


## Industriell videoanalys för processtyrning

Erik Erlandsson, Solution manager VideONet, projektledare Virify



*Industriell videoanalys har blivit ett allt viktigare verktyg för att optimera och automatisera industriella processer. Genom att analysera aggregerad videodata från kameror och data från andra källor, kan företag få värdefulla insikter i sin verksamhet och identifiera förbättringsområden. Valet av vilket tillvägagångssätt som ska användas för videoanalys, maskininlärning (ML) eller algoritmer kan dock vara ett komplext beslut med avvägningar. I denna text utforskas för- och nackdelar med ML kontra algoritmbaserad analys i samband med industriell videoanalys, och pekar på faktorer som bör beaktas när man bestämmer vilket tillvägagångssätt som är bäst lämpat för en given applikation.*

Inom industriell videoanalys kan algoritmer och tekniker för djupinlärning båda användas för att extrahera användbara insikter och information från videodata.

Algoritmer är en uppsättning steg eller regler som följs i en specifik ordning för att lösa ett problem eller utföra en uppgift. De används vanligtvis för uppgifter som involverar strukturerad data, som att räkna objekt eller identifiera mönster i en datauppsättning. Algoritmer kan vara effektiva för uppgifter som har väldefinierade regler eller mönster, men kanske inte fungerar lika bra när de hanterar mer komplexa eller ostrukturerade data. En grundläggande faktor för algoritmer är att de är matematiska, exakta och reversibla. Detta ger fördelen att varje enskilt beslut kan analyseras genom att "räkna igenom" formlerna baklänges och härleda och justera de individuella faktorerna.

Deep learning, å andra sidan, är en typ av maskininlärning som innebär att man tränar artificiella neurala nätverk på stora mängder data. Dessa neurala nätverk kan lära sig att känna igen mönster i data på egen hand, utan att vara explicit programmerade att göra det. Deep learning är särskilt effektivt för uppgifter som involverar bearbetning och förståelse av ostrukturerad data, som bild- och videodata. De neurala nätverkslagren är inte transparenta för utvecklaren och ett individuellt beslut

kan inte spåras bakåt genom lagren. Justering av den analytiska funktionen kallas träning och med tillräckligt stora datamängder med tillräckligt stor variation i träningen kan nästan vilken funktion som helst uppnås, så småningom.


Inom ramen för industriell videoanalys kan tekniker för djupinlärning användas för att identifiera objekt, känna igen mönster och göra förutsägelser baserat på videodata. Deep learning kan till exempel användas för att upptäcka defekter på en produktionslinje, identifiera fordon i ett trafikövervakningssystem eller förutsäga utrustningsfel i en tillverkningsanläggning. Å andra sidan kan algoritmer användas för uppgifter som att mäta och räkna objekt eller identifiera specifika objekttegenskaper ur videodata.

Maskininlärning (ML) och algoritmbaserad analys skiljer sig åt i vissa viktiga aspekter gällande spårbarhet och verifierbarhet.

Spårbarhet avser förmågan att spåra data och produkters ursprung och bearbetningshistorik, verifierbarhet avser förmågan att verifiera uppgifternas riktighet och giltighet.

Generellt sett är algoritmbaserad analys mer spårbar och verifierbar än ML, eftersom algoritmer är baserade på specifika regler eller formler som kan definieras tydliga och förståeliga. Detta gör det lättare att spåra bearbetningshistoriken för data och verifiera resultatens riktighet.

Installationsmiljö är en ofta förbisedd faktor av avgörande betydelse. Rätt placering och montering av kameror kan avsevärt påverka kvaliteten på analysresultaten. Bra belysning, raka vinklar mot objekten och en stabil och vibrationsfri montering kan bidra till att videodata är tydlig, korrekt och representativ för de objekt som analyseras.



Dålig belysning, skuggor eller solljus kan orsaka distraktioner eller störningar i videodata, vilket kan

påverka analysresultatets noggrannhet och tillförlitlighet. På liknande sätt, om kamerorna inte är monterade i rätt vinkel eller avstånd från objekten, kanske videodata inte tillräckligt detaljerat representerar objekten som analyseras.

