



Identifiering av gnistor med hjälp av kameror och AI-modeller

Test av kameror och AI-modeller för
användning i praktiken

Roni Nasr
Marcus Persson
Erik Bergelin
Joel Jacobsson

BRANDFORSK
2026:4



**BRAND
FORSK**

Referensgrupp

Mattias Delin, Brandforsk

Emilia Norin, Myndigheten för civilt försvar, MCF

Pia Ljunggren, Brandskyddsföreningen

Nicklas Larsson, Brandskyddsföreningen

Fredrik Askog, Vattenfall

Johan Sydqvist, Vattenfall

Andreas Stagnebo, Vattenfall

Anders Loid, Johnsons Controls

Johan Sjöström, Rise

Denna rapport utgör ett slutligt arbetsmanuskript för det rubricerade projektet. Den officiella projektrapporten, till vilken referens bör ske återfinns på Brand och Byggs hemsida:

Identifiering av gnistor med hjälp av kameror och AI-modeller
Test av kameror och AI-modeller för användning i praktiken

www.brandochbygg.se

BRANDFORSK
2026:4



FÖRORD

Detta är slutrapport i projektet ” Identifiering av gnistor med hjälp av kameror och AI-modeller” - Test av kameror och AI-modeller för användning i praktiken. Projektet är finansierat av Brandforsk. Projektet har även finansierats av egna insatser från Brand och Bygg, Sigma Technology, Södra Älvsborgs räddningstjänstförbund och även referensgruppen.

Projektet utgör ett test av att träna och applicera AI-program med kameror som är vanligt förekommande inom kamerabevakning. Rapporten förväntas utgöra underlag för framtida utveckling inom nyttjandet av kameror som en del av brandskyddet inom byggnader med befintlig kamerabevakning.

Projektet har även tagit del av stöd från referensgruppen. Referensgruppen har utgjort stöd i form av referensgruppsmöten, kommentarer/input på rapporten. Referensgruppen bestod av följande:

- Mattias Delin, Brandforsk
- Emilia Norin, MCF
- Pia Ljunggren, Brandskyddsföreningen
- Nicklas Larsson, Brandskyddsföreningen
- Fredrik Askog, Vattenfall
- Johan Sydqvist, Vattenfall
- Andreas Stagnebo, Vattenfall
- Anders Loid Johnsons Controls
- Johan Sjöström, Rise

Ett stort tack riktas till referensgruppen för allt stöd och input i projektet.


Sammanfattning

I Sverige utgör arbeten som genererar gnistor inom industri, byggarbetsplatser och byggnader generellt en potentiell antändningskälla, vilket kan få förödande konsekvenser. Antalet incidenter kopplade till heta arbeten och gnistor var cirka 340 stycken år 2015, vilket utgjorde 3-4 % av det totala antalet bränder det året.

Projektet undersöker om vanliga kameror, i kombination med avancerade AI-modeller, kan användas för att upptäcka gnistor som utgör möjliga antändningskällor vid arbeten där gnistbildning förekommer. Genom datainsamling och modellträning utvärderas teknikens potential och begränsningar, samt hur resultaten förhåller sig till befintlig forskning. Målet är att bedöma om kamerabaserad gnistdetektering kan bli ett framtida verktyg i riskreducering.

Resultatet av testserien blev underlag till ett dataset med 2 149 bilder och 50 571 instanser på gnistor. Antalet bilder och instanser bedömds vara tillräckligt för att upprätta en AI-modell för det aktuella ändamålet.

Resultaten visar att detektering kan ske på det insamlade underlaget och med de tränade AI-modellerna. Träningen resulterade i AI-modeller där skillnaden var indatan, två olika metoder att uppnå 640x640 pixlar på indatan (bilderna) och två olika startvärden för parametrarna inom AI-modellen. Indatan uppnådde 640x640 pixlar med nedskalning eller med bildsegmentering av ett fokusområde centrerat kring intresseområden (svetsning/slipning). Dessa olika startvärden som modellerna förtränades på var från två olika dataset, en redan inbyggd i YOLOv11 och ett dataset hämtat från en separat källa kallad ”Common objects in Context” (Coco). Namnet på modellerna är baserat på skillnaderna i indata. Figur 1 nedan görs en jämförelse mellan olika relevanta mätvärden för modellerna. Den modell som detekterade mest gnistor i alla jämförelser och även hade flest korrekta gissningar var modellen som hade förträning med startvärden från datasetet Coco.



Figur 1. Jämförelse av resultaten för de olika modellerna. Resultatet som jämförs är mAP50 och mAP50-95. mAP50-95 är en typ av mAP med ett strängare mått, där modellen måste vara mer exakt i dess träffsäkerhet.

Det mått som har blivit standardmättet att jämföra AI-baserat objekt-detekteringsprogram med varandra är mean Average Precision* (mAP), medelgenomsnittliga precisionen. mAP är ett mått på hur bra ett bildigenkänningsprogram är på att hitta rätt saker på en bild. Det visar både hur många rätt modellen hittar och hur noggrant den gör det. Resultatet påvisar att bildsegmenterade bilder fungerar bättre för att identifiera små gnistor.

Innehåll

1	Inledning	2
1.1	Olyckor kopplade till heta arbeten i Sverige	2
1.2	Kameraanvändning i Sverige idag	2
1.3	Detektering av gnistor som funktion i brandskyddet	3
1.4	Gnistor	3
1.5	Tidigare forskning om bilddetektering med AI-modeller	3
1.6	Syfte, mål och frågeställning	4
1.7	Avgränsningar och begränsningar	5
2	Metod	7
2.1	Genomförande	7
2.2	Utrustning	7
2.3	Testområde	10
2.4	Testuppställning	10
2.5	Bildanalys / bildigenkänning	14
3	Resultat	16
3.1	Insamlad data	16
3.2	AI-modellens träningsresultat	16
4	Diskussion	18
4.1	AI-modellerna	18
4.2	Jämförelse med befintlig forskning	19
4.3	Felklassificeringar och konsekvenser för säkerhet	20
4.4	Etisk användning av AI-modeller och kameror	21
5	Slutsats	21
6	Framtida Arbeten	22
6.1	Multimodal detektering och redundans	22
6.2	Integration av flera AI-baserade system	22
6.3	Standardiserat datautbyte och systemintegration	22

Nomenklatur

AI-modell	I denna rapport används begreppet AI-modell som en samlingsbenämning för de avancerade algoritmer som används för att konstruera och träna neurala nätverk för objektidentifiering av gnistor.
AND-Funktion	En logisk funktion som endast ger resultatet ”sant” om båda ingångarna är sanna.
Avgränsningsbox (Bounding box)	En rektangel som markerar objektets position i en bild vid objekt-detektering.
COCO	Ett stort och standardiserat dataset av bilder för bildigenkänning och objekt-detektering, ofta använt för utvärdering av modeller.
Dataset	En samling strukturerade data som används för att träna, validera eller testa en maskininlärningsmodell.
Epoker	Antalet gånger en träningsprocess passerar igenom hela träningsdatasetet.
CNN (Convolutional Neural Networks)	En typ av neuralt nätverk som använder konvolutioner för att effektivt känna igen mönster i bilder.
FOV (Field of View)	Det synfält som en kamera, sensor eller modell kan ”se” inom en given vinkel eller yta.
Förtroendepoäng (Confidence Score)	Ett mått på hur säker en modell är på att dess detektering eller klassificering är korrekt.
Gränsvärde (Threshold)	Ett tröskelvärde som avgör när en detektering eller klassificering ska accepteras eller filtreras bort.
Inzoomning	Processen att förstora en del av en bild för att analysera detaljer tydligare.
Instanser	Enskilda förekomster av objekt som identifieras i en bild, även om de tillhör samma kategori.
IoU (Intersection over Union)	Ett mått på överlappet mellan två ytor, ofta en förutsagd och en sann avgränsningsbox, för att bedöma detekteringskvalitet.
Konvergens	Punkten där en modell slutar förbättras märkbart och har lärt sig mönstren i datan.
mAP50	Medelvärdet av precision över alla klasser vid ett fast IoU-tröskelvärde på 0,50.
mAP50-95	Medelvärdet av precision över flera IoU-tröskelvärden (0,50–0,95) och är ett mer heltäckande kvalitetsmått än mAP50.
Objekt-detektering	Tekniken att lokalisera och klassificera objekt i en bild eller video.
PR-Kurva (Precision-Recall Curve)	En graf som visar sambandet mellan precision och recall vid olika tröskelvärden.
Precision	Andelen korrekta positiva detekteringar av alla detekteringar som modellen gjort.
Recall	Andelen korrekt identifierade positiva objekt av alla verkliga positiva objekt i datan.
XOR-Funktion	En logisk funktion som ger resultatet ”sant” endast när exakt en av ingångarna är sann.
YOLOv11	En modern och snabb objekt-detektor i YOLO-familjen utvecklad för hög noggrannhet och realtidsprestanda.
Överanpassning (Overfitting)	När en modell lär sig träningsdata för detaljerat och presterar sämre på ny, osedd data.

1 Inledning

1.1 Olyckor kopplade till heta arbeten i Sverige

Incidenter där arbeten som genererar gnistor utgör antändningskällan har ett betydande antal bränder och explosioner i Sverige. Detta inkluderar bränder i industriella anläggningar, byggarbetsplatser samt allmänna byggnader. Typiska exempel är bränder uppkomna vid svetsning, skärbränning eller slipning (arbeten där gnistor förekommer), som antänt brännbart material.

Bränder orsakade av arbeten som alstrar värme och bildar gnistor även känt som ”heta arbeten” har minskat dramatiskt sedan introduktionen av Brandskyddsföreningens säkerhetsregler och certifiering 1990 (1). Under perioden 2000–2025 utgör denna brandkategori en relativt liten del av alla bränder. Exempelvis stod heta arbeten år 2015 för endast cirka 1–2 % och gnistor för cirka 2 % av alla byggnadsbränder i Sverige, vilket är 340 bränder av totalt 9 497 år 2015 (2). Till och med i branscher där heta arbeten är vanliga har andelen bränder sjunkit. I byggindustrin var heta arbeten år 2022 den näst vanligaste orsaken på byggarbetsplatser (efter anlagd brand) och orsakade ungefär 12 % av bränderna under 2013–2022 (3).

