



CHALMERS

Artificiell Intelligens användning inom drönarskanning och livedata

En kartläggning över befintliga modeller och branschperspektiv

*Examensarbete inom teknologprogrammet Affärsutveckling och Entreprenörskap inom
Samhällsbyggnadsteknik*



**ARVID GARVALD
DAVID NORDIN**

INSTITUTIONEN ACE – ARCHITECTURE AND CIVIL ENGINEERING

CHALMERS TEKNISKA HÖGSKOLA
Göteborg, Sverige 2025

www.chalmers.se

EXAMENSARBETE ACEX20

Artificiell Intelligens användning inom drönarskanning och livedata

En kartläggning över befintliga modeller och branshperspektiv

*Examensarbete inom teknologiprogrammet Affärsutveckling och Entreprenörskap
inom Samhällsbyggnadsteknik*

ARVID GARVALD

DAVID NORDIN



CHALMERS

Institutionen för arkitektur och samhällsbyggnadsteknik

Avdelningen för avdelningsnamn

Examinator Mathias Gustafsson

Handledare Mathias Gustafsson

CHALMERS TEKNISKA HÖGSKOLA

Göteborg, 2025

Artificiell Intelligens användning inom drönarskanning och livedata

En kartläggning över befintliga modeller och branschperspektiv

*Examensarbete inom teknologiprogrammet Affärsutveckling och Entreprenörskap
inom Samhällsbyggnadsteknik*

ARVID GARVALD

DAVID NORDIN

© ARVID GARVALD & DAVID NORDIN, 2025

Examensarbete ACEX20

Institutionen för arkitektur och samhällsbyggnadsteknik
Chalmers tekniska högskola 2025

Institutionen för arkitektur och samhällsbyggnadsteknik
Avdelningen för avdelningsnamn
Chalmers tekniska högskola
412 96 Göteborg
Telefon: 031-772 10 00

Institutionen för arkitektur och samhällsbyggnadsteknik
Göteborg 2025

Artificiell Intelligens användning inom drönarskanning och livedata

En kartläggning över befintliga modeller och branshperspektiv

Examensarbete inom teknologiprogrammet Affärsutveckling och Entreprenörskap inom Samhällsbyggnadsteknik

ARVID GARVALD

DAVID NORDIN

Institutionen för arkitektur och samhällsbyggnadsteknik
Avdelningen för avdelningsnamn
Chalmers tekniska högskola

SAMMANFATTNING

Denna studie undersöker integrationen av artificiell intelligens (AI) och drönarteknik i Pontarius arbetsflöden, med fokus på att förbättra inspektioner av infrastruktur, såsom asfalt och byggnader. Genom att kombinera kvalitativa och kvantitativa forskningsmetoder utforskar projektet både tekniska och organisatoriska utmaningar kopplade till implementeringen av Artificiell Intelligens. En fallstudiedesign används för att ge en djupgående förståelse av de specifika förutsättningarna för en effektiv AI-användning.

Forskningen bygger på semistrukturerade intervjuer med nyckelintressenter, tekniska dataanalys av AI-modeller som DeepCrack, samt granskning av interna arbetsflöden och riktlinjer. Denna metodkombination möjliggör en omfattande förståelse för potentiella hinder och möjligheter vid AI-integrering. Genom att säkerställa validitet och tillförlitlighet via metodtriangulering levererar studien handlingsbara insikter som kan överföras till andra organisationer med liknande utmaningar.

Resultaten syftar till att bidra till utvecklingen av anpassningsbara och skalbara metoder för teknikimplementering, tillämpliga inte bara för Pontarius utan även för andra sektorer. Studien förväntas ge värdefulla perspektiv på både den tekniska effektiviteten och den organisatoriska beredskapen som krävs för en framgångsrik AI-integrering, och därigenom främja innovation och förbättrad infrastrukturförvaltning

Nyckelord: Artificiell intelligens (AI), UAV, drönarteknik, skadedetektion, infrastruktursinspektion, YOLOv8, DeepCrack, EfficientCrackNet, maskininlärning, implementering, Pontarius, säkerhetsaspekter, realtidsanalys, AI-modeller, strukturell hälsomonitorering, processövervakning, teknisk integration, förändringsledning, byggprocess.

Artificial Intelligence usage in drone-scanning and live data

A mapping of existing models and industry perspectives

*Degree Project in the Engineering Programme
Business Development and Entrepreneurship*

ARVID GARVALD

DAVID NORDIN

Department of Architecture and Civil Engineering

Chalmers University of Technology

ABSTRACT

This study explores the integration of artificial intelligence (AI) and drone technology into Pontarius' workflows, focusing on improving the inspection of infrastructure, such as asphalt and buildings. By combining qualitative and quantitative research methods, the project investigates both technical and organizational challenges associated with AI implementation.

A fall study design is employed to provide an in-depth understanding of the specific conditions under which AI can be effectively adopted.

The research utilizes semistructured interviews with key stakeholders, technical data analysis of AI models like DeepCrack, and analysis of internal workflows and policies. This methodological combination enables a comprehensive understanding of the potential barriers and opportunities for AI integration. By ensuring validity and reliability through method triangulation, the study delivers actionable insights that are transferable to other organizations with similar challenges.

The findings aim to contribute to developing adaptable and scalable methods for technology implementation, not only applicable to Pontarius but also to other sectors. The results are anticipated to provide valuable perspectives on both the technical effectiveness and organizational readiness required for successful AI integration, contributing to innovation and enhanced infrastructure management practices.

Key words: Artificial Intelligence (AI), UAV, drone technology, damage detection, infrastructure inspection, YOLOv8, DeepCrack, EfficientCrackNet, machine learning, implementation, Pontarius, security aspects, real-time analysis, AI models, structural health monitoring, process monitoring, technical integration, change management, construction progress.

Innehåll

1. Inledning	1
1.1. Bakgrund och motivering	1
1.2 Syfte	2
1.3 Aktuella forskningsfrågor för projektet	2
1.4 Teoretisk referensram	2
1.4.1 Teknisk modellöversikt	3
1.4.2 Teknisk kontext som analysgrund	3
2. Metod	4
2.1 Metodstrategi	4
2.2 Intervjuer som datakälla	4
2.3 Datainsamlingens upplägg	5
2.4 Analys av intervjudata	5
2.5 Användning av AI i examensarbetet	5
3. Teoretisk bakgrund	6
3.1 DeepCrack och nyare lättviktsmodeller	6
3.1.1 Modellens uppbyggnad och funktionalitet	6
3.2 UAV och maskininlärning för automatiserad framstegsövervakning i markutvecklingsprojekt	7
3.2.1 Modellens uppbyggnad och funktionalitet	7
3.2.2 Datakrav och systemarkitektur	7
3.2.3 Tillämpningsområden och nytta	8
3.3 Deep learning-baserad strukturell hälsomonitorering i UAV-inspektioner	8
3.3.1 Modellens uppbyggnad och funktionalitet	8
3.3.2 Datakrav och implementeringsaspekter	9
3.3.3 Tillämpningsområden och utmaningar	9
3.4 YOLOv8 för skadedetektion i UAV-baserade vägyteinspektioner	10
3.4.1 Modellens uppbyggnad och funktionalitet	10
3.4.2 Datakrav och systemkrav	11
3.4.3 Tillämpningsområden och utmaningar	12
3.5 Användbarhet, teknisk acceptans och förändringsvilja	12
4. Implementering	14
4.1 Implementering av YOLOv8 för realtidsdetektion av vägyteskador	14
4.2 Implementering av DeepCrack för detaljerad sprickanalys	15
4.3 Implementering av Cha et al:s metod	16
4.4 Implementering av Han et al:s metod	16
4.5 Sammanvägd tillämpning och modellinteraktion	17
5. Begränsningar och risker vid AI-implementering	20
5.1. Tekniska begränsningar	20
5.2. Organisatoriska risker	20
6. Insamling av data och branshperspektiv	22
6.1 Teknikacceptans	22
6.2 Barriärer och säkerhet	23
6.3 Potentiella användningsområden	23

7. Diskussion	25
7.1 Tekniska möjligheter och modellernas komplementaritet	25
7.2 Säkerhet och informationshantering som tröskel	25
7.3 Kompetensgap och användaracceptans	26
7.4 Förändringsvilja och organisatorisk mognad	27
7.5 Metodreflektion	28
8. Slutsats	29
8.1 Hur ser förutsättningarna ut hos Pontarius för att implementera AI i kombination med drönarteknik?	29
8.2 Vilka är de potentiella fördelarna och riskerna med AI inom branschen?	29
8.3 Vad är inställningen till användningen av AI idag inom branschen?	30
8.4 Framtida fortsatt forskning	30
8.5 Avslutande reflektion	31
9. Referenser	32
10. Bilagor	34

Förord

Examensarbetet genomfördes under vårterminen 2025 på halvfart och omfattar 15 högskolepoäng. Arbetet är det avslutande momentet på kandidatprogrammet *Affärsutveckling och Entreprenörskap inom Samhällsbyggnadsteknik*. Arbetet är skrivet av Arvid Garvald och David Nordin, där Pontarius AB har varit det företag som hjälpt oss utanför Chalmers för att ge stöttning och idéer till det som presenteras i detta arbete.

Vi vill tacka alla parter som varit delaktiga under projektets gång, utan er hade det inte varit möjligt att slutföra arbetet. Extra stort tack till Niklas, Filip och Johanna på Pontarius som bidragit med lärarik och nyttig kunskap samt stöttat oss hela vägen. Även de respondenter som ställt upp på intervjuer. Slutligen vill vi såklart också visa vår tacksamhet till Mathias Gustafsson för den guidning vi fått här på Chalmers Tekniska Högskola.

Tack!

Göteborg Maj 2025
Arvid Garvald & David Nordin

Begreppslista

Begrepp	Förklaring
Artificiell Intelligens (AI)	En gren inom datavetenskap som syftar till att skapa system som kan utföra uppgifter som normalt kräver mänsklig intelligens.
UAV (Unmanned Aerial Vehicle)	Obemannat luftfartyg, även kallat drönare, som används för datainsamling.
Pixelnivåsegmentering	Teknik där varje pixel i en bild analyseras för att exakt identifiera objekt, som t.ex. sprickor.
Skadedetektion	Processen att identifiera skador eller defekter i t.ex. vägar eller byggnader via bildanalys.
Falska positiva/negativa	När en AI-modell felaktigt identifierar (eller missar) ett objekt, t.ex. en spricka.
Molntjänst	Extern lagring och databehandling via internet, ofta hos tredjepartsleverantörer.
Edge-enhet	Lokal hårdvara nära datakällan som kan bearbeta information utan att använda molnet.

1. Inledning

Det inledande kapitlet kommer att behandla områden som bakgrund, syfte och frågeställningar.

1.1. Bakgrund och motivering

Underhåll och inspektion av infrastruktur, som vägar och byggnader, är avgörande för att säkerställa samhällsfunktioner (Msverige, 2024). Pontarius har identifierat ett behov av att effektivisera dessa processer genom integrering av AI och drönarteknik. Enligt EU-kommissionen (2024) är en av de främsta fördelarna med artificiell intelligens dess förmåga att bearbeta stora mängder data snabbt och med hög precision. Detta gör AI till ett kraftfullt verktyg inom områden som samhällsbyggnadsteknik, där snabb och noggrann dataanalys är avgörande för att upptäcka skador effektivt. Medan drönare kan samla in högupplösta bilder av svårtillgängliga områden. Kombinationen av dessa teknologier kan leda till kostnadsbesparingar och förbättrad precision vid skadedetektion.

Relevansen för projektet ligger i dess potential att bidra till effektivare arbetsflöden, ökad datasäkerhet och bättre beslutsstöd för underhållsåtgärder. Dessutom kan insikterna från projektet anpassas för andra verksamheter med liknande behov, vilket gör det av stort värde för samhället. Förutom den tekniska aspekten finns en betydande organisatorisk dimension, där arbetssätt och kompetensutveckling spelar en viktig roll för att uppnå framgångsrik implementering.

Historiskt sett har inspektion av infrastruktur varit en arbetsintensiv process, ofta beroende av manuell inspektion och dokumentation. Med den snabba teknologiska utvecklingen erbjuder AI och drönarteknik nya möjligheter för automation och datadrivet beslutsfattande, vilket Pontarius idag saknar i sin verksamhet. I en växande urban miljö är det av största vikt att hålla infrastrukturen i gott skick samtidigt som resurser används effektivt. Det här projektet syftar till att möta dessa utmaningar och bidra till en mer hållbar förvaltning av samhällsviktiga resurser.

