



CHALMERS

Användning av artificiell intelligens som beslutsstöd för kapacitetsplanering och resursallokering av personal inom järnvägssektorn

Kandidatarbete inom Industriell ekonomi

LIV ASK
MOA KILÉN
ARVID MATTSSON

OLIVIA BERNTSSON CIMESA
CLARA LINDBERG
LOVISA WINGSTEDT

**INSTITUTIONEN FÖR TEKNIKENS EKONOMI OCH ORGANISATION
AVDELNINGEN FÖR TEKNIK, VETENSKAP OCH SAMHÄLLE**

CHALMERS TEKNISKA HÖGSKOLA
Göteborg, Sverige 2026
www.chalmers.se
Kandidatarbete TEKX18-VT26-16A

Användning av artificiell intelligens som beslutsstöd för kapacitetsplanering och resursallokering av personal inom järnvägssektorn

The Use of Artificial Intelligence as Decision Support for
Capacity Planning and Personnel Resource Allocation in
the Railway Sector

LIV ASK
MOA KILÉN
ARVID MATTSSON

OLIVIA BERNTSSON CIMESA
CLARA LINDBERG
LOVISA WINGSTEDT

Användning av artificiell intelligens som beslutsstöd för kapacitetsplanering och resursallokering av personal inom järnvägssektorn

LIV ASK

MOA KILÉN

ARVID MATTSSON

OLIVIA BERNTSSON CIMESA

CLARA LINDBERG

LOVISA WINGSTEDT

© LIV ASK, 2026

© MOA KILÉN, 2026

© ARVID MATTSSON, 2026

© OLIVIA BERNTSSON CIMESA, 2026

© CLARA LINDBERG, 2026

© LOVISA WINGSTEDT, 2026

Kandidatarbete TEKX18-VT26-16A
Teknikens ekonomi och organisation
Chalmers tekniska högskola
412 96 Göteborg
Sverige
Telefon + 46 (0)31-772 1000

Göteborg, Sverige 2026
Gothenburg, Sweden 2026

The Use of Artificial Intelligence as Decision Support for Capacity Planning and Personnel Resource Allocation in the Railway Sector

LIV ASK
MOA KILÉN

ARVID MATTSSON

OLIVIA BERNTSSON CIMESA

CLARA LINDBERG

LOVISA WINGSTEDT

Department of Technology Management and Economics
Chalmers University of Technology

SUMMARY

Railway companies in Sweden operate under significant pressure due to high network utilization and a heavily regulated environment, where personnel planning and capacity management are central to maintaining stable operations. Current planning processes rely largely on manual methods and individual experience, making it difficult to handle disruptions quickly and creating recurring trade-offs between cost, robustness and working conditions. The aim of this study was to examine how AI-based decision support can be used in railway personnel planning as well as to identify factors that enable or challenge such use and what economic and organizational consequences it would bring. The study was conducted as a qualitative case study combining a literature review with semi-structured interviews with personnel planners, traffic managers and professionals with experience of AI implementation. Task-Technology Fit was used as a theoretical framework to assess how well AI aligns with the demands of personnel planning. The results show that AI has the potential to act as decision support through all stages of the planning process. However, the degree of Task-Technology Fit varies. The greatest potential is found in short-term planning, where prescriptive AI based on Reinforcement Learning is well suited, while predictive models are better fitted for tactical planning over longer time horizons. It also emerges that AI can contribute to more transparent and standardized decision-making, potentially shifting the balance between competing goals in a more favorable direction. At the same time, barriers exist in the form of limited trust in automated decisions, data quality requirements and high implementation costs. Overall, the study contributes empirical insights into how AI-based decision support can be adapted to different planning stages in the railway sector and what organizational and economic conditions are needed to realize its potential.

Note: The report is written in Swedish.

Keywords: Artificial Intelligence, Capacity Planning, Decision Support Systems, Resource Allocation, Railway Sector, Task-Technology Fit.

SAMMANFATTNING

Järnvägssektorn i Sverige präglas av hög belastning och ett komplext regelverk där kapacitetsplanering och resursallokering utgör kritiska funktioner. Planeringsprocessen är idag i stor utsträckning manuell och erfarenhetsbaserad, vilket försvårar hanteringen av snabba förändringar och skapar återkommande målkonflikter mellan kostnad, robusthet och arbetsmiljö. Syftet med studien var att analysera hur AI-baserat beslutsstöd kan användas i personalplanering inom järnvägssektorn, men också att identifiera faktorer som möjliggör eller hindrar en sådan användning samt undersöka vilka ekonomiska och organisatoriska konsekvenser det skulle medföra. Studien genomfördes som en kvalitativ fallstudie baserad på en kombination av litteraturstudie och semistrukturerade intervjuer hållna med personalplanerare, trafikledningschefer samt personer med erfarenhet av AI-implementering. Task-Technology Fit användes som teoretiskt ramverk för att analysera hur väl de egenskaper AI har överensstämmer med de krav som personalplaneringen ställer. Resultaten visar att AI har potential att användas som beslutsstöd i samtliga planeringsfaser men att graden av uppgift-teknologianpassning varierar. Störst potential finns i korttidsplaneringen där preskriptiv AI baserad på Reinforcement Learning lämpar sig väl, medan prediktiva modeller passar bättre för taktisk planering med längre tidshorisonter. Vidare framgår det att AI kan bidra till mer transparenta och konsekventa beslut, vilket kan förskjuta målkonflikter i en mer fördelaktig riktning. Samtidigt finns det hinder i form av begränsad tillit till automatiserade beslut, datakvalitetskrav och höga implementeringskostnader. Sammantaget bidrar studien med empiriska insikter om hur AI-baserat beslutsstöd kan anpassas till olika planeringsfaser inom järnvägssektorn samt vilka organisatoriska och ekonomiska förutsättningar som krävs för att realisera dess potential.

Nyckelord: Artificiell Intelligens, Beslutsstöd, Järnvägsbranschen, Kapacitetsplanering, Resursallokering, Task-Technology Fit

Innehållsförteckning

1. Inledning.....	1
1.1 Bakgrund.....	1
1.1.1 Den svenska järnvägens utveckling	1
1.1.2 Behovet av beslutsstöd inom järnvägsbranschen.....	2
1.1.3 Konsekvenserna av bristande kapacitetsplanering.....	3
1.2 Problembeskrivning	3
1.3 Syfte	5
1.4 Task-Technology Fit Theory	5
1.5 Metod	8
1.5.1 Forskningsansats	8
1.5.2 Forskningsdesign	8
1.5.3 Insamling, analys och presentation av intervjuer.....	9
1.5.4 Insamling, analys och presentation av litteratur	11
1.6 Avgränsningar.....	11
1.7 Studiens kunskapsbidrag.....	11
2. Resultat och analys	13
2.1 Personalplaneringsprocessen	13
2.2 Utmaningar i dagens personalplanering.....	16
2.3 AI-modeller som beslutsstöd	19
2.3.1 Maskininlärning och prediktiva modeller	20
2.3.2 Reinforcement Learning och preskriptiv analys	23
2.3.3 Multiagentsystem.....	24
2.3.4 Probabilistiska modeller och bayesianska nätverk	25

2.3.5 Genetiska algoritmer och optimeringsbaserad schemaläggning	27
2.4 Empiriskt grundat perspektiv på potentialen med AI	27
3. Slutsatser.....	34
4. Källförteckning	37
Appendix.....	43
Appendix 1: Intervjuguide 1	43
Appendix 2: Intervjuguide 2	45
Appendix 3: AI-deklaration	46

1. Inledning

Detta kapitel introducerar studien genom att beskriva dess kontext samt artificiell intelligens potentiella roll som beslutsstöd i komplexa planeringsprocesser. Vidare redogörs studiens syfte, det teoretiska ramverket i form av Task-Technology Fit samt den metod som ligger till grund för genomförandet. Till sist beskrivs studiens avgränsningar och kunskapsbidrag.

1.1 Bakgrund

Det svenska järnvägsnätverket är under hög belastning. Delar av systemet har ett kapacitetsutnyttjande som resulterar i att även mindre störningar riskerar att eskalera och orsaka stora konsekvenser (Törnquist Krasemann, 2012; Wang et al., 2024). Under dygnets två mest trafikintensiva timmar är 34 procent av det svenska nätverket mättat, vilket innebär ett kapacitetsutnyttjande på 81–100 procent (Banverket, 2009). Ett mättat system får betydande konsekvenser för tågtrafiken, inte minst på grund av låg medelhastighet och hög störningskänslighet. En av anledningarna till den ökade belastningen är de intensifierade klimatutmaningarna och att järnvägstransport därtill anses vara ett transportalternativ med lägre klimatpåverkan än många andra alternativ.

1.1.1 Den svenska järnvägens utveckling

Det svenska järnvägsnätet utgör en central del av samhällets infrastruktur och präglas av ett ökat behov av effektivitet och robusthet. Det är en bransch under förändring och med höga krav från alla inblandade aktörer. Driften av järnvägsnätet och dess fordon var länge en helt statlig verksamhet. År 2001 splittrades den statliga myndigheten SJ i mindre delar och omvandlades till aktiebolag. Enligt Indén (2015) var detta första steget mot en liberalisering av svenska tågmarknaden. Nästa steg mot liberalisering togs 2009, när en lagändring avskaffade SJ:s monopol på de mest lönsamma tågsträckorna. Detta gjorde det möjligt för fler företag att bedriva tågtrafik i Sverige. Järnvägssektorn är sedan dess en bransch som är hårt pressad av konkurrens och kostnadseffektivitet. Inom sektorn avgör offentliga upphandlingar vem som får uppdraget att driva tågtrafiken. Företagen behöver därför en välfungerande personalplanering för att upprätthålla långsiktig kostnadsmässig konkurrens (Huisman et al., 2005; Nielsen, 2011; Törnquist Krasemann, 2012). Detta är särskilt relevant för att vinna anbud i offentliga upphandlingar. Det är även av allmänt intresse att driva kostnadseffektiv tågtrafik, eftersom majoriteten av trafiken finansieras med skattemedel och bidrar till ökad social hållbarhet. Ett attraktivt och långsiktigt hållbart järnvägssystem förutsätter hög säkerhet, god tillgänglighet, effektiv energianvändning samt tjänster med hög punktlighet. Samtidigt måste järnvägsnätet utnyttjas effektivt för att minimera kostnaderna. Detta ställer krav på en kontinuerlig avvägning mellan ett högt kapacitetsutnyttjande och en

tillräcklig robusthet i systemet för att minska sårbarheten för störningar och säkerställa stabil drift även vid oförutsedda händelser (Huisman et al., 2005; Nielsen, 2011; Törnquist Krasemann, 2012; Wang et al., 2024).

1.1.2 Behovet av beslutsstöd inom järnvägsbranschen

I praktiken har kapacitetsplaneringen inom järnvägsbranschen i stor utsträckning baserats på manuella processer, historiska data och yrkesmässig erfarenhet. Dessa metoder innebär dock begränsningar, framför allt när det gäller att hantera snabba förändringar och stora datamängder (Nielsen, 2011; Gestrelus, 2023). Johanna T. Krasemann (2012) har exempelvis genom sin studie visat hur kapacitetsrelaterade störningar i järnvägstrafiken kan hanteras genom metoder baserade på algoritmer för omplanering i realtid. Studien undersöker hur kapacitetsrelaterade störningar kan hanteras i situationer där beslut behöver fattas under osäkerhet, tidspress och begränsad tillgång till resurser.