Även om antalet bränder i byggnader sjunkit på grund av proaktiva arbeten utgör bränder orsakade av heta arbeten fortfarande cirka 12 % av bränderna på byggarbetsplatser. Enligt skadestatistik från svensk försäkring var den genomsnittliga skadeersättningen för olyckor av ”heta arbeten” 606 000 kr under 2017. Totalt betalades skadeersättning ut för 70 olika skador, vilket totalt blir cirka 42 miljoner det året (4).

Proaktiva arbeten och satsningar på dessa bör således vara fortsatt i fokus om dessa olyckor ytterligare ska förhindras i framtiden. Rapportens avsikt är därför att ge förslag på ett sådant fortsatt steg i arbetet med proaktiva lösningar.

Det bör noteras att en stor del av olyckor som sker ej går att utreda fullt ut. Skadorna är i en stor del av fallen omfattande och då att orsaken inte alltid fullt ut kan fastställas.

1.2 Kameraanvändning i Sverige idag

Kamerabevakning blir alltmer vanligt förekommande i samhället av olika anledningar (5) (6). I takt med att kameror de senaste åren både har förbättrats tekniskt och blivit mer prisvärda. Detta har lett till att fler aktörer väljer att investera i övervakningskameror för en rad olika ändamål.

Användningsområdena kan omfatta allt från inbrottskydd och trygghetsskapande åtgärder till processövervakning inom industri och verksamhetsdrift.

Från och med den 1 april 2025 gäller dessutom nya regler för kamerabevakning (7). Tidigare krävdes det att aktörer ansökte om tillstånd hos Integritetsskyddsmyndigheten (IMY) för kamerabevakning. Samma avvägning mellan bevakningsintresset och integritetsintresset ska fortfarande genomföras, men ansvaret för denna bedömning har nu förskjutits till myndigheter, kommuner samt privata aktörer som utför offentliga uppdrag. IMY har publicerat vägledningar för att stödja verksamheter i deras bedömningar av kamerabevakning. Med de nya reglerna blir det både snabbare och enklare att påbörja kamerabevakning, men aktörerna måste fortsatt själva göra en noggrann och väl dokumenterad bedömning av behovet och proportionaliteten.

Det finns för närvarande varken anmälningsplikt eller tillståndsplikt för kamerabevakning i allmänhet. Denna förändrade reglering bedöms kunna leda till att antalet övervakningskameror i samhället ökar ytterligare, eftersom tröskeln för att införa bevakning blivit lägre. Ingen vet dock hur stor ökningen varit i Sverige (8).

Kamerabevakning som utförs av butiker, privata företag och bostadsrättsföreningar är i regel inte tillståndspliktig. För denna typ av aktörer har det därför länge varit enklare att införa kamerabevakning, vilket även fortsättningsvis gäller. Detta innebär att privata aktörer har relativt goda möjligheter att nyttja kamerateknik för säkerhet och övervakning, samtidigt som de fortfarande måste följa dataskyddsregler och säkerställa att bevakningen sker på ett lagligt och proportionerligt sätt.

Kameraanvändningen kan därför komma att öka och utgöra ett mer naturligt inslag inom olika verksamheter och industrier. Det finns således en potential att nyttja redan befintliga kameror för alternativa ändamål. Exempel på det är redan framtagna algoritmer för detektion av rök och brand (9). Gnistor skulle i så fall utgöra ytterligare ett komplement.

1.3 Detektering av gnistor som funktion i brandskyddet

Försäkringsbolag baserar ofta sin försäkringspremie på ett stort antal faktorer. En del kopplat till just brandskyddet. Några av dessa är exempelvis brandtekniska installationer men även riskmoment inom en enskild byggnad och olycksfrekvens. Varje månad, kvartal eller år betalas denna försäkringspremie för att hålla försäkringen aktiv. Då täcks generellt skador och olyckor som kan tänkas ske på organisationens tillgångar. Försäkringspremien kan höjas och sänkas baserat byggnadstekniska skydd, vilka antingen begränsar eller eliminerar olycksrisken. Nedan följer ett axplock av brandtekniska installationer som kan begränsa risker med brand och brandgasspridning:

- Automatiskt vattensprinklersystem
- Brand- och utrymningslarm
- Brandsektioner och brandcellsgränser
- Branddörrar inkl. stäng funktioner
- Ventilationsbrandskydd

Andra typer av installationer som kan påverka försäkringar kan vara:

- Kamerabevakning
- Inbrottsskydd
- Nattlås
- Etc.

Ofta kan ovanstående brandtekniska installationer och övriga organisatoriska skydd användas som ett krav som organisationerna måste uppfylla utifrån givna krav från försäkringsbolaget eller andra statliga kravställare (Boverket, LSO, räddningstjänst). Uppfylls inte kraven kan försäkringsbolag komma att neka verksamheten en försäkring.

Dessa brandtekniska installationer är ofta kopplade till hanteringen av okontrollerade exotermiska reaktioner som frigör energi till omgivningen. Om kamerabaserade detektionssystem ska fungera som en funktion av brandskyddet bör detektionen fokuseras på de inledande indikationerna/förlopp som kända riskkällor inom byggnader/industrier där olyckorna sker.

1.4 Gnistor

Att gnistor kan antända närliggande material har påvisats i flera fall. I ett exempel har även RISE tidigare undersökt om det är möjligt att naturligt förekommande skogsförna (halvt nedbrutet organiskt material) i skog kan antändas av gnistor mellan skogsmaskiner/anläggningsmaskiner (metall) och stenar. Rapporten kom fram till att gnisttemperaturer från kollisioner av metall och sten kunde uppnå en temperatur på mellan 1 400 och 2 000 °C samt att gnistorna var potenta nog att orsaka en antändning. Potentialen låg i en kombination av storlek på gnistan, temperatur samt oxidering i luften vilket höjde temperaturen på gnistan över tid (10). Potentialen för antändning är alltså stor, även av byggnadsmaterial.

1.5 Tidigare forskning om bilddetektering med AI-modeller

Forskning inom bildbaserad branddetektion har länge främst inriktats på att upptäcka rök, medan gnistor ofta har fått mindre uppmärksamhet trots att de kan vara ett tidigt tecken på att en brand håller på att starta. Den aktuella studien om modellen YOLO DKM lyfter detta som ett tydligt problem och undersöker hur det går att förbättra upptäckten av både små flammor och mycket små gnistor i industriella miljöer (11).

YOLO DKM är vidareutvecklad från YOLOv8 och innehåller flera förbättringar som gör det lättare att känna igen små ljuskällor. Modellen använder SKAttention för att uppmärksamma små detaljer i bilden, vilket hjälper den att urskilja gnistor som annars lätt försvinner. Den använder även DSConv som gör det möjligt att fånga upp små lokala mönster, och CBAM som minskar störningar från bakgrunden och gör det enklare att skilja gnistor från komplicerade industrimiljöer.

Studien visar att YOLO DKM presterar bättre än den ursprungliga YOLOv8. Precisionen ökar med 5,4 procentenheter och Recall ökar med 3,6 procentenheter. Det innebär att modellen hittar fler brandrisker och samtidigt gör färre fel vid identifieringen. Resultaten tyder på att förbättrade uppmärksamhetsfunktioner kan ge en betydligt bättre förmåga att uppfatta brandrisker tidigt i miljöer där bränder kan uppstå.

Studien har även jämfört de olika tilläggen och deras påverkas på specifika klasser inom resultatet. Dock har inte AI-modellen YOLO DKM jämförts i förbättringar i separata klasser, jämförelsen utfördes endast på helheten dvs. brand, gnistor och rök kombinerat. Nedan sammanställs data på förbättringen av varje ingående förbättringsmoduler på YOLOv8 av klassen gnistor.

Tabell 1. Resultaten av separata förbättringsmoduler på YOLOv8 på klassen gnistor.

Förbättrings modul	Precision	Recall	mAP
DSConv	0,640	0,483	0,511
SCConv	0,620	0,452	0,510
AKConv	0,620	0,46	0,484

1.6 Syfte, mål och frågeställning

Detta projekt förväntas bidra till ökad kunskap om hur kameror kan nyttjas för att detektera risker kopplade till arbeten som generar gnistor. Kameror förekommer idag allt mer frekvent inom industri, byggarbetsplatser och andra yrkesmiljöer, och deras användning fortsätter att öka i takt med teknikutvecklingen. Detta skapar nya möjligheter att använda kamerabaserade system som ett stöd i säkerhetsarbetet, särskilt för att identifiera riskfyllda moment.

Syftet med projektet är att ta fram underlag för framtida användningsområden för kameror inom riskdetektering via insamling av videomaterial i laboratoriemiljö. I detta fall fokuserar projektet på att undersöka om kameror ihop med avancerade datormodeller kan användas för att detektera möjliga antändningskällor. Det insamlade underlaget ska kunna ligga till grund för fortsatt utveckling och forskning inom området. Specifikt ska projektet studera antändningskällor där arbeten som generar gnistor förekommer.

Vidare syftar projektet till att jämföra det insamlade materialet med befintlig forskning inom det aktuella forskningsområdet. Denna jämförelse ska bidra till att bedöma teknikens potential, begränsningar och framtida användningsmöjligheter.

Målet är att, med hjälp av vanligt förekommande kameror som används i industri-, kontors- och övervakningsmiljöer, fastställa om kameror kan nyttjas för gnistdetektering. Målet omfattar även insamling av data i form av film- och bildmaterial från typiska arbetsmoment där arbeten som generar gnistor förekommer, såsom svetsning och slipning, samt från moment där gnistor förekommer inom underhållningsbranschen. Vidare är målet att med insamlad data träna en avancerad datamodell till att kunna automatiskt detektera gnistor. Denna datamodell ska sedan jämföras med befintlig forskning inom området. För att uppnå projektets mål ska följande forskningsfråga besvaras:

- I) ”Går det att detektera gnistor med kameror?”

1.8.1 Projektet process gentemot referensgruppen

Projektet har haft tre avstämningsmöten med referensgruppen. Det första uppstartsmötet var den 22:a augusti 2025. Där presenterades projektet och genomförandet. Efter att ha bearbetat synpunkter från referensgruppen fick de möjlighet att lämna synpunkter på försöksuppställningen och de planerade testerna. Det andra mötet med referensgruppen hölls den 19 december 2025. Där presenterades data från försöken och de preliminära resultaten från testkörningar i AI-modellen. Det tredje och sista mötet med referensgruppen hölls den 3:e mars 2026. Till detta möte fick gruppen ett utkast av rapporten och möjlighet att kommentera innehållet i rapporten.

