



tech
BORÅS

**Automatiserad cykeltidsprognos: Ett
multimodalt AI-beslutsstöd för smart
tillverkning**

Sammanfattning

Detta projekt har genomförts i samarbete mellan Tranemo Metal AB samt forskare och systemutvecklare inom AI och digitalisering, med syftet att undersöka hur maskininlärning kan användas för att automatisera uppskattning av cykeltider vid offertarbete. Utgångspunkten var företagets behov av att effektivisera en expertberoende offertprocess som i dagsläget kräver manuell tolkning av PDF-ritningar och STEP-filer.

Projektet resulterade i en prototyp – Cycle Time Predictor (CTP) – som kombinerar bildanalys av 2D-ritningar med geometrisk analys av 3D-filer. Genom att extrahera visuella och numeriska mått kunde modellen förutsäga cykeltid med hög precision. Den bästa modellen (CatBoost) förklarade 88 % av variationen i cykeltid och hade ett genomsnittligt fel på 7,4 minuter, vilket bedöms som acceptabelt.

Prototypen testades i praktiken av offertingenjören och fick ett positivt mottagande. Den bidrog även till att förändra medarbetares attityder till AI – från skepsis till nyfikenhet – och stärkte företagets pågående digitalisering. Insamling av faktiska cykeltider har påbörjats i produktionen och på sikt planeras både fortsatt träning av modellen och utveckling av en RPA-lösning för helautomatisk offertgenerering.

Projektet visar att AI kan skapa mervärde även i små tillverkningsföretag, förutsatt att lösningarna anpassas till verksamhetens faktiska data och arbetssätt. Metoden har potential att tillämpas i liknande SME-miljöer där ritningsbaserad offertbedömning är vanlig. Sammanfattningsvis har projektet både lagt grunden för ett konkret digitalt verktyg och bidragit till ökad förståelse för hur AI kan integreras i industriella beslutsprocesser.

Innehåll

1. Inledning.....	3
2. Metod och genomförande.....	4
2.1 Förståelse och inramning	4
2.2 Lösningssidé och prototyp	4
2.3 Utvärdering och vidareutveckling.....	5
3. Teknisk lösning och utveckling.....	5
3.1 AI-modellens uppbyggnad och funktionalitet.....	5
3.2 Bild- och STEP-baserad feature extraction.....	6
3.3 Lösningens tekniska arkitektur.....	6
4. Resultat och utvärdering.....	6
4.1 AI-lösningens prestanda och precision.....	6
4.2 Utvärdering av användarvänlighet	7
4.3 Affärsmässig nytta och effektiviseringspotential	7
5. Lärdomar och erfarenheter	7
6. Preliminära forskningsresultat.....	8
7. Nästa steg och vidare utveckling.....	9
Bilaga 1. Arbetssteg mjukvarurobot.....	10

1. Inledning

Inom *engineer-to-order* tillverkning i små orderstorlekar är offerthanteringen en central process där kundens förväntningar måste balanseras mot produktionens kapacitet. För små och medelstora företag (SMF) är denna process ofta manuell, expertberoende och tidskrävande. Tekniska ritningar tolkas av erfarna ingenjörer som estimerar cykeltider för CNC-bearbetning utifrån personlig erfarenhet och praxis—en arbetsmetod som riskerar att ge upphov till fel, förseningar och låg skalbarhet.

Hos Tranemo Metal AB sker offertsättningen huvudsakligen genom manuell tolkning av PDF-ritningar och STEP-filer. Denna process är inte bara långsam och svår att standardisera, utan skapar även flaskhalsar i produktionsflödet. Ett särskilt problem är beroendet av en enskild offerteringenjör, vilket gör processen känslig för frånvaro eller kunskapstapp.

Digitala lösningar såsom CAD-automatisering och AI-baserad feature recognition har visat potential att förbättra offertprecisionen. Däremot förutsätter många existerande lösningar tillgång till strukturerad CAD-data, vilket inte alltid är fallet i verkliga SME-miljöer där inkommande underlag ofta består av rasterbaserade ritningar och ej vektoriserade filer.

