


# DATADRIVNA METODER FÖR ATT DETEKTERA AVVIKANDE MÄTVÄRDEN INOM DAMMSÄKERHET

RAPPORT 2020:640





# **Datadrivna metoder för att detektera avvikande mätvärden inom dammsäkerhet**

**TORBJÖRN JOHANSSON, HÅKAN FRIDÉN, MIKAEL SUNDBERG,  
OSCAR SAMUELSSON OCH ANDERS BJÖRK**

ISBN 978-91-7673-640-1 | © Energiforsk januari 2020

Energiforsk AB | Telefon: 08-677 25 30 | E-post: [kontakt@energiforsk.se](mailto:kontakt@energiforsk.se) | [www.energiforsk.se](http://www.energiforsk.se)



## Förord

**Detta arbete behandlar datadrivna metoder för att fånga upp avvikande tillstånd hos dammar eller värden från givare monterade på eller intill dammar.**

Rapporten presenterar en kort introduktion till dammsäkerhetsområdet, instrumentering, datakedjan, god modelleringspraktik och avvikelседetektion. Därefter har en bredare litteraturstudie om datadriven dammsäkerhet gjorts. För att ge en fördjupning och breddning till detta avsnitt tar rapporten sedan upp olika statistiska, dataanalys- och maskininlärningsmetoder i sig. Därefter ges rekommendationer för vidare arbeten.

Rapporten har skrivits av:

Torbjörn Johansson, Håkan Fridén, Oscar Samuelsson och Anders Björk på IVL Svenska Miljöinstitutet samt Mikael Sundberg på In Situ Instrument.

Projektledare har varit:

Anders Björk på IVL Svenska Miljöinstitutet

Projektet har haft en referensgrupp bestående av:

Uno Kuoljok (Uniper), Kerim Genel Waldenström (Vattenfall), Sezar Moustafa Näsval (Fortum), Romanas Wolfsborg (Vattenfall), Börje Nilsson (Statkraft), Truls Lagendahl (Skelleftekraft) samt Johan Westholm (Vattenregleringsföretagen).

Referensgruppen har bidragit med värdefulla kommentarer under arbetet och på rapporten. Även Carl-Oscar Nilsson (Uniper) har bidragit med goda kommentarer efter diskussioner vid besöket på Storfinnforsens kraftstation.

Projektet "Datadrivna metoder för att detektera avvikande mätvärden inom dammsäkerhet" har finansierats av Energiforsks program för Dammsäkerhet och Stiftelsen Institutet för Vatten- och Luftvårdsforskning.

I denna publikation presenteras resultat och slutsatser från projektet. För innehållet ansvarar IVL. Rapporten har granskats och godkänts i enlighet med IVL:s ledningssystem.

## Sammanfattning

**Rapporten handlar om hur sensorer och datadrivna metoder för analys av sensordata kan användas för att höja säkerheten på svenska dammar. Vi gör en litteraturstudie av state of the art i dammsäkerhet och tar reda på vad som har gjorts i andra länder. Vi tittar även på teorier och metoder som inte ännu har använts i dammsäkerhet, men som skulle kunna vara lämpliga. Med stöd av tiotals års erfarenhet av forskning och utveckling i datadrivna metoder ger vi rekommendationer för hur ett arbete för att implementera datadrivna metoder för att höja dammsäkerheten i Sverige skulle kunna utformas.**

Det är lätt att komma igång med datadriven analys med hjälp av färdiga verktygslådor som finns öppet tillgängliga. Men ett bra förarbete är nödvändigt om metoderna ska vara tillräckligt pålitliga för att kunna användas till dataanalys. Vi diskuterar vanliga fallgropar vid dataanalys och hur man undviker dem, god modelleringspraktik och vanliga dataeffekter som beror på fel i sensorer eller datainsamlingssystem.

En datadriven dammsäkerhetsmetod kan delas upp i prediktion av mätvärden med hjälp av en modell och detektion av avvikelser från denna prediktion. Den så kallade Hydrostatic Season Time (HST)-modellen har använts flitigt för att prediktera dammsensormätvärden, och har även implementerats för storskalig övervakning av tolv dammar från en central plats. Detta visar att datadriven dammsäkerhet har tagit steget från vetenskap till verklighet.

Mycket av den vetenskapliga litteraturen inom datadriven dammsäkerhet handlar om tillämpning av maskininlärningsmetoder. Den struntar ofta i förbehandling och antar att alla sensorer fungerar. Vi summerar resultat om förbehandling av sensordata och hur avvikelser kan detekteras, och ser att här finns ett gap i dammsäkerhetslitteraturen.

Det saknas även studier där man använt data från flera olika dammar. Detta gör att det är svårt att dra någon slutsats om vilken metod som är mest lämplig. Vi ser att väl förstådda och utredda metoder som PCA och PLS, tidsseriemodellering, SPC/MSPC och neurala nätverk är lämpliga för vidare studier. Vidare arbete bör fokusera på att få till ett system som fungerar på verkliga data och kan ge verklig nytta för dammsäkerheten. Förbehandling, analys av sensordatas egenskaper, samt implementation och utvärdering av några få datadrivna metoder på stora mängder riktiga data från flera olika dammar kommer att vara viktiga komponenter i det vidare arbetet. Separation av avvikelser i sensorfel och anomalier i dammen är ett svårt problem, men det finns resultat från andra fält som kan lyftas in. Detta är också högtintressant för tillämpningen.

Vi ser att datadrivna metoder för dammsäkerhet är redo att implementeras i Sverige, och bedömer att i kombination med väl utformad instrumentering, rätt givarplacering och god kommunikation kan de bidra till väsentligt höjd dammsäkerhet.



## Summary

**This report deals with how sensors and data-driven methods for analysing sensor data can be used to enhance the safety of Swedish dams. The report builds on a literature review of state of the art in dam safety, showing what has been done in other countries. We have also been looking at theories and methods that have not yet been used in dam safety, but which could be appropriate. With the support of tens of years of experience in research and development in data-driven methods, we provide recommendations for how a work to implement data-driven methods for raising dam safety in Sweden could be designed.**

It's easy to get started with data-driven analysis using ready-made toolboxes that are openly available. But good preparatory work is necessary if the methods are to be reliable enough to be used for data analysis. We discuss common pitfalls in data analysis and how to avoid them, good modelling practice and common data effects due to errors in sensors or data collection systems.

A data-driven dam safety method can be divided into prediction of measurement values using a model and detection of deviations from this prediction. The so-called Hydrostatic Season Time (HST) model has been widely used to predict dam sensor metrics and has also been implemented for large-scale monitoring of twelve dams from a central location. This shows that data-driven dam safety has taken the leap from science to reality.

Much of the scientific literature in data-driven dam safety is about the application of machine learning methods. It often ignores pre-processing and assumes that all sensors work. We summarize results on pre-processing of sensor data and how anomalies can be detected and see that there is a gap in the dam safety literature.

There is also a lack of studies using data from several different dams. This makes it difficult to draw any conclusion as to which method is most appropriate. Well understood and investigated methods such as principal component analysis, PCA, and projections to latent structures, PLS, time series modelling, statistical process control, SPC, and multivariate SPC, MSPC, and neural networks are suitable for further study. Further work should focus on developing a system that works on real data and can provide real benefits for dam safety.

Pre-processing, analysis of sensor data properties, and implementation and evaluation of a few data-driven methods on large amounts of real data from several different dams are important in further work.

Separation of anomalies in sensor failures and anomalies in a dam is a difficult problem, but there are results from other fields that can be utilised. This is also highly interesting for the application.

Data-driven methods for dam safety are ready to be implemented in Sweden and believe that in combination with well-designed instrumentation, the right sensor placement and good communication, they can contribute to significantly increased dam safety.

# Innehåll

|          |                                                                    |           |
|----------|--------------------------------------------------------------------|-----------|
| <b>1</b> | <b>Inledning</b>                                                   | <b>8</b>  |
| 1.1      | Dammsäkerhet och dammar                                            | 8         |
| 1.2      | God datahantering                                                  | 10        |
| 1.3      | Fallgropar vid dataanalys                                          | 11        |
| 1.4      | God modelleringspraktik                                            | 12        |
| 1.5      | Avvikelsesdetektion                                                | 14        |
| <b>2</b> | <b>Instrumentering för tillståndsovervakning på svenska dammar</b> | <b>17</b> |
| 2.1      | Instrumentering för dammsäkerhet                                   | 17        |
| 2.2      | Kontrollerade 'haveri'-försök för utvärdering av instrumentering   | 20        |
| 2.3      | Vanligt förekommande fel på instrumentering                        | 21        |
| <b>3</b> | <b>Maskininlärningsbaserad tillståndsovervakning av dammar</b>     | <b>22</b> |
| 3.1      | Modellering för att förutsäga miljövariationer                     | 22        |
| 3.1.1    | Modelltyper                                                        | 23        |
| 3.2      | HST (Hydrostatic Season Time)-modellen                             | 25        |
| 3.3      | Andra linjära modeller för dammsäkerhet                            | 28        |
| 3.4      | Ickelinjära datadrivna modeller                                    | 28        |
| 3.4.1    | Ickelinjära stationära modeller                                    | 29        |
| 3.4.2    | Ickelinjära autoregressiva modeller                                | 30        |
| 3.4.3    | Beslutsträd och supportvektorregression                            | 31        |
| 3.4.4    | Jämförelser av linjära och icke-linjära modeller                   | 31        |
| 3.5      | Rapporterade övervakningssystem                                    | 31        |
| 3.6      | Datadrivna tekniker för dammövervakning                            | 33        |
| <b>4</b> | <b>Analysmetoder</b>                                               | <b>36</b> |
| 4.1      | Enklare ordinär och robust (icke-parametrisk) statistik            | 36        |
| 4.1.1    | Beskrivande statistik                                              | 36        |
| 4.1.2    | Robusta statistiska tester                                         | 38        |
| 4.1.3    | Korrelation                                                        | 40        |
| 4.1.4    | Drift i tidserier                                                  | 40        |
| 4.2      | Principalkomponentanalys, PCA                                      | 40        |
| 4.3      | Klassificering                                                     | 45        |
| 4.3.1    | KNN                                                                | 45        |
| 4.3.2    | SIMCA                                                              | 46        |
| 4.3.3    | Beslutsträd                                                        | 46        |



|       |                                              |           |
|-------|----------------------------------------------|-----------|
| 4.4   | Regression                                   | 46        |
| 4.4.1 | Förbehandling och transformationer           | 47        |
| 4.4.2 | Univariat linjär regression                  | 47        |
| 4.4.3 | Multipel linjär regression, MLR              | 48        |
| 4.4.4 | Partial Least Squares regression, PLS        | 49        |
| 4.4.5 | Gaussisk process regression, GPR             | 51        |
| 4.4.6 | Supportvektorregression                      | 53        |
| 4.4.7 | Neurala Nätverk                              | 53        |
| 4.5   | Tidseriemodeller – linjära och icke linjära  | 54        |
| 4.6   | Statistisk Processkontroll, SPC              | 58        |
| 4.6.1 | Multivariat Statistisk processkontroll, MSPC | 60        |
| 5     | <b>Rekommendationer</b>                      | <b>61</b> |
| 6     | <b>Referenser</b>                            | <b>64</b> |

# 1 Inledning

Säker och tillförlitlig elproduktion från svenska vattenkraftverk är avgörande för Sveriges omställning till klimatneutral energiproduktion. Pågående klimatiförändringar resulterar i ökande variationer i nederbörd, grundvattennivåer, temperaturer och därmed vattenstånden i magasinerna. Detta i sin tur innebär ökande påfrestningar på den infrastruktur som kraftverken och dammkonstruktionerna utgör. Det är också troligt att flera av klimatiförändringens effekter ännu är okända, vilket även gör det svårt att förutse hur specifikt dammsäkerheten påverkas.

Övervakning av tillståndet hos en vattenkraftsdamm med hjälp av olika givare är ett etablerat sätt att öka säkerheten i vattenkraften. Denna rapport handlar främst om hur mätvärden från dessa givare kan användas tillsammans med modern digital teknik och algoritmer för att ytterligare öka säkerheten.

## 1.1 DAMMSÄKERHET OCH DAMMAR

Vattenkraftverksamhet och dammsäkerhet styrs av olika lagar, förordningar, föreskrifter och riktlinjer. Här ingår bl.a. Miljöbalken (1998:808) med tillhörande förordningar om dammsäkerhet och verksamhetsutövarens egenkontroll. Dammägare är skyldiga att följa bl.a. dessa regelverk, med syfte att så långt det är rimligt undvika dammhaveri med efterföljande negativa verkningar på samhälle och miljö.

Samhällets förväntningar och allmänhetens acceptans påverkar hur vattenkraftverksamheten bedrivs. Det är av största vikt att säkerhet prioriteras. Energiföretagen Sverige verkar för god dammsäkerhet hos medlemsföretagen genom att ge ut Energiföretagens riktlinjer för dammsäkerhet, RIDAS. Riktlinjerna utgör grund för dammsäkerhetsarbete enligt god praxis för medlemsföretagen vad gäller arbetsmetoder och tekniklösningar (RIDAS 2019).

Dammätningar görs med syfte att följa och utvärdera eventuella förändringar och ge underlag för en långsiktig bedömning av anläggningens tillstånd. Detta ger ett bra underlag för att på lång sikt bedöma dammkonstruktionens behov av eventuella åtgärder. Installerad mätutrustning ska även ge indikationer för styrning av drift där även varnings- och larmfunktioner ska ingå.

För att övervaka dammarna mäts en rad storheter vilka i flera fall har både varnings- och larmgränser definierade. Dock saknas det i många fall en tillräckligt lång och kvalitetsmässigt god dataserie för att bestämma nivåerna för varning och larm. Med tanke på den stora mängden mätdata som hela tiden flödar in till driftcentralens Scadasystem och databaser är det inte enkelt att övervaka dammarna optimalt. Avvikande mätvärden kan grovt klassificeras i två klasser; de som beror av dammens tillstånd eller i viss mån väderförhållanden, respektive de värden som avviker på grund av att givare rapporterar felaktigt värde eller där signalkedjan från givaren är på något sätt är störd.

Hur man tolkar den information som mätarna, givarna, sensorerna levererar beror på vilken typ av dammkonstruktion det är och dess lokala förutsättningar. Framförallt är det viktigt att bedöma vilka förändringar som är "normala" och vilka som är avvikande. Det är problematiskt när rena mätfel (exempelvis felaktigt placerade eller trasiga givare) ger upphov till avvikande förändringar i mätdata och detta i sin tur påverkar bedömningen av dammens tillstånd. Idag görs denna bedömning erfarenhetsmässigt men den ökande mängden mätdata, effekter från pågående klimatförändring, ändrade regleringsförhållanden med mera gör bedömningen allt svårare men även allt mer kritisk.

De effekter som uppkommer vid en omställning till en mer klimatneutral energiproduktion vet vi redan idag kommer att påverka kraftverksägarnas regleringsstrategier t ex att parera ökad vindkraftsproduktion med högre inslag av korttidsreglering. Detta i sin tur innebär mer slitage på avbördningsanordningar men även på de dämmande konstruktionerna.

De pågående klimatförändringarna kommer att påverka våra reglerade vattendrag på olika sätt genom förändrade flödesförhållanden. Det är också troligt att flera av klimatförändringens effekter ännu är okända, vilket gör det svårt att förutse hur dammsäkerheten påverkas.

Samtidigt som utmaningarna ökar med att övervaka, mäta och tolka data från dammar ökar även möjligheterna att samla in mycket data och automatiskt bearbeta dessa med olika algoritmer och modeller. Med den pågående digitaliseringen är metoder såsom multivariat dataanalys och maskininlärning (Machine learning) kraftfulla verktyg. En svårighet är att ett ökat antal mätare eller givare riskerar att minska överskådligheten som helhet; även här kan maskininlärningsmetoderna hjälpa till att öka överskådligheten. Metoderna har varit framgångsrika i flera olika industrier och det är oklart hur mycket kraftbolagen kan förbättra tillståndsbedömning och dammövervakning med hjälp av dessa.

Innehållet i rapporten kan bidra genom att sammanställa kunskap för en bättre och effektivare tillståndsbedömning av dammar genom att använda datadrivna metoder för att detektera avvikande mätvärden som kan bero på: 1) felaktiga mätvärden eller felinstallerade sensorer; 2) kritiska förändringar i dammkonstruktionen; 3) naturliga flödesvariationer i hydrogeologin.

Hur kan man på ett bra sätt fånga dessa tre olika företeelser?

- I det första fallet (1) skulle man kunna använda metoder som antingen detekterar att signalen får en plötslig ändring, glidande förändring (svårt då omgivningen kan driva samtidigt) eller så kan man använda andra givarsignaler för att bygga modeller för att beräkna ett värde för den aktuella givaren.
- I det andra fallet (2) handlar det om att ta fram smarta metoder som detekterar både ändringen av helheten från alla givare på dammen samt även detektera när enskilda sensorsignaler sticker ut. Kravet på ett sådant system är det ska ge ett larm tidigt och helst med så få falsklarm som möjligt men absolut inte på bekostnad att av fånga de allvarliga om än långsamt krypande förändringarna.

- I det tredje fallet (3) är det att genom att samla in data och göra modeller från befintliga datakällor som exempelvis SMHI-väderprognoser eller utfall samt med egna mätstationer fånga upp när väderförhållanden kommer få en stor påverkan på hydrogeologin.

En annan viktig aspekt kring detta är att se hur människor arbetar med frågan på akutbasis, på daglig basis och på långsiktig basis i ett system. Den andra viktiga faktorn är hur utbildningsnivå och motivation påverkar olika kategorier av medarbetare till att utföra denna typ av arbete. Det är därför viktigt att ha med alla medarbetarkategorier när man utformar system, testar system och driftsätter system. Efter att systemet är driftsatt sker en kontinuerlig uppföljning där eventuella brister identifieras och åtgärdas. En annan sak som behövs är återkommande utbildning om systemet.

## 1.2 GOD DATAHANTERING

God datahantering börjar med god ordning på de givare man installerat. Detta kan innefatta många saker som t ex dokumentation om var givaren är installerad, givartyp, mätområde, när den har kalibrerats, kalibrerat ingångskort eller logger. Man behöver även ha dokumenterat eventuella program för medelvärdesbildning i dataloggrar, PLC eller Scada. Man ska också ha klart för sig hur signaler sparas i långtidsdatabas och om det sker någon komprimering (exempelvis dödbandsfiltering) av data, se t ex Thornhill et al., (2004).

Det senare är något att se upp med eftersom det kan ge invertering av korrelationer mellan variabler, så i stället för en positiv korrelation så kan man i värsta fall få en negativ korrelation. Det kan speciellt hända då man har en reglerloop där utsignalen ändras automatisk för att parera det värde man önskar hålla konstant. IVL använder i sin stora försöksanläggning ingen dödbandsfiltering på signaler utan sparar data som en minutsmedelvärden, detta har man valt för att minimera risken för att datakvaliteten påverkas negativt. Många av de idag använda komprimeringsmetoderna lever kvar sedan senare delen av 1900-talet, då datalagring var dyrt.

Man kan enkelt samla uppgifterna om givarna ovan i ett Excelblad med en rad per givare och olika informationsfält. Detta skulle man kunna säga är en slags meritförteckning eller CV för varje signal.

När man tar utdrag från en långtidsdatabas är det bra om man alltid spara undan en kopia man inte kommer att jobba med för säkerhets skull. Även att ha ordentliga backuper på sina databaser är av vikt. Både rådata och bearbetade data bör sparas i databaser. Rådata skall sparas med skrivskydd så att de inte kan skrivas över. Om det inte finns möjlighet att spara både rå- och bearbetade data ska man välja att spara rådata. Då ska även tydliga beräkningsformler för bearbetning av data finnas dokumenterade, så att bearbetade data kan återskapas från rådata.

