


# Autofix - Automatisk design av fixturer

Publik rapport



Författare: Mehdi Tarkian  
Datum: 2024-01-30  
Projekt inom Hållbar produktion

**FFI** Fordonsstrategisk  
Forskning och  
Innovation

VINNOVA

Energimyndigheten

TRAFIKVERKET

FKG

VOLVO

SCANIA

VOLVO

SCANIA

VOLVO

SCANIA

VOLVO

SCANIA

VOLVO

# Innehållsförteckning

<b>1 Sammanfattning .....</b>	<b>3</b>
<b>2 Executive summary in English.....</b>	<b>3</b>
<b>3 Bakgrund.....</b>	<b>4</b>
<b>4 Syfte, forskningsfrågor och metod .....</b>	<b>5</b>
<b>5 Mål .....</b>	<b>5</b>
<b>6 Resultat och måluppfyllelse .....</b>	<b>5</b>
6.1 Designautomation (Papper 1, AP1 & AP2) .....	5
6.2 Övervakad inläring (Papper 2, AP3 & AP4).....	6
6.3 Förstärkningsinläring (Papper 3, AP3).....	7
6.4 Val ML-arkitektur med ChatGPT (AP3).....	8
<b>7 Spridning och publicering .....</b>	<b>9</b>
7.1 Kunskaps- och resultatspridning .....	9
7.2 Publikationer.....	9
<b>8 Slutsatser och fortsatt forskning .....</b>	<b>10</b>
<b>9 Deltagande parter och kontaktpersoner.....</b>	<b>10</b>

## Kort om FFI

FFI är ett samarbete mellan staten och fordonsindustrin om att gemensamt finansiera forsknings- och innovationsaktiviteter med fokus på områdena Klimat & Miljö samt Trafiksäkerhet. Satsningen innebär verksamhet för ca 1 miljard kr per år varav de offentliga medlen utgör drygt 400 Mkr.

Läs mer på [www.vinnova.se/ffi](http://www.vinnova.se/ffi).

# 1 Sammanfattning

Syftet med AutoFix-projektet var att öka automatiseringsgraden inom fixturkonstruktion genom en tätare integration av digitala verktyg från olika discipliner och införandet av automatisering baserad på multidisciplinär optimering (MDO) och maskininlärning (ML). AutoFix har utvecklat metoder och verktyg för att automatiskt optimera resurskrävande fixtureringsarbete med hjälp av designautomation (DA), MDO och ML.

Förväntade effekter inkluderade möjligheten till in-sourcing från låglöneländer genom att öka arbetsmängden samtidigt som antalet ingenjörstimmar bibehålls. Projektet syftade även till effektiv kunskapshantering och standardisering för att underlätta ingenjörsarbete, frigöra tid för värdeskapande aktiviteter, öka effektiviteten inom produkt- och produktionsutveckling, samt förstärka företagets konkurrenskraft. En ytterligare målsättning var kunskapsuppbyggnad inom digitalisering, särskilt hur ML kan underlätta beslutsstöd inom produkt- och produktionsutveckling.

Projektet utgöordes av fem huvudsakliga arbetspaket (AP:n), sammanfattat nedan:

AP1 Att utveckla nya metoder för att skapa detaljerade CAD modeller och för att konfigurera dessa.

AP2: Att utforska designutrymmet på ett nytt sätt och optimera fixturer

AP3. Att generera mönster och CAD-instruktioner automatiskt med hjälp av ML-algoritmer baserat på data som genereras ur MDO-processen i AP2. AP4 De metoder som utvecklats i AP1 till

AP4 utvärderas gentemot dagens utvecklingsprocess

AP5 Resultatet av projektet sprids kontinuerligt för att skapa ett brett nyttiggörande

Projektet resulterade i fyra vetenskapliga publikationer och en licentiatexamen, helt eller delvis finansierade av AutoFix.

