieområden

Fokusområde i arbetet har varit Sävjaåns avrinningsområde, där mätningar av vattennivå har testats mot vattenflöde, en fördjupad analys av C-Q dynamik under högflödesepisoder har gjorts samt användning av vattenkvalitetsmodellen INCA-PEco. Avrinningsområdet (722 km<sup>2</sup>) har en blandad markanvändning, där 71 % domineras av skog, ofta på moränmark, och 24 % jordbruksmark och öppen mark ofta på lerdominerad mark, resterande ytor är urbana miljöer (2%) och sjöar (3%). Området är låglänt (1 - 72 möh) och Sävjaån har tidigare beskrivits som en typisk slättlandså (Vattenmyndigheten, 2017).

C-Q analysen har även testats på ytterligare tre avrinningsområden för att undersöka möjligheten att generalisera slutsatserna: Fyrisån, Hågaån och Skivarpsån (beskrivs i tabell 1). Fyrisån är ett betydligt större avrinningsområde (2003 km<sup>2</sup>) med liknande

markanvändning som i Sävjaån (och där Sävjaån är ett av Fyrisåns biflöden). Vattenkemin i Fyrisån är dock påverkad av dagvatten och avloppsreningsverket i Uppsala (VISS, 2023). Hågaån och Skivarpsån är ungefär lika stora, men där Hågaån har en varierande markanvändning som domineras av skog men med jordbruk på lerjordar i närheten av vattendraget. Skivarpsån domineras av jordbruk på sandiga-leriga jordar (SMHI, 2023b).

I Hågaån mäts inte flöde av SMHI (vattennivå mäts av SLU). En tidigare studie har undersökt om data från närbelägna Sävaån (12 km från Hågaån) kan användas för att uppskatta flöde i Hågaån (Pierrau, 2022). Då användning av datan från Sävaån gav goda resultat för uppskattning av flöde i Hågaån användes (1) högfrekvent vattenföringsdata från Sävaån (uppmätt av SMHI) samt (2) högfrekvent vattennivådata från Hågaån (mätt av SLU) för analys av C-Q förhållanden i Hågaån.

Tabell 1. Beskrivning av analyserade vattendrag (och avrinningsområden). Data från SMHI Vattenwebb, 2023. Dominerande jordtyper redovisas.

Vattendrag	Sävjaån	Fyrisån	Hågaån	Skivarpsån
Avrinningsområdesarea (km <sup>2</sup> )	722	2003	123	124
Medelflöde (m <sup>3</sup> /s)	2	7	1.4	0.8
Markanvändning %	Skog (54), jordbruk (25), urban (9), myrmark (5), hygge (3), sjö (2)	Skog (52), jordbruk (25), urban (8), myrmark (7), Öppen mark (3), hygge (3), sjö (2)	Skog (53), jordbruk (23), urban (8), öppen mark (7), myrmark (7), hygge (3)	Jordbruk (77), urban (9), skog(7), öppen mark (5), myrmark (1), sjö (1)
Jordtyp %	Morän (35), ler-silt (23), tunn jord (15), finjord (11), torv (9),	Morän (38), ler-silt (21), torv (11), finjord (10), tunn jord (9)	Morän (27),ler-silt (22), finjord (20), tunn jord (17)	Sand (72), morän (11) ler-silt (4)

## 4 Modellering högfrekvent vattennivådata

### 4.1 PERSiST

PERSiST är en semi-distribuerad modell som simulerar hydrologi i mark och vatten på avrinningsområdesnivå, genom nederbörd- och temperaturdata (Futter m.fl., 2014). Versionen som användes i detta delprojekt (<https://github.com/INCAWQModels/Distribution>) kan köras på valfri tidsupplösning, även om ett dagligt tidssteg är det vanliga. Den kan kalibreras mot vattenföring, vattennivå eller markfuktighet. Tidigare versioner av modellen har använts för att simulera vattenföring på avrinningsområden från några hektar (Kupec m.fl., 2021) upp till flera

tusen km<sup>2</sup> (Futter m.fl., 2015). Modellen levererar även data kring markfuktighet, effektiv nederbörd och snösmältning. Detta kan sedan användas som input till andra modeller (exempelvis olika modeller på avrinningsområdesnivå) eller för analys av data. För det här projektet användes en nyligen utvecklad anpassning av modellen som gör det möjligt att kalibrera mot vattennivå i stället för flöde.

## 4.2 Modelluppsättning och data

Här utfördes tre modelluppsättningar för att utvärdera möjligheten att simulera vattenföring med hjälp av vattennivå.

(1) Dagliga flöden och vattennivåer simulerades i Sävjaån med hjälp av uppmätta flöden och nivåer samt dagliga nederbörds- och temperaturdata från SMHI (SMHI, 2023c).

(2) Vattennivåer per timme simulerades i Sävjaån med hjälp av SMHI:s mätningar av vattennivå i Sävjaån samt temperatur och nederbörd vid ett antal stationer i Uppsalaområdet tillhandahållna av SMHI (AUT, Ärna, Sala) (Beskrivning i Bilaga 1).

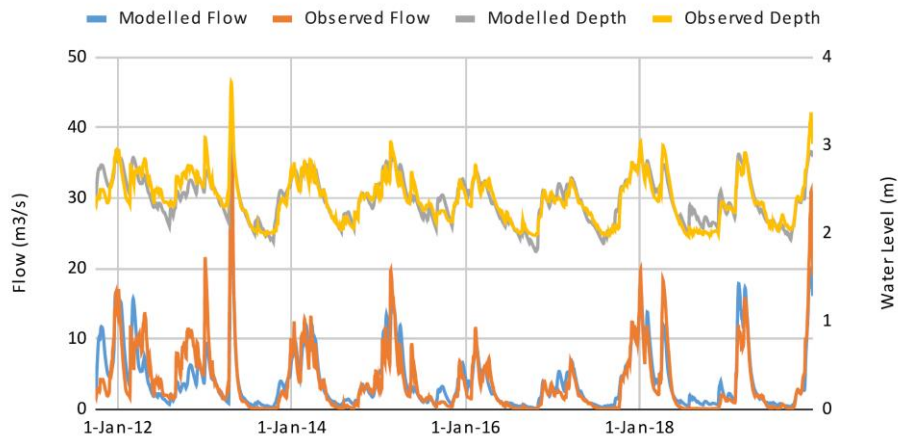
(3) Vattennivåer per timme simulerades med hjälp av högfrekvent vattennivå (dock ej från in-situ sensor, från en så kallad TruTrack) i Hågaån och SMHI:s mätningar av temperatur och nederbörd som användes ovan (2).

För varje test (1-3) identifierades en parameteruppsättning som resulterade i bäst överensstämmelse mellan observerade och simulerade värden med hjälp av en Monte Carlo-analys (50 kandidatparameteruppsättningar härledda från kedjor med 250 modellkörningar, Futter m.fl., 2014) baserat på rimliga parameterintervall identifierade i Laguna Marin (2023) och Pierrau (2022). Parameteruppsättningen med den bästa överensstämmelsen mellan observerade och simulerade värden bedömdes genom Nash-Sutcliffe (NSE, Nash & Sutcliffe, 1970) och Kling-Gupta-värde (KGE, Gupta m.fl., 2009), vilket är två olika statistikberäkningar som används för att utvärdera modellens utförande.

## 4.3 Vattennivå till vattenföring – tre testcase

Vid ”test case 1” kalibrerades PERSiST med daglig data mot både vattennivå och vattenföring, vilket fungerade bra (Figur 2). Acceptabla resultat kunde presenteras och modellen simulerade kortsiktig dynamik både gällande flöden och nivåer, vilket betyder att det bör gå att simulera endast vattenföring när vattennivådata används.