Referensgruppen har bestått av:

Emilia Norin, MSB
Pia Ljunggren, Svenska Brandskyddsföreningen
Nicklas Larsson, Svenska Brandskyddsföreningen
Fredrik Åskog, Nationella brandsäkerhetsgruppen (Vattenfall)
Johan Sydqvist, Vattenfall
Andreas Stagnebo, Vattenfall
Mattias Delin, Brandforsk
Johan Sjöström, Rise
Anders Loid, Tyco/JCI

1.7 Avgränsningar och begränsningar

1.7.1 Tidsbegränsningar

Denna rapport begränsas i den grad att det endast fanns tillfälle för en testserie. Två dagar spenderades på testområdet där testserien utfördes under en dag. En av dagarna nyttjades till att förbereda testuppställningen. Därmed begränsades testerna till endast en dag och en plats där förutsättningarna i omgivningen var relativt homogena hela dagen. Således var underlaget att träna upp datormodellen på begränsat till den data som samlades in under testseriedagen.

1.7.2 Ekonomiska förutsättningar

Testområdet vid gnistbildningen var det enda området lokalt inom testuppställningen som belystes med korrekt belysning. Detta berodde på att om projektet krävde att hela testområdet varit belyst skulle det medföra avsevärt större kostnader. För att projektet skulle vara genomförbart inom de ekonomiska ramarna begränsades projektets omfattning även till typ av AI-modell, testområde samt antal kameror.

1.7.3 Processorkraft

Projektet har avgränsat sig från att undersöka processorkraften som behövs för att nyttja program som kan användas för att detektera gnistor. Mängden processorkraft inom systemet som krävs för att driva programmet är högst relevant för att besvara om systemet går att köras lokalt på kamerorna eller om det krävs ett centralt system för alla kameror med starkare processorkraft. Detta kan undersökas vidare om projektet följs upp.

1.7.4 Ljusintensitet

Under testen begränsades projektet till att använda endast en ljusintensitet (lux nivå) över gnistbildarna. Anledningen var att det tog betydande tid att ställa om belysningen mellan olika testuppställningar, samtidigt som varje omställning krävde noggrann kalibrering för att säkerställa att rätt lux nivå uppnåddes vid teststart för varje uppställning. Eftersom testuppställningens utformning, kamerornas positioner och närvaron av operatörer påverkade ljusfördelningen behövde varje justering verifieras manuellt med lux mätare. Detta visade sig vara tidskrävande och riskerade att skapa variationer i testmiljön. För att möjliggöra en konsekvent och reproducerbar testserie valdes därför att hålla en fast ljusnivå genom samtliga test.

1.7.5 Reliabilitet och validitet

Reliabilitet handlar om att en annan forskare ska kunna genomföra samma studie och erhålla liknande resultat. I detta projekt påverkas reliabiliteten av att AI-modeller är beroende av mänsklig input vid definitionen av vad som klassificeras som en gnista. Om olika personer markerar gnistor på olika sätt, eller använder något avvikande kriterier, kan detta leda till variationer i den färdigtränade modellen. Även valet av datainsamling har en direkt påverkan på slutresultatet; olika kameravinklar, belysning eller gnistkällor kan förändra datasetets egenskaper. Det finns i dag flera internationella standarder som reglerar hur AI-modeller ska styras, dokumenteras och kvalitetssäkras, men det saknas fortfarande helt standardiserade och universellt accepterade metoder för hur den faktiska AI-modellen ska utvecklas i detalj. Detta innebär att även om ramarna kring AI-utveckling blir alltmer standardiserade, kan praktiska moment som data-annotering, val av träningsupplägg och modelloptimering fortfarande skilja sig åt mellan forskare och organisationer. Detta gör noggrann dokumentation av arbetsprocess och metodval särskilt viktigt för att stärka studiens reliabilitet.

Validitet avser i vilken utsträckning studien faktiskt mäter det den avser att mäta. För gnistdetektering innebär det att säkerställa att modellen verkligen identifierar gnistor och inte andra föremål eller ljuseffekter som liknar gnistor. Om modellen reagerar på objekt som är visuellt snarlika men inte utgör verkliga gnistor, kan det ifrågasättas om den lärt sig rätt typ av mönster. En relevant fråga är även om en mänsklig observatör skulle gjort samma felbedömning, om svaret är nej indikerar det bristande validitet i AI-modellen. Om modellen ger utslag på allt som påminner om gnistor finns en risk att den blir opålitlig i praktiska tillämpningar, där precision är avgörande för att undvika falska larm och felaktiga riskbedömningar. Hög validitet kräver därför både representativa träningsdata och noggrann utvärdering mot verkliga förhållanden.

Metodiken bakom upplärning av avancerade AI-modeller låter sig i regel inte återskapas eller redovisas i en fullständigt transparent eller reproducerbar skriftlig form. Detta beror dels på modellernas komplexitet, dels på att upplärningsprocessen ofta involverar stora mängder data, distribuerad beräkningskapacitet och iterativa optimeringar som inte är möjliga att dokumentera steg för steg på ett meningsfullt sätt. Till skillnad från traditionella ingenjers- eller forskningsprojekt, där man vanligtvis kan redovisa samtliga mellanliggande uträkningar, antaganden och preliminära resultat, präglas AI-modellers träningsprocess av en hög grad av automatisering och opacitet. Som följd blir det i praktiken endast slutprodukten, det vill säga modellens observerbara beteende och dess prestanda i validerade testmiljöer som kan granskas, verifieras och utvärderas vetenskapligt.

2 Metod

2.1 Genomförande

Projektet har genomförts i följande delmoment:

1. Litteraturstudie
2. Planering av test och AI-modell
3. Utförande av test med hjälp av LTH
4. Träning av AI-modell
5. Rapportering

I den första delen har en översiktlig litteraturstudie genomförts för att fastställa kunskapsläget idag.

I den andra delen har involverade aktörer planerat utförandet av projektet: framtagande av en testserie med relevanta variabler, planering av testområde ihop med LTH, planering av träningen av AI-modellen.

I den tredje delen utfördes testerna på LTHs område på Revingehed. Första dagen bestod av uppställning av testutrustning, den andra dagen utfördes testerna och inspelning samt nedtagning av utrustning och städning.

I den fjärde delen bearbetades den insamlade datan och sedan tränades AI-modellen med denna bearbetade datan ihop med icke bearbetad data tills konvergens uppnåddes.

Sist har punkterna 1-4 sammanställts i denna rapport.

2.2 Utrustning

2.2.1 Gnistbildare

För att kunna träna AI-modellen att identifiera gnistor krävdes insamling av bild- och filmmaterial där gnistor tydligt förekommer. Denna datainsamling utgjorde en central del av projektets metodik, eftersom en AI-modell behöver ett omfattande och varierat dataset för att kunna lära sig relevanta mönster och visuella egenskaper kopplade till gnistbildning.

I detta projekt valdes tre typer av gnistbildare ut för att skapa ett representativt dataset. Två av dessa utgör vanligt förekommande gnistkällor inom industrin, medan den tredje utgörs av en gnistbildare som används inom underhållningsbranschen. På så sätt säkerställs att AI-modellen tränas på material som speglar både typiska industriella arbetsmoment och gnistbildning som uppstår i scen- och specialeffektssammanhang. Kombinationen av dessa tre gnistkällor bidrar till att skapa en bredare täckning i datan och ökar därmed förutsättningarna för att utveckla en robust och generaliserbar AI-modell.

2.2.1.1 MIG/MAG-svets

En vanligt förekommande användningskälla inom industrin är svetsar. Dessa används för att sammanfoga metall genom att värma upp materialet tills det smälter, varefter det vid avsvälning bildar ett sammanhållet stycke. I detta projekt användes en MIG/MAG-svets (trådsvets), vilken är en av de mest vanligt förekommande svetsmetoderna inom industrin på grund av dess effektivitet och breda användningsområde.

Vid svetsning är det vanligt att gnistor uppstår som en naturlig del av processen. Dessa gnistor består av små, glödande metallpartiklar som slungas ut från arbetsområdet när smält metall och slagg kastas åt sidan. Därtill bildas heta ytor runt svetsfogen som kan utgöra ytterligare potentiella användningskällor. Temperaturen av dessa gnistor/partiklar varierar beroende på hur långt de har färdats ifrån svetsen, från 1 850 grader Celsius nära svetsen till cirka 1 572 grader Celsius när partikeln färdats 2,8 meter nedanför svetsen (12).

Gnistor från svetsning utgör således en relevant och representativ gnisttyp för projektets syfte, då de förekommer frekvent vid arbeten som genererar gnistor och har tydliga visuella egenskaper som kan vara lämpliga för kamerabaserad detektion och träning av AI-modellen.

Den modell av svets som har använts är ESAB Orio MIG C141, anpassad för svetsning i konstruktionsstål och rostfritt stål.

2.2.1.2 Vinkelslip

En annan vanligt förekommande antändningskälla inom industrin är vinkelslipar. Dessa används för att slipa eller kapa metall och förekommer i en mängd olika arbetsmoment inom både verkstadsindustri, byggarbete och underhåll. Vinkelslipen fungerar genom att en skiva, sammansatt av hårt och abrasivt material, fästs på maskinens drivaxel. Maskinen skapar därefter rotation i hög hastighet, och när den roterande skivan förs mot det material som ska bearbetas uppstår en mekanisk påverkan genom slipning eller kapning.

De abrasiva partiklarna i skivan skär in i det mjukare materialet, i detta fall metall, vilket ger upphov till friktion. Denna friktion genererar i sin tur värme. När en partikel från arbetsstycket eller skivan lossnar helt kan den nå mycket höga temperaturer och därmed bli till en gnista. Dessa gnistor består alltså av små, glödande partiklar av metall eller skivmaterial som kastas ut från arbetsområdet med hög hastighet.