Alla arbetspaket har genomförts, och från ett tekniskt perspektiv har kunskapsgenereringen varit betydelsefull, speciellt inom maskininlärning och i synnerhet inom områden som reinforcement learning och supervised learning. Trots detta uppnådde projektet inte sina marknadsmässiga mål.

Detta har många anledningar, en av dessa är den stora omorganisationen som utfördes på Volvo Cars som ledde till byte av kontaktperson vid ett par tillfällen. Trots detta så har Volvo Cars bistått projektet med mycket tekniskt kunnande och stöd. Vi har därför kunnat ta fram tekniska lösningar för att försöka lösa dem identifierade behoven. Detta har dock inte varit framgångsrikt pga:

- Modeller och ramverk har utvecklats i verktyg som Volvo inte använder och har därför varit svåra att implementera på plats
- Implementeringarna har inte löst ett tillräckligt stort problem med avseende på investeringar som behövs för att utveckla dem.

Rapporten kommer att ge ytterligare detaljer, men sammanfattningsvis har de identifierade problemen varit väldefinierade och relevanta, men lösningarna har inte varit tillräckligt robusta eller tillämpbara.

## 2 Executive summary in English

The AutoFix project aimed to enhance the degree of automation in fixture construction through tighter integration of digital tools from various disciplines, and by introducing automation based on Multi-Disciplinary Optimization (MDO) and Machine Learning (ML). The project delivered methods and tools for automatically optimizing resource-intensive fixture work using Design Automation (DA), MDO, and ML.

The anticipated outcomes included the potential for in-sourcing from low-wage countries by enabling more work with maintained engineering hours. This would facilitate effective knowledge management and standardization, easing engineering work and freeing time for more value-creating activities, thereby increasing efficiency in product and production development and enhancing corporate competitiveness. The project also aimed to build

knowledge in the field of digitalization, especially in how ML can enable better decision support in product and production development.

The project comprised five main work packages (WPs):

WP1: Development of new methods for creating detailed CAD models and configurations.

WP2: Exploration of the design space in novel ways and optimization of fixtures.

AP3: Generation of patterns and CAD instructions automatically using ML algorithms based on data from the MDO process in WP2.

WP4: Evaluation of the methods developed in WPs 1 to 4 against current development processes.

WP5: Continuous dissemination of project results to ensure broad utilization.

Overall, the project produced four scientific publications and one licentiate thesis, either fully or partially funded by the AutoFix project.

All work packages were completed, and from a technical perspective, significant and valuable knowledge was generated, particularly in machine learning areas like reinforcement learning and supervised learning. However, the project did not meet its market-oriented goals. Various factors contributed to this, such as major reorganizations at Volvo Cars, the primary stakeholder, leading to change contact person in a couple of occasions. Despite these challenges, Volvo Cars provided significant technical knowledge and support. We developed technical solutions to address identified needs, but these were not entirely successful due to:

- Models and frameworks developed in tools not used by Volvo, making on-site implementation challenging.
- Implementations by Linköping University and Prodtex didn't address sufficiently significant problems in relation to the required investment for their development.

The report will further clarify these points, but overall, while the identified problems were well-defined and relevant, the solutions lacked robustness and applicability.

