


# Pilot sluttrapport

## Bildeanalyse i anleggsforvaltning

Author: Kristin Tukun



---

## ***CINELDI - Centre for intelligent electricity distribution***

*SINTEF and NTNU are the main research partners, with grid operators, technology providers, public authorities and international R&D institutes and universities as partners.*

*The research centre is financed by the Research Council of Norway and the Norwegian partners through the Centre for Environment-friendly Energy Research (FME) scheme. The FME scheme consists of research centres of limited duration that conduct concentrated, focused and long-term research on a high international level to solve specific challenges related to energy and the environment.*

---



Centres for  
Environment-friendly  
Energy Research

# Prosjektnotat

TITTEL			
<b>Resultat og erfaringsnotat for Pilot <i>Bildeanalyse i anleggsforvaltning</i></b>			
WORK PACKAGE	VERSJON	DATO	ANTALL SIDER
WP Pilot	1.0	2024-09-20	13
FORFATTER(E)	WP-LEDER	GRADERING	
Kristin Tukun <i>Per-Oddvar Osland</i> <small>Per-Oddvar Osland (Feb 27, 2025 12:24 GMT+1)</small>	Maren Istad <i>Maren Istad</i> <small>Maren Istad (Jan 8, 2025 08:55 GMT+1)</small>	Åpen	

## SAMMENDRAG

Agder Energi Nett drifter et stort nett som strekker seg utover hele Agder. Master, stolper og påmontert utstyr er en del av vedlikeholdsprosessen hvor feil og mulige farer vurderes basert på visuell inspeksjon. Dette gjøres per i dag ved at vedlikeholdsingeniører/ sommerstudenter ser på dronebilder av mastene. Dette er et manuelt arbeid som både er tidkrevende og ressurskrevende. I tillegg kan menneskelige feil føre til feilaktige konklusjoner og dermed redusert kvalitet i arbeidet. Bildeanalyse ved hjelp av maskinlæring kan automatisk detektere og kategorisere feil. Dette kan redusere mengden bilder inspektørene må se gjennom og kunne prioritere hvilke feil som bør behandles først. På denne måten kan kritiske feil detekteres tidlig.

I denne piloten har Agder Energi Nett hatt to pilotpartnere for å prøve ut eksisterende løsninger i markedet. Vi har undersøkt hvordan de lar seg integrere med AEN sine IT-systemer og vedlikeholdsprosesser. Samt å evaluere nytteverdien av bildeanalyse i anleggsforvaltning. Bildeanalysen må fungere slik at man får et akseptabelt nivå av feilklassifisering og det må samtidig være lett å ta i bruk i vedlikeholds prosessen.

Hypotesene som ligger til grunn er at bildeanalyse i anleggsforvaltning skal bidra til:

- Lavere kostnader i vedlikeholdsprosessen
- Bedre forsyningsikkerhet, og dermed redusert KILE-kostnad
- Forbedret HMS (reduert risiko for skade)

Inspektørene ser etter mange forskjellige feil. Da piloten ble gjennomført var ikke algoritmene modne for alle feilene. I samråd med pilotpartnere og våre inspeksjonsingeniører ble vi enige om å prøve å automatisk detektere følgende feil:

Isolator: Skade / Sprekk / Avskalling
Travers: Skadet / Skjev / Råte / Rust
Stolpe: Manglende Topphatt
Stolpe: Hakkespett hull
Stolpe: Råte / Maur / Sopp / Skadet

Det ble valgt ut bilder i områder hvor man hadde en høy forekomst av disse feilene.

# Innholdsfortegnelse

<b>1</b>	<b>Bakgrunnsinformasjon om pilotprosjektet.....</b>	<b>3</b>
<b>2</b>	<b>Om Piloten og fysisk pilotområde.....</b>	<b>5</b>
<b>3</b>	<b>Resultater og innovasjoner fra Piloten.....</b>	<b>6</b>
3.1	Resultater fra delaktivitet 1: Test av integrasjon og vedlikeholdsprogramvare.....	6
3.2	Resultater fra delaktivitet 2: Test av KI modeller 4000 master .....	6
3.3	Resultater fra delaktivitet 3: Test av KI modeller 4000 master – oppdaterte modeller .....	9
3.4	Innovasjoner fra Piloten.....	10
<b>4</b>	<b>Tekniske/faglige erfaringer fra Piloten.....</b>	<b>11</b>
4.1	Oppsummering .....	12
<b>5</b>	<b>Kost-/nyttevurderinger basert på resultatene for Piloten.....</b>	<b>13</b>
5.1	Kostnader .....	13
5.2	Nyttevurderinger .....	13

