

Rapport 2026:09

Avfall Sveriges Utvecklingssatsning
ISSN 1103-4092

BÄTTRE FELSORTERINGSSTATISTIK PÅ ÅVC MED HJÄLP AV AI-PLOCKANALYS



AVFALL SVERIGE

Författare

Linnea Lindkvist, Moheb Nayeri, Faruk Geles, alla på Chalmers Industriteknik

Ett samfinansierat projekt mellan:



Avfall Sveriges utvecklingssatsning

Avfall Sverige bedriver utvecklingsverksamhet inom hela avfallsområdet. Detta sker genom utvecklingssatsningen. Syftet med Avfall Sveriges utvecklingssatsning är att genom samordnade insatser främja medlemmarnas verksamhetsutveckling för en miljösäker och långsiktigt hållbar avfallshantering. Utvecklingssatsningen finansieras genom att Avfall Sveriges kommunmedlemmar betalar en särskild utvecklingsavgift.

Förord

Kommunerna har alltid behov av att följa upp hur avfall sorteras på återvinningscentralerna. Samtidigt är traditionella plockanalyser resurskrävande och genomförs ofta så sällan att de endast ger en ögonblicksbild av situationen.

Mot denna bakgrund har projektet CertAI:n undersökt om ny teknik i form av kameror och AI-baserad bildanalys kan användas för att komplettera dagens metoder för uppföljning. Ambitionen har inte varit att ersätta personalens kunskap eller etablerade arbetssätt, utan att undersöka möjligheterna att skapa mer kontinuerlig statistik om avfallsflöden och felsortering på återvinningscentraler.

Resultaten visar att tekniken har potential att ge nya insikter om hur avfall sorteras och att bidra med ett mer omfattande kunskapsunderlag än vad som vanligtvis är möjligt genom enstaka mätningar. Samtidigt visar projektet att det finns frågor kvar att lösa innan tekniken kan användas i större skala, bland annat kopplade till metodik, tillförlitlighet och hur resultaten ska kunna omsättas till den statistik som efterfrågas i dagens uppföljningssystem.

Projektet har utförts av Linnea Lindkvist, Moheb Nayeri, Faruk Geles, alla på Chalmers Industriteknik.

Projektet har finansierats av Vinnova, Avfall Sverige och medfinansierande kommunala projektparter. De som har deltagit i projektet är Chalmers Industriteknik och kommunerna Göteborg, Alingsås och Kungsbacka.

Malmö i augusti 2026

Cecilia Holmblad
Ordförande Avfall Sveriges
Utvecklingskommitté

Tony Clark
Vd, Avfall Sverige

Författarnas förord

Projektet CertAI:n har syftat till att utveckla och demonstrera AI-baserade datorseendemodeller som kan identifiera och klassificera det avfall som lämnas av besökare i lastbärare för olika fraktioner på återvinningscentraler. Huvudsyftet med sådan lösning är möjligheterna att använda dessa modeller som ett digitalt alternativ och komplement till dagens manuella plockanalyser, där statistik och insikter från systemet kan kommuniceras till kommunernas personal och besökare på ÅVC:er.

Det finns många farhågor inför vad AI-utvecklingen kan innebära för framtiden, och det finns legitima frågor att ställa kring teknikens samhälleliga konsekvenser. Det finns dock områden där AI-utvecklingen erbjuder möjligheter som är svåra att uppnå på annat sätt, och avfallshantering är ett sådant område. Behovet av bättre data, mer kontinuerlig uppföljning och mer träffsäkra insatser för att höja sorteringsgraderna är stort. Här kan AI-baserade metoder fylla en reell funktion, inte som ett substitut för mänskligt omdöme, utan i ett första led som ett verktyg för att ge personal och beslutsfattare ett bättre faktaunderlag.

AI och AI-baserat seende är samtidigt ett fält under snabb utveckling. Detta märktes tydligt under projektets gång. Metoder och modeller som inte var tillgängliga eller praktiskt användbara när projektet startade hade vid projektets mitt mognat till en punkt där de erbjöd möjligheter som översteg vad de ursprungligen planerade metoderna kunde ge. Projektet fick därför anpassa sin tekniska inriktning under projektets gång. Denna flexibilitet var nödvändig och resulterade i ett bättre slutresultat. Dock ställer det också krav på att framtida projekt inom detta fält planeras med utrymme för metodomvärdering och teknisk anpassning längs vägen.

Projektet har letts av Stiftelsen Chalmers Industriteknik och utförts mellan juni 2024 och juni 2026. Projektet har finansierats av Vinnova, Avfall Sverige och medfinansierande kommunala projektparter. De som har deltagit i projektet är Chalmers Industriteknik och kommunerna Göteborg, Alingsås och Kungsbacka.

Vi i projektgruppen vill tacka alla som har bidragit till projektet för stort engagemang, kreativa idéer och för att ni så generöst har delat med er av all kunskap. Vår förhoppning är att projektets resultat ska bidra till att fler kommuner på sikt kan tillgodogöra sig fördelarna med en kontinuerlig och datadriven uppföljning av avfallssorteringen. Det kan i förlängningen leda till ökade sorteringsgrader och en mer hållbar resursanvändning i linje med de nationella och kommunala avfallsplanernas mål.