En annan viktig aspekt är att utforska de möjliga barriärer som kan hindra denna typ av teknologi. Organisationer tenderar att motstå förändring, och det är viktigt att adressera sådana hinder genom planering och välvald implementeringsstrategi. Förståelse för samspelen mellan teknik, människor och organisatoriska strukturer ses som avgörande för projektets framgång.

Utmaningarna inom den tekniska utvecklingen kräver även ett samarbete mellan flera olika aktörer, inklusive myndigheter, teknikutvecklare och slutanvändare. Detta projekt positionerar sig i en unik roll att agera som en brygga mellan dessa aktörer genom att kombinera teknisk utveckling med en analys av organisatoriska behov och tekniska förutsättningar. Genom att skapa samverkan mellan tekniska och organisatoriska insikter hoppas projektet bidra till en mer helhetsorienterad strategi för AI-implementering.

Dessutom har projektet en viktig roll i att belysa de potentiella samhällsliga vinsterna med att implementera AI och drönarteknik i infrastruktursektorn som helhet. En effektiv inspektions

process kan exempelvis bidra till en snabbare identifiering av problem, vilket i sin tur kan leda till en minskad risk för allvarliga olyckor och minskad resursanvändning för företag.

1.2 Syfte

Detta projekt syftar till att undersöka hur artificiell intelligens (AI) kan integreras i Pontarius arbetsprocesser för att effektivisera datahantering och användning av drönarteknik vid inspektion av infrastruktur, såsom asfalt och byggnader. Syftet är att identifiera hur AI-teknologier kan förbättra skadedetektion samt analysera vilka förändringar som behövs för en framgångsrik implementering. Utöver detta ska studien också belysa inställningen till AI hos nyckelpersoner i branschen. Denna studie ska generera insikter som inte bara är tillämpbara för Pontarius utan även kan anpassas till andra verksamheter med liknande behov och tekniska utmaningar.

1.3 Aktuella forskningsfrågor för projektet

För att projektet ska bli värdefullt och användbart krävs att projektet utgår ifrån ett antal frågeställningar som bör kunna besvaras efter att rapporten är färdigställd:

Hur ser förutsättningarna ut hos Pontarius för att implementera AI i kombination med drönarteknik?

Vilka är de potentiella fördelarna och riskerna med AI inom branschen?

Vad är inställningen till användningen av AI idag inom branschen?

1.4 Teoretisk referensram

För att förstå förutsättningarna för AI-implementering i Pontarius UAV-verksamhet är det avgörande att utgå från den tekniska utvecklingen inom datorseende (computer vision), maskininlärning och UAV-baserad inspektion. Forskning inom dessa områden visar att AI-modeller kan spela en central roll för att automatisera uppgifter som traditionellt krävt manuell analys, särskilt i samband med identifiering av skador på infrastruktur (Cha et al., 2024; Zou et al., 2019; Samadzadegan et al., 2023). Detta gör tekniken särskilt relevant för Pontarius, vars uppdrag ofta involverar flygplatsinspektioner, asfaltsbedömning och byggdokumentation.

1.4.1 Teknisk modellöversikt

I detta projekt har fyra tekniska lösningar studerats: YOLOv8, DeepCrack, EfficientCrackNet samt modeller för strukturell hälsomonitorering och byggprogress. Varje modell adresserar olika delar av inspektionskedjan, från realtidsigenkänning till detaljerad segmentering och långtidsuppföljning, och utgör därför en teknisk grund för det system som föreslås i rapportens implementeringskapitel (Ma et al., 2023; Han et al., 2024).

Särskilt relevant för Pontarius är kombinationen av UAV-teknik och AI-modeller anpassade för fältförhållanden. Teknologierna måste kunna hantera varierande ljusförhållanden, brusig bakgrund samt olika typer av skador och objekt i bildmaterialet (Samadzadegan et al., 2023). Detta kräver robusta algoritmer med hög noggrannhet och generaliseringsförmåga, samtidigt som prestandan måste anpassas till hårdvarubegränsningar i praktiken. Modeller som DeepCrack är exempel på lösningar med hög precision (Zou et al., 2019), medan YOLOv8 erbjuder snabbhet och realtidskapacitet, något som ofta efterfrågas av Pontarius platsledning.

1.4.2 Teknisk kontext som analysgrund

Istället för att använda ett enskilt teoretiskt ramverk bygger analysen i denna rapport på att relatera empiriskt insamlade data till den tekniska kapaciteten hos AI-modellerna och de praktiska krav som Pontarius ställt. Fokus ligger på att förstå tekniken som ett stödverktyg i ett befintligt arbetsflöde snarare än som en fullständig ersättning för mänsklig kompetens. Denna pragmatiska syn är också återkommande i forskningslitteraturen, där AI allt oftare ses som ett komplement snarare än ett substitut i komplexa arbetsmiljöer (Gao et al., 2020; Dalenogare et al., 2018).

2. Metod

Detta kapitel redogör för den metodologiska ansats som använts i studien. Syftet med metoden är att undersöka hur artificiell intelligens kan integreras i Pontarius arbetsflöden för skadeidentifiering och projektövervakning. För att uppnå en helhetsförståelse kombineras teknisk modellanalys med semistrukturerade intervjuer med branschaktörer. På så sätt belyses både de tekniska förutsättningarna och de mänskliga, organisatoriska och affärsrelaterade aspekterna av AI-implementering. Kapitlet beskriver val av undersökningsstrategi, design, datainsamlingsmetoder och urval av respondenter.

2.1 Metodstrategi

Undersökningsstrategin för detta projekt är utformad enligt en kombinerad metodansats (mixed methods), inspirerad av Denscombe (2017), där både kvalitativa och kvantitativa inslag används för att uppnå en bredare och mer nyanserad förståelse. Den kvalitativa delen fokuserar på semistrukturerade intervjuer, medan den kvantitativa delen utgörs av teknisk genomgång och jämförelse av olika AI-modeller. Genom att använda en trianguleringsstrategi (Guba & Lincoln, 1985) stärks studiens validitet och tillförlitlighet, då flera typer av datakällor och perspektiv kombineras för att belysa samma problemområde.

Studiens design är en fallstudie, där Pontarius fungerar som det specifika fall som undersöks. Fallstudiemetodiken gör det möjligt att fördjupa sig i de kontextuella och operativa förutsättningar som påverkar implementeringen av AI i ett svenskt konsultföretag inom infrastrukturen. Fokus ligger på skadedetektion i vägar och byggnader, där UAV-teknik och AI-modeller undersöks för att förbättra effektivitet, precision och beslutsunderlag.

2.2 Intervjuer som datakälla

De semistrukturerade intervjuerna har en central roll i studien och syftar till att fånga upplevda möjligheter, hinder och risker med att införa AI i verkliga arbetsflöden. För att uppnå detta har intervjuer genomförts med personer som har praktisk erfarenhet av Pontarius verksamhet, både inom drönarinspektion och datahantering. Intervjupersonerna valdes strategiskt för att representera olika roller och erfarenhetsnivåer inom organisationen, såsom projektledare, tekniska konsulter och personer med insyn i digitaliseringsprocesser, men även fastighetsskötare på andra sidan spektrumet.

För att få en mer nyanserad bild har målsättningen varit att inkludera personer från olika bakgrunder och åldersgrupper, då attityder till ny teknik ofta kan skilja sig mellan generationer och beroende på roll i företaget. Detta möjliggör identifiering av både tekniska och mänskliga aspekter, såsom förändringsmotstånd, säkerhetsfrågor, kompetenskrav och systemintegration.

Exempelvis har intervjuerna lyft frågor om dataintegritet vid hantering av säkerhetsklassad information, behovet av utbildning kring AI-verktyg, samt oro för att AI ska tolkas som ett ersättningsverktyg snarare än ett komplement. Samtidigt framkommer en hög generell nyfikenhet och positiv inställning till AI, särskilt vad gäller effektivisering av uppgifter som idag upplevs som repetitiva eller manuella.

Intervjuerna har därmed fungerat som ett verktyg för att komplettera den tekniska analysen med organisatoriska och psykologiska perspektiv, samt för att identifiera praktiska flaskhalsar och behov som annars inte framgår i den teoretiska litteraturen. Ett urval av frågorna återfinns i bilagorna.

2.3 Datainsamlingens upplägg

Datainsamlingen genomfördes i flera steg:

1. **Inledande arbetsflödesanalys** – som ett första steg genomfördes en genomgång av Pontarius arbetsflöde, arbetsprocesser och deras verktyg för att skapa en överblick över befintliga processer och hitta nyckelfrågor.
2. **Litteraturstudie och urval av AI-modeller** – teoretisk granskning av relevanta tekniker (ex. YOLOv8, DeepCrack, Cha et al., Han et al., EfficientCrackNet).
3. **Semistrukturerade intervjuer** – genomförda både fysiskt och digitalt.

Denna strukturerade metodik gör det möjligt att kombinera teknisk utvärdering av AI-modeller med djupare insikter i branschens praktiska verklighet, vilket utgör en grund för de rekommendationer som presenteras i senare delar av rapporten.

2.4 Analys av intervjudata

Analysen av det insamlade intervjumaterialet har genomförts med en kvalitativ tematisk ansats, där syftet har varit att identifiera mönster, nyanser och återkommande teman i respondenternas svar. Arbetet har i huvudsak haft en induktiv karaktär, vilket innebär att analysen utgick från det empiriska materialet snarare än ett färdigt teoriramverk. Samtidigt vägledades tolkningen av studiens syfte och forskningsfrågor, vilket möjliggjorde en fokuserad men öppen tematisering.

Efter att intervjuerna transkriberats granskades materialet för att identifiera återkommande uttryck, begrepp och uppfattningar kopplade till exempelvis upplevda hinder, förväntningar, teknisk förståelse och tillit till AI. Dessa formuleringar kodades manuellt och grupperades successivt i flera teman. I denna process såg man centrala teman såsom säkerhetsaspekter, rollberoende inställningar till AI, kompetensgap och synen på användbarhet. Dessa teman har sedan legat till grund för struktureringen av resultatkapitlet.

2.5 Användning av AI i examensarbetet

Användningen av AI har till största delen bestått av att få hjälp med grammatik, meningsformuleringar, delvis informationssökning, datasammanfattning och text granskning. Den AI som har använts är OpenAi's - Chat-GPT - 4o och den har utnyttjats för att få en mer välformulerad text med variation i språket för att undvika upprepningar. AI har även använts för att få hjälp med källhänvisning i vissa fall.

3. Teoretisk bakgrund

I detta kapitel presenteras den teoretiska grunden för de artificiella intelligensmodeller som används i vårt examensarbete. Syftet är att ge en överblick över relevanta begrepp, metoder och tidigare forskning som ligger till grund för valet av modeller samt hur dessa tillämpas inom det aktuella problemområdet. I avsnittet skapas en förståelse för hur modellerna fungerar, deras styrkor och begränsningar, samt varför just dessa modeller är lämpliga för vår tillämpning.

3.1 DeepCrack och nyare lättviktsmodeller

DeepCrack är en avancerad djupinlärningsbaserad segmenteringsmodell som utvecklats för exakt och robust detektion av sprickor i bilder av vägytor och infrastruktur (Zou, Zhang, & Li, 2019). Modellen använder en hierarkisk arkitektur som extraherar och sammanfogar både låg- och hög-nivåegenskaper från bilddata, vilket möjliggör detektion av sprickor av varierande storlek, form och komplexitet.

3.1.1 Modellens uppbyggnad och funktionalitet

Kärnan i DeepCrack utgörs av en multi-scale convolutional feature learning-struktur, där information från olika skalnivåer integreras genom en multi-level hierarchical fusion. Denna strategi gör modellen kapabel att identifiera tunna och svår-detekterade sprickor även i utmanande förhållanden, såsom vid låga kontraster, brus eller varierande bakgrunder (Zou et al., 2019). DeepCrack använder ett end-to-end fully convolutional network (FCN), vilket innebär att segmenteringen av sprickor sker direkt från råbilder utan omfattande för- eller efterbehandling.

Träningen av DeepCrack har huvudsakligen baserats på publika dataset som CRACK500, där varje pixel i träningsbilderna annoterats som antingen tillhörande en spricka eller ej. Modellen använder en pixel-wise softmax loss-funktion, vilket möjliggör mycket exakt klassificering på pixelnivå. Prestandaresultat från tester visar att DeepCrack överträffar flera tidigare metoder, särskilt i sin förmåga att segmentera sprickor som är tunna, fragmenterade eller delvis dolda av andra visuella element.