## 1 Bakgrunnsinformasjon om pilotprosjektet

Tabell 1: Bakgrunnsinformasjon

	Fra malen "planlegging av pilotprosjekt"	Viktige endringer i løpet av pilotperioden
<b>Målsetting</b>	<p>Piloten skal teste ut to eksisterende løsninger for bildeanalyse som del av inspeksjon av linjenett. Det er to hovedmålsetninger/hypoteser:</p> <ul style="list-style-type: none"> <li>• Implementasjon – vurdere hva som må til av teknisk integrasjon og tilrettelegging av arbeidsprosess for å ta i bruk løsning</li> <li>• Bildeanalyse vil bidra til at vedlikeholdsprosessen blir raskere, billigere og med minst like god kvalitet som dagens manuelle prosess.</li> </ul>	
<b>Problemstilling</b>	<p>Som del av inspeksjon av linjenettet, blir det tatt store mengder bilder fra lufta. For Agder Energi Nett utgjør dette flere hundre tusen bilder pr år. For å vurdere tilstanden i nettet og beslutte hvilke tiltak som skal settes i gang, er det nødvendig å inspisere bilder. Dette gjøres i dag manuelt, noe som medfører store kostnader og lang ledetid før tiltak kan settes i gang.</p> <p>Agder Energi Nett ønsker å bruke tilgjengelige produkter/tjenester for bildeanalyse. AEN ser det ikke som hensiktsmessig å selv bygge kompetanse og løsninger på dette feltet, ettersom det vil kreve stor innsats og fokus på KI og IKT-utvikling. En viktig del av prosjektet er derfor å teste ut eksisterende løsninger og vurdere hvor godt disse fungerer. Gjennom 2020 og 2021 gjennomførte AEN er RFI for bildeanalyse, basert på dette ble det valgt to pilotpartnere.</p>	
<b>Aktiviteter</b>	<p>Aktiviteter</p> <ol style="list-style-type: none"> <li>1. Planlegging og systemdesign (AEN og pilotpartner)</li> <li>2. Integrasjon med pilotpartner for overføring av bildemateriale og</li> <li>3. Trening av KI-modeller (pilotpartner)</li> <li>4. Bildeanalyse (pilotpartner)</li> <li>5. Utarbeide rapporter med oversikt over feil/mangler som er funnet (pilotpartner)</li> <li>6. Motta rapporter, integrere resultater i AENS vedlikeholdssystem</li> <li>7. Evaluere resultater med fokus på presisjon i resultater og anvendbarhet</li> </ol>	

	8. Oppsummering, rapportering og presentasjon av resultat.	
<b>Kostnadsestimat</b>	<p>Det er estimert timeforbruk til pilotansvarlig (AE Nett) og 2 pilotdeltagere. Det er lagt opp til at pilotdeltagerne dekker deler av egne kostnader, inkludert kostnader til maskinvare og programvare. I denne oversikten er det kun tatt med kostnader som AE Nett skal dekke. Dialog rundt omfang og innsats i prosjektet pågår, så estimater er derfor usikre.</p> <p>KNOK 1 000 Timeforbruk AE Nett</p> <p>KNOK 500 Timeforbruk, Prosjektpartner 1</p> <p>KNOK 500 Timeforbruk, Prosjektpartner 1</p> <p><u>KNOK 2 000 Sum kostnader</u></p>	
<b>Innovasjonspotensial</b>	Leverandørene kan utvikle sine KI-algoritmer og tilby nye produkter.	
<b>Forventet resultat</b>	<p>Det er forventet at man kan svare tydelig på målsetning/hypoteser (se øverst).</p> <p>Leveranser:</p> <ul style="list-style-type: none"> <li>• Gjennomført bildeanalyse for flere tusen bilder</li> <li>• Rapporter som viser resultat av bildeanalyse</li> <li>• Evaluering av resultat (se under)</li> </ul> <p>Måling og evaluering</p> <p>Teknisk egnethet</p> <ul style="list-style-type: none"> <li>• Måling: Kvalitativ vurdering</li> <li>• Evaluering: Hvor lett/effektivt fungerer systemintegrasjon? Hvor godt fungerer brukergrensesnitt? I hvor stor grad bidrar løsningene til å løse oppgaven?</li> </ul> <p>Tid</p> <ul style="list-style-type: none"> <li>• Måling: Ledetid - Tid det tar fra data er tilgjengelig (bilde blir tatt), til feil/avvik er identifisert</li> <li>• Evaluering: Ledetid er vesentlig kortere enn med manuell prosess</li> </ul> <p>Kvalitet</p> <ul style="list-style-type: none"> <li>• Måling: Presisjon (Evne til å finne faktiske feil) og «Recall» (Evne til å unngå falske positiv)</li> </ul>	