Störningar i tågtrafiken är ett vanligt och omtalat problem där operativ planering präglas av frekvent omplanering (Törnquist Krasemann, 2012; Gestrelus, 2023; Wang et al., 2024). Förmågan att effektivt planera om trafiken i realtid är därför särskilt viktig. Utöver tidigare forskning har det vid initiala samtal med aktörer inom branschen framkommit att dagens manuella processer resulterar i en ökande, oönskad och kostnadsdrivande mängd overtid. Detta skapar tillsammans med ökade konkurrensrelaterade krav nya behov av tekniska lösningar för bättre kapacitetsplanering (Nielsen, 2011; Törnquist Krasemann, 2012; Gestrelus, 2023).

Ett potentiellt verktyg för att möta de nya behoven och utmaningarna är implementering av artificiell intelligens (Gestrelus, 2023; Asmar & Abu Al-Rob, 2024). Artificiell intelligens, hädanefter förkortat AI, kan definieras på många olika sätt. I följande studie definieras AI som teknologier och modeller som gör det möjligt för datorer att analysera information, dra slutsatser och anpassa sitt beteende genom inlärning (Asmar & Abu Al-Rob, 2024). Dessa teknologier uppvisar egenskaper som är förknippade med mänsklig intelligens och beteende, såsom förmågan att lära, vara målorienterade, lösa problem och anpassa sig till förändrade förutsättningar. Målet med AI kan även vara att simulera eller efterlikna mänsklig intelligens. I många fall handlar det om att utveckla förmågor och metoder som överträffar mänskliga kapaciteter, exempelvis vid hantering av stora och komplexa beräkningar (Monostori, 2019).

Inom både forskning och bransch finns ett tydligt växande intresse för att använda digitala och datadrivna beslutsstöd för planering och optimering inom järnvägssektorn (Huisman et al., 2005; Nielsen, 2011; Gestrelus, 2023; Wang et al., 2024). Trafikverket lyfter i sin forsknings- och innovationsagenda fram behovet av nya metoder för kapacitetsplanering, prognostisering och hantering av störningar, där AI och avancerad dataanalys pekas ut som centrala möjliggörare (Gustafsson, 2024). Särskilt betonas potentialen i att nyttja stora mängder historiska och realtidsbaserade data för att stödja operativa beslut och förbättra systemets effektivitet och robusthet. Detta indikerar att förutsättningarna och intresset för att

implementera AI-baserade beslutsstöd inom kapacitetsplanering redan finns etablerat på systemnivå (Nielsen, 2011; Gestrelus, 2023; Gustafsson, 2024).

1.1.3 Konsekvenserna av bristande kapacitetsplanering

För att förstå de konsekvenser som bristande kapacitetsplanering kan medföra kan exempel från närtiden studeras. Ett aktuellt sådant är situationen kring Mälartågen under perioden 2021–2024. MTR Mälartåg tog över driften av dessa tågsträckor i december 2021 och trafiksituationen präglades därefter av återkommande förseningar och inställda avgångar, både med kort varsel och som permanenta förändringar (Pfriem & Olausson, 2024). Övertagandet skedde till följd av att den tidigare operatören uppvisat liknande problem. Brist på personal pekades ut som den stora orsaken, men anställda vittnade i media om att det snarare var schemaläggningen som var bristfällig (Tångeberg, 2022; Johannesson, 2024). Trots åtgärder sades avtalet med MTR Mälartåg upp i förtid under våren 2024. Detta efter redan höga viteskostnader som påföljd, det vill säga ekonomiska sanktioner som järnvägsbolag kan åläggas vid exempelvis inställda avgångar eller allvarliga förseningar (Wickenberg, 2024). Därefter följde en nödupphandling av en ny operatör för tågtrafiken. Ett annat exempel där bristande system för personalplanering var orsaken till problem är den situation som uppstod hos SJ efter ett systembyte 2021 (Nyström, 2022). Det nya systemet hade funktioner som inte fungerade ordentligt, vilket resulterade i att personal saknades på tågen, avgångar ställdes in och att planering behövde genomföras manuellt. Enligt bolaget själva var problemen bland annat kopplade till en optimeringsfunktion som skulle effektivisera personalens arbetsscheman. Funktionen togs sedan bort när problemen uppstod. Dessa exempel visar att bristande kapacitetsplanering, inte minst av personal, kan få stora ekonomiska och organisatoriska konsekvenser. Det belyser även behovet av att utveckla arbetsprocessen inom personalplanering.

1.2 Problembeskrivning

Järnvägsbranschen präglas av strukturella och regulatoriska förutsättningar som ställer höga krav på hur resurser planeras och utnyttjas. Inom branschen finns det incitament att på ett kostnadseffektivt sätt balansera behov och tillgångar av resurser, däribland personal. Enligt SJ AB:s års- och hållbarhetsredovisning (2025) är detta för att undvika viteskostnader, dröjsmåls effekter, oövertidskostnader och minskat förtroende i kundrelationer till följd av bristsituationer. Det är även viktigt för att undvika höga kostnader till följd av outnyttjad kapacitet. På SJ AB stod personalkostnader motsvarande 4,5 miljarder kronor för 36 % av de totala kostnaderna under 2024. I och med personalkostnadernas stora andel av de totala kostnaderna, kan ett förbättrat resursutnyttjande av personal resultera i stora kostnadsbesparingar.

Personalplaneringen inom järnvägssektorn kännetecknas vidare av ett regelstyrkt system med begränsad flexibilitet. Spårnätets komplexitet och personalens geografiska omlopp skapar särskilda utmaningar för bemanningen av tåg. Bemanningen styrs av det omlopp som fordon och personal flödar i, vilket innebär att resurser förflyttas geografiskt under tiden som värdeskapandet sker. Dessutom tas det sällan hänsyn till variationer i efterfrågan vid kortsiktig planering, eftersom tidtabeller fastställs ungefär 2–14 månader i förväg utifrån prognostiserad efterfrågan (Trafikverket, 2024). Detta innebär att möjligheten att anpassa bemanningen efter kortsiktiga förändringar är begränsad, vilket ställer höga krav på planeringens robusthet.

Verksamheten för persontåg bedrivs i varierande omfattning hela året och alla tider på dygnet, vilket innebär ett ständigt behov av personal. Samtidigt styrs personalens arbetstid av kollektivavtal. Dessa utgör en ram för personalplanering genom att bland annat reglera ersättning, arbetstid och viloperioder. Exempelvis gäller för resande personal på SJ att en arbetsperiod inte får vara längre än 12 timmar i åkande verksamhet, att det krävs en viloperiod på minst 11 timmar mellan varje gång man arbetar och att en sammanhängande veckovila på minst 36 timmar måste förekomma varje vecka (SJ AB, 2024). Utöver kollektivavtalens regler behöver många arbetsgivare skapa en långsiktigt hållbar arbetsmiljö och inte bara uppfylla de avtalade minimikraven. Dessa aspekter bidrar således till en mer komplex personalplanering.

En ytterligare central utmaning i personalplaneringen är att små störningar snabbt kan få stora konsekvenser i tågens omlopp och det system de ingår i. Förutom att personal behövs för att praktiskt kunna bedriva verksamheten för persontåg, finns det även fastställda bemanningskrav som säkerställer en hållbar och säker tågtrafik i Sverige. Dessa krav, som i Sverige fastställs av Trafikverket, innebär en ökad sårbarhet för personalbrist och att vissa trafiksäkerhetsfunktioner måste vara uppfyllda beroende på vilken typ av färd som genomförs. Exempelvis är förare av tåget en obligatorisk funktion, vilket innebär att tåget inte kan avgå om denne inte infinner sig på rätt plats vid rätt tidpunkt (Cardell, 2020). På grund av det tidskänsliga omloppet i spårnätets komplexa struktur behöver man gardera sig mot händelser som dessa för att undvika försenade samt inställda avgångar. Detta kan exempelvis ske genom omfördelning av kapacitet över tid eller tillfällig kapacitetsanpassning, såsom övertidsarbete eller användning av tidsbegränsade anställningar (Jonsson & Mattsson, 2005). Detta innebär att hanteringen av operativa osäkerheter i praktiken bygger på åtgärder som medför ökade kostnader. Utöver de direkta kostnaderna kan förseningar också leda till missnöjda kunder. Undersökningar från SJ visar att nöjd-kund-index (NKI) minskar kraftigt vid förseningar på mer än fem minuter (Nelldal et al., 2022). Detta innebär också en ökad risk för minskade framtida intäkter om kunderna väljer en annan operatör eller ett alternativt färd sätt nästa gång. Bemanningen utgör därmed en kritisk faktor i systemet, där även mindre avvikelser snabbt kan få omfattande operativa och ekonomiska konsekvenser.

Personalplaneringen inom järnvägssektorn präglas alltså av ett komplext samspel mellan regulatoriska krav, operativ osäkerhet och motstridiga verksamhetsmål där dagens manuella

och erfarenhetsbaserade arbetssätt skapar en sårbarhet som blir särskilt påtaglig vid störningar och personalomsättning. Mot bakgrund av denna komplexitet väcks frågan om huruvida AI-baserade beslutsstöd kan bidra till att hantera dessa utmaningar på ett mer systematiskt och effektivt sätt vilket utgör grunden för denna studies syfte.

1.3 Syfte

Syftet med studien är att analysera hur ett AI-baserat beslutsstöd kan användas i personalplanering inom järnvägssektorn, med särskilt fokus på hur väl teknikens egenskaper överensstämmer med de krav som beslutsfattandet i planeringsarbetet ställer. Studien syftar även till att identifiera faktorer som möjliggör eller hindrar användningen av ett sådant beslutsstöd samt vilka ekonomiska och organisatoriska konsekvenser det skulle medföra.

Utifrån syftet har följande frågeställningar tagits fram:


- Hur kan AI användas som beslutsstöd i personalplanering inom järnvägssektorn och vilka faktorer skapar möjligheter respektive hinder för användning av AI i detta sammanhang?
- Hur väl passar ett AI-baserat beslutsstöd de krav som personalplanering inom järnvägssektorn ställer?
- Vilka ekonomiska och organisatoriska konsekvenser skulle det medföra att implementera och använda ett AI-baserat beslutsstöd för personalplanering inom järnvägssektorn?

1.4 Task-Technology Fit Theory

Task-Technology Fit Theory (TTF) är en teori inom informationssystemsforskning som används för att analysera hur väl en teknologi stödjer utförandet av specifika arbetsuppgifter. Teorin utgår från att ett informations- eller digitalt systems effekt på resultatet beror på hur väl teknologins funktioner stämmer överens med vad uppgiften kräver (Goodhue & Thompson, 1995). En hög grad av anpassning innebär att teknologin tillhandahåller funktioner som underlättar genomförandet av arbetsuppgifterna, vilket kan bidra till ökad effektivitet och förbättrade resultat.

För att förklara sambandet mellan teknologi, användning och prestation har Goodhue och Thompson (1995) utvecklat modellen Technology-to-Performance Chain som beskrivs visuellt i figur 1. Modellen kombinerar två sätt att förstå hur informationssystem påverkar prestation. Den första fokuserar på användningsperspektivet. Denna inriktning beskriver hur prestationseffekterna påverkas i en kedja av teknologiska egenskaper samt användarnas attityd och uppfattningar för att förutsäga användningen av informationssystem. Den andra fokuserar på att prestationseffekter uppstår i en kedja genom anpassningen av teknologin till uppgiften, utan att inkludera modellen för systemanvändning som förklaringsfaktor.

Kombinationen av de två ger en mer komplett bild av hur teknologier, användaruppgifter och användning hänger samman med förändringar i prestation.



Figur 1: Kedjan från teknologi till prestation

TTF betonar det faktum att teknologiers värde inte kan förstås isolerat från den kontext där de används (Furneaux, 2012). Samma teknologi kan ge olika resultat beroende på vilka uppgifter den används för samt hur arbetsprocesserna är organiserade. Teorin används även för att analysera varför vissa informationssystem skapar värde för en organisation men inte för en annan, trots att de implementeras på liknande sätt.