Vibrationer eller instabilitet i kameramonteringen kan också påverka kvaliteten på analysdata, eftersom de kan orsaka rörelseoskärpa eller andra förvrängningar i bilderna. En stabil och vibrationsfri montering är därför väsentlig för att säkerställa att videodata är tydlig och korrekt.

Den slutliga kvaliteten på analysresultatet beror på många faktorer, inklusive kamerornas placering och montering, såväl som kvaliteten och egenskaperna hos videodata. Genom att noggrant överväga dessa faktorer är det möjligt att uppnå bild- eller videodata av hög kvalitet som säkerställer analytiska resultat som är korrekta och tillförlitliga över tid.

## Analys med maskininläring (ML/AI/Deep learning etc.)

Det finns många olika sätt på vilka maskininläring, som integrerar algoritmer och tekniker för djupinläring, kan användas i industriella videoanalysapplikationer. Några exempel inkluderar:

- **Defektdetektering** : Maskininläring kan användas för att identifiera defekter på en produktionslinje genom att träna en modell för att känna igen mönster eller avvikelser i videodata. Detta kan bidra till att förbättra kvalitetskontrollen och minska kostnaderna för defekta produkter.
- **Förebyggande (prediktivt) underhåll** : Maskininläring används för att förutsäga när utrustning sannolikt kommer att falla genom att analysera video och data från utrustningen i drift. Detta kan hjälpa till att minska stilleståndstiden och förbättra effektiviteten i tillverkningsanläggningar.
- **Trafikövervakning** : Maskininläring kan användas för att identifiera och klassificera fordon i trafikövervakningssystem, vilket ger insikter i trafikmönster och hjälper till att förbättra transportplaneringen.
- **Säkerhet och övervakning** : Maskininläring kan fungera för identifiering av misstänkt beteende eller potentiella hot i säkerhets- och övervakningssystem, vilket hjälper till att förbättra säkerheten och säkerheten i offentliga utrymmen.
- **Jordbruk** : Maskininläring kan analysera videodata om växttillväxt för att identifiera mönster och förutsäga avkastning, vilket hjälper till att optimera resursallokeringen och förbättra jordbrukets produktivitet.

Dessa punkter är ett fåtal exempel på hur maskininläring kan användas i industriella videoanalysapplikationer. Det finns många andra potentiella användningsområden, beroende på organisationens specifika behov och mål.

Maskininläring (ML) kan användas för att mäta enskilda objekt i en videoström genom att träna en modell för att känna igen och klassificera objekt. Processen för att göra detta innefattar vanligtvis följande steg:

- **Samla in och kategorisera (tagga) träningsdata** : Först måste en datauppsättning av taggade bilder eller videoramar samlas in. Dessa data kommer att användas för att träna ML-modellen att känna igen objekten av intresse. Etiketterna bör innehålla information om föremålets egenskaper eller egenskaper som storlek, form eller färg.
- **Träning**: En maskininlärningsmodell, som ett konvolutionellt neuralt nätverk (CNN), tränas på kategoriserad träningsdata. Modellen lär sig att känna igen föremålets egenskaper och klassificera dem utifrån kategorietiketterna.
- **Identifiera objekt i videoströmmen** : När modellen har tränats kan den användas för att få data om enskilda objekt i en videoström. Modellen bearbetar videoflödet och matar ut förutsägelser för objektens egenskaper eller egenskaper, som deras storlek, form eller färg. Dessa förutsägelser kan användas för att beräkna mått eller extrahera annan relevant information om föremålen.

Det är viktigt att notera att ML-modellens noggrannhet och prestanda beror på kvaliteten och mängden träningsdata, uppgiftens komplexitet och egenskaperna hos de föremål som mäts. För att förbättra modellens prestanda kan det vara nödvändigt att finjustera modellen och samla in ytterligare träningsdata.