## Sävjaån Modelled and Observed Depths and Levels




Figur 2 Modellerad och observerad vattenföring (y-axel vänster) och vattennivå (y-axel höger) i Sävjaån.

Användning av nederbördstidsserien från Uppsala AUT/Ärna/Sala gav ej tillfredsställande resultat (ej visat). Modellen kunde simulera kortsiktig och säsongvis variation men ej mellanårsvariation. I ett försök att avhjälpa detta skapades en ny nederbördstidsserie där varje timvärde för nederbörd var relaterat till förhållandet mellan årsnederbörd från Uppsala universitets observationsserie (Celcius, 2023) och summan av årlig nederbörd från provtagningsplatsen. Denna “konstgjorda tidsserie” användes sedan för ”test case 2 och 3”. Detta tyder på att indatan till modellen (nederbörd och temperatur) är väldigt viktig för resultatet.

Vid kalibrering mot högfrekvent timdata i ”test case 2” användes samma parameterinställningar för daglig modellkalibrering som för att modellera timvärden. Detta har fungerat i andra studier som utvärderat möjligheten att använda samma parameterset för olika tidsupplösning (ex. Reynolds m.fl., 2017, Fuentes-Andino m.fl., 2022). Acceptabla värden för utvärdering av modellen kunde uppnås oavsett vilken utvärderingsstatistik som användes (NSE eller KGE). Båda statistikberäkningarna resulterade i visuellt liknande resultat.

Generellt kunde modellen även i “test case 3” simulera medel-långtidsvariation i vattennivådynamiken i Hågaån, men misslyckades med att fånga delar av den högfrekventa variationen (Figur 3).

### Hågaån Water Levels




Figur 3. Modellerat (blå) och observerad (röd) vattennivå i Hågaån.

## 5 C-Q analys (högfrekvent turbiditet, flöde)

### 5.1 Identifiering av episoder

Vid analys av vattenkemi i förhållande till flöde är det första steget att identifiera episoder då snabba förändringar i flödet leder till förändringar i vattenkvaliteten. Dessa förändringar i flöde kan vara genererade av olika processer, exempelvis regn, snö eller snösmältning. Ofta används lågvattenflöde som genereras från grundvatten (basflöde) som ”gräns” för att markera när dessa episoder startar. Denna metod fungerar dock inte när vattenflödet inte går tillbaka till lågvattenflöde mellan varje episod. Därför användes en anpassad metod, baserad på daglig vattenföring eller vattennivå. Flödet analyseras utifrån hur mycket det ökar eller minskar (i relation till observationen innan), samt när det minskat till nära ursprungsnivån (detaljerad beskrivning i Lannergård m.fl., 2021) (Figur 4). Episodidentifieringen utfördes med en rutin som programmerats i verktyget Python. Det är generellt en automatiserad process men det går även att ändra vissa värden för att anpassa metoden till en aktuell flödeskurva.



Figur 4. Exempel på episodidentifiering för Hågaån. Gröna markörer visar när eventet startar, lila markörer vilka observationer som ingår i episoden och röda när episoden avslutas.

Episodidentifiering utfördes i de fyra olika vattendragen. I tabell 2 beskrivs episoderna utifrån antal, maxflöde, medelflöde och minflöde. Identifierade episoder för alla vattendrag kan ses i bilaga 2.

Tabell 2. Beskrivning av episoder i de olika lokalerna. Antalet episoder i Sävjaån är baserat på perioden 2012-2020 och i Fyrisån, Hågaån och Skivarpsån 2018-2022.

Lokaler	Sävjaån	Fyrisån	Hågaån	Skivarpsån
Antal event	43	51	44	43
Maxflöde (event)	45	45	11	8
Medelflöde (event)	5	10	3	1
Tröskel minflöde (def. i metod)	0.35	1.15	0.2	0.13
Längd dagar (min-max)	3-66	3-66	3-37	3-39
Säsong (n 1,2,3,4)	17,15,7,4	28,15,1,7	21,12,1,10	21,7,2,7

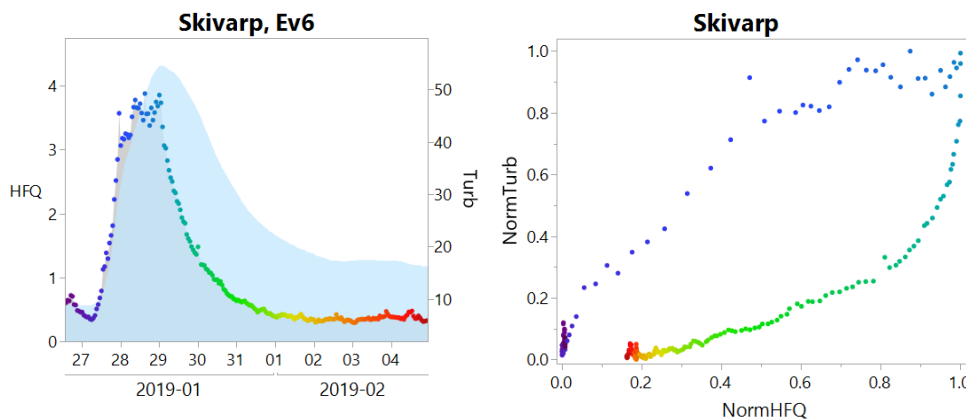
## 5.2 Hysteresisanalys

### 5.2.1 Vad betyder de olika mönstren?

Partikelhalten uppvisar ofta ett tydligt positivt samband med flöde, men med olika samband när flödet ökar i början av en episod och senare i episoden när flödet minskar. Denna dynamik av halter under en flödesepisod benämns hysteresis. Ibland är halterna högre i början vilket kan bero på lösa partiklar som spolas bort från ytor samt erosion i dikeskanter (tabell 3). Ibland är halterna istället högre under slutet av



episoden vilket kan bero på att marken hunnit bli så mättad av vatten att det uppstår jorderosion i anslutning till vattendragen. I större mer sammansatta avrinningsområden blir responsen mer komplex. Vid hysteresisanalys visualiseras vattenföring på y-axeln mot parametern i fråga på x-axeln (Figur 5, fler exempel i bilaga 3). De olika mönstren som då bildas indikerar olika respons i vattendraget, där exempelvis ett medsols (clockwise, C) mönster indikerar en snabb respons utifrån det ökande vattenflödet. Ett motsols mönster (anticlockwise, A) indikerar en långsam respons i systemet. När turbiditeten har fler toppar i förhållande till flödestoppen (anticlockwise-clockwise, AC och clockwise-anticlockwise, CA) finns sannolikt fler källor till partikelmobiliseringen. I de fall då turbiditetstopparna inte är kopplade till flödet blir mönstret komplext (Complex, Cx). Olika teorier finns kring hur partiklarna mobiliseras utifrån de olika mönstren (tabell 3).



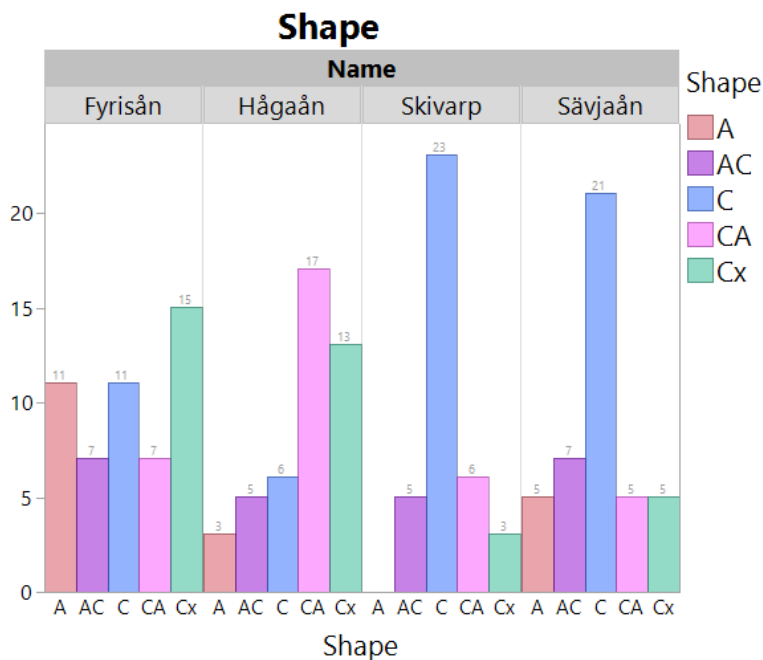
Figur 5. Skivarpån. En episod med medsols mönster (C), en snabb respons i systemet där turbiditetstoppen kommer före flödestoppen.