Forskare har med hjälp av TTF identifierat flera faktorer som påverkar graden av anpassning mellan teknologi och uppgift. Bland annat har kvaliteten på tillgänglig information, systemets tillförlitlighet, användarvänlighet och utbildningsstöd visat sig vara viktiga faktorer inom forskning om informationssystem och TTF (Goodhue & Thompson, 1995; Cane & McCarthy, 2009; Al-Rahmi et al., 2023). Dessa faktorer påverkar i sin tur hur teknologin används i praktiken och vilken effekt den får på organisationens prestation.

Studier har visat att värdet av AI i beslutsfattande är beroende av hur väl den valda teknologin är anpassad till uppgiftens krav och informationsbehov, vilket gör TTF mycket relevant för studier om AI som beslutsstöd (Goodhue & Thompson, 1995; Zigurs & Buckland, 1999; Al-Rahmi et al., 2023). Ofta talar man om kompatibilitet, vilket handlar just om hur väl tekniken passar den avsedda tillämpningen (Pumplun et al., 2019). Bättre kompatibilitet bidrar till större sannolikhet att tekniken används (Mishra & Pani, 2021). Om AI-teknologin är utformad för att hantera komplexiteten i en uppgift och har tillgång till relevant data kan det bidra till förbättrad informationsbearbetning och mer effektiva beslut. Enligt Technology-to-Performance Chain påverkas användningen av en teknologi av både graden av anpassning mellan teknologi och uppgift samt organisatoriska och sociala faktorer.

Dessa faktorer är exempelvis arbetsrutiner, erfarenhet och attityd (Goodhue och Thompson, 1995). Det innebär att både teknologins utformning och den kontext den används i är avgörande för om och hur systemet faktiskt används i praktiken, samt i vilken grad teknologin bidrar till prestationseffekter.

Task-Technology Fit utgör således studiens teoretiska ramverk och nyttjas för att analysera användningen av AI-baserade beslutsstöd inom kapacitetsplanering och resursallokering av personal i järnvägssektorn. AI-baserade system kan i sammanhanget bidra till att analysera stora datamängder och vara ett hjälpmedel för planeringen. Samtidigt är systemens effektivitet beroende av hur väl deras funktioner är anpassade till planeringsprocessens krav, organisatoriska rutiner och de mänskliga beslutsfattarnas behov. Genom att använda TTF som analytiskt perspektiv blir det möjligt att undersöka hur samspelet mellan arbetsuppgifter och AI-teknologi påverkar systemanvändning, beslutsstöds relevans och upplevd nytta inom kapacitetsplanering.

För att kunna analysera och beskriva användningen av AI-baserade beslutsstöd på ett relevant sätt har ramverket i figur 2 tagits fram av författarna. Beslutsfattande och planeringsprocessens egenskaper har adderats till Goodhue och Thompsons (1995) originalmodell. Anpassningarna av modellen har genomförts för att återspegla situationen som studien genomförs i. Beslutsfattande i denna studie avser operativa och planeringsrelaterade beslut som fattas av den personal som ska använda teknologin. Teknologins egenskaper har specificerats som AI:s egenskaper för att tydligare spegla studiens fokus på AI-baserade beslutsstöd. Det ger möjlighet att mer konkret analysera hur egenskaper så som krav på data och analyskapacitet påverkar anpassningen till uppgiften. Begreppet uppgift som återfinns i originalmodellen har konkretiserats som den analyserade delen av planeringsprocessens egenskaper. Detta för att möjliggöra analys av de specifika krav som kapacitetsplaneringen innefattar, så som komplex schemaläggning, realtidsförändringar och resursbegränsningar.



Figur 2: Teoretiskt ramverk

Ramverket i figur 2 beskriver hur egenskaper hos de olika stegen i planeringsprocessen och AI-teknologin simultant påverkar graden av uppgift-teknologi-anpassning. Denna anpassning utgör en central mekanism i modellen och påverkar både hur teknologin används, hur den

påverkar det operativa beslutsfattandet samt vilka prestationseffekter som uppnås. Vidare påverkar det operativa beslutsfattandet prestationseffekterna, samtidigt som prestationseffekterna i sin tur påverkar användningen av teknologin. Detta innebär att användning inte enbart är en konsekvens av anpassningen, utan även en konsekvens av tidigare resultat. Slutligen inkluderar modellen en återkopplingsloop där användningen påverkar beslutsfattandet, vilket speglar hur erfarenhet och lärande successivt kan förändra hur teknologin används och påverka hur beslut fattas i planeringsprocessen.

1.5 Metod

Följande avsnitt presenterar den metod som använts för att besvara studiens frågeställningar. Rapporten har en kvalitativ och abduktiv ansats och är genomförd som en fallstudie av företag 1. Den är baserad på både primärdata från intervjuer och primär- samt sekundärdata från litteratur.

1.5.1 Forskningsansats

En kvalitativ forskningsansats kan användas både för att förstå människors upplevelser, värderingar och beteende, samt komplexitet genom att fokusera på problem i sitt sociala sammanhang (Al Kilani & Kobzeiv, 2016). Dessutom möjliggör ett kvalitativt angreppssätt en djupare förståelse och analys av specifika fenomen, samt utveckling av teorier. Då syftet med studien är att undersöka hur AI kan användas som beslutsstöd i en verksamhet där både tekniska och mänskliga faktorer samverkar var en kvalitativ ansats därför lämplig. Vidare är järnvägsbranschen en mycket komplex verksamhet, vilket ökar behovet av data som möjliggör en djup förståelse och ytterligare stärker användandet av kvalitativa data.

Den abduktiva ansatsen innebär att man under analysen, likt en spiralrörelse, växlar mellan teoretiskt ramverk, litteratur och empiri (Blomkvist & Hallin, 2015). Detta växlande skapar en känslighet till det empiriska materialet då förståelse för empiri, litteratur och applicering av teori påverkas av ordningen vi tar till oss informationen. I denna studie användes det teoretiska ramverket Task-Technology Fit som ett verktyg för att analysera litteratur och empiriskt material. Under arbetets gång, efter initial insamling av data, justerades ramverket för att bättre kunna appliceras på studien. Dessutom möjliggjorde ytterligare litteratur och intervjuer analys av tidigare data på ett djupare plan. Studien har vuxit fram genom denna iterativa process som också gett en fördjupad förståelse i relation till studiens syfte.

1.5.2 Forskningsdesign

En fallstudie är en typ av studie där ett eller fler verkliga fall studeras med hjälp av olika typer av data (Blomkvist & Hallin, 2015). Både kvantitativa och kvalitativa data kan

användas och kombineras beroende på studiens syfte. Information samlas in via fallen för att utreda, förklara eller beskriva det fenomen som studien ämnar att hantera. Fallstudier genomförs systematiskt genom medvetna val av fall och datainsamlingsmetoder. Dessutom ger forskningsdesignen omfattande empiriskt material som fångar komplexiteten av verkliga sammanhang och möjliggör upptäckten av nya dimensioner.

En fallstudie lämpar sig väl när syftet är att undersöka, förklara eller beskriva. Metoden lämpar sig även då frågeställningarna ämnar besvara frågor som "varför" eller "hur". Då syftet är att besvara *hur* AI kan användas som beslutsstöd är det en relevant forskningsdesign för denna studie. Vidare beskriver Blomkvist och Hallin (2015) att det finns två sätt att välja fall, antingen väljs fallet baserat på tidigare forskning och teorier, eller baserat på tillgänglighet. Denna studie använde företag 1 som fallstudie baserat på det sistnämnda. Utöver det bedömdes företaget vara väl lämpat för studien eftersom det bedriver omfattande operativ verksamhet inom den svenska järnvägssektorn, där personalplanering utgör en central roll. Organisationen uttalade även en vilja att utveckla sina arbetssätt samt ett intresse för digitalisering och datadrivna beslutsstöd. Detta skapade goda förutsättningar för att undersöka både möjligheter och utmaningar med användning av AI inom företags personalplanering. Slutligen bedömdes företags storlek och organisatoriska komplexitet vara tillräcklig för att ge ett empiriskt material som speglar centrala utmaningar inom branschen, samtidigt som verksamheten är tillräckligt avgränsad för att möjliggöra en djupgående fallstudie. Detta stärker studiens analytiska generaliserbarhet även om en fallstudie aldrig kan resultera i statistisk generaliserbarhet.

1.5.3 Insamling, analys och presentation av intervjuer

Kvalitativa primärdata samlades in via intervjuer samt en litteraturstudie. Intervjumetodik är passande då det finns ett behov av djup förståelse för ett fenomen samt en vilja att förstå olika perspektiv och uppfattningar (Blomkvist & Hallin, 2015). Detta var, som tidigare nämnts, mycket relevant för denna studie.

Intervjuerna var semistrukturerade där respondenter med liknande kompetenser och uppdrag fick samma grundfrågor. Två olika intervjuguider användes som utgångspunkt under intervjuerna och innehöll grundfrågor samt potentiella följdfrågor som ställdes vid oklara, eller ofullständiga svar (se Appendix 1 och 2). Strukturen i datainsamlingen stärker studiens reliabilitet, samtidigt som flexibiliteten möjliggör en tydligare och mer fördjupad empiri (Blomkvist & Hallin, 2015). Den första intervjuguiden användes vid intervjuer med olika personalplanerare medan den andra användes vid intervjuer med respondenter som har tidigare erfarenhet av att implementera AI i liknande kontexter. Denna uppdelning tydliggörs i tabell 1.

Urvalet av respondenterna baserades på kompetens och tillgänglighet. Intervjupersonerna var avgränsade till företag 1 och gruppens kontaktnätverk, därav genomfördes intervjuer främst med anställda på företag 1. Flera personer med samma typ av kompetens intervjuades i grupp

för att ge fler perspektiv, till exempel två respondenter som arbetar med kortsiktig planering av personal. Kompletterande intervjuer med andra aktörer i branschen och personer med erfarenhet av AI-implementeringsprojekt genomfördes för att skapa en djupare förståelse för branschen, teknologi samt organisatoriska frågor. Respondenterna har alltså olika roller och kompetensområden som är relevanta för studiens syfte.

Samtliga intervjupersoner och företag har av sekretessskäl anonymiserats. Företag 1 och företag 2 är båda medelstora järnvägsaktörer inom offentlig persontrafik i Sverige. Företag 4 är en stor europeisk aktör inom samma sektor, med verksamhet både inom person- och godstrafik. Företag 3 är ett globalt konsultföretag verksamt inom management och IT-tjänstesektorn med fokus på digital transformation, systemutveckling och strategisk rådgivning. Företagens koppling till intervjuerna presenteras i tabell 1 nedan.

	Vem	Antal respondenter	Företag	Datum	Intervjuguide
1	Kortsiktiga personalplanerare	2	Företag 1	27/1	Intervjuguide 1
2	Trafikledningschef	1	Företag 2	20/2	Intervjuguide 1
3	Taktiska personalplanerare	1	Företag 1	24/2	Intervjuguide 1
4	Managementkonsult inom digitalisering	1	Företag 3	27/2	Intervjuguide 2
5	Realtidspersonalledare	2	Företag 1	2/3	Intervjuguide 1
6	Turkonstruktörer med särskild IT kunskap	2	Företag 1	5/3	Intervjuguide 1
7	Chef för algoritmutveckling inom operativ tågverksamhet	1	Företag 4	20/3	Intervjuguide 2

Tabell 1: Översikt av intervjuer

På grund av sekretessskäl spelades inga intervjuer med respondenter anställda på företag 1 in. Dessa kunde därför inte transkriberas, utan dokumenterades i stället genom att någon av studiens skribenter löpande förde anteckningar under intervjuerna. För att minimera risken för informationsförluster sammanställdes dessa direkt efter att intervjuerna genomfördes. Bristen på transkribering innebar trots det en viss svårighet i att fånga all information från respektive intervju samt återge exakta citat. Följaktligen är den empiri som baseras på intervjuer med anställda på företag 1 inte lika heltäckande som om inspelning och transkribering hade varit möjligt. Intervjuer på övriga företag spelades däremot in och transkriberades i efterhand. Genom att dokumentera intervjuerna möjliggjordes analys av den insamlade empirin i efterhand. Alla intervjuer analyserades tematiskt där informationen delades in i kategorier. En tematisk analys är att föredra då struktur är viktigt och för att enkelt kunna hitta likheter och skillnader (Blomkvist & Hallin, 2015).