	<ul style="list-style-type: none"> <li>• Evaluering: Kvalitet er minst like god som ved manuell prosess</li> </ul> <p>Kostnad</p> <ul style="list-style-type: none"> <li>• Måling: Driftskostnad (inkl avskrivning på investering) ved automatisert prosess</li> <li>• Evaluering: Driftskostnad er lavere enn ved manuell prosess</li> </ul>																																																															
<b>Tidsplan</b>	<table border="1"> <thead> <tr> <th>Milepæl</th> <th>Frist</th> </tr> </thead> <tbody> <tr> <td>Oppstart</td> <td>01.09.2021</td> </tr> <tr> <td>Avslutning</td> <td>30.12.2022</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th>Aktivitet</th> <th>Q3 21</th> <th>Q4 21</th> <th>Q1 22</th> <th>Q2 22</th> <th>Q3 22</th> <th>Q4 22</th> </tr> </thead> <tbody> <tr> <td>Oppstart</td> <td></td> <td></td> <td></td> <td></td> <td></td> <td></td> </tr> <tr> <td>Planlegging, kontrakt</td> <td></td> <td>▶</td> <td></td> <td></td> <td></td> <td></td> </tr> <tr> <td>Teknisk integrasjon</td> <td></td> <td>▶</td> <td></td> <td></td> <td></td> <td></td> </tr> <tr> <td>Prosesstilpassing</td> <td></td> <td>▶</td> <td></td> <td></td> <td></td> <td></td> </tr> <tr> <td>Gjennomføring bildeanalyse</td> <td></td> <td></td> <td>▶</td> <td></td> <td></td> <td></td> </tr> <tr> <td>Evaluering</td> <td></td> <td></td> <td></td> <td>▶</td> <td></td> <td></td> </tr> <tr> <td>Avslutting</td> <td></td> <td></td> <td></td> <td></td> <td></td> <td>▶ Buffer</td> </tr> </tbody> </table>	Milepæl	Frist	Oppstart	01.09.2021	Avslutning	30.12.2022	Aktivitet	Q3 21	Q4 21	Q1 22	Q2 22	Q3 22	Q4 22	Oppstart							Planlegging, kontrakt		▶					Teknisk integrasjon		▶					Prosesstilpassing		▶					Gjennomføring bildeanalyse			▶				Evaluering				▶			Avslutting						▶ Buffer	Prosjektet tok lengere tid enn forventet og ble ferdig i 2024.
Milepæl	Frist																																																															
Oppstart	01.09.2021																																																															
Avslutning	30.12.2022																																																															
Aktivitet	Q3 21	Q4 21	Q1 22	Q2 22	Q3 22	Q4 22																																																										
Oppstart																																																																
Planlegging, kontrakt		▶																																																														
Teknisk integrasjon		▶																																																														
Prosesstilpassing		▶																																																														
Gjennomføring bildeanalyse			▶																																																													
Evaluering				▶																																																												
Avslutting						▶ Buffer																																																										

## 2 Om Piloten og fysisk pilotområde

Tabell 2: Piloten og pilotområdet

<b>Pilotområdet</b>	Agder
<b>Måledata og andre data som samles inn og lagres fra Piloten</b>	Dronebilder tatt i 2021, annoteringer av feil gjort av ingeniører og KI algoritmer.
<b>Personvern og/eller kraftsensitiv informasjon</b>	Kraftsensitiv informasjon (Informasjon om strømmettet)
<b>Måle- og kommunikasjonsinfrastruktur</b>	
<b>Use-case-beskrivelser og testplaner</b>	Bruk av maskinlæring til å avdekke feil i strømmettet, se tabell 1. (aktiviteter)
<b>Regulering og forskrifter</b>	
<b>Barrierer og løsninger</b>	Stor kompleksitet i problemstillingen, KI algoritmene er ikke avanserte nok til å takle mange typer feil. Algoritmene hadde blitt bedre med et større bildegrunnlag.

