



WHEN TRUST MATTERS

Ansvarlig teknologiutvikling

Sikkerhetsforums årskonferanse 2024

Christian Markussen

06 June 2024





Hvilken trender ser vi?




- Mere komplekse systemer
 - Kunstig Intelligens
 - Fysikk-baserte modeller / simuleringsmodeller,
 - Modeller satt sammen til «system-av-systemer»
- Mer integrasjon
 - Data fra mange systemer og disipliner blir brukt av hele organisasjonen
 - Applikasjoner fra forskjellige leverandører blir integrert sammen
 - Integrasjon av OT og IT
- Høyere endringshastighet
 - Utviklings-hastigheten øker i takt med digitaliseringen
 - Benytter «agile» utviklingsprosesser som stammer fra software utvikling
 - Utfordrer organisasjoners styringsmodell for håndtering av data, modeller og teknologiutvikling
- Teknologiene blir mer driftskritisk, både finansielt og sikkerhetsmessig

Sikkerhets-relaterte systemer



Sikkerhets-relaterte systemer



Hva med integrering av KI og fysikk-baserte modeller?

- DNV-RP-A203 Technology Qualification
- ISO/IEC TR 5469 Functional safety
- DNV-RP-0671 Artificial intelligence
- DNV-RP-0665 Machine learning
- ISO/IEC 23053 Framework for AI & ML
- DNV-RP-0497 Data quality
- DNV-RP-0513 Simulation models

Så hva er problemet?




- Manglende standarder og retningslinjer for rådgivning-systemer
- Modeller utviklet og kvalifisert for lavkritiske applikasjoner blir brukt i mere høykritiske applikasjoner
- Rådgivnings-systemer, brukt aktivt i operasjoner med potensiale for storulykker, er implementert i IT systemer / skyløsninger
 - Manglende robusthet og pålitelighet
- «Det er ikke et sikkerhets-system siden vi har menneske-i-loopen»
 - Dette forutsetter at operatøren har riktig situasjons-forståelse basert på informasjon fra systemene
 - Mangler ofte overvåkning av det digitale systemet og metode for å informere operatøren om degradert informasjonskvalitet.
- Integrasjon av avanserte modeller og KI i sikkerhets-relaterte systemer er komplisert og krever en kombinasjon av flere standarder
- Umoden tilnærming på kvalitetssikring av slike systemer
 - Ikke tilstrekkelig å sikre digitale systemer ved «black-box» testing
 - Tre-parts samarbeid → hvordan skal operatøren overholde «påseplikten»?

Menneske-sentrert design



Overvåkningsevne



- Cognitive load
- Situational awareness
- Available time
- Stress & fear

- Human centred design
- HMI design
- Alarm system
- Status / quality indicators

Human capacity

Competence

- Competence and training
- Quality of training
- User manuals


Robustness

Technology interface


Governance

- Management engagement
- Roles & responsibilities
- Procedures


AI – Integrating building and assurance




Conceptual Model



- From experience, most modelling problems stems from a lack of a **Conceptual Model**
- Conceptual Model
 - bridge between reality and the model
 - ensures a common understanding of the model objectives, requirements, assumptions, etc.
 - bridge the gap between the domain expert, the modeller and the end user
- Purpose:
 - provide a model specification for the intended application
 - basis for verification and validation of the model
 - Black-box → Gray or white box verification
 - element in the “duty to ensure”




Conceptual Model



Includes:


- Objectives
- System boundary
- Requirements
- Modelling concepts
- Assumptions
- Risks
- Validation plan (white- or gray-box vs. black-box)

➔ Model specification (verified and agreed)




Building trust into AI algorithms

Bringing all knowledge into AI – not just data




Science-guided AI



- Combine physical-models with data-driven models (“hybrid-models”)
- Include physical constraints into AI
- Use synthetic data for safety-critical scenarios with little data

Uncertainty-aware AI



- AI that knows when it is uncertain
- Avoid confident mistakes
- Tells you when you cannot trust it




Causal AI




- Understands cause-and-effect
- Distinguishing correlations and causation
- Distinguishing observation from intervention

Assure using proper approaches


A combination of technology qualification, risk assessment and assurance case



A mature organisation is the foundation for success¹




the degree to which an organization has processes, procedures and capabilities in place addressing the organizational aspects of developing, maintaining and operating a digital asset



Oppsummering



- Ta menneske-sentrert design på alvor under teknologiutvikling
 - Operatøren som sikkerhetsbarriere → forutsetter riktig situasjons-forståelse
 - Spesifiser hvordan feiltilstander skal detekteres og formidles til operatøren
 - Inkluder spesialister på området
- Integrer kvalifisering og verifikasjon i utviklingsprosessen
 - Planlegg hvordan “påseplikten” skal ivaretas
 - Etabler gode konsept-modeller som alle interessehavere forstår
 - Unngå kvalifisering av komplekse digital modeller som en «black-box»
- Organisasjons-modenhet
 - Høy endringstakt stiller krav til organisasjonsmodenhet
 - Moden organisasjon – en forutsetning kvalitetssikring og vedlikehold av komplekse systemer
 - Gjelder både operatører og leverandører





WHEN TRUST MATTERS

Takk for oppmerksomheten

Spørsmål?

Christian.Markussen@dnv.com

+47 94831307

www.dnv.com