Mot denna bakgrund initierades ett utvecklingsprojekt i form av en innovationssprint, där en multimodal AI-lösning testades. Lösningen bygger på kombinationen av bildanalys med ResNet50V2 och geometrisk analys av STEP-filer för att prediktera total cykeltid. Projektet syftade till att öka träffsäkerhet och hastighet i offertsättningen samt minska beroendet av personbunden kunskap.

Offerthantering		Omfattning
Primär användare	Offertingenjör. Företaget har en stark koppling mellan offertarbete och produktion, där offertingenjören spelar en central roll. Processen är tekniskt avancerad och kräver förståelse för produktionsteknik.	
Utmaning	Hög precision men resurskrävande – Offertarbetet kräver noggranna beräkningar av bearbetningstider och tillgång till detaljerad teknisk information. Processen är tidskrävande och beroende av enskilda experter, vilket skapar ett personberoende och en sårbarhet för företaget.	
Data och underlag	PDF-ritningar och STEP-filer, e-post med förfrågan på ledtid och kostnad.	Ca 500 PDF-ritningar Ca 150-200 STEP-filer
Målsättning	Ökad automatisering och standardisering – Företaget vill förbättra precisionen och effektiviteten i offertarbetet genom digitala verktyg och mer strukturerad datahantering. En mer förutsägbar och skalbar offertprocess eftersträvas. <i>Mål lång sikt:</i> Kund ska kunna ladda upp ritning och STEP-fil på företagets hemsida och omedelbart få uppgift om pris och ledtid.	

	<i>Mål kort sikt:</i> • Förenkla hantering av offerter • 90 % noggrannhet i uppskattning av ledtid • Förkorta ledtid för offertprocessen • Minska personberoende i offertprocessen • Minska störning av maskinoperatörer • Sänka kompetenskraven på offertingenjören	
Nytta för företaget	Bättre kundservice och högre konkurrenskraft – Genom att minska ledtider och förbättra noggrannheten i offerter kan företaget stärka sin position på marknaden, öka kundnöjdheten och förbättra lönsamheten. • Förbättrad kundservice genom att företaget kan lämna en offert snabbare • Högre kostnadskontroll genom förbättrad noggrannhet i cykeltidsberäkningen • Minskade kompetenskrav på offertingenjören • Minskat personberoende i offertprocessen	Ca 500 offerter per år. 10-60 minuter per offert beroende på komplexitet.

Tabell 1. Sammanställning över företagsfallet Tranemo Metal.

2. Metod och genomförande

Projektet genomfördes inom ramen för en innovationssprint där forskare och företagsrepresentanter från Tranemo Metal samarbetade för att utveckla en AI-baserad lösning för cykeltidsprediktion. Arbetet följde en iterativ och utforskande process i tre steg: förståelse och inramning, lösningsidé och prototyp, samt utvärdering och vidareutveckling.

2.1 Förståelse och inramning

I projektets inledningsfas analyserades Tranemo Metals nuvarande offertprocess. Fokus låg på hur tekniska ritningar i PDF- och STEP-format tolkas manuellt av en erfaren offerteringenjör, och hur detta skapar flaskhalsar och personberoende. Processens beroende av ostrukturerade dataformat och bristen på digitalt beslutsstöd identifierades som nyckelutmaningar. I detta skede inventerades även historisk offert- och produktionsdata för att förstå tillgången till träningsdata för AI-modeller.

2.2 Lösningsidé och prototyp


Utifrån problemanalysen designades en prototyp där två datakällor – 2D-ritningar och 3D STEP-filer – används för att extrahera relevanta features. Bildembeddings från ritningar genererades med hjälp av ResNet50V2, medan geometriska mått som volym, yta och ett komplexitetsindex extraherades ur STEP-filer med PythonOCC. Dessa features kombinerades till multimodala vektorer som användes för att träna maskininlärningsmodeller, inklusive CatBoost och Random Forest. Prototypen realiserades i Python och strukturerades så att den på sikt ska kunna integreras med affärs- och ERP-system.