Stor vikt lades vid att återge insamlade data så korrekt som möjligt för att minimera systematiska fel och felkällor. Det bör dock beaktas att även korrekt återgivna intervjuer inte kan antas återspegla objektiva beskrivningar av verkligheten. Exempelvis kan resultaten vara subjektivt färgade av respondentens personliga uppfattningar och oro kring förändrade

arbetsroller. För att hantera detta lades stor vikt vid att presentera intervjuresultaten som respondenternas egna uppfattningar snarare än som fakta. Samtidigt stärktes tillförlitligheten till intervjuresultaten då de i stor mån validerades mot litteraturen.

1.5.4 Insamling, analys och presentation av litteratur

Litteraturstudien är genomförd i syfte att beskriva bakgrunden till studien och formulera frågeställningar, men också för att lägga grund för teoretisk förankring samt möjliggöra djupare analys av empirin. Relevanta vetenskapliga artiklar hämtades via sökmotorer såsom Scopus, Google Scholar och ScienceDirect. Dessa särskildes genom sökord som artificiell intelligens, kapacitetsplanering, resursallokering samt Task-Technology fit. Utöver dessa inkluderades även organisatoriska och branschspecifika dokument så som årsredovisningar, myndighetsrapporter och kollektivavtal. Dessa bidrar till en mer heltäckande bild av de förutsättningar som präglar personalplanering inom järnvägssektorn, samtidigt som de vetenskapliga artiklarna i huvudsak bidrar med teori och tidigare forskning.

I stor utsträckning analyserades all litteratur genom en iterativ kvalitativ textanalys där centrala begrepp och teman identifierades och behandlades löpande under arbetets gång. Metoden valdes då den möjliggör en systematisk genomgång av textmaterialet genom strukturerad och aktiv läsning (Esaiasson m.fl., 2007). I en kvalitativ textanalys antas helheten av texten som läses skilja från summan av textens delar. Genom att läsa texten både översiktligt och ingående och successivt kategorisera materialet skapades en förståelse för textens innehåll och dess relation till övrigt material.

1.6 Avgränsningar

Studien avgränsades till att behandla kapacitetsplanering och resursallokering av personal inom järnvägssektorn. Både kortsiktiga och långsiktiga planeringshorisonter samt operativa och strategiska planeringsperspektiv har beaktats. Den geografiska avgränsningen begränsades till Sverige vilket motiveras av rapportens forskningsdesign och tillgång till empiriskt material. Vidare avgränsades studien till att enbart undersöka AI-teknologier och därmed analyseras inte andra tekniska lösningar för personalplanering. Ytterligare en avgränsning som gjordes var att studien inte undersökte hur den tekniska implementeringen ska gå till i praktiken. Exempelvis undersöktes inte vem som ska tillhandahålla eventuell AI-teknologi samt hur integration, drift och ansvarsfördelning ska hanteras.

1.7 Studiens kunskapsbidrag

Denna studie bidrar med ny kunskap genom att analysera hur AI kan användas som beslutsstöd för personalplanering inom järnvägssektorn. Tidigare forskning har i stor

utsträckning undersökt hur AI kan planera och optimera resurser, men tycks i mindre utsträckning ha undersökt hur AI specifikt kan användas som beslutsstöd i personalplaneringssyfte inom järnvägsbranschen. Studien bidrar vidare med empiriska insikter genom en fallstudie av ett företag i branschen. Fallstudien möjliggör en djupare förståelse för hur personalplanering faktiskt genomförs i praktiken och vilka utmaningar kapacitetsplaneringen ställs inför. Slutligen bidrar studien till att analysera ekonomiska och organisatoriska faktorer till följd av implementering av AI. Detta bidrar till en bättre helhetsbild av hur AI påverkar verksamheten.

2. Resultat och analys

Följande kapitel presenterar studiens resultat baserat på den genomförda litteraturstudien samt intervjuer tillsammans med en löpande analys av fynden. Kapitlet inleds med en kartläggning av nuläget, där nuvarande arbetssätt för personalplanering inom järnvägssektorn beskrivs och analyseras. Därefter introduceras AI som beslutsstöd, följt av en genomgång av relevanta AI-modeller med potential att tillämpas inom kapacitetsplanering och resursallokering. Avslutningsvis redogörs för AI:s potential som beslutsstöd. Eftersom studiens resultat indikerar att flera av de identifierade utmaningarna kan hanteras eller mildras tack vare viss anpassning analyseras de begränsande faktorerna ur flera perspektiv. Detta görs med utgångspunkt i studiens teoretiska ramverk, där stor vikt läggs vid att avgöra huruvida AI uppvisar god överensstämmelse med de specifika behov som beslutsfattandet inom personalplaneringen ställer.

2.1 Personalplaneringsprocessen

Följande processbeskrivning bygger på en hierarkisk ordning från Nielsen (2011) som är kompletterad med information från Jonsson och Virtala (2021). Denna information har även bekräftats genom personlig kommunikation med SJ AB. Dessutom har kompletterande bidrag från intervjuer adderats. Figur 3 utgör en visuell representation av planeringsprocessens olika faser i kronologisk ordning.



Figur 3: Översikt över planeringsprocessens faser

Den första fasen är strategisk planering, vilket innebär planering över flera år. Planeringen sker med lång tidshorisont på grund av de fördröjda effekterna som tillkommer med besluten. Exempel på sådana beslut kan vara utbildning, rekrytering eller uppsägning. En utbildning kan ta upp emot ett år och utgör därför en viktig aspekt att beakta vid personalplanering. Enligt en respondent från företag 1 som jobbar med personalplanering krävs minst två utbildningar per år för varje åkande personal. Samma respondent uppger att det genomförs en årlig grundlig planering utifrån schemagrupper och semesterallokering. Schemagrupper innebär att personalen är uppdelad i basgrupper som följer samma grundplanering, för att skapa en kontinuitet i planeringen. Här används prognoser för att kunna se när det är mest kostnadseffektivt att bevilja ledighet. Andra viktiga beslut som tas under denna planeringsfas kan vara att bestämma storlek på varje personaldepå. Det vill säga hur stor mängd reservpersonal ska finnas till hands vid eventuella störningar och vart denna personal geografiskt ska utgå ifrån. Detta indikerar att strategisk planering har en avgörande påverkan på hela systemets robusthet och kostnadsstruktur. Felaktiga beslut i detta skede kan få

långsiktiga konsekvenser, exempelvis i form av överkapacitet eller personalbrist. Utifrån studiens teoretiska ramverk innebär detta att ett beslutsstöd i denna fas behöver kunna hantera långsiktiga prognoser och osäkerhet, vilket ställer höga krav på datakvalitet och analysförmåga.

Den andra fasen är taktisk planering, som syftar till att skapa en generell grundplanering med en tidshorisont på några månader upp till ett år. I denna planeringsfas skapas turer. Turer är enskilda arbetspass för personal såsom lokförare eller ombordpersonal kopplade till en specifik avgång eller sträcka utifrån en given tidtabell (Jonsson & Virtala, 2021). Till en början är dessa turer anonyma, vilket betyder att det inte finns någon tilldelad personal till arbetspasset. Vid skapandet av grundplaneringen anpassas turerna efter personalens kompetens och tillgängliga resurser, vilket i detta fall är tåg. Flera respondenter från företag 1 har uppgett att detta kan göras med hjälp av ett befintligt optimeringsverktyg. Målet är att skapa turer med så få avbrott som möjligt och med få byten mellan olika linjer. Detta för att öka effektiviteten och bygga robusta scheman. Det är dessutom viktigt med tanke på personalens arbetstimmar, då avtal och regler finns för hur många timmar personalen får arbeta. Grundplaneringen är vanligtvis ett år lång men anpassas månadsvis till banarbete och trafikändringar. Enligt en respondent från företag 1 kan dessa månadsvisa anpassningar även innefatta sjukskrivningar, utbildningar eller semester som har sökts med kort varsel. Respondenten uppger även att prognosmöten hålls varje månad för att se över rekryteringsbehovet. Vidare är helgdagar viktigt att ta hänsyn till, då dessa ändrar resenärernas resmönster och påverkar efterfrågan. Detta visar att taktisk planering innebär en avvägning mellan flera mål där effektivitet, robusthet och regeluppfyllnad måste balanseras samtidigt. Planeringen baseras dessutom på prognoser, vilket innebär att den alltid innehåller en viss grad av osäkerhet. Detta ökar risken för att scheman senare behöver justeras, vilket flyttar komplexitet och arbetsbelastning till de mer operativa planeringsstegen.

Nästa fas är korttidsplanering som har en tidshorisont på några dagar upp till några veckor. I denna fas fördelas personal till de anonyma turerna. Det är därför viktigt att schemat har justerats efter helgdagar och trafikstörningar på rätt sätt i tidigare faser. Schemaläggningen måste även här anpassas efter avtal, regler och personalens kompetens. Det är dessutom korttidsplaneringens uppgift att hantera obalanser i schemaläggningen. Det kan handla om för mycket eller för lite schemalagd personal. En respondent från företag 1 som jobbar med korttids- och daglig planering uppger att de då behöver ringa runt till personal för att byta och flytta arbetspass. Att planerare behöver ringa runt för att lösa schemaändringar innebär att beslutsfattandet sker utan en samlad överblick över alla tillgängliga alternativ, eftersom arbetssättet kan leda till att första tillgängliga lösning väljs i stället för den mest optimala. Det är först efter att samtliga relevanta samtal är gjorda som man kan utvärdera alla möjliga alternativ. Planerare kan även ta hjälp av åkande personals enstaka ledighetsdagar för att omfördela personal vid obalanser i schemat eller vid oplanerad frånvaro. Enligt respondenten behöver korttidsplaneringen också hantera frånvaro som sjukskrivningar, vård av barn och ledigheter. Dessa arbetsuppgifter sker i nuläget manuellt. Korttidsplanerare genomför även manuella kontroller bakåt i tiden för att identifiera personal som ska ha ersättning och

komensation för övertid. Detta innefattar även att kontrollera vilken personal som har genomfört sina utbildningar. Den manuella hanteringen i detta skede visar att stora delar av planeringsprocessen fortfarande är beroende av ett tidskrävande och erfarenhetsbaserat arbetssätt. Samtidigt kännetecknas korttidsplaneringen av att förändringar ofta sker med kort varsel, vilket innebär att besluten måste fattas snabbt och under tidspress. I kombination med ett manuellt arbetssätt försämras förmågan att säkerställa att den bästa lösningen väljs, då tiden och informationen som finns tillgänglig är begränsad. Detta leder till att planeringen i hög grad blir reaktiv där fokus ligger på att lösa akuta problem snarare än att optimera helheten.

I daglig planering är målet att lösa problem som uppkommer på kort varsel. Dagliga planeringen har en tidshorisont på ett fåtal dagar. Arbetsuppgifterna innefattar att underhålla schemat och fylla i vakanser som uppstått på grund av sjukdom eller annan frånvaro. Dessa problem kan hanteras genom att ändra arbetstider för annan personal. Detta görs på samma sätt som i korttidsplaneringen, alltså att planerare ringer runt till personal för att lösa schemaändringar.