### 3 Bakgrund

Digitaliseringen av industrin ger stora möjligheter till att effektivisera utvecklingsprocessen för komplexa och integrerade produkter så som moderna fordon, exempelvis genom smartare och effektivare produktionsberedning som står i fokus för detta projekt, AutoFix. I Framtiden måste arbetet vid framtagning av produktionsutrustning, såsom fixturer, fokusera på det värdeadderande arbetet och att skapa innovationer i konstruktionsarbetet snarare än att skapa punkter, streck och rita sketcher som extruderas till 3D-format som slutligen omformas till 2D-ritningar. Idag krävs lång erfarenhet för att jobba som fixturkonstruktör, och det ligger en stor stolthet hos dessa sakkunniga experter i att optimera fixturen utifrån olika konstruktionskrav, ledtid och kostnad. Framtagningen av fixturer anses idag vara ett mycket avancerat och svårt arbete med hög risk, då kvaliteten i produkterna som tillverkas avgörs till stor del av fixturernas egenskaper. Detta leder till att konstruktörerna inte vågar prova nya tekniker och möjligheter, som att ta in nya standardelement, då det kan upplevas som onödiga risker i ett projekt som kan leda till bristfällig produktkvalitet. Fokus hamnar på att konstruera på ett säkert sätt snarare än att motivera till innovativa tänkande. Dessutom resulterar globaliseringen, med ökad konkurrens, till att behovet av kundanpassningar ökar och därmed ökade krav på flexibel produktion. Fokus bör därför ligga på att ta steget mot flexibla lösningar, som stödjer kundanpassning och effektiv produktion, även för lägre produktionsvolymmer. Skall detta bli möjligt kommer det krävas stora insatser för att använda automation, så som optimering och maskininlärning, för att hjälpa konstruktörerna att i framtiden få fram effektiva fixturer som minskar risken i fixturprojekt samtidigt som det ökar och stöder möjligheterna till flexibel produktion. Då sakkunskapen som finns i den äldre generationens konstruktörer successivt förloras av naturliga skäl, blir det speciellt viktigt att säkerställa att kunskapen finns kvar inom företaget genom att den lagras i digitala modeller och verktyg, och inte enbart i huvudet på erfarna konstruktörer.

OEM-bolag brukar sällan konstruera sina fixturer själva, bl.a. p.g.a. höga risker och att kärnverksamheten framförallt ligger i t.ex. att bygga bilar eller flygplan. Därför läggs detta arbete ut på underleverantörer. Leverantörer är ofta mindre, agila bolag som är hårt konkurrensutsatta, där de med lägst pris oftast vinner budgivningen. Dessa

mindre bolag har sällan muskler att driva forskning/utveckling inom konstruktionsarbetet vilket cementerar det konservativa tänkandet. Här finns en distinktion mellan fixturområdet och robottekniken. Forskning inom industrirobotteknik tar stora steg framåt nu inom områden som kollaborativa robotar och maskininlärning.

## 4 Syfte, forskningsfrågor och metod

Projektet syfte var att effektivisera beredning och framför allt konstruktion av fixturer med följande forskningsfrågor:

- Vilka kriterier kan användas för att bedöma flexibiliteten i automatisering av fixturdesign?
- På vilka sätt bidrar dessa kriterier till utvecklingen av fixturer som ökar produktionseffektiviteten?
- Hur kan multidisciplinär optimering användas för att öka flexibiliteten i fixturer? (AP1 & AP2)
- Hur kan neurala nätverk förbättra designautomation och integreras sömlöst i tillverkningsystem? (AP3)

Metoden som används kan kategoriseras på två nivåer. På en högre nivå överensstämmer metodologin med aktionsforskning inom området programvaruutveckling, som föreslagits av Staron (2020). På en mer specifik nivå följer implementationerna som presenteras kvantitativ DA, MDO och ML-ansats.

## 5 Mål

Det övergripande målet för projektet är att stärka svensk fordonsindustris internationella konkurrenskraft genom en mer datadriven produkt- och produktionsutvecklingsprocess baserad designautomation, multi-disciplinär optimering och maskininlärning (ML). De metoder som utvecklas kommer att kunna leda till en 50%-ig reduktion av antalet ingenjörstimmar inom produktionsberedning, samt motsvarande kostnadsbesparing.

De generella metoder som utvecklas är däremot möjliga att implementera hos flera företag och är inte bundna till projektets partner. Genom att använda ML är det möjligt att automatiskt generera de CAD-instruktioner som utgör grunden för DA. Ytterligare ett mål är därmed att möjliggöra att DA som ett verktyg görs tillgängligt även för mindre och medelstora företag, vilket det inte är idag på grund av brist på både kunskap och resurser för att generera de CAD-instruktioner som krävs, men som nu kan automatgenereras med hjälp av ML.