Tabell 3. Tolkning av olika mönster enligt litteraturen.

Mönster	Tolkning	Referens
Medsols (C)	Källor i nära anslutning till vattendraget, kort transportsträcka i relation till sensorn.	Haddadchi & Hicks, 2020; Lloyd m.fl., 2016
Motsols (A)	Transport från källor längre bort i relation till sensorn, erosion orsakad av att markfuktigheten successivt höjs	Haddadchi & Hicks, 2020; Williams, 1989
Två toppar (AC, CA)	Två eller fler källor är aktiva, exempelvis nära och längre bort från sensorn.	Haddadchi & Hicks, 2020
Komplext (Cx)	Fler turbiditetstoppar i relation till flödesökningen, kan orsakas av regn.	Haddadchi & Hicks, 2020

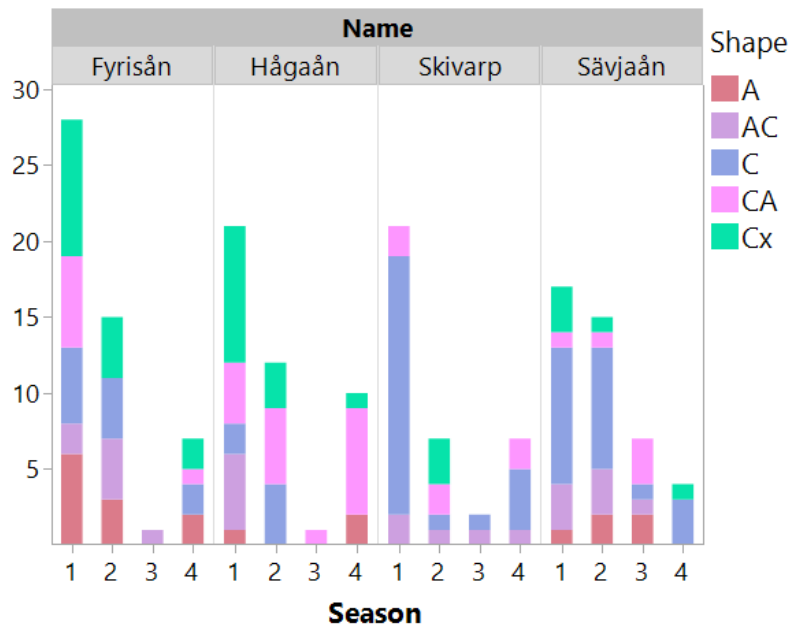
### 5.2.2 Dominerande respons för de olika vattendragen

Den dominerande responsen för de olika vattendragen varierade. I Fyrisån visade en del episoder en långsam respons (Figur 6, A=11), turbiditetstoppen kom i många fall efter flödestoppen. Det tyder på att partiklar antingen transporteras innan det når sensorn eller att avrinningsområdet har en buffrande förmåga. Den vanligaste responsen i Fyrisån var dock komplexa mönster (Figur 6, Cx=15), vilket innebär att turbiditetstopparna inte är direkt sammanlänkade med flödet. I Hågaån däremot dominerade en snabb respons i systemet (Figur 6, C=6 och CA=17) ofta med en efterföljande mindre turbiditetstopp efter flödestoppen. Detta skulle kunna förklaras med erosion i närheten av sensorn som svar på det ökade flödet, samt transport från uppströmsområden. I Skivarpsån med stor andel jordbruksmark och finkorniga jordar dominerade en snabb respons av systemet (Figur 6, C =23), ofta förklarad som erosion i det närliggande området till sensorn. Även i Sävjaån dominerade den snabba responsen (Figur 6, C=21), detta avrinningsområde har också mycket jordbruksmark och lerjordar i direkt anslutning till sensorn. Typisk respons för de olika vattendragen kan ses i bilaga 2.



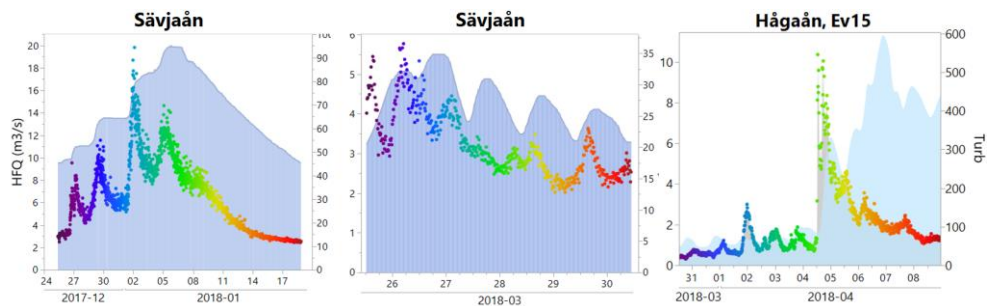
Figur 6. Antalet episoder uppdelat på respons (A-motsols, AC – motsols/medsols, C – medsols, CA – medsols/motsols och Cx- komplexa) och vattendrag.

Vidare kunde olika mönster observeras under olika säsonger. De flesta episoderna identifierades under vintersäsongen som definierats som perioden dec-feb (säsong 1, Figur 7). Å andra sidan identifierades väldigt få episoder under sommaren (säsong 3, jun-aug) vilket kan förklaras med stor andel låga flöden. Inga samband mellan säsong och hysteresismönster kunde ses för de undersökta vattendragen.



Figur 7. En uppdelning av hysteresismönster per säsong och provplats där 1=dec till feb, 2=mar-maj, 3=jun-aug, 4=sep-nov.

Exempelvis snösmältning, en process som genererar turbiditet, kunde identifieras på ett liknande sätt mellan de olika vattendragen då mönstren såg ut på liknande sätt (stegvis ökning av vattenflöde med tillhörande turbiditetstoppar, Figur 8). Dessa episoder ägde rum under perioder då snösmältning var en sannolik förklaring.



Figur 8. Snösmältning i Sävjaån och Hågaån med liknande mönster för vattenföring och turbiditet.