Temperaturen på en gnista från en vinkelslip kan uppgå till 170 grader Celsius för slipning av Q235A stål, det kan dock vara en stor andel gnistor som skapas vid slipning. Temperaturen på gnistorna beror huvudsakligen på material och rotationsfrekvensen (13). Och i tidigare rapport av brandforsk uppmättes högre temperatur på gnistor om gnistorna skapa mellan kollision av metall och sten, se avsnitt 1.4. Detta gör att gnistor från vinkelslipar utgör en betydande antändningskälla, och de är därför mycket relevanta för projektets syfte att samla in data för kamerabaserad och AI-baserad gnistdetektering.

Den modell som användes i testerien var en Black & Decker KG1200-QS med en standard metallkapskiva (KAPSKIVA BOSCH METALL 42X130MM).

2.2.1.3 Gnistmaskin (Gnistfontän)

En gnistmaskin använder sig av pyroteknik där en exoterm reaktion utnyttjas för att skapa visuella effekter. Denna typ av utrustning förekommer främst inom underhållningsbranschen, där kontrollerade gnisteffekter används i exempelvis scenproduktioner, evenemang och specialeffekter. I gnistmaskinen placeras ett granulat bestående av små metallkorn i en uppvärmningskammare. I detta projekt användes gnistmaskinen Starville Prometheus Spark 1, som fungerar genom att granulaten gradvis värms upp till en förutbestämd temperatur. Granulatet som användes var av titandioxid. När korrekt temperatur uppnåtts indikeras detta via en signallampa på maskinen, vilket visar att systemet är redo för aktivering.

Vid aktivering skickas de upphettade, glödande metallkornen ut genom maskinens utloppsskål. De kan nå en höjd på upp till cirka fem meter, beroende på inställningar och mängden granulat. Effekten fortgår kontinuerligt så länge maskinen är aktiverad eller tills dess att granulaten är förbrukade.

Denna typ av gnistbildning har tydliga och regelbundna visuella egenskaper, vilket gör gnistmaskiner till en värdefull källa för datainsamling inom projektet. Effekten är dessutom mer kontrollerbar jämfört med industriella gnistprocesser, vilket underlättar insamling av konsekvent och reproducerbart träningsmaterial för AI-modellen. Det bryter också det klassiska svets- och vinkelslipsmönstret av hur gnistor bildas och skjuts iväg.

2.2.2 Kameror

Till testen valdes kameramodeller som är vanligt förekommande inom industrimiljöer samt i byggnader med högt skyddsvärde. Urvalet gjordes för att säkerställa att resultaten blir relevanta för praktiska tillämpningar där kamerabevakning redan används i dag.

Utöver dessa valdes även en något mer avancerad och kostsam kameramodell för att möjliggöra jämförelser mellan standardkameror och utrustning med högre teknisk prestanda i framtiden. Detta ger projektet förutsättningar att i framtiden utvärdera hur kamerans kvalitet påverkar möjligheten att detektera gnistor och vilken nivå av kamerateknik (processorkraft/upplösning) som kan anses vara tillräcklig i verkliga tillämpningar.

Inom detta projekt har AI-modellen inte körts på kamerornas interna dator, dessa har enbart nyttjats för att samla in data till träningen av AI-modellen. Underlaget har dock samlats in med kameror som är inom rätt användningsområde för att i framtiden kunna bedöma om det går att köra på kameror som är vanligt förekommande.

Se Tabell 2 nedan för en översikt av de valda kameramodellerna samt relevant teknisk specifikation.

Tabell 2. Beskrivning av kameror och relevant teknisk specifikation.

Kameramodell	Horisontellt synfält (FOV)	Vertikalt synfält (FOV)	Upplösning	Bilder per sekund (FPS)
Axis P3267-LV	104° - 40°	74° - 29°	2592×1944	30
Axis P3265-LVE	100° - 36°	53° - 20°	1920×1080	50
Hanwha PNM-C34404RQPZ	65,66° - 1,88°	39,4° - 1,09°	1920×1080	50
Hanwha XNZ-6320A	64,66° - 2,29°	38,08 - 1,30°	1920×1080	50

2.2.3 Belysning

Belysningen i testmiljön behövde efterlikna de verkliga förhållanden som råder på en arbetsplats där de aktuella gnistbildarna normalt förekommer. För att uppnå detta valdes att utgå från standarden SS-EN 12464-1, som innehåller rekommenderade lux-nivåer för olika typer av arbetsmoment (14). I detta projekt begränsades testerna till endast en lux-nivå, den nivå som valdes var rekommenderade lux-nivån för svetsarbete vilket återfinns i tabell 26, eftersom denna nivå är representativ för de ljusförhållanden där gnistbildning vanligtvis uppstår.

På plats monterades belysningen längs containerns långsidor och så högt upp som möjligt för att skapa en jämn och stabil ljusfördelning över testområdet. Därefter genomfördes mätningar av lux-nivån i mitten av testuppställningen, där gnistbildningen skulle ske. Mätningen utfördes även med en person stående på samma plats där operatören skulle befinna sig under testen, för att säkerställa att kroppens skuggning och påverkan på ljusfördelningen inte påverkade resultatet negativt.

Med hjälp av en kombination av justerbara LED-lister och LED-arbetsbelysning uppnådde belysningen en lux-nivå på 300 lux, vilket motsvarar rekommendationen för arbetsmoment som involverar svetsning. Detta gav en belysningsnivå som både speglade realistiska arbetsförhållanden och samtidigt säkerställde att kamerorna hade tillräckligt goda förutsättningar för att registrera enskilda gnistor under testen.

För att mäta ljusintensiteten användes standard luxmätare med fotodiod som omvandlar ljus till energi. Apparaten beräknar om infallande energi till antal lux, mätfel är inte beaktat.

2.2.4 Testmaterial

2.3 Testområde

Testerna ägde rum på MSB:s anläggning i Revinge, belägen i Lunds kommun. Revinge är ett av MSB:s största utbildnings- och övningsområden och erbjuder varje år ett omfattande utbud av kurser och utbildningar med fokus på civilt försvar och samhällsskydd. Här utbildas och övar räddningstjänster från hela Sverige samt från andra europeiska länder. Myndigheten för civilt försvar tillhandahåller även utbildningar i samverkan med högskolor och universitet inom områdena skydd mot olyckor, civilt försvar och krisberedskap [5].

Inom Revingeområdet har Lunds Tekniska Högskola (LTH) tillgång till en särskild testsektion som används för forskning och experiment kopplade till brandteknik och riskhantering, se Figur 2. I detta avgränsade område var ett antal containrar placerade och sammankopplade i serie, med en total längd på cirka 60 meter. Den ursprungliga avsikten med denna containeruppställning var att studera brandgasflöden i tunnelliiknande miljöer, vilket kräver kontrollerade och avgränsade utrymmen.




Figur 2. Satellitbilder av LTH's område på Revinge

Denna uppställning lämpade sig väl för genomförandet av projektets tester då det fanns möjlighet att styra och kontrollera ljusnivån (lux-värdet) under samtliga inomhustest. Containerarna möjliggjorde en miljö med stabila, kontrollerbara ljusförhållanden, vilket var avgörande för att kunna utvärdera kamerornas och AI-modellens förmåga att detektera gnistor under reproducerbara och tekniskt konsekventa testförhållanden. Containerarna är även helt utförda i obrännbara ytor.

2.4 Testuppställning

Uppställningen för testen bestod av två huvudkomponenter: kameror och gnistbildare. Fyra olika kamerapositioner testades, varav tre placerades inomhus. Se Figur 3 för en översikt av dessa positioner. Samtliga kameror monterades i en och samma linje, markerad med rött streck i figuren. För ytterligare visualisering av monteringen hänvisas till Figur 5 och Figur 6, där de faktiska installationerna framgår tydligare.




Figur 3. Testuppställning inne i container.

Testuppställningen utomhus placerades mot en befintlig huskropp, cirka 25 meter från ena änden av containeruppställningen, se Figur 4. Denna placering valdes då den visade sig vara den mest effektiva och praktiska lösningen. Genom att låta gnistbildningen ske på samma plats som tidigare kunde förflyttning av utrustningen undvikas, vilket sparade tid och underlättade projektsamordningen.

Dessutom var detta en kostnadseffektiv lösning eftersom det inte krävdes att hyra en ny testyta för de utomhusbaserade testen. Ett byte av område hade medfört extra kostnader, utökade administrativa krav samt behov av en ny riskbedömning för hela uppställningen.

Vidare hade en ny testplats även krävt omfattande saneringsåtgärder. Detta eftersom Revinge omfattas av strikta regler och rutiner kring kontaminering av omgivande områden, vilket innebär att all verksamhet som riskerar att sprida material eller restprodukter måste följas av korrekt och dokumenterad sanering. Genom att använda den befintliga platsen kunde dessa krav hanteras mer effektivt.




Figur 4. Testsuppställning utomhus.

Kameror inomhus

Kamerauppställningen bestod av flera kameror monterade på ett flyttbart stativ, vilket möjliggjorde flexibel positionering under testen. Kamerorna placerades på en höjd av cirka 1,2 meter, med undantag för en kamera som monterades i taket på 2 meters höjd. Denna kamera var konstruerad för att filma nedåt, vilket motiverade dess positionering på högre höjd.

Samtliga kameror anslöts både till strömförsörjning och till internet via nätverkskabel eller WiFi. Internetuppkoppling var nödvändig för att kunna rikta kamerorna med hjälp av tillhörande mjukvara, justera tekniska inställningar samt för att spela in hela händelseförloppet. Detta säkerställde att både kamerajustering och datainsamling kunde ske i realtid och med hög precision.

En av de viktigaste variablerna som justerades under testen var kamerornas FOV (Field of View – synfält). Genom att ändra FOV kunde man kontrollera hur stor del av omgivningen som fångades av bildsensorn. En lägre FOV innebär att kameran fokuserade på ett mindre område, medan en högre FOV omfattade ett större område men med lägre avbildningsdetaljer. Denna inställning motsvarar i praktiken kamerans zoomfunktion och hade direkt påverkan på hur tydligt gnistorna kunde observeras i det inspelade materialet.



Figur 5. Kamerauppställning inomhus.

Kameror utomhus

Kamerauppställningen utomhus monterades på en stege placerad på marknivå. När samtliga kameror var fastmonterade höjdes stegen och lutades mot taket på en närliggande byggnad för att erhålla önskad kameravinkel och höjdposition. Kamerorna hamnade på cirka 3,7 meters höjd. Stegen fixerades därefter mot fasaden med hjälp av spännband för att säkerställa stabilitet och minska risken för vibrationer eller oavsiktliga rörelser under testen.