Även om det övergripande målet med projektet är den stora besparingen i termer av ingenjörstimmar och kronor, så finns även andra positiva delmål som snabbare kunskapsuppbbyggnad inom företaget, formalisering och lagring av kunskap i formella strukturer och databaser, och minskad risk för fel och därmed en effektivare utvecklingsprocess.

## 6 Resultat och måluppfyllelse


### 6.1 Designautomation (Papper 1, AP1 & AP2)

Detta papper introducerar ett ramverk för att automatisera designen av fixturer, genom att utnyttja synergier mellan designautomation (DA), multidisciplinär optimering (MDO) och robotiksimulering. Kärnan i MDO innefattar användningen av samtidiga och parametriska designer, möjliggjorda av DA och kunskapsbaserade ingenjörswerktyg, med målet att minska både tid och kostnader associerade med designprocesser för fixturer genom förbättrad automatisering. AutoFix erbjuder metoder och verktyg för att optimera resurstunga fixturer genom att integrera digitala verktyg från olika discipliner:

- Ramverket möjliggör automatisering av designprocessen för fixturer, vilket kombinerar designautomation (DA), multidisciplinär optimering (MDO) och robotiksimulering för att minska tid och kostnader.
- Genom att tillämpa DA elimineras repetitiva uppgifter, vilket frigör tid för mer värdeskapande aktiviteter och förbättrar produkt- och produktionsutvecklingens effektivitet.
- Skapandet av parametriska modeller ökar flexibiliteten i fixturens design, vilket möjliggör en snabbare anpassning till nya produktionsbehov.
- Användningen av DA, optimering och robotiksimulering i designprocessen leder till utveckling av fixturer som förbättrar produktionseffektiviteten.
- Ramverket automatiserar designen av fixturer för karossstrukturer (BIW) och optimerar monteringen för en kollisionsfri modell, vilket effektiviserar designutrymmets utforskning vid ändringar i BIW-designen.



**Figure 6. Robot sweep volume extracted after spot-welding simulation**



**Figure 7. Comparison of design automation (left) and optimization results (right)**

## 6.2 Övervakad inlärning (Papper 2, AP3 & AP4)

Ett grundläggande koncept, känt som 3-2-1 placeringsprincipen, är avgörande för att säkra ett objekt genom att begränsa dess rörelsefrihet i sex grader, en standard som alla fixturer måste följa.

Till skillnad från traditionella metoder som automatiserar fixturutläggning genom optimering eller regelbaserade system, introducerar denna uppsats en ny metod med användning av övervakad inlärning. Specifikt tillämpas denna teknik för att designa plåtfixturer, med bilarstolpar som fallstudie. Metoden innebär analys av tidigare designupplevelser för att lösa 3-2-1 placeringsprincipen.

Denna forskning bidrar med följande insikter:

- Till skillnad från traditionella metoder, använder uppsatsen övervakad inlärning för att automatisera utläggningen av fixturer i plåtdesigner, med ett fokus på bilarstolpar som fallstudie.
- Introducerar en ny metod för att representera plåtdesigndata i ett CNN genom att projicera geometrin på en plan, där Z-koordinaten omvandlas till gråskalepixelvärden för att skapa en topografisk karta.
- Ramverket är integrerat som ett tillägg inom CAD-miljön, vilket möjliggör återanvändning av befintlig kunskap om fixturutläggning för nya arbetsstycken.
- Använder ett fint justerat CNN för regression för att generera den slutliga fixturutläggningen, vilket visar hög noggrannhet och snabb konvergens i regressionsuppgifter.

- Resultaten visar modellens höga noggrannhet (ungefär 100%) vid klassificering av bilarstolpar och bekräftar dess användbarhet för industriella fall.