Det kan vara praktiskt svårt att verifiera alla steg i mätkedjan, då medvetna ändringar i mjukvara kan göras på många olika platser längs kedjan.

Detta för att hålla systemen uppdaterade av t ex säkerhetsskäl. Detta gör det än viktigare att verifiera mätkedjan med jämna mellanrum.

### 1.3 FALLGROPAR VID DATAANALYS

I de flesta industrier idag finns det stora mängder historiska data, samtidigt som flödet av tillkommande data ständigt ökar. Insikten om att dessa data är en användbar tillgång har kommit starkt det senaste fem åren. Tillgången har fått ett namn, "Big Data", och exploderat som ett eget kunskapsområde med en mängd konferenser, seminarier, kurser och "lätthanvända" verktyg.

I princip är det tre typer av data vi har att göra med:

- Tidseriedata, som typiskt är data från olika givare, insamlade med konstant tidsmellanrum, vanligen ett värde per minut eller snabbare.
- Laboratedata och manuella observationer, som är analysresultat av prover tagna vid olika punkter och tillfällen längs processen.
- Händelsedata, som är listor med tidpunkter då olika händelser inträffat, t.ex. ankomsttider eller larmtider.

Generellt kan man nog säga att arbetet med att modellera utifrån historiska data till 80 % utgörs av datatvätt, såsom validering och filtrering av data. Går inte den tiden åt för detta, skall man vara misstänksam!

Vi identifierade i ett tidigare projekt sex olika fallgropar vid dataanalys, se A. Björket al., (2016). Här har vi gått ett steg vidare och föreslår motmedel mot att hamna i en specifik fallgrop.

Den första fällan är att man tror att data är korrekta. Det är de sällan - här lurar bl.a. givarfel, samplingsfel, provtagningsfel och bortfall.

*Motmedel: Inventera vilka givare som finns och vilka feltillstånd som är aktuella. Plotta data och räkna bortfall av datapunkter. Karaktärisera och identifiera "enkla" feltillstånd. Ta reda på förväntade intervall och undersök data som ligger utanför intervallen. För att säkerställa manuell provtagning och laboratorieanalyser kan man göra upprepade blindtester. Analysera hur snabba förändringar man behöver kunna uppfatta och välj samplingsfrekvens efter detta.*

Den andra fällan är att korrelationssamband i data, t.ex. mellan processdata och kvalitetsdata, sällan kan etableras som orsakssamband. Oftast finns det dolda underliggande faktorer som man inte kommer åt och som orsakar stor del av de registrerade variationerna.

*Motmedel: Skriv ner tänkbara fysikaliska samband mellan olika typer av mätningar. Plotta samband för att verifiera. Verifiera än hellre tänkta orsakssamband genom kontrollerade försök, om möjligt. Verifiera att förändringar i orsaksvariabeln inträffar "före" motsvarande förändringar i utfallsvariabeln. Identifiera linjära samband med hjälp av korskorrelationer.*

Den tredje fällan är att man använder analysmetoder som bygger på statistiska förutsättningar som inte är uppfyllda i data, t.ex. att data skall vara normalfördelade, att de inte får vara korrelerade. Risken ökar ju mer lätthanvända dessa verktyg är.

*Motmedel: Plotta fördelningar av data och verifiera att antaganden håller. Många metoder förutsätter att data är normalfördelade, vilket de sällan är. Om fördelningen är annan kan en lösning vara att transformera data. Ett exempel är att vanlig linjär regression utgår ifrån att orsaksvariabeln ( $x$ ) är felfri och normalfördelad. Ett annat är att multipel linjär regression kräver oberoende orsaksvariabler, vilket man kan komma runt genom att använda andra regressionsmetoder som t ex Projektion till Latent Strukturer, PLS. Analysera korskorrelationer.*

Den fjärde fällan är att man använder data från perioder då processen har legat helt fel eller varit under omställning.

*Motmedel: Alla modeller har en giltighetsdomän. Det kan bland vara motiverat att titta just på perioder då man kört processen i onormala lägen, men risken ligger i om man använder modellen för normala driftpunkter och bara byggt den på ett onormalt läge så är den inte tillräckligt generell.*

Den femte fällan är att man inte beaktar interaktioner och olinjäriteter, som i någon mån alltid är närvarande.

*Motmedel: Samla ihop fysikalisk kunskap och leta olinjäriteter. Studera residualer – dvs leta efter systematiska variationer i det som modellen inte innefattar. Använd vid behov modeller där man kan bygga in olinjäriteter.*

Den sjätte fällan är att data inte har tillräcklig spridning.

*Motmedel: Viktigt att fånga data vid driftsättning, underhållsstopp mm*

Vi hoppas att kombinationen av vilka fallgropar som kan förekomma och föreslagna motmedel kan vara en hjälp för att genomföra ett gott arbete med dataanalys och modellbaserade feldetektionsmetoder.

## 1.4 GOD MODELLERINGSPRAKTIK


Så nu funderar du/ni på att göra ett projekt för att implementera förbättrade datadrivna metoder för att förbättra övervakningen av dammsäkerheten. Vilka viktiga saker bör man göra enligt vår mening? Denna lista kan säkert göras mer komplett men är ändå någon slags vägvisare.

1. Definiera målsättningen och omfattningen med projektet.  
Börja smått men tänk på hur det går att skala upp andra anläggningar eller till och med dela med sig av erfarenhet inom branschen.
2. Fundera på vilken egen kompetens som ni har i organisationen och vilka delar där andra kan bidra med erfarenhet såväl som nya idéer.
3. Skapa en projektgrupp som med medarbetare med olika roller och vid behov externa, det underlättar, säkerställer kvaliteten och användbarheten av det som utvecklas och ska användas.
4. Tänk på hela kedjan från sensor till användbart resultat, larm och visualisering av resultat.  
Skräp in är ofta skräp ut som resultat från modell. Det krävs vidare alltid någon slags integration mellan långtidsdatabas och modelleringsverktyg.
5. Dokumentera antingen genom kod eller genom loggbok hur arbetet med utveckling av en datadriven anpassad metod fortskrider för just er.

6. Validera alla modeller på ett noggrant sätt och för uppgiften anpassat sätt.
7. Tilltro till denna typ av system är väldigt viktigt, det kan vara svårt att återfå förtroende för något som fungerat dåligt till en början.
8. Rulla ut resultat stegvis. Som nämns i 5 så är tilltro viktigt. Det är därför viktigt att begränsa vilka som har tillgång till resultat innan man provdriftat dem speciellt om det är en ny metod. Så håll förslagsvis modellresultat/larm i provdrift 6–12 månader inom projektgruppen innan man släpper det till full användning.
9. Kommunicera inom organisation om arbetet, när arbetet har gått inom olika steg.

Validering av modeller är något som är mycket viktigt för att man ska kunna fånga upp om en modell är överanpassad eller underanpassad. Ju mer flexibel en modell och metod för att anpassa modellen till tillgängliga data ju större risk är det för överanpassning. Man vill ju inte heller underanpassa modellerna så att man inte fångar viktiga förändringar, speciellt inte i så kritiskt system som dammsäkerhet systemen kan vara. När vi pratar om validering mot data finns det egentligen tre sätt att göra det på, se Figur 1.

- Interna tal på hur väl en modell funkar på det tränings- eller kalibreringsdata man använder (Internal Validation).
- Ett separat dataset för testning (Test Set Validation) som man beräknar hur väl modellen passar till data, när man bestämt slutligen hur modellen ska se och hur komplex den ska vara.
- Ett mellanting för detta är man delar upp datasetet man bygger/tränar modellen på i mindre delar och tar bort en del och bygger modell, testar på den och upprepar det tills alla tidpunkter data eller segment över olika tidsperioder använts (Cross Validation).



Figur 1 Olika typer av angreppssätt för validering av modeller mot olika datamängder. Bild från Anders Björk, (2007).



Noterbart är här att nyttjandet av alla data man insamlat kanske inte är det optimala, detta eftersom att tidserier alltid är korrelerade och med för många datapunkter som ligger för nära varandra i tiden finns en risk att bygga in spökkorrelationer.

Så välj lagom långt intervall mellan datapunkter och välj längre tidsperioder som plockas ut om man använder korsvalidering (Crossvalidation), s.k. segmenterad korsvalidering.

Vi utrullning av modeller rekommenderar vi att man testar hela system med gamla data och säkerställer att man får värden som inte avviker nämnvärt från det man fick när man lärde upp modellerna.


## 1.5 AVVIKELSEDETEKTION

Vi väljer här att börja diskussionen med avvikelседetektion i stället för detektion av fel eller fara. En svårighet är att för dammsäkerhet, såväl som underhåll av andra komplexa anläggningar och maskiner att man inte har råd eller där det inte är praktiskt möjligt att orsaka ett fel. Speciellt inom detta område så är ju de fel eller incidenter vi verkligen vill skydda oss emot helt omöjliga att utföra test kring i en verklig anläggning.

Näst bäst är att lära av mindre riktade försök (vilket vi tar upp i 2.2 Kontrollerade 'haveri'-försök för utvärdering av instrumentering), men problemet här är hur överförbara är dessa kunskaper till en större anläggning och hur implementera vi dessa lärdomar i damm övervakningssystemet.


Det 3:e bästa blir att utgå från det normala tillståndet i data och dess variation, och sätta gränser för vad som är normalt och vad som är en avvikelse. Man kan även använda en modell för att förutsäga vad en sensor borde visa för värde och jämföra med det verkliga värdet. Man får då sätta en gräns för hur stor skillnad man tillåter mellan dessa två signaler (den verkliga och den skattade). Det finns även andra avvikelser som är mer av datainsamlings- eller mättekniskkaraktär, mer om detta nedan.

I Figur 2 visas från vänster till höger olika typer av förekommande givarfel (där den sanna signalen är i grått och den felaktiga i lila). Först visas hur givare driver dvs signalen påverkas åt ett håll övertiden (Drift). Sedan följer en signal som har konstant skillnad mellan vad den borde visa och vad den visar (Bias). Därefter följer exemplet på bortfall av signal, dvs vi har inget värde på signalen sparat vid tidpunkten, ses som en lucka på den lila linjen (Missing data). Efter detta följer ett exempel på en signal som fryser dvs antar ett konstant värde en tid, syns som rät lilalinije under en tidsperiod (Constant values). Slutligen visas en signal som skalats fel dvs visar mer alternativt mindre konsistent än signalen borde visa (Incorrect scaling).



Figur 2 Vanligt förekommande givarfel och mätinsamlingsfel I. Bild från O. Samuelsson, (2017).

Vidare i Figur 3 från vänster till höger (där den sanna signalen är i grått och de felaktiga i lila) återigen olika vanligt förekommande fel. Först så visas en givare vars signal är utanför mätområdet aningen för givaren eller hos det mottagande datainsamlingssystemet (Out of range). Därefter följer avvikande värden, här kanske sporadiskt starkt slumpmässigt brus som överlagrar signalen (Outliers). Sedan visas ett exempel där brusnivå ökar (Increased noise) och slutligen visas ett exempel där givarens tidskonstanter och signalskala är påverkad (Change in autocorrelation).



Figur 3 Vanligt förekommande givarfel och mätinsamlingsfel II, Bild från O. Samuelsson, (2017).

I ICOLDs bulletin om dammövervakning används termerna larm och varning, där ett larm (alarm) är kopplat till ett farligt beteende och varning (alert) till ett oförväntat beteende, se *Dam surveillance guide. ICOLD Bulletin 158.*, (2018). I denna rapport används begreppen detektion och avvikande beteende för både larm och varningar.

Ett larm innebär en akut fara för dammen och innebär att omedelbara åtgärder måste sättas in. En varning innebär en misstanke om skada och måste inte hanteras lika skyndsamt.

Enligt Hellgren et al., (2019) är larmvärden "oftast kopplade till stora förändringar i globala mätinstrument, exempelvis plötsliga och stora förändringar i mätare som mäter rörelsen mellan damm-berg eller porttryck". **Dessa plötsliga förändringar behöver inte komma från dammen utan kan vara sensorfel.** Därför är det viktigt att kunna skilja på avvikande beteende orsakat av förändringar i dammen och sådant beteende som orsakas av sensorfel.

Venkatasubramanian et al., (2003) ger tio kriterier som en processfel-detektionsmetod bör uppfylla. Anpassade till dammövervakningsmetoder blir dessa:

1. Snabb detektion och diagnos av avvikelser. Men snabb detektionsförmåga ger bruskänslighet, och vi har en avvägning mellan robusthet och detektionsprestanda.
2. Isolerbarhet, vilket betyder systemets förmåga att skilja mellan olika typer av fel. Hög isolerbarhet riskerar att leda till många falsklarm orsakade av osäkerheter i modelleringen.
3. Robusthet. En robust metod flaggar inte brus och modellosäkerheter som avvikelser. Men om kraven på robusthet ställs för högt minskar förmågan att flagga verkliga avvikelser.
4. Förmåga att identifiera nya fel. Man har sällan data som täcker alla möjliga feltyper. Därför är det viktigt att systemet kan detektera och identifiera nya fel.
5. Konfidensuppskattningar. Det är lättare för en användare att få förtroende för ett feldetektionssystem om det anger rättvisande konfidensintervall, t ex för risken att ett visst mätvärde motsvarar ett fel eller för konfidensen i en viss feldetektion.
6. Anpassningsbarhet. Processer och system är sällan stationära, utan utvecklas och förändras med tiden. Anpassningsbarhet är metodens förmåga att anpassa sig till dessa förändringar med bibehållen prestanda.
7. Orsaksanalys. Metoden kan förutom att detektera fel säga något om orsaken bakom felen.
8. Arbetsinsats vid driftsättning av metod. För största användbarhet bör det gå lätt och smidigt att ta metoden i drift.
9. Datalagrings- och beräkningskrav. En metod som behöver lagra en mindre mängd data och kräver få och/eller snabbt exekverbara beräkningar är att föredra framför en metod med stora datalagringskrav och stort beräkningsbehov. Men mer avancerade metoder kan ha förmåga att framgångsrikt detektera fel i svårare omständigheter, varför lagrings- och beräkningsbördan måste avvägas mot prestanda.
10. Förmåga att detektera och identifiera flera simultana fel. Detta är inte så lätt som det kan låta eftersom fel ofta interagerar.

Vi ser att flera av dessa kriterier står i motsatsförhållande till varandra. Insikten att man kommer att behöva göra avväganden mellan olika önskvärda aspekter är viktig att ta med sig in i en utveckling av ett datadrivet dammövervakningssystem.

## 2 Instrumentering för tillståndsovervakning på svenska dammar

### 2.1 INSTRUMENTERING FÖR DAMMSÄKERHET

Detta avsnitt baseras till största delen på tre Energiforsk-rapporter som kom ut under första halvan av 2019. Sjödahl et al., (2019) diskuterar möjlig geofysisk instrumentering för dammsäkerhet och vad som är lämpligt för svenska förhållanden. Rapporten fokuserar på fyllningsdamm. Hellgren et al., (2019) diskuterar instrumentering och metoder för övervakning av betongdamm. Mohlin & Åström, (2019) diskuterar de brister och problem hos instrumenteringsinstallationer som kan uppstå från projektering fram till drift och underhåll, samt behovet av kunskapsökningar. Även ICOLD bulletin 158 presenterar en detaljerad genomgång av instrumentering, mätförfaranden och analys, se *Dam surveillance guide. ICOLD Bulletin 158.*, (2018). Ytterligare diskussion om rekommenderar instrumentering och användning av givare återfinns i *Dam safety performance monitoring and data management – best practice*, (2014).

Hellgren et al., (2019) ger i kapitel 3 en detaljerad genomgång av instrumentering för betongdamm och mätdatainsamling. Läsaren hänvisas dit för mer information om sensorer för betongdamm; denna rapport fokuserar på sensorer för fyllningsdamm. Författarna ger dock en mycket viktig slutsats som vi vill upprepa här, nämligen att det inte räcker att mäta faktorer som kan indikera skada på dammen. Man bör även mäta faktorer som påverkar dammen, såsom temperatur och hydrostatiskt tryck.

Sjödahl et al., (2019) går igenom olika typer av dammhaverier för fyllningsdamm och finner att överströmning och inre erosion är de dominerande orsakerna. Man fokuserar på inre erosion och beskriver fyra initieringsmekanismer för detta och hur det sedan utvecklas. Av de generella slutsatser som dras är följande särskilt viktiga att nämna här:

- Inre erosion är ett komplext fenomen och dess initiering och utveckling kan variera stort mellan olika dammar.
- Vissa nyckelparametrar, t ex porositeten i materialet och även permeabiliteten, ökar alltid.
- Processerna börjar i liten skala och utvecklas successivt. Det är svårare att detektera denna typ av förändring än en mer plötslig händelse, men samtidigt är det viktigt att detektera en förändring så tidigt som möjligt.
- Det är svårt att förutse var inre erosion kommer att uppkomma. Hela dammen behöver därför övervakas.

Inre erosion påverkar porositeten, och detta i sin tur leder till "minskad densitet, ökat läckageflöde, ökad permeabilitet, påverkan på temperaturen, minskad seismisk gånghastighet, påverkan på dielektricitetskonstanten, påverkan på resistiviteten mm", Sjödahl et al., (2019).

Författarna refererar till egna tidigare arbeten, där de visat att de parametrar som är relaterade till läckageflöde eller förändringar däri är mer känsliga än de som är relaterade till materialegenskaper och materialförändringar.

Exempel på den förstnämnda kategorin är läckage och porositet men även temperatur och permeabilitet, medan i den andra kategorin ingår t ex densitet och dielektricitetskonstant.

Nilsson, (2014) är en summering av slutrapporten från projektet "Dam safety performance monitoring and data management – best practices" som genomfördes inom Dam Safety Interest Group (DSIG). Den diskuterar instrumentering och övervakning av dammar, och anger att övervakning med hjälp av givare som avläses automatiskt bör användas åtminstone för dammar av klass 1 och 1+ enligt RIDAS 2019 (stora konsekvenser vid dammhaveri). Dessa givare ska kunna varna för utvalda och relevanta dammhaverisförlopp. För dammar i klass 2 enligt RIDAS 2019 (mellanstora konsekvenser vid dammbrott) räcker det med givare som kan avläsas manuellt.

Vad gäller instrumentering rekommenderar Nilsson, (2014) åtminstone **porttrycksmätning** i nedströmsfilter, stödfyllning och grundläggning, mätning av **magasinsnivån**, **läckagemätning**, och mätning av **deformation** av punkter längs dammkronet i både plan och nivå. Hellgren et al., (2019) framhåller det hydrostatiska trycket som en viktig mätfaktor. Metoden är vanlig förekommande i fyllningsdammar där grundvattenrör borras ner i kärnan på dammen varpå grundvattennivån monitoreras med dränkbara tryckgivare.

Även *Dam surveillance guide. ICOLD Bulletin 158.*, (2018) rekommenderar mätning av **porttryck**. Porttrycket mäts ofta i **grundvattenrör**, som är vanliga på svenska dammar. Vidare säger denna rapport att **läckagemätning** är en grundläggande och nödvändig del i dammövervakning och ska ses som obligatoriskt för god dammsäkerhet (*Dam surveillance guide. ICOLD Bulletin 158.*, (2018)). Enligt samma källa är det lämpligt att mäta turbiditeten i läckagevattnet, eftersom hög turbiditet kan indikera erosion.

Sjödahl et al., (2019) ger även en översikt över olika geofysiska mätmetoder för dammsäkerhet. Rapporten tar alltså bara upp sensorer av geofysisk karaktär, vilka inte innefattar geotekniska och geodetiska metoder, och inte heller läckagemätning eller porttrycksmätning. De bedömer också lämpligheten för användning för dammsäkerhet i Sverige idag och med framtida utveckling.