Summary

The main objective of the CertAI_n project has been to develop and demonstrate AI-based computer vision models capable of identifying and classifying waste objects deposited by visitors at Swedish household waste recycling centers. The project has been carried out between June 2024 and June 2026, with Stiftelsen Chalmers Industriteknik as the technical lead, in collaboration with the City of Gothenburg, Kungsbacka municipality and Alingsås municipality, and with financing from Vinnova and Avfall Sverige.

Motion-detecting cameras were installed at eleven measurement points across three household waste recycling centers. All video data were stored locally on encrypted hard drives and transferred to secure servers at Chalmers Industriteknik. A two-stage GDPR compliance pipeline was implemented: an AI-model first masks areas outside the waste container to remove background and any bystanders, after which a second AI-model systematically screens all retained frames to ensure that no images of identifiable persons are stored or used in the project.

The technical methodology for identifying and classifying waste objects was developed in several stages throughout the project, partly because of the rapid advances in AI and computer vision where new and more powerful models became available during the project period. The final solution combines several complementary AI methods to achieve the best possible classification results per fraction.

Classification accuracy varies by fraction: Plastic packaging 99%, Corrugated cardboard 98%, Wood 99%, Concrete 94%, Hard plastic 92%, Insulation 83%, and Energy recovery 76%. The energy recovery fraction is the most heterogeneous and consequently the most challenging to classify reliably. A physical waste composition analysis (plockanalys) was conducted in parallel with the AI system, confirming reasonable agreement between the results. However, the comparison also highlighted a fundamental methodological difference: the AI system produces a numerical object count, while conventional waste composition analysis is

based on weight distribution, a gap that represents an important area for future development, as reporting to authorities such as Naturvårdsverket is done in weight percent. The developed system is therefore best understood as a complement to, rather than a replacement for, manual waste composition analyses. The project has established a proof of concept and identified, through workshops with project partners, the steps required to advance from the current prototype towards broader implementation at Swedish household waste recycling centers.

Project managers and authors: Linnea Lindkvist, Moheb Nayeri, Faruk Geles, all at Chalmers Industriteknik

Project partners: City of Gothenburg, Allingsås municipality, Kungsbacka municipality

Sammanfattning

Huvudmålet med CertAIIn-projektet har varit att utveckla och demonstrera AI-baserade datorseendemodeller med förmåga att identifiera och klassificera avfallsobjekt som lämnas av besökare vid svenska återvinningscentraler (ÅVC:er). Projektet har genomförts mellan juni 2024 och juni 2026, med Stiftelsen Chalmers Industriteknik som tekniskt ansvarig, i samarbete med Göteborgs Stad, Kungsbacka kommun och Alingsås kommun, samt med finansiering från Vinnova och Avfall Sverige.

Rörelsedetekterande kameror installerades på elva mätpunkter fördelade över tre ÅVC:er. Allt videomaterial lagrades lokalt på krypterade hårddiskar och överfördes till Chalmers Industritekniks interna servrar. Projektet använde en pipeline i två steg för efterlevnad av GDPR: i ett första steg maskerar en AI-modell bort områden utanför avfallsbehållaren, för att ta bort bakgrund och eventuella förbipasserande, varefter en andra AI-modell systematiskt granskar alla kvarvarande bildrutor för att säkerställa att inga bilder på identifierbara personer sparas eller används i projektet.

Den tekniska metodiken för att identifiera och klassificera avfallsobjekt utvecklades i flera steg under projektets gång, delvis som ett resultat av den snabba utvecklingen inom AI-området och för datorseende, där nya och kraftfullare modeller blev tillgängliga under projektiden. Den slutliga lösningen kombinerar flera kompletterande AI-strategier för att uppnå bättre klassificeringsresultat per fraktion.

Klassificeringsnoggrannheten varierade mellan fraktioner: Plastförpackningar 99 %, Wellpapp 98 %, Trä 99 %, Betong 94 %, Hårdplast 92 %, Isolering 83 %, och Energiåtervinning 76 %. Energiåtervinningsfraktionen är den mest heterogena och därmed den svåraste att klassificera på ett tillförlitligt sätt. En manuell plockanalys genomfördes parallellt med AI-systemet och bekräftade en rimlig överensstämmelse mellan resultaten. Jämförelsen belyste dock en grundläggande

metodskillnad: AI-modellerna producerar en numerisk objekträkning, medan traditionell plockanalys baseras på viktfördelning, en skillnad som utgör ett viktigt område för fortsatt utveckling, då rapportering till myndigheter som Naturvårdsverket i dagsläget sker i viktprocent.

Det utvecklade metodiken bör därför i första hand förstås som ett komplement till, snarare än en ersättning för, manuella plockanalyser. Projektet har etablerat en konceptvalidering och, genom workshops med projektparterna, identifierat de steg som krävs för att gå från nuvarande prototyp mot en bredare implementering vid svenska ÅVC:er.

Projektutförare och författare: Linnea Lindkvist, Moheb Nayeri, Faruk Geles, alla på Chalmers Industriteknik

Projektpartners: Göteborgs Stad, Alingsås kommun, Kungsbacka kommun

Förkortnings- och ordlista

”Optical flow”-baserad metod: En metod som analyserar hur pixlar rör sig mellan bildrutor i en video för att detektera rörelse — i det här projektet använd för att identifiera när ett föremål kastas i containern.

Aktiv inlärning (active learning): Träningsstrategi där AI-modellen själv pekar ut de bilder den är osäker på, så att mänskliga granskare kan prioritera att märka just dessa.

Annotera/annotering: Märka/märkning av bilddata, där objekt i en bild märks (antingen med bounding box- eller segmenteringskoordinater) utifrån den kategori de tillhör.