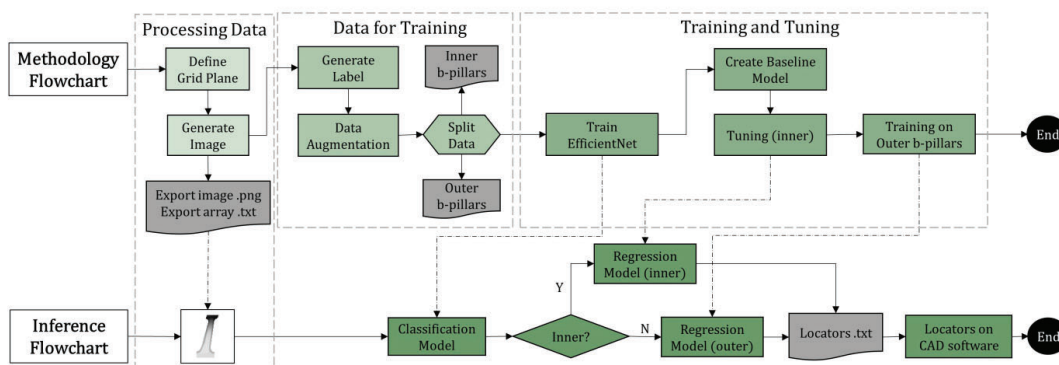


Figure 7: General flowchart for the methodology and the resulting inference framework




Figure 10: Test sample. Comparison between original label, baseline prediction and tuned model predicted values.

### 6.3 Förstärkningsinläring (Papper 3, AP3)

Implementeringen av maskininläring (ML) erbjuder en betydande möjlighet för tillverkningsindustrin att förbättra processer för både produktutveckling och produktionsutveckling. ML:s förmåga att skapa anpassningsbara och mycket precisa modeller är särskilt fördelaktig i scenarier där traditionell produktionsautomation inte är genomförbar, till exempel vid massanpassning där produktionsinställningarna är oförutsägbara och ostrukturerade. För att hantera variationen i produktionssystem och miljöer föreslås användning av förstärkningsinläring (RL) i kombination med lättviktiga spelmotorer som en lösning från de tidiga stadierna av produkt- och produktionsutvecklingen. Utmaningar såsom att simulera observationer i en virtuell miljö för att efterlikna verkliga interaktioner behöver dock adresseras. Detta projekt fokuserar på att utveckla RL-metoder för vägfinnande och kollisiondetektering i varierande miljöer. Det inkluderar en fallstudie om automatisering av monteringsvalidering inom bilindustrin, som traditionellt sett är beroende av manuellt arbete. Här tränas en mannekäng för att utföra plock- och placeringsuppgifter i olika inställningar, vilket effektiviserar processen för monteringsvalidering i de initiala designstadierna:

Förstärkningsinläring för flexibilitet: Användning av RL i kombination med lättviktiga spelmotorer erbjuder lösningar på utmaningar i ostrukturerade och oförutsägbara produktionsmiljöer:

- Projektet adresserar svårigheter med att skapa realistiska virtuella miljöer för att simulera verkliga interaktioner och processer.

- En fallstudie inom bilindustrin visar på automatisering av monteringsprocesser med hjälp av en tränad mannekäng, vilket minskar beroendet av manuellt arbete i de tidiga designfaserna.
- RL kräver inte fördefinierade datamängder för träning, vilket möjliggör större flexibilitet och snabbare utveckling av nya produktionslinjer i föränderliga miljöer.




FIGURE 12

Sequence of operations performed by a trained mannequin, including approaching an object, picking it up, transporting it to a designated drop-off location, positioning itself at the drop-off location, and finally releasing the object at the final location.

## 6.4 Val ML-arkitektur med ChatGPT (AP3)

Att välja en lämplig arkitektur för maskininlärningsmodeller för tillverkningsuppgifter kräver expertis inom både datavetenskap och tillverkning. Integrering av avancerade maskininlärningsmodeller och tillverkningsprocesser är ofta en utmaning på grund av avståndet mellan dessa fält. OpenAIs populära språkmodell, ChatGPT, har potential att överbrygga detta gap.