När kamerorna var upplyfta och korrekt placerade anslöts strömförsörjning och internet/WiFi på nytt, vilket möjliggjorde fjärrstyrning och inspelning. Efter att uppställningen var färdig genomfördes finjusteringar av kamerornas riktning för att säkerställa att gnistbildningen hamnade tydligt inom respektive kameras synfält. Dessa justeringar var nödvändiga för att optimera det insamlade materialets kvalitet och därmed förutsättningarna för en effektiv AI-träning.



Figur 6. Kamerauppställning utomhus.

Gnistbildare

Uppställningen för gnistbildarna placerades i ena änden av containeruppställningen. I detta område monterades ljusanordningar vars ljusstyrka kunde justeras (lux-nivå), samt kompletterande arbetsbelysning med fast ljusstyrka. Belysningen arrangerades så att den belysta ytan utgjorde en kvadrat på cirka 4 m², där ljusnivån var så jämn som möjligt för att säkerställa reproducerbara testförhållanden.

I centrum av kvadraten placerades en arbetsbänk som täcktes med ett obrännbart ytskikt i form av en brandfilt. På arbetsbänken monterades ett tving, vilket användes för att fixera det material som skulle utsättas för gnistbildning under testerna. Denna fixering var viktig för att bibehålla konsekventa förhållanden mellan testen och för att rikta gnistflödet mot kamerorna på ett kontrollerat sätt. Framför arbetsbänken placerades en svart isoleringsskiva där gnistor förväntades passera, således samlades det in underlag (bilder/videor) med fler olika typ av bakgrundsfärger bakom gnistorna.

Vid de utomhusbaserade testerna öppnades containerdörrarna för att skapa fri sikt mot testområdet. Tack vare detta behövde inte uppställningen för gnistbildarna flyttas mellan inomhus- och utomhusmomenten, till skillnad från kamerauppställningen som krävde ompositionering.

Som en extra säkerhetsåtgärd placerades både en pulversläckare och en brandfilt i direkt anslutning till testområdet. Detta var nödvändigt eftersom gnistbildning alltid innebär en teoretisk risk för antändning, trots att testmiljön utformades för att minimera brandrisk genom användning av obrännbart material och kontrollerad ljus- och arbetsmiljö.



Figur 7. Testområde för gnistbildning.

2.4.1 Testserie

Nedan listas alla test som ingick i projektet och faktorer som varierades, se Tabell 3 på nästa sida. Det ingick även en till variabel som ej listas i testserien, varje test utfördes nämligen två gånger, ett med en person (ett hinder) framför gnistbildare och ett utan.

Tabell 3. Tester och ingående faktorer

Testnamn	Avstånd	Lux [Lumen]	Material	Gnistbildare	Synvinkel	Testområde
46.Q.2.1	46 meter	300	Q235	MIG/MAG-svets	Bred	Inomhus
46.Q.3.1	46 meter	300	Q235	Vinkelslip	Bred	Inomhus
46.T.4.1	46 meter	300	Titan	Gnistmaskin	Bred	Inomhus
46.Q.2.0	46 meter	300	Q235	MIG/MAG-svets	Smal	Inomhus
46.Q.3.0	46 meter	300	Q235	Vinkelslip	Smal	Inomhus
46.T.4.0	46 meter	300	Titan	gnistmaskin	Smal	Inomhus
30.Q.2.1	30 meter	300	Q235	MIG/MAG-svets	Bred	Inomhus
30.Q.3.1	30 meter	300	Q235	Vinkelslip	Bred	Inomhus
30.T.4.1	30 meter	300	Titan	Gnistmaskin	Bred	Inomhus
30.Q.2.0	30 meter	300	Q235	MIG/MAG-svets	Smal	Inomhus
30.Q.3.0	30 meter	300	Q235	Vinkelslip	Smal	Inomhus
30.T.4.0	30 meter	300	Titan	Gnistmaskin	Smal	Inomhus
10.Q.2.1	10 meter	300	Q235	MIG/MAG-svets	Bred	Inomhus
10.Q.3.1	10 meter	300	Q235	Vinkelslip	Bred	Inomhus
10.T.4.1	10 meter	300	Titan	Gnistmaskin	Bred	Inomhus
10.Q.2.0	10 meter	300	Q235	MIG/MAG-svets	Smal	Inomhus
10.Q.3.0	10 meter	300	Q235	Vinkelslip	Smal	Inomhus
10.T.4.0	10 meter	300	Titan	Gnistmaskin	Smal	Inomhus
25.Q.2.1	25 meter	utomhus	Q235	MIG/MAG-svets	Bred	Utomhus
25.Q.3.1	25 meter	utomhus	Q235	Vinkelslip	Bred	Utomhus
25.T.4.1	25 meter	utomhus	Titan	Gnistmaskin	Bred	Utomhus
25.Q.2.0	25 meter	utomhus	Q235	MIG/MAG-svets	Smal	Utomhus
25.Q.3.0	25 meter	utomhus	Q235	Vinkelslip	Smal	Utomhus
25.T.4.0	25 meter	utomhus	Titan	Gnistmaskin	Smal	Utomhus
25.0.3.0	25 meter	utomhus	Inget	Inget	Smal	Utomhus
25.0.2.0	25 meter	utomhus	Inget	Inget	Smal	Utomhus
25.Q.2.5	25 meter	utomhus	Q235	Mig/Mag-svets	Mellan	Utomhus
25.Q.3.5	25 meter	utomhus	Q235	Vinkelslip	Mellan	Utomhus

2.5 Bildanalys / bildigenkänning

Det finns ett stort antal programvaror och ramverk för bildanalys och bildigenkänning, och dessa bygger delvis på olika tekniska principer. Därför är det viktigt att noggrant överväga vilket system som är mest lämpligt för den specifika uppgift som ska lösas. För uppgiften att identifiera gnistor valdes programmet YOLOv11, ett modernt och effektivt objektidentifieringssystem. Resonemanget bakom valet av just YOLOv11 redovisas mer utförligt i det examensarbete som tagits fram av Erik Berglin (15).

Denna rapport kommer inte att gå in på djupet kring hur faltande neurala nätverk (CNN – AI-modellen) fungerar, då även denna beskrivning återfinns i ovan nämnda examensarbete. Nedan följer dock en kortfattad och övergripande beskrivning av grunderna i bildigenkänning för att skapa en förståelse för träningsprocessen.

Träning av bildigenkänning innebär att en dator lär sig känna igen mönster genom att analysera ett stort antal exempelbilder som är märkta med information om vad de innehåller. Under träningsprocessen visas bilderna för datorn en i taget, där varje bild är försedd med etiketter. Etiketterna innehåller klassen för objektet, exempelvis "gnista", och en avgränsningsbox (bounding box) som visar var i bilden objektet befinner sig. Det kan finnas flera etiketter i samma bild om det finns fler än ett objekt. Modellen gör därefter en första gissning, utan att se etiketterna, baserat på sina aktuella interna parametrar. Denna gissning jämförs med det korrekta svaret, och om modellen gissar fel justeras parametrarna något i syfte att förbättra resultatet vid nästa iteration.

Processen upprepas och med ett brett urval av bilder. Genom denna kontinuerliga återkoppling blir modellen gradvis mer optimerad på att känna igen visuella egenskaper såsom mönster, konturer, färgvariationer och rörelsemönster som är typiska för olika typer av objekt. När modellen har genomgått tillräckligt många träningspass kan den tillämpa det den lärt sig för att analysera helt nya bilder som den inte tidigare har sett och göra kvalificerade bedömningar av vad dessa innehåller.

Träningen bygger således på principerna om upprepning, återkoppling och successiv förbättring. Denna metodik utgör grunden för modern bildigenkänning och gör det möjligt att utveckla modeller som på ett tillförlitligt sätt kan identifiera komplexa visuella fenomen, såsom gnistor från olika typer av gnistbildare.

2.5.1 För-träning och dataset

Flera olika modeller blev tränade på det dataset som tagits fram för detta arbete. Flera modeller tränades då det fanns risk för så kallade "overfitting", överanpassning, där en modell lär sig träningsbilderna otroligt bra men blir oanvändbar på bilder utanför dem. Mängden data i datasetet var rimlig (tumregeln är minst 1 000 bilder med minst 10 000 instanser, datasetet blev 2 149 bilder med 50 571 instanser på gnistor) men eftersom alla bilderna kommer från samma testserie är det möjligt att det är för lite variation mellan bilderna (16). För-träning, att AI-modellen tränas på andra dataset innan den tränas på gnistdatasetet, ska teoretiskt göra den mer robust mot överanpassning. Tre olika AI-modeller tränades med olika för-träning: en blev inte för-tränad alls, en blev för-tränad på COCO (17), och en blev för-tränad på VisDrone (18).

YOLOv11 skalar om bilder till 640x640 pixlar innan dem används i träning, vilket tillsammans med att detaljer försvinner när en CNN plockar fram information från bilderna, gör att gnistor lätt försvinner. Det är möjligt att träna på bilder i högre upplösning än 640x640 pixlar, men då krävs rejäl datorkraft som inte fanns när arbetet utfördes. Istället skapades ett till dataset genom bildsegmentering från 1920x1080 och 2592x1944 pixlar (beroende på vilken kamera användes för att ta bilden, se tabell 1) ner till 640x640 pixlar innan träningen, så YOLOv11 inte behöver skala ner bilderna. Det bildsegmenterade datasetet innehåller färre bilder än originalet (73 bilder färre), men förlusten bedömdes tillräckligt liten att det inte var värt tiden det skulle ta att felsöka metoden att bildsegmenterad.


2.5.2 Bedömningsmått

Träffsäkerheten hos en CNN bedöms med några olika mått. De viktigaste kommer att diskuteras här, för att ge en förklaring om vad siffrorna i efterföljande sektioner betyder.

Det är två basmått som de flesta andra mått uträknas från: precision och recall (återkallelse). Precision mäter hur ofta CNN-modellen gissar rätt. En precision på 50% betyder att hälften av de gissningar som CNN-modellen har gjort är rätt. Recall mäter hur många av de objekt som finns som blivit identifierade. En recall på 50% betyder att hälften av objekten i datasetet har identifierats.