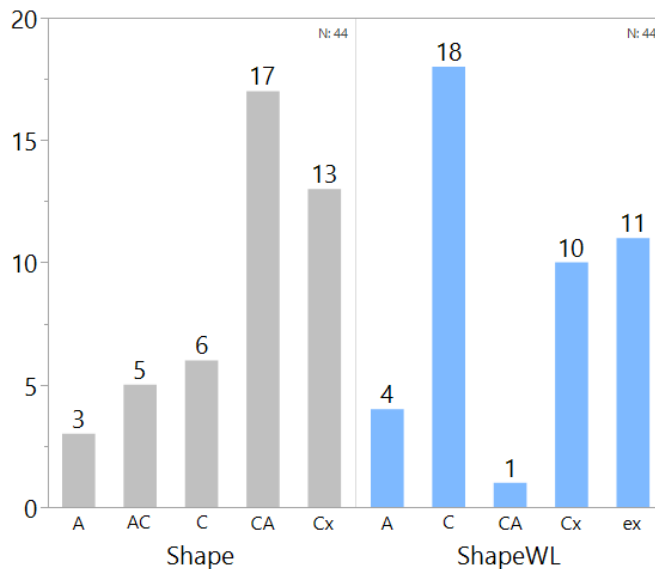
### 5.2.3 Fördjupad analys i Sävjaån

En mer djupgående analys av hysteresismönster i Sävjaån har gjorts (Lannergård m.fl., 2021). Där sammankopplades de olika hysteresismönster med fler miljöförhållanden, exempelvis regn, snö, snösmältning och markfuktighet. Medsols mönster (C), som var den dominerande responsen i vattendraget var sammanlänkat med vinter och vårsäsongen. Snö, snösmältning och hög markfuktighet var ofta överensstämmande med episoder som visade snabb respons i vattendraget, vilket kan förklara en direkt mobilisering av partiklar. Episoder som visade medsols (C) mönster och

dubbla toppar i turbiditet (AC, Cx) var ofta kopplade till nederbörd. Under sommaren visade analysen av episoderna att turbiditet och flödesförändringar var fränkopplade, dvs att turbiditeten varierade oberoende av flödet. Detta tyder på andra källor till turbiditeten, exempelvis biologisk aktivitet (alger, växter/växtdelar/fisk/andra vattenlevande djur) i vattendraget.

#### 5.2.4 Högfrekvent vattennivå för hysteresisanalys i Hågaån

En jämförelse har gjorts mellan hysteresisanalys med högfrekvent data från Sävaån (samma station som för episodidentifieringen) och högfrekvent vattennivåmätning i Hågaån. Hysteresismönstret var i 33/44 fall inte överensstämmande mellan de två metoderna (Figur 9). Analysen med högfrekvent vattennivåmätning visade fler episoder med snabb respons (clockwise), 18 i jämförelse med 6. Analysen med högfrekvent vattenföring från Sävaån visade fler komplexa mönster (CA, AC, Cx). I 11 fall kunde inte episoderna analyseras med högfrekvent vattenföringsmätning på grund av att vattennivådynamiken var ur fas.



Figur 9. Antalet av respektive kategori (hysteresismönster) för analys med högfrekvent vattenföringsdata (Shape) och högfrekvent vattennivådata (ShapeWL)


## 6 Högfrekvent data i modellering

### 6.1 INCA-PEco

INCA-PEco är en avrinningsområdesmodell för fosfor och biologi som används för att simulera flöde, fosfor (TP) och suspenderat material (TSS) (Crossman m.fl., 2021). INCA-PEco är processbaserad, vilket betyder att ekvationer används för att simulera de olika processer som bidrar till mobilisering och transport av fosfor och suspenderat material. Modellen tar hänsyn till mark och vattendragsprocesser (exempelvis internbelastning från sediment och den bäcknära zonen). Modellen är semi-distribuerad vilket innebär att området som modelleras kan delas upp utifrån vattendragens tillrinningsområde, varje del har sin specifika markanvändning vilket påverkar processerna i modellen. Modellens tidsupplösning är per dygn.

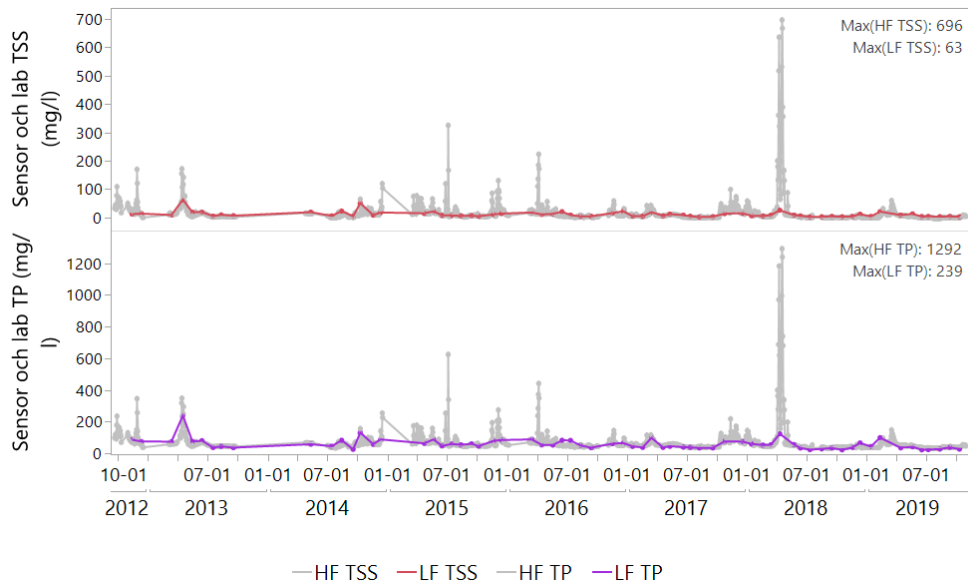
### 6.2 Dataset för kalibrering

Två olika dataset användes för kalibrering av modellen. Månadsvisa stickprover av vatten analyserade på lab (lågfrekvent, LF) användes som observerade värden, samt högfrekvent data (HF) där turbiditet använts som en proxy för att beräkna TSS och TP (Figur 10). Ekvationen från den linjära regressionen (mellan turbiditet-TSS respektive turbiditet-TP) används för att beräkna respektive parameter. Den högfrekventa datan finns tillgänglig var 15:e minut, men aggregerades här till dygnsmedelvärden då tidssteget i modellen är per dygn.



Figur 10. Linjär regression mellan sensor turbiditet och lab TSS (vänster) respektive lab TP (höger).  $R^2$ -värdet turbiditet-TSS var 0.79 och turbiditet-TP, 0.82. Sävjaån.

En markant skillnad mellan de olika dataseten (LF och HF) är att koncentrationerna varierar olika mycket (Figur 11). Maxvärdena för LF respektive HF data för TSS är 63, 696 mg/l och TP 239, 1292 µg/l vilket påverkar modelleringsresultatet.



Figur 11. Visualisering av de olika dataseten som använts för kalibrering per parameter i Sävjaån.

### 6.3 Användning av låg- och högfrekvent data

#### 6.3.1 Överensstämmelse modellerad och observerad data


I tabell 4 redovisas KGE-värden för flöde (Q), TSS och TP. Flödet predikterades lika bra med lågfrekvent som högfrekvent data, detta var väntat då flödet kalibrerats mot samma dataset (dagligt uppmätt flöde). Både avseende TSS och TP gav den lågfrekventa datan bättre KGE-värden än den högfrekventa. Det kan bero på att dynamiken i den högfrekventa datan är svårare att förutse och prediktera än den mindre varierande lågfrekventa datan.

Tabell 4. KGE värden (bästa parameteraset) för kalibrering mot lågfrekvent (LF) data och högfrekvent (HF) data. KGE-värden sträcker sig mellan  $\infty$  till 1 där 1 är perfekt överensstämmelse mellan modellerad och observerad data. Sävjaån 2012-2020.


LF TSS och TP (KGE)			HF TSS och TP (KGE)		
Q	TSS	TP	Q	TSS	TP
0.85	0.71	0.42	0.85	0.29	0.38

### 6.3.2 Koncentrationer och belastning

När högfrekvent data användes för kalibrering gav det modellerade resultatet generellt sett högre observationer i jämfört med modellerade värden från lågfrekvent data (Figur 12 och 13).



Figur 12. Modellerade koncentrationer av TSS baserat på den högfrekventa datan (orange) jämfört med den lågfrekventa datan (grå). Sävjaån 2012-2020.



Figur 13. Modellerade koncentrationer av TP baserat på den högfrekventa datan (lila) jämfört med den lågfrekventa datan (grå). Sävjaån 2012-2020.