**Temperaturmätning** med optisk fiber används kontinuerligt eller regelbundet på ett stort antal svenska dammar. Med sådan mätning kan man hitta zoner med avvikande vattenströmning och i många fall ge en god uppskattning av läckageflödet genom dammen. Fibern placeras typiskt längs dränet eller i vattenståndsrör. Kablage med flertalet temperaturnoder används även vanligtvis i vattenståndsrören för mätning av vertikal temperaturprofil. Internationellt har även en aktiv metod där man tillför värme och mäter temperaturresponsen använts. Värmekamera kan vara lämplig för att mäta temperaturfördelning och på så sätt hitta utströmningsområden, men bedöms endast vara relevant för låga invallningsdammar. Totalt sett bedöms temperaturmätning vara utmärkt lämplig. Samtidigt

är det viktigt för datadriven övervakning att data görs tillgängliga i realtid och sänds till central analyspunkt.

**Elektriska mätningar** bygger på galvanisk mätning av elektriska potentialer vid likström eller mycket lågfrekvent växelström (upp till 20 Hz).

Självpotential-metoden är en passiv metod som mäter naturligt alstrade potentialer. Resistivitetsmetoden och inducerad polarisation (IP) är aktiva metoder som mäter de elektriska potentialerna som uppkommer då man sänder en ström genom marken. Resistivitetsövervakning sker idag på ett fåtal svenska dammar. Metoden kräver beräkningar s.k. inversion för att få fram en modell över resistivitätsfördelning i dammen. Inversion kan göras automatiskt men det görs inte idag. Istället beräknas resistivitet från mätdata någon gång om året.

De elektriska metoderna bedöms vara lämpliga för svenska förhållanden, både för sporadisk inspektion och kontinuerlig övervakning. De kan störas av elektriska fält från ledningar, men detta är sällan ett problem. Ledande objekt i kontakt med marken kan dock störa. Dessa elektriska metoder kräver också stor kompetens i analys och tolkning av resultaten, vilket ställer mycket stora krav på utbildning av personal eller inhyrning av externa experter.

**Seismiska och akustiska mätningar** studerar elastiska vågors utbredning i mark och utbredningsegenskapernas förändringar i tiden. I refraktions- och reflektionsseismik krävs att vågor alstras på något sätt t ex med slägga. Dessa metoder är mindre lämpliga för kontinuerlig övervakning. Läckljudsmätning bedöms dock ha bra potential för användning i Sverige, även för kontinuerlig övervakning. En fråga är dock på vilket avstånd från en läcka som ljudet av den kan detekteras. Detta besvaras inte av Sjödahl et al.

Metoder som bedöms som mindre lämpliga för kontinuerlig övervakning är georadar, induktiva elektromagnetiska metoder, magnetiska metoder och gravimetriska metoder.

**Geodetiska metoder** mäter deformation och är viktiga eftersom mätresultaten kopplar tydligt och direkt till skadlig påverkan på dammen. Det finns flera sätt att mäta deformation. Vi lutar oss här mot Scaioni et al., (2018). De delar in dessa mätmetoder i sådana som mäter position eller rörelse i specifika punkter och sådana som ger resultat över ett område.

Bland punktmetoderna finns optiska kollimatorer, vilka kan mäta horisontell deformation med millimeterprecision. Det finns automatiska kollimatorer som används för övervakning av flera dammar i utlandet. Geodetiska kontrollnätverk och optiska nivåmätare mäter horisontella respektive vertikala positioner hos kontrollpunkter och kan också automatiseras med mätintervall ner till ca 10 minuter. Man kan också använda Global Navigation Satellite System (GNSS) och om man kalibrerar och korregerar i flera steg kan man uppnå en tredimensionell karta över kontrollpunkters läge i tre dimensioner med subcentimeterprecision. En liknande metod baserad på landbaserad radiofrekvenssändare kan uppnå liknande precision och har även den demonstrerats på dammar.

Bland de områdesskannande metoderna finns marklaserskanning, vilken ger en 3D-karta. Metoden lider av brus och svårigheter att kalibrera, men kan potentiellt ge millimeterupplösning och man lyckas relatera alla mätpunkter i en karta till motsvarande punkter i en annan karta. Markbaserad syntetisk aperturradar kan potentiellt erbjuda ännu bättre upplösning, men den kan bara mäta deformationer längs siktlinjen och ställer höga krav på bl. a koherens. Den har ännu inte använts för att mäta dammdeformationer, kanske också på grund av systemets höga kostnad. Slutligen kan man använda satellitburen interferometrisk radar. På grund av att de bärande satelliterna flyger förbi en given damm med ett intervall av några dagar duger denna metod inte för att snabbt detektera problem. Mycket forskning ägnas dock åt att illustrera dess duglighet för att mäta dammdeformationer över längre tid, vilket man har lyckats få centimeterprecision i. De satellitburna mätningarna har den unika fördelen att ingen utrustning på marken krävs.

## 2.2 KONTROLLERADE 'HAVERI'-FÖRSÖK FÖR UTVÄRDERING AV INSTRUMENTERING

Kontrollerade felmodsförsök har utförts bland annat i Nederländerna och i Rössvatn, Norge. Detta beskrivs i mer detalj i Sjødahl et al., (2019). Det visade sig att temperaturmätningar är viktiga i sammanhanget.

I holländska Ijkdijk har ett antal dammhaveriförsök genomförts. Under 2009 utfördes fyra försök på 3,5 m höga dammar där brottmekanismen var inre erosion (piping) i undergrunden. Man hade mycket god instrumentering av olika slag vid dessa försök. Temperaturmätningar visade områden med förändringar och hur de utvecklades i tiden.

I den norska dammförsöksanläggningen i Rössvatn har flera dammsäkerhetstester genomförts. Johansson S., (2005) beskriver ett blindtest där olika metoder försökte detektera och lokalisera inbyggda defekter. De mätmetoder som testades var temperatur, självpotential och resistivitet. Temperatursensorer placerades längs dammtån med ca 1,5 m mellanrum. Med en samplingstid av 5 minuter syntes tydliga avvikande värden för samtliga defekter. Resultaten visade att temperaturmätning är en effektiv metod som upptäckte samtliga fyra skador.

Resistivitetsmätningen detekterade tre skador, och SP-mätningarna endast en av skadorna. Temperaturmätningarnas framgång talar för att installera optisk fiber i dammtån, till exempel i samband med anläggande av stödbankar i dammsäkerhetshöjande projekt, är en effektiv övervakningsåtgärd. En lärdom för resistivitetsmätningen är att upprepade mätningar är viktiga för att kunna hitta skador. Förhållandena var gynnsamma för resistivitetsmätningar. Självpotentialmetoden bedömdes vara känslig för störningar.

Även försök i Tyskland på 1980-talet indikerade att temperaturmätning är lämplig för detektion av läckage i dammar. Självpotential utvärderades också och fanns delvis lämplig.



### 2.3 VANLIGT FÖREKOMMANDE FEL PÅ INSTRUMENTERING

Mohlin & Åström, (2019) belyser flertalet brister i utförandet från projektör, beställare och entreprenör samt hos driften/underhåll av damminstrumenteringen. En viktig åtgärd som klarläggs är behovet av att stärka kunskaperna i flertalet områden för hela damsäkerhetsarbetet.

Höga krav ställs på driftsäkerhet och tillförlitlighet hos damminstrumentering men tidvis kan fel uppstå som t ex att en givare går sönder. Ett tydligt tecken på fel är att mätsignalen eller matningen driver signifikant ifrån det giltiga området. Felet ligger då ofta på kretskortsnivå i områdena där givaren har galvanisk förbindning med omgivning, t ex via kablage. Orsaken till givarfelet har ofta en mycket komplex natur som är svår att på förhand prediktera innan det är ett faktum.

Det finns avgörande systemtekniska designlösningar som kan implementeras på en damminstrumentering för att störsäkra och på så sätt stärka driftsäkerheten signifikant med avseende på komponenters livslängd och tillförlitlighet. Litteratur om "störningsfri elektronik", bl.a. Benda, (1996), tar upp anläggningskonstruktion och apparatkonstruktion med vikt på avstörningsregler, jordning, potential-utjämning, skärmning, överspänningsskydd samt behandling kring signalöverföring och störkällor. Det finns således en viktig designfilosofi vid konstruktion av den här typen mätapplikation och säkerhetssystem. Detta med hänvisning till Mohlin & Åström, (2019) är ett bra kunskapslyft för att åtgärda systemtekniska brister i damminstrumenteringen.

Damminstrumenteringen, inkl. dammövervakningssystem, konstrueras som ett industriellt system för autonom drift med förväntad livslängd på 10+ år, och skall kontinuerligt logga flertalet mätvärden till databas samt kunna larma till överordnade system vid kritiska mätvärden eller fel. Tittar man på den miljö där damminstrumenteringen installeras så spänner den till ytan upp ett relativt stort territorium. Dammen kan vara uppbyggd av flera olika typer av dammbyggnader mot vattenmagasinet vilket kan resultera i flertalet oberoende delsystem spridda på dammen där vart och ett av mätsystemen rent galvaniskt spänner upp ett stort område på ett par hundra meter. Denna fysiska galvaniska utbredning på dammen är ofta en källa till de "vanliga" felen om inte åtgärder vidtagits vid konstruktion som t ex att potentialutjämna och sätta överspänningsskydd. Störningsproblematiken kan orsakas av kraftelektronik (transformatorstationer, ställverk och kraftledningar) som finns i och omkring mätterritoriet eller av atmosfäriska fenomen där olika markpotentialer kan uppstå inom det galvaniska området och skapa problem.

Ett annat vanligt förekommande fel, när det uppmärksammas, har en betydligt mänskligare prägel rakt igenom och det rör konfiguration/programmering av instrument eller mätlogger. Mohlin & Åström, (2019) framhåller detta som brister i hur funktionstester utförs. Det kan vara felkonfiguration av givare (om möjligt) så fysikalisk parameter kontra utsignal får felaktig skalning eller offset.

Det kan även förekomma direkta beräkningsfel i algoritmer eller att fel instrument läses inför uppladdning av mätvärden till databas. Här är det viktigt med egenkontroller vid installation så att hela mätkedjan provas med kända tillstånd från givarens transducer till överordnade databaser och larmsystem.

### 3 Maskininlärningsbaserad tillståndsövervakning av dammar

#### 3.1 MODELLERING FÖR ATT FÖRUTSÄGA MILJÖVARIATIONER

Med modellering menar vi här att använda en modell av hur sensormätvärden beror på uppmätta miljövariabler för att förutsäga sensormätvärden. Vi använder alltså en modell för att beskriva förväntad respons hos en damm baserat på de indata som finns tillgängliga. En sådan modell bör ta hänsyn till miljöförhållanden som signifikant påverkar dammen. De variabler som generellt påverkar dammars beteende är vattennivån, temperaturen (luft, vatten och damm), dammens ålder, samt för fyllningsdammarna även regnfall och snösmältning.

Hellgren et al., (2019) ger en översiktlig genomgång över modeller som används för att förutsäga dammsensordata. Denna rapport går betydligt djupare i syfte att ge läsaren en fördjupad förståelse för modellering av dammsensordata. Detta är relevant för rapportens huvudsyfte inom avvikelседetektion, då en känslig och precis avvikelседetektion kräver en noggrann förståelse för och modellering av sensordata.

Vi illustrerar med ett förenklat fall. Anta att vi vill detektera avvikande värden i sensormätvärdesserien  $y(t)$ . En enkel modell för  $y$  är att det är ett konstant värde  $y_0$ . Avvikelse-detektion innebär då att detektera värden som ligger långt från  $y_0$ . Oftast använder man något slags integrering i tiden och/eller filtrering, men detta är inte relevant för vårt tankeexperiment. En avvikelседetektor kan då formuleras som

$$e = |y - y_0| \geq \lambda_0$$

där talet  $\lambda_0$  är ett tröskelvärde som vi jämför avvikelсен  $e$  med. Om  $e$  är större än  $\lambda_0$  anser vi att mätvärdet är en avvikelse. Detta är en god grund för en avvikelседetektor – om modellen konstantvärde är korrekt. Men om modellen inte är korrekt kommer vår avvikelседetektor att ge falsklarm och även missa verkliga avvikelser. Hur stora dessa problem blir beror på hur stora avvikelserna från vår modell är. Vi kan minska problemen genom att införa en modell som stämmer bättre med verkligheten. Om mätvärdet i själva verket är temperaturberoende kan vi identifiera temperaturberoendet och införa modellen  $y_1 = y_1(T)$ . En bättre avvikelседetektor är då

$$e = |y - y_1(T)| \geq \lambda_1$$

Vi har här infört ett variabelt intervall, vilket beror av det förväntade mätvärdet vid en viss temperatur. Mätvärden som faller utanför detta intervall flaggas som avvikande (larm eller varningar).

Värt att notera är att avvikelсен  $e$  innehåller både mätfel, modelleringsfel och dammens avvikelse från förväntat beteende. Det är endast det sistnämnda som vi är intresserade av.

Därför är det mycket viktigt att mätsystem och modell utformas, driftsätts, verifieras, övervakas och underhålls så att mät- och modelleringsfel är små jämfört med de avvikelser som kommer från dammens beteende.

Om mät- och modelleringsfel är stora kan konsekvensen bli att anomalier i strukturen inte detekteras. Användaren av ett dammsäkerhetssystem invaggas då i en falsk säkerhet. Detta är värre än att inte övervaka dammen alls, då användaren kanske inte ser någon anledning att sätta in andra övervakningsåtgärder och risken att missa en anomali som kan leda till haveri då är stor. Ett damm-övervakningssystem måste alltså vara pålitligt och tydligt varna för alla allvarliga anomalier.

### 3.1.1 Modelltyper


Venkatasubramanian et al., (2003) ger en indelning av metoder för feldetektion i en process i **modellbaserade metoder** och **metoder baserade på processhistorik**. De modellbaserade metoderna är de som använder kunskap om systemet eller processen t ex från fysikaliska relationer eller matematisk modellering såsom FEM. Man skiljer på **kvantitativa metoder**, vilka uttrycker den fysikaliska kunskapen som relationer mellan indata (miljövariabler) och utdata (sensormätvärden), och **kvalitativa metoder**, vilka uttrycker den som kvalitativa relationer för olika delar i ett system eller steg i en process. Vi fokuserar i denna rapport på **metoder baserade på processhistorik** och använder den modernare benämningen **datadrivna metoder**.

De **fysikaliska metoderna** bygger på fysikaliska modeller av damm och omgivning. Vanligen kan dessa modeller inte uttryckas i sluten form, utan beräknas numeriskt. Flera sådana modeller baserade på finit elementanalys (FEM) har rapporterats, t ex Tayfur et al., (2005) och De Sortis & Paoliani, (2007). Sådana metoder använder detaljerad kunskap om material och dess egenskaper, vilket kan göra dem svåra att använda. De har dock vunnit viss framgång på betongdammar, se t ex Hellgren et al., (2019).

De **datadrivna metoderna** använder endast historiska data och behöver ingen fysikalisk kunskap. Detta gör de lätta att träna och använda, förutsatt att tillräckligt med data för att träna metoderna finns tillgängliga. Till de datadrivna metoderna hör maskininlärningsmetoder, och modeuttrycket artificiell intelligens (AI) används ofta om tränade datadrivna metoder. Artificiella neuronnät inklusive deep learning-metoder och olika typer av statistisk mönsterigenkänning är exempel på metoder som använts med stor framgång i flera olika fält.

Enligt ICOLD ska data från minst tre år användas för träning av en databaserad metod (*Dam surveillance guide. ICOLD Bulletin 158. , (2018)*). Den schweiziska dammsäkerhetskommittén går ännu längre och rekommenderar minst fem års data (*Methods of analysis for the prediction and the verification of dam behaviour, (2003)*). Fernando Salazar et al., (2017) ger i sin review-artikel av databaserade metoder för dammsäkerhet också en jämförelse av hur mycket träningsdata 53 tidigare studier använt. Tolv studier hade använt tre års data eller mindre, 18 fem år eller mindre, och hela 35 studier hade använt mer än fem års data. 14 studier hade använt mer än tio års data. Det finns alltså anledning att gå utöver rekommendationerna; mer

data är alltid nyttigt (även om längre tidsserier ökar behovet att testa stationaritet och hantera eventuell ickestationaritet). Detta ser vi också i resultaten hos F. Salazar et al., (2015), som jämför sex olika datadrivna metoder för dammsäkerhet. Mer information om dessa metoder kommer i följande avsnitt, men här vill vi endast ta upp hur deras prestanda sågs bero av mängden träningsdata som användes. Figuren nedan visar detta. Varje graf visar resultaten för en metod, och varje plot ger resultat för en sensor (här visas radiell deformation). På x-axeln finns träningsdatas storlek mätt i år, och på den logaritmiska y-axeln ett mått på prediktionsfelet. Vi ser att felen tydligt minskar när träningsdata ökar från 5 till 10 år. När de ökar till 15–18 år är trenden inte tydlig; för vissa metoder och sensorer minskar felen, för vissa händer inte så mycket, och för vissa ökar felen. Vi drar slutsatsen att mer än tio års träningsdata kan vara bra, men att förhållandena under träningsperioden måste vara desamma som under valideringsperioden, vilket är svårare att uppfylla ju längre tillbaka i tiden träningsdata sträcker sig.



Figur 4. Feluppskattning för prediktion av sensordata med datadrivna metoder som funktion av träningsdatas längd (år) för sex olika datadrivna metoder. Från F. Salazar et al., (2015).

I Sverige finns det flera s.k. flerårsmagasin. Det här är stora magasin som regleras med längre tidshorisont än ett år. För att fånga vattenytans alla nivåer i träningsdata kommer det alltså att behövas längre dataserier. Det krävs alltså större datamängder för att träna upp en datadriven modell att förutsäga mätdata från en damm med flerårsmagasin.

En nackdel med datadrivna metoder är att de inte kan användas vid driftsättande, vilket är den mest kritiska fasen för dammen. Det beror på beroendet av historiska data för träning.

Enligt Hellgren et al., (2019) kan de databaserade metoderna endast användas för definition av varningsgränser, men inte för att ge larm. Detta motiverar de med att de databaserade metoderna inte kan ge giltiga utdata när indata ligger långt utanför det intervall som använts för träning. De gör alltså det rimliga antagandet att man inte kommer att ha några data från larmtillstånd att träna på. De menar alltså att en datadriven metod inte kan extrapolera på ett kontrollerat sätt. Så är det om modellen som används har en dimensionalitet som är betydligt högre än vad problemet kräver, s.k. överanpassning. Men om en väl dimensionerad modell används undviks detta problem. Val av modellordning är ett väl studerat problem och det finns flera kriterier som kan användas på linjära modeller, t ex Akaikes informationskriterium (AIC), Akaike, (1974).

Från litteratur- och fallstudier drar Hellgren et al., (2019) slutsatsen att de data-drivna metoderna är bättre än de fysikaliska på att förutsäga mätvärden. De säger också att de fysikaliska metoderna ändå behövs för att ge ökad förståelse av orsaker och förlopp.

### 3.2 HST (HYDROSTATIC SEASON TIME)-MODELLEN

Standardmetoden för att modellera en damms respons vid variation i miljö-parametrar är den så kallade HST-modellen, där HST står för Hydrostatic Season Time. HST-modellen används ofta som riktmärke i studier av andra metoder för dammodellering. Den togs ursprungligen fram för att modellera påverkan av miljövariabler på deformationer i betongdammar, men har använts för många andra typer av sensordata och även på fyllningsdammar.