En särskilt viktig egenskap hos DeepCrack är dess contextual feature learning, där spatiala relationer i bilden används för att förbättra segmenteringens noggrannhet. Detta gör modellen särskilt lämpad för UAV-inspektioner av vägytor, där skuggor, ljusvariationer och markstruktur kan skapa utmanande detektionsförhållanden. Dock bör noteras att DeepCrack inte är optimerad för realtidsapplikationer, eftersom dess djupa arkitektur kräver relativt mycket beräkningsresurser (Zou et al., 2019).

För att möta krav på snabbare och mer resurseffektiv sprickdetektion har nyare lättviktsmodeller utvecklats. EfficientCrackNet är en av dessa moderna varianter, som kombinerar konvolutionella nätverk och Transformer-komponenter för att möjliggöra realtidsdetektion på UAV- och edge-plattformar (Ma et al., 2023). Modellen är utformad för att reducera antalet parametrar och beräkningsoperationer avsevärt, samtidigt som noggrannheten bibehålls på en nivå jämförbar med mer komplexa system som DeepCrack.

EfficientCrackNet är därför ett attraktivt alternativ vid tillämpningar där omedelbar återkoppling från inspektionsdata är avgörande.

3.2 UAV och maskininlärning för automatiserad framstegsövervakning i markutvecklingsprojekt

För att förbättra effektiviteten och noggrannheten vid övervakning av markutvecklingsprojekt har Han, Hsu och Huang (2024) utvecklat en metod där UAV-teknik kombineras med maskininlärningsalgoritmer. Metoden syftar till att automatisera framstegsbedömningar och identifiering av avvikelser, vilket traditionellt sett har varit en manuell och arbetsintensiv process. Genom integrationen av UAV och maskininlärning möjliggörs en kontinuerlig, objektiv och mer tillförlitlig övervakning av utvecklingsområden.

3.2.1 Modellens uppbyggnad och funktionalitet

Den föreslagna metoden bygger på insamling av högupplösta ortofoton med hjälp av UAV-enheter. Dessa bilder används för att skapa noggranna 2D-kartor och 3D-modeller av utvecklingsplatserna. Med hjälp av bildsegmenterings- och objektidentifieringstekniker tränas maskininlärningsmodeller på att upptäcka och klassificera konstruktionselement såsom byggnader, vägar, manhål och diken. Modellen använder en kombination av supervised learning och spatial analys för att kunna jämföra insamlade data med designritningar och därigenom automatiskt bedöma projektens framsteg.

Ett viktigt inslag i Han et al.s metod är användningen av tidsseriedata. Genom att regelbundet samla in och analysera UAV-data över tid möjliggörs detektering av förändringar och avvikelser från planerad utveckling. Systemet är utformat för att snabbt bearbeta stora mängder bilddata, vilket förutsätter en välutvecklad infrastruktur för datalagring och beräkningskraft.

Dessutom inkluderar metoden en säkerhetsmodul som automatiskt identifierar potentiellt farliga områden, där till exempel skyddsbarriärer bör installeras för att minska olycksrisken. Detta breddar användningsområdet från enbart framstegsövervakning till även att omfatta arbetsmiljösäkerhet.

3.2.2 Datakrav och systemarkitektur

För att metoden ska kunna fungera effektivt krävs högkvalitativa UAV-bilder, med jämn upplösning och minimala störningar från skuggor och varierande ljusförhållanden. En annan förutsättning är tillgång till korrekt georefererad data, vilket innebär att bilderna måste kopplas till exakta geografiska koordinater, ofta med hjälp av GNSS-teknik.

Den tekniska arkitekturen som föreslås av Han et al. omfattar en pipeline där data först samlas in via UAV, därefter bearbetas och analyseras i maskininlärningsmoduler, och slutligen visualiseras i kartgränssnitt och rapporteringssystem. Modellen är utformad för att vara skalbar och kan anpassas till olika typer av markutvecklingsprojekt, från mindre anläggningsarbeten till större stadsutvecklingsområden.

3.2.3 Tillämpningsområden och nytta

Han et al.'s. (2024) studie visar att metoden kan minska den mänskliga insats som krävs för framstegsövervakning avsevärt, samtidigt som den förbättrar datanoggrannheten och möjliggör snabbare reaktion vid identifierade avvikelser. Den automatiserade processen minskar risken för mänskliga fel och kan bidra till att projekt hålls inom angivna tids- och kostnadsramar. Därutöver möjliggör användningen av maskininlärning för kontinuerlig analys en ökad transparens och spårbarhet i projektuppföljningen, vilket kan vara särskilt värdefullt vid komplexa och tidskritiska projekt.


Han et al. (2024) understryker även vikten av teknisk kompetens och lämplig IT-infrastruktur för att kunna implementera systemet framgångsrikt. Detta inkluderar behov av serverkapacitet, dataskyddslösningar och möjlighet till integration med befintliga projekthanteringssystem.

3.3 Deep learning-baserad strukturell hälsomonitorering i UAV-inspektioner

För att förbättra och automatisera inspektionsprocesser i infrastrukturella tillämpningar, har Cha, Ali, Lewis och Büyükoztürk (2024) utvecklat ett avancerat system för strukturell hälsomonitorering (Structural Health Monitoring, SHM) baserat på deep learning och UAV-teknik. Deras metod syftar till att identifiera sprickor och andra typer av strukturella defekter i exempelvis broar och byggnader genom analys av högupplösta bilder insamlade från drönare. Genom att integrera UAV och deep learning-modeller möjliggörs en snabbare, mer konsekvent och objektiv bedömning av skadestatus jämfört med traditionella manuella inspektionsmetoder.

3.3.1 Modellens uppbyggnad och funktionalitet

Cha et al. (2024) föreslår en flerlagers deep learning-arkitektur där konvolutionella neurala nätverk (CNN) används för att automatiskt extrahera bildfunktioner och klassificera skador. Modellen tränas på stora mängder annoterade bilder för att kunna identifiera olika typer av strukturella defekter, såsom sprickor, materialförslitningar och deformationer, under varierande miljöförhållanden. Till skillnad från enklare mönsterigenkänningsmetoder tillämpar modellen en hierarkisk analys, där både globala och lokala egenskaper hos skador beaktas.



Figur 1. Schematisk illustration av skadeklassificering med hjälp av sliding window och CNN (Cha, Ali, Lewis & Büyükoztürk, 2024).

Bilden visar hur ett konvolutionellt neuralt nätverk (CNN) används för att klassificera sprickor i en bildsekvens. En glidande ruta (sliding window) rör sig över indata-bilden, extraherar bildutsnitt och skickar dessa till en tränad CNN-modell som avgör om en spricka finns inom varje ruta. Den högra bilden visar slutresultatet där de identifierade sprickområdena markeras .

Bilddata från UAV-flygningar bearbetas i flera steg, där först förbehandling sker för att reducera brus och normalisera ljusförhållanden. Därefter utförs en initial segmentering för att identifiera potentiella skador, följt av en mer detaljerad klassificering baserad på morfologiska och texturbaserade funktioner. Detta flerstegsangrepp bidrar till att minska risken för falska positiva resultat och ökar noggrannheten i detekteringen.

En av de innovativa aspekterna i Cha et al.s metod är användningen av ensemble learning, där flera olika deep learning-modeller kombineras för att förbättra klassificeringsprestandan. Detta ökar systemets robusthet och möjliggör bättre generalisering till nya och varierande inspektionsmiljöer.

3.3.2 Datakrav och implementeringsaspekter

För att säkerställa hög noggrannhet och tillförlitliga resultat kräver metoden tillgång till omfattande träningsdata med hög upplösning och noggrant annoterade defekter. Hanteringen av stora datamängder ställer krav på betydande datalagringskapacitet och hög beräkningskraft, vilket i praktiken innebär att systemet måste stödjas av kraftfulla servrar eller molntjänster för effektiv dataprocessering.

Vidare poängterar Cha et al. vikten av regelbunden modelluppdatering för att bibehålla systemets prestanda över tid. Eftersom infrastrukturen förändras och nya typer av skador kan uppstå krävs ett kontinuerligt inflöde av ny träningsdata och återträning av modellerna. Detta innebär också att kvaliteten på UAV-insamlad bilddata måste standardiseras och att operativa riktlinjer för drönarflygningar behöver följas noggrant för att undvika variationer som kan påverka analysresultaten.

3.3.3 Tillämpningsområden och utmaningar

Cha et al.s deep learning-baserade SHM-system kan appliceras på ett brett spektrum av infrastrukturella objekt, inklusive broar, tunnlar, byggnader och andra konstruktioner där strukturell integritet är avgörande för säkerheten. Genom att automatisera inspektionsprocessen kan systemet bidra till att minska beroendet av manuella kontroller, vilket leder till snabbare inspektionscykler, minskade kostnader och ökad säkerhet för inspektionspersonal.

Samtidigt identifierar studien flera utmaningar vid praktisk tillämpning. Bland annat kräver metoden tillgång till konsistent och högkvalitativ bilddata, vilket kan vara svårt att säkerställa vid flygningar under ogynnsamma väderförhållanden eller i komplexa miljöer. Andra utmaningar inkluderar behovet av anpassning av modeller till olika infrastrukturella kontexter och risken för felklassificering vid skador som avviker från tidigare träningsdata.

Genom att kombinera UAV-teknik, avancerad bildanalys och deep learning-metoder utgör Cha et al.s arbete en viktig referenspunkt för utvecklingen av framtida AI-baserade system för infrastrukturell skadeinspektion och hälsomonitorering.

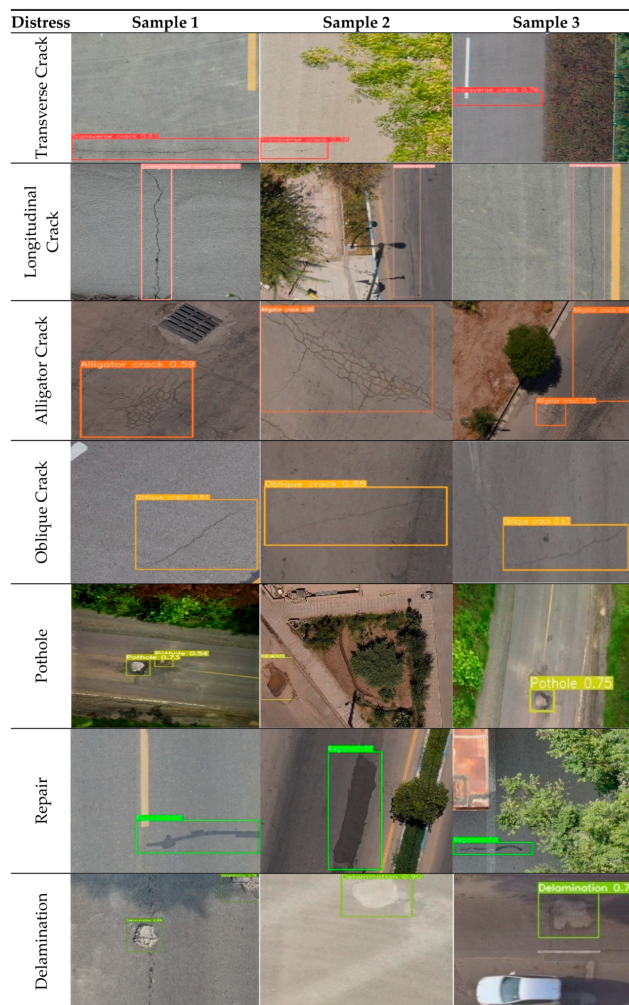
3.4 YOLOv8 för skadedetektion i UAV-baserade vägyteinspektioner

För att möjliggöra effektiv och automatiserad identifiering av vägsador baserat på UAV-bilddata har Samadzadegan, Dadrass Javan, Ashtari Mahini, Gholamshahi och Nex (2023) utvecklat en metod som använder den avancerade deep learning-modellen YOLOv8. Metoden syftar till att förbättra snabbheten och noggrannheten vid upptäckt av olika typer av skador på vägbanor, såsom längsgående sprickor, tvärgående sprickor, sneda sprickor och potthål. Genom integrationen av UAV-teknik och YOLOv8 skapas en skalbar och realtidskapabel lösning som kan användas för omfattande infrastrukturella inspektioner.

3.4.1 Modellens uppbyggnad och funktionalitet

YOLOv8 (You Only Look Once version 8) är en objektigenkänningsmodell som är särskilt anpassad för realtidsdetektion med hög precision. I Samadzadegan et al.s arbete tränas modellen med hjälp av ett omfattande dataset bestående av 5 796 UAV-bilder av vägytor, där varje bild innehåller annoteringar för sju typer av vägrelaterade skador. Modellen är utformad för att genomföra end-to-end-detektion och klassificering i ett enda steg, vilket möjliggör snabba analyser utan att kompromissa med noggrannheten.