Belastning beräknades utifrån modellerade dygnskoncentrationer från (1) LF och (2) HF data. Dessa dygnskoncentrationer multipliceras sedan med det dagliga flödet. Vidare jämfördes dessa belastningar med belastning beräknad från linjärt interpolerad lågfrekvent (månadsvis) labbdata, vilket är den vanliga metoden exempelvis inom vattenförvaltningen (HELCOM, 2021). Vid linjär interpolation dras en linje mellan de uppmätta koncentrationerna som sedan används för att uppskatta dygnsvärden av koncentrationer som sedan multipliceras med dagligt flöde.

Vid jämförelse av lågfrekvent jämfört med högfrekvent data var belastningen genomgående högre för högfrekvent data (Tabell 5). När belastningarna istället jämfördes mot interpolerad data varierade resultatet där den interpolerade belastningen vissa år var högre än resultaten från den modellerade datan (2012,2013), vissa år lägre (2015, 2017) och under övriga år mittemellan modellerad belastning för LF respektive HF data.

Tabell 5. Tabellen visar TP belastning (ton/år) från interpolerad månadsvis data, samt modellerade värden för lågfrekvent (LF) respektive högfrekvent (HF) data.

År	Interpolerad lab data (ton/år)	LF TP/TSS (ton/år)	HF TP/TSS (ton/år)
2013	17	6.8	13
2014	9.0	8.3	16
2015	8.6	9.8	20
2016	6.6	4.5	7.0
2017	6.4	7.3	14
2018	8.6	7.6	15
2019	14	10	22

### 6.3.3 Processer för mobilisering av material (TSS och TP)

Känslighetsanalysen pekar på vilka processer som är viktiga för att uppnå modellerat resultat. En jämförelse gjordes av känsliga parametrar för kalibrering mot LF och HF data. Generellt var parametrar som genererar suspenderat material viktiga för resultatet, men även parametrar som reglerar vattenflöde från land. Parametrar som innefattas i TSS parameter 1-4 är kopplade till erosion orsakad av flöde samt hur mycket vegetationen bromsar denna erosion (tabell 6). Parametrar som reglerar vattenflöde från land benämns nedan inom kategorien LandQ. LandQ parameter 1-3 innefattar processer kopplade till vattenhållandekapacitet och ytavrinning. Oavsett om modellen kalibrerades mot LF eller HF data förekom i stort sett samma parametrar i känslighetsanalysen (tabell 6).

Tabell 6. Tabellen visar känsliga parametrar för kalibrering mot lågfrekvent (LF) data eller högfrekvent (HF) data. TSS parameter 1-4 motsvarar parametrar kopplade till generering av suspenderat material och LandQ parameter 1-3, parametrar rörande markvatten och ytavrinning.

LF	HF
TSS parameter 2-4	TSS parameter 1-3
LandQ parameter 1 och 3	LandQ parameter 2,3



## 7 Tillämpning i förvaltningen

Sensorer ger värdefull information om variation och hur representativa stickproverna är, men de är ännu dyra. Vi har här gett några exempel på hur olika typer av fördjupad analys kan öka användningen med potential att ge underlag för vattenförvaltningen så att värdet av datan ökar. Arbetet med att skala upp användning av data från in-situ sensorer är dock ännu i ett tidigt skede, och mycket arbete kvarstår innan applikationer kan användas direkt i förvaltningen.

Gällande användning av vattennivå för att beräkna vattenföring verkar resultaten lovande, men fördjupade studier behöver göras för att bekräfta detta. Detta skulle göra det enklare och billigare att få relevanta högupplösta vattenföringsdata utan att behöva göra dyra installationer och ta fram avbördningskurvor. Användning av vattennivådata från sensorerna behöver undersökas för att se om kvaliteten är tillräckligt bra för att kunna användas. Hysteresisanalys kan i dagsläget användas för att fördjupa förståelsen för olika vattendrag och hur dessa eventuellt kommer att reagera vid framtida klimatförändringar. Även här finns en databegränsning i form av flödesdata, vattennivå (minst) behöver mätas i det specifika vattendraget för att möjliggöra denna typ av analys. Modellering med högfrekvent data är ännu i sin linda och det kvarstår många frågetecken kring vilket värde det kommer att få. Det är därför för tidigt att kunna säga något om värdet av modellering med högfrekventa data för förvaltningen.

## 8 Slutsatser

Att ta tillvara all den information vi får med hjälp av högfrekvent datainsamling är en utmaning - men av högsta relevans. Efter att datan kvalitetssäkrats (Fölster m.fl., 2019) kan den användas för olika syften (Lannergård & Fölster, 2023). I denna rapport har beskrivits olika sätt med vilka vi kan generalisera och skala upp användningen av sensordata.

Vattennivå, som exempelvis kan mätas med tryckgivare, kan användas i modellen PERSiST och skapa en ”syntetisk avbördningskurva” och skapa tidsserier för vattenföring. Detta kan göras med hög frekvens (exempelvis per timme) då tillgänglig nederbörds- och temperaturdata finns, men alternativet finns även att använda ett dagligt tidssteg. Avgörande för resultatet är kvaliteten på högfrekvent temperatur och nederbördsdata.

Genom att analysera flödesdata tillsammans med sensordatan under höglödesepiso-der kan vi få en bättre förståelse för processer som driver dynamik av olika paramet-erar i vattendragen. Vi har visat att med hjälp av denna metod kan skillnader och likheter mellan processer som exempelvis genererar turbiditet utrönas mellan olika

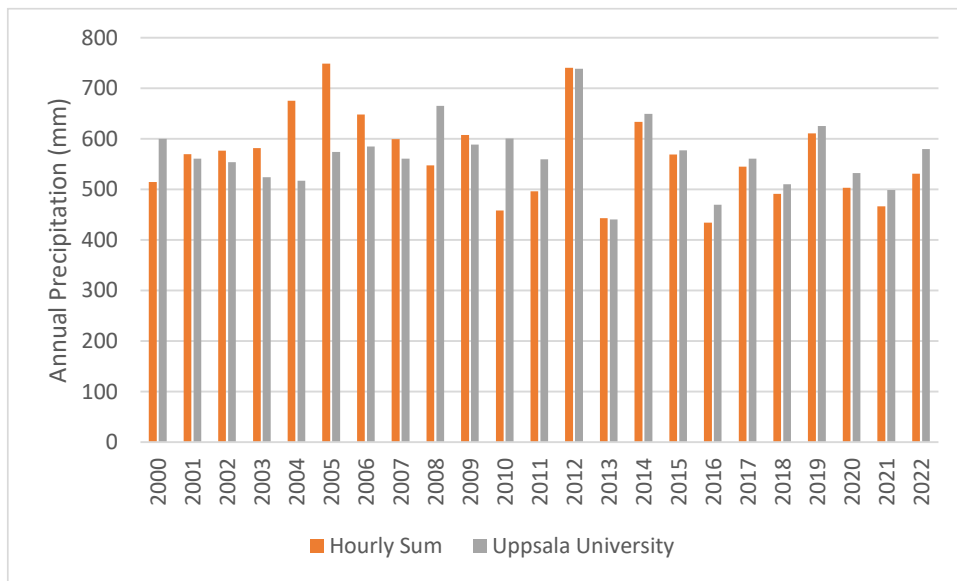
vattendrag. Vid addering av ytterligare miljöförhållanden (exempelvis regn/snö, snösmältning, markfuktighet) kan responsen i vattendragen kopplas till olika processer och säsonger. Vi har även visat att flödes- och kemidata bör användas från samma vattendrag, men att ett visst värde finns även vid interpolering av flöde från närliggande vattendrag. Att analysera vilka processer som mobiliserar partiklar kan användas för att identifiera effektiva åtgärder för platsen, men även för att se vilka vattendrag som är mer känsliga för klimatförändringar (exempelvis extrem nederbörd, snabba flödesförändringar).