HST är en linjärisering av en olinjär relation mellan miljövariabler och mätvärden med hjälp av tillagda olinjära termer. Modellen identifieras sedan med multipel linjär regression (MLR), vilket kanske kan ha sina problem och brister. Läs mer om detta i sektion 4.4.3. Många olika metoder kan användas för att uppskatta koefficienterna i denna relation, se standardverk om statistik och matematisk modellering. En direkt minstakvadratlösning minimerar kvadratsumman av felen.

HST-modellen modellerar mätvärdena  $y$  i en dammsensor som en linjär-kombination av termer som beror av magasinets vattennivå, årstiden eller ett temperaturmått, samt dammens ålder. En ofta använd formulering är

$$\hat{y}(h, s, \tau) = c_1 h^4 + c_2 h^3 + c_3 h^2 + c_4 h + \dots \\ c_5 \tau + c_6 e^\tau + c_7 e^{-\tau} + \dots \\ c_8 \cos s + c_9 \sin s + c_{10} \sin^2 s + c_{11} \sin s \cos s$$

I denna ekvation beskriver de fyra första termerna beroendet av magasinets vattennivå  $h$ . Nästa tre termer beskriver beroendet av magasinets ålder  $\tau$ . Många författare använder  $c_5 = 0$ , andra tar med en logaritmisk funktion av åldern, och ytterligare andra ett polynom av åldern. Följande fyra termer anger beroendet av tiden på året  $s$ , vilken definieras som  $s = 2\pi j/365$ , där  $j$  = antal dagar efter nyår. Dessa termer beskriver en periodisk modell med perioder 6 och 12 månader. Samtliga faktorer  $h$ ,  $s$  och  $\tau$  bör normeras. Vissa författare normerar så att alla mätvärden ligger mellan 0 och 1, medan andra normerar till medel 0 och standardavvikelse 1.


HST-modellen beskriver alltså effekterna av vattennivå, tid på året och dammens ålder som oberoende. Detta stämmer sällan, t ex är det vanligt att vattennivån är korrelerad med tiden på året. Men trots detta kan HST ge modeller som väl kan prediktera mätvärden från dammsensorer.

Mätvärdet  $y$  kan skrivas som en prediktion från HST-modellen plus en residual  $e$  (ett prediktionsfel),

$$y = \hat{y}(h, s, \tau) + e$$


Oftast används inte alla termer i HST-modellen; vanligen tas endast de som bedöms ha en signifikant påverkan på modellens residual med.

Ett exempel på sensordata och prediktioner från en anpassad HST-modell syns nedan. Här är det tydligt att HST-modellen ger betydligt bättre förutsägelser av sensordata än vad en förenklad modell med ett konstant värde skulle kunna göra. Under 2001–2003 syns flera mätvärden som ligger nära 95 % konfidensintervallet runt HST-prediktionerna och alltså skulle kunna flaggas som avvikande. Dessa data ligger nära medelvärdet av alla sensordata, varför det är osannolikt att en modell med ett konstant värde skulle flagga dem som avvikande.



Figur 5. Uppmätt deformation längs en stendammns krön (blå prickar), prediktioner från en HST-modell (röda prickar) och 95 % konfidensintervall (röda linjer). Från Gamse & Oberguggenberger, (2017).

HST har utvecklades som nämnts för betongdammar, och anses vara särskilt lämplig för deformationer av dessa. Gamse & Oberguggenberger, (2017) utvärderade HST-modellens lämplighet för deformationer hos stendammar. De noterade att årstidsvariationer ofta är tydliga i den hydrostatiska delen av modellen via magasinens nivåvariationer, men kom fram till att de årstidsberoende termerna ändå ger en signifikant bättre modell för deras 21 års deformationsdata från en stendamm. Nedan återges en figur från deras artikel som tydligt illustrerar detta genom att visa hur stor påverkan varje grupp av termer (hydrostatisk, årstidsberoende och åldersberoende) har på de predikterade mätvärdena.



Figur 6. Påverkan av hydrostatiska, årstids- och åldersberoende termer i en HST-modell på predikterade deformationsdata (blå = horisontellt och vinkelrätt mot dammen, röd = horisontellt och längs dammen, grön = vertikalt). Enheten på x-axeln är månader. Från Gamse & Oberguggenberger, (2017).



För jorddammar behöver man utvidga HST-modellen med termer som beror på regnfall, se Bonelli et al., (2003). Flera författare har utgått från daglig regnmängd  $q$  och olika löpande medelvärden  $Q$  av denna. Även tidigare värden av  $Q$  kan tas med för att fånga fördröjningen mellan nedfall och observationer i sensordata. Detta kan sammanfattas som att både nuvarande och tidigare värden av dagliga regnmängden  $q$  bör användas. Vi skriver tidsberoendet som  $q = q(t)$  och uttrycker HST-modellen för jorddammar som

$$\hat{y} = \hat{y}(h, s, \tau, [q(t), q(t-1), q(t-2), \dots])$$

HST-modellen har flera kända svagheter. Den använder, förutom för regntermerna ovan, endast data från samma tid som mätdata. Detta gör att den inte kan ta hänsyn till fördröjningar mellan miljöparametrar och sensordata. Vidare kan det fjärdegradspolynom av vattennivån som vanligen används som hydrostatisk term modellera många beroenden, men har ingen fysikalisk betydelse. Om den hydrostatiska termen stämmer dåligt med de verkliga relationerna mellan vattennivå och sensordata kan det bli svårt och även vara förrädiskt att modellera dessa data. Vid få träningsdata kan polynomkoefficienterna kanske bestämmas så att den hydrostatiska termen medger en god modellanpassning, varvid man kan luras att tro att man har en bra modell. Men ju fler träningsdata man lägger till ju sämre blir anpassningen. Detta är ett exempel på överanpassning, ett fenomen som varje dataanalytiker måste vara på sin vakt mot.

För svenska förhållanden bör man också ta med att med en indikator på snösmältning och eventuellt ett mått på nedfall av snö i indata till en prediktionsmodell. Lufttemperatur och snödjup kan vara goda indikatorer, förutsatt att man lyckas mäta snödjupet med en fjärrstyrd och uppkopplad sensor. ICOLD rekommenderar att man mäter om nederbörd faller som regn eller snö, (*Dam surveillance guide. ICOLD Bulletin 158.*, (2018)), då en stor del av snöns påverkan på dammen inte kommer förrän den smälter. Tyvärr har vi inte hittat några tidigare arbeten som tagit hänsyn till snöfall eller -smältning i modelleringen av mätdata från en damm.

HST-modellen är som nämnts framtagen för att modellera deformationer, men den har även använts för att modellera 13 piezometer- och 7 porttryckssensorer från en jorddamm i Frankrike, se Bonelli et al., (2003). Här användes totalt ca 100 mät-punkter per sensor från en tidsperiod av 9 år. Med tanke på att HST ger en modell för varje sensor och den modell som användes här har 18 parametrar är risken för överanpassning överhängande. Författarna redovisar inte heller några resultat på en testperiod som inte använts för träning av modellerna, utan redovisar endast resultat för träningsdata.

Även Hellgren et al., (2019) utvärderade HST på porttrycksmätningar från en fyllningsdamm. Även om framställningen är kortfattad ser resultaten lovande ut. Det är dock känt att det finns en fördröjning mellan en förändring i magasinsnivån och motsvarande reaktion i porttryck i en fyllningsdamm, Radzicki & Bonelli, (2008). HST tar inte hänsyn till sådana fördröjningar.

Flera författare har föreslagit förbättringar till HST-modellen, bl. a en HTT-modell där årstidsberoendet bytts ut mot en temperatur uppmätt någonstans i dammen. En svårighet med detta är att välja vilken eller vilka av de ofta många temperatur-sensorerna som ska anses vara representativ.



Mata et al., (2014) applicerar principalkomponentanalys (PCA) på ett flertal temperatursensormätvärden från 4 år och använder de första principalkomponenterna i HTT-modellen. Resultaten är något bättre än för HST, men ungefär desamma som då man valt några representativa temperatursensorer genom att studera korskorrelationer. Andra har föreslagit sätt att hantera fördröjningar mellan in- och utdata.

### 3.3 ANDRA LINJÄRA MODELLER FÖR DAMMSÄKERHET

Yu et al., (2010) demonstrerar hur principalkomponentanalys (PCA), se avsnitt 4.2, kan användas på dammsensordata för att reducera dimensionaliteten, öka signal-till-brusförhållandet och därigenom underlätta larmdetektion.

Principalkomponenter beräknades från nio års data från fem töjningsgivare på en betongdamm i Kina. Man kom fram till att de första två principalkomponenterna kunde förklara 91,9 % av variabiliteten i data.

De flesta dammodeller, t ex HST, antar att dammens beteende kan beskrivas med en stationär modell. Li, Wang, & Liu, (2013) undersökte hur väl det antagandet håller på deformationsdata från en valvdamm. Med hjälp av Dickey-Fuller-testet visar de att stationäritet inte håller i en serie av 169 värden samplade med en veckas intervall. Vidare visar de att en s.k. Error Correction Model ger bättre prediktioner än en MLR-uppskattad HST-modell på 20 värden som följer på de 169 träningsdata. Detta står i intressant kontrast till observationen ovan att mer än fem års träningsdata ofta ger bättre prediktioner med stationära modeller. Vi kan förstå detta som att ökningen av mängden träningsdata ger en förbättring av prestanda som är större än den försämring som bör resultera av den ökade ickestationäriteten.

Enligt H. Huang, Chen, & Liu, (2015) är superhöga dammar (över 200 m) svårare att modellera än lägre dammar på grund av att deras respons på miljövariationer är mer icke-linjär. De modellerar uppmätta radiella deformationer från en superhög valvdamm i Kina. Deformationerna uttrycks som linjärkombinationer av polynom av vattennivån, årstidstermer och dammens ålder precis som i HST-modellen. Denna används också som riktmärke. HST uppskattar ju konstanta parametrar i regressionen. Detta gör även Partial Least Squares (PLS) – se avsnitt 4.4.4 - vilken i detta exempel uppnår ungefär en halvering av mean-square prediktionsfelet mätt på en testmängd jämfört med HST. Metoden Optimal Kernel PLS innehåller en icke-linjär transformation och uppnår betydligt bättre prestanda - ett MSE som är under en tiondel av det som uppskattades för PLS. Möjligen är detta ett tecken på överanpassning. Optimal Kernel PLS är en PLS som föregås av en icke-linjär transformation till ett högdimensionellt rum. PLS appliceras sedan i det högdimensionella rummet.

### 3.4 ICKELINJÄRA DATADRIVNA MODELLER

Litteraturen inom icke-linjära datadrivna modeller har en karaktär av att utforska signalbehandlingsmetoders lämplighet för dammsäkerhetstillämpningen. Det är dock inte tydligt hur utbrett användning av dessa metoder är inom dammsäkerhetsövervakning.

### 3.4.1 Ickelinjära stationära modeller


Det finns flera tidigare genomgångar av ickelinjära datadrivna metoder för dammsäkerhet. Hellgren et al., (2019) fokuserar på instrumentering, men tar även upp artificiella neuronnät. F. Salazar et al., (2015) jämför olika maskininlärningsmetoder med HST.

För tillämpningen på dammsäkerhet är syftet med att använda en maskininlärningsmetod att ta fram en modell av en ickelinjär avbildning från indata till utdata. De olika maskininlärnings-metoderna skiljer sig åt i hur de uttrycker denna avbildning och hur de tränas. En viss typ av metod kan också vara mer lämpad för ett visst problem än andra metoder. Metoderna skiljer sig också åt i vilken grad av förståelse av dammens beteende som de kan ge.

För att välja lämplig maskininlärningsmetod för dammsäkerhetsövervakning i Sverige krävs dialog med användarna om krav på förståelse och insyn i modellens funktion, samt utprovning på stora mängder träningsdata. Vi vill därför i nuläget inte rekommendera någon modell före någon annan. Det är dock tydligt att neurala nätverk har använts flitigt i litteraturen och ofta gett goda resultat. Ofta har relativt enkla former av nätverk använts. Det finns idag neurala nätverk med stor kapacitet att modellera komplexa relationer mellan in- och utdata, s.k. deep learningmetoder. Dessa kräver stor insats vid träning men är fullt rimliga att implementera. IVL har tidigare använt deep learning för att extrahera information ur bilder. I en eventuell fortsättning av den här studien vore det naturligt att utvärdera neurala nätverk på data från svenska dammar.

Vi gör nu en kort översikt över maskininlärningsmetoder tillämpbara på modellering av avbildningen från indata till utdata i dammsäkerhet, samt genomgång av tidigare studier som använt maskininlärningsmetoder på dammar. Vi har hittat en artikel som tillämpar på data från en jorddamm, medan övriga använder data från betong- och valvdammar.

Tayfur et al., (2005) jämför neurala nätverk med FEM-modellering för prediktion av läckage genom en jorddamm. FEM-modellen hade 3010 noder och var tätare i dammkroppen och vid dräneringsdikena. Det neurala nätverket var ett trelagers feed forward-nätverk med sigmoid aktiveringsfunktion. Indata var vattennivåerna på upp- och nedströmssidan av dammen, och mätdata var vattennivåer uppmätta inuti och på dammkroppen. Figur 7 visar indata och de fyra utdata. Det neurala nätverket tränades på data från 2 oktober 1995 till 2 juli 2000, och testades på data från 3 juli 2000 till 20 maj 2002. Resultaten blev att FEM och det neurala nätverket presterade lika bra på av utdata, men det neurala nätverket var bättre på det fjärde.



Figur 7. Tayfur et al., (2005) modellerar vattennivåer i och kring dammkroppen som funktion av vattennivåer upp- och nedströms kroppen.

V. Ranković et al., (2014) predikterade vattennivåer i en annan dammkropp med feed forwardnätverk. De jämförde med en multipel regressionsmodell och drog slutsatsen att neurala nätverk är intressanta och bör studeras vidare för modellering av mätdata från dammar. Mata, (2011) och Panizzo & Petaccia, (2009) har applicerat neurala nätverk av feedforwardtyp på deformationer i betongdammar och funnit att de även där kan ge goda prediktioner.

### 3.4.2 Ickelinjära autoregressiva modeller

Linjära AR- och ARX-modeller (se avsnitt 4.5) har inte använts i litteraturen om dammsäkerhet, vilket delvis kan bero på att HST har haft så stor framgång och att maskininlärningsmetoder med stor kapacitet blivit populära. Ett exempel på användning av NARX-modellering på dammsäkerhetsdata ges av Piroddi & Spinelli, (2003). De använder polynom av in- och utdata i en modell som är linjär i de okända polynomkoefficienterna. Detta gör att traditionella minstakvadratmetoder kan användas för att uppskatta detta. Men det är inte detta som är det svåra, utan valet av polynomens ordningar och vilka fördröjningar som ska användas. Författarna använder en stegvis metod där de i varje steg inför en ny predikterande variabel som bidrar mycket till prestanda, undersöker vilken av de valda regressorerna som bidrar minst, tar bort denna om dess bidrag är litet, och upprepar detta tills ett stoppkriterium uppfylls. De validerar sin metod på nio års data från Schlegeis 131 m höga valvdamm. Data som används är vattennivån, deformation av krönet i radiell riktning, sex betongtemperaturer och dygnsmedeltemperaturen i luften. Modellen tränas med de första sju årens data och valideras med de sista två åren. Efter urval av lämpliga predikterande variabler/regressorer används 11 regressorer i den slutliga modellen, alltså ungefär lika många som i en HST-modell. Summan av kvadraterna på prediktionsfelen för deformationen blev 1,76 på träningsdata och 1,29 på valideringsdata. Författarna jämförde med fyra

olika HST-modeller, vilkas fel låg mellan 1,44 och 2,9 på valideringsintervallet. NARX presterade alltså bättre än samtliga HST-modeller, och detta med ett automatiskt val av regressorer.

### 3.4.3 Beslutsträd och supportvektorregression

F. Salazar et al., (2015) applicerade random forests (beslutsträd) för deformations- och flödesdata från en betongdamm, och kom fram till att metoden presterade bra, bättre än HST men dock något sämre än boosted regression trees. Denna metod liknar random forests men viktar utdata från de olika modellerna till en slutlig prediktion. Läs mer om beslutsträd under 4.3.3.

Vesna Ranković et al., (2014) har demonstrerat att supportvektormaskiner (se 4.4.6) kan prediktera tangentiella deformationer i en betongdamm.

### 3.4.4 Jämförelser av linjära och icke linjära modeller

Flera författare har jämfört HST med icke linjära maskininlärningsmetoder. Hellgren et al., (2019) fann att en HTT-modell presterade bättre eller likvärdigt i jämförelse med en icke linjär modell baserad på ett neuralt nätverk. De rekommenderade därför att HTT-modellen ska användas för betongdammar, då den är enklare, anpassad för betongdammar och även har viss fysikalisk koppling. De påpekade dock att den icke linjära modell som användes var av en enkel form. Mer avancerade maskininlärningsmetoder skulle mycket väl kunna prestera bättre.

Simon et al., (2013) modellerade uplift och läckage med HST, men fick bättre resultat med neurala nätverk.

F. Salazar et al., (2015) jämförde fem maskininlärningsmetoder med HST för modellering av deformations- och läckagedata från en betongdamm i Spanien. Med fem radiella deformationer, fem tangentiella deformationer och fyra läckagesensorer hade de 14 mätdataserier att tillgå. De kom fram till att HST var bäst på att prediktera mätdata för två av de tangentiella deformationerna. Ett neuralt nätverk av feed forward-typ var bäst på fyra av mätdataserierna, men den bästa maskininlärningsmetoden var en s.k. boosted regression tree-metod, vilken var bäst på fem av mätserierna. Två av de utvärderade maskininlärningsmetoderna kunde inte sägas vara bättre än HST, och var i många fall sämre. Man gav ingen hypotes om varför just boosted regression trees gav bäst prestanda, utan sade istället att eftersom ingen metod presterade bäst för alla mätdata borde man beakta flera metoder även i framtida dammsäkerhetsstudier.

## 3.5 RAPPORTERADE ÖVERVAKNINGSSYSTEM


I den vetenskapliga litteraturen finns få rapporter om dammövervakningssystem. En vidare sökning ger dock ett par exempel på övervakningssystem som kan användas och som används idag.

S. V. De Simone, (2018) beskriver ett dammövervakningssystem baserat på HST-modellen. Detta system har implementerats på tolv dammar i Turkiet och samlar in ca 1500 mätvärden i realtid. Det tar in data från många olika sensorer bland

annat deformationssensorer, läckagemätare, tryckgivare, töjningsgivare, och nivåmätare. Data skickas i realtid till en central databas. En HST-modell används för att ge spann för normala sensorvärden vid varje tidpunkt. Denna modell tränas om med regelbundna intervall.

Artikeln beskriver inte hur detta går till eller om någon expert överser träningen. Det är viktigt att systemet inte sköter hela omträningen själv, då risken finns att anomalier då smyger sig in i träningsdatat, vilket kan göra det svårare att upptäcka framtida anomalier. Det är inte tydligt om HST appliceras på andra sensorer än deformationsgivare. Viss validering av data sker innan presentation och analys; denna innefattar interpolation vid saknade värden, kontroll att värden ligger inom fördefinierade intervall som anses realistiska, kontroll av förändringshastigheter och korsvis valideringar mellan olika sensorer. Både rådata och förbehandlade data sparas i databasen. Rådata sparas med skrivskydd så att de alltid är tillgängliga för förbättringar och review av systemet.

Systemet föreskriver regelbundna manuella inspektioner och avläsningar av givare som inte är uppkopplade. Foton som tas på plats kan laddas upp och lagras i databasen tillsammans med sensordata. Artikeln nämner dock inget om hur personalen utbildades för att sköta systemet och använda larm och annan information från det.



Figur 8. Grafiskt gränssnitt till dammövervakningssystem för 12 dammar i Turkiet. Från S. V. De Simone, (2018).