## Analys med algoritmer

Det finns vissa uppgifter och situationer där algoritmer är att föredra framför maskininlärningstekniker för industriell videoanalys. Några exempel inkluderar:

- **Tids- och resursbegränsningar** : Att träna och finjustera en maskininlärningsmodell är en tids- och resurskrävande process. När tid eller resurser är begränsade är det mer praktiskt att använda en algoritm som snabbt kan implementeras och köras och som kan sättas i produktion inom en kortare tidsram.
- **Uppgifter med väldefinierade regler eller mönster** : Om uppgiften involverar strukturerad data och väldefinierade regler eller mönster, kan algoritmer vara mer lämpliga än maskininläring. Till exempel kan mätning och räkning av objekt i en videoström eller identifiering av specifika funktioner i data utföras mer effektivt med en specifik algoritm snarare än en maskininlärningsmodell.
- **Förklaring** : I vissa fall är det viktigt att förstå hur en modell fattar beslut. Algoritmer är mer transparenta och lättare att förstå än maskininlärningsmodeller, vilket kan vara användbart om resultaten av analysen behöver förklaras för intressenter.
- **Datakvalitet** : Maskininlärningsmodeller kräver stora mängder högkvalitativ data för att lära sig och göra korrekta antaganden. Om data är brusiga eller ofullständiga kan en algoritm vara effektivare för att hantera dessa problem.

Att mäta enskilda objekt i en videoström med hjälp av algoritmer uppnås genom att definiera specifika regler eller steg för att identifiera och extrahera information om objekten. Processen för att göra detta beror på de specifika egenskaperna hos föremålen och de önskade måtten, men kan innebära följande steg:

- **Förbearbetning** : Videodata kan behöva förbehandlas för att förbereda den för analys. Detta kan innebära att man tillämpar bildbehandlingstekniker, som filtrering eller tröskelvärden, för att förbättra objektens synlighet eller ta bort brus från data.
- **Egenskapsextrahering** : Nästa steg är att detektera specifika funktioner eller egenskaper hos objekten från videodata. Det kan handla om att identifiera kanter eller konturer i bilderna, mäta former, storlekar eller färginformation.
- **Mätning** : När de relevanta egenskaperna hos föremålen har genererat data kan den användas för att beräkna mått och defekter eller abstrahera annan relevant information. Det kan handla om att tillämpa specifika regler eller formler, eller använda statistiska tekniker som klustring eller klassificering.

Det är viktigt att notera att effektiviteten av algoritmen beror på kvaliteten på data, komplexiteten i uppgiften och utformningen av själva algoritmen. För att förbättra mätningarnas noggrannhet kan det vara nödvändigt att förfina algoritmen eller förbearbetningsstegen, eller att samla in ytterligare data.

## USECASE 1

### Mätning av enskilda föremål, som t.ex. plankor eller stockar i ett sågverk

#### Metod

Det optimala valet mellan att använda algoritmer eller maskininlärning (ML) för att mäta objekt i en videoström, beror på flera faktorer inklusive komplexitet, kvalitet på data och önskad noggrannhet i mätningarna.

Generellt sett är algoritmer snabbare att implementera än ML-modeller eftersom de inte kräver den tidskrävande processen att samla och träna in stora datamängder. Implementationstiden beror på den specifika algoritmen och uppgiftens komplexitet. Vissa algoritmer kan vara mer komplexa och kräva mer tid att implementera och testa än andra.

Å andra sidan kan ML-modeller, särskilt modeller för djupinlärning, vara mer effektiva för att hantera komplexa eller ostrukturerade data som videodata. Men ML-modeller kräver en betydande mängd tid och resurser för att samla in och kategorisera träningsdata, samt att träna och finjustera modellen.

Sammantaget kommer det optimala alternativet för att mäta enskilda objekt i en videoström att bero på de specifika kraven och begränsningarna för uppgiften. Det kan vara nödvändigt att väga behovet av precision mot tillgänglig tid och resurser.

#### Datafångst

Den bästa videokällan för att mäta ett flöde av objekt beror på de specifika kraven och begränsningarna för uppgiften. Några faktorer att tänka på i valet av videokälla inkluderar:

- **Upplösning och synfält** : Kamerans upplösning och synfält avgör detaljnivån och omfånget för videodata. En kamera med högre upplösning kan till exempel kunna fånga mer detaljerade bilder av plankorna, medan en kamera med ett bredare synfält kanske kan fånga mer av flödet på en gång.
- **Känslighet och dynamiskt omfång** : Kamerans känslighet och dynamiska omfång kommer att påverka synlighet och kontrast för videodata. En kamera med högre känslighet kan till exempel kunna ta bilder i svagt ljus, medan en kamera med ett brett dynamiskt omfång kanske kan fånga både ljusa och mörka områden i samma bild.
- **Datahastighet** : Kamerans datahastighet, eller mängden data som den producerar per tidsenhet, kommer att påverka bearbetningskraven och lagringsbehoven för videodata.