Sista fasen är realtidsplanering, som innefattar att identifiera störningar under pågående drift, vidta lämpliga åtgärder samt övervaka tidtabellen i realtid. Denna del av planeringen har en stor direkt påverkan på trafikflödet och syftar till att omplanera schemat vid oförutsägbara händelser då det inte längre är möjligt att genomföra arbetet enligt plan. I intervjuerna med de operativa planerarna framkom det att vid oväntade händelser utgår arbetet från en prioriteringslista som är upprättad efter kostnadseffektivitet. I första hand kontrolleras tillgången på reserver, det vill säga befintliga personalresurser som snabbt kan bokas in. Denna redundans finns dock inte alltid, men möjliggör snabba lösningar när den är tillgänglig. Därefter kontrolleras möjligheten att använda timanställda, förutsatt att de är tillgängliga. I nästa steg sker en omprioritering av personals befintliga scheman, vilket innebär att personal omfördelas eller att arbetspass justeras för att täcka upp behovet. Som sista utväg används övertid, vilket lyftes i samtliga intervjuer med företag 1.

För att hantera komplexiteten i dagens personalplanering används digitala och integrerade planeringssystem. Ett vanligt planeringssystem är IVU, vilket är ett komplett och integrerat system för planering av personal och fordon. Syftet är att kunna hantera järnvägsföretagens komplexa uppgifter genom att översätta verksamheten till ett helt digitalt arbetsflöde. I detta digitala arbetsflöde kan alla verksamhetsdelar integreras, från planerare till lokförare. Med IVU vill man optimera fordonsanvändning, säkerställa att personal befinner sig på rätt plats vid rätt tidpunkt och lagra all data i ett och samma system (IVU, u.å.). Trapeze är ett annat system som används för planering av både personal och fordon. Till skillnad från IVU är Trapeze inte enbart anpassat efter järnvägssystem, utan används även inom buss, färdtjänst och annan kollektivtrafik. Detta gör Trapeze mindre specialiserat för järnväg, men mer flexibelt i multimodala trafikmiljöer. Funktionerna inkluderar flexibel och automatiserad schemaläggning, avancerad arbetspassplanering samt scenariobaserad planering som utvärderar regler och avtal för att hitta kostnadseffektiva lösningar (Trapeze, u.å.). För att förstå hur liknande komplexitet hanteras i andra branscher kan planeringssystem inom

exempelvis flygindustrin studeras. Dessa präglas av liknande utmaningar, såsom komplexa regelverk, störningshantering och resursbegränsningar, men har i större utsträckning integrerat AI i traditionell optimering. Ett exempel är Jeppesen, som utvecklar avancerade planeringssystem där AI kombineras med optimering. Genom funktioner som kalibrering, används historiska data och maskininlärning för att kunna placera buffertar på rätt ställen och balansera avvägningar mellan kostnad och andra mål (Jeppesen, 2026).

Personalplaneringssystemen har olika egenskaper men utgör alla en central del i att hantera komplexiteten inom personalplanering. En del system har kommit längre med att implementera AI vilket förändrar deras förmåga att fungera som ett avancerat beslutsstöd.

Sammantaget framkommer det att planeringsprocessen i stor utsträckning är manuell. I de tidiga faserna skapas mer generella och anonyma scheman vilket innebär en högre grad av flexibilitet. Men ju närmare genomförandet man kommer desto mindre flexibilitet finns det. Samtidigt ökar komplexiteten vilket leder till en högre användning av manuella justeringar, vilket belyser en central utmaning i planeringsprocessen.

2.2 Utmaningar i dagens personalplanering

Intervjuerna har visat att det på företagsnivå finns olika huvudutmaningar i personalplaneringen bland aktörerna, men även på avdelningsnivå inom företagen.


Respondenten som är trafikledningschef på företag 2 berättar att deras största utmaning är kollektivavtalen samt förhandlingar med fackförbund inom järnvägsbranschen. Till skillnad från företag 2 beskriver en kontaktperson på företag 1 att deras största utmaning är att få ner övertidskostnader, till följd av att personal tvingas arbeta längre än schemalagd tid. Dessa två företag har alltså olika huvudutmaningar, även om företag 1 instämmer att kollektivavtal är en stor utmaning även för dem. På samma sätt finns skillnader i utmaningar även inom företagen. En respondent på företag 1 som arbetar med korttidsplanering och daglig planering uppger att deras största utmaning är alla ändringar som behöver genomföras med kort varsel för att verksamheten ska fungera. Detta problem är en orsak till att man behöver använda övertid. En annan respondent på företag 1, som jobbar med taktisk planering, upplever inte att övertid är ett återkommande problem på dennes avdelning. Respondenten uppger i stället att personalbrist på grund av semesterledighet, föräldraledighet och olika kompetenskrav är en större utmaning att lösa. De viktigaste faktorerna skiljer sig alltså beroende på vilket perspektiv man har.

Kollektivavtal och fackliga regler begränsar inte bara arbetstider och viloperioder, utan påverkar även hur personalstyrkan måste dimensioneras. Järnvägsbranschen präglas av strikta kollektivavtal och den starka fackliga ställningen bidrar till stor praktisk påverkan på planeringen. Denna påverkan bekräftas även i intervjuer med både företag 1 och företag 2, där respondenterna återkommande lyfter kollektivavtal och fackliga regler som en stor del av planeringsarbetet. Flera respondenter från företag 1 beskriver hur dessa regler inte endast fungerar som riktlinjer, utan som tydliga begränsningar som måste beaktas i varje beslut. Detta minskar flexibiliteten i planeringen. Samtidigt framhåller flera respondenter att fackets

roll inte enbart bör ses som en begränsning. Regler kring arbetstid, vila och arbetsbelastning lyfts som centrala för att säkerställa en hållbar arbetsmiljö för personalen. Enligt kollektivavtalet ska exempelvis varje åkande personal vara ledig varannan helg. I en situation där det på vardagar finns behov av 20 personer per dag, medan det på helger finns behov av 15 personer, innebär det att det behöver finnas 30 anställda totalt. Således behövs en större personalstyrka än det maximala dagsbehovet. Vidare är det inte tillåtet att anställa personal enbart för helgarbete, vilket medför att bemanningen måste dimensioneras utifrån regelverk snarare än faktisk efterfrågan. Detta försvårar möjligheten till optimering. Samma respondent förklarar även vikten av att samverka med facket. Detta kan i vissa fall innebära att planeringen behöver justeras, exempelvis vid utbildningstillfällen där flera medarbetare måste närvara. Samtidigt finns ett visst utrymme för flexibilitet genom kompromisser. En turkonstruktör kan exempelvis, i samråd med fackliga företrädare, planera så att en anställd arbetar något längre en dag i utbyte mot kortare arbetstid en annan dag. Detta illustrerar att personalplaneringen inte enbart handlar om att minimera kostnader, utan också om att upprätthålla rimliga arbetsvillkor.

En annan faktor som påverkar kostnadseffektiviteten negativt i planeringsprocessen är den stora andelen manuellt arbete. Under intervjuer med företag 1 framkom att många justeringar som sker med kort varsel görs manuellt. Enligt en respondent från korttidsplaneringen kan det innefatta att ringa personal för att byta arbetspass och sedan manuellt göra ändringarna i systemet. En förklaring till det omfattande manuella arbetet är enligt intervjuerna att personalen inte har kunskap om hur man använder det befintliga optimeringsverktyget. Ytterligare en potentiell orsak är den organisatoriska frågan kring teknisk kompetens. Utan den tekniska kompetensen i företaget är det svårt att använda befintliga verktyg, men även att implementera nya verktyg som en del av arbetsprocesserna. En vidare möjlig förklaring till det manuella arbetet är graden av erfarenhetsbaserad arbetsrutin, vilket bekräftas av flera respondenter från företag 1. Erfarenhetsbaserad arbetsrutin kan innebära att personal har svårt att acceptera nya arbetsrutiner och hellre arbetar som de alltid har gjort. Dessutom uppger respondenterna att man fortfarande vill kunna kontrollera de datadrivna besluten manuellt, eftersom tillit saknas.

I samtliga intervjuer med personalplanerare på företag 1 lyfts avvägningar och beslut som en stor del av personalplaneringsarbetet. Detta innebär att planerare dagligen ställs inför situationer där möjliga handlingsalternativ kan medföra både för- och nackdelar. Besluten måste bidra till verksamhetens mål, exempelvis kostnadseffektivitet. Samtidigt ska det säkerställas en tillfredsställande arbetsmiljö för de anställda och en tillräcklig robusthet i systemet för att kunna lösa de många oväntade händelser som kan uppstå. Målkonflikten mellan robusthet, kostnad och arbetsmiljö illustreras i figur 4, där en förbättring av en av dem ofta sker på bekostnad av de andra.



Figur 4: Målkonflikten mellan kostnad, arbetsmiljö och robusthet


Det är avgörande att kunna säkerställa viss flexibilitet i personalplaneringen, samtidigt som det motstrider de effektivitetsmål som tågoperatörer strävar mot (Nielsen, 2011). Högre grad av robusthet, exempelvis genom att ha stora reserver av personal eller större marginaler i schemalaggnings, bidrar till en ökad förmåga att hantera störningar. Samtidigt innebär detta att resurser ofta inte utnyttjas fullt ut, vilket ger ökade kostnader. På liknande sätt beskriver respondenter från företag 1 att en god arbetsmiljö ofta ställer krav på ökad bemanning eller mer komplexa ändringar. Detta då en god arbetsmiljö exempelvis innebär arbete på varierande sträckor, flexibla arbetstider och genomtänkta scheman, vilket också driver kostnader. Omvänt innebär en stark kostnadsoptimering att resurser utnyttjas mer effektivt, men sker ofta på bekostnad av både robusthet och god arbetsmiljö för personal. Sammantaget innebär detta att det sällan är möjligt att optimera alla tre mål samtidigt och beslutsfattandet inom personalplanering bör i stället förstås som en balansering av dessa.

Sammanfattningsvis visar de identifierade utmaningarna att personalplanering inom järnvägssektorn präglas av en hög grad av komplexitet, där flera motstridiga mål och begränsningar måste hanteras simultant. Med utgångspunkt i TTF ger detta upphov till specifika krav på ett AI-baserat beslutsstöd. Målkonflikter mellan kostnad, robusthet och arbetsmiljö innebär att ett beslutsstöd behöver ha förmåga att hantera flera optimeringsmål parallellt, snarare än att optimera mot ett enskilt mål. Ett system som enbart minimerar kostnader riskerar således att generera lösningar som är tekniskt optimala men praktiskt oanvändbara, eftersom de inte tar hänsyn till robusthet eller personalens arbetsmiljö. Vidare indikerar det faktum att utmaningarna skiljer sig åt beroende på planeringsnivå att ett generellt beslutsstöd sannolikt inte kan uppnå hög uppgift-teknologianpassning i samtliga delar av organisationen. Korttidsplaneringens behov av snabba omprioriteringar under tidspress skiljer sig från den taktiska planeringens behov av robusta prognoser över längre tidshorisonter. Detta talar för att ett AI-baserat beslutsstöd behöver vara anpassat efter den specifika planeringsfasen. Dessutom utgör den utbredda avsaknaden av tillit till automatiserade beslut som framkommit i intervjuerna en organisatorisk förutsättning som påverkar i vilken grad ett beslutsstöd faktiskt kommer att användas i praktiken. Detta är

oberoende av hur väl det tekniskt är anpassat till uppgiften. Dessa krav utgör en viktig referenspunkt för den efterföljande genomgången av AI-teknologier med potential att tillämpas inom kapacitetsplanering och resursallokering.