2.3 Utvärdering och vidareutveckling

Prototypen testades på ett historiskt dataset med kända cykeltider från tidigare offerter. Utvärderingen omfattade prestandamått såsom RMSE, MAE och R^2 , samt en jämförelse mellan olika modeller. Resultaten visade att särskilt CatBoost-modellen uppnådde hög precision. I denna fas identifierades även potentiella förbättringsområden, såsom utökad mängd träningsdata, förbättrad hantering av ritningar i rasterformat, samt möjlighet till användarfeedback för framtida reinforcement learning.

3. Teknisk lösning och utveckling

I projektet togs en multimodal AI-lösning fram för att förutsäga cykeltider i småskalig tillverkning baserat på tekniska ritningar. Lösningen bygger på en kombination av bildanalys och geometrisk analys, där information extraheras från både 2D-ritningar i rasterformat (PNG/PDF) och 3D STEP-filer, se Figur 1. Den resulterande datan används för att träna prediktionsmodeller med hög noggrannhet.



Figur 1. Övergripande lösning för Tranemo Metal AB. De skuggade aktiviteterna kan möjliggöras genom implementering av en så kallad RPA-robot, se vidare avsnitt 7.

3.1 AI-modellens uppbyggnad och funktionalitet

Systemet består av två parallella analyskedjor som extraherar features från ritningsunderlaget:

- Bildanalys: CAD-ritningar i PNG-format processas med den förtränade modellen ResNet50V2, som genererar 2048-dimensionella embeddings från varje bild. Dessa embeddings fångar visuella mönster kopplade till ritningens komplexitet, såsom hål, radier och bearbetningsytor.
- Geometrisk analys: STEP-filer tolkas med hjälp av PythonOCC-biblioteket. Här extraheras numeriska features som volym, yta och en sammansatt *Complexity Index*.

baserat på antalet hörn, kanter och ytor. Dessa mått fungerar som indikatorer på bearbetningskomplexitet.


Dessa två datakällor kombineras till en gemensam multimodal feature-vektor, som ligger till grund för träningen av flera maskininlärningsmodeller.

3.2 Bild- och STEP-baserad feature extraction

Feature engineering utgjorde en kritisk del av utvecklingen. En korrelationsanalys visade att särskilt komplexitetsindex, yta och volym hade hög korrelation med total cykeltid. För att undvika multikollinearitet aggregerades vissa starkt korrelerade variabler till sammansatta mått. Modellerna tränades på dessa reducerade och optimerade feature-set.

3.3 Lösningens tekniska arkitektur

Den tekniska lösningen är uppbyggd i Python och använder bibliotek som TensorFlow, scikit-learn, XGBoost, CatBoost och PythonOCC. Arkitekturen är modulär, vilket möjliggör framtida integration med API:er för ERP-system eller kundportaler. Figur 2 visar systemets arkitektur, där bild- och 3D-data processas parallellt, kombineras och skickas till ett ML-lager för prediktion.



Figur 2. Lösningen tekniska arkitektur. De gråa komponenterna kan implementeras genom en så kallad RPA-robot, se vidare avsnitt 7.

4. Resultat och utvärdering

4.1 AI-lösningens prestanda och precision

Efter träning och testning på ett historiskt dataset från Tranemo Metal visade modellen god prediktiv förmåga. Av de testade modellerna presterade CatBoost bäst, med ett R^2 -värde på 0,88, vilket innebär att 88 % av variationen i cykeltid kunde förklaras av modellen. Modellen uppnådde även lägst felvärden jämfört med övriga alternativ. Det genomsnittliga felet – mätt i minuter – var 7,4 (RMSE), vilket innebär att modellen i snitt gissade fel med ungefär 7 minuter per offert. När felet istället mäts i procent (MAPE) låg det på 19,8 %, vilket betyder att modellen i genomsnitt låg cirka 20 % över eller under den verkliga cykeltiden.

Andra modeller, som till exempel Random Forest och neurala nätverk, gav också acceptabla resultat (R^2 omkring 0,71–0,72), men var inte lika träffsäkra – särskilt när ritningarna var mer komplicerade. Det blev större skillnader mellan vad modellen visade och vad som var den verkliga cykeltiden. Den modell som kombinerade både PDF-ritningar och mått från STEP-filer gav bäst resultat. Det visar att det är en fördel att använda flera olika typer av information i stället för bara en.