Det mått som har blivit standardmättet att jämföra CNN-modeller med varandra är mean Average Precision (mAP), medelgenomsnittliga precisionen (19) (20). Den heter mean AP eftersom den är medelvärdet på alla klassernas AP, som beräknas individuellt för varje klass utifrån deras Precision-Recall kurva (P-R kurva). När en CNN gör sina gissningar ger den även en confidence score, förtroendepoäng, som beskriver hur säker CNN är på att sin gissning är rätt. Förtroendepoängen ges mellan strax över 0 och 1, där 1 är helt säker och 0 betyder att den inte gör en gissning. Vilket förtroendepoäng som används som gränsvärde för en giltig detektion påverkar både recall och precision. Om det krävs en hög förtroendepoäng för att räknas kommer precision att vara högt, eftersom endast de objekt som modellen är väldigt säker på kommer räknas. Däremot, är förtroendepoängskravet lågt kommer recall att vara högt, eftersom ett högre antal gissningar innebär att fler objekt kommer att identifieras. För att ta fram en PR-kurva beräknar man precision och recall vid sjunkande förtroendepoängskrav och ritar sedan en kurva utifrån precision och recall paren som framtagits. Arean under kurvan är AP, och genomsnittet för AP blir mAP. Figur 4 visar ett exempel på P-R kurvor.

Det är två olika mAP som används, mAP50 och mAP50-95. Siffrorna anger hur stor Intersection over Union (IoU) behöver vara, alltså hur mycket avgränsningsboxen från modellens gissning måste stämma överens med etikettens avgränsningsbox. mAP50 betyder att IoU måste vara 50%, alltså att hälften av gissningens avgränsningsbox måste stämma med etikettens avgränsningsbox. mAP50-95 betyder att IoU-kravet har stegvis ökat från 50% till 95%, och genomsnittsvärdet för mAP vid alla kraven blir mAP50-95.



Figur 6: Ett exempel på P-R kurvor.

3 Resultat

3.1 Insamlad data

Resultatet av testerna som utfördes blev 5,63 GB data som kan användas som underlag till framtida forskning. Det förekommer data på samma moment från olika typer av kameror. En del data är även utan gnistor, alltså är materialet inte rensat på förberedelse inför gnistbildningen.

3.2 AI-modellens träningsresultat

Följande sektion kommer att presentera kortfattat de bästa resultaten från träningen som gjordes. De andra resultaten och mer ingående analys på CNN-delarna finns i exjobbet som utfördes av Erik Bergelin (15).

Fyra modeller blev tränade till konvergens, dvs. då träningen slutar att resultera i en mer optimerad modell för det specifika syftet. Det var två modeller per dataset, modellen som inte var för-tränad samt den för-tränade modellen som gav bäst resultat efter 100 epoker. Svetsning och slipning lades till som klasser för att göra processen att sätta etiketter på bilder lättare. I tabell 3 nedan visas resultaten, med informationen om gnistor fetstilt. Namnen ger vad de är för-tränade på (Coco640 är för-tränat på COCO, Yolo640 är inte för-tränat) och 640 i namnet är en kvarleva från försök att köra träningen i högre upplösningar, såsom 1920x1920. Modellerna tränade på det bildsegmenterade datasetet har "cropped" i slutet på sina namn.

Modellerna tränade på det bildsegmenterade datasetet hade en högre procentuell träffsäkerhet än de tränade på det originella datasetet. Det bästa resultatet är Coco640Cropped med över två tredjedelar av dess gissningar korrekt (precision på 68,7%) och som korrekt identifierade hälften av gnistorerna (recall på 50,1%). Se även Tabell 4 på nästa sida där resultatet för alla modeller har tabellerats.

Tabell 4. Testresultat efter träningen nådde konvergens

Modell	Klass	Bilder	Instanser	Precision	Recall	mAP50	mAP50-95
<i>Coco640</i>	Alla	229	5378	84,3%	55,4%	65,1%	48,8%
	Svetsning	97	97	98,5%	51,5%	73,2%	59,7%
	Slipning	70	70	92,9%	98,6%	98,1%	74,4%
	Gnista	206	5211	61,4%	16,1%	24,1%	12,2%
<i>Yolo640</i>	Alla	229	5378	83,5%	54,1%	59,7%	38,8%
	Svetsning	97	97	98,5%	51,5%	63,1%	46,4%
	Slipning	70	70	87,9%	98,6%	98%	62,5%
	Gnista	206	5211	63,9%	12,1%	18,1%	7,57%
<i>Coco640 Cropped</i>	Alla	220	4832	86,3%	83,4%	84,9%	64,7%
	Svetsning	97	97	99,3%	100%	99,5%	82,1%
	Slipning	61	61	90,8%	100%	99%	78,9%
	Gnista	198	4674	68,7%	50,1%	56,4%	33,1%
<i>Yolo640 Cropped</i>	Alla	220	4832	86,5%	80,7%	82,9%	61,2%
	Svetsning	97	97	100%	96,8%	99,4%	81,3%
	Slipning	61	61	92,5%	98,4%	96,8%	72,6%
	Gnista	198	4674	66,9%	47%	52,5%	29,9%

4 Diskussion

4.1 AI-modellerna

Metoden i denna rapport bygger på att generera en omfattande och varierad datamängd, exempelvis genom att variera avstånd, kameramodeller och kamerahöjder. Dessa variationer användes dock inte för att utveckla separata modeller i syfte att jämföra hur respektive variabel påverkar resultatet. Att skapa en ny AI-modell för varje enskild variabeländring är tidskrävande, och inom ramen för detta projekt fanns inte möjlighet att genomföra en sådan tillämpnings baserad analys.

Det är dock fortsatt av stort intresse att undersöka hur dessa variabler påverkar detekteringen, då sådan kunskap är central för att kunna optimera AI-modellen för olika situationer i framtida praktiska tillämpningar. Detsamma gäller användningen av flera kameramodeller; även här saknades tid för att separera datan och utveckla en modell per kamera för att analysera deras respektive påverkan.

En variabel som särskilt hade behövt en fördjupad analys är avståndet till kameran. AI-modellen påverkas av antalet gnistor per pixel, vilket i sin tur beror både på bildsegmenteringen och avståndet mellan gnistkällan och kameran. I denna studie har det inte varit möjligt att avgöra vilken av dessa faktorer som har störst betydelse, eller om det är en balanserad kombination av dem som utgör den mest optimala lösningen vid en framtida praktisk tillämpning.

Att modellerna tränade på det bildsegmenterade datasetet ger en högre procentuell detektering betyder inte nödvändigtvis att de är mer lämpade för praktisk tillämpning. Eftersom de är tränade på bilder som är bildsegmenterade till 640x640 behöver de samma storlek på bilder som de används på. Bilderna från kamerorna måste alltså segmenteras till 640x640 innan CNN-modellen används. Det var relativt lätt att göra för träningsdatan, eftersom områdena där gnistor befann sig var känt innan bildsegmentering började. I industrin är intresseområdet i bilderna okänt, vilket betyder att processen för att identifiera intresseområden också behöver automatiseras.

Modeller tränade på ej bildsegmenterad data har inte samma problem när det kommer till implementering. Eftersom de är tränade på bilder som är fullstora (1920x1080 och 2592x1944) används modellerna direkt på bilderna från kamerorna. Om den lättare implementeringen väger upp för det sämre resultatet måste bedömas enskilt för varje fall.

Kontexten för användningsområdet måste också tas i åtanke. Vinkelslipning och svetsning producerar väldigt många gnistor, och dessa gnistor befinner sig ofta i grupper. Detta arbete har försökt identifiera individuella gnistor. Att identifiera två gnistor istället för tre gnistor i en grupp på fem gnistor ger sämre resultat för statistiken, men liknande resultat för brandsäkerheten. För brandsäkerheten räcker det med att detektion sker och inte att många detektioner sker.

Identifieringen av gnistor kanske inte borde bedömas med det vedertagna standardmåttet för bedöma CNN-modeller. Ett förslag är att modellerna kan istället bedömas baserat på vilken modell som kan utföra detektion i minst optimala förhållanden. Till exempel i olika förhållanden som försvårar detektering, smutsig kameran, långa avstånd och ett begränsat antal gnistor. Figur 7 nedan visar ett exempel på resultat från när Coco640, bilden till vänster, och Coco640Cropped, bilden till höger, användes på en bild som visar vinkelslipning. Coco640Cropped identifierar fler gnistor än Coco640, men många av identifieringarna kan ses som överflödiga. Däremot tar Coco640 både gnistan nere till höger och gnistorna uppe till höger som är på väg bort från vinkelslipen, medan Coco640Cropped endast tar gnistan nere till höger. Hade denna bild blivit bedömd hade Coco640Cropped fått högre betyg i bedömningsmåttet, men Coco640 hade varit mer tillämpbar i en verklig situation.



Figur 7: Coco640 (till vänster) och Coco640Cropped (till höger) använda på en bild som visar vinkelslipning

Figur 7 är ett exempel som visar en situation där en ej bildsegmenterad modell påvisar mer detektering än en bildsegmenterad modell. Kameran är relativt nära, och gnistorna är relativt stora. Figur 8 visar en bild på svetsning tagen från 30 meters avstånd med P3265-LVE vid full inzoomning. Återigen har Coco640 och Coco640Cropped använts på bilden. Vid längre avstånd blir gnistorna för små för att ej bildsegmenterade modeller ska kunna identifiera dem, medan klippta modellerna har den förmågan. Större delar av bilden innehåller ointressant information, och beskärningen möjliggör detektion genom att ta bort den överflödiga informationen innan CNN-modellen börjar arbeta.



Figur 8: Coco640 (till vänster) och Coco640Cropped (till höger) använda på en bild som visar svetsning

AI-modeller kan detektera gnistor har resultatet bevisat. Det kvarstår att undersöka hur en eventuell tillämpning i verkliga förhållanden hade fungerat. Aktuell studie har inte varit tillämpningsbaserad och således går det inte att avgöra vilka variabler som är av vikt för en praktiskt tillämpning. Varje praktisk tillämpning exempelvis en byggarbetsplats eller industri har även unika faktorer som påverkar AI-modellerna och behöver tas i beaktning vid tillämpning. En praktisk tillämpning av modellen hade varit inom riskfyllda miljöer där ingen riktig struktur på var arbeten som genererar gnistor förekommer, till exempel större byggarbetsplatser.