2.3 AI-modeller som beslutsstöd

AI kan användas som beslutsstöd i operativa processer genom att analysera stora datamängder och generera underlag för beslut. Inom flera verksamhetsområden, däribland Supply Chain Management, har AI visat potential att förbättra noggrannhet och effektivitet i beslutsfattandet (Asmar & Abu Al-Rob, 2024). Kunskapsbaserade AI-teknologier kan dessutom integrera regelstyrda begränsningar i beslutsprocessen, vilket är särskilt relevant i personalplanering där exempelvis kollektivavtal och kompetenser måste beaktas. Det finns flera olika typer av AI-modeller som kan användas som beslutsstöd. I en AI-teknologi är dessa modeller ofta representerade av enheter som kallas agenter. En agent avser en mjukvaruenhet som kan utföra uppgifter samt ta beslut baserat på fördefinierade kriterier och indata (Zehang et al., 2025). Modellerna kan vidare delas in i olika kategorier och familjer av algoritmer, där figur 5 ger en översikt på hur de modeller som beskrivs i avsnittet är relaterade till varandra.



Figur 5: Översikt av AI-modeller

2.3.1 Maskininlärning och prediktiva modeller

Maskininlärning är en grupp av algoritmer som möjliggör identifiering av mönster och som en AI-teknologi kan byggas av. En maskininlärningsalgoritm är en beräkningsprocess som använder den data som matas in i maskinen för att utföra en uppgift, utan att vara explicit programmerad för att resultera i något specifikt (El Naqa & Murphy, 2015). Algoritmerna har förmågan att automatiskt anpassa och förändra sin struktur genom upprepning. Detta gör att de successivt blir bättre på att nå det önskade målet. Processen där algoritmen anpassas kallas för träning, där exempel på indata presenteras tillsammans med de önskade målen.


Algoritmen förbättrar sig på ett sätt som blir optimalt för att producera det önskade målet för den data som ingår i träningen, samt för att kunna generalisera och producera enligt målen för nya och tidigare osedda data.

Inom järnvägssektorn har prediktiva modeller använts för att exempelvis stödja optimerad tilldelning av lokförare, där maskininlärningsalgoritmer så som Random Forest har visat sig väl lämpade för att generera tillförlitliga prediktioner som kan användas som beslutsstöd (Brezulianu et al., 2023). Random Forest användes för att analysera data om exempelvis förarnas trötthet, avstånd till avgångsplats och tillgänglighet. Modellen beräknar sannolikheten att en specifik förare bör tilldelas ett uppdrag. Den föraren med högst sannolikhet rekommenderas därefter för tilldelning.

Prediktiva modeller kan användas för att skapa statistiska modeller över framtida beteenden och händelser, där AI kan integreras för att tillföra intelligent beteende (Mejri et al., 2025). Målet med maskininlärning är att imitera eller efterlikna hur människor lär sig att bearbeta signaler för att uppnå ett mål. Detta kan exempelvis innebära att skilja mellan olika grupper av objekt genom mönsterigenkänning. I stället för att explicit programmera maskinen med exakta exempel kan den programmeras för att lära sig särskilja objekten genom upprepad exponering av de olika objekten. Detta kallas även för övervakad inlärning, där träningen på inmatade data kopplas till en känd klassificeringsetikett. Detta möjliggör för algoritmen att hantera likheter och olikheter, även när en grupp av objekt har många varierande egenskaper men ändå har grundläggande attribut som identifierar dem (El Naqa, I., Murphy, M.J., 2015). Det leder även till ett tillförlitligt underlag för beslut inom planeringen och minskar antalet manuella bedömningar som behöver göras av personalen inom planeringen.


Random Forest är en kombinationsbaserad maskininlärningsalgoritm. Algoritmen består av en samling trädstrukturerade klassificerare och kombinerar flera beslutsträd för att generera en gemensam prediktion. Detta möjliggör hög precision vid prediktioner och klassificeringar. Modellen bygger på att ett stort antal beslutsträd konstrueras, där varje träd tränas oberoende av varandra med hjälp av slumpmässiga variationer i den data den tränas på. Den kännetecknas av att slumpmässiga variabler väljs vid varje nod där trädet delas, vilket minskar korrelationen mellan träden och förbättrar modellens generaliseringsförmåga. Random Forest uppvisar hög klassificeringsnoggrannhet, robusthet mot brus och avvikande värden samt har låg tendens till överanpassning när antalet träd ökar (Pious et al., 2024).

Figur 6 illustrerar hur ett dataset behandlas i flera beslutsträd, vars individuella prediktioner därefter kombineras till ett slutgiltigt resultat.



Figur 6: Random Forest-algoritmer


En annan algoritm som är vanligt förekommande i prediktiva modeller för tillståndsbedömning och klassificering inom järnvägssektorn är Gradient Boosted Decision Trees. Den kan hantera olika typer av data och används för såväl prediktion som klassificering. Det är en integrerad algoritm där flera beslutsträd kombineras sekventiellt. Varje nytt träd tränas för att justera de fel som tidigare träd gjort, vilket görs genom att minimera en förlustfunktion. Den prediktiva modellen uttrycks som summan av de enskilda trädens funktioner. Förlustfunktionen beskriver skillnaden mellan det observerade värdet och modellens prediktion, vilket innebär att modellen iterativt justeras för att minska felet (Wen et al., 2023). Detta innebär exempelvis att modellen kan identifiera tillståndsförändringar eller avvikelser i ett järnvägssystem och därigenom stödja beslut om vilka komponenter som bör prioriteras för underhåll. Figur 7 visar hur nya beslutsträd adderas i varje iteration, där varje träd bidrar till att minska den totala förlustfunktionen.



Figur 7: Gradient Boosted Decision Trees

Denna typ av prediktiva modeller används exempelvis i datadrivna ramverk för prioritering av underhåll, där både teknisk tillgångsstatus och passagerarpåverkan vägs in (Consilvio et al., 2024). Dessa tillgångars tillstånd kan bland annat bedömas utifrån degradering och risk för fel, samtidigt som påverkan på resenärer uppskattas utifrån trafikbelastning och antal berörda passagerare. Detta innebär att olika faktorer kan vägas samman i beslutsprocessen på ett strukturerat sätt, vilket kan bidra till mer konsekventa prioriteringar i planeringen och ett minskat behov av manuella och individuella bedömningar.

Ytterligare en vanligt förekommande maskininlärningsalgorithm är artificiella neurala nätverk. Ett artificiellt neuralt nätverk (ANN) är ett system bestående av ett stort antal starkt sammankopplade bearbetningsenheter (Shobika et al., 2023). Dessa enheter är organiserade i olika lager bestående av ett indatalager, ett eller flera dolda lager samt ett utdatalager, där data bearbetas stegvis genom nätverket (Qamar & Zardari, 2023). Enheterna är dessutom organiserade i ett mönster inspirerat av hjärnans hjärnbark och kan användas för att koda och avkoda data (Shobika et al., 2023). Denna algorithm kan därför användas för att lösa problem som traditionella datorer har svårt att hantera. Användningen av ANN sker särskilt i tillämpningar där stora datamängder och komplexa samband förekommer. Kapacitetsplanering och resursallokering av personal inom järnvägssektorn är en sådan tillämpning. Figur 8 visar en representation av ett ANN samt hur algoritmen i sina lager tar givna indata och identifierar komplexa samband med hjälp av bearbetningsenheterna för att generera resultat.



Figur 8: Neurala nätverk

ANN kan användas i utveckling av ett beslutsstödsystem för olika typer av transport. I en kontext med transportsystem kan ANN användas för att hantera avvikelser, där modellen visar god förmåga att identifiera mönster i komplexa data (Gorbachev et al., 2021). I dessa system används ANN för att hantera avvikelser från planerade scheman, så som förseningar eller störningar i trafiken. Förmågan att modellera komplexa samband gör ANN särskilt


användbara i beslutsstödsystem. Mönster i data kan med ANN identifieras automatiskt, exempelvis återkommande förseningar eller andra avvikelser från tidtabeller. Det kan underlätta hantering av störningar genom att ge beslutsfattare stöd i att identifiera orsaker och välja lämpliga åtgärder, samt minska behovet av manuella analyser.

Sammanfattningsvis visar tidigare forskning att träd-baserade metoder såsom Random Forest, Gradient Boosted Decision Trees samt neurala nätverk alltså är särskilt lämpade för prediktiva uppgifter inom infrastruktursystem. Dessa teknologier möjliggör datadriven prognostisering och kan därmed utgöra en grund för AI-baserade beslutsstödsystem inom kapacitetsplanering och resursallokering.

2.3.2 Reinforcement Learning och preskriptiv analys

Reinforcement Learning (RL) innebär att systemet lär sig genom interaktion med omvärlden och återkoppling från tidigare beslut, vilket används för att successivt förbättra dess beslutsfattande (Littman, 2015; Szepesvári, 2010). RL är särskilt lämplig vid sekventiella beslutsproblem där varje handling ger effekter på lång sikt (Szepesvári, 2010). Ett sådant exempel är vid kapacitetsplanering och resursallokering inom järnvägssektorn, där en förändring på ett tåg påverkar efterföljande trafik och resursanvändning. En förstudie av Gestrelus och Ranjbar (2023) om Trafikverkets organisation undersöker möjligheterna att använda RL som beslutsstöd för operativ lokstyrning inom godstrafik. Förstudien visar att implementering av RL är tekniskt genomförbart i denna kontext genom att modellera problemet som ett sekventiellt beslutsproblem. Modellen som föreslås innefattar lok, tåg och verkstäder representerade genom noder i en grafstruktur och möjliga kombinationer mellan resurser som kanter. Agentens uppdrag består av att vikta dessa kombinationer. Detta indikerar att samma modellstruktur potentiellt kan appliceras på personalplanering. I ett sådant fall skulle personal betraktas som resurser inom en motsvarande grafbaserad representation av beslutsproblemet.

De senaste decennierna har stora framsteg inom RL bland annat inkluderat utveckling inom generalisering och planering. Detta har ökat möjligheten att tillämpa teknologin på verkliga problem, exempelvis vid planering av trafikflöden i järnvägssystem. Figur 9 illustrerar hur RL fungerar genom ett samspel mellan agent och omgivning. Vid varje tidpunkt befinner sig systemet i ett visst tillstånd, vilket representerar den aktuella situationen. Baserat på detta tillstånd väljer agenten en handling, som påverkar omgivningen. Omgivningen svarar sedan genom att övergå till ett nytt tillstånd och ge en återkoppling i form av en belöning som indikerar hur bra handlingen var. Denna information används av agenten för att successivt lära sig vilka handlingar som leder till önskade resultat över tid. Processen upprepas iterativt, vilket gör att agenten kan förbättra sitt beslutsfattande baserat på tidigare erfarenheter.



Figur 9: Reinforcement Learning


RL kan även tillämpas som hjälpmedel för att dynamiskt planera om tågtidtabeller (Ning et al., 2019). Med ett sådant hjälpmedel kan den genomsnittliga totala förseningen för alla tåg längs järnvägslinjen minskas. Den lärande agenten är baserad på RL och ansvarar för att justera körtider, uppehållstider och avgångssekvenser, samtidigt som den parallellt löser konflikter. RL kan även, genom ett utvecklat system med flera agenter, flexibelt lösa uppgifter kring planering inom järnvägssektorn (Schneider et al., 2024). Detta visar att systemet möjliggör automatisering och optimering av den dynamiska planeringen, vilket kan ge högre kapacitet och kvalitet.