Applikation: Datorprogram eller mjukvara, i det här projektet ett webbverktyg för att analysera och visualisera avfallsstatistik.

Bounding box: En rektangel som ritas runt ett objekt i en bild för att markera var objektet finns.

Cosinuslikhet: Ett matematiskt mått (0–1) på hur lika två representationer är. Användes i projektet för att avgöra vilket avfallsslag ett okänt objekt liknar mest bland referensobjekten.

Dashboard: En webbaserad kontrollpanel där statistik och resultat presenteras visuellt, t.ex. i form av diagram och tabeller, för att ge en snabb överblick.

Djupinlärningsmodell: En typ av AI-modell uppbyggd av många lager som bearbetar information i steg, liknande hur hjärnans nervceller är kopplade. Modellen lär sig känna igen mönster i stora mängder bilder utan att behöva uttryckliga regler.

Foundation-modell: En stor AI-modell som tränats på enorma mängder data och kan användas som utgångspunkt för många olika uppgifter, utan att behöva tränas om från grunden. Exempel är SAM och CLIP.

Hubb: Central plats för lagring av data. I projektet användes lokala krypterade hubbar för att lagra videodata vid respektive ÅVC.

Iterativ/Iteration: En process som upprepas i omgångar där varje omgång förbättrar resultatet utifrån erfarenheterna från föregående omgång.

LLM, stor språkmodell: AI-modell tränad på stora mängder text som kan förstå och generera naturligt språk. Exempel: ChatGPT. I projektet testades sådana modeller för att se om de kunde klassificera avfallsobjekt.

LMM, multimodal modell: AI-modell som kan hantera både text och bilder samtidigt — den kan alltså "se" en bild och svara på frågor om den på naturligt språk.

Mockup: En visuell prototyp eller skiss av ett gränssnitt, t.ex. hur ett webbverktyg skulle kunna se ut, utan att vara ett fullt fungerande system.

Modellarkitektur: Den principiella uppbyggnaden och strukturen hos en AI-modell — hur den är organiserad och hur information flödar genom den.

Multimodal modell: Se LMM ovan — en AI-modell som kan bearbeta och kombinera flera typer av information, t.ex. bilder och text, samtidigt.

MVP: Minimum Viable Product, minsta fungerande produkt

Open-vocabulary detection-modell: En AI-modell som kan hitta och lokalisera objekt i bilder baserat på en fri textbeskrivning, utan att vara begränsad till en fördefinierad lista av kategorier. Den kan t.ex. söka efter "wellpappkartong" i en bild utan att ha tränats specifikt på den kategorin.

Pipeline: Tekniskt arbetsflöde, en serie automatiserade steg som utförs i ordning, där resultatet från ett steg skickas vidare som indata till nästa.

Prompt/prompta/promptning: Att ge en AI-modell en textbeskrivning eller instruktion för att styra vad den ska göra eller leta efter. Att "prompta SAM3 att hitta wellpapp" innebär att man ber modellen med ord söka efter just det avfallsslaget i bilden.

Referensbaserad matchning: En klassificeringsmetod där ett okänt objekt jämförs mot ett bibliotek av kända exempelbilder. Kräver inte traditionell modellträning — nya kategorier kan läggas till bara genom att lägga till nya exempelbilder.

Referensbibliotek: En samling av representativa exempelbilder per avfallskategori som används som jämförelsebas vid referensbaserad matchning.

Referensembedding: Den matematiska representation (en lista av tal) som beskriver en referensbild. Denna representation används sedan för att jämföra okända objekt mot kända kategorier.

Segmentering/segmenterad: Processen att dela upp en bild i regioner och peka ut exakt vilka pixlar som tillhör ett visst objekt — mer precist än en bounding box eftersom hela objektets kontur markeras.

Särdragsrepresentationer (embeddings): En komprimerad matematisk beskrivning av en bilds innehåll som en AI-modell skapar. Liknande objekt får liknande representationer, vilket gör det möjligt att jämföra och klassificera dem.

YOLO: Förkortning för "You Only Look Once" — en familj av snabba AI-modeller för objekt-detektering i bilder och video. Används i projektet för att maskera containrar (segmentering) och för att screena bort bilder med personer (detektion).

ÅVC: Återvinningscentral

Innehållsförteckning

1. Inledning och bakgrund	1
2. Genomförande	3
3. Resultat och diskussion.....	7
3.1 Datainsamling och metodutveckling för annotering av data	8
3.2 Utveckling av kommunikationsgränssnitt	13
3.3 Tester och verifiering av projektresultat	14
3.4 Projektledning samt nyttiggörande och spridning av projektresultat	16
4. Slutsatser, nyttiggörande och nästa steg	17

1

Inledning och bakgrund

Projektet CertAln har syftat till att utveckla AI-baserade datorseendemodeller för att identifiera och klassificera avfall som lämnas av besökare i lastbärare för olika fraktioner på återvinningscentraler. Modellerna erbjuder en metod för kontinuerlig och automatiserad insamling av statistik om avfallsfördelning vid ÅVC:er, ett potentiellt kostnadseffektivt alternativ och komplement till dagens manuella plockanalyser, som är tidskrävande, kostsamma och endast ger en ögonblicksbild av sorteringsläget.