<b>Hvem skal eventuelt ta resultater fra Piloten i bruk?</b>	Andre nettselskaper som vurderer KI som del av sin vedlikeholdsprosess
<b>Hvem er erfaringene relevant for?</b>	Andre nettselskaper som vurderer KI som del av sin vedlikeholdsprosess, andre aktører som skal utvikle algoritmer som skal avdekke feil i nettet.
<b>Hva påvirkes av resultater fra Piloter?</b>	Vi får mer effektivt vedlikeholdsarbeid og vi kan finne feil raskere.
<b>Informasjonsdeling mellom aktørene før/underveis/etterpå</b>	Deler dronebilder, annoteringer og generelle resultater/erfaring har blitt delt eksternt.
<b>Er det laget planer for videreføring? Skalering/fullskala implementering?</b>	Underlaget skal bli brukt i vurdering av valg av system for vedlikehold og bruk av KI i vedlikeholdsprosessen. Agder Energi Nett er klar til å ta i bruk KI som del av vedlikeholdsprosessen, så snart dette er en del av produkt fra leverandører.

### 3 Resultater og innovasjoner fra Piloten

#### 3.1 Resultater fra delaktivitet 1: Test av integrasjon og vedlikeholdsprogramvare

Leverandør A hadde en programvare for sjekk av dronebilder og annotering av feil. Der var det implementert en algoritme som foreslo avvik på mastene. Vi overførte 400 bilder for å sjekke om integrasjonen var gjennomførbar og sjekket brukervennligheten til programvaren.

Det ble satt opp et område for Agder Energi i leverandørens datalake. Her kunne vi laste opp bilder, en liste over master og en liste med bildeinformasjon. Deretter kunne vi trigge importen gjennom et API. Dette gjør det nokså enkelt å sette opp automatiske prosesser som kan laste disse dataene inn i programvaren. Vi møtte noen utfordringer med lasting av data. Spesielt det at det var en grense på hvor mange bilder vi kunne importere om gangen. Vi måtte da dele opp importen som gjorde at vi måtte lage logikk på å sende bilder av master som var lokaliserte på samme sted slik at vi fikk samlet mastene i prosjekter.

Testen av programvaren ble gjort av to vedlikeholdsingeniører. De brukte programvaren med forslag fra KI-algoritmen. Tilbakemeldingen fra disse var at KI kunne finne topphettene på en god måte. Og at det var lett å legge til avvik og sortere avvikene i programvaren. KI algoritmen gjorde en del logiske feil. Blant annet ble linjer fanget opp som sprekker og det ble funnet sprekker i ståltraverser hvor dette ikke gir mening. KI-algoritmen foreslo avvik på sprekker i master som ikke ble ansett som problematiske sprekker. Dermed ble det unødvendige mange annoteringer fra KI. KI-algoritmen klarte ikke alltid å skille mellom hakkespetthull og sprekk, disse kom om hverandre. Det var også litt funksjonalitet i programvaren som kunne vært forbedret, blant annet med kartfunksjonaliteten og hvordan KI-forslagene beveger seg etter hvert som man avkrefter feilen. Generelt gjorde ikke de tilgjengelige KI-algortimene på dette tidspunktet jobben til ingeniørene noe lettere.

#### 3.2 Resultater fra delaktivitet 2: Test av KI modeller 4000 master

4000 bilder ble sendt over til leverandørene slik at KI kunne gjøre annoteringer på disse. Av praktiske årsaker er det sendt ulike bilder til de to leverandørene. Dette betyr at resultatene ikke er sammenlignbare mellom leverandørene. Deretter ble det sammenlignet med resultatet fra vedlikeholds annoteringene i 2021. Dette ble gjort av en sommerstudent som gikk gjennom bildene for å sikre at feilene er annotert på riktig sted. Her dukket det opp en del problemstillinger knyttet til hvordan man



annoterer en feil. Spesielt hvordan KI-algortimene kategoriserer en feil sammenlignet med hvordan ingeniørene kategoriserer feil.

Det er mulig å beregne nøyaktighetsmålene på tre ulike måter.


- Annoteringsnivå – Hver annotering blir kategorisert som en feil eller riktig annotering.
- Bildenivå – Per bilde ser man om det er en feiltype som er riktig annotert. Denne blir da en riktig prediksjon uavhengig om det er andre prediksjoner gjort på bilde.
- Mastenivå – Per mast ser man om det er en feiltype som er riktig annotert. Denne blir da en riktig prediksjon uavhengig om det er andre prediksjoner gjort på masten.