En viktig styrka i YOLOv8 är dess förmåga att hantera små objekt och komplexa bakgrunder, vilket ofta förekommer i UAV-bilder av vägnät. Arkitekturen bygger på en kombination av Feature Pyramid Networks (FPN) och Path Aggregation Networks (PAN), som effektivt integrerar bildinformation från olika nivåer av nätverket för att maximera detektionsprestandan. Förlustfunktionen är en kombination av klassificerings-, lokaliserings- och objektivitetsförluster, vilket bidrar till en balanserad optimering av modellens olika mål.



Figur 2. Exempel på identifiering av olika typer av vägsador i UAV-bilder. (Samadzadegan et al., 2023). Bilden visar hur YOLOv8-modellen detekterar olika typer av beläggningsskador från drönarbilder, inklusive tvärgående sprickor, längsgående sprickor, alligator-sprickor, sneda sprickor, pothål, lagningar och delaminering. Varje skadetyper är markerad med rektanglar och klassificeringsetiketter, vilket illustrerar modellens förmåga att särskilja mellan olika skadeformer under varierande förhållanden.

Enligt resultaten i studien uppnår YOLOv8 en genomsnittlig noggrannhet (mAP) på 79 % och en precision på 77 %, vilket demonstrerar dess kapacitet att på ett tillförlitligt sätt identifiera skador även under varierande ljusförhållanden och i närvaro av brus och skuggor.

3.4.2 Datakrav och systemkrav

För att YOLOv8 ska prestera optimalt krävs högupplösta UAV-bilder som täcker de skadetyper modellen tränats på. Bildinsamlingen behöver vara konsekvent avseende flyghöjd, bildöverlappning och ljusförhållanden för att säkerställa att tränings- och testdata liknar inspektionsdata. Modellen är kapabel att köras i realtid på kraftfullare edge-enheter eller servrar, vilket gör det möjligt att bearbeta stora datamängder snabbt efter UAV-inspektioner.

Dessutom påpekar Samadzadegan et al. vikten av att kontinuerligt uppdatera modellen med nya bilddata för att upprätthålla hög prestanda över tid, särskilt när vägmateriäl, slitage eller omgivningsförhållanden förändras.

3.4.3 Tillämpningsområden och utmaningar

YOLOv8:s egenskaper gör den särskilt lämplig för användning i storskaliga vägyteinspektioner där snabbhet och realtidsrespons är avgörande. Genom att kunna identifiera och klassificera flera typer av skador på kort tid möjliggör modellen effektiv prioritering av underhållsbehov och stöd för proaktiva underhållsstrategier.

Bland de utmaningar som nämns i studien finns svårigheter kopplade till variationer i skadeutseende och vägmateriäl, vilka kan leda till försämrade detektionsnoggrannhet om modellen inte tränas på tillräckligt representativa dataset. Skuggor, bländning och andra störningar i UAV-bilder kan också påverka modellens prestanda och kräver noggrann bildförbehandling eller vidareutvecklade algoritmer för robusthet.

Genom att kombinera UAV-baserad bildinsamling med YOLOv8:s kapacitet för snabb och exakt objektigenkänning erbjuder Samadzadegan et al.s arbete en kraftfull lösning för framtidens vägunderhålls- och inspektionssystem.

3.5 Användbarhet, teknisk acceptans och förändringsvilja

För att artificiell intelligens ska få genomslag i praktiken räcker det inte med teknisk kapacitet, det krävs också att användarna upplever systemen som begripliga, användbara och förenliga med befintliga arbetsrutiner. Forskning visar att den mänskliga faktorn är avgörande för teknologins framgång (Davis, 1989; Venkatesh et al., 2003).

Technology Acceptance Model (TAM), utvecklad av Davis (1989), identifierar två nyckelfaktorer för att en teknik ska accepteras: *upplevd användbarhet* (perceived usefulness) och *upplevd användarvänlighet* (perceived ease of use). Dessa påverkar i sin tur individens attityd till tekniken och viljan att använda den.

En vidareutveckling av TAM är Unified Theory of Acceptance and Use of Technology (UTAUT) som bland annat inkluderar faktorer som social påverkan och förväntad ansträngning (Venkatesh et al., 2003). Detta är användbart för att förstå skillnaden i acceptans mellan olika yrkesroller, exempelvis att tekniskt insatta konsulter inom Pontarius visar högre acceptans för AI jämfört med mer operativa roller. Flera av de AI-modeller som undersökts, såsom YOLOv8, bygger på avancerade neurala nätverk och kan i sin standardform vara svåra att tolka för slutanvändare (Samadzadegan et al., 2023). Detta understryker behovet av tydliga gränssnitt och utbildningsinsatser för att sänka tröskeln till användning, särskilt i branscher där traditionella arbetssätt dominerar. I denna studie används TAM och UTAUT inte som primära analytiska ramverk, utan snarare som ett orienterande perspektiv för att kontextualisera hur teknisk acceptans och användbarhet kan förstås i relation till intervjurespondenternas upplevelser.

Förändringsvilja är också en kritisk faktor. Motstånd mot ny teknik kan bota i oro för informationssäkerhet, bristande utbildning eller rädsla för att tekniken ska ersätta befintliga


arbetssätt (Cha et al., 2024). Därför bör AI-implementering inte endast betraktas som en teknisk övergång utan även som en organisatorisk och kulturell förändringsprocess.

4. Implementering

I detta kapitel presenteras förslag på implementering av de AI-modeller som identifierats som potentiellt användbara för Pontarius verksamhet. Fokus ligger på hur de utvalda modellerna kan integreras i arbetsflöden för skadeidentifiering, spricksegmentering, strukturell hälsomonitorering och byggprocessövervakning. Implementeringsförslagen baseras på analyser av modellerna YOLOv8, DeepCrack, Cha et al:s metod och Han et al:s metod, där varje delkapitel beskriver respektive modells funktionalitet, tekniska krav och potentiella tillämpningar inom Pontarius specifika kontext.

4.1 Implementering av YOLOv8 för realtidsdetektion av vägyteskador

För att möta Pontarius behov av snabb skadeidentifiering i fält har modellen YOLOv8 identifierats som särskilt lämplig. YOLOv8 är optimerad för realtidsdetektion och möjliggör därmed omedelbar analys av bilddata från UAV-inspektioner. Genom att integrera modellen i Pontarius arbetsflöde kan skadeidentifiering av vägytor ske direkt efter UAV-flygningar, vilket möjliggör snabb återkoppling till platsledning och andra berörda parter.



Figur 3. UAV-baserad identifiering av olika typer av vägsador (Samadzadegan et al., 2023). Bilden illustrerar hur en drönare används för att övervaka vägytor från luften och identifiera olika typer av skador.

Den föreslagna implementeringen innebär att drönaren efter flygning omedelbart laddar upp bildmaterialet till en edge-enhet eller server där YOLOv8 körs. Modellen bearbetar då bilderna och identifierar samt klassificerar skador såsom längsgående och tvärgående sprickor, sneda sprickor och potthål. Resultaten kan presenteras i ett användargränssnitt där skadornas position och typ visualiseras på en karta, vilket möjliggör snabb prioritering av underhållsåtgärder.

För optimal realtidsanvändning bör UAV-systemen integreras med en kraftfull databehandlingsenhet (exempelvis en GPU-baserad dator) antingen ombord på drönaren eller

stationerad i närheten av arbetsplatsen. Alternativt kan molntjänster användas om tillgång till tillförlitliga nätverk finns.

Implementeringen av YOLOv8 kan effektivisera skadeinspektionsprocessen genom att minska tiden mellan datainsamling och beslutsfattande, vilket är särskilt värdefullt vid akuta skador som kräver omedelbara åtgärder. För att säkerställa hög precision krävs dock en initial anpassning av modellen med hjälp av bilddata från svenska vägförhållanden och Pontarius typiska arbetsmiljöer, inklusive variationer i asfaltens struktur, färg och materialval.

En viktig aspekt vid införandet är att hantera utmaningar relaterade till bildkvalitet, såsom skuggor, rörelseoskärpa och väderförhållanden. Dessa faktorer kan påverka modellens prestanda och måste beaktas i insamlingsprotokollen. Trots dessa utmaningar erbjuder YOLOv8 en kraftfull lösning för att integrera realtids AI-baserad skadeidentifiering i Pontarius befintliga UAV-inspektionsprocesser.

4.2 Implementering av DeepCrack för detaljerad sprickanalys

För att komplettera realtidsidentifieringen av skador med en mer detaljerad och noggrann analys föreslås implementering av DeepCrack i Pontarius arbetsflöde. DeepCrack är särskilt lämpad för att utföra pixelnivåsegmentering av sprickor, vilket möjliggör exakt kartläggning av sprickornas geometri, bredd och längd. Modellen kan användas som ett andra analyssteg efter en initial snabbdetektion, där de områden som flaggats av till exempel YOLOv8 kan analyseras i högre detalj.

Implementeringen av DeepCrack innebär att insamlade UAV-bilder från de identifierade riskområdena bearbetas i en kraftfull servermiljö där modellen segmenterar sprickorna direkt från råbilderna. Resultatet är högupplösta sprickmasker som kan användas för att kvantifiera skadornas omfattning och allvarlighetsgrad. Detta möjliggör en mer grundlig skadekartering, som kan integreras i Pontarius befintliga GIS-system eller 3D-modeller för vidare analys och underhållsplanering.

Det är viktigt att notera att DeepCrack inte är optimerad för realtidsbearbetning i fält. Beräkningskraven är relativt höga, och bearbetningen bör därför ske offline efter UAV-flygning. För att förbättra anpassningen till Pontarius specifika arbetsmiljöer rekommenderas att modellen tränas vidare på insamlade bilder från svenska vägar och flygplatser, med variationer i asfaltens utseende och material.

För framtida utveckling kan lättare varianter av DeepCrack övervägas, såsom EfficientCrackNet, som utvecklats för att möjliggöra realtidsdetektion med liknande noggrannhet. Dessa optimerade modeller kan integreras om behovet av direkt sprickanalys i fält ökar.

Sammanfattningsvis erbjuder DeepCrack en robust och exakt lösning för detaljerad skadekartering och kan fungera som ett viktigt stödverktyg i Pontarius arbete med att effektivisera skadeinspektion och underhållsbeslut.

4.3 Implementering av Cha et al:s metod

Cha et al. (2024) presenterar en metod för automatiserad skadebedömning av infrastrukturella konstruktioner, särskilt broar, genom att kombinera UAV-insamlad bilddata med avancerade neurala nätverksmodeller. Denna modell, som använder sig av deep learning-baserad bildanalys, är direkt tillämpbar på Pontarius verksamhet, där skador på asfaltytor, betongkonstruktioner och byggnader regelbundet dokumenteras och analyseras. Genom att ta tillvara på modellens styrkor kan Pontarius effektivisera sin skadedetektion och öka tillförlitligheten i sina inspektionsresultat.

Modellen från Cha et al. är särskilt användbar för att upptäcka och klassificera olika typer av strukturella defekter såsom sprickor, avflagningar och korrosion. Den tränas på annoterade UAV-bilder och uppvisar hög noggrannhet även under varierande miljöförhållanden. Detta innebär att metoden lämpar sig väl för svenska väderförhållanden och komplexa ytskikt som ofta förekommer i Pontarius uppdrag, exempelvis på flygplatser, gångbanor och äldre betongtytor. En viktig styrka är att modellen inte bara upptäcker skador, utan också kan rangordna dem efter allvarlighetsgrad, vilket stödjer prioritering av underhållsåtgärder.

I Pontarius arbetsflöde kan modellen implementeras genom att UAV-bilder som samlas in vid återkommande inspektioner matas in i en tränad deep learning-modell för automatisk analys. Resultatet kan presenteras som riskkartor eller annoterade bilder där skador är markerade och kategoriserade. För att modellen ska fungera optimalt krävs antingen att Pontarius använder öppna träningsdatamängder från bro- eller väginspektioner med liknande förhållanden, eller att de själva bygger upp ett eget annoterat dataset från tidigare uppdrag. Det senare alternativet skulle skapa bättre anpassning till svenska förhållanden men kräver initialt en högre insats.

Cha et al. (2024) lyfter även fram vikten av att integrera analysresultaten med existerande GIS- eller BIM-system, vilket är direkt överförbart till Pontarius befintliga arbetsmetoder. Genom att resultat från AI-modellen integreras i deras geografiska informationssystem kan beslutsfattare snabbt visualisera skadornas placering och omfattning. I kombination med annan insamlingsdata, till exempel från 3D-skanning eller lidar, skapas ett kraftfullt beslutsunderlag som stödjer både akut åtgärd och långsiktig planering.