I de kommunala avfallsplanerna finns ofta mål för sortering av avfall på ÅVC:er. För flera avfallsfraktioner ligger dagens sorteringsnivåer väl under dessa mål, och uppföljningen sker i alltför liten utsträckning. På nationell nivå är det årligen endast cirka 10 % av Sveriges kommuner som låter utföra plockanalyser för en fraktion som energiåtervinning. Nyligen utförda plockanalyser vid de ÅVC:er som ingick i projektet illustrerade behovet tydligt: felsorteringsgraden i fraktionen för energiåtervinning uppgick till 64 viktprocent i Göteborg respektive 52 viktprocent i Kungsbacka, med felaktigt sorterat trä, plast och tidningar som de vanligast förekommande materialen.

Detta projekt har avsett att utveckla AI-baserade datorseendemetoder som ska möjliggöra att betydligt mer detaljerad statistik genereras löpande. Avsikten är att dessa metoder ska kunna ge dataunderlag som möjliggör bättre förståelse av var problem uppstår vid avfallssortering och möjliggöra bättre utformning av insatser men också uppföljning av dessa insatser för att minska felsorteringen. Parallellt kan dessa metoder vidareutvecklas för att ge indikation i nära realtid om felsortering förekommer.

2

Genomförande

Huvudmålet med projektet har varit att utveckla och träna AI-baserade modeller som kan känna igen och föra statistik om det avfall som lämnas vid de deltagande återvinningscentralerna. Projektet har genomförts i nära samarbete mellan Chalmers Industriteknik (CIT) och de deltagande kommunerna Göteborg, Alingsås och Kungsbacka. CIT har ansvarat för den tekniska utvecklingen, inklusive installation, datainsamling och utveckling av AI-modeller, medan kommunerna har spelat en central roll i datainsamling, kravställning och verifiering av resultat. Samarbetet har koordinerats genom regelbundna uppdateringsmöten där projektparterna gemensamt följt upp projektets utveckling, löst praktiska utmaningar och fattat beslut om prioriteringar och teknisk inriktning.

Arbetet har varit indelat i sex arbetspaket:

AP1 Plats- och nulägesanalys samt installation av kameror och hårdvara vid ÅVC:er

AP2 Datainsamling och metodutveckling för annotering av data

AP3 Utveckling och träning av AI-baserade bildigenkänningsystem

AP4 Utveckling av kommunikationsgränssnitt

AP5 Tester och verifiering av projektresultat

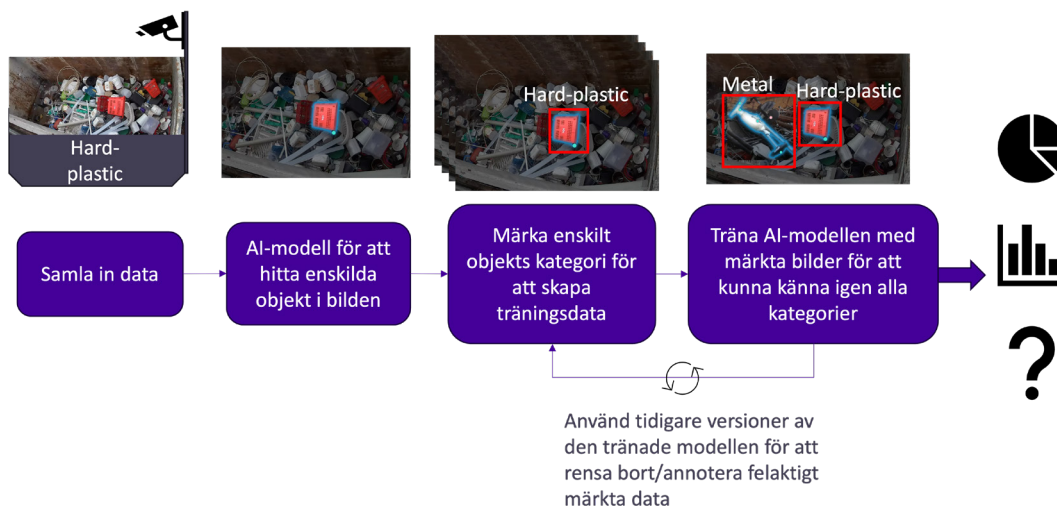
AP6 Projektledning samt nyttiggörande och spridning av projektresultat

En tidig prioritet i projektet har varit att komma i gång med datainsamling så snart som möjligt, för att möjliggöra att stor mängd data samlas in. Parallellt med detta lades ett betydande arbete på att säkerställa att datainsamlingen skedde i enlighet med GDPR. Detta arbete innefattade framtagande av interna rutiner och dokumentation för hantering av bilddata, med tydliga riktlinjer för hur data får lagras, överföras och användas inom projektet. Rutiner och metoder utvecklades så att det videomaterial som samlades in inte skulle innehålla bilder på personer innan datan användes i projektets syften, något som genomförts med stöd av en AI-baserad filtreringspipeline i två steg som beskrivs närmare i avsnitt 3.2. Respektive kommun har också ansvarat för att skylta vid de berörda ÅVC:erna om att ett innovationsprojekt pågår, i enlighet med krav på transparens gentemot besökare.

Ett genomgående inslag under projektet har varit att AI-området har utvecklats i snabb takt under den tid projektet pågått. Framväxten av starkare ”foundation-modeller” och ”multimodala modeller” har under projektets gång öppnat tekniska möjligheter som inte var tillgängliga eller praktiskt användbara vid projektstart. Detta har inneburit att det tekniska tillvägagångssättet behövt omprövas och anpassas längs vägen, där den tekniska delen av projektet vid flera tillfällen omvärderat och förändrat den planerade metodiken för att tillvarata de möjligheter som nya modeller erbjöd. Sammantaget har detta lett till ett starkare slutresultat än vad som hade varit möjligt med det ursprungligen planerade tillvägagångssättet.