#### Kamerateknik

I speciella fall kan linje-scan kameror och termografikameror vara mer lämpade för att mäta ett flöde av föremål än CCTV-kameror, på grund av deras specialiserade funktion, upplösning och kapacitet. Linje-scan kameror kan ta bilder av ett rörligt objekt genom att skanna en enda linje med pixlar över objektet när det rör sig, vilket ger en bild uppbyggd av en kontinuerlig ström av linjer. Termografiska kameror kan upptäcka och mäta temperaturskillnader i videodata, vilket kan vara användbart för vissa applikationer. För allmän analys är högupplösta CCTV-kameror en användbar datakälla. Valet av videokälla för att mäta ett flöde av föremål beror på hur processen som ska analyseras ser ut, föremålets specifika egenskaper, de önskade analysresultaten såväl som de tillgängliga resurserna och begränsningarna för projektet.

## Termografiska kameror

Termokameror kan vara ett idealiskt val för att mäta föremål i vissa applikationer där temperaturskillnader är relevanta. Några exempel på mål där termokameror kan vara användbara är:

- **Upptäcka defekter** : Genom att mäta temperaturen på föremålen kan termokameror kanske upptäcka defekter eller avvikelser som inte är synliga för blotta ögat. Till exempel, om en planka är skev eller har en strukturell brist, kan den ha en annan temperatur än omgivande föremål på grund av skillnader i värmeöverföring.
- **Övervakning av fukthalt** : Fukthalten i trä kan påverka dess termiska egenskaper, termokameror kan i vissa fall mäta dessa förändringar. Detta kan vara användbart till exempel för att övervaka fukthalten i trä i förvaring eller under transport, eftersom fukt kan påverka träets kvalitet och stabilitet.
- **Mätning av temperaturförändringar** : Termokameror kan också användas för att mäta temperaturförändringar i föremål under bearbetning eller tillverkning. Till exempel kan termokameror användas för att övervaka temperaturen på plankor under torknings- eller härdningsprocesser eller för att upptäcka överhettning i utrustning.
- **Kvalitetskontroll** : Genom att mäta temperaturen på plankor kan Termokameror i vissa lägen identifiera variationer i kvalitet eller konsistens. Detta kan vara användbart för kvalitetskontroll i tillverknings- eller bearbetningsapplikationer.



Det kan finnas vissa mål där termokameror är mindre lämpade för att analysera föremål, beroende på begränsningar i kamerans arbets sätt för uppgiften. Några exempel på uppgifter där termokameror kan vara mindre lämpliga inkluderar:


- **Låga temperaturskillnader** : Termokameror är designade för att upptäcka och mäta temperaturskillnader i videodata. Om temperaturskillnaderna mellan föremålen är små eller svåra att urskilja, kan det vara svårt att exakt mäta dem med en termografisk kamera.
- **Synliga ljusförhållanden** : Termokameror kan ta bilder i det infraröda spektrumet, som inte är synligt för blotta ögat. Om föremålen rör sig genom synliga ljusförhållanden kan det vara svårt att fånga tydliga och detaljerade bilder med en termografisk kamera.
- **Objekt som rör sig snabbt** : Termokameror kanske inte kan ta detaljerade bilder av objekt som rör sig snabbt, eftersom bildhastigheten inte är tillräckligt hög för att få skarpa bilder av plankornas rörelse. Detta kan vara ett problem om det som analyseras rör sig i höga hastigheter.
- **Specialiserade mätningar** : Termokameror kanske inte har den specialiserade kapacitet som krävs för att mäta vissa egenskaper hos objekten. Till exempel, om uppgiften involverar mätning av storlek, form eller färg, kan en termografisk kamera inte fånga nödvändiga data med tillräcklig precision.

Termokamerors lämplighet att mäta föremål kommer i slutändan att bero på föremålens specifika egenskaper och önskade noggrannhetskrav.