Slutligen kan metoden även kombineras med realtidsverktyg som YOLOv8 för snabb initial screening, medan Cha et al:s metod används i ett senare steg för fördjupad analys. Detta öppnar för ett arbetsflöde där Pontarius kan uppnå både snabbhet och precision i sin skadebedömning – utan att behöva kompromissa med kvalitet eller säkerhet.

4.4 Implementering av Han et al:s metod

Han, Hsu och Huang (2024) föreslår ett heltäckande system för automatiserad övervakning av markutvecklingsprojekt genom att integrera UAV-teknik och maskininlärning. Deras metod fokuserar på att analysera byggprocessens fortskridande över tid, identifiera potentiellt farliga zoner samt säkerställa att arbetet följer fördefinierade ritningar och kvalitetsstandarder. Även om Pontarius inte i dagsläget driver större markutvecklingsprojekt, är de tekniker som beskrivs i artikeln direkt överförbara till flera av företagets affärsområden, såsom planering och övervakning av anläggningsarbeten, flygplatsunderhåll och samhällsbyggnadsprojekt.

En central del i Han et al:s metod är att UAV-bilder används för att automatiskt identifiera objekt och jämföra dessa med digitala ritningar eller BIM-modeller för att utvärdera byggprocessen. Modellen tillämpar bildsegmentering och objektigenkänning med hjälp av machine learning-algoritmer, vilket innebär att t.ex. brunnar, diken, kantstenar och andra fysiska objekt kan lokaliseras och spåras över tid. Denna typ av funktionalitet är mycket relevant för Pontarius, som idag arbetar med både 3D-skanning och UAV-baserad datainsamling. Genom att koppla denna typ av AI till befintliga projektplaneringsverktyg kan de automatiskt kontrollera att utfört arbete överensstämmer med plan.

För Pontarius kan implementationen ske genom att använda insamlad UAV-data från anläggningsområden, som t.ex. flygplatsramper eller gatuombyggnader, där olika objekt och arbetsmoment behöver kontrolleras i sekvenser. AI-modellen skulle kunna tränas med hjälp av tidigare insamlade bilder där objekt som diken, vägkanter och ledningsbrunnar annoterats. Denna modell kan därefter användas för kontinuerlig uppföljning under byggtiden. På så sätt får Pontarius ett digitalt beslutsstöd som inte bara visar var skador finns, utan också hur långt arbetet kommit och om något avviker från plan.

En annan fördel som Han et al. (2024) betonar är möjligheten att upptäcka farozoner eller områden där skyddsutrustning saknas. Genom att identifiera sådana riskzoner från luften skulle Pontarius kunna bidra till ökad säkerhet på sina projektplatser. Detta blir särskilt relevant i känsliga miljöer som flygplatser eller tät trafikmiljö där säkerhet är avgörande.

Metoden är också skalbar och lämpar sig för stora datamängder, vilket gör den lämplig för att användas i kombination med Pontarius övriga AI-inspektioner. Genom att integrera denna typ av processövervakning med modeller som DeepCrack och YOLOv8 kan företaget få ett helhetsgrepp om både skadestatus och bygg progress i sina projekt. Därmed kan Han et al:s system fungera som en bredare plattform för automatiserad inspektion, kvalitetskontroll och säkerhetsövervakning inom Pontarius verksamhet.

4.5 Sammanvägd tillämpning och modellinteraktion

De fyra analyserade AI-modellerna i detta kapitel adresserar olika delar av Pontarius behov inom skadeidentifiering, dokumentation och processuppföljning. Genom att kombinera deras styrkor i ett gemensamt arbetsflöde kan ett mer robust, automatiserat och effektivt inspektionssystem skapas som inte bara upptäcker skador, utan också klassificerar deras allvarlighetsgrad, följer upp över tid och levererar beslutsunderlag i realtid.

En logisk inledande komponent i ett sådant flöde är YOLOv8, som tack vare sin höga prestanda i realtidsigenkänning kan användas för snabb initial screening. Under pågående UAV-inspektioner kan modellen identifiera objekt eller skador omedelbart och förse platspersonal med relevant information under inspektionens gång (Samadzadegan et al., 2023). Detta ökar möjligheterna för omedelbara åtgärder vid akuta fel, exempelvis på flygplatser där driftstörningar till följd av skador kan ha stora konsekvenser.

Efter denna initiala screening tar modeller som DeepCrack och EfficientCrackNet vid för att leverera en mer detaljerad och exakt analys av upptäckta skador. DeepCrack är särskilt lämpad för noggrann segmentering av komplexa sprickmönster, även i svårbedömda miljöer,

tack vare sin djupa hierarkiska arkitektur och pixelbaserade noggrannhet (Zou, Zhang & Li, 2019). EfficientCrackNet å sin sida erbjuder en mer resurssnål och snabb variant som möjliggör realtidsanvändning i fält, vilket gör den idealisk när hårdvarubegränsningar föreligger (Ma et al., 2023). Kombinationen av dessa två modeller gör det möjligt att välja mellan hög precision och realtidskapabilitet beroende på kontext och tillgängliga resurser.

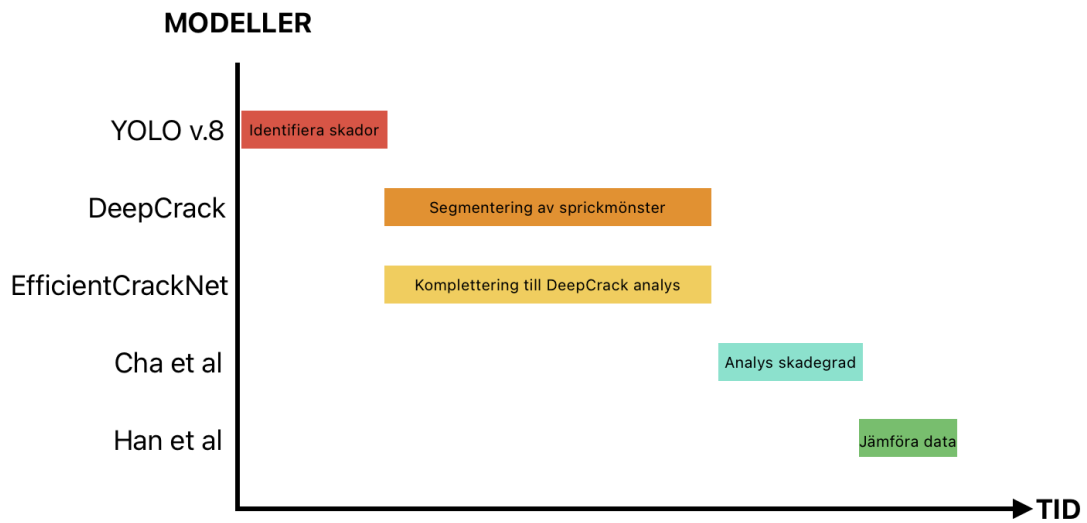
För att ytterligare förädla skadeinformationen kan Cha et al:s metod användas för att klassificera och bedöma skadornas allvarlighetsgrad. Med sin strukturella hälsomonitorering (SHM) och djupa neurala arkitektur kan modellen analysera defekters morfologi och föreslå prioriteringar i underhållsåtgärder (Cha, Ali, Lewis & Büyükoztürk, 2024). I praktiken fungerar modellen som ett beslutsstöd för tekniska konsulter och projektledare hos Pontarius, som då får bättre underlag för att planera åtgärder baserat på skadans omfattning och risknivå.

Han et al:s modell förstärker denna kedja genom att tillföra möjligheten att följa upp projektets framsteg över tid, säkerställa att utförda åtgärder motsvarar planerade, samt detektera avvikelser (Han, Hsu & Huang, 2024). Genom att jämföra UAV-insamlade bilder med digitala ritningar och fördefinierade objektpositioner fungerar modellen som ett digitalt kontrollverktyg för både utförd kvalitet och täckning. Denna aspekt är särskilt relevant för Pontarius i rollen som samordnande teknikkonsult i mark- och anläggningsprojekt.

Sammantaget kompletterar modellerna varandra både funktionellt och tekniskt. YOLOv8 erbjuder snabbhet men med viss begränsning i noggrannhet vid små skador. DeepCrack ger hög precision men kräver mer bearbetningstid. EfficientCrackNet fyller glappet mellan dessa två med en balanserad realtidslösning. Cha et al. tillför kontextuell bedömning och allvarlighetsklassificering, medan Han et al. skapar möjligheter för processuppföljning och dokumentation i ett bredare tidsperspektiv. Denna kombination möjliggör en kontinuerlig kedja från upptäckt till åtgärd, där varje modell svarar mot olika krav i ett distribuerat AI-system – något som är centralt för att realisera potentialen i UAV-inspektioner på riktigt.

För att konkretisera flödet kan ett scenario beskrivas där en UAV-inspektion av en flygplats utförs. Först används YOLOv8 för att snabbt identifiera potentiella skador på landningsbanan. Dessa markerade områden skickas sedan till DeepCrack och EfficientCrackNet för detaljerad spricksegmentering och kvantifiering. Därefter används Cha et al:s metod för att analysera skadornas allvarlighetsgrad och rangordna dem baserat på risk och omfattning. Slutligen kan Han et al:s modell användas för att jämföra insamlade data med ursprungliga ritningar och säkerställa att inga avvikelser från planerade åtgärder har inträffat.

Genom att kombinera modellerna i en sekventiell pipeline kan ett robust flöde etableras: YOLOv8 för realtidsupptäckt, DeepCrack eller EfficientCrackNet för finmaskig spricksegmentering, Cha et al. för riskbedömning, och Han et al. för dokumentation och uppföljning. Samtliga modeller kan antingen implementeras i modulär form eller integreras i en gemensam plattform för datavisualisering och beslutsstöd. Nedan illustreras en tidsplan för hur det skulle kunna se ut:



Figur 3. Illustration av tidsplan AI-modeller (Skapad i freeform av David Nordin)

För Pontarius innebär detta en möjlighet att få en helhetssyn på inspektion, från fältdata till analys och åtgärdsplanering, vilket stärker både konkurrenskraft och kvalitet i deras tjänsteerbjudande.

5. Begränsningar och risker vid AI-implementering

Implementeringen av de analyserade AI-modellerna i Pontarius arbetsflöde erbjuder betydande möjligheter till förbättrad skadeidentifiering och övervakning av byggprocesser. Dock medför teknikintegrationen även vissa begränsningar och risker som behöver beaktas för att säkerställa en framgångsrik och långsiktig implementering.

5.1. Tekniska begränsningar

Enligt Zou et al. (2019) är DeepCrack starkt beroende av högupplösta bilder och konsekvent bildkvalitet. Vid UAV-inspektioner under ogynnsamma väderförhållanden, med skuggor, bländning eller rörelseoskärpa, kan modellen misslyckas med att korrekt identifiera sprickor, vilket kan leda till missvisande analysresultat. Samadzadegan et al. (2023) framhåller att YOLOv8 kan prestera sämre vid små sprickor eller skador som döljs av skuggor eller andra visuella störningar. Förlust av detaljer kan särskilt påverka modellens precision vid realtidsanalys där bilderna bearbetas snabbt.

Cha et al. (2024) diskuterar riskerna med överanpassning i deep learning-modeller. Om modellen tränas på ett dataset med specifika skadetyper kan den få svårt att generalisera till nya kontexter eller oväntade skademönster. Detta är särskilt kritiskt i varierande miljöer som flygplatser och vägnät där skador kan variera i utseende och intensitet. Samtidigt betonar Han et al. (2024) vikten av regelbundna modelluppdateringar för att bibehålla systemets prestanda över tid. Om UAV-bilderna inte uppdateras kontinuerligt kan modellen förlora sin förmåga att exakt detektera förändringar, vilket minskar dess operativa värde.

5.2. Organisatoriska risker

I Pontarius kontext innebär detta att UAV-flygningar måste planeras noggrant för att säkerställa enhetlig bildkvalitet, särskilt vid inspektioner av vägytor, flygplatser och andra komplexa miljöer. Hanteringen av false positives och false negatives kan bli kostsam om modellerna genererar onödiga varningar som kräver manuell uppföljning. Vidare är integrationen av AI-modeller i UAV-baserade arbetsflöden beroende av att bildmaterialet är enhetligt och följer specifika protokoll för flyghöjd, vinkel och överlappning. Detta är särskilt viktigt för DeepCrack och EfficientCrackNet, som kräver detaljerad pixelklassificering för att leverera precisa segmenteringsresultat.