Figur 1 visar den ursprungliga tanken bakom hur data skulle samlas in och annoteras i projektet. Bilden visar också att vi ursprungligen tänkte att märkningen skulle vara på ”bounding box”-nivå, som innebär att man med koordinaterna för en rektangel märker ut området runt objektet, men att detta ändrades från början av projektet till att ha en mer noggrann märkning genom segmentering av objektet, där gränsen till objektet ges som pixelkoordinater av objektet. Denna förändring gjordes delvis genom användning av ”foundation-modellerna” Segment Anything Model från Meta. Mer om resultaten från den tekniska utvecklingsresan och de metodval som slutligen gjordes återfinns mer ingående i avsnitt 3.2 och 3.3.

Figur 1: Schematisk bild för hur upplägget i projektet var tänkt för att samla data och träna AI-modeller att hitta (antingen med ”bounding box” som är den röda rektangeln runt objekten, eller genom ”segmentering”, vilket är de exakta gränserna på objektet, visas ej i figuren) och klassificera enskilda objekt.



Figur 2: Bilden visar installation av en kamera vid Alelyckans återvinningscentral i Göteborg.



Baserat på de resultat och erfarenheter som genererats under projektet har workshops genomförts med projektparterna för att gemensamt diskutera och identifiera vad som krävs för att ta systemet vidare mot en faktisk implementering på ÅVC:er. Dessa diskussioner har gett en tydligare bild av var systemet befinner sig i dag, vad som fungerar väl och vad som återstår att lösa innan en MVP kan anses vara uppnådd. Parallellt har kommunernas behov av ett kommunikationsgränssnitt för visualisering och analys av den genererade avfallsstatistiken utretts och en enklare prototyp för detta har tagits fram.

3

Resultat och diskussion

3.1 DATAINSAMLING OCH METODUTVECKLING FÖR ANNOTERING AV DATA

Datainsamlingen har skett genom rörelsedetekterande övervakningskameror med solpaneler, som spelar in korta videosekvenser (cirka 5–30 sekunder) enbart när en händelse registreras, det vill säga när avfall lämnas av en besökare. Till detta syfte köptes EufyCam S330-kameror. Dessa kopplades upp trådlöst mot lokala hubbar (Eufy HomeBase S380) vid respektive återvinningscentral där data lagrades lokalt på krypterade hårddiskar och överfördes periodvis fysiskt till Chalmers Industritekniks interna servrar. Totalt har mer än 20 000 videosekvenser samlats in från de olika fraktionerna sedan driftstarten i oktober 2024. De elva fraktioner som filmades framgår av Tabell 1. Data för avfall av elektrisk och elektronisk utrustning kompletterades från ett parallellt projekt (det Vinnovafinansierade projektet AutoWEEEdakt II – Automatisk AI baserat system för detektion av konsumentelektronikavfall, diarienummer 2023–02974).

Tabell 1: Översikt över de fraktioner som data samlades in från.


Göteborg	Kungsbacka	Alingsås (omlastningscentral)
Energiåtervinning	Energiåtervinning	Pappersförpackningar
Hårdplast	Wellpapp	Plastförpackningar
Trä	Isolering	
Impregnerat trä	Metall	
Sten, betong, tegel		
Ej återvinningsbart		

Vilka typer av avfall som får slängas i en viss fraktion varierar mellan olika återvinningscentraler. Reglerna bestäms av kommunens riktlinjer och avfallsplan. Skillnaderna är särskilt stora för hur kommuner gör med fraktionerna ”Energiåtervinning” och ”Ej återvinningsbart”. Till exempel tillåter vissa kommuner att fulla sopsäckar slängs i energiåtervinningen, medan andra kräver att säckarna töms först. Därför måste AI-systemet kunna anpassas till de lokala reglerna på varje ÅVC. Det var ett viktigt krav i projektet. Lösningen utvecklades därför för att vara flexibel och kunna finjusteras utifrån olika lokala behov och regler.

Som ett led i att säkerställa att insamlad data uppfyller kraven i GDPR implementerades en pipeline i två steg för filtrering av videos där personer kunde ses i videomaterialet. I ett första steg används en tränad YOLO-segmenteringsmodell för att maskera de delar av bilderna som ligger utanför avfallsbehållaren, exempelvis angränsande containrar, bakgrundsmiljö och besökare. Därigenom reduceras risken för att identifierbara individer förekommer i bilddata. I ett andra steg tillämpas ytterligare en YOLO-detektionsmodell som


systematiskt granskar alla bildrutor i de inspelade videosekvenserna för att hitta förekomst av personer. Om en person detekteras i någon av bilderna i en inspelat video så raderades videon och användes inte i projektet. Sammantaget innebär denna pipeline att det bildmaterial som faktiskt användes för träning och utvärdering av avfallsklassificeringsmodellerna inte innehöll bilder på identifierbara individer.

Figur 3: Bilden visar hur en AI-modell tränades upp för att isolera det relevanta området.