Vi har även kunnat visa att högfrekvent data kan användas i vattenkvalitetsmodellering. Den betydande variationen i högfrekvent kalibreringsdata gjorde det svårare att uppnå hög samstämmighet mellan modellerade och observerade värden. Den högfrekventa datan gav generellt både högre TSS och TP koncentrationer och belastning (kg/dag) i jämförelse med den lågfrekventa datan. När den årliga belastningen jämfördes med linjärt interpolerad belastning från stickprover, gav den linjärt interpolerade belastningen ibland högre och ibland lägre årliga värden jämfört med modellerade värden. Sannolikt beror detta på den höga känslighet för nivå på enskilda stickprover i den linjära interpoleringen som även tidigare observerats (Lannergård m.fl., 2019). I takt med att kunskapen om användningen av högfrekvent data i dessa modeller ökar kommer det visa sig i vilken mån de kommer kunna användas i förvaltningen.

Sensorer är fortfarande relativt dyra att köpa, därav är det extra viktigt att utnyttja datan på bästa sätt. Möjlighet finns att tillämpa hysteresisanalys i förvaltningen då det har hög användarvänlighet och går snabbt att genomföra med befintliga script. Modellering ger ökad förståelse för vilka processer som är viktiga och gör det möjligt att modellera scenarier med ändrat klimat och olika implementeringsgrad av åtgärder. Sannolikt representerar den högfrekventa datan ett bredare koncentrationsintervall i modellerna vilket gör resultaten intressanta för framtiden, mer arbete behövs dock för att förstå hur vi kan kombinera högfrekvent data med modeller på ett bra sätt.

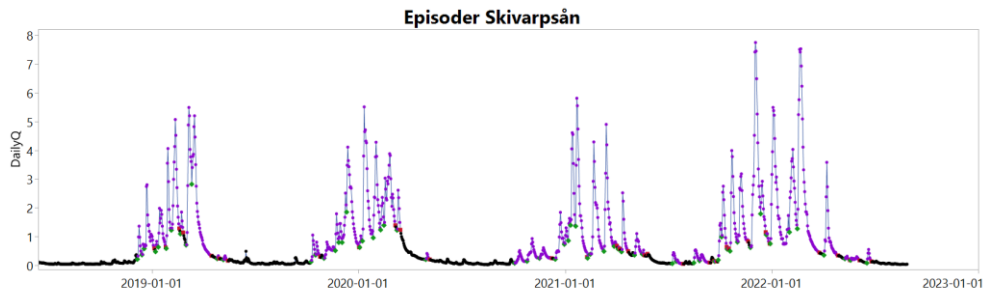
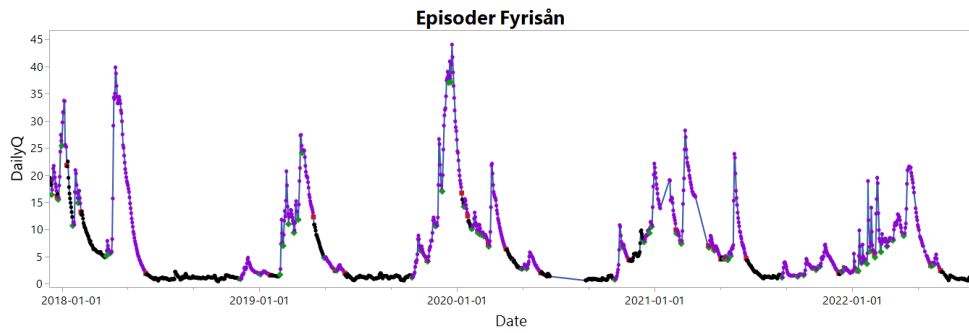
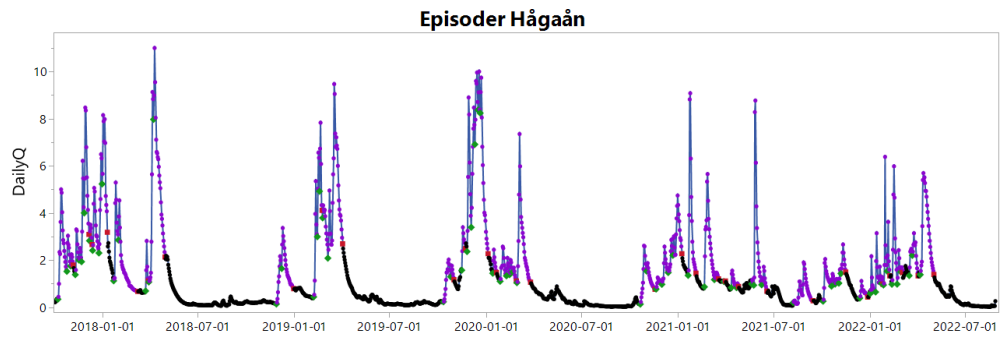
## Bilaga 1 Högfrekvent väderdata för modellering av vattenflöde

På grund av uppehåll i uppmätt data från stationen “Uppsala AUT”, användes data från den närbelägna stationen “Uppsala Ärna” samt medeldygnstemperatur från stationen Sala (näst närmaste stationen) samt vissa perioder av nederbörd. Det fanns vissa olikheter mellan uppmätt data från Uppsala universitet och dataserien med kombinerad data från fler sites (se figur 1).

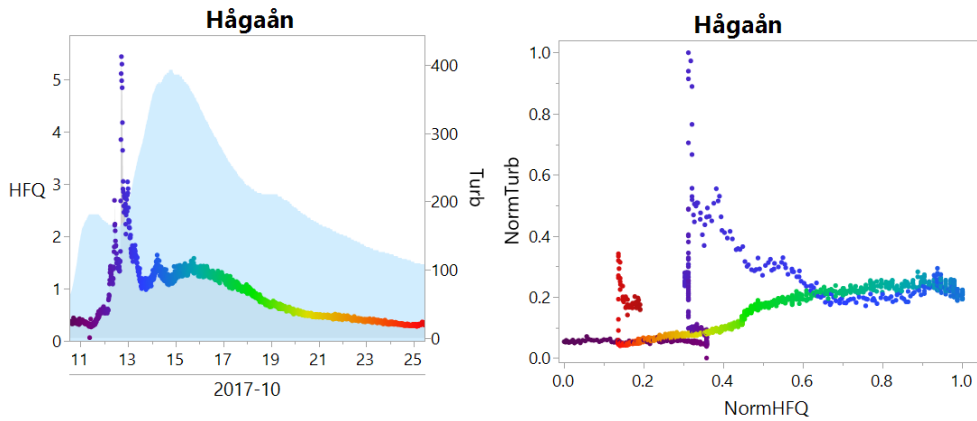


Figur 1. Jämförelse mellan årlig nederbörd från data från Uppsala universitet (Celcius) och från flerstationskombinationen (Uppsala AUT, Uppsala Ärna, Sala, SMHI).