4.2 Utvärdering av användarvänlighet

Prototypen testades internt av offertingenjören i samverkan med forskare. Användningen bedömdes som intuitiv tack vare en enkel gränssnittsdesign och automatiserad bearbetning av indata. Värdefull återkoppling gavs kring möjligheten att manuellt korrigera modellens prediktion, samt behovet av transparens i hur prediktionen beräknats. Ett viktigt förbättringsområde är därför att integrera förklaringsfunktioner (t.ex. SHAP-värden¹) och stöd för användarfeedback i framtida versioner.

4.3 Affärsmässig nytta och effektiviseringspotential

Den utvecklade lösningen har potential att minska offerttiden från 10–60 minuter per förfrågan till mindre än 5 minuter, vilket innebär både snabbare kundrespons och frigjord tid för nyckelpersonal. Nedan sammanfattas identifierade affärsnyttor:

Fördel	Beskrivning
Tidsbesparing	Automatisering av cykeltidsprediktion minskar tiden per offert väsentligt
Minskad felrisk	Ökad standardisering och datadrivna beslut minskar risken för offertfel
Skalbarhet	Mindre personberoende möjliggör hantering av fler kundförfrågningar parallellt
Frigjord expertkapacitet	Offertingenjören kan fokusera på komplexa fall och kundrelationer
Ökad konkurrenskraft	Snabbare och mer träffsäkra offerter stärker Tranemo Metals marknadsposition

Även om modellen ännu inte är färdig för full produktionssättning visar resultaten tydligt att multimodal AI kan skapa mervärde i SME-baserad offertverksamhet. För framtida användning krävs dock fortsatt utveckling av gränssnitt, integrationsmöjligheter samt ett bredare träningsunderlag.

5. Lärdomar och erfarenheter

Projektet har gett värdefulla insikter både tekniskt och organisatoriskt. En av de tydligaste lärdomarna är att tillförlitliga AI-modeller kräver både rätt typ av data och tillräcklig mängd data. Kombinationen av bildinformation från ritningar och geometriska mått från STEP-filer visade sig ge bäst resultat. Modeller som bara använde en av dessa källor presterade sämre.

¹ SHAP-värden (SHapley Additive exPlanations) är ett sätt att visa hur mycket varje enskild faktor – till exempel ritningsyta eller komplexitet – påverkar modellens förutsägelse. Det gör modellen mer begriplig och hjälper användaren att förstå varför ett visst resultat uppstår.

En annan central insikt är att mått som *Complexity Index* – en sammanslagning av hörn, kanter och ytor – förenklar modellens förståelse för hur komplicerad en detalj är att bearbeta, vilket gör den lättare att träna.

Från ett användarperspektiv framgick det att AI-modeller måste vara begripliga och transparenta för att accepteras. Det räcker inte med ett resultat; användaren behöver kunna förstå varför modellen gissar som den gör. Detta öppnar för att i framtiden integrera tekniker som SHAP för att tydliggöra modellens resonemang.

Under projektets gång installerades en version av Cycle Time Predictor (CTP) lokalt på offertingenjörens dator. Modellen testades mot ordinarie offertarbete för att jämföra noggrannhet och användbarhet. Den direkta kopplingen till det dagliga arbetet skapade både engagemang och trovärdighet. Attityden till AI förändrades också tydligt i takt med att modellen demonstrerades – från initial skepsis till en mer positiv och nyfiken hållning. Projektet bidrog därmed till att stärka det interna stödet för fortsatt digitalisering och AI-stöd.

Även i produktionen har projektet väckt intresse. Operatörer har involverats genom manuell registrering av faktiska cykeltider, vilket gett insikter om hur produktionsdata kan bidra till framtida modellträning. Det visar på en bredare organisatorisk inläring där både teknisk utveckling och kompetenshöjning skett parallellt.

6. Preliminära forskningsresultat

Detta projekt har undersökt hur en multimodal AI-metod – som kombinerar bildanalys och geometri från tekniska ritningar – kan användas för att automatisera uppskattning av cykeltid i småskalig tillverkning. Studien visar att det är möjligt att uppnå hög prediktionsträffsäkerhet även när indata kommer från verkliga kundunderlag i form av PDF-ritningar och STEP-filer, snarare än idealiserade CAD-modeller.