En annan risk är systemkompatibilitet och dataintegration. Pontarius använder redan befintliga 3D-modeller för dokumentation och planering. Implementeringen av flera AI-modeller med olika datakrav kan kräva omfattande anpassningar för att säkerställa att analysresultaten kan integreras i dessa system utan informationsförlust. Att underhålla och uppdatera modellerna över tid innebär även resursmässiga utmaningar, särskilt eftersom realtidsanalys eftersträvas.

En annan risk är personalens förståelse för de implementerade AI-modellerna. Många AI-modeller, såsom DeepCrack och Cha et al:s metod, är komplexa och kan vara svåra att tolka för tekniker som inte är insatta. Detta kan leda till missförstånd eller felaktig tolkning av analysresultaten, vilket i sin tur kan påverka beslutskvaliteten. En bristande förståelse för modellernas funktionssätt kan också göra det svårare att upptäcka när en modell genererar felaktiga resultat, vilket kan leda till att skador förbises eller överdrivs.

Slutligen kan motstånd mot förändring utgöra en organisatorisk risk. Implementeringen av AI innebär ofta en omställning från traditionella, manuella arbetsprocesser till mer digitaliserade och automatiserade arbetsflöden. Om personalen inte upplever sig ha tillräckligt stöd eller utbildning kan det leda till motstånd mot användningen av AI-systemen, vilket minskar deras effektivitet och potential (Hays, 2024). För att minimera dessa risker bör Pontarius investera i utbildning och kontinuerlig kompetensutveckling inom AI och dataanalys, samt säkerställa att användargränssnitt och rapporter är tydliga och lätta att tolka.

Sammanfattningsvis kräver en framgångsrik AI-implementering i Pontarius verksamhet inte bara teknisk anpassning av modellerna, utan även en strukturerad pipeline för datainsamling, bearbetning och integrering. Genom att etablera tydliga riktlinjer för UAV-inspektioner och säkerställa att insamlade data följer modellernas krav kan riskerna minimeras och modellernas prestanda optimeras.

6. Insamling av data och branschperspektiv

För att få en djupare förståelse för branschens inställning till AI-implementering och de utmaningar som kan uppstå, genomfördes intervjuer med nyckelpersoner inom företaget och externa företag i branschen. Intervjuerna syftade till att undersöka hur AI uppfattas i nuvarande arbetsprocesser, vilka specifika områden som anses ha störst potential för AI-baserade lösningar, hur man ser på användningen av AI idag i verksamheten, samt vilka risker och hinder som identifieras av branschexperter.

Frågorna i intervjuerna var strukturerade kring centrala teman såsom teknisk kompetens samt organisatoriska och kulturella hinder. Syftet var att identifiera de områden där AI kan bidra till effektivisering och förbättrad skadeidentifiering samt de flaskhalsar som kan motverka implementeringen av AI. De specifika frågorna som ställdes till respondenterna finns att läsa i medföljande bilagor.

De respondenter som intervjuats är Filip Birkeland, verksam inom drönbaserade inspektioner, och Johanna Sandén, också delvis inom drönbaserad verksamhet, båda från Pontarius. Vidare har även Tomas Eriksson, fastighetschef på DB Schenker, och Magnus Nordin, fastighetsägare till IN Fastigheter, intervjuats. Även en anonym respondent A, anställd fastighetsskötare på företaget i Göteborg, har varit deltagande i intervju. Deras svar sammanställs och jämförs i kommande delavsnitt.

6.1 Teknikacceptans

En av frågorna som diskuterades under intervjun var hur respondenterna ställde sig till användningen av ny teknik, i form av AI. De svar som noterades varierade och en trolig faktor till det var åldersfördelningen. Filip, en av de yngre respondenterna, som dagligen använder sig av mycket teknik uttryckte sin positivitet till att implementera AI som verktyg för att underlätta arbetsprocesser. Johanna förmedlade, likt Filip, sin positiva inställning till AI och nämnde att *“Generationsskillnaden, kollegor som är äldre har ingen aning om vad man kan få ut av AI”* antagligen är den största faktorn i hur tekniken uppfattas. Tomas, som tillhör den äldre generationen, håller med de andra i frågan om generationsskillnad och menar att den äldre generationen hänger inte med i den snabba utvecklingen utan är mer *“konservativa”* i sitt arbetssätt. Något som även Magnus menar stämmer, där han är tydlig med att hans egen oförmåga och okunskap sätter begränsningar.

Det visade sig dock finnas en hel del skepsis kring acceptansen av ny teknologi hos de längre ner i hierarkin, där mycket av det arbete som görs är fysiskt. Respondenten menar att det är onödigt att förändra ett arbetssätt som fungerar och är inte för att låta *“en dator”* genomföra hans arbete. Han ställer sig alltså mot de tidigare respondenternas åsikter om att acceptera ny teknik. Även här är det dock en generationsfråga, där den svarande tillhör de äldre och generellt sett hållt sig till *“traditionella metoder”*.

De flesta av respondenterna har varit för att implementera ny teknik, då de tror att AI kommer bli en användbar del i arbetet i framtiden. Det är tydligt att det handlar om en skillnad i kunskap om ämnet och verktyget mellan den yngre och äldre generationen, men att inställningen till att implementera AI är trots allt mer positiv. Det visar dock tydligt att de respondenter som är för att implementera AI har jobbat mer med digitalisering eller högre upp i verksamheter än de som är emot.

6.2 Barriärer och säkerhet

Trots positiviteten gällande att implementera AI hos majoriteten av respondenterna finns det både utmaningar och krav som behöver uppfyllas för att de ska känna sig trygga i att använda verktyget. En av de största utmaningarna som framför allt den äldre generationen känner, är deras okunskap och oförmåga att använda AI. Flera av respondenterna menar att det hinder som gör att de inte använder ny teknik har att göra med att man inte är utbildad inom området: *“Att lära mig hur man kommer in i användningen, hur man ställer frågor och hur man kan utnyttja AI, min egen ovana är största barriären”*. Beroende på vilken roll man har inom branschen finns det också olika hinder. Skillnaden mellan konsulttjänster, som ofta är mer öppna för AI-lösningar, och traditionella operativa roller där teknisk skepsis kan utgöra ett hinder var något som Filip nämnde. Något som respondent A menar stämmer, då han själv inte gärna förändrar sitt arbetssätt och i så fall kräver tydliga riktlinjer samt förklaringar. Den mänskliga barriären är alltså en utmaning som den äldre generationen dras med och där de själva säger att de skulle vilja lära sig mer om det, utbilda sig inom det för att bli bekväma med att implementera det.

Vidare tas säkerheten upp som en av de mest kritiska kraven som ställs, framför allt inom privata sektorn där information måste hållas undangömt. Idag finns ingen garanti för hur AI lagrar information och de respondenter som är verksamma inom drönerverksamhet var framför allt tydliga med att det krävs teknisk kontroll samt organisatorisk utbildning som säkerställer att information inte sprids utanför gränserna. Då en del av projekten som genomförs av Pontarius är säkerhetsklassade måste informationsspridning garanteras inte ske. Medan detta är en risk för Pontarius menar andra respondenter att säkerhetsfrågan inte alls är en barriär då det arbete som genomförs av dem är information som redan finns tillgänglig. *“I byggbranschen för oss förvaltare, är det sekundärt, det vi pratar om vet alla redan idag...”* menar en av respondenterna. Förvaltningstjänster och andra konsulttjänster som inte kräver högsta säkerhet kan därmed utnyttja och verkställa AI som verktyg utan att riskera att säkerhetsklassad information läcks ut. Däremot kan det bli en säkerhetsrisk om det skapar oro på grund av bristande kunskap och kompetens förtydligar flera av respondenterna. En av respondenterna uttrycker sin tveksamhet kring vart informationen hos AI lagras och vad som skulle hända om det hamnar i fel händer.

Ytterligare hinder som respondenterna har tagit upp inkluderar resursbegränsningar och organisatoriska trösklar men även fysiska uppgifter. En hel del arbeten kräver att mänsklig kraft finns på plats, som bland annat installationer och renoveringsarbeten. Där menar en av respondenterna att det är en stor tröskel gällande den nya tekniken då den mestadels genomförs *“digitala arbeten”* och ett arbete som kräver armar och ben blir omöjligt. I grunden är de flesta respondenter alltså trots barriärerna för användningen men de anställda längst ner i hierarkin som utför de fysiska arbetena uttrycker en negativ inställning till förändringen, och därmed ser sig själva som en barriär till det.

6.3 Potentiella användningsområden

Utifrån vad personerna sagt gällande acceptans och risker har de även poängterat områden inom deras yrke där AI skulle kunna underlätta och effektivisera arbetet. Några av respondenterna uttryckte behovet av att underlätta sökprocesser i arbetet, men också skadeidentifiering vilket är centralt för de modeller som tas upp i rapporten. Medan andra framförde att AI delvis skulle kunna användas som ett värdefullt komplement till dagens

arbetsbelastning, men att man måste identifiera tydliga mål och konkreta användningsområden. Dock bör det endast ses som ett komplement och inte som ett substitut till de befintliga uppgifterna, menar en av respondenterna. *"Att man förlitar sig för mycket på AI och inte själv undersöker ordentligt efter att AI:n har kollat på det. Idag kan det användas som ett komplement men man behöver själv titta igenom arbetet"*, trycker en av respondenterna på. Enklare arbeten eller effektivisering av bygglovsprocesser, informationssökning är också arbeten som AI skulle kunna hjälpa till med i framtiden menar flera av respondenterna. Alla är alltså överens om att AI skulle kunna bli ett bra verktyg i framtiden för att effektivisera arbetsprocesser, medan några är mer öppna för att använda det i större grad än andra, beroende på hur höga säkerhetskrav som finns.

7. Diskussion

Detta kapitel syftar till att analysera och sätta resultaten i ett sammanhang. Diskussionen fokuserar på vad intervjuernas fynd faktiskt innebär för möjligheter att implementera AI i praktiken. Genom att tolka insikterna tematiskt och relatera dem till teknikens egenskaper, användarnas förutsättningar och organisatoriska strukturer, blir det möjligt att förstå vilka faktorer som främjar eller hindrar ett framgångsrikt införande. På så sätt bidrar diskussionen till att fördjupa förståelsen för hur tekniska lösningar möter verkliga behov i en komplex verksamhetsmiljö.

7.1 Tekniska möjligheter och modellernas komplementaritet

De tekniska möjligheterna med AI i Pontarius arbetsflöde framstår som lovande, men de olika modellerna erbjuder varierande funktionalitet. Det har därför varit centralt att analysera hur modellerna kompletterar varandra i praktiken, både vad gäller kapacitet för realtidsanalys och fördjupad precision.

Modellen YOLOv8 möjliggör snabb identifiering av skador direkt i fält och utmärker sig därmed genom sin realtidsförmåga. Detta uppskattas av exempelvis respondent Filip Birkeland, som betonar behovet av "snabba insikter ute i fält". Samadzadegan et al. (2023) bekräftar modellens kapacitet för realtidsdetektion, särskilt vid övergripande screening av vägsador i stora datamängder. Detta innebär att YOLOv8 har en roll som "första steg" i ett sekventiellt flöde där övriga modeller tar vid i nästa analysfas.

DeepCrack och Cha et al:s metod, däremot, har visat sig mer lämpade för detaljerad efteranalys där precision och kontextuell förståelse är i fokus. Dessa modeller är inte realtidskapabla, men deras styrka ligger i att de möjliggör djupare insikter om skadornas komplexitet och potentiella konsekvenser (Zou et al., 2019; Cha et al., 2024). EfficientCrackNet placerar sig mellan dessa två extremer: den kombinerar segmenteringsprecision med tillräckligt låg resursförbrukning för att vara användbar i fält (Ma et al., 2023). Det kan därmed fungera som en brygga mellan snabbhet och detaljrikedom.

Detta kompletterande förhållande möjliggör en pipeline-struktur där varje modell får en tydlig funktion. YOLOv8 kan användas för att screena stora ytor och markera potentiella skador. Därefter kan DeepCrack eller EfficientCrackNet analysera markerade områden på pixelnivå för att kvantifiera sprickors omfattning och egenskaper. Cha et al:s modell bidrar sedan med riskklassificering och prioritering, medan Han et al:s system stödjer uppföljning och projektkontroll. Denna logik stöds även av Han et al. (2024), som understryker vikten av att integrera olika typer av AI-system i arbetsflödet för att uppnå helhetsinsikt.

Detta kan tolkas som att modellernas komplementaritet är en nyckel till användbarhet i praktiken: ingen modell är "tillräcklig" ensam, men tillsammans kan de täcka ett komplett behov, från upptäckt till dokumentation. Det pekar även på att implementeringen måste ta hänsyn till tillgängliga resurser och prioriteringar. I projekt med brådskande behov passar snabba system bättre, medan detaljerade inspektioner kräver kraftfullare efteranalys. Det indikerar också att val av modell inte enbart är ett tekniskt beslut utan bör grunda sig i användningskontexten.