I dette prosjektet har vi hovedsakelig sett på annoteringsnivået og ikke tatt i stor grad hensyn til om feilene er på samme bilde eller mast.

I figur 1 og 2 kan man se hvor mange observasjoner er gjort av KI-algortimene per feiltype for hver av leverandørene sammenlignet med inspeksjonen.


### AI Prediksjon

Defect	Antall Distinkte Master	Totale Observasjoner
Isolator-Skadet	27	32
Stolpe-Hakkespettskade	134	231
Stolpe-Manglende topphette	38	58
Stolpe-Sprekk	97	154
Travers-Råte	21	44
<b>Totalt</b>	<b>188</b>	<b>519</b>



### Inspeksjon

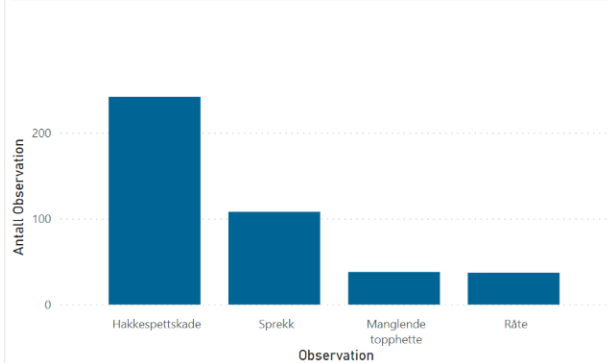
Defect	Antall Distinkte Master	Totale Observasjoner
Isolator-Skadet	22	24
Stolpe-Hakkespettskade	109	130
Stolpe-Manglende topphette	43	61
Stolpe-Råte	7	7
Stolpe-Skadet	8	9
Stolpe-Sprekk	7	8
Travers-Råte	21	24
Travers-Skadet	4	4
<b>Totalt</b>	<b>204</b>	<b>267</b>



**Figur 1: Antall observasjoner av avvik for KI prediksjonen og inspeksjonen for leverandør A.**

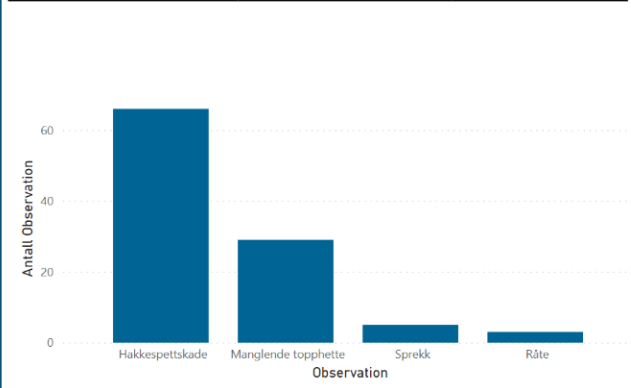
### AI Prediksjon

Defect	Antall Distinkte Master	Totale Observasjoner
Stolpe-Hakkespettskade	187	242
Stolpe-Manglende tophette	36	38
Stolpe-Råte	14	31
Stolpe-Sprekk	99	104
Travers-Råte	4	6
Travers-Sprekk	4	4
<b>Totalt</b>	<b>339</b>	<b>425</b>



### Inspeksjon

Defect	Antall Distinkte Master	Totale Observasjoner
Stolpe-Hakkespettskade	52	66
Stolpe-Manglende tophette	27	29
Stolpe-Råte	2	2
Stolpe-Sprekk	5	5
Travers-Råte	1	1
<b>Totalt</b>	<b>86</b>	<b>103</b>



**Figur 2: Antall observasjoner av avvik for KI prediksjonen og inspeksjonen for Leverandør B**

Deretter er det beregnet nøyaktighetsmål basert på hvor mange av observasjonene er gjort rett sammenlignet med resultatet av inspeksjonen til våre vedlikeholdsingeniører. En summering av de forskjellige feiltypene er gjort og resultatet kan ses i figur 3 og 4.