Det som särskilt skiljer denna studie från tidigare forskning är användningen av både bildbaserade embeddings och geometriska mått från 3D-modeller i en gemensam prediktionsmodell. Detta gör det möjligt att hantera variationer i ritningsformat, geometri och detaljkomplexitet på ett sätt som är direkt tillämpbart i SME-miljöer.

En annan forskningsmässig nyhet är det föreslagna Complexity Index, som kondenserar flera geometriska faktorer till en enda, lättanvänd prediktor. Detta underlättar både modellträning och tolkning av resultat. I kombination med tekniker för förklarbar AI, såsom SHAP, skapas en lösning som inte bara är effektiv utan också möjlig att förstå och förklara – något som är avgörande i industrin.

Studien pekar även på metodens potential att generaliseras till andra tillverkningsområden där man arbetar med ritningsunderlag, till exempel inom specialtillverkning, verktygstillverkning och formsprutning. Dessutom visar resultaten att det finns en stark framtida forskningspotential i att integrera denna typ av AI-stöd med användarfeedback i form av interaktiv inläring (reinforcement learning), där modellen successivt förbättras utifrån operatörens bedömningar.

Sammanfattningsvis demonstrerar studien att AI kan användas för att överbrygga klyftan mellan ostrukturerat offertunderlag och datadrivna beslutsstöd – ett steg mot mer responsiv, transparent och skalbar produktion även i små företag.

7. Nästa steg och vidare utveckling

Flera möjligheter har identifierats för att vidareutveckla och förfina den framtagna lösningen.

Ett tydligt vägval gäller hur modellen ska tränas framöver. I nuläget bygger modellen huvudsakligen på offertingenjörens tidigare uppskattningar samt viss feedback från produktionen (s.k. GARP-data). En framtida utvecklingslinje är att använda reinforcement learning, där modellen lär sig av offertingenjörens manuella korrigeringar. På så vis kan systemet successivt förbättras utifrån verklig användarerfarenhet.

Ett alternativ är att i större utsträckning basera träningen på faktiska cykeltider från maskinerna. Denna metod är mer objektiv men kräver mer tid och arbete eftersom operatörer idag registrerar tider manuellt, vilket sedan matas in i ett separat dataset. En automatiserad koppling mellan CNC-maskiner och träningsdatan vore därför en långsiktig förbättring.

För att göra lösningen ännu mer användbar och skalbar på sikt planeras även att tillgängliggöra nya versioner av användargränssnittet via GitHub, samt erbjuda uppdateringar av modellens parametrar.

Parallellt med detta pågår ett försök att utveckla ett proof-of-concept för robotiserad offertautomation. Tanken är att använda RPA-teknik (Robotic Process Automation) för att automatisera hela flödet från inkommande kundmejl till färdig offert, se mjukvarurobotens arbetssteg i Bilaga 1. Om detta lyckas kan modellen integreras i ett större system som hanterar offertprocessen mer helautomatiskt.

Tillsammans visar dessa nästa steg att det finns både tekniska och organisatoriska förutsättningar för fortsatt utveckling. Projektet har lagt grunden för en mer datadriven och skalbar offertprocess – och banar väg för hur små tillverkningsföretag kan ta steg mot AI-stödd produktion på ett konkret och behovsanpassat sätt.

Bilaga 1. Arbetssteg mjukvarurobot

1. Ta emot och läsa mail om offertförfrågan > kund, kontaktperson, antal, leveransdatum, artikelnummer
2. Ladda ned bilagor > pdf-ritning, step-fil
3. Ladda upp ritningar i app > uppskattad aggregerad cykeltid
4. Registrera artikel i GARP > ny produktionsartikel med artikelnummer som i 1)
5. Skapa operationskort i GARP > operationskort med aggregerad cykeltid samt standardtider
6. Beräkna offertvärde i GARP > offertvärde
7. Skapa utkast till offert > offerttext
8. Maila offerttext till offertingenjör > mail med offerttext i offertingenjörens mailkorg



Techarena Report Series 2025:X
ISSN 2004-8963

University of Borås
Department of Information Technology
Allégatan 1
501 90 Borås, Sweden
+46 (0) 33-435 40 00