F. Salazar, (2016) beskriver och ger programkod för en mjukvara för dammövervakning som arbetar offline på lagrade tidshistorier av sensordata. Mjukvaran illustrerades för övervakning av en damm baserat på data från fem deformationssensorer och fyra temperaturgivare. En modell för hur sensordata beror på miljövariablerna hydrostatisk last, lufttemperatur, regnmängd per dag, tid och årstid tas fram med hjälp av maskininlärningstekniker. Datapunkter som inte stämmer överens med modellens prediktioner markeras sedan som avvikande och flaggas för närmare studier.



Figur 9. Träning av maskininlärningsmetod (boosted regression trees) på dammsensordata. Från F. Salazar, (2016).

"GOCA - GNSS/LPS/LS-based online Control and Alarm System," (2019) är ett övervakningssystem för geodetiska sensorer som inte specifikt är till för dammsäkerhet Jäger & Gonzalez, (2005). Det utvecklades vid Hochschule Karlsruhe i Tyskland. Det har utvidgats till att också stödja inklinometrar och tryckgivare. Systemets mjukvara analyserar sensordata, predikterar med hjälp av en Kalmanfiltermodell och kan ge larm vid avvikande beteenden.

### 3.6 DATADRIVNA TEKNIKER FÖR DAMMÖVERVAKNING

En god genomgång av fallgropar och visdom vid utveckling och implementation av ett datadrivet beslutsstödsystem för dammsäkerhet ges av Fernando Salazar et al., (2017). De går igenom olika maskininlärningsmetoder och listar ett antal saker man ska tänka på när man implementerar dessa, bland annat uppdelning i test- och träningsdata och felanalys. De gör en omfattande litteraturgenomgång (81 referenser) och kommer fram till att de flesta tidigare studier i området endast behandlar en specifik typ av data och/eller har undermålig validering. De drar slutsatsen att det behövs ytterligare validering och generalisering. Vidare rekommenderar de utveckling av kriterier för modellapplikation och förbehandling av data.

Fernando Salazar et al., (2017) summerar 59 artiklar om modellering av dammsensordata. 38 av dessa studerade radiella deformationer, speciellt i valvdammar (31 st.). Detta anses bero på en större oro för säkerheten i dessa dammar och på att deformationer så tydligt kopplar till säkerhetsrisker, men andra



indikatorer såsom läckage och uplift är lika relevanta för dammsäkerhet. Det faktum att de senare data mer sällan modelleras i litteraturen kan bero på ett mer komplicerat miljöberoende, vilket gör dem svårare att tolka.

Prakash et al., (2018) ger ett statistiskt ramverk för att övervaka en damm. En HSTT (hydrostatic season temperature time) -modell anpassas till 4,5 års mätdata från en valvdamm i Bulgarien. Residualer beräknas som skillnader mellan prediktioner från modellen och aktuella principalkomponentvärden. Därefter uppskattas fördelningen av residualerna. Kontrollgränser sätts vid 95:e percentilen (UCL1) och 99:e percentilen (UCL2). För korrelerade mätvärdessignaler applicerar författarna en vitningstransformation. Om sensordata är normalfördelade följer de resulterande signalerna en F-fördelning. Det kan man utnyttja för att sätta kontrollgränser på de vitade signalerna.

Några författare har tagit hänsyn till eller sökt detektera felaktigheter i sensordata.

Stojanovic et al., (2013) utvecklade en modell för prediktion av dammövervakningsdata som är robust mot sensorfel, förutsatt att dessa kan detekteras. Efter att sensorfel detekterats skapas en MLR-modell liknande HST från miljövariabeldata från fungerande sensorer. När ett sensorfel detekteras kan man gå bakåt i tiden och utesluta den felande sensorn i en ny MLR-modell. Om sensorn börjar fungera igen kan en ny MLR-modell skapas – så fort tillräckligt mycket träningsdata har samlats in. Eftersom ”tillräckligt mycket” ofta är några år kan denna metod vara olämplig att implementera i praktiken.

A. L. Pyayt et al., (2013) diskuterar detektion av anomalier orsakade av sensorfel för sensor på dammar eller översvåmningsvallar. Man modellerar relationer mellan olika sensorer med överföringsfunktioner (ARMA) och neurala nätverk. Modellerna tränas på perioder när man vet att sensorerna fungerar, och man visar sedan hur de kan användas för att detektera en period när en sensor uppvisar ett avvikande beteende. För att metoderna ska fungera måste sensorerna placeras så nära varandra att relationer mellan sensordata kan beskrivas med någon modell. I den här studien är det tydligt att beteendet beror på ett sensorfel, men det är inte troligt att dessa metoder skulle kunna skilja på sensorfel och andra effekter som endast förekommer lokalt (i data från en enskild sensor).

L. A. Pyayt et al., (2014) av diskuterar användning av tid-frekvensmetoder, i det här fallet wavelets och short-time Fourier transform (STFT, ”spektrogram”), för att detektera anomalier i sensordata från övervakning av dammar och vallar. De illustrerar metoderna på temperaturdata mätta med optisk fiber. Avvikelserna som de detekterar är stora, så resultaten verkar inte övertygande.

Liknande metoder för diagnostik av sensorfel diskuterades också av Huang et al., (2017) för generell strukturövervakning. De använde PCA för att uttrycka sensormätdata i ett underrum fritt från mätbrus, och projicerade på detta rum. Därefter visade de två metoder för sensorfel detektion; en Bayesisk som uttrycks som kvot mellan sannolikheter (Likelihood Ratio Test) och en vidareutvecklad i form av ett Generalized Likelihood Ratio Test. Dessa utgick dock från antagandet att både felfria sensordata och residualer är Gaussiska. Detta stämmer sällan i praktiken. Metoderna demonstrerades också endast på data från en modell av en bro i labbmiljö.



Ett steg längre tog Kullaa, (2013). Han visade att om sensorerna i ett sensornätverk är korrelerade och datafördelningen hos varje sensor är Gaussisk kan sju olika sensorfel detekteras, identifieras och korrigeras: skift av medelvärdet, ändrad förstärkningsfaktor, gradvis förändring av medelvärdet (drift), minskad mätprecision, totalt bortfall, mätdata är endast brus, och mätdata är ett konstant värde plus brus. Metoderna illustrerades på accelerometerdata från en trästruktur i labbmiljö. Li et al., (2019) visade att metoder av denna typ även fungerar på mätdata från en verklig bro.

## 4 Analysmetoder

I det här kapitlet tar vi upp ett antal metoder som kan vara relevanta för analys av data från dammar.

Den som är intresserad av att göra egna analyser kan göra enkel statistik i Excel. Därutöver finns så gott som alla publicerade statistiska metoder tillgängliga i programmeringsspråket R.

R är egentligen ett stort publikt projekt för statistiska beräkningar, se "The R Project for Statistical Computing," (2019). En annan möjlighet är att använda språket Python, som också är gratis tillgängligt och har en hel del tilläggs paket för maskininlärning och statistik. Även det kommersiella matematiska analys-verktyget Matlab har paket för maskininlärning och statistik, men kräver mer av användaren i form av matematisk förståelse.

Det finns förstås många kommersiella program för statistiska beräkningar, tex SAS, SPSS, Minitab, SYSTAT, Statgraphics, SIMCA, för att bara nämna några.

### 4.1 ENKLARE ORDINÄR OCH ROBUST (ICKE-PARAMETRISK) STATISTIK

Ordinär eller klassisk statistik utgår ofta från att data följer en känd, parametriserad, fördelning. Ofta antas data vara normalfördelade. Fördelningens parametrar skattas ofta från data.

Kan man inte anta att data följer en känd fördelning finns det metoder som inte kräver detta, så kallade robusta metoder. För en översiktlig introduktion till robusta metoder se t ex "Robust statistics," (2019). Andra benämningar är icke-parametriska metoder, eller distributionsfria metoder. Dessa metoder utgår ofta från rangordnade/sorterade data. Detta gör att alla extremer i mätdata försvinner och ersätts med rangordningstal, data tilldelas alltså värdena 1,2,3, etc. till och med antalet observationer i data. Dessa ordningstal används sedan istället för ursprungsvärdena. Metoderna är inte fullt så starka som de parametriska men gör heller inga antaganden om data.

Använder man parametriska metoder för analysen trots att data inte följer den för metoden antagna fördelningen kan resultatet vara missvisande. Med icke-parametriska metoder är man på säkra sidan.

Det finns ett test, Kolmogorov-Smirnovs test, som kan användas för att testa data mot en antagen fördelning. Shapiro-Wilks normalfördelningstest är ett annat alternativ. Man kan också kolla om data är normalfördelade medelst en normalfördelningsplot, se nedan.

Ibland kan man via transformation göra en variabel hyfsat normalfördelad, t.ex.  $\log(x - \text{konst})$ , eller Box-Cox' transformation, G. E. P. Box & Cox, (1964).


#### 4.1.1 Beskrivande statistik

En bra referens för beskrivande statistik är Colton, (1974).

*Visualisera data*


Det är alltid klokt att plotta data före analys. Ögat är bra på att upptäcka konstigheter i data.

Man kan lämpligen börja med att göra trendkurvor för tidseriedata och rita **frekvensdiagram** (histogram) över data för att kolla hur de är fördelade, se Figur 10.




Figur 10 Ett histogram visar antalet värden inom varje intervall av data

**Låddiagram** (box-whisker plot) är en enklare form av histogram. Det sammanfattar data med hjälp av 5 värden (minimum, undre kvartil (25%), medianvärde (50%), övre kvartil (75%) och maximum). "Morrhåren" anger min och max i data, men är inte längre än kvartilavståndet, se nedan. Värden mindre än undre kvartil – kvartilavståndet, respektive större än övre kvartil + kvartilavståndet, plottas ut. Detta är ett enkelt sätt att indikera eventuella avvikare, se Figur 11.



Figur 11 Ett låddiagram som visar en fördelning med extremvärden.

Man kan också kombinera olika typer av fördelningsdiagram i en och samma figur. Se Figur 12, som visar ett exempel (från programspråket R) på kombination av låddiagram, skatterplot, histogram och fördelningsdiagram.



Figur 12 I en bild kombineras histogram-, fördelnings-, skatter- och låddiagram.

#### Centralt värde

Medelvärde anges av summan för alla värden delat med antalet värden. Extremvärden har stor inverkan på medelvärdet.

Medianvärdet, det robusta måttet, är det värde som har lika många observationer med mindre som med högre värden. Vid jämnt antal värden är medianen lika med medelvärdet av de två mitre värdena. Medianvärdet påverkas inte speciellt mycket av avvikare.

#### Spridning

Standardavvikelsen,  $sd$ , är det klassiska spridningsmåttet, men det påverkas starkt av avvikare och om data är skevt fördelade. Med normalfördelade data ligger ca 95% av data inom intervallet  $\pm 2sd$ . Den robusta motsvarigheten är MAD, (Median Absolute Deviation) medianvärdet av de absoluta avvikelserna från medianvärdet. Om data är normalfördelade kan standardavvikelsen skattas som  $1.483 * MAD$ .

Spridningsintervallet anges som skillnaden mellan max och min i data. Det robusta måttet är kvartilavståndet (IQR, Inter Quartile Range). IQR är skillnaden mellan övre och undre kvartilens gränser. Om data är normalfördelade kan standardavvikelsen skattas som  $0.7413 * IQR$ .

#### Varians

Det klassiska måttet på spridning är standardavvikelsen i kvadrat.

Robusta skattningar på datas varians ges av  $IQR^2$  eller  $MAD^2$ .

#### 4.1.2 Robusta statistiska tester

En bra referens för robusta statistiska tester är Siegel, (1956).

### Centralt värde

Det finns det flera olika tester som kan användas för att testa om en dataserie har ett visst centralt värde eller om två dataserier har samma centrala värde.

**Wilcoxons rangsummetest med ett hypotetiskt värde** (Wilcoxon signed-rank) börjar med att bilda de absoluta differenserna till det hypotetiska värdet. Alla differenser som inte är noll rangordnas och man bildar rangsumman för de negativa respektive positiva differenserna. Om data har det hypotetiska centrala värdet bör de två summorna vara lika. Med hjälp av en sannolikhetstabell avgör man om stickprovet skiljer sig signifikant från det hypotetiska värdet. Det gäller att ha någorlunda många observationer; med 5 eller färre observationer går det inte att avgöra någon skillnad.

**Wilcoxon rangsummetest för samma centrala värde** (även kallad Mann-Whitney U-test, på engelska Wilcoxon rank sum test for same central value in two data sets) rangordnar data från båda stickproven tillsammans, man får en talserie 1, 2, 3, 4, osv. Sedan bildar man rangsumman för respektive stickprov. Med dessa summor och en tabell avgör man om stickproven kommer från samma fördelning eller ej.

**Wilcoxons teckenrangtest för parade differenser** (Wilcoxon matched-pairs signed-rank test for same central value in paired samples) görs på samma sätt som med en dataserie mot ett hypotetiskt värde, men först bildar man pardifferenserna och testar dem mot värdet 0.

### Varians

Om man vill testa om variansen i två dataset är lika kan man använda **Ansari-Bradleys** test. Det finns även andra tester om man har fler än två grupper av data.

### Avvikare

Att upptäcka avvikare är svårt. Det är lättare att se avvikare i en plot med ögat än att detektera dem med automatiska metoder. Ligger avvikelser i en kombination av variabler behövs multivariata metoder. Vet man att en signal skall ligga i ett visst intervall kan man sätta larm som indikerar om signalen faller utanför. För tidserier kan man använda **CuSum** som innebär att man kontinuerligt summerar avvikelser från ett börvärde. För mer information om CuSum, se avsnitt 4.6.

I R:s bibliotek *mvoutlier* finns en metod **pcout**, som kan användas för multivariat detektion av avvikare. Metoden baseras på robust PCA.

Man kan använda en modell som uppskattar värdet från en givare. Detta värde kan sedan jämföras med det värde som givaren ger. Differensen kan användas för att detektera avvikare.

Ett problem vid **detektion av skador** på en damm är att man troligen **saknar mätdata från tidigare skador**, vilket gör det svårt att veta hur en skada påverkar mätdata. Vad man generellt gör i dammövervakning är att söka mätdata som på något sätt avviker från normalläget. En intressant vidareutveckling av denna metodik ges i Goi & Kim, (2017) för övervakning av skador på en bro. Man använder vibrationer från kontrollerade överfarter med ett visst fordon och sätter upp en statistisk modell för hur vibrationsmätdata beter sig när bron är intakt.

Avvikelse detekteras sedan med hjälp av en likelihood ratio vilken är kvoten av sannolikheten att bron är intakt och att den är skadad givet mätdata. Denna Bayesiska metod kräver kännedom om sannolikhetsfördelningen för mätdata på skadad bro, vilken inte är tillgänglig. Man löser det problemet genom att approximerar en generell sannolikhetsfördelning för alla typer av skador (med hjälp av Schwarz kriterium). Metoden lyckas tydligt och framgångsrikt detektera två skador som tillfogats bron. Liknande metoder bör utvärderas på dammdata.

Fisher, (2017) presenterar olika **oövervakade metoder för avvikardetektion** som kan vara värda att utvärdera på dammsäkerhetsdata. Dessa metoder kräver ingen modell som kan prediktera sensordata. Författaren utvärderar metoderna på vibrationsdata från en liten damm i labbmiljö. En klustringsmetod kan separera avvikande och normala värden i ett exempel, men det ser ut att vara stor skillnad mellan dessa värden. En metod som modellerar data som multivariat Gaussiska och beräknar kontrollgränser från detta kan också detektera dessa stora anomalier. En tredje metod som baseras på wavelettransformation och träning av en supportvektorklassificerare med endast en klass (normala data) ger också goda prestanda på testdata.

#### 4.1.3 Korrelation

Korrelation är ett mått på hur relaterade två variabler är. Oftast menar man linjär korrelation när man pratar om korrelation. Pearsons korrelation,  $r$ , är det klassiska måttet för korrelationen mellan två variabler. Den definieras som

$$r = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y}$$

där  $\sigma_x$  och  $\sigma_y$  är standardavvikelseerna för  $x$  respektive  $y$  och  $\text{cov}(x, y)$  är kovariansen mellan variablerna  $x$  och  $y$ ,

$$\text{cov}(x, y) = E[(x - \mu_x)(y - \mu_y)]$$

Här är  $\mu_x$  medelvärdet för  $x$  och  $\mu_y$  medelvärdet för  $y$ . Medelvärdena skattas oftast från data.

Det vanligast robusta måttet på korrelation är **Spearman's rangkorrelation**, men Kendalls tau är också vanligt.

#### 4.1.4 Drift i tidserier

Drift innebär att det centrala värdet i en tidsserie varierar med tiden. Mann-Kendall är en icke-parametrisk metod för att upptäcka linjära monotona trender. Det finns också en variant som inkluderar säsongvariationer.

## 4.2 PRINCIPALKOMPONENTANALYS, PCA

PCA kan nog sägas vara modern till all multivariat dataanalys. Den bör man känna till om man umgås med dataanalys!

Ett generellt två-dimensionellt dataset från en process har  $N$  observationer och  $K$  variabler. Det är inget som hindrar att  $K > N$ . Varje observation i data kan representeras som en punkt i ett  $K$ -dimensionellt koordinatsystem. Med  $N$  observationer får vi en punktsvärm med ett centrum definierat av variablernas medelvärden. Svärmens utbredning kallas ibland processens utbredningsdomän. Svärmen är sällan absolut klotformad utan har en struktur i rummet. Den axel genom centrum längs vilken svärmen har sin största utsträckning är den första principalkomponenten. Den andra komponenten fångar den näst största utbredningsriktningen, vinkelrätt mot den första komponenten. Man kan fortsätta beräkningen av nya komponenter, alla vinkelräta mot de föregående i fallande ordning tills man beräknat  $K$  komponenter. Ofta stannar man vid 1–3 komponenter.


Med  $A$  komponenter definierar modellen ett  $A$ -dimensionellt hyperplan i den  $K$ -dimensionella rummet. Med komponent ett och två definierar man det dominerande 2-dimensionella planet i rummet, det plan genom centrum som passar så bra som möjligt till punktsvärmen. Punkterna kan projiceras ned på planet, ovanifrån och underifrån, och resultatet blir en 2-dimensionell bild av hur punkterna ligger i  $K$ -rummet.

Mycket förenklat kan PCA sägas fånga den dominerande strukturen i två komplementära få-(1–3)-dimensionella bilder. Det är en bild för observationerna och en för variablerna. I bilderna ser man hur data fördelar sig, både observations- och variabelvis, man ser grupperingar, avvikelser och trender. Riktningar från centrum i den ena bilden hänger samman med samma riktning från centrum i den andra. En bra introduktion till PCA finns i Varmuza & Filzmoser, (2008) och en mindre rigorös är "Principal Component Analysis," (2019).

Ett exempel på resultat från en PCA av ett dataset Glass, som består av analysdata med 13 variabler från 180 olika arkeologiska glasprover ses i Figur 13. Man ser enkelt att proverna ligger i 4 grupper och att även variablerna är grupperade/korrelerade. Eftersom riktningar hänger samman mellan bilderna, kan man tolka att de blå proverna har låga värden för  $K_2O$  och  $PbO$ . De gula proverna har höga värden för de variabler som ligger till vänster i variabelbilden och låga värden för  $SiO_2$ . Det vita området i observationsbilden anger det område där de flesta proverna skulle ligga om data vore helt normalfördelade.


En PCA kan också användas för klassning. Ett nytt prov läggs in i modellen och man kan se in vilken grupp det hamnar, eller, minst lika viktigt, om det inte passar till någon av de etablerade grupperna.






Figur 13 Två bilder från PCA. Övre grafen ser man observationerna (scores) och undre grafen variablerna (loadings).