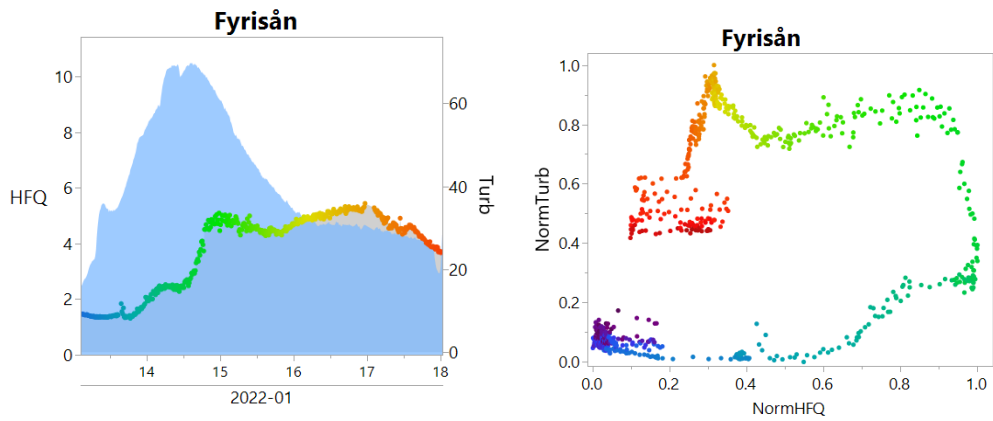
## Bilaga 2 Episoder



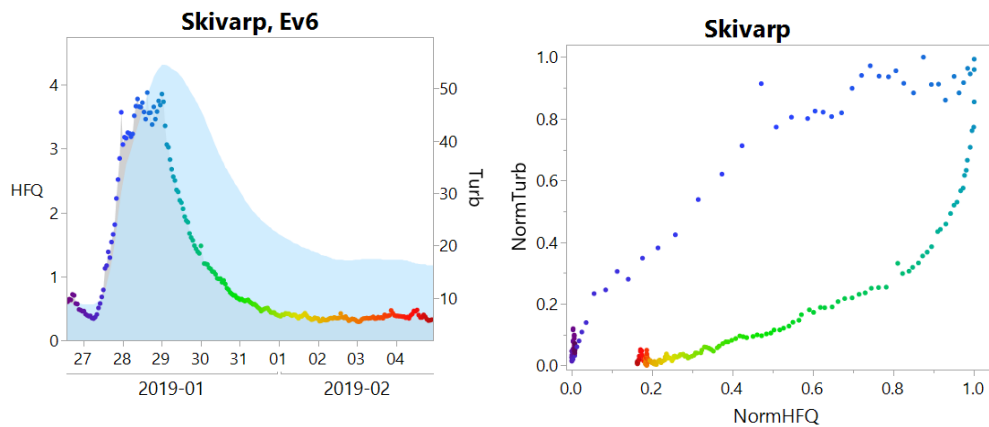
## Bilaga 3 Exempel hysteresismönster



*Hågaån: En episod med mönstret CA, först en snabb respons sedan en efterföljande turbiditetstopp.*



*Fyrisån: En episod med mönstret A, en långsam respons där turbiditetstoppen kommer efter flödestoppen.*



*Skivarpån: En episod med mönstret C, en snabb respons i systemet där turbiditetstoppen kommer före flödestoppen.*

## Referenser

Bieroza M, Acharya S, Benisch J, ter Borg RN, Hallberg L, Negri C, Pruitt A, Pucher M, Saavedra F, Staniszewska K, et al. 2023. Advances in Catchment Science, Hydrochemistry, and Aquatic Ecology Enabled by High-Frequency Water Quality Measurements. *Environ Sci Technol* [Internet]. [accessed 2023 Mar 24]. <https://doi.org/10.1021/acs.est.2c07798>

Castrillo M, García ÁL. 2020. Estimation of high frequency nutrient concentrations from water quality surrogates using machine learning methods. *Water Research*. 172:115490. <https://doi.org/10.1016/j.watres.2020.115490>

CELSIUS. [accessed 2023 May 17]. <http://celsius.met.uu.se/>

Crossman J, Bussi G, Whitehead PG, Butterfield D, Lannergård E, Futter MN. 2021. A New, Catchment-Scale Integrated Water Quality Model of Phosphorus, Dissolved Oxygen, Biochemical Oxygen Demand and Phytoplankton: INCA-Phosphorus Ecology (PEco). *Water*. 13(5):723. <https://doi.org/10.3390/w13050723>

Fitzpatrick D. 2018. Chapter 10 - Monte Carlo Analysis. In: Fitzpatrick D, editor. *Analog Design and Simulation Using OrCAD Capture and PSpice (Second Edition)* [Internet]. [place unknown]: Newnes; [accessed 2023 May 22]; p. 151–164. <https://doi.org/10.1016/B978-0-08-102505-5.00010-0>

Fuentes-Andino, D., Hundecha, Y., Lindström, G. and Olsson, J. 2022. Exploring the potential for parameter transfer from daily to hourly time step in the HYPE model for Sweden. *Hydrological Sciences Journal*, 67(13), pp.1988-2001. <https://doi.org/10.1080/02626667.2022.2121165>

Futter MN, Erlandsson MA, Butterfield D, Whitehead PG, Oni SK, Wade AJ. 2014. PERSiST: a flexible rainfall-runoff modelling toolkit for use with the INCA family of models. *Hydrol. Earth Syst. Sci.*, 18, 855–873, <https://doi.org/10.5194/hess-18-855-2014>, 2014.

Futter, M.N., Whitehead, P.G., Sarkar, S., Rodda, H. & Crossman, J. 2015. Rainfall runoff modelling of the Upper Ganga and Brahmaputra basins using PERSiST. *Environmental Science: Processes & Impacts*, 17(6), pp.1070-1081. <https://doi.org/10.1039/C4EM00613E>

Fölster, J., Lannergård E, Valley S & Olshammar M. 2019. Sensorer för vattenkvalitet i miljö-ervakning av vattendrag - Hur användbara är de i praktiken? SLU, Vatten och miljö: Rapport 2019:10.

Gippel CJ. 1995. Potential of turbidity monitoring for measuring the transport of suspended solids in streams. *Hydrological processes*. 9(1):83–97. <https://doi.org/10.1002/hyp.3360090108>

Gupta HV, Kling H, Yilmaz KK, Martinez GF. 2009a. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*. 377(1):80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>

Haddadchi A, Hicks M. 2020. Interpreting event-based suspended sediment concentration and flow hysteresis patterns. *J Soils Sediments* [Internet]. [accessed 2020 Nov 5]. <https://doi.org/10.1007/s11368-020-02777-y>

Heathwaite AL, Bieroza M. Fingerprinting hydrological and biogeochemical drivers of freshwater quality. *Hydrological processes*. 35:1. <https://doi.org/10.1002/hyp.13973>

HELCOM, 2021, Applied methodology for the PLC-7 assessment. [accessed 2023 May 17]. [https://helcom.fi/post\\_type\\_publ/applied-methodology-for-the-plc-7-assessment/](https://helcom.fi/post_type_publ/applied-methodology-for-the-plc-7-assessment/)

Hollaway MJ, Beven KJ, Benskin CMcWH, Collins AL, Evans R, Falloon PD, Forber KJ, Hiscock KM, Kahana R, Macleod CJA, et al. 2018. The challenges of modelling phosphorus in a headwater catchment: Applying a 'limits of acceptability' uncertainty framework to a water quality model. *Journal of Hydrology*. 558:607–624. <https://doi.org/10.1016/j.jhydrol.2018.01.063>

Husic A, Fox JF, Clare E, Mahoney T, Zarnaghsh A. 2023. Nitrate Hysteresis as a Tool for Revealing Storm-Event Dynamics and Improving Water Quality Model Performance. *Water Resources Research*. 59(1):e2022WR033180. <https://doi.org/10.1029/2022WR033180>

Jackson-Blake LA, Starrfelt J. 2015. Do higher data frequency and Bayesian auto-calibration lead to better model calibration? Insights from an application of INCA-P, a process-based river phosphorus model. *Journal of Hydrology*. 527:641–655. <https://doi.org/10.1016/j.jhydrol.2015.05.001>

Jiang SY, Zhang Q, Werner AD, Wellen C, Jomaa S, Zhu QD, Büttner O, Meon G, Rode M. 2019. Effects of stream nitrate data frequency on watershed model performance and prediction uncertainty. *Journal of Hydrology*. 569:22–36. <https://doi.org/10.1016/j.jhydrol.2018.11.049>

Jones AS, Stevens DK, Horsburgh JS, Mesner NO. 2011. Surrogate Measures for Providing High Frequency Estimates of Total Suspended Solids and Total Phosphorus Concentrations I. *JAWRA Journal of the American Water Resources Association*. 47(2):239–253. <https://doi.org/10.1111/j.1752-1688.2010.00505.x>

Kupec, P., Deutscher, J. & Futter, M. 2021. Longer growing seasons cause hydrological regime shifts in central European forests. *Forests*, 12(12), p.1656.