7.2 Säkerhet och informationshantering som tröskel

Ett genomgående tema i intervjuerna är oron för informationssäkerhet, särskilt vid användning av externa AI-verktyg. Denna oro gäller både var data lagras och hur den används. Johanna Sanden uttrycker exempelvis tveksamhet inför att använda AI-verktyg som

ChatGPT i projekt med hög sekretess, där “det är bara vi och beställaren som får se arbetet”. Detta visar att tekniken i sig inte är problemet, utan bristen på kontroll över dataflödet.

Tomas, fastighetschef på DB Schenker, beskriver problemet mer övergripande:

“Säkerhetsbarriären, de flesta har uppmärksammat den. Vad händer med datan vi skapar? Det är en mer och mer påtaglig fråga utifrån säkerhet, både på internet och fysiskt i fastigheter. Ju mer data som finns, desto lättare för ‘onda men’.” Uttalandet illustrerar att hotbilden inte enbart handlar om IT-säkerhet utan också om fysisk säkerhet på exempelvis flygplatser eller anläggningar. I litteraturen belyser Cha et al. (2024) liknande risker, särskilt i projekt där UAV-bilder innehåller känsliga detaljer. Detta förstärker behovet av kontroll över datalagring, åtkomst och spårbarhet.

Utifrån ett organisatoriskt perspektiv kan detta tolkas som att säkerhet inte bara är en teknisk fråga, utan också en kulturell tröskel. Den digitala kompetens som krävs för att förstå riskerna och för att kunna hantera dem är ofta ojämnt fördelad inom organisationen. Det syns tydligt i intervjuerna, där vissa medarbetare är bekväma med molnbaserade lösningar medan andra är skeptiska till att ens “mata in något” i ett AI-system. Detta överensstämmer med Venkatesh et al. (2003), som i sin vidareutveckling av TAM-modellen lyfter vikten av “perceived risk” och organisatoriskt stöd som faktorer för acceptans.

Pontarius hanterar idag uppdrag åt kunder med varierande krav på datasäkerhet, vilket innebär att AI-lösningar måste kunna skalas och anpassas. Det kan till exempel innebära att AI endast får användas i offline-miljöer eller med intern datalagring. Flera respondenter lyfter också behovet av “säkerhetsintyg” och EU-baserade lösningar för att våga gå vidare med tekniken. Det kan tolkas som att ökad tydlighet från leverantörer i kombination med interna riktlinjer är avgörande för att AI ska kunna användas bredare.

Sammantaget pekar detta på att säkerhet är en tröskel både i faktisk implementation och i användarnas förtroende för tekniken. Det räcker inte att tekniken fungerar – den måste också upplevas som trygg, förutsägbar och kontrollerbar. I praktiken innebär det att Pontarius inte bara behöver AI-kompatibla system, utan även interna policyer, utbildning och kanske en särskild roll för informations säkerhet vid AI-implementering.

7.3 Kompetensgap och användaracceptans

En tydlig insikt från intervjuerna är att upplevelsen av AI och viljan att använda tekniken, skiljer sig beroende på yrkesroll, tidigare erfarenhet och ålder. Det finns ett tydligt kompetensgap mellan tekniskt insatta konsulter och mer operativa roller inom Pontarius. Detta framgår bland annat i intervjun med Respondent A, en fastighetsskötare, som uttrycker: “Jag använder inte AI i någon av mina arbetsuppgifter... mycket av det jag gör är fysiska arbeten och där känner jag inte att AI skulle kunna vara till någon större nytta för mig.” Det visar inte bara på en praktisk begränsning, utan också på en upplevd distans till tekniken som sådan.

Samtidigt säger samma respondent att han “skulle kunna tänka mig använda det” om det till exempel kunde hjälpa till att hantera felanmälningar, men tillägger: “Jag behöver lära mig mer om AI först.” Detta pekar på att acceptansen inte saknas, men att den är villkorad av tillgång till kunskap och förståelse. Denna observation är förenlig med Technology Acceptance Model (TAM), där begreppet “perceived ease of use” är avgörande för teknikens genomslag (Davis, 1989). Om AI-system upplevs som komplexa eller svåra att tolka minskar sannolikheten att de kommer till användning, oavsett deras tekniska potential.

Filip Birkeland uttrycker det på ett liknande sätt från ett projektledarperspektiv: “Gubbarna på plats behöver väldigt tydliga förklaringar.” Här blir frågan inte bara om tekniken fungerar, utan hur väl den går att förmedla. Det är inte ovanligt att AI-lösningar presenteras med

tekniska termer och avancerade gränssnitt, vilket skapar en barriär för användning hos icke-tekniska yrkesgrupper. Detta förstärker behovet av pedagogiska gränssnitt och inbyggda guider, eller som Johanna beskriver det: “en hjälpreda” som hjälper till i olika program.

Detta kan tolkas som att acceptansen för AI är högst situationsberoende, alltså att den ökar när användningen är konkret, begriplig och direkt relevant för arbetsuppgiften.

Användarvänlighet är därmed inte en estetisk fråga, utan en strategisk faktor för implementering. Litteraturen stödjer denna slutsats. Venkatesh et al. (2003) menar att “effort expectancy”, det vill säga hur mycket ansträngning användaren tror att tekniken kräver, är avgörande för hur snabbt och brett den accepteras i en organisation.

En ytterligare aspekt är att AI ofta tolkas som något abstrakt och avlägset. Det framgår tydligt i flera intervjuer att respondenterna främst associerar AI med stora språkmodeller som ChatGPT, snarare än med specialiserade verktyg för exempelvis skadeanalys. Det skapar en diskrepans mellan teknikens faktiska möjligheter och den bild användarna har. I praktiken innebär detta att Pontarius, och andra organisationer i liknande position, behöver arbeta aktivt med både kunskapsspridning och intern kommunikation. Att lyfta fram exempel på hur AI redan används i vardagen, eller att låta anställda testa enklare tillämpningar, kan sänka tröskeln och öka engagemanget.

Slutsatsen är att teknisk funktionalitet inte är tillräcklig för att skapa genomslag utan att användarens förtroende och förståelse är avgörande. Genom att arbeta med kompetensutveckling, pedagogiska verktyg och förenklade gränssnitt kan Pontarius överbrygga det kompetensgap som i dag utgör ett hinder för bredare implementering.

7.4 Förändringsvilja och organisatorisk mognad

En återkommande insikt i både intervjuer och litteratur är att AI-implementering inte bara är en teknisk fråga, utan en process som påverkas av organisationskultur, interna rutiner och förändringsvilja. Det framgår tydligt att flera medarbetare, särskilt i operativa roller, inte motsätter sig AI som idé, men uttrycker en ovilja eller osäkerhet inför att förändra invanda arbetssätt. Respondent A beskriver detta med orden: “Jag är bekväm med att göra det jag alltid har gjort”, vilket signalerar att tröskeln för att påbörja ett förändringsarbete ofta handlar mer om vanor och trygghet än om teknikens faktiska kapacitet.

Denna inställning kan delvis förstås genom innovationsforskning, där införandet av ny teknik ofta beskrivs som en social process. Denscombe (2017) betonar att teknologisk förändring kräver stödstrukturer, kommunikation och delaktighet, inte bara nya verktyg. En ny arbetsmetod, hur effektiv den än är, kommer inte att användas om den upplevs som påtvingad eller svår att förstå. I intervjuerna märks detta genom att flera respondenter efterlyser tydligare förklaringar, interna utbildningar och exempel på vad AI faktiskt kan göra i deras vardag. Johanna uttrycker att tryggheten kring informationshantering och tydlig vägledning är centrala krav för att kunna välkomna AI i verksamheten. Behovet av säkerhetsintyg och intern kompetensutveckling signalerar inte motstånd, utan snarare en vilja till förändring, givet att implementeringen sker under kontrollerade och förståeliga former. Det tyder på att acceptansen för AI till stor del är beroende av omständigheterna kring införandet snarare än tekniken i sig.

I detta sammanhang är det även relevant att diskutera hur olika tekniker kräver olika mycket av användaren. En modell som YOLOv8 kan integreras i ett arbetsflöde utan att användaren direkt behöver interagera med den, vilket sänker kraven på förändringsvilja. Däremot kräver mer avancerade system, som Cha et al:s modell för strukturell hälsomonitorering, både insikt och aktiv tolkning av resultat. Det betyder att teknisk mognad och organisatorisk mognad måste utvecklas parallellt för att implementeringen ska lyckas fullt ut.

En annan aspekt som påverkar förändringsviljan är graden av intern samordning. Om AI-projekt drivs isolerat från andra delar av verksamheten finns en risk att förändringen inte förankras tillräckligt. Det kan skapa motstånd även bland de som i grunden är positiva till tekniken. Därför kan det vara värdefullt för Pontarius att skapa tvärfunktionella team, där både tekniker, administratörer och beslutsfattare deltar i utformningen av AI-baserade arbetsflöden. En sådan strategi ökar känslan av delaktighet och förståelse för hur AI kan stödja hela verksamheten, inte bara enskilda funktioner.

Avslutningsvis pekar intervjuerna på att det finns en grundläggande vilja att förbättra arbetssätt och effektivitet. Det som krävs är att denna vilja kanaliseras genom tydliga mål, pedagogisk vägledning och organisatorisk förankring. Med rätt strategi kan Pontarius inte bara implementera AI-teknik, utan också stärka sin interna kapacitet att hantera framtida tekniska förändringar.

7.5 Metodreflektion

Valet att kombinera litteraturstudier med semistrukturerade intervjuer har visat sig vara en styrka. Den tekniska analysen har skapat ett teoretiskt ramverk, medan intervjuerna har gett konkret insyn i praktiska behov, begränsningar och attityder. Det har gjort det möjligt att identifiera gapet mellan teknisk potential och organisatorisk verklighet, som är ett centralt tema i hela studien.

Valet av respondenter har baserats på att få flera olika perspektiv och därmed resultera i en bredare, mer varierad analys av respondenternas svar. Genom att intervjua företagsägare, chefer men också anställda längre ner i hierarkin, samt att de intervjuade är från olika företag inom olika delar av samhällbyggnadsbranschen, gör att svaren blir mer varierade. Detta är också en styrka som bidrar till att studien blir mer anpassningsbar och konkret för fler företag inom branschen.

Samtidigt finns begränsningar. Urvalet av respondenter är begränsat, vilket innebär att generaliserbarheten till branschen som helhet är begränsad. Fler intervjuer med aktörer i liknande roller, men i andra företag eller sektorer skulle kunna förstärka validiteten. Majoriteten av respondenterna är även inom Pontarius eller kopplade till Pontarius, i och med detta kan svaren bli vinklade.

Kvalitetssäkringen i denna studie har stärkts genom en strukturerad intervjuguide och noggrann dokumentation av intervjusvar, vilket bidragit till att säkerställa att intervjuerna följde en enhetlig linje och täckte samtliga centrala frågeställningar. Tilläggas ska dock, att intervjuerna som är av semistruktur, ibland har "svävat iväg" och därmed inte alltid har varit exakt likadana som kan förväntas utav vald struktur. Valet av semistrukturerade intervjuer har på så sätt gjort att diskussionerna blivit mer flytande och öppna, vilket har kunnat ge värdefulla insikter som inte varit med i beräkningarna från början. Transkriberingarna har även granskats för att minimera risken för feltolkningar och därmed ökat trovärdigheten i det empiriska materialet.

Samtidigt är det viktigt att betona att resultaten är kontextberoende, de bygger på Pontarius specifika arbetssätt, kultur och tekniska förutsättningar, vilket innebär att direkta generaliseringar bör göras med försiktighet.

Den kombinerade metoden anses vara lämplig med reservation för att det begränsade antalet respondenter bidrar till viss generalisering och tolkning av resultatet. En längre och bredare datainsamling hade kunnat bidra till ett mer precist resultat vilket bör finnas i åtanke i framtida studier.

8. Slutsats

Syftet med detta kandidatarbete har varit att undersöka hur artificiell intelligens (AI) i kombination med drönarteknik kan integreras i Pontarius verksamhet, samt att belysa branschens syn på teknologins potential och begränsningar. Genom en kombination av litteraturstudier och intervjuer med anställda inom Pontarius har tre forskningsfrågor kunnat analyseras. Denna slutsats sammanfattar arbetets huvudsakliga insikter och besvarar de tre forskningsfrågorna.