Avståndet från centrum i modellplanet kan vägas samman till ett mått, Hotelling's T2. Oavsett antalet komponenter erhåller man en plot som anger hur långt från centrum som observationerna ligger, Figur 14.



**Figur 14** Plot över Hotelling's  $T^2$ , observationernas avstånd i modellplanet från centrum.

Eftersom  $\text{Data} = \text{Modell} + \text{Residual}$  (det omodellerade), kan man också plotta residualerna, observationernas avstånd till modellplanet, DModX, Figur 15.




**Figur 15** Plot över observationernas vinkelräta avstånd till modellplanet.

Vanlig PCA kan lätt domineras av avvikare, på gott och ont, eftersom man lägger bildplanen så nära observationerna som möjligt i minsta-kvadratmetodens mening. Det finns därmed en hel del robusta varianter av PCA, dock inget för den normale användaren. Det man i stället oftast gör är att utesluta avvikare, eller bilda en PCA för varje identifierad grupp i data.


Som exempel på dammdata fick vi tillgång till ett dataset från Bålforsens kraftverk i Umeälven. Data består av timmedelvärden, 21 024 observationer, för 36 signaler för tiden 2012-12-03 till 2015-04-29. Signalerna är från 2 övervakade monoliter, M18 och M38, och kommer från temperaturgivare, töjningsgivare, porttrycksgivare, pendelgivare och batterispänning.

Med dessa data ser bilderna för en 2-komponents PCA ut som nedan i Figur 16.



Figur 16 Observationsbild (score plot) för data från Bålforsens damm, färgen anger tiden, från blått till rött.


Man ser att processen rör sig motsols drygt två varv på årsbasis. Pilen ovan i Figur 16 pekar på det första kvartsvrvet avviker från den i övrigt ganska cirkulära formen. Vi fick sedan veta att mätsystemet inte var intrimmat korrekt under den tiden.



Figur 17 Processens rörelse från föregående figur, uppdelad på X- och Y-rörelser (komponent 1 och 2).

I Figur 17 plottar man observationsbilden (från Figur 16) som rörelser i X- och Y-led var för sig. I vänstra delen i X-led anar man en sinuskurva, med undantag för den första delen. I högra delen i Y-led anar man också sinuskurvan men inte så tydlig, och därtill någon annan form av snabbare svängning.

Loadings - BFN (M4, PCA-X), Som M3, men BFN-M38-U-U-1T, BFN-M18-PENDULUMY-U-1T uteslutna



Figur 18 Variabelbild (loading plot) för data från Bålforsen. I data ingår signaler från 2 monoliter M18 och M38.

Variabelbilden, Figur 18, visar hur variablerna hänger samman. På våren och sommaren befinner sig processen till vänster i observationsbilden. Ser man på vidhängande variabelbild ser vi tempgivarna (\*T\*) som en grupp till vänster, samtidigt ligger sprickgivarna (\*S\*) till höger.

Detta är förklarligt eftersom sprickorna är minst då monoliterna är som varmest. BatchPCA, ParaFac och Tucker3 är utvidgningar av PCA till att hantera 3-dimensionella data, t.ex. observationer\*variabler\*tid, se Varmuza & Filzmoser, (2008). En beskrivning på hur man identifierar felande sensorer med hjälp av PCA ges i Dunia et al., (1996)

### 4.3 KLASSIFICERING

Det finns många metoder för klassificering. Här redovisas ett litet urval. I nästa avsnitt om Regression beskrivs några metoder som kan användas som underlag för klassificering, bland annat PLS, supportvektormaskiner, och neurala nätverk.

#### 4.3.1 KNN


KNN, K Nearest Neighbours, är en enkel metod för klassificering. Givet ett dataset med kända klasser, klassas en ny observation enligt de K närmaste observationernas klasstillhörighet. Metoden beror förstås på hur man beräknar avståndet. Det Euklidiska avståndet, Pythagoras sats, är vanligast. För mer information se "k-nearest neighbors algorithm," (2019)

### 4.3.2 SIMCA

SIMCA (Soft Independent Modeling of Class Analogy) är en metod där man gör en PCA för varje klass, Wold & Sjostrom, (1977). En ny observation klassas genom att man projicerar den mot varje PCA-modell. En fördel med SIMCA jämfört med KNN är att observationer som inte passar till någon klass också kan upptäckas. Detta kan även göras med flera andra klassificeringsmetoder, tex linjär diskriminant, supportvektormaskiner och neurala nätverk.

### 4.3.3 Beslutsträd

Klusteranalys är ett sätt att beskriva ett dataset i ett hierarkiskt träd, baserat på avståndet mellan observationerna. Metoden delar själv upp observationerna efter likhet, på olika nivåer, som anges av Y-axeln, Figur 19.



**Figur 19** Hierarkisk klusteranalys för glasdatasetet. Y-axeln är en funktion av avståndet mellan de funna klasserna.

Random forests är en annan beslutsträdsmetod som kan prediktera ett mätvärde som medelvärde av utdata från flera olika linjära modeller (regressioner). Varje modell ser en slumpvis utvald del av träningsdata och ett slumpvis urval av indata. Genom att skapa många sådana modeller och kombinera ihop dem kan man hantera icke linjära avbildningar.

## 4.4 REGRESSION


Regressionsanalys, regression, är en gren inom statistik där målet är att skapa en funktion som bäst kan beskriva relationen mellan prediktionsvariabler  $X$  och responsvariabler  $Y$ . Matematiskt handlar det alltså om att beskriva en okänd avbildning från  $X$  till  $Y$ , alltså att försöka beskriva hur man kan beräkna  $Y$  från  $X$ . Den framtagna avbildningen eller funktionen kallas ofta för en modell.

Det finns flera kraftfulla statistiska metoder och verktyg som kan användas för att identifiera modeller som är linjära i parametrarna. Och inom maskininlärning finns många metoder för att ta fram modeller som inte är linjära i parametrarna. Dessa

modeller anges då inte alltid på sluten form, dvs kan inte på enkelt sätt uttryckas med hjälp av matematiska uttryck.

#### 4.4.1 Förbehandling och transformationer

Vanligtvis förbehandlas multivariata data före modellering med autoskalning. Det innebär att medelvärdet skalas till 0 och standardavvikelsen skalas till 1 för alla ingående variabler, se Figur 20. På så sätt ges varje variabel samma chans att bidra till modellresultatet.



Figur 20 Förbehandling av data medelst autoskalning

Enklare varianter av olinjäriteter mellan X och Y kan hanteras i en linjär modell genom att använda förbehandling medelst transformationer. Vanligast är  $\log(x)$  eller  $\log(y)$ , på vilka man sedan bygger den linjära modellen. PCA och PLS kan också fås att hantera olinjära samband genom att man kompletterar X-sidan med olinjära termer ( $X^2$ ,  $X^3$ ,  $\log(x)$ ,  $\sqrt{x}$ ,  $x_1 \cdot x_2$ , ...). Årsvariationer kan man ta hänsyn till genom att inkludera  $\sin()$  och  $\cos()$  av tiden på året. Ett annat sätt är att dela upp en eller flera X-variabler i ett antal 0/1 intervallvariabler, där varje sådan variabel är 1 om data ligger i sitt respektive intervall, Berglund et al., (2001).

#### 4.4.2 Univariat linjär regression

Den enklaste formen av regression är univariat linjär regression. Relationen mellan x och y modelleras som

$$y = ax + b$$


med två obekanta parametrar, a och b. De obekanta kan bestämmas med minsta-kvadratmetoder eller någon metod som är mer robust mot avvikare.

När vi använder vanlig regression så gör vi två antaganden: att x och y är normalfördelade samt att x-variabeln är felfri. Ofta klarar metoden även andra data, även om konfidensintervall och sannolikheter inte blir riktiga. Metoden minimerar

summan av kvadraten av avståndet mellan regressionslinjen och datapunkterna i y-led. Det innebär att vi bör fundera på vilken mätning som utgör x resp. y när vi gör en regression. Se Figur 21, högra delen.

När det gäller ortogonal regression (Orthogonal) så minimeras det vinkelräta avståndet mellan punkterna och regressionslinjen, Massart et al., (1997b).

I ortogonal regression är således ansatsen att både x och y har fel, vilket är ofta fallet.



Figur 21 Skillnad mellan ordinär och ortogonal minsta kvadratmetod (regression). Bild Anders Björk, (2007).

#### 4.4.3 Multipel linjär regression, MLR

Multipel linjär regression, MLR, är en regressionsmetod som kan spåras till början av 1800-talet. Den är en klassisk metod för **en** y-variabel och flera x, som även skattar signifikanser och konfidensintervall för koefficienter och prediktioner. Metoden antar att ingående x-variabler är utan brus och andra observationsfel, är normalfördelade och oberoende, och man får inte heller ha fler variabler än observationer. Alla dessa förutsättningar är sällan uppfyllda, och risken finns att resultatet blir överskattat så att man får en skenbart utmärkt modell som är överanpassad till data och har dålig prediktionsförmåga för nya data.

Inom statistiken har det utvecklats flera alternativ till MLR som söker komma runt dessa problem. Stegvis variabelselektion är en av dessa metoder. Den kan utföras framåt eller bakåt. I det första fallet utgår man från den X-variabel som korrelerar bäst med Y. Därefter söker man iterativt bland de återstående efter den som ökar modelleringsresultatet mest. I det andra fallet exkluderar man iterativt den variabel som bidrar minst. Det finns olika stoppkriterier. Metoden kritiseras för att vara brusberoende och leder ofta till överanpassade modeller vilket innebär dålig prediktionsförmåga för nya observationer. Se "Stepwise regression," (2019).

Andra motmedlet mot kolinjäritet och brus i X är att göra PCA på X och sedan använda principalkomponenterna som X i MLR, så kallad PCR (Principal Component Regression), Massart et al., (1997a). Risken med PCR är att data kan



domineras av sådant som inte har med Y att göra och modellen blir sämre än vad som skulle kunna uppnås.

Har man flera Y-variabler måste man göra en MLR-modell per Y-variabel.

#### 4.4.4 Partial Least Squares regression, PLS


Vid PLS har man data i 2 rymder, X för X-variablerna och Y för Y-variablerna. Varje observation i data representeras alltså av en punkt i X-rymden för X-delen, och en punkt i Y-rymden för Y-delen av data. PLS är en metod som maximerar kovariansen mellan observationernas läge i X och Y. Den fungerar med många X och många Y. Man kan ha många fler variabler än observationer så som ofta är fallet vid spektrala data.

PLS reducerar risken för överanpassning genom intern kors-validering: man gör modeller på delmängder av observationerna och testar mot de som inte är inkluderade i delmängden.

Metoden resulterar bland annat i tolkningsbara få-dimensionella bilder, liksom för PCA, men här för både X och Y och residualerna, samt även en regressions-ekvation för varje Y.

Vid prediktion av Y från nya X-observationer finns metoder för att testa att X passar till modellens giltighetsdomän i X, så att observationer som är avvikare i X-rymden kan tas bort. Därefter projicerar PLS observationen ner på modellplanet i X-rymden och via den inre relationen förs projektpunkten över till Y-planet. När observationen väl är överförd till Y-rymden projiceras den ner på Y-axlarna och de predikterade Y-värdena erhålls, Figur 22.


Läs mer om PLS i Eriksson et al., (2003) eller Varmuza & Filzmoser, (2008).



**Figur 22** Prediktionsproceduren vid PLS. En ny observation läggs in som en punkt i X-rymden (vä bild), via den inre relationen (mittre bilden) erhåller man en projicerad punkt i Y-rymdens modellplan (hö bild). Punkten projiceras på Y-axlarna och man kan läsa av de predikterade Y-värdena. Eriksson et al., (2003)


Vid tidserieanalys behöver man ofta särskilja variation som är säsongsberoende, som driver linjärt över tiden och den övriga variationen som då är hyfsat stationär (stabil i sitt medelvärde). Detta kan man göra med PLS. Då tar man in tidstermer, såsom  $\sin(\text{tid})$ ,  $\cos(\text{tid})$ ,  $\sin(\text{tid})^2$ ,  $\cos(\text{tid})^2$ ,  $\text{sign}(\text{abs}(\sin(\text{tid}))^2)$  och  $\text{sign}(\text{abs}(\cos(\text{tid}))^2)$  som förklaringsvariabler och sätter de 36 säsongssvängande variablerna som Y. På detta sätt erhöi vi en modell där årsvariationen kunde modellera 84% av signalernas variation. Genom att plotta residualen (det som inte korrelerar med

tiden) och beräkna dess standardavvikelse kunde vi beräkna konfidensintervall för de predikterade Y-värdena, Figur 23.




**Figur 23** Trendkurva för den del av temperaturen BFN-M38-T1-U-1T som inte kunde modelleras som funktion av endast tiden. Det framgår att 2 standardavvikelse är cirka 1.7 grader C.

Med vetskap om residualens storlek kan man i nästa steg plotta originalsignalen, modellens predikterade värden, samt dess konfidensintervall, Figur 24. Konfidensintervallet är förmodligen väl stort för att vara till någon nytta, men modellen kan kompletteras med ytterligare förklaringsvariabler, såsom utomhustemperatur, nederbörd osv.




**Figur 24** Observerad signal (svart), predikterat från tiden (blå), övre och undre 2 standardavvikelse konfidensintervall (orange).

Vill man driva modellen ett steg till kan man inkludera tidigare Y-data på X-sidan, dvs en AR (autoregressiv) del i modellen. Med Y (tid - 1 vecka) inkluderad på X-sidan i modellen erhöll vi en modell som kunde förklara 95% av variationen hos Y-variablerna (några litet mer och några litet mindre). Då blev 2 standardavvikelse för residualen för samma signal som ovan 0.6 grader, Figur 25. En sådan modell kan användas som prediktor för signalerna för 1 vecka framåt! Tar man därtill med SMHIs prediktioner för kommande vecka blir prediktionerna kanske ännu mer tillförlitliga.



Figur 25 Den omodellerade delen av samma variabel som ovan, med tid och signalvärden (-1 vecka) som förklaringsvariabler.

Här kan vi nu visa modellens prediktioner för signalerna 1 vecka framåt inkl. 2 standardavvikelsers konfidensintervall, Figur 26. Konfidensintervallet är bra mycket smalare.



Figur 26 Observerad signal (svart), predikterat från tiden (blå), övre och undre 2 standardavvikelsers konfidensintervall (orange), då tid och data (-1 vecka) används som X-variabler i modellen.

#### 4.4.5 Gaussisk process regression, GPR


Gaussisk processregression är en olinjär regressionsmetod som kan användas för regression eller interpolering mellan X- och Y-variabler. Både uni- och multivariat regression är möjlig. Som namnet antyder är grundantagandet att data kan modelleras som en Gaussisk (normalfördelad) process (GP) enligt

$$Y(x) \sim GP(m(x), k(x_i, x_j)) = N(m(x), k(x_i, x_j))$$

där  $k(x_i, x_j)$  är en matris som beskriver kovariansen mellan datapunkterna  $x_i$  och  $x_j$ . Medelvärdesvektorn  $m(x)$  antas ofta till noll eftersom att det framförallt är just kovariansen i data man vill beskriva. Notera att antagandet om en multivariat normalfördelning är betydligt mer generellt än en variabel som i sig är normalfördelad.

Genom antagandet om multivariat normalfördelning (här blir varje datapunkt  $x_i$  en egen dimension) kan prediktioner göras för nya värden på  $x^*$  som ännu inte observerats. Detta görs genom kända statistiska samband för simultanfördelning av normalfördelningar. Genom dessa antaganden fås  $Y(x^*)$  med ett medelvärde  $m(x^*)$  och tillhörande varians  $k(x^*, x^*)$  för de nya  $x^*$  man söker.

Variansen kring det predikterade värdet tolkas vanligen som osäkerheten i prediktionen, vilket är värdefullt för att sätta larmgränser vid avvikelstdetektion. En detaljerad beskrivning av Gaussisk processregression finns fritt tillgänglig som elektronisk bok (Rasmussen & Williams, (2005)) och en introduktion till GPR och maskininläring finns i Bishop, (2006). För en illustration, se Figur 27.



Figur 27. (a) Tre funktioner dragna från en Gaussisk processfördelning. (b) Intervall för prediktioner av mätvärden och tre funktioner dragna från samma GPR som i (a) och fem mätvärden markerade med plustecken. Från Rasmussen & Williams, (2005).

Modellantagandet för GPR ska ses som mycket generellt och flexibelt. Ofta så används uttrycket mjuk regression (engelska smooth) för att påpeka att GPR kan användas för ett stort antal olinjära funktioner. Dess flexibilitet i kombination med osäkerhetsskattningar av predikterade värden har resulterat i ett stort antal publikationer med olika tillämpningsområden.

En annan anledning till att GPR har blivit populär är att den i viss mån är **oparametrisk**. Det innebär att regressionsparametrar inte skattas explicit såsom med MLR eller PLS. Istället väljs ett antal hyperparametrar som styr hur kovariansfunktionen beskrivs. Skattningen av hyperparametrar sker tillsammans med ett träningsdataset och sker vanligen genom optimering, men till skillnad från neurala nätverk begränsas risken för överanpassning. Som med alla icke-linjära optimeringsproblem finns dock en risk att optimering av hyperparametrar fastnar i s.k. lokala optimum, vilka motsvarar en suboptimal och kanske direkt dålig regressionsmodell. Risken för detta kan reduceras med användning av avancerade beräkningsmetoder, se Oscar Samuelsson et al., (2017).


En viktig del när GPR används är att välja lämpliga kovariansstrukturer ("kernels"). Dessa kan användas för att modellera olika "högnivåmönster" i data såsom trender, periodicitet och olika typer av brus. Försök att automatgenerera modeller och tolka data utifrån dessa datamönster har genomförts av Duvenaud., (2014). GPR har tillämpats både med statistiska och tidsseriesdata och det pågår forskning om hur dynamiska tillståndsmodeller kan appliceras, se Svensson, (2018).

Den främsta begränsningen med GPR är att antalet träningsdata i praktiken begränsas till ett tiotusental datapunkter. Detta på grund av en matrisinvertering

som kräver exponentiellt ökande beräkningskraft med antal träningsdata. Det finns dock metoder för att approximeras och välja ut ett mindre antal representativa punkter för att på så sätt ändå kunna använda stora datamängder.

#### 4.4.6 Supportvektorregression

Supportvektormaskiner är en klassificeringsmetod som delar in indata i klasser genom att definiera en klassgräns baserat på datapunkter nära gränsen, s.k. supportvektorer, se Figur 28. I grundbeskrivningen sker delningen med linjära gränser men det är relativt enkelt att transformera data med avbildningar s.k. kärnfunktioner ("kernels") så att klassgränserna kan vara olinjära. Supportvektormaskiner kräver normalt sett data från båda klasserna, d.v.s. data från både normala och felaktiga moder.



Figur 28. En supportvektormaskin anger gränsen mellan två klasser med hjälp av datapunkter nära gränsen, s.k. supportvektorer. Figur av Larhmam - Own work, CC BY-SA 4.0, <https://commons.wikimedia.org/w/index.php?curid=73710028>.

Supportvektorregression, å andra sidan, representerar utdata som en regression av en viktvektor och en icke linjär transformation av indata till ett högdimensionellt rum. Data som ligger närmare prediktionen än ett visst värde ignoreras, vilket ger skydd mot överanpassning, Vesna Ranković et al., (2014).

En introduktion till supportvektorer och icke linjära transformationer (kärnfunktioner/kernels) ges i Bishop, (2006) med ett flertal referenser till olika tillämpningssätt, inklusive klassificering baserat på enbart normala data.


#### 4.4.7 Neurala Nätverk

Ett neuralt nätverk söker efterlikna den mänskliga hjärnans funktion. Det finns många typer av neurala nätverk, men de flesta har det gemensamt att de byggs upp av neuroner. Neuronerna ska efterlikna en nervcell. En neuronnod kombinerar ihop flera indata med hjälp av olika vikter och applicerar en icke linjär s.k. aktiveringsfunktion på dem för att beräkna ett utdatavärde.