Preskriptiv analys syftar inte bara till att förutsäga framtida tillstånd, utan även till att rekommendera konkreta åtgärder i en beslutssituation (Lepenioti et al., 2021). RL kan ses som ett verktyg för att möjliggöra preskriptiv analys, givet att tekniken kan hantera dynamiska och osäkra miljöer där beslut tas sekventiellt över tid. En typisk sådan miljö är ett järnvägsnätverk, där förutsättningar konstant förändras. Tillsammans med mänsklig återkoppling kan ett system baserat på RL optimeras utifrån exempelvis prioriteringsregler, operativa riktlinjer eller mänskliga önskemål. Detta innebär att delar av arbetet med omplanering vid störningar, såsom att identifiera och utvärdera alternativa lösningar kan automatiseras. Systemet kan generera och jämföra olika alternativ baserat på tidigare erfarenheter och historiska data. Det kan vara konkreta förslag på resursallokering eller prioriteringsordningar för beslut. I stället för att manuellt hitta, konstruera och bedöma möjliga lösningar kan planeringspersonalen därmed få beslutsstöd som redan är optimerat utifrån definierade mål.

2.3.3 Multiagentsystem

Ett multiagentsystem är ett system som använder sig av en grupp sammankopplade och autonoma agenter (Li et al., 2025). Dessa strävar efter att uppnå ett gemensamt mål genom samarbete eller konkurrens. Agenterna kan även samverka genom att dela kunskap med varandra. I ett sådant system modelleras besluten som en miljö där varje agent observerar ett lokalt tillstånd, väljer en handling och får återkoppling i form av en belöningsignal

(Schneider et al., 2024). Genom denna interaktion kan agenterna gemensamt optimera ett övergripande systemmål. De olika agenterna har vanligtvis förmågan att anpassa sig till förändrade förhållanden och agera utifrån aktuell situationsinformation (Li et al., 2025). Dessa egenskaper möjliggör i princip realtidsbaserad kommunikation och beslutsfattande mellan fordon i ett system, en teknik som beskrivs som gynnsam hos autonoma fordon (Chen et al., 2023). Autonoma fordon kan liknas vid ett järnvägsnätverk och dess aktörer, där båda är komplexa system med frekventa förändringar i omgivningen. Figur 10 beskriver skillnaden mellan singel- och multiagentsystem. I figuren syns hur varje agent har egen information, men i ett multiagentsystem interagerar de även med de andra agenterna i systemet.



Figur 10: Singelagentsystem och multiagentsystem

Genom att kombinera multiagentsystem med RL kan lösningen delas upp i flera autonoma agenter, där varje agent representerar ett tåg, i stället för ett singelagentsystem som hade representerat och kontrollerat alla tåg samtidigt (Schneider et al., 2024). Detta kan förenkla skalning av lösningen från en modell till ett verkligt system. Det möjliggör dessutom en flexibel omplanering vid störningar, eftersom varje agent kan anpassa sitt beteende utan att hela systemet behöver beräknas om från grunden. I praktiken innebär detta att alternativa lösningar kan genereras och justeras stegvis i systemet. Detta minskar behovet av att planera manuellt vid en förändring eller att ett singelagentsystem hade tvingats till omfattande och tidskrävande omberäkningar. I en motsvarande lösning baserat på ett multiagentsystem för kapacitetsplanering och resursallokering kan varje agent representera en schemagrupp, en slutstation i nätverket eller till och med en individ.

2.3.4 Probabilistiska modeller och bayesianska nätverk


Probabilistiska modeller kan beskrivas som ett ramverk för att hantera osäkerhet, något som tidigare presenterade AI-modeller ofta bortser från. De tidigare modellerna utgår ofta från att indata är relativt säker medan planeringssituationen i praktiken präglas av osäkerheter, exempelvis kring efterfrågan, förseningar eller resursers faktiska tillgänglighet.

Probabilistiska modeller utgår i stället från att osäkerhet är en grundläggande del av lärande och beslutsfattande. En central aspekt är att modelleringen explicit hanterar denna osäkerhet genom att kvantifiera graden av osäkerhet i de prognoser som genereras. Detta är särskilt relevant i komplexa system där beslutsfattande influeras av ofullständig information och stor variation i förutsättningar. Lärande kan beskrivas som en process där systemet försöker hitta rimliga förklaringar till den data det observerar. Eftersom flera olika förklaringar i många fall är möjliga finns det en osäkerhet kring vilken modell som är mest korrekt. När ny information tillkommer justeras därför systemets tidigare antaganden. Det som först var en uppskattning baserad på tidigare kunskap uppdateras i takt med att nya data observeras, på så sätt kan modellen stegvis förbättra sina bedömningar och bli mer precis över tid (Ghahramani, 2015).

Bayesianskt nätverk är en typ av probabilistiska modeller som är särskilt användbara när data är osäker, ofullständig eller när kausala samband är viktiga att modellera. Algoritmen används för att representera och analysera osäkerheten samt hur de olika variablerna är beroende av varandra. Ett bayesianskt nätverk består av ett riktat acykliskt grafnätverk, där varje nod representerar en variabel och varje länk beskriver ett sannolikhetsbaserat beroende mellan variablerna. Strukturen gör det möjligt att formalisera hur olika faktorer påverkar varandra inom ett system. En viktig funktion är möjligheten att uppdatera sannolikheter när ny information tillkommer. Detta sker genom Bayes sats:

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$$

Detta gör att modellen dynamiskt och kontinuerligt kan justera sina bedömningar i takt med att nya observationer görs (Mihaljević, 2021). Det innebär även att osäkerhet exempelvis kring personalfrånvaro eller förseningar kan kvantifieras och uppdateras när ny information tillkommer. Detta skapar ett mer strukturerat sätt att hantera osäkerhet, i stället för att helt förlita sig på mänskliga uppskattningar och bedömningar. Figur 11 visar ett bayesianskt nätverk och hur de villkorliga sannolikheterna i dessa är sammanlänkade och representerar osäkerheter i varje steg.



Figur 11: Exempel på ett bayesianskt nätverk där tillhörande sannolikheter representeras genom villkorliga sannolikhetsstabeller

2.3.5 Genetiska algoritmer och optimeringsbaserad schemaläggning

Genetiska algoritmer är populationsbaserade, heuristiska optimeringsmetoder inspirerade av det naturliga urvalet. I modellerna är varje möjligt utfall representerat av en "kromosom", där exempelvis resurskrav och prioritet är kodade. En funktion utvärderar varje möjlig lösning baserat på kriterier som exekveringstid, resursanvändning och hur väl varje lösning uppfyller de givna målen. De bästa lösningarna väljs och kombineras iterativt genom genetiska operatorer, såsom selektion och mutation, för att generera förbättrade lösningar (Mohammed et al., 2024). De förbättrade lösningarna kan vara mer effektiva kombinationer av resurser och tidsplaner.

I system där uppgifter med olika resurskrav och deadlines ska schemaläggas i realtid uppstår utmaningar kopplade till varierande arbetsbelastning och resurstillgång (Mohammed et al., 2024). Genetiska algoritmer kan hantera detta genom att generera, utvärdera och förbättra schemalägningslösningar. En sådan algoritm kan därmed anpassa sig till förändringar, hantera flera uppgifter med olika deadlines och optimera flera mål samtidigt. Detta skapar ett system med förmåga att förbättra prestanda, skalbarhet och effektiv resursallokering. Vidare innebär det att alternativa scheman kan genereras och jämföras automatiskt. För en personalplanerare innebär det att behovet av manuell konstruktion och bedömning av alternativ minskar, särskilt i komplexa situationer med många begränsningar.

2.4 Empiriskt grundat perspektiv på potentialen med AI

Utifrån de AI-modeller som presenterats i avsnitt 2.3 och de möjligheter och utmaningar som uttryckts i intervjuerna kan ett antal kopplingar mellan specifika modeller och planeringsutmaningar urskiljas. För att förstå AI:s faktiska potential krävs en analys som både beaktar dess möjligheter och begränsningar, där graden av anpassning mellan teknologi och uppgift varierar beroende på vilken planeringsfas som analyseras.

Intervjuresultaten visar att det finns potential att förbättra den befintliga planeringsprocessen med AI. Samtidigt lyfts farhågor kring dess förmåga att hantera de komplexa krav som personalplaneringen ställer. Samtliga respondenterna framhåller att AI kan bidra till en mer datadriven och effektiv planeringsprocess. En möjlighet som lyfts är AI-teknologiers förmåga att generera alternativa lösningar i det komplexa planeringsarbetet. Variabler som kompetenser, trafiksäkerhet, kollektivavtal och kostnadseffektivitet behöver alla tas i beaktning samtidigt. Detta ställer höga krav på AI-teknologin. Respondenterna från företag 1 uttrycker en oro kring om AI kan hantera och väga samman ett stort antal variabler på ett tillförlitligt sätt. En av respondenterna ställer sig även frågande kring om AI kan generera felaktiga eller missvisande resultat genom så kallade hallucinationer. Detta innebär att systemets förmåga att hantera regelstyrda begränsningar som kollektivavtal och trafiksäkerhetskrav är avgörande för graden av uppgift-teknologianpassning. Ett system som genererar lösningar som strider mot dessa krav eller som inte kan förklara varför ett visst beslut rekommenderas kommer sannolikt inte att användas i praktiken. Detta gäller oberoende av hur tekniskt sofistikerat det är. Behovet förstärks således eftersom personalplanerare fortsatt bör ha det yttersta ansvaret för de beslut som fattas samt att AI-rekommendationer bör granskas kritiskt.

Respondenterna med ansvar över realtidsplanering beskriver ett behov av att snabbt kunna ta fram och jämföra olika handlingsalternativ vid eventuella störningar. I dessa beslut behöver flera olika variabler vägas in. De lyfter att de i flertalet situationer har svårt att komma vidare i sina analyser och ser fördelar med att få förslag av AI. Samma problem och fördelar lyfts av respondenterna som arbetar med korttidsplanering. Resultaten indikerar att användning av preskriptiv AI baserad på RL (Reinforcement Learning) inom korttids, daglig och realtidsplanering är ett potentiellt hjälpmedel för beslutsstöd. Detta eftersom en sådan AI-modell har förmågan att generera förslag på alternativa planeringslösningar. Användning av genetiska algoritmer kan också motiveras av resultaten från dessa intervjuer. Genetiska algoritmer är som tidigare presenterat heuristiska optimeringsmetoder. Respondenten som arbetar med algoritmutveckling inom operativ tågverksamhet på företag 4 framhåller dock heuristiska metodens egenskaper som otillräckliga vid krav på snabba lösningar och de uppvisar därför en låg uppgift-teknologianpassning.

RL-algoritmens förmåga att successivt förbättra sitt beslutsfattande baserat på återkoppling från användarna är särskilt värdefull. Det möjliggör att systemet gradvis anpassas efter organisationens specifika prioriteringar och kan därmed bidra till ökad tillit över tid. Användning av RL kan således bidra till en positiv förstärkande effekt av prestationseffekterna, eftersom den tekniska algoritmen som används i RL förbättras via interaktion med användaren. För att på bästa sätt kunna realisera värdet av en RL-algoritm kan denna kombineras med multiagentsystem och bayesianska nätverk. Dessa kan bidra till att skapa en effektiv algoritm där endast nödvändiga omberäkningar genomförs, samt hantera den osäkerhet som planeringsprocessen innefattar. Uppgift-teknologianpassningen bedöms vara hög för denna planeringstyp, då uppgiftens karaktär, bestående av sekventiella beslut under tidspress med många variabler, överensstämmer väl med vad RL är kapabel till. Ur ett

målkonfliktperspektiv är detta särskilt relevant eftersom korttids- och realtidsplanering är de faser där avvägningen är som mest akut. Dagens manuella hantering av dessa situationer resulterar ofta i övertid som kortsiktig lösning vilket driver kostnader utan att nödvändigtvis stärka robustheten. Ett RL-baserat beslutsstöd kan därmed bidra till att synliggöra fler handlingsalternativ samtidigt, vilket skapar bättre förutsättningar för att hitta lösningar som balanserar alla tre mål snarare än att använda övertid.