## Linje-scan kameror

Linje-scan kameror kan vara ett idealiskt val för att mäta föremål i vissa applikationer där hög upplösning och en kontinuerlig ström av objekt skall analyseras. Några exempel på mätningar där Linje-scan kameror kan vara användbara är:

- **Dimensionering och sortering** : Linje-scan kameror kan ta detaljerade bilder av föremålen och mäta deras dimensioner med hög noggrannhet. Detta kan vara användbart för att sortera och klassificera objekt baserat på storlek eller andra egenskaper.
- **Spårning och övervakning** : Linje-scan kameror kan fånga en kontinuerlig ström av data när objekten rör sig genom en process eller ett system. Detta kan vara användbart för att spåra och övervaka objektens rörelse, eller för att identifiera mönster eller avvikelser i data.
- **Kvalitetskontroll** : Genom att ta detaljerade bilder av objekten kan Linje-scan kameror identifiera defekter eller avvikelser som inte är synliga för blotta ögat. Detta kan vara användbart för kvalitetskontroll i tillverknings- eller bearbetningsapplikationer.
- **Inspektion och analys** : Linje-scan kameror kan också användas för att inspektera och analysera föremålen för forsknings- eller utvecklingsändamål. Linje-scan kameror kan till exempel kunna ta detaljerade bilder objektens ytstruktur eller krökning, vilket kan vara användbart för att förstå dess egenskaper eller prestanda.



Det finns applikationer där Linje-scan kameror är mindre lämpade för att mäta föremål, beroende på de specifika kraven och begränsningarna för uppgiften. Några exempel är:

- **Brett synfält** : Linje-scan kameror är utformade för att ta bilder av ett rörligt objekt genom att skanna en enda linje med pixlar över objektet. Det betyder att de har ett begränsat synfält och kanske inte kan fånga ett stort område av föremålen på en gång.
- **Ojämn rörelse** : Linje-scan kameror är utformade för att ta bilder av ett objekt som rör sig med jämn hastighet. Om föremålen rör sig ojämnt kan det vara svårt att fånga tydliga och detaljerade bilder med linje-scanteknik.
- **Låga ljusförhållanden** : Linje-scan kameror fungerar inte bra i svagt ljus, eftersom de förlitar sig på synligt ljus för att ta bilder. Om föremålen rör sig i en miljö med svagt ljus kan det vara svårt att få skarpa bilder.

## Högupplösta IP-kameror

IP-kameror är ofta ett idealiskt val för att mäta föremål i vissa applikationer där detaljerade bilder och ett brett synfält krävs. Några exempel på mål där IP-kameror kan vara användbara är:

- **Kvalitetskontroll** : IP-kameror kan ta detaljerade bilder av föremålen och identifiera defekter eller avvikelser som inte är synliga för blotta ögat. Detta kan vara användbart för kvalitetskontroll i tillverknings- eller bearbetningsapplikationer.

- **Dimensionering och sortering** : Genom att ta detaljerade bilder av föremålen kan IP-kameror mäta dimensioner med hög noggrannhet. Detta kan vara användbart för att sortera och klassificera plankor baserat på storlek eller andra egenskaper.
- **Spårning och övervakning** : IP-kameror kan fånga ett brett synfält av föremålen när de rör sig genom en process eller ett system. Detta kan vara användbart för att spåra och mäta plankor i rörelse eller för att identifiera mönster eller avvikelser i mått eller yta.
- **Inspektion och analys** : IP-kameror kan också användas för att inspektera och analysera föremålen för forsknings- eller utvecklingsändamål. Till exempel kan IP-kameror ta detaljerade bilder av objektens ytstruktur eller skador, vilket kan vara användbart för att förstå egenskaper eller prestanda.



Det kan finnas vissa applikationer där IP-kameror är mindre lämpade för att mäta plankor, beroende på de specifika kraven och begränsningarna för uppgiften. Några exempel på mål där IP-kameror kan vara mindre lämpliga inkluderar:

- **Låga ljusförhållanden** : IP-kameror kanske inte fungerar bra i svagt ljus, eftersom de är beroende av synligt ljus för att ta bilder. Om föremålen rör sig genom en miljö med svagt ljus, till exempel ett lågt upplyst lager, kan det vara svårt att fånga skarpa detaljerade bilder med en IP-kamera. I dessa fall kan ytterligare ljuskällor läggas till, observera att det är viktigt att dessa är flimmerfria och skapar en jämn belysningsnivå.
- **Objekt som rör sig snabbt** : IP-kameror kanske inte kan ta detaljerade bilder av objekt som rör sig snabbt, eftersom slutartiden i normalbelysning inte är tillräckligt hög för få skarpa bilder av plankor i rörelse. Det kan vara ett problem om de rör sig i höga hastigheter att det blir rörelseoskarpa i bilderna. Alla applikationer kräver inte höga bildhastigheter och korta slutartider, men i de fall som gör det är en stark ljuskälla till hjälp för att uppnå bra resultat.
- **Specialiserade mätningar** : IP-kameror har i vissa fall inte den specialiserade kapacitet som krävs för att mäta vissa egenskaper hos objekten. Om uppgiften t.ex. innebär att mäta temperaturskillnader eller fukthalt, kanske en IP-kamera inte kan fånga nödvändiga data.
- **Komplexa eller ostrukturerade data** : IP-kameror är inte alltid lämpade för uppgifter som involverar komplexa eller ostrukturerade data, som bildigenkänning eller objekt-detektering. För dessa typer av uppgifter kan maskininlärningstekniker eller specialiserade kameror med specialiserad kapacitet vara mer effektiva.

Högupplösta IP-kameror kan vara ett idealiskt val för att mäta föremål i applikationer där detaljerade bilder och ett brett synfält krävs, och den önskade analysen inte kräver specialiserade möjligheter. Lämpligheten hos IP-kameror för att mäta föremål beror på föremålens specifika egenskaper och de önskade måtten, såväl som tillgängliga resurser, installationsmiljö och projektets begränsningar.



## USECASE 2

### Strekkoder och kvalitetskontroll i pappersbruk

#### Metod


Valet mellan att använda algoritmer eller maskininlärning (ML) för att läsa streckkoder eller bedöma förpackningskvaliteten för stora föremål i en videoström beror på flera faktorer, uppgiftens komplexitet, kvaliteten på data och önskad noggrannhet i mätning.

Generellt sett är algoritmer snabbare att implementera än ML-modeller eftersom de inte kräver den tidskrävande processen att träna på stora datamängder. Tidsåtgången beror på den specifika algoritmen och uppgiftens komplexitet. Vissa algoritmer kan vara mer komplexa och kräva mer tid att implementera och testa än andra.



För uppgifter som att läsa streck-, QR-koder och text räcker det med algoritmer för att uppnå god noggrannhet och prestanda. Koder och tecken innehåller strukturerad data som enkelt kan läsas och avkodas med hjälp av specifika regler eller formler. Algoritmens noggrannhet kommer dock att bero på kvaliteten på bilderna, som upplösning, vinkel och skärpa hos streckkoderna i videoströmmen.

För uppgifter som att bedöma förpackningskvaliteten för stora föremål kan ML-modeller vara mer effektiva för att hantera komplexa eller ostrukturerade data, som videodata, och kan kanske uppnå högre nivåer av noggrannhet. Om kvalitetskraven kan brytas ned till mät- eller detekterbara detaljnivåer kan aggregerade algoritmer användas även i denna typ av applikation.



En ML-metodik kommer annars kräva en betydande mängd tid och resurser för att samla in och tagga utbildningsdata, samt att träna och finjustera modellen.

Det optimala alternativet för att implementera ett system för att läsa streckkoder eller bedöma förpackningskvaliteten för stora föremål i en videoström beror på de specifika kraven och begränsningarna för uppgiften. Generellt kommer en algoritmbaserad lösning att driftsättas till en lägre kostnad och inom en kortare tidsram än en maskininlärningsmetod.

Val av videokälla

#### Val av videokälla

Den bästa videokällan för streckkodsläsning och verifiering av förpackningsintegriteten för stora pappersrullar beror på de specifika kraven och begränsningarna för uppgiften samt installationsmiljön.