Aktiveringsfunktionen är ofta sigmoid eller baserad på någon hyperbolisk trigonometrisk funktion. Den har typiskt långsamt varierande derivata. För mer information om neurala nätverk, se t ex Haykin, (1994) eller Duda et al., (2006).

I ett feed forward-nätverk placeras neuronerna ut i olika lager, där varje lager endast ser utdata från tidigare lager. Det första lagret tar in indata, och det sista lagrets utdata ger prediktionen av mätdata. Att träna ett neuralt nätverk handlar om att ställa in vikterna i samtliga neuroner och eventuellt också aktiveringsfunktionerna, om dessa har någon parameter som kan styras.


I moderna s.k. convolutional neural networks (CNN) används många lager av neuroner, och varje neuron kan se hela eller en del av föregående lager. Utdata kan också beräknas genom att falta indata med varandra eller med en aktiveringsvektor, och sedan appliceras en icke-linjär funktion. Dessa CNN är populära i s.k. deep learning, se t ex Ptucha et al., (2019).



Figur 29. Ett neuralt nätverk av feed forward-typ består av neuroner ordnade i olika lager. Från Tayfur et al., (2005)

#### 4.5 TIDSERIEMODELLER – LINJÄRA OCH ICKELINJÄRA

Till skillnad från data i allmänhet utgörs tidsreier av sekvenser av observationer gjorda över tiden, oftast med samma tidsavstånd. Tidsavståndet mellan närliggande datapunkter kallas samplingsintervall. Närliggande värden i en tidsserie är ofta korrelerade. Figur 30 ger ett exempel på två korrelerade tidsreier. Man anar att CO2 ligger efter GasFlow och att en ökning av GasFlow ger en minskning av CO2. En relativt lättillgänglig referens för tidsserieanalys är G.E.P. Box et al., (1994) och en mer detaljerad genomgång kan fås i signalbehandlingsliteratur, t ex Proakis & Manolakis, (2007).




Figur 30 Tidserie för ett gasflöde och resulterande CO2-halt med samplingsintervallet 9 minuter. Data är skalade så att man kan se tidsförskjutningen mellan signalerna.

Graden av självkorrelation i en signal kan man undersöka genom att bilda **autokorrelations-funktionen**, akf. För en tidsserie  $x$  med reella värden kan den beräknas som

$$r_{xx}(k) = \frac{1}{\sigma^2} \frac{1}{N - k + 1} \sum_{n=k}^N x(n)x(n - k)$$

där  $r(k)$  är autokorrelationen vid en fördröjning av  $k$  steg,  $\sigma^2$  är variansen av  $x$  och  $N$  är antalet värden i tidsserien. Autokorrelationen vid fördröjning 0 är alltid 1.

I Figur 31 ser vi att signalen GasFlow korrelerar med sig själv i cirka 15 tidssteg.



Figur 31 Autokorrelationsfunktionen för signalen i figuren ovan.


Korrelationen mellan två signaler undersöker man med korskorrelations-funktionen, kkf. Den definieras på liknande sätt som autokorrelationsfunktionen.



Korskorrelationen mellan  $x$  och  $y$  är

$$r_{xy}(k) = \frac{1}{\sigma_x \sigma_y} \frac{1}{N - k + 1} \sum_{n=k}^N x(n)y(n - k)$$

Figur 32 visar korskorrelationen mellan tidsserierna GasFlow och CO<sub>2</sub>. Man ser att CO<sub>2</sub> ligger 5 tidssteg efter GasFlow och att korrelationen då är -0.94.



Figur 32 Korskorrelationsfunktionen mellan GasFlow och CO<sub>2</sub>.

Enligt Nyquists teorem räcker det att sampla en signal med en frekvens som är dubbelt så hög som den högsta frekvensen i signalen, se t ex Hayes, (1996). Om precisionen i de samplade värdena är oändlig kan man då återskapa den underliggande analoga signalen utan fel. I praktiken är signaler sällan helt begränsade till ett visst frekvensband; även om det mesta av energin i signalen ligger under en viss frekvens finns nästan alltid lite grann över denna frekvens. Därför applicerar man typiskt ett lågpasfilter före sampling. Detta tar bort de delar av signalen som har frekvenser över halva samplingsfrekvensen, så att dessa inte ger upphov till störningar i den samplade signalen. Detta lågpasfilter kallas också anti-aliasing-filter; aliasing är de störningar som uppkommer om vi samplar med en frekvens som ligger under två gånger den högsta frekvensen i signalen. På grund av att filter inte har oändligt brant frekvensrespons och för att minska fel på grund av begränsad upplösning samplar man i praktiken ofta fortare än två gånger den högsta frekvensen i signalen. Fem gånger denna frekvens är ett värde som har används som tumregel och i dammsäkerhetstillämpningar.

Autokorrelationsfunktionen påverkas av samplingsfrekvensen. För att förstå detta behöver vi inse att den diskreta autokorrelationen som gäller för en samplad signal kan ses som en samplad version av den kontinuerliga autokorrelationen som gäller för den kontinuerliga signalen. I figuren ovan korrelerade signalen med sig själv i ca 15 tidssteg. Om vi inte vet hur fort den här signalen är samplad, så vi skriver den obekanta samplingsfrekvensen som  $f$ . 15 tidssteg motsvarar  $15 \cdot 1/f$  sekunder. Signalen korrelerar alltså med sig själv i ca  $15/f$  sekunder. Om signalen skulle ha samplats dubbelt så fort, alltså med frekvensen  $f' = 2f$ , skulle den korrelera med sig själv 30 tidssteg (då  $15/f = 30/f'$ ). Detta innebär alltså inte att signalen har en längre korrelationslängd i fysikaliska enheter, men det ser ut så räknat i antal tidssteg.

Vi har sett att vissa mätvärden från en damm reagerar med en fördröjning på ändringar i miljövariabler. En modell som är byggd för att modellera sådana situationer är moving average-modellen, eller MA-modellen som den ofta kallas. En MA-modell beskriver ett mätvärde  $y(n)$  som en linjär kombination av nuvarande och tidigare värden på en insignal  $x(n)$ ,

$$\hat{y}(n) = b_0x(n) + b_1x(n-1) + b_2x(n-2) + \dots + b_Mx(n-M)$$

Koefficienterna kan uppskattas med Durbins metod, se t ex Hayes, (1996).

En autoregressiv modell beskriver ett mätvärde  $y(n)$  som en linjär kombination av tidigare mätvärden,

$$\hat{y}(n) = a_1y(n-1) + a_2y(n-2) + \dots + a_My(n-M)$$

Antalet tidigare mätvärden  $M$  som används för prediktionen kallas för AR-modellens ordning. AR-modeller är lätta att uppskatta från data och har använts flitigt i många olika fält, t ex för taligenkänning. De lämpar sig väl för data som har ett antal dominerande frekvenser (toner), alltså periodiska data. Koefficienterna i en AR-modell kan identifieras med Yule-Walkers metod, se t ex Hayes, (1996).

En kombination av AR- och MA-modellerna är ARMA-modellen,

$$\hat{y}(n) = b_0x(n) + b_1x(n-1) + b_2x(n-2) + \dots + b_Mx(n-M) + a_1y(n-1) + a_2y(n-2) + \dots + a_My(n-M)$$

Linjära förändringar i medelvärdet av  $y(n)$  kan hanteras i en ARIMA-modell, där  $I$  står för integrated. Man beräknar differensen mellan successiva mätvärden och får då en signal med konstant medelvärde. Denna kan modelleras med en ARMA-modell.

En AR-modellerad signal i brus kan modelleras genom att skriva  $y(n) = s(n) + w(n)$  där  $s$  är signal och  $w$  är brus och utöka modellen till en constrained autoregressive moving average (CARMA)-modell, Johansson & White, (2011). Sådana modeller har med framgång använts för att identifiera och följa smalbandiga signaler i brus i flera fält t ex telekommunikation och sonar. Om systemet inte är stationärt kan det under vissa förhållanden modelleras med en tidsvarierade AR-modell. Om tidsvariationen i AR-koefficienterna kan antas vara långsam kan denna parametreras t ex som ett polynom i tiden, vilket ger en modell med konstanta parametrar som kan uppskattas med minstakvadratlösning, Johansson & White, (2008).

För att ta hänsyn till beroendet av flera indata kan man ta med dessa i modellen, vilken då kallas en exogen AR-modell (ARX). En ARX-modell som predikterar nuvarande mätvärde  $y(n)$  baserat på tidigare värden av  $y(n)$  och nuvarande och tidigare värden av indata  $x(n)$  och  $v(n)$  kan skrivas som

$$\hat{y}(n) = b_0x(n) + b_1x(n-1) + b_2x(n-2) + \dots + b_Nx(n-N) + \dots + c_0v(n) + c_1v(n-1) + c_2v(n-2) + \dots + c_Qv(n-Q)$$

Här används  $M$  tidigare värden av mätvärdet  $y$ ,  $N+1$  värden av insignalen  $x(n)$  och  $Q+1$  värden av insignalen  $v(n)$ .

En AR-modell använder i sin ursprungsform endast en linjärkombination av nuvarande och tidigare värden, men värdena transformeras inte på något sätt. En icke-linjär ARX-modell (NARX) använder en funktion av nuvarande och tidigare indata och tidigare utdata,

$$\hat{y}(n) = f(y(n-1), \dots, y(n-M), x(n), \dots, x(n-N), v(n), \dots, v(n-Q))$$


istället för en linjärkombination av dem som AR- och ARX-modellerna. NARX-familjen öppnar också andra möjligheter att använda den stora verktygslåda med signalbehandlingsteori som tagits fram för användning i andra fält.

Hellgren et al., (2019) säger att ett problem med AR-modeller är att de anpassar sig efter data. Med detta menar de att om mätvärdet börjar avvika från normalt beteende kommer detta att påverka prediktionen av nästa mätvärde, så att en avvikelse kanske inte upptäcks. De antar då implicit att man använder en AR-modell av låg ordning och/eller en modell där det senaste mätvärdet har stor vikt i prediktionen av nuvarande värde. Detta är en fara som man måste se upp med; om det i urvalet av regressorer för AR-modellen endast finns sådana som har lägre tidsfördröjningar än vad som är fysikaliskt lämpligt kan den bästa AR-modellen från dessa regressorer bli den konstanta modellen att nuvarande data bäst kan förutsägas som lika med föregående data. Men om modellordningen är tillräckligt hög att en bättre modell kan tas fram utgående från regressorerna så är chansen stor att detta inte blir fallet (val av rätt modell är inte utan sina svårigheter). Det är sunt att jämföra residualer och koefficienter för en skattad AR-, ARX- och NARX- modell med de som gäller för den naiva modellen att nuvarande data är lika med föregående. Piroddi & Spinelli, (2003) använde data med en dags upplösning och tog fram modeller som skilde sig stort från de den naiva.

#### 4.6 STATISTISK PROCESSKONTROLL, SPC


Statistisk processkontroll (Statistical Process Control) är ett samlingsnamn för statistiska metoder för processövervakning, se "Statistical process control," (2019). Normalt avser SPC metoder för en variabel i taget. Syftet är att kontrollera att processen beter sig normalt och fånga avvikelser.

Den enklaste varianten är **Shewhart**-diagrammet, Figur 33. De övre och undre streckade linjerna anger diagrammets larmgränser (ofta kallade UCL och LCL, upper resp. lower control limits). I Shewhartfallet utgörs de av  $\pm 3$  standardavvikelser för den övervakade variabeln.




Figur 33 Shewhartdiagram för signalen GasFlow. Det finns 4 gränser inlagda,  $\pm 2$  och  $\pm 3$  standardavvikelser, skattad från data.

XbarR och XbarS är varianter på Shewhart, med grupperade data. De möjliggör övervakning också av signalens spridning. Data delas upp i grupper och för varje grupp beräknas medelvärde (Xbar) och spridning (R respektive S). R är intervall och S är standardavvikelse.




Figur 34 XbarS: Xbar (övre) och S(undre)-diagram för GasFlow med gruppstorleken 10.

EWMA är ett diagram där varje värde är ett exponentiellt glidande medelvärde, som uppdateras med lambda gånger det senaste värdet. Lambda ligger i intervallet 0–1. Ju lägre, desto mindre uppdatering med senaste värdet. Vid  $\lambda = 1.0$  (inget minne) blir EWMA = Shewhart.



Figur 35 EWMA diagram för GasFlow med  $\lambda = 0.5$ . Vid tidsteget ca 30 avviker processen från sitt medelvärde.

CuSum är en kraftfull metod för att upptäcka trendavvikelse från ett börvärde. Man summerar avvikelserna från börvärdet och plottar denna summa som funktion av tiden.



Figur 36 CuSum diagram för GasFlow. Vid tidsteget ca 30 avviker processen från sitt medelvärde.

#### 4.6.1 Multivariat Statistisk processkontroll, MSPC

MSPC utvidgar SPC till att även omfatta multivariata data. I stället för SPC på enskilda variabler gör man SPC på de multivariata principal- eller PLS-komponenterna, samt residualerna. Följande referenser ger en introduktion till MSPC: Wikstrom et al., (1998a), Wikstrom et al., (1998b) samt Nomikos & MacGregor, (1995).

## 5 Rekommendationer

Vi ger här några rekommendationer för vidare arbete med dammövervakning med datadrivna metoder. Litteraturen visar att det finns många datadrivna metoder som kan och har tillämpats på dammövervakning. Det finns även datadrivna system i drift för dammövervakning.

Vi tänker oss ett dammövervakningssystem i två steg:

1. prediktion av mätdata från miljövariabler och/eller tidigare mätdata
2. detektion av anomalier genom jämförelser med prediktionerna.

Det finns mycket skrivet om maskininlärningsmetoder, och de flesta studier pekar på att de kan prestera bättre än standardmodellen HST för att prediktera mätvärden. Men **storskalig utvärdering på data från flera dammar** har inte publicerats. Vi ser det som den viktigaste komponenten i ett vidare arbete.

**Utvärdering av maskininlärningsmetoder i jämförelse med HST på realistiska data, inklusive sensorfel och andra kvalitetsproblem** som förekommer i dessa, bör vara det viktigaste steget att ta. Här bör man dra nytta av befintlig arkitektur för datainsamling och de stora mängder data som finns insamlade. Man börjar lämpligen med enkla metoder och utvärderar var brister finns och hur de kan åtgärdas.

De metoder vi ser att man bör titta närmare på i en framtida studie är

- PLS och PCA för förbättrad modellidentifiering och hantering av korrelerade givare
- Tidsseriemodeller för tidsförskjutna data och de signalbehandlingsteorier som kan stötta identifiering och urval av dessa modeller
- Någon modern ickelinjär maskininlärningsmetod

Tidigare studier har rekommenderat olika maskininlärningsmetoder, men det finns ingen överensstämmelse om vilken som är lämpligast. Jämförelser av olika maskininlärningsmetoder har gjorts, men inga slutsatser om varför en viss metod presterade bättre än en annan har dragits. I en sådan säkerhetskritisk tillämpning som dammsäkerhet är det viktigt med **förståelse**. Detta gör att man bör välja en **relativt enkel metod**, t ex de klassiska neurala nätverken av feed-forward-typ som har använts i många tidigare studier.

**Förbehandling av data** är en viktig del i hantering av verkliga data. Här bör man utföra statistiska tester för att undersöka om dammstrukturen beter sig på ett stationärt sätt i datafönster med olika längd. Detta ger värdefull information till implementationen av modelleringen av data. Uppdelning av data i fönster i vilka data kan anses vara stationära har visats på dammsäkerhetsdata i litteraturen, även om modellerna i den studien troligen var överanpassade. Sådan uppdelning är värd att studera om dammens beteende inte är stationärt. Även adaptiva modeller med ett glidande fönster i vilket data kan antas vara stationära är aktuella.

Det allra första man ska göra är att **lära känna data**, se avsnitt 4. Man bör plotta histogram, tidsserier, auto- och korskorrelationsfunktioner och dra slutsatser om datas egenskaper. Dessa egenskaper är viktiga att ta hänsyn till i utvecklingen av det datadrivna dammsäkerhetssystemet. Vissa maskininlärningsmetoder kanske inte ens är värda att implementera på det aktuella data, och då bör det beslutet tas så tidigt som möjligt för att arbetet ska kunna bedrivas effektivt. På data från t ex seismiska och akustiska givare kan **spektralanalys** användas för att karaktärisera dammens beteende och detektera och identifiera olika typer av anomalier. Filtrering kan användas som förbehandling och för att förstärka intressant information. Wavelets ger möjlighet till anpassad tid-frekvensupplösning och har tidigare använts med framgång vid tidsserieanalys. De kan implementeras i glidande fönster. Resultaten kan jämföras med spektrogram (STFT).

En viktig del i utvecklingen av en datadriven dammövervakning är att hänsyn till alla relevanta miljövariabler. Det finns tidigare resultat om hur man kan ta hänsyn till **regn**, men inget om **snö och snösmältning**. Eftersom snösmältning kan ge stora bidrag till vattenflöden är det mycket viktigt att man tar fram en metod för att mäta snösmältning och integrerar dessa mätdata i prediktioner av dammätdata.

**Placering av givare** är en viktig fråga som man bör studera närmare. Flera författare har visat att redundans och korrelation mellan givare starkt underlättar detektion och till och med korrektion av sensorfel. Tätt placering av givare bör därför bidra till att ett övervakningssystem blir pålitligt. Hur tätt givarna bör placeras behöver undersökas närmare.

Man bör börja med att implementera enkla metoder för **anomalidetektion** såsom de som beskrivs i avsnitt 4.6. Här kan PCA och PLS användas för förbehandling av data. Man bör sedan implementera statistiska metoder för avvikardetektion i syfte att försöka få bättre prestanda.

Att **skilja på anomalier i sensorerna och anomalier i strukturen** är en svår och viktig fråga som behöver studeras vidare. Nylig utkom Ma et al., (2019) med en artikel som behandlar detta för structural health monitoring. Den använder generalized likelihood ratio (GLR), alltså kvoter av de uppskattade sannolikheterna att data kommer från en oskadad struktur med fungerande sensorer, att de kommer från en oskadad struktur med felaktiga sensorer, och att de kommer från en skadad struktur. GLR-kvoter för varje sensor samlas ihop till nya signaler. Dessa signaler används som indata till en PCA. Tidigare har man visat att scorevärden för den första principalkomponenten är känsliga för sensorfel. Detta används för att utveckla en detektor som reagerar på sensorfel. Denna metod antar att data är Gaussiskt fördelade, och kan därför vara svår att direkt överföra till dammsäkerhetsövervakning. Men det är värt att studera om den kan utvidgas till data med andra fördelningar som är mer realistiska. Det finns även andra metoder som kan användas.

En fördel med GPR för avvikelседetektion är att man kan använda variansbanden kring predikterade värden för att **automatiskt ställa in statistiskt baserade larmgränser**. Genom att basera en GPR-modell på enbart normala data, skapas ett tillhörande variationsband för prediktioner för normala data.



Det är dock viktigt att förstå att variansbanden baseras på kovariansen i data och därmed inte speglar alla underliggande variationer. Förhållandet mellan process, brus och kovariationer är något som behöver studeras separat för varje specifikt dataset för att avgöra hur relevanta variansbanden är att använda som larmgränser.

**Aktiv feldetektion** innebär att man aktivt stimulerar damm och/eller magasin och söker anomalier i de resulterande sensorsignalerna. Detta har testats i ett fåtal dammstudier utomlands där man injicerade värme och mätte temperatur, t ex Ndour et al., (2016), men såvitt vi vet har aktiv feldetektion enbart testats för VA-tillämpningar i Sverige. Om man har möjlighet bör stimulinen väljas på ett klokt sätt för att få ut så mycket information som möjligt om den studerade strukturen. Detta avhandlas bl. a i Nikoukhah & Campbell, (2006). Sådan möjlighet ges troligen om man jobbar med seismik, men troligen inte med värme (på grund av de långa tidskonstanterna).