Laguna Marin, C. 2023. Assessment of future climate and land use changes on streamflow and phosphorus transport in a Swedish agricultural catchment. SLU Master Thesis.

Pierrau, H. 2022. Evaluation of Streamflow Predictions in an Ungauged Swedish Catchment: A Study of Håga River. SLU Masters Thesis

Kämäri M, Huttunen I, Valkama P, Huttunen M, Korppoo M, Tattari S, Lotsari E. 2019. Modelling inter- and intra-annual variation of riverine nitrogen/nitrate losses from snowmelt-affected basins under agricultural and mixed land use captured with high-frequency monitoring. *CATENA*. 176:227–244. <https://doi.org/10.1016/j.catena.2019.01.019>

Lannergård EE, Ledesma JLJ, Fölster J, Futter MN. 2019. An evaluation of high frequency turbidity as a proxy for riverine total phosphorus concentrations. *Sci Total Environ*. 651(Pt 1):103–113. <https://doi.org/10.1016/j.scitotenv.2018.09.127>

Lannergård EE, Fölster J, Futter MN. 2021. Turbidity-discharge hysteresis in a meso-scale catchment: The importance of intermediate scale events. *Hydrological Processes* [Internet]. [accessed 2023 Mar 24] 35(12). <https://doi.org/10.1002/hyp.14435>

Lannergård E.E. & Fölster J. 2023. In-situ sensorers användning i nationell miljöövervakning. SLU Rapport 2023:2

Lloyd CEM, Freer JE, Johnes PJ, Coxon G, Collins AL. 2016. Discharge and nutrient uncertainty: implications for nutrient flux estimation in small streams: Discharge and Nutrient Uncertainty: Implications for Nutrient Fluxes. *Hydrol Process.* 30(1):135–152. <https://doi.org/10.1002/hyp.10574>

Me W, Abell JM, Hamilton DP. 2015. Effects of hydrologic conditions on SWAT model performance and parameter sensitivity for a small, mixed land use catchment in New Zealand. *Hydrol Earth Syst Sci.* 19(10):4127–4147. <https://doi.org/10.5194/hess-19-4127-2015>

Nash JE, Sutcliffe JV. 1970. River flow forecasting through conceptual models part I — A discussion of principles. *Journal of Hydrology.* 10(3):282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)

Pfannkuche J, Schmidt A. 2003. Determination of suspended particulate matter concentration from turbidity measurements: particle size effects and calibration procedures. *Hydrological Processes.* 17(10):1951–1963. <https://doi.org/10.1002/hyp.1220>

Piniewski M, Marcinkowski P, Koskiaho J, Tattari S. 2019. The effect of sampling frequency and strategy on water quality modelling driven by high-frequency monitoring data in a boreal catchment. *Journal of Hydrology.* 579:124186. <https://doi.org/10.1016/j.jhydrol.2019.124186>

Reynolds, J.E., Halldin, S., Xu, C.Y., Seibert, J. and Kauffeldt, A. 2017. Sub-daily runoff predictions using parameters calibrated on the basis of data with a daily temporal resolution. *Journal of hydrology*, 550, pp.399-411.

Rogora M, Cancellario T, Caroni R, Kamburska L, Manca D, Musazzi S, Tiberti R, Lami A. 2023. High-frequency monitoring through in-situ fluorometric sensors: A supporting tool to long-term ecological research on lakes. *Frontiers in Environmental Science* [Internet]. [accessed 2023 Mar 21] 10. <https://www.frontiersin.org/articles/10.3389/fenvs.2022.1058515>

Skarbøvik E, Gyritia Madsen van't Veen S, Lannergård EE, Wennig H, Stutter M, Bierzoza M, Atcheson K, Jordan P, Fölster J, Mellander P-E, et al. 2023. Comparing in situ turbidity sensor measurements as a proxy for suspended sediments in North-Western European streams. *CATENA.* 225:107006. <https://doi.org/10.1016/j.catena.2023.107006>

Spear RC, Hornberger GM. 1980. Eutrophication in peel inlet—II. Identification of critical uncertainties via generalized sensitivity analysis. *Water Research.* 14(1):43–49. [https://doi.org/10.1016/0043-1354\(80\)90040-8](https://doi.org/10.1016/0043-1354(80)90040-8)

Steffy LY, Shank MK. 2018. Considerations for using turbidity as a surrogate for suspended sediment in small, ungaged streams: Time-series selection, streamflow estimation, and regional transferability. *River Research and Applications.* 34(10):1304–1314. <https://doi.org/10.1002/rra.3373>

SMHI. 2023. Vattenföringsmätningar [accessed 2023 May 10]. <https://www.smhi.se/kunskapsbanken/hydrologi/vattenforing/smhis-vattenforingsmatningar-1.80833>

SMHI. 2023b. Modelldata per område | SMHI - Vattenwebb. [accessed 2023 May 17]. <https://vattenwebb.smhi.se/modelarea/>

SMHI. 2023c. Vattenwebb - Mätningar. [accessed 2023 May 17]. <https://vattenwebb.smhi.se/station/>

Systea WIZ Nutrients Analyser. 2023. [accessed 2023 Mar 21]. <https://observator.com/products/wiz-nutrients-analyser/>



Taylor SD, He Y, Hiscock KM. 2016. Modelling the impacts of agricultural management practices on river water quality in Eastern England. *Journal of Environmental Management*. 180:147–163. <https://doi.org/10.1016/j.jenvman.2016.05.002>

Ullrich A, Volk M. 2010. Influence of different nitrate–N monitoring strategies on load estimation as a base for model calibration and evaluation. *Environ Monit Assess*. 171(1–4):513–527. <https://doi.org/10.1007/s10661-009-1296-8>

Vattenmyndigheten. 2017. Fyrisåns åtgärdsområde, underlag till åtgärdsprogram. Länsstyrelsen i Västmanlands län. Västerås

VISS-Vatteninformationssystem Sverige. [accessed 2023 May 17]. <http://viss.lansstyrelsen.se>

Villa Solis A, Fölster J, Kyllmar K. 2019. Determining suspended solids and total phosphorus from turbidity: comparison of high-frequency sampling with conventional monitoring methods. *Environmental Monitoring and Assessment*. 191. <https://doi.org/10.1007/s10661-019-7775-7>

Wallin MB, Audet J, Peacock M, Sahlée E, Winterdahl M. 2020. Carbon dioxide dynamics in an agricultural headwater stream driven by hydrology and primary production. *Biogeosciences*. 17(9):2487–2498. <https://doi.org/10.5194/bg-17-2487-2020>

Williams G.P. 1989. Sediment concentration versus water discharge during single hydrologic events in rivers, *Journal of Hydrology*, 111, 1-4, pp 89-106. [https://doi.org/10.1016/0022-1694\(89\)90254-0](https://doi.org/10.1016/0022-1694(89)90254-0)

Yao M, Nan J, Chen T. 2014. Effect of particle size distribution on turbidity under various water quality levels during flocculation processes. *Desalination*. 354:116–124. <https://doi.org/10.1016/j.desal.2014.09.029>

YSI Blue-Green Algae. [accessed 2023 Mar 21]. <https://www.y.si.com/parameters/blue-green-algae>