Några viktiga faktorer är :

- **Montering:** Den slutliga kvaliteten på analysresultatet beror på kamerornas placering och montering. Bra belysning fri från skuggor och solljus, raka vinklar mot föremålen och en stabil och vibrationsfri montering är kvalitetsbestämmande faktorer.
- **Upplösning och synfält :** Kamerans upplösning och synfält avgör detaljnivån och omfånget av videodata. Till exempel kan en kamera med högre upplösning kunna ta mer detaljerade bilder av streckkoderna, medan en kamera med ett bredare synfält kanske kan fånga fler av streckkoderna på en gång.
- **Känslighet och dynamiskt omfång :** Kamerans känslighet och dynamiska omfång kommer att påverka synlighet och kontrast för videodata. En kamera med högre känslighet kan till exempel kunna ta bilder i svagt ljus, medan en kamera med ett brett dynamiskt omfång kanske kan fånga både ljusa och mörka områden i samma bild.
- **Datahastighet :** Kamerans datahastighet, eller mängden data som den producerar per tidsenhet, kommer att påverka bearbetningskraven och lagringsbehoven för videodata.

I allmänhet är högupplösta IP-kameror eller specialiserade inspektionskameror väl lämpade för streckkodsläsning och verifiering av förpackningsintegriteten hos stora pappersrullar, eftersom de kan ta detaljerade bilder och har ett brett synfält. Dessa kameror kanske kan identifiera defekter eller brister i förpackningen som inte är synliga för blotta ögat, och kan mäta dimensioner eller andra egenskaper med hög noggrannhet. De kan också noggrant fånga och avkoda den strukturerade informationen i streckkoderna, även om streckkoderna är delvis skymda.

### Slutsats

Sammantaget kommer valet mellan att använda algoritmer eller maskininlärning i olika användningsfall bero på den specifika uppgiften och typen av data som bearbetas men också på tillgänglig tid, resurser och förekomsten av relevant träningsdata. Medan maskininlärning kan vara kraftfullt för uppgifter som involverar komplexa ostrukturerade data, är algoritmer mer lämpade för uppgifter med väldefinierade regler och mönster, där spårbarhet är viktigt, eller i situationer där tid eller resurser är begränsade.

ML kan lära sig och anpassa sig till förändrade mönster och relationer i data. Detta kan göra metoden mer effektiv vid hantering av uppgifter som bildigenkänning, objekt-detektering eller naturlig språkbehandling.

Å andra sidan kan algoritmer vara mer lämpade för uppgifter där spårbarhet är viktigt och i situationer där tid eller resurser är begränsade. Algoritmer är baserade på specifika regler eller formler som kan definieras tydligt och beräkningsbart och kan vara snabbare att implementera och distribuera än ML-modeller, som kräver den tidskrävande processen att samla in och tränas på stora datamängder.

Valet mellan algoritmer och ML bör avgöras av de specifika kraven och begränsningarna för uppgiften, valet kan innebära avvägningar mellan faktorer som budget, tidsram, noggrannhet, prestanda, flexibilitet, spårbarhet och verifierbarhet. Det kan vara nödvändigt att överväga dessa faktorer och utvärdera för- och nackdelarna med båda tillvägagångssätten för att välja det mest lämpliga alternativet för ett givet användningsfall.

## **Virify - Vilka är vi?**

*Vi är en specialiserad avdelning inom Nilhe och VideONet. Vår verksamhet är att utveckla och distribuera enkla processtyrningsfunktioner genom videoanalys.*

### **Vår verksamhet**

*Att leverera högkvalitativa, kostnadseffektiva mjukvarulösningar för videoanalys som gör det möjligt för våra kunder att förbättra sin processkontroll och beslutsfattande i realtid. Vi strävar efter att kontinuerligt förbättra våra produkter och tjänster genom forskning och utveckling, och att bygga långsiktiga relationer med våra kunder baserade på förtroende och ömsesidig nytta. Vårt mål är att göra det möjligt för våra kunder att uppnå högre effektivitet, produktivitet och lönsamhet genom att använda vår teknologi.*

### **Varför oss?**

*Vi baserar vår domänkunskap på våra teammedlemmars utbildningsbakgrund och yrkeserfarenhet. Teamet står på den fasta grunden för Nilhes +40 års erfarenhet som integratör och VideONets +20 år som utvecklare av avancerade videohanteringssystem för processindustriprojekt.*

### **Vår vision**

*Att vara den ledande leverantören av innovativa och pålitliga mjukvarulösningar för videoanalys för industriella processkontrollapplikationer, vilket ger våra kunder möjlighet att optimera sin verksamhet och uppnå sina mål.*