Ett möjligt hjälpmedel för mer långsiktig planering är prediktiva modeller. Under intervjun med respondenten som arbetar med taktisk planering på företag 1 framkom att det idag finns en optimeringsfunktion för mer långsiktig planering. Denna skapar i många fall extra arbete, snarare än förenklar planeringsarbetet. Det framkom även att en stor del av arbetet innefattar prognoser och beräkningar av olika slag, där de flesta baseras på historiska data och egna erfarenheter. Även denna respondent uttryckte en positiv inställning till att använda AI för att effektivisera och optimera sitt arbete. Maskininlärning och prediktiva modeller kan användas för att ta fram datadrivna prognoser som i mindre utsträckning är beroende av mänsklig erfarenhet och som förbättras över tid mot önskade mål. Uppgiftens karaktär i den taktiska fasen kännetecknas av ett stort behov av prognoser över längre tidshorisonter, där historik kring exempelvis sjukfrånvaro, semestermönster och trafikbelastning utgör indata. Prediktiva modeller är utformade för att identifiera mönster i denna typ av strukturerade historiska data. Således överensstämmer teknologins egenskaper väl med uppgiftens krav. Detta eftersom mer träffsäkra prognoser direkt påverkar möjligheten att planera bemanningen mer exakt. En effektivare bemanning kan i sin tur bidra till minskade kostnader genom ett reducerat behov av överkapacitet i form av reservpersonal och reaktiv övertid.

Respondenten från företag 2 ser också potential i att använda AI för att strukturera och analysera lösningar. AI kan minska den tid som idag läggs på manuella analyser och därmed effektivisera arbetet. Många av dessa analyser och beslut baseras som tidigare nämnt i stor utsträckning på mänskliga erfarenheter, vilket kan leda till variation i beslutsfattandet. Genom att använda AI som beslutsstöd kan beslutsunderlaget bli mer konsekvent och transparent, samtidigt som den mänskliga bedömningen fortsatt kan användas för att hantera situationer där kontextuell förståelse är avgörande. Detta är även betydelsefullt ur ett organisatoriskt perspektiv. Den erfarenhetsbaserade arbetsrutin som framkommit i intervjuerna innebär att mycket planeringskunskap idag är personbunden och därmed svår att överföra. En AI-teknologi som synliggör och strukturerar beslutsunderlag kan därmed bidra till att göra denna tysta kunskap mer explicit och tillgänglig för hela organisationen, vilket minskar sårbarheten vid exempelvis personalomsättning bland planerare.

Intervjuer med respondenter från företag 1 belyser vikten av mänsklig kontroll och att endast människor kan ta hänsyn till mjuka värden och önskemål, även om de är positiva till att använda AI för att väga för- och nackdelar mellan olika alternativ. Med mjuka värden avses de faktorer som inte på ett enkelt sätt kan kvantifieras eller kodas som data. Exempel på detta kan vara individuella önskemål, relationer och välmående hos individer. Respondenter från företag 1 förklarar vidare att väl avvägda beslut kräver förståelse för hur verksamheten fungerar. De betonar även behovet av ett grundläggande tänk kring kostnadseffektivitet,

trafiksäkerhet och logistik samt hur dessa påverkas av besluten som tas. Genom att implementera AI finns en risk för att personalplanerare får ett ökat beroende av de AI-genererade lösningarna. Ur ett långsiktigt perspektiv kan detta ge en minskad egen analysförmåga och ett sämre helhetstänk. En respondent lyfter att åkande personal potentiellt kan få minskad tillit till personalplanerarna om de använder AI-optimerade scheman i stället för manuellt och personligt anpassade scheman. I dagsläget finns en värdefull relation mellan planerare och åkande personal, där den åkande personalen har stor tillit till att personalplanerarna har deras individuella preferenser i åtanke när schemaändringar genomförs. En annan respondent uppger att det kan beskrivas som en relation där kompromisser är vanligt förekommande. Tjänster och gentjänster utbyts alltså mellan planerare och åkande personal, eftersom det finns en gemensam vilja att hjälpa till. Hela organisationen behöver därmed ha en förståelse för AI, vilken roll den spelar och hur den kommer påverka de anställda eftersom de behöver lita på AI-teknologin vid beslutsfattande (Makarius et al., 2020). Människans tillit till AI kan vara svår att bygga upp eftersom AI inte upplever känslor. Dessutom beror den upplevda tilliten på graden av förståelse för tekniken (Keding, 2021). För organisationer utgör de informella relationerna ett socialt kapital som är svårt att värdera ekonomiskt men som har en direkt påverkan på verksamhetens robusthet. När personal ställer upp utöver vad som är avtalat bygger det på en ömsesidig tillit som riskerar att undermineras om schemaläggningen upplevs som opersonlig och automatiserad. Detta är en utmaning som varken är teknisk eller ekonomisk till sin natur utan handlar om hur AI-implementeringen kommuniceras och förvaltas organisatoriskt.

Kollektivavtal och fackliga begränsningar ställer krav på att en AI-teknologi kan hantera ett stort antal hårda restriktioner. Personalplaneringen innefattar som tidigare nämnt ibland att kompromissa med facket kring deras krav. AI är enligt respondenten från företag 2 inte redo att ta hänsyn till eller genomföra sådana kompromisser vilket utgör en potentiell utmaning vid införande av AI. Respondenten konstaterar detta eftersom företag 2 tidigare genomfört tester med ett AI-baserat system. De såg att systemet gjorde avsteg från fackliga krav i samtliga fall, inte bara när en lösning krävde kompromisser. Testet genomfördes dock för länge sedan och det kan finnas mer lämpade system för uppgiften idag. En annan utmaning som samma respondent lyfter är att automatiserade system saknar förmågan att agera mänskligt i de situationer där det krävs. Som tidigare nämnt förs en kontinuerlig dialog mellan personalplanerare och de fackliga företrädarna där man gemensamt kan komma överens om mindre avvikelser från kollektivavtalen i särskilda situationer. Detta skapar ett förhandlingsutrymme som bygger på ömsesidig tillit och situationsanpassad bedömning. Ett automatiserat system saknar förmågan att föra denna typ av dialog eller att känna av när en kompromiss är rimlig och önskvärd. Genom att analysera dessa faktorer förstår man att detta påverkar uppgift-teknologianpassningen mellan AI och beslutsstöd inom personalplaneringen negativt.

Data, dess infrastruktur och kvalitet spelar en avgörande roll för hur AI kan användas som beslutsstöd inom personalplanering. Det kan vara en möjliggörande faktor men vid brister ge upphov till betydande utmaningar. En av utmaningarna är att det krävs stor volym data

eftersom det direkt påverkar AI-applikationens prestanda (Afiouni, 2019; Wang et al., 2019). Vidare är det nödvändigt att data är av god kvalitet för att kunna göra pålitliga prediktioner (Alsheibani et al., 2018). En respondent från företag 4 menar att bra och rena data av god kvalitet är ett krav för att kunna använda den och fatta välgrundade beslut. Några utmaningar kopplade till data som respondenten lyfter är datapolicys, statliga regleringar, säkerhetskrav, manuellt inskrivna data och informella data. Vissa data skrivs in manuellt, vilket kan ge upphov till felaktigheter. Vidare förklarar samma respondent att en del data endast återfinns ostrukturerat hos enskilda medarbetare. Det kan exempelvis handla om att en specifik körsträcka har stängts av, utan att denna förändring har dokumenterats formellt då den anses vara allmänt känd i verksamheten. Detta kan skapa problem när en AI-teknologi ska användas för att optimera körningen, eftersom systemets rekommendationer då riskerar att bygga på ofullständig eller inaktuell information. Vidare förklarar respondenten från företag 3 att datatillgänglighet är en grundförutsättning för att AI ska fungera. Respondenten berättar även att informationsälgande är viktigt men att det är något organisationer inte alltid beaktar, vilket gör ansvarsfrågan kring data svår.

Ytterligare en utmaning kopplat till data, som många företag med en önskan att implementera AI möter, är datapolicys och General Data Protection Regulation (GDPR). Det är en aspekt som respondenterna både från företag 3 och 4 berättar att man behöver ta hänsyn till. Data inom ett företag är enligt respondenten från företag 3 i många fall lagrad i silos, indelade efter funktion. Personliga data är således ofta lagrade i en silo kopplad till HR. Respondenten diskuterar att denna silo i sådana fall är starkt skyddad av GDPR vilket begränsar möjligheterna att träna AI på all relevant data. Begränsningar i att nyttja personliga data kan innebära att AI-teknologin inte når sin fulla potential. Ett alternativ för att hantera problemet är enligt respondenten från företag 3 att skapa en stängd och kontrollerad miljö som tillåter AI-teknologin att bearbeta viss konfidentiell information utan att riskera informationsläckage. Detta kan medföra både tekniska och ekonomiska utmaningar. Tidigare forskning visar att implementering av AI i miljöer där konfidentiella data behöver behandlas, ofta medför betydande kostnader kopplade till exempelvis säkerhetsåtgärder, dokumentation och efterlevnad av regelverk (Nørregaard Jørgensen et al., 2025). I personalplaneringen hanteras personlig information om anställda i stor utsträckning och kostnaderna för en eventuell AI-implementering skulle således kunna bli särskilt höga.

Respondenterna med särskild IT-kompetens på företag 1 lyfter att planeringsrelaterade data i deras system lagras i strukturerade databaser. Därifrån finns det möjlighet att exportera data till strukturerade filer, så som excel och csv. Detta indikerar att det hos företag 1 finns en grundläggande datainfrastruktur som stödjer bearbetning av data med hjälp av AI, vilket tyder på god kompatibilitet. Detta leder till en ekonomisk fördel i form av resursbesparing, eftersom mindre tid behöver spenderas på att förbereda data. Det möjliggör i sin tur för träning, integrering och användning av de AI-teknologier som identifierats i studien, så som prediktiva och preskriptiva modeller. Dessa resonemang tyder på att förutsättningarna för en hög grad av anpassning mellan AI-teknologi och uppgift stärks, då tillgången till

strukturerade data är en viktig faktor för väl fungerande AI-teknologier. Däremot kvarstår hindren kopplade till datapolicys.

Ett perspektiv som är viktigt att ta hänsyn till vid implementering är AI-teknologins integration med befintliga system. Detta kan vara särskilt utmanande i organisationer där befintliga system är komplexa eller bygger på äldre tekniska lösningar. Samtidigt visar exempel från flygindustrin, så som Jeppesens lösning med maskininlärning, att AI kan integreras i liknande planeringsmiljöer. Detta indikerar även att det kan finnas goda möjligheter att framgångsrikt implementera motsvarande lösningar i system som IVU och Trapeze, trots de tekniska och ekonomiska utmaningar integrationen kan medföra.

Respondenten från företag 3 menar att en hel del stora företag redan har en väl fungerande data-infrastruktur för deras verksamhet på plats, men att den inte nödvändigtvis är lämpad för AI. Respondenten betonar förändringsledning som centralt för en lyckad implementering samt att implementering och integration behöver vara situationsanpassad. Det är viktigt att ha ett strukturerat tillvägagångssätt där man tar hänsyn till affär, människor och teknik samtidigt. Enligt respondenten från företag 4 måste man dessutom bygga ett robust datasystem, vilket betyder att man tar höjd för osäkerhet och att systemet ska klara ändringar och små justeringar utan att planeringen behöver göras om. Detta kan exempelvis innebära att systemet behöver kunna hantera ändringar som sjukfrånvaro, utan att omfattande manuella justeringar behövs göras. För att implementera AI i ett befintligt system som möter kraven på robusthet, krävs det enligt respondenten investeringar i både tid och pengar. Respondenten menar att dessa faktorer gör det viktigt att ha stöd från högsta ledningen för att få tillgång till de resurser som krävs. Tillgängliga resurser så som ekonomiska medel och medarbetare med teknisk kompetens är en förutsättning för att kunna implementera en AI-teknologi (Pumplun et al., 2