4.2 Jämförelse med befintlig forskning

Nedan jämförelse är mot forskningen som utfördes 2025 och presenteras i avsnitt 1.5 (11).

Befintlig forskning har, likt denna rapports bästa resultat, genomförts med en bildstorlek på 640 gånger 640 pixlar. Datasetet som används i forskningen för just gnistdetektering är dock okänt. Det framgår endast att materialet består av en blandning av gnistor, flammor och rök, vilket innebär att den specifika parametern för gnistfokusering inte kan jämföras direkt med denna studie.

I Tabell 5 nedan redovisas en jämförelse mellan modellen Coco640Cropped, som uppnådde de bästa resultaten i denna studie, och de resultat som rapporteras i den aktuella forskningen. AI-modellen som togs fram i denna rapport och även i Berglin, E (15), uppvisar 4,7 procentenheter högre precision, 1,8 procentenheter högre recall samt 5,3 procentenheter högre mAP50 jämfört med forskningmodellen. Det är dock viktigt att uppmärksamma att det föreligger betydande skillnader i underlaget mellan modellerna. I forskningsstudien användes bilddata från ett bredare spektrum av miljöer, inklusive inomhusmiljöer, utomhusmiljöer, industriella miljöer och skogsmiljöer, vilket innebär en större variation i både ljusförhållanden och visuell komplexitet. Även skillnader i hur bildsegmenteringen av originalbilderna genomfördes kan ha påverkat resultatens utfall.

Trots dessa skillnader är resultaten ändå väl jämförbara och ligger nära de nivåer som rapporteras i tidigare forskning, vilket ligger i linje med vad som rimligen kunde förväntas.

Tabell 5. Jämförelse av forskningsresultat och bästa AI-modellen som togs fram i denna rapport.

Förbättrings modul	Precision	Recall	mAP50
DSConv	0,640	0,483	0,511
SCConv	0,620	0,452	0,510
AKConv	0,620	0,46	0,484
Coco640Cropped	0,687	0,501	0,564

4.3 Felklassificeringar och konsekvenser för säkerhet

När en CNN-modell tränas finns det alltid en risk för felklassificeringar, att modellen har fel när den identifierar ett objekt. Det kallas för en falsk positivt när en modell gör en felaktig identifiering. För modellerna i detta projekt kan det bli fel när objekt delar utseende med gnistor. En stor felkälla är långa, diagonala linjer som är ljusare än sin omgivning. Eftersom gnistor ofta rör sig väldigt snabbt, blir deras profil i bilder ofta en lång, ljus linje. Exempel på föremål som ofta ger falska positiva är lampor och reflexvästar.

Falska positiva kan orsaka problem i verksamheten. Ett onödigt stopp kan orsaka långa förseningar. Att det i detta fall kan orsakas falska positiva av föremål som är vanliga på arbetsplatser och som förekommer i stora mängder är en begränsning som måste tas i hänsyn. Det är möjligt att det skulle kunna förbättras om det tillkommer bilder med folk i reflexvästar i datasetet, så att CNN-modellen får lära sig att identifiera reflexvästar och därmed inte felklassificerar bilder av sådana.

En falsk negativ inträffar när CNN-modellen missar en gnista. Eftersom gnistor utgör en brandrisk, är det därmed en säkerhetsrisk när falska negativa inträffar. Det är svårare att identifiera vad som orsakar falska negativa. Generellt är det svårare att identifiera föremål när de är små relativt storleken på bilden. Därmed kan falska negativa motverkas genom att maximera storleken på gnistorerna i bild. Detta kan göras genom att placera kameror med arbeten som genererar gnistor i fokus och zooma in så mycket som möjligt. En lägre ljusnivå i utrymmet bidrar också till tydligare gnistor, eftersom kontrasten mellan gnistan och bakgrunden skulle öka.

Både falska positiva och falska negativa kan bekämpas via ett större dataset. Det är egentligen inte just mängden data som är intressant, utan mer en utökning av variationen i bilderna. Som nämnts tidigare var alla bilderna som använts i detta projekt insamlade i ett labb på en dag. Detta har lett till en stor homogenitet hos bilderna: samma bakgrund, samma personer som gör arbetet, samma arbetsyta, osv. En större variation hos träningsbilderna leder till att CNN-modellen blir mer generell och mindre beroende av de specifika omständigheterna som gällde när träningsdatan blev insamlad.

Etiketteringen av insamlade datan påverkar också resultatet. Det är etiketterna som utgör grunden för CNN-modellens inlärning, och är etiketterna inkonsekventa blir träningen lidande. Gnistor som inte fick etiketter eller föremål som inte är gnistor men får etiketter gör att parameterjusteringen inte blir lika pålitlig, då den utgår från felaktig grund. Inkonsekvent hantering av andra situationer kan också ha en negativ påverkan, exempelvis om två gnistor som överlappar ibland etiketteras som en gnista och ibland som två gnistor. Då datasetet skapades för hand av en person, och inte granskades i sin helhet efter det var skapat, finns det garanterat exempel på feletikettering.

4.4 Etisk användning av AI-modeller och kameror

Användningen av kameror för gnistdetektering berör både juridiska och etiska frågor, särskilt vid införande i arbetsmiljöer. Ur ett lagstiftningsperspektiv skiljer sig förutsättningarna mellan industrimiljöer och offentliga miljöer. I industrimiljöer kan bevakning ofta motiveras av säkerhet, förebyggande av olyckor och skydd av verksamhetskritiska tillgångar, medan offentliga miljöer generellt ställer högre krav på proportionalitet och integritetsskydd. Oavsett kontext måste grundläggande principer upprätthållas:

- laglig grund för behandlingen,
- tydligt och avgränsat ändamål,
- informationsskyldighet,
- dataminimering,
- lagringsbegränsning
- adekvat skydd av materialet.

Etiskt uppstår särskilda utmaningar när kameraövervakning riskerar att uppfattas som personövervakning. För att undvika otillbörlig övervakning bör kameror i första hand riktas mot arbetsytor och processer, inte mot individer, och åtkomsten till inspelat material ska vara strikt begränsad och loggförd. Problematik uppstår också när personer som vistas i området inte har accepterat eller informerats om att bli inspelade, detta kan stå i konflikt med dataskyddsreglerna om inte annan laglig grund föreligger. Vid gnistdetektering bör därför utformningen sträva efter att minimera integritetsintrång, till exempel genom att maskera personer automatiskt, behandla data lokalt utan lagring av video, lagra enbart detektionshändelser eller anonymiserade metadata samt genom att välja kameravinklar där individer inte kan identifieras. Vidare bör risker för funktionsglidning motverkas genom tydliga interna riktlinjer som förbjuder sekundär användning av materialet (exempelvis prestationsövervakning), samt genom att fastställa ansvar, roller och rutiner för hantering, radering och incidentrapportering. Slutligen bör införandet föregås av en dokumenterad intresseavvägning och, vid behov, en strukturerad konsekvensbedömning avseende dataskydd samt ett aktivt arbete med information och dialog med berörd personal för att bevara förtroendet. Det bör säkerställas att syftet som i detta fall är ökad säkerhet vid arbeten som genererar gnistor förblir styrande.

5 Slutsats

Detta projekt visar att kameror i kombination med avancerade AI-modeller har potential att identifiera gnistor som uppstår vid arbeten där gnistbildning förekommer. Genom att samla in data i en kontrollerad miljö och träna flera olika modeller kunde projektet påvisa att kamerabaserad gnistdetektering är genomförbar, men att resultatet påverkas starkt av bildkvalitet (antalet pixlar), kameravinkel och avstånd. Modeller tränade på bildsegmenterat bildmaterial uppnådde högre precision och förmåga att upptäcka små gnistor, medan modeller tränade på ej bildsegmenterat material kräver mer processorkraft. Bildsegmentering kräver ett ytterligare steg av AI-modellen att välja intresseområde. Detta understryker att olika modeller lämpar sig för olika praktiska situationer.

Projektet visar även att utvecklingen av en tillförlitlig AI-modell kräver noggrann hantering av träningsdata, tydliga definitioner av vad som räknas som en gnista och en förståelse för hur kamerans tekniska begränsningar påverkar utfallet. Samtidigt belyser arbetet möjligheten att i framtiden integrera denna typ av system i industriella miljöer som ett stöd för tidig riskidentifiering. Sammantaget indikerar projektets resultat att kamerabaserad gnistdetektering är lovande, men att vidare forskning och utveckling krävs för att uppnå tillräcklig robusthet och generaliserbarhet för verkliga tillämpningar.

Denna rapport har en begränsning i att analysen innefattar flera olika kameror och avstånd. Det har inte skett någon analys av respektive kamera eller avstånd.

6 Framtida Arbeten

Det finns flera möjliga utvecklingsområden för att vidareutveckla det presenterade systemet och öka dess robusthet, skalbarhet och användbarhet i praktiska tillämpningar.

6.1 Standardiserat datautbyte och systemintegration

Ett framtida arbete är att utveckla standardiserade lösningar för datautbyte och systemintegration. Detta omfattar definiering av krav, kommunikationsgränssnitt och säkerhetsarkitektur för att möjliggöra koppling mot överordnade system såsom BMS (Building Management System) och SCADA-system (Supervisory Control and Data Acquisition). En sådan integration är avgörande för att systemet ska kunna användas i industriella och fastighetstekniska miljöer där krav på driftsäkerhet, cybersäkerhet och interoperabilitet är höga.

6.2 Kriterier för tillämpning på befintliga installationer/system

Ett centralt område för framtida arbete är att fastställa vilka kriterier AI-modellen kräver för att fungera tillförlitligt i verkliga förhållanden. För att en praktisk tillämpning ska vara möjlig behöver man tydligt definiera vilka tekniska och miljömässiga förutsättningar som modellen är beroende av, exempelvis minsta kameraupplösning, optimala avstånd, ljusförhållanden, bildfrekvens, samt hur mycket variation i bakgrundsmiljö modellen kan hantera utan att prestandan försämras. Genom att systematiskt utreda dessa grundläggande behov kan man avgöra om och hur AI-modellen kan implementeras i befintliga installationer och operativa miljöer. En sådan kriteriebaserad analys är avgörande för att bedöma modellens robusthet, anpassningsförmåga och praktiska användbarhet samt för att ge tydliga riktlinjer inför framtida tillämpningar.