8.1 Hur ser förutsättningarna ut hos Pontarius för att implementera AI i kombination med drönarteknik?

Pontarius befinner sig i ett gynnsamt läge för att börja implementera AI-lösningar i sina UAV-baserade inspektionsflöden. Företaget har redan etablerad kompetens inom drönarteknik, vilket innebär att den tekniska infrastrukturen till stor del är på plats. Det som framför allt krävs för att realisera implementeringen är kompletterande resurser i form av serverkapacitet, anpassade AI-modeller samt tydliga riktlinjer för hur data ska hanteras och analyseras. Implementeringskapitlet visar att flera av de modeller som undersökts såsom YOLOv8, DeepCrack och Cha et al:s SHM-system, kan integreras i en sekventiell pipeline för att skapa ett effektivt och skalbart arbetsflöde. Det finns även en god förståelse internt för att AI bör införas gradvis och med människan kvar i kontrollen, vilket i sig är en positiv förutsättning.

Samtidigt finns vissa flaskhalsar som måste adresseras. Dessa handlar om att anpassa AI-modellerna till svenska miljöförhållanden, att utbilda personal i hur verktygen ska användas, samt att standardisera drönarinspektionerna för att säkerställa jämförbarhet mellan olika dataset. Ett särskilt hinder som återkommit i både litteratur och intervjuer är frågan om datakvalitet, modeller som DeepCrack är mycket känsliga för brus, skuggor och lågupplösta bilder, vilket ställer krav på högkvalitativ bildinsamling. Den största barriären för att kunna implementera AI-modeller i Pontarius arbetsflöde är säkerhetskravet. Då de arbetar med flera externa kunder gäller det att information kan lagras lokalt och inte läcker ut. Här behöver ytterligare framtida studier göras för att kunna säkerställa att kraven uppfylls. Trots detta visar analysen att Pontarius har de organisatoriska och tekniska grundförutsättningarna som krävs för att påbörja en AI-implementation, särskilt om tekniken först introduceras i begränsad skala och i projekt med låga säkerhetskrav.

8.2 Vilka är de potentiella fördelarna och riskerna med AI inom branschen?

De huvudsakliga fördelarna med AI i kombination med UAV-inspektioner är förbättrad effektivitet, högre analyskvalitet och en mer systematisk hantering av stora datamängder. AI-modeller som YOLOv8 kan snabbt upptäcka skador på väg- och beläggningsytor i realtid, medan modeller som DeepCrack eller EfficientCrackNet möjliggör mer noggrann och detaljerad spricksegmentering. Kombinationen av realtidsanalys och fördjupad efterbearbetning ger en bred användning för både akuta och planerade underhållsinsatser. Modeller som Cha et al. och Han et al. breddar användningsområdet ytterligare, genom att även erbjuda möjligheter till strukturell hälsomonitorering och byggprocessövervakning.

Riskerna ligger dock i flera skikt. På det tekniska planet finns utmaningar kopplade till felaktig klassificering, behovet av ständiga modelluppdateringar och höga krav på datakvalitet. Samtidigt lyfter flera respondenter fram säkerhetsaspekter som ett centralt hinder. Johanna uttrycker en oro för att data som laddas upp till generativa AI-system kan spridas okontrollerat, något som Tomas också återkommer till med sin reflektion om att “ju mer data som finns, desto lättare för onda män”. Denna oro är särskilt aktuell i säkerhetsklassade projekt där informationsläckage skulle kunna få allvarliga konsekvenser. Det råder därmed en balansgång mellan att vilja använda AI för att effektivisera processer och att samtidigt skydda känslig information.

Ytterligare en riskfaktor är kunskapsbrist. Respondent A berättar exempelvis att han inte ser nyttan med AI i sitt arbete, vilket både kan spegla en faktisk rollspecifik irrelevans och ett informationsgap. Om AI ska införas brett i branschen krävs det utbildningsinsatser och förändringsledning som visar konkret hur tekniken kan användas, inte bara för att övertyga skeptiker, utan för att säkerställa korrekt och säker användning.

8.3 Vad är inställningen till användningen av AI idag inom branschen?

Det generella intrycket från intervjuerna är att branschen står i ett nyfiket men försiktigt förhållningssätt till AI. Flera respondenter uttrycker entusiasm över de möjligheter som tekniken medför, men samtidigt råder en osäkerhet kring dess användbarhet i det egna arbetet. Johanna beskriver till exempel att AI redan används som “hjälpreda” i enklare administrativa uppgifter, men att tekniken ännu inte är en integrerad del i tyngre analyser eller beslutsstöd. Det tyder på att AI är på väg in i verksamheterna, men att implementeringen ännu är i sin linda.

Samtidigt skiljer sig inställningen markant beroende på roll. Medan projektledare och tekniska specialister ofta ser AI som ett framtida verktyg för beslutsstöd och effektivisering, uttrycker operativa roller som exempelvis fastighetsskötare att de varken har behov av tekniken eller tillräcklig kunskap för att använda den. Detta visar att implementationen inte enbart är en teknisk fråga, utan även en kulturell och pedagogisk utmaning. AI måste förankras i den praktiska verkligheten hos varje yrkesgrupp – annars riskerar tekniken att bli något som bara används av en liten del av organisationen.

Intervjuerna visar också att det finns en efterfrågan på “certifierade” eller standardiserade AI-verktyg. Flera respondenter uttrycker att de gärna skulle använda AI mer, men bara om det fanns tydliga garantier kring precision, datasäkerhet och juridiskt ansvar. Detta antyder att framtida AI-implementeringar i branschen kommer att behöva backas upp av både utbildning och policyarbete, inte minst för att skapa förtroende för tekniken hos användarna.

8.4 Framtida fortsatt forskning

Studien har också identifierat viktiga områden för framtida forskning. Ett nästa steg är att undersöka hur AI-implementering ser ut i andra delar av branschen, exempelvis hos beställare, entreprenörer eller myndigheter, för att skapa en mer heltäckande bild av sektorns mognad. Även praktiska pilotprojekt där de föreslagna modellerna testas i inspektionsmiljöer hade kunnat ge ytterligare insikter om faktiska hinder, användarupplevelse och datakvalitet. Det vore också värdefullt att genomföra fler kvantitativa mätningar av tidsbesparingar,

felmarginaler och kostnadseffektivitet vid användning av AI i skadekartering, för att i större grad kunna påvisa teknikens ekonomiska nytta.

Vidare bör framtida forskning utifrån den information som givits i denna studie undersöka datasäkerheten hos AI. Där bör nästa fokusområde ligga på att man kan bevisa att, eller hitta lösningar på, lagringen av datan som lagras i dessa modeller förblir intern och inte sprids utanför de databanker som användarna själva utnyttjar. Genom att forska vidare och undersöka dessa frågor, kommer förhoppningsvis lösningar komma fram där modellteorierna kan bli verklighet och applicerbara.

8.5 Avslutande reflektion

Sammantaget visar arbetet att AI och drönarteknik mycket väl kan integreras i Pontarius verksamhet, men att detta kräver ett stegvis införande där tekniska möjligheter balanseras med organisatoriska realiteter. De modeller som har analyserats i studien erbjuder olika styrkor som tillsammans skapar en kraftfull pipeline för skadeidentifiering och processuppföljning. För att detta ska bli verklighet måste dock frågor om säkerhet, kunskap, ansvar och anpassning stå i fokus. En tydlig insikt är att AI inte är en enskild lösning som införs över en natt, utan snarare en omställning som kräver nya rutiner, ny förståelse och nya former av samverkan mellan teknik och människa. Om detta inte beaktas riskerar tekniken att skapa mer förvirring än värde, särskilt för yrkesroller som inte direkt arbetar med digitala verktyg. Därför måste utbildning, förankring och policyutveckling gå hand i hand med teknikutvecklingen.

Denna studie kan därmed fungera som ett vägledande underlag för både Pontarius och andra aktörer inom infrastruktursektorn som vill förstå vad som krävs för att lyckas med AI-implementering i praktiken. Genom att kombinera teoretisk förståelse med intervjubaserade insikter har rapporten gett en nyanserad bild av både möjligheter och utmaningar, och har lagt grunden för fortsatt utveckling, både tekniskt, organisatoriskt och forskningsmässigt.

9. Referenser

- Gao, R., Wang, L., & Teti, R. (2020). Big Data for smart manufacturing: Opportunities and challenges. *CIRP Annals*, 69(2), 679–702. <https://doi.org/10.1016/j.cirp.2020.05.002>
- Dalenogare, L. S., Benitez, G. B., Ayala, N. F., & Frank, A. G. (2018). The expected contribution of Industry 4.0 technologies for industrial performance. *International Journal of Production Economics*, 204, 383–394. <https://doi.org/10.1016/j.ijpe.2018.08.019>
- Denscombe, M. (2017). *The Good Research Guide: For Small-Scale Social Research Projects* (6th ed.). Open University Press.
- Davis, F. D., (1989). *Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology*. <https://doi.org/10.2307/249008>
- EU-kommissionen. (2024). Rapport om AI och databehandling: *Effektivitet och tillämpningar inom cybersäkerhet och infrastrukturinspektion*. DiVA Portal. <https://www.diva-portal.org/smash/get/diva2:1824886/FULLTEXT01.pdf>
- Hays. (2024). *Training deficit slowing AI adoption, finds Hays research*. <https://www.hays.co.uk/media-centre/press-releases/content/training-deficit-slowng-ai-adoption>
- gNext Labs. (2025). *The Complete Guide to Infrastructure Inspection: Emerging Technologies, Trends, and Best Practices*. <https://www.gnextlabs.com/blog/the-complete-guide-to-infrastructure-inspection-emerging-technologies-trends-and-best-practices/>
- Guba, E. G., & Lincoln, Y. S. (1985). *Naturalistic Inquiry*. Sage Publications.
- Ma, N., Song, Z., Hu, Q., Liu, C.-W., Han, Y., Zhang, Y., Fan, R., & Xie, L. (2023). EfficientCrackNet: A Lightweight Network for Crack Detection on UAV Platforms. arXiv. <https://doi.org/10.48550/arXiv.2503.18082>
- Msverige. (2024). Rapport Tema Infrastruktur. Riksförbundet M Sverige. <https://msverige.se/media/b5emspb5/m-sverige-rapport-tema-infrastruktur.pdf>
- Samadzadegan, F., Dadrass Javan, F., Ashtari Mahini, F., Gholamshahi, M., & Nex, F. (2024). *Automatic Road Pavement Distress Recognition Using Deep Learning Networks from Unmanned Aerial Imagery* [Article]. *Drones*, 8(6), Article 244. <https://doi.org/10.3390/drones8060244>
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425–478. <https://doi.org/10.2307/30036540>
- Zou, Q., Zhang, Z., Li, Q., Qi, X., Wang, Q., & Wang, S. (2019). DeepCrack: Learning hierarchical convolutional features for crack detection [Article]. *IEEE Transactions on Image Processing*, 28(3), 1498-1512, Article 8517148. <https://doi.org/10.1109/TIP.2018.2878966>

Han, J. Y., Hsu, C. R., & Huang, C. J. (2024). Automated progress monitoring of land development projects using unmanned aerial vehicles and machine learning [Article]. *Automation in Construction*, 168, Article 105827.
<https://doi.org/10.1016/j.autcon.2024.105827>

Cha, Y. J., Ali, R., Lewis, J., & Büyüköztürk, O. (2024). Deep learning-based structural health monitoring [Review]. *Automation in Construction*, 161, Article 105328.
<https://doi.org/10.1016/j.autcon.2024.105328>

10. Bilagor

10.1. Intervjufrågor:

- **Vilka är de största barriärerna eller motstånden ni upplever i branschen när det gäller att implementera AI?**

Handlar det främst om tekniska utmaningar, lagstiftning och regelverk, eller är det "funkar det så ändra inte på det" mentalitet?

- **Finns det några specifika flaskhalsar i era nuvarande arbetsprocesser där AI skulle kunna bidra till effektivisering eller kostnadsbesparingar?**

Exempelvis i skadeidentifiering, administration, dataprocessering eller rapportgenerering?

- **Hur ser ni generellt på användningen av AI i er verksamhet idag?**

Är det något ni aktivt undersöker eller finns det osäkerhet kring nyttan och riskerna?

- **Vilka risker eller utmaningar ser ni med att integrera AI, och hur påverkar dessa er vilja att investera i tekniken?**

Exempelvis felmarginaler, ansvarsfrågor, eller beroende av ny kompetens?

- **Vad skulle krävas för att ni ska känna er trygga med att AI blir en integrerad del av era processer?**

Är det främst en fråga om teknisk precision, juridiska aspekter eller förändringsledning internt?