Detta papper föreslår riktlinjer och frågor för att utforska alternativ för modellarkitektur och utvinna värdefull information från ChatGPT:s förmågor inom naturlig språkbearbetning. Även om ChatGPT är ett kraftfullt verktyg, är det viktigt att verifiera alla svar mot pålitliga källor innan beslut fattas. Riktlinjerna består av ett flödesschema med fyra frågor för att ge ChatGPT tillräckligt med kontext och information om befintliga indatadata. ChatGPT:s förslag kommer att riktas mot bearbetning av indata, utdata och förslag på arkitektur. Den sista frågan producerar nyckelord baserat på chatten för en bakgrundsstudie i ämnet.

En fallstudie inom tillverkning genomfördes för att demonstrera riktlinjernas effektivitet. Studien innefattade skapandet av en modell för att förutsäga fixeringsplatser för svetsprocesser inom fordonssektorn. Efter att ha genomfört fyra separata intervjuer med ChatGPT, diskuterar författarna valet av arkitektur baserat på ChatGPT:s förslag och jämför detta med tidigare litteratur.

De föreslagna riktlinjerna förväntas vara användbara i en mängd olika tillverkningsområden, då de erbjuder en strukturerad metod för att utforska alternativ för modellarkitektur med hjälp av ChatGPT:s kapaciteter, vilket i slutändan leder till nya och innovativa tillämpningar av maskininläring inom detta område.



Detta papper presenterar en uppsättning riktlinjer för effektiv användning av ChatGPT i utforskningen av arkitektur för maskininlärningsmodeller. Riktlinjerna inkluderar ett flödesschema med 5 frågor som hjälper användare att navigera genom utforskningsprocessen. Vår studie har visat att ChatGPT kan ge värdefulla insikter i utforskningen av modellarkitektur, och de föreslagna riktlinjerna kan fungera som en utgångspunkt för forskare och praktiker inom olika områden.

Applicerbarheten av dessa riktlinjer demonstreras i en fallstudie inom tillverkning, som består i utvecklingen av en modell för att förutsäga fixeringsplatser för svetsoperationer inom bilindustrin. En sådan modell har potential att avsevärt minska planeringstiden för processer och iterationer mellan team. Genom intervjuer med ChatGPT har författarna identifierat en semantisk segmenteringsansats som använder 2D-projektioner av monteringen som den mest lovande lösningen för fallstudien. Framtida arbete kommer att fokusera på att bygga det föreslagna ramverket.