6.3 Multimodal detektering och redundans

Ett utvecklingsområde är att kombinera den kamerabaserade gnistdetekteringen med ljudbaserad detektering. Genom att inarbeta flera sensormodaliteter i AI-modellen eller kombinera systemet med en separat AI-modell kan systemet uppnå ökad tillförlitlighet och redundans, vilket minskar risken för falska positiva och falska negativa detekteringar. En sådan multimodal lösning möjliggör även bättre funktion i miljöer med varierande ljus- eller ljudförhållanden.

6.4 Integration av flera AI-baserade system

Vidare arbete kan även fokusera på integration av flera olika typer av system baserade på artificiell intelligens. Detta inkluderar samverkan mellan specialiserade AI-modeller för olika deluppgifter, exempelvis detektering, klassificering och prediktion. Ett viktigt utvecklingsområde är optimering av beräkningsresurser, där hela datorns kapacitet utnyttjas effektivt genom parallellisering och fördelning av beräkningar mellan flera modeller och mjukvarukomponenter. Olika typer av system är till exempel:

- Brand- och rökdetektering
- Detektering av obehöriga
- Bevakning av processrisker
- Bevakning och korrekt användning av skyddsutrustning
- Etc.

Referenser

1. Brandskyddsföreningen. Brandskyddsföreningen.se. [Online] den 7 april 2020. [Citat: den 3 Februari 2026.] <https://www.brandskyddsforeningen.se/tidningen-brandsakert/artiklar/framgangssagan-som-bade-sparat-pengar--och-raddat-liv/#:~:text=och%20andra%20heta%20arbeten%20eskalerat,under%20en%20tid.>
2. Myndigheten för samhällsnydd och beredskap (MSB). Räddningstjänst i siffror 2015. Karlstad : MSB, 2016. ISBN: 978-91-7383-701-9.
3. Brandsäkert.se. Tidningen brandsäkert. [Online] den 14 Februari 2024. [Citat: den 3 Februari 2026.] <https://brandsakert.se/2024/02/14/brand-pa-byggarbetsplatser/#:~:text=Under%20de%20senaste%20tio%20%C3%A5ren,31%20av%20fel%20i%20utrustningen.>
4. Svensk Försäkring. Skador orsakade av brand och åska. Stockholm : Svensk Försäkring, 2018.
5. Brottsförebyggande rådet. bra.se. Kamerabevakning och belysning. [Online] den 28 april 2025. [Citat: den 08 April 2026.] <https://bra.se/amnen/kamerabevakning-och-belysning/#:~:text=Kamerabevakning%20i%20brottsf%C3%B6rebyggande%20syfte%20blir%20allt%20mer,%20kraft%20i%20augusti%202018%20beh%C3%B6ver%20f%C3%A4rre.>
6. Regeringskansliet. regeringen.se. Regeringen går vidare med lagförslag om utökad kamerabevakning. [Online] den 3 Februari 2025. [Citat: den 8 April 2026.] <https://regeringen.se/pressmeddelanden/2025/02/regeringen-gar-vidare-med-lagforslag-om-utokad-kamerabevakning/#:~:text=Kravet%20p%C3%A5%20tillst%C3%A5nd%20f%C3%B6r%20kamerabevakning%20tas%20bort.,f%C3%A5r%20anv%C3%A4nda%20kameror%20p%C3%A5%20fler%20platse.>
7. Integritetsskyddsmyndigheten. imy.se. Nya kameraregler från den 1 april 2025. [Online] den 27 Januari 2026. [Citat: den 8 April 2026.] [https://www.imy.se/verksamhet/kamerabevakning/nya-kameraregler-fran-den-1-april/.](https://www.imy.se/verksamhet/kamerabevakning/nya-kameraregler-fran-den-1-april/)
8. Caicedo, Sebastian G. Bevakning. Övervakningskameror i tusental – utan samlad överblick. P4 Örebro, Örebro : Sveriges Radio, den 6 April 2026.
9. Nilsson, D och Holmsted, G. Kompendium i aktiva system - detektion. Lund : Lunds Universitet, 2008. ISSN 1402-3504.
10. Sjöström, J, o.a. Ignition of natural fuels from strikes between steel and rocks. Borås : RISE Research institutes of Sweden AB, 2022. ISBN: 978-91-89561-39-7.
11. YOLO-DKM: A Flame and Spark Detection Algorithm Based on Deep Learning. Shang, L. och al, et. u.o. : IEEE Access, 2025, Vol. 13.
12. Mikkelsen, K. An Experimental Investigation of Ignition Propensity of Hot Work Processes in the Nuclear Industri. Ontario, Waterloo : University of Waterloo, 2014.
13. Study on the Mechanism of Sparks Generated Mechanical Friction. Pan, H och Zhang, Y. Xuzhou : John Wiley & Sons Ltd, 2022, Journal of Engineering, Vol. 2022. ISSN:2314-4912.
14. Swedish Standards Institute. Light and lighting - Lighting of work places - Part 1: Indoor work places. SS-EN 12464-1:2021. Stockholm : Swedish Institute for Standards, 2021. 4. STD-80032945.
15. Berglin, E. Detecting Sparks from Hot Work Using a Convolutional Neural Network. Institutionen för system- och rymdteknik, Rymdteknik. Luleå : Lule Tekniska Universitet, 2026.
16. Ultralytics inc. Tips for Best YOLOv5 Training Results. [Online] den 12 November 2023. [Citat: den 2 april 2026.] [https://docs.ultralytics.com/yolov5/tutorials/tips_for_best_training_results/.](https://docs.ultralytics.com/yolov5/tutorials/tips_for_best_training_results/)

17. COCO - Common Objects in Context. cocodataset. [Online] [Citat: den 17 Februari 2026.] <https://cocodataset.org/#home>.
18. Zhu, P, o.a. Cornell University. arxiv. [Online] den 23 April 2018. [Citat: den 17 Februari 2026.] <https://arxiv.org/abs/1804.07437>.
19. Ruman. Medium. [Online] den 28 feb 2025. [Citat: den 2 april 2026.] <https://rumn.medium.com/why-map-is-the-gold-standard-for-object-detection-9e6d96dce402>.
20. Shah, D. v7labs. [Online] V7 Ltd, den 7 mars 2022. [Citat: den 2 april 2026.] <https://www.v7labs.com/blog/mean-average-precision>.

Stödorganisationer

under 2025 då detta projekt beviljades

Asplan Viak AS • Bengt Dahlgren Brand & Risk • Brand och Bygg Sverige AB
Brandkonsulten AB • Brandkåren Attunda • Brandskydds föreningen
Brandskydds föreningen Dalarna • Brandskydds föreningen Gävleborg
Brandskydds föreningen Södermanland • Brandskydds föreningen Värmland
Brandskydds föreningen Väst • Brandskydds föreningen Västernorrland
Brandskydds laget • Brandutredarna • Bricon AB • Cold Cut Systems
Deap Fire Safety Design • Dina Försäkringar • Eld & Vatten • Fabege AB
Finlands Svenska Brand & Räddnings förbund, FSBR • Fire Safety Design AB
FireTech Engineering Folksam • FSS Solutions AS • Föreningen för brandteknisk ingenjörsvetenskap, BIV
Försäkrings AB Göta Lejon • GellCon • GKN Aerospace Sweden AB • Hovedorganisationen KA
Höglandets räddningstjänst förbund • If Skadeförsäkring • Jämtlands Räddningstjänst förbund
Kiruna Räddningstjänst • Kommunassurans Försäkrings AB • Kristianstads Räddningstjänst
Kyrkans Försäkring • Lantmännen • Mariöff Skandinavien AB • MAUS Sweden AB
MSB, myndigheten för samhällsskydd och beredskap • NBSG, Nationella Brandsäkerhetsgruppen
Nerikes Brandkår • Q-Fog i Nora AB • Ramboll Sweden AB • RED Fire Engineers Sweden AB
Region Stockholm, Trafikförvaltningen • Region Uppsala • RISE, Research Institutes of Sweden
Räddningstjänsten Boden • Räddningstjänsten Dala Mitt • Räddningstjänsten Fyrbodal
Räddningstjänsten Gotland • Räddningstjänsten Halmstad • Räddningstjänsten Hässleholm
Räddningstjänsten Kalix • Räddningstjänsten Karlstadregionen • Räddningstjänsten Ljungby
Räddningstjänsten Luleå • Räddningstjänsten Mälardalen • Räddningstjänsten Skaraborg
Räddningstjänsten Skellefteå • Räddningstjänsten Skinnskatteberg • Räddningstjänsten Storgöteborg
Räddningstjänsten Strömstad • Räddningstjänsten Syd • Räddningstjänsten Väst
Räddningstjänsten Östra Götaland • St Eriks Försäkring • SIMBRA Rädgivning AS
Stockholms Stads Brandförsäkringskontor • Storstockholms Brandförsvär
Svenska Institutet för standarder, SIS • Svensk Brand- och säkerhetscertifiering AB, SBSC • Swedisol
Säkerhetsbranschen • Södertörns brandförsvärs förbund • Södra Älvsborgs Räddningstjänst förbund
Trygg Hansa • Trä- och möbelföretagen TMF • Umeåregionens brandförsvär • Uppsala Brandförsvär
Västra Sörmlands Räddningstjänst

Insamlingsstiftelsen Brandforsk verkar för ett brandsäkert hållbart samhälle byggt på kunskap. Det gör vi genom att initiera och finansiera kunskapsutveckling inom området brandsäkerhet, och vi arbetar för att sprida den kunskapen så att den ska göra nytta.

Vi finansierar detta med insamlade medel från våra stödorganisationer som på så sätt bidrar till vår vision om **Ett brandsäkert och hållbart samhälle byggt på kunskap.**

Brandforsk

info@brandforsk.se, www.brandforsk.se



Projektgrupp

BRAND
& BYGG



Södra Älvsborgs
Räddningstjänstförbund



Finansierad av Brandforsk

Brandforsks verksamhet möjliggörs av stöd från olika organisationer i samhället. Läs mer om våra stödorganisationer på www.brandforsk.se



BRAND
FORSK