		Predikert		
		Positive	Negative	
Faktisk	True	267 183 TP	84 84 FN	0,69 Recall
	False	336 336 FP	TN skal være her, men ettersom den ikke er løst blir det feil å ta den med. Negative er satt som FN og False er satt som FP.	0,31 Miss rate
		0,35 Precision	0,65 False discovery rate	0,47 F1 score

**Figur 3: Nøyaktighetsmål for 4000 master for Leverandør A**

		Predikert		
		Positive	Negative	
Ektekk	True	425	20	
	103	83 TP	20 FN	0,81 Precision
False	342	342 FP	TN skal være her, men ettersom den ikke er løst blir det feil å ta den med. Negative er satt som FN og False er satt som FP.	0,19 Miss rate
		0,20 Precision	0,80 False discovery rate	0,31 F1 score

**Figur 4: Nøyaktighetsmål for 4000 master Leverandør B**

I tabell 3 og 4 kan man se resultater for nøyaktighetsmål for hver av feiltypene for hver leverandør. Vi tar utgangspunkt i nøyaktighetsmålene presisjon og tilbakekalling (recall).

Alle resultater er rundet opp/ ned til nærmeste heltall.

**Tabell 3: Resultater per feiltype leverandør A – delaktivitet 2**

Feiltype	Precision	Recall
Isolator – Skadet	60%	75%
Stolpe – Hakkespettskade	40%	70%
Stolpe – Manglende topphette	90%	90%
Stolpe – Råte	40%	80%
Stolpe – Sprekk	5%	100%
Travers – Råte	40%	80%

**Tabell 4: Resultater per feiltype leverandør B – delaktivitet 2**

Feiltype	Precision	Recall
Isolator – Skadet	-	-
Stolpe – Hakkespettskade	20%	80%
Stolpe – Manglende topphette	80%	100%
Stolpe – Råte	0%	0%
Stolpe – Sprekk	1%	20%
Travers – Råte	20%	100%

### 3.3 Resultater fra delaktivitet 3: Test av KI modeller 4000 master – oppdaterte modeller

Leverandørene trente modellene ytterligere og fikk teste modellene en gang til på et nytt sett med bilder. Denne gangen hadde vi ikke en student til rådighet. Leverandøren A brukte da selv programvare

som beregnet om annoteringen er riktig plassert ift. inspeksjonen. Annoteringer ble sendt over slik at leverandørene fikk resultatet av inspeksjonen. Resultatet er i tabell 5.

**Tabell 5: Resultater per feiltype leverandør A - delaktivitet 3**

Feiltype	Recall – delaktivitet 2	Recall – delaktivitet 3
Isolator – Skadet	75%	81%
Stolpe – Manglende topphette	90%	96%

De resterende feiltypene var for vanskelige å få et godt resultat på med tanke på å regne ut om en annotering er riktig plassert eller ikke. Dette kan være spesielt fordi at inspektøren vil annotere en hel stolpe om stolpen har sprekker. Mens en KI-algoritme vil annotere hver sprekk. Dette gjør det vanskelig å sammenligne maskinelt. Det kan også være vanskelig å beregne om annoteringen er riktig om boksene er i veldig forskjellig størrelse eller strekker seg over flere feil. Leverandøren fant også feil som våre inspektører har oversett.

Leverandør B gjorde også sin egen sammenligning. De beregnet nøyaktighetsmålene på tre forskjellige måter beskrevet i avsnitt 3.2. Resultatene i denne delaktiviteten er kun gitt på maste nivå. Leverandør B valgte å bruke en egen intern fasit. Hvor de selv hadde gått igjennom bildene og annotert feil. Dette ga bedre resultater på noen feiltyper. I denne rapporten har vi fokusert på resultatene som er sammenlignet med resultatet fra vår vedlikeholdsprosess, vist i tabell 6.

**Tabell 6: Resultater per feiltype leverandør B - delaktivitet 3**

Feiltype	Precision	Recall
Isolator – Skadet	43%	16%
Stolpe – Hakkespettskade	11%	67%
Stolpe – Manglende topphette	90%	77%

### 3.4 Innovasjoner fra Piloten

**Tabell 7 Beskrivelse av innovasjoner i forskningsrådets kategorier**

Forskningsrådets kategorier	Beskrivelse	Antall
Ferdigstilte nye/bedre metoder/modeller/ prototyper	Gjennom pilotperioden utviklet leverandøren enda bedre algoritmer.	2
Bedrifter utenfor FMEen som har innført nye/forbedrede metoder eller modeller eller teknologi	Ja	2