Metodutvecklingen för annotering av data har inneburit att en pipeline byggdes upp för att i möjligaste mån automatisera annoteringen av insamlade bildrutor. Segment Anything Model (SAM2 och SAM3) nyttjades för att föreslå och segmentera ut enskilda avfallsobjekt i bilderna. Ett webbaserat gränssnitt vidareutvecklades från ett tidigare projekt för att förbättra de förslagna annoteringarna i den mån som det behövdes (se Figur 3). En annan metod som utnyttjades för att isolera det senaste placerade objektet i en container var att använda så kallade "optical flow"-baserade metoder som är tillämpade i OpenCV (bibliotek med olika datorseendemetoder i programmeringsspråket Python) (se Figur 4). I projektet har ett potentiellt användningsområde för de utvecklade metoderna varit att i realtid klassificera och upptäcka om senaste objektet som kastas är av rätt klass eller inte. De "optical flow"-baserade metoder som har utvecklats i projektet kan användas för att i realtid markera det senast kastade föremålet och därefter avgöra om det har sorterats rätt, se Figur 5.

Figur 4: Bilden visar det webbaserade gränssnittet som utvecklades för att förbättra de annoteringar som förtränade segmenteringsmodeller (som SAM2 och SAM3) föreslog.



Parallellt med den automatiserade annoteringen skapades en iterativ process för att förbättra datakvaliteten, där tidigare versioner av tränade AI-modeller nyttjades för att flagga tveksamma eller potentiellt felaktiga annoteringar för manuell granskning – i linje med principerna för aktiv inlärning (active learning). Syftet var alltså att successivt förbättra träningsdatats kvalitet genom att utnyttja AI-modellen själv som ett verktyg för datarensning, i linje med principerna för aktiv inlärning (se Figur 1). För att förenkla detta arbete och dessutom ha möjlighet att använda kunnig personal från deltagande ÅVC:er så utvecklades det en webbaserad applikation för detta ändamål (se Figur 6).

Figur 5: "Optical flow"-metod användes för att identifiera och isolera det senaste objektet som lades i en container.




Det initiala tillvägagångssättet i projektet, vars schematiska representation kan ses i Figur 1, var att samla in data och träna en klassificeringsmodell där objekt märktes med den fraktion i vilken de lämnats, för att på så sätt skapa ett träningsdataset där klassetiketten härleds direkt från containertillhörigheten. Tanken var att en segmenteringsmodell (YOLOv11) skulle tränas och finjusteras på dessa data för att lära sig känna igen rätt klassificering.

Resultatet från detta arbete visade dock att metoden ställde höga krav på datamängd och att trots de utvecklade annoteringsverktygen så krävdes en hel del omannotering. Detta motiverade en omprövning av det tekniska tillvägagångssättet, och arbetet övergick till en metod baserad på referensbaserad matchning, vilket visade sig vara både mer flexibelt och mer robust givet de förutsättningar som rådde. Mängden referensdata kunde dock berikas och förbättras med de verktyg som utvecklades för annotering av data i linje med första tillvägagångssättet i projektet (se Figur 6).

Dessa segmenterade objekt klassificeras sedan med hjälp av referensbaserad matchning, där en djupinlärningsmodell används för att extrahera visuella särdragsrepresentationer (embeddings). Ett flertal modellarkitekturer utvärderades för detta ändamål, däribland DINOv2-ViT-L/16, DINOv3-ViT-H/14+, DINOv3-ConvNeXt-Large (förtränad på LVD-142M), DINOv3-ViT-L/16 (förtränad på LVD-142M) samt OpenAI:s ViT-L/14 (CLIP). Den klass vars referensembedding uppvisar högst cosinuslikhet med det aktuella objektets embedding tilldelas som etikett.

Figur 6: Bilden visar gränssnittet för omannoteringsverktyget, som utvecklades för att omarkera bilder där AI-modellerna visade låg säkerhet.



Under projektets gång utvärderades även en bredare uppsättning av de AI-modeller som successivt blev tillgängliga. Stora språk- och multimodala modeller (LLM/ LMM), såsom ChatGPT, Mistral och Gemini, testades för att bedöma hur väl de kunde klassificera enskilda avfallsobjekt. Dessa modeller förbättrades påtagligt under projektiden i sin förmåga att ge korrekta klassbeteckningar för isolerade objekt, men visade sig ha tydliga begränsningar när det gällde att hantera en större bild och ange rumsliga koordinater för objektens position, vilket är en grundläggande förutsättning i detta sammanhang. Parallellt utvärderades så kallade open-vocabulary detection-modeller, däribland OWL-ViT och Grounding DINO, som är konstruerade för att lokalisera och i vissa fall segmentera objekt i bilder utifrån textbeskrivningar med öppna beskrivningar. Dessa hade ganska hög felprocent, men i de fall de identifierade ett objekt så var de bra på att ge koordinaterna för bilden.

Situationen förändrades i samband med lanseringen av SAM3 i slutet av 2025 (sammanfallande med att Vinnova-delen av projektet avslutades), som introducerade en modell med betydligt starkare kombinerad förmåga för segmentering och klassificering via promptning med lämpliga nyckelord. SAM3 fungerar väl för de flesta avfallsklasser, men för fraktionerna Energiåtervinning och Ej återvinningsbart, som är mycket heterogena fraktioner som är svåra att beskriva utifrån nyckelord och inte har tydliga visuella särdrag, presterar modellen betydligt sämre. För dessa fraktioner har referensbaserad matchning visat sig vara ett mer robust tillvägagångssätt. Vi har i projektets slutskede integrerat SAM3 genom att utveckla en hybridmetod där bilder från dessa fraktioner behandlas med en kombination av SAM3 och referensbaserad matchning för att utnyttja styrkorna hos respektive metod.