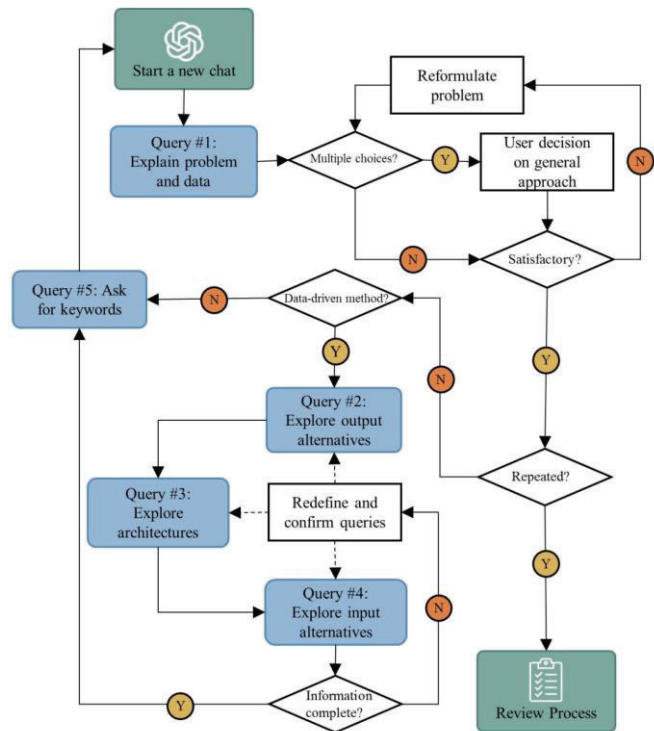


FIGURE 2: FLOWCHART FOLLOWED FOR THE CHATGPT INTERVIEW PROCESS FOR MODEL EXPLORATION

## 7 Spridning och publicering

### 7.1 Kunskaps- och resultatspridning

Hur har/planeras projektresultatet att användas och spridas?	Markera med X	Kommentar
Öka kunskapen inom området	x	AutoFIX har varit helt avgörande för att öka kunskapen inom maskininläring
Föras vidare till andra avancerade tekniska utvecklingsprojekt	x	Flertalet nya forskningsprojekt har i dagsläget användning av den kunskapshöjning som nåddes tack vare AutoFIX.
Föras vidare till produktutvecklingsprojekt		Även om det inte finns en planerad så hoppas vi att ett sådant projekt kan realiseras vid slutet av ett eventuell ny forskningsprojekt inom området.
Introduceras på marknaden		
Användas i utredningar/regelverk/tillståndsärenden/ politiska beslut		

### 7.2 Publikationer

Nedan publikationer är helt eller delvist finansierade av AutoFIX projektet. Undantaget är Nambiar (2022) som är ett saminvesterad papper mellan projekten AutoFIX och AUTOPACK2.0 som båda är inkluderade i FFI programmet.

1. Nambiar S, Albert AP, Rimmalapudi VVRC, Acharya V, Tarkian M, Kihlman H. Autofix – Automated Design of Fixtures. *Proceedings of the Design Society*. 2022;2:543-552. doi:10.1017/pds.2022.56
2. Villena Toro J., Wiberg A., Tarkian M. "Application of optimized CNN to fixture layout in automotive parts". *International Journal of Production Research*, Taylor and Francis, (Handed manuscript 2022)
3. Nambiar, S., Wiberg, A. and Tarkian, M. Automation of unstructured production environment by applying reinforcement learning. *Frontiers in Manufacturing Technology* 3,(2023).
4. Villena Toro, J. and Tarkian, M. (2023). Model Architecture Exploration Using Chatgpt for Specific Manufacturing Applications. In *IDETC-CIE. Volume 2: 43rd Computers and Information in Engineering Conference (CIE)*.
5. Villena Toro, Javier (2023), "Machine Learning in Design Engineering and Manufacturing" Licentiate Thesis. Linköping:Linköping University Electronic Press.

## 8 Slutsatser och fortsatt forskning

Utmaningen är kort och gott -> data!

- Att hitta tillräckligt mycket data så att modellen har ett tillräckligt stort designområde.
- Att hitta bra och relevant data så att modellen approximerar rätt.
- Att rensa och annotera data så att modellen kan tränas rätt och effektivt.

Modellen blir inte bättre än den data som används för att träna den. För att adressera ovan har vi identifierat två alternativa vägar som vi redan idag har börjat arbeta med; Syntetisk data generering och Physics Informed Neural Networks (PINN):

- Kalibrera tillgängliga data med digitala tvillingar som sedan används för att generera bra, relevant och tillräckligt med data.
- PINN möjliggör ett nytt sätt att lösa partiella differentialekvationer genom att utöka neurala nätverk för att även inkludera derivator i träningsprocessen genom att inkludera ett residualblock. PINN framhålls för sin effektivitet i att lösa dåligt ställda och inversa problem, erbjuder en mesh-fri implementation och är skalbara för stora problem genom domändekomposition.

## 9 Deltagande parter och kontaktpersoner

Mehdi Tarkian – Projektledare – [mehdi.tarkian@liu.se](mailto:mehdi.tarkian@liu.se)

Henrik Kihlman – Prodtex kontaktperson – [henrik.kihlman@prodtex.com](mailto:henrik.kihlman@prodtex.com)

Ferudun Ali – Volvo Cars kontaktperson - [ferudun.ali.2@volvocars.com](mailto:ferudun.ali.2@volvocars.com)

Javier Villena Toro – Doktorand – [villena.toro@liu.se](mailto:villena.toro@liu.se)

Sanjay Nambiar – Doktorand - [sanjay.nambiar@liu.se](mailto:sanjay.nambiar@liu.se)