<b>Bedrifter innenfor FMEen som har innført nye/forbedrede arbeidsprosesser</b>	Det er innført en ny arbeidsprosess. Leverandør som leverer dronetjenester og data (bilde, LiDAR, termografering), bruker KI som del av jobben de utfører. Dette fører til at vi har endra våre prosesser ettersom vi ikke treng å leite igjennom underlaget på samme måten som tidligere.	1
<b>Bedrifter innenfor FMEen som har innført nye/ forbedrede metoder eller modeller eller teknologi</b>	Nei	
<b>Inngåtte lisensieringskontrakter</b>	Nei	
<b>Registrerte patenter</b>	Nei	
<b>Ferdigstilte nye/forbedrede produkter</b>	Gjennom pilotperioden utviklet leverandøren enda bedre algoritmer.	2
<b>Ferdigstilte nye/forbedrede prosesser</b>	Nei	
<b>Ferdigstilte nye/forbedrede tjenester</b>	Nei	
<b>Nye foretak som følge av FME'en</b>	Nei	
<b>Nye forretningsområder i eksisterende bedrifter</b>	Nei	

## 4 Tekniske/faglige erfaringer fra Piloten

I delaktivitet 1 ble det klart at en integrasjon mot leverandørene er nokså enkel å sette opp. Det er noen endringer i importen som må endres for at det skal fungere optimalt, men dette bør ikke være et problem. Våre inspektører erfarte også at vedlikeholdssystemet fungerte godt, men at KI-algortimene ikke var gode nok til å forkorte tiden de bruker per bilde da denne testen ble gjort. Denne testen ble kun gjort for leverandør A. Da testen ble utført var det ikke KI-algoritmer for alle feiltyper som våre inspektører ser etter, dermed må de se ganske nøye på bilde uavhengig av en KI-algoritme sin hjelp. Men inspektørene kunne se at dette ville gi en god støtte om det var KI-algoritmer for flere feiltyper og at disse fungerte optimalt. Vi kunne se progresjon på modellene gjennom prosjektet og det er nærliggende å tro at modellene yter bedre nå enn de gjorde under pilotprosjektet.

Et typisk mønster i delaktivitet 2 er at KI predikerer flere feil enn det faktisk er, dvs. den har flere falske alarmer (FP) enn treff (TP) for de fleste feiltyper. Dette indikerer at KI-en er overfølsom for denne feiltypen. Grunnen for at KI-en gjør det dårlig på Stolpe-Sprekk feiltypen kan være at personene som designet algoritmen i selskapene ønsket å finne alle sprekker på en stolpe. Inspektøren derimot ser bare på sprekker som er kritiske eller som kan utvikle seg til alvorlige sprekker. Her må Agder Energi Nett vurdere hva de ønsker. På en side er det fint med mange predikerte tilfeller av Stolpe-Sprekk siden inspektøren da kan gjøre en individuell vurdering av dem, men det vil være mer tidkrevende og kanskje

ikke gi den nytten av algoritmen som de ønsker. En tradeoff mellom potensielt alle mulige sprekker på en stolpe eller kun de mest alvorlige må derfor vurderes av selskapet.

Algoritmene gjør det best på klassifisering av Stolpe-Manglende topphette med nesten 100% recall på begge datasettene. Det er flere riktige klassifiseringer (TP) enn falske alarmer (FP) og det er også flere riktige klassifiseringer enn uoppdagede tilfeller

Precision er rimelig lav for begge leverandører i flere feiltyper som betyr at vi ikke kan være særlig sikker på våre TP. Hvis Agder Energi Nett ønsker å maksimere presisjon betyr det at man ønsker å være oftere sikker på at KI har riktig når det er en faktisk feil. Det vil si at de ønsker færre forslag fra KI-en om feil og at KI-en er veldig sikker når det først predikeres en feil. Det er ikke sikkert at dette er en effekt vi ønsker. Om recall er forholdsvis høy så vi kan være sikre på at vi hvert fall ikke misser mange faktiske feil. Agder Energi Nett bør fokusere på å maksimere recall dersom tilfeller av feil som ikke blir oppdaget er uakseptabelt. Her må de vurdere om de heller vil ha noen ekstra falske alarmer fremfor misses. For å dra tråder til hypotesene presentert i begynnelsen av rapporten bør minimering av FN (maksimering av recall) ha høyest *prioritet* siden mangelfull detektering av en f.eks en skadet isolator kan øke KILE-kostnad og gå utover HMS dersom den brennes i stykker. For å ivareta redusert KILE-kostnad og øke fokus på HMS bør derfor recall prioriteres. En stor gevinst av disse algoritmene er at man kan prioritere hvilke bilder søm bør undersøkes først. Dette vil gjøre feilrettingen mer effektiv.