3.2 UTVECKLING AV KOMMUNIKATIONSGRÄNSSNITT

Under projektet genomfördes workshops med de deltagande kommunerna för att identifiera och kravställa behovet av ett kommunikationsgränssnitt för avfallsstatistiken. Kommunernas miljöingenjörer och driftpersonal betonade vikten av ett lättanvänt och visuellt tydligt gränssnitt som möjliggör löpande uppföljning av sorteringsresultat per fraktion och per ÅVC, samt möjlighet att se trender över tid.

Figur 7: Bilden visar ett gränssnitt som skapades för statistiksammanställning, som visar resultat från AI-modellens analys av valda bilder eller videos från ÅVC-avfall.




Baserat på kommunernas kravställning togs en prototyp fram för ett webbaserat dashboard som visar den procentuella fördelningen av identifierade avfallsobjekt per kamera och fraktion. Gränssnittet inkluderar visualiseringar i form av stapeldiagram och trendvyer, samt möjlighet att filtrera och jämföra data mellan olika kameror och tidsperioder. Prototypen har presenterats för och fått återkoppling från projektparterna, och resulterade i en tydligare bild av vad som krävs för en produktionsfärdig implementering.

3.3 TESTER OCH VERIFIERING AV PROJEKTRESULTAT

Modellernas klassificeringsförmåga har utvärderats per fraktion och resultaten visar på en tydlig variation beroende på fraktionens visuella egenskaper. För fraktioner med tydliga och homogena visuella särdrag är noggrannheten hög: Plastförpackningar 99 %, Wellpapp 98 %, Trä 99 %, Betong 94 %, Hårdplast 92 % och Isolering 83 %. För Energiåtervinning uppmättes en noggrannhet på 76 %, som är lägre än för övriga fraktioner. Detta förväntas då energiåtervinning är den mest heterogena av de undersökta fraktionerna.

Figur 8: Bilden visar den webapplikation som utvecklades för att analysera och ta fram statistik för en vald bild eller video. Bilden som visas är tagen från en uppställning som gjordes på ett urval av objekt som hittades i energiåtervinningsfraktionen vid Alelyckan ÅVC. Som synes i bild på märkningar och färgkodningar, så lyckades AI-modellen att i hög utsträckning identifiera rätt klass.



En manuell plockanalys genomfördes vid en av energiåtervinningscontainrarna på Alelyckan ÅVC i Göteborg, med deltagande från samtliga projektparter. Resultaten från AI-modellen och den manuella plockanalysen visade en rimlig överensstämmelse i den övergripande fördelningen av avfallstyper, men jämförelsen belyste också en grundläggande metodskillnad: AI-modellen räknar enskilda objekt och ger en numerisk fördelning, medan traditionell plockanalys baseras på viktfordelning, där olika avfallsfraktioner sorteras i högar som därefter vägs.

Det är också i viktprocent som sorteringsresultat rapporteras, exempelvis till Naturvårdsverket och mot mål i kommunala avfallsplaner. Att överbrygga denna skillnad, och utveckla metoder för att omvandla numerisk objektfördelning till uppskattad viktfördelning, är ett viktigt område för framtida utveckling.

Den manuella plockanalysen var lärorik på flera sätt och belyste också svårigheten med att dra slutsatser baserade på statistik från sällan genomförda plockanalyser. Under genomförandet observerades att en stor mängd, uppemot hundra, stora svarta säckar fyllda med invasiva växtarter hade kastats i containern, troligen av ett företag eller en bostadsförening som genomfört en större röjningsinsats den dagen. Dessa säckar utgjorde en betydande del av containerns innehåll men kan inte antas vara representativa för den genomsnittligt årliga fördelningen i energiåtervinningsfraktionen. Vidare noterades också problemet med att fyllda säckar i energiåtervinningsfraktionen ofta visade sig innehålla objekt som borde ha sorterats i andra fraktioner. Datorseendemodeller kan naturligtvis inte upptäcka vad som finns inuti en öppen säck, vilket är ytterligare ett skäl till att se de utvecklade metoderna i projektet som ett komplement till manuell plockanalys snarare än en fullständig ersättning. Plockanalysen visade även att det för energiåtervinningsfraktionen finns tydliga gråzoner där erfaren ÅVC-personal kan vara oenig om ett objekt har sorterats korrekt eller inte, något som sannolikt bidrar till den lägre klassificeringsnoggrannhet som AI-modellen uppvisar för denna fraktion. Dessa aspekter är viktiga att adressera i ett eventuellt följdprojekt för att höja systemets tillförlitlighet ytterligare.

3.4 PROJEKTLEDNING SAMT NYTTIGGÖRANDE OCH SPRIDNING AV PROJEKTRISULTAT

Spridning av projektrISultat har skett löpande under projektets gång genom deltagande i ett flertal konferenser och mötessammanhang, både nationellt och internationellt. Projektets tillvägagångssätt och idéer presenterades först vid Avfall Sveriges höstkonferens 2024, innan projektet hade kommit så långt i sitt genomförande. Detta tillfälle gav dock möjlighet att nå ut till en bred grupp kommunala aktörer och avfallsansvariga runt om i Sverige. Ungefär ett år senare genomfördes en presentation för Sirk Norge (tidigare Avfall Norge), vilket bidrog till att synliggöra projektets tillvägagångssätt och resultat även i ett nordiskt perspektiv. Projektet har också presenterat på en konferens anordnad av AI Sweden inom Vinnova-utlysningen "Gemensamma AI-förmågor", som projektet har fått delar av sitt anslag från. Vidare har också projektet och dess preliminära resultat presenterades för en grupp deltagare på studiebesök kopplat till ett EU-projekt (ClearCities, finansierat av Interreg Europé)¹ inom avfallsområdet under hösten 2025.