Sist, men inte minst, är det viktigt att **höja kompetensen kring data och datadrivna metoder** hos de som ska använda metoderna. En **föreläsningsserie** i ämnet bör vara en viktig del i implementationen.

## 6 Referenser

- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716-723. doi:10.1109/TAC.1974.1100705
- Benda, S. (1996). *Störningsfri elektronik, elektromagnetisk kompatibilitet* (2nd ed.). Lund: Studentlitteratur.
- Berglund, A., Kettaneh, N., Uppgård, L., Wold, S., Bendwell, N., & Cameron, D. R. (2001). The GIFI approach to non-linear PLS modeling. *Journal of Chemometrics*, 15(4), 321-336. doi:10.1002/cem.679
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. United States of America: Springer.
- Björk, A. (2007). *Chemometric and signal processing methods for real time monitoring and modeling using acoustic sensors Applications in the pulp and paper industry. Doctoral Thesis*. Royal Institute of Technology School of Chemical Science and Engineering Department of Chemistry Division of Analytical Chemistry, Stockholm. Retrieved from <http://kth.diva-portal.org/smash/get/diva2:12066/FULLTEXT01>
- Björk, A., Fridén, H., Andersson, S., & Tönnfors, E. (2016). *Goda råd för integrerad design inom processindustri*. Retrieved from
- Bonelli, S., Tourment, R., & Felix, H. (2003, 9-11 Oct 2003). *Analysis of earthdam monitoring data*. Paper presented at the Selected Problems of Water Engineering, Krakow, Poland.
- Box, G. E. P., & Cox, D. R. (1964). An Analysis of Transformations. *Journal of the Royal Statistical Society. Series B (Methodological)*, 26(2), 211-252.
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (1994). *Time series analysis. Forecasting and control. Time series analysis. Forecasting and control*. Engelwood Cliffs: Prentice-Hall.
- Colton, T. (1974). *Statistics in medicine*. Boston: Little, Brown and Company.
- Dam safety performance monitoring and data management – best practice*. (2014). Retrieved from <https://energiforskmedia.blob.core.windows.net/media/18414/dam-safety-performance-monitoring-and-data-management-kortversion-energiforskrapport-2014-9.pdf>
- Dam surveillance guide. ICOLD Bulletin 158*. . (2018). ICOLD.
- De Sortis, A., & Paoliani, P. (2007). Statistical analysis and structural identification in concrete dam monitoring. *Engineering Structures*, 29(1), 110-120. doi:<https://doi.org/10.1016/j.engstruct.2006.04.022>
- Duda, R. O., Hart, P. E., & Stork, D. G. (2006). *Pattern Classification* (2nd ed.): Wiley Interscience.
- Dunia, R., Joe Qin, S., Edgar, T. F., & McAvoy, T. J. (1996). Use of principal component analysis for sensor fault identification. *Computers & Chemical Engineering*, 20(Supplement 1), S713-S718.
- Duvenaud, D. K. (2014). *Automatic Model Construction with Gaussian Processes*. (PhD thesis), University of Cambridge.
- Eriksson, L. B., T. Johansson, E. T., J., & Vikström, C. (2003). *Multi- and Megavariate Data Analysis. Principles and Applications: Umetrics*.
- Fisher, W. D. (2017). *Machine learning for the automatic detection of anomalous events*. (PhD), Colorado School of Mines.
- Gamse, S., & Oberguggenberger, M. (2017). Assessment of long-term coordinate time series using hydrostatic-season-time model for rock-fill embankment dam. *Structural Control and Health Monitoring*, 24(1), e1859. doi:10.1002/stc.1859
- GOCA - GNSS/LPS/LS-based online Control and Alarm System. (2019). Retrieved from [www.goca.info](http://www.goca.info)
- Goi, Y., & Kim, C.-W. (2017). Bayesian outlier detection for health monitoring of bridges. *Procedia Engineering*, 199, 2120-2125. doi:<https://doi.org/10.1016/j.proeng.2017.09.073>
- Hayes, M. H. (1996). *Statistical digital signal processing and modelling*: Wiley.
- Haykin, S. S. (1994). *Neural Networks: a comprehensive foundation* (1st ed.). Indianapolis, USA.: Macmillan Publishing Co.
- Hellgren, R., Malm, R., & Nordström, E. (2019). *Modeller för övervakning av betongdammar* (2019:580). Retrieved from

- Huang, H.-B., Yi, T.-H., & Li, H.-N. (2017). Sensor Fault Diagnosis for Structural Health Monitoring Based on Statistical Hypothesis Test and Missing Variable Approach. *Journal of Aerospace Engineering*, 30(2), B4015003. doi:doi:10.1061/(ASCE)AS.1943-5525.0000572
- Johansson, A. T., & White, P. R. (2008). Instantaneous frequency estimation at low signal-to-noise ratios using time-varying notch filters. *Signal Processing*, 88(5), 1271-1288. doi:https://doi.org/10.1016/j.sigpro.2007.11.014
- Johansson, A. T., & White, P. R. (2011). An adaptive filter-based method for robust, automatic detection and frequency estimation of whistles. *The Journal of the Acoustical Society of America*, 130(2), 893-903. doi:10.1121/1.3609117
- Johansson S., N. Å., Garner S., Dahlin T., Friborg J. & Sjö Dahl P. . (2005). *Internal erosion detection at the Rössvatn test site – experiences from blind test using resistivity, self potential, temperature and visual inspection* (05:42). Retrieved from
- Jäger, R., & Gonzalez, F. (2005, March 7-19). *GNSS/GPS/LPS based Online Control and Alarm System (GOCA) - Mathematical Models and Technical Realisation of a System for Natural and Geotechnical Deformation Monitoring and Hazard Prevention*. Paper presented at the IAG Symposium, Jaen, Spain.
- k-nearest neighbors algorithm. (2019). Retrieved from https://en.wikipedia.org/wiki/K-nearest\_neighbors\_algorithm
- Kullaa, J. (2013). Detection, identification, and quantification of sensor fault in a sensor network. *Mechanical Systems and Signal Processing*, 40(1), 208-221. doi:https://doi.org/10.1016/j.ymssp.2013.05.007
- Lag (2003:778) om skydd mot olyckor, (2003).
- Li, L., Liu, G., Zhang, L., & Li, Q. (2019). Sensor fault detection with generalized likelihood ratio and correlation coefficient for bridge SHM. *Journal of Sound and Vibration*, 442, 445-458. doi:https://doi.org/10.1016/j.jsv.2018.10.062
- Ma, S.-L., Jiang, S.-F., & Li, J. (2019). Structural damage detection considering sensor performance degradation and measurement noise effect. *Measurement*, 131, 431-442. doi:https://doi.org/10.1016/j.measurement.2018.08.040
- Massart, D. L., Vandeginste, B. G. M., Buydens, L. M. C., De Jong, S., Lewi, P. J., & Smeyers-Verbeke, J. (1997a). Multiple and Polynomial Regression. Introduction, Estimation of the regression parameters and Multicollinearity *Handbook of Chemometrics and Qualimetrics: Part A* (pp. 263-270 & 286-288). Amsterdam: Elsevier.
- Massart, D. L., Vandeginste, B. G. M., Buydens, L. M. C., De Jong, S., Lewi, P. J., & Smeyers-Verbeke, J. (1997b). Straight Line Regression and Calibration. Regression when both the predictor and the response variable are subject to error *Handbook of Chemometrics and Qualimetrics: Part A* (pp. 213-216). Amsterdam: Elsevier.
- Mata, J. (2011). Interpretation of concrete dam behaviour with artificial neural network and multiple linear regression models. *Engineering Structures*, 33(3), 903-910. doi:https://doi.org/10.1016/j.engstruct.2010.12.011
- Mata, J., Tavares de Castro, A., & Sá da Costa, J. (2014). Constructing statistical models for arch dam deformation. *Structural Control and Health Monitoring*, 21(3), 423-437. doi:10.1002/stc.1575
- Methods of analysis for the prediction and the verification of dam behaviour*. (2003). Paper presented at the 21st Congress of the International Commission on Large Dams, Montreal, Canada.
- Mohlin, B., & Åström, A. (2019). *Erfarenheter Av Damminstrumentering*. Retrieved from https://www.energiforsk.se/media/26301/erfarenheter-av-damminstrumentering-energiforskrapport-2019-577.pdf
- Ndour, M., Chang, K. T., & Hossain, S. I. (2016, 5-6 Nov 2016). *Leakage detection in dam and reservoir using optical fiber cable sensor (FOCS) based on active method*. Paper presented at the The 52nd IRES International Conference, Kuala Lumpur, Malaysia.
- Nikoukhah, R., & Campbell, S. L. (2006). Auxiliary signal design for active failure detection in uncertain linear systems with a priori information. *Automatica*, 42(2), 219-228. doi:https://doi.org/10.1016/j.automatica.2005.09.011

- Nilsson, Å. (2014). *Dam safety performance monitoring and data management – best practices. Svensk kortversion och reflektioner*. Retrieved from
- Nomikos, P., & MacGregor, J. F. (1995). Multivariate spc charts for monitoring batch processes. *Technometrics*, 37(1), 41-59.
- Panizzo, A., & Petaccia, A. (2009, 2009//). *Analysis of Monitoring Data for the Safety Control of Dams Using Neural Networks*. Paper presented at the New Trends in Fluid Mechanics Research, Berlin, Heidelberg.
- Piroddi, L., & Spinelli, W. (2003, 9-12 Dec. 2003). *Long-range nonlinear prediction: a case study*. Paper presented at the 42nd IEEE International Conference on Decision and Control (IEEE Cat. No.03CH37475).
- Prakash, G., Sadhu, A., Narasimhan, S., & Brehe, J.-M. (2018). Initial service life data towards structural health monitoring of a concrete arch dam. *Structural Control and Health Monitoring*, 25(1), e2036. doi:10.1002/stc.2036
- Principal Component Analysis. (2019). Retrieved from [https://en.wikipedia.org/wiki/Principal\\_component\\_analysis](https://en.wikipedia.org/wiki/Principal_component_analysis)
- Proakis, J. G., & Manolakis, D. K. (2007). *Digital Signal Processing: Principles, Algorithms and Applications*: Pearson.
- Ptucha, R., Petroski Such, F., Pillai, S., Brockler, F., Singh, V., & Hutkowski, P. (2019). Intelligent character recognition using fully convolutional neural networks. *Pattern Recognition*, 88, 604-613. doi:<https://doi.org/10.1016/j.patcog.2018.12.017>
- Pyayt, A. L., Mokhov, I. L., Kozionov, A. P., Kusherbaeva, V. T., Lang, B., Krzhizhanovskaya, V. V., & Meijer, R. V. (2013). Data-driven modelling for flood defence structure analysis. In K. Schreckendiek (Ed.), *Comprehensive flood risk management*. London: Taylor & Francis.
- Pyayt, L. A., Kozionov, P. A., Mokhov, I. L., Lang, B., Meijer, J. R., Krzhizhanovskaya, V. V., & Slood, M. P. (2014). Time-Frequency Methods for Structural Health Monitoring. *Sensors*, 14(3). doi:10.3390/s140305147
- The R Project for Statistical Computing. (2019). Retrieved from <https://www.r-project.org/>
- Radzicki, K., & Bonelli, S. (2008). Impulse response function analysis of pore pressure in earthdams. *European Journal of Environmental and Civil Engineering*, 12(3), 243-262.
- Ranković, V., Grujović, N., Divac, D., & Milivojević, N. (2014). Development of support vector regression identification model for prediction of dam structural behaviour. *Structural Safety*, 48, 33-39. doi:<https://doi.org/10.1016/j.strusafe.2014.02.004>
- Ranković, V., Novaković, A., Grujović, N., Divac, D., & Milivojević, N. (2014). Predicting piezometric water level in dams via artificial neural networks. *Neural Computing and Applications*, 24(5), 1115-1121. doi:10.1007/s00521-012-1334-2
- Rasmussen, C. E., & Williams, C. K. I. (2005). *Gaussian Processes for Machine Learning (Adaptive Computation and Machine Learning)*. Cambridge, Massachusetts.
- RIDAS - Kraftföretagens riktlinjer för dammsäkerhet. (2019). Guideline. Energiföretagen Sverige & Swedenergy AB.
- Robust statistics. (2019). Retrieved from [https://en.wikipedia.org/wiki/Robust\\_statistics](https://en.wikipedia.org/wiki/Robust_statistics)
- S. V. De Simone, M. N. (2018, 15-18 May). *Data management system for dam monitoring of hydropower projects*. Paper presented at the 7th IAHR Symposium on Hydraulic Structures, Aachen, Germany.
- Salazar, F. (2016). *A machine learning based methodology for anomaly detection in dam behaviour*. (PhD PhD), Universitat Politècnica de Catalunya, Barcelona.
- Salazar, F., Morán, R., Toledo, M. Á., & Oñate, E. (2017). Data-Based Models for the Prediction of Dam Behaviour: A Review and Some Methodological Considerations. *Archives of Computational Methods in Engineering*, 24(1), 1-21. doi:10.1007/s11831-015-9157-9
- Salazar, F., Toledo, M. A., Oñate, E., & Morán, R. (2015). An empirical comparison of machine learning techniques for dam behaviour modelling. *Structural Safety*, 56, 9-17. doi:<https://doi.org/10.1016/j.strusafe.2015.05.001>
- Samuelsson, O. (2017). *Fault Detection in Water Resource Recovery Facilities*. (Tekn Lic), Uppsala University.

- Samuelsson, O., Björk, A., Zambrano, J., & Carlsson, B. (2017). Gaussian process regression for monitoring and fault detection of wastewater treatment processes. *Water Science and Technology*, 75(12), 2952-2963. doi:10.2166/wst.2017.162
- Scaioni, M., Marsella, M., Crosetto, M., Tornatore, V., & Wang, J. (2018). Geodetic and Remote-Sensing Sensors for Dam Deformation Monitoring. *Sensors*, 18(11), 3682.
- Siegel, S. (1956). *Nonparametric statistics for the behavioral sciences* (International student ed ed.). New York ; London: McGraw-Hill.
- Simon, A., Royer, M., Mauris, F., & Fabre, J. (2013). *Analysis and interpretation of dam measurements using artificial neural networks*. Paper presented at the 9th ICOLD European Club Symposium, Venice, Italy.
- Sjödahl, P., Johansson, S., & Dahlin, T. (2019). *Geofysiska metoder inom dammsäkerhetsområdet - en kunskapssammanställning* (Rapport 2019:571). Retrieved from
- Statistical process control. (2019). Retrieved from [https://en.wikipedia.org/wiki/Statistical\\_process\\_control](https://en.wikipedia.org/wiki/Statistical_process_control)
- Stepwise regression. (2019). Retrieved from [https://en.wikipedia.org/wiki/Stepwise\\_regression](https://en.wikipedia.org/wiki/Stepwise_regression)
- Stojanovic, B., Milivojevic, M., Ivanovic, M., Milivojevic, N., & Divac, D. (2013). Adaptive system for dam behavior modeling based on linear regression and genetic algorithms. *Advances in Engineering Software*, 65, 182-190. doi:<https://doi.org/10.1016/j.advengsoft.2013.06.019>
- Svensson, A. (2018). *Machine learning with state-space models, Gaussian processes and Monte Carlo methods*. (1709 Doctoral thesis, comprehensive summary), Acta Universitatis Upsaliensis, Uppsala. Retrieved from <http://urn.kb.se/resolve?urn=urn:nbn:se:uu:diva-357611> DiVA database.
- Tayfur, G., Swiatek, D., Wita, A., & Singh Vijay, P. (2005). Case Study: Finite Element Method and Artificial Neural Network Models for Flow through Jeziorsko Earthfill Dam in Poland. *Journal of Hydraulic Engineering*, 131(6), 431-440. doi:10.1061/(ASCE)0733-9429(2005)131:6(431)
- Thornhill, N. F., Choudhury, M. A. A. S., & Shah, S. L. (2004). The impact of compression on data-driven process analyses. *Journal of Process Control*, 14(4), 389-398.
- Varmuza, K., & Filzmoser, P. (2008). *Introduction to Multivariate Statistical Analysis in Chemometrics* (pp. 1-328). Retrieved from <http://kcl.ebib.com/patron/FullRecord.aspx?p=427098>
- Venkatasubramanian, V., Rengaswamy, R., Yin, K., & Kavuri, S. N. (2003). A review of process fault detection and diagnosis: Part I: Quantitative model-based methods. *Computers & Chemical Engineering*, 27(3), 293-311. doi:[https://doi.org/10.1016/S0098-1354\(02\)00160-6](https://doi.org/10.1016/S0098-1354(02)00160-6)
- Wikstrom, C., Albano, C., Eriksson, L., Friden, H., Johansson, E., Nordahl, A., . . . Wold, S. (1998a). Multivariate process and quality monitoring applied to an electrolysis process: Part I. Process supervision with multivariate control charts. *Chemometr. Intellig. Lab. Syst.*, 42(1-2), 221-231.
- Wikstrom, C., Albano, C., Eriksson, L., Friden, H., Johansson, E., Nordahl, A., . . . Wold, S. (1998b). Multivariate process and quality monitoring applied to an electrolysis process: Part II. Multivariate time-series analysis of lagged latent variables. *Chemometr. Intellig. Lab. Syst.*, 42(1-2), 233-240.
- Wold, S., & Sjostrom, M. (1977). *SIMCA: A method for analyzing chemical data in terms of similarity and analogy*. Paper presented at the Chemometrics Theory and Application, American Chemical Society Symposium Series 52, Wash., D.C.
- Yu, H., Wu, Z., Bao, T., & Zhang, L. (2010). Multivariate analysis in dam monitoring data with PCA. *Science China Technological Sciences*, 53(4), 1088-1097. doi:10.1007/s11431-010-0060-1

# DATADRIVNA METODER FÖR ATT DETEKTERA AVVIKANDE MÄT- VÄRDEN INOM DAMMSÄKERHET

Här beskrivs hur sensorer och datadrivna metoder för analys av sensordata kan användas för att höja säkerheten på svenska dammar. Efter en litteraturstudie av state of the art i dammsäkerhet och en studie av vad som gjorts i andra länder tittar forskarna också på teorier och metoder som ännu inte har använts i dammsäkerhet, men som skulle kunna vara lämpliga.

Det är lätt att komma igång med datadriven analys med hjälp av färdiga verktygslådor som finns öppet tillgängliga. Här diskuteras vanliga fallgropar vid dataanalys och hur de undviks, god modelleringspraktik och vanliga dataeffekter som beror på fel i sensorer eller datainsamlingssystem.

Mycket av den vetenskapliga litteraturen inom datadriven dammsäkerhet handlar bara om tillämpning av maskininlärningsmetoder. Här summeras också resultat om förbehandling av sensordata och hur avvikelser kan detekteras.

Datadrivna metoder för dammsäkerhet är redo att implementeras i Sverige, och kan i kombination med väl utformad instrumentering och rätt givarplacering bidra till väsentligt höjd dammsäkerhet.

## Ett nytt steg i energiforskningen

Energiforsk är en forsknings- och kunskapsorganisation som samlar stora delar av svensk forskning och utveckling om energi. Målet är att öka effektivitet och nyttiggörande av resultat inför framtida utmaningar inom energiområdet. Vi verkar inom ett antal forskningsområden, och tar fram kunskap om resurseffektiv energi i ett helhetsperspektiv – från källan, via omvandling och överföring till användning av energin. [www.energiforsk.se](http://www.energiforsk.se)