I delaktivitet 3 ble modellene testet på et nytt sett med 4000 bilder. Ved å endre bildesettet kan vi undersøke robustheten til modellene. For leverandør A kunne vi se en bedring på feiltypene skadet isolator og manglende topphette. Man kan kun se at recall øker siden dette var det nøyaktighetsmålet de leverte. Dermed vet vi ikke om presisjonen har sunket. For de andre feiltypene ble det vanskelig å regne ut riktige og uriktige prediksjoner. For leverandør B kan man se litt endring i resultatene. For hakkespettskade ser vi en nedgang av nøyaktighetsmål. Dette kan være fordi vi endret bildesettet. Det kan også være at usikkerheten rundt å kategorisere annoteringene med en annen metode har en innvirkning her. For topphette har de økt presisjonen, men fått mindre recall. Dette kan være for å få en modell som er sikrere på sine forslag. Isolator gir ikke særlig gode resultater, på testen med leverandøren sin egen fasit så var resultatene mye bedre. Det ble ikke undersøkt nærmere hva grunnen til dette kan være. På generelt grunnlag så gir dette antydninger til at dette er en problemstilling som kan løses med KI-algoritmer. Utfra de resultatene vi ser fra piloten kan man peke på problematikk knyttet til hva vi som nettselskap anser som en feil i nettet og hva leverandørene har modellert etter. Dette kan være knyttet til at nettselskapene verner om sine bilder og ikke ønsker at leverandørene skal bruke sine bilder for å utvikle en algoritme som de igjen selger. For at leverandørene skal kunne lage en algoritme som er best mulig for nettselskapene i Norge, så trenger de bilder fra Norge å trene på. Dermed ville det vært nyttig å dele bildene med leverandører i lignende prosjekt eller da man skal ta i bruk et slik inspeksjonsprodukt.

#### 4.1 Oppsummering

Gjennom denne piloten er det testet om KI-algoritmer kan brukes for å spare tid, kost og minske HMS risiko i vedlikeholdsprosessen. Algoritmene som ble utviklet i pilotprosessen er enkle å implementere i vedlikeholdsprosessen. Det lot seg teknisk gjøre med den dataarkitekturen som Agder Energi Nett har. Gjennom pilotprosjektet har vi sett en forbedring av algoritmene. Algoritmene viser potensiale for å kunne spare tid, kost og minske HMS risiko i vedlikeholdsprosessen. Vi ser at KI baserte annoteringer gir mulighet for å finne feil raskt. Dette vil minske risiko for alvorlige feil og risiko knyttet til HMS. Samtidig vil ikke dette erstatte manuelt arbeid, heller støtte og effektivisere det.

## 5 Kost-/nyttevurderinger basert på resultatene for Piloten

### 5.1 Kostnader

Totale kostnader = 2 000 000 NOK

### 5.2 Nyttevurderinger

Etter endt pilotprosjekt har leverandør A gjort ytterligere forbedringer på sine algoritmer. Leverandør B utviklet mye av sine algoritmer fra bunnen av gjennom pilotprosjektet. Dette pilotprosjektet har bidratt til å utvikle markedet knyttet til KI-algoritmer brukt på vedlikehold av nett. Vi har konkludert på hvor står bildeanalyse i dag. Det er et område som er i rask utvikling og som vi ser stort potensiale for at dette skal effektivisere vedlikeholdsprosessen. Vi ser spesielt nytten av å kunne prioritere inspeksjon av mastene basert på annoteringer fra KI-algoritmer. Glitre Nett (Tidligere Agder Energi Nett) har nå rigget oss for å ta i bruk et slikt verktøy da neste vurdering av inspeksjonsverktøy skal skje.

**FME CINELDI**

Host: SINTEF Energy Research in cooperation with NTNU  
Visiting address: Sem Sælands vei 11, N-7034 Trondheim  
Post address: P.O.Box 4761 Torgarden, N-7465 Trondheim  
Telephone: +47 454 56 000\*  
E-mail: [cineldi@sintef.no](mailto:cineldi@sintef.no)  
Enterprise/VAT No: NO 939 350 675 MVA  
<http://www.cineldi.no>