Den 3 juni 2026 genomfördes en presentation för Avfall Sveriges användarråd för Avfall Web, Avfall Sveriges webbaserade statistiksystem för hantering av avfallsstatistik. Den 11 juni 2026 presenterades projektet i Stavanger på ett arrangemang organiserat av de norska organisationerna IVAR (Interkommunalt Vann, Avløp og Renovasjon, ett interkommunalt avfallsbolag i Norge med säte i Stavanger) och Sirk Norge, vilket ytterligare breddade den internationella spridningen av projektets erfarenheter och resultat. Sammantaget har dessa aktiviteter bidragit till att skapa kännedom om projektet, etablera kontakter för eventuella fortsättningsprojekt och synliggöra potentialen i att använda AI-baserade datorseendemetoder för digital plockanalys vid ÅVC:er.

¹ <https://www.interreg-europe.eu/clear-cities#project-summary>

4

**Slutsatser,
nyttiggörande och
nästa steg**

Projektet har resulterat i en konceptvalidering som visar att AI-baserade datorseendemodeller kan användas för att generera löpande och automatiserad statistik över avfallsfördelningen vid ÅVC:er, en förmåga som saknar direkt motsvarighet på marknaden i dag. Rörelsedetekterande kameror har installerats och driftsatts vid tre ÅVC:er i Göteborg, Kungsbacka och Alingsås, data har samlats in sedan oktober 2024 och cirka 120 000 avfallsobjekt har annoterats. Modellerna uppvisar god klassificeringsförmåga för de flesta fraktioner, med noggrannheter från 83 % (isolering) upp till 99 % (plastförpackningar och trä). För energiåtervinningsfraktionen, som är den mest heterogena, uppmättes 76 % i noggrannhet, ett resultat som är förväntat, givet att gränsdragningen för denna fraktion delvis är otydlig även för erfaren ÅVC-personal.

En lärdom från projektet är att AI-modellerna preliminärt i första hand bör ses som ett komplement till manuella plockanalyser, snarare än en ersättning. Den manuella plockanalysen som genomfördes under projektet belyste tydligt varför: AI-systemet räknar enskilda objekt och producerar en numerisk fördelning (antal), medan rapportering till myndigheter och mot mål i kommunala avfallsplaner sker i viktprocent. Att utveckla metoder för att omvandla numerisk objektfordelning till uppskattad viktfördelning är ett viktigt nästa steg. Vidare så kan datorseendemodeller inte se det som har felsorterats i säckar och förpackningar, något som en manuell plockanalys kan upptäcka. Plockanalysen visade däremot också på svagheten av manuella plockanalyser, där (förutom att vara dyra och därför utförs mycket sällan) dessa punktinsatser (som den dag då ett stort antal säckar med invasiva växtarter dominerade en containers innehåll) kan ge mycket missvisande statistik. Just där erbjuder det AI-baserade systemets kontinuerliga insamling en tydlig fördel: statistiken baseras på en lång tids observation, och sårbarheten mot enstaka avvikande händelser minskar väsentligt.

För att ta systemet från konceptvalidering till en lösning som är redo för bredare implementering krävs fler piloter vid ÅVC:er med skilda lokala förutsättningar avseende fraktionsuppsättning, kameraplacering och lokala sorteringsregler. Systemet behöver också kunna konfigureras av slutanvändaren utan djupgående teknisk kompetens, så att kommuner själva kan anpassa vilka fraktioner som bevakas och hur statistiken presenteras. Det finns också ett fortsatt behov av att förbättra noggrannheten hos de utvecklade metoderna, både genom att förbättra datakvaliteten och genom att löpande tillvarata de generella framsteg som sker inom området AI-baserat datorseende.

Det breda intresset för projektet, från kommuner, norska avfallsorganisationer och nationella aktörer som AI Sweden och Avfall Sverige, pekar på ett tydligt behov och att lösningen upplevs som relevant. Projektet har därmed lagt en viktig grund, och både de tekniska resultaten och de erfarenheter som genererats utgör en god bas för ett fortsättningsprojekt, med målet att ta systemet till en skalbar och driftsäker lösning som kan implementeras brett på svenska ÅVC:er.

Avfall Sverige är kommunernas branschorganisation inom avfallshantering. Det är Avfall Sveriges medlemmar som ser till att avfall tas om hand och återvinns i landets alla kommuner. Vi gör det på samhällets uppdrag: miljösäkert, hållbart och långsiktigt. Vår vision är "Det finns inget avfall". Vi verkar för att förebygga att avfall uppstår, att mer återanvänds och att det avfall som uppstår återvinns och tas om hand på bästa sätt. Kommunen och deras bolag är ambassadör, katalysator och garant för denna omställning.



Avfall Sverige Utveckling 2026:09

ISSN 1103-4092

©Avfall Sverige AB

Adress Baltzarsgatan 25, 211 36 Malmö
Telefon 040-35 66 00
E-post info@avfallsverige.se
Hemsida www.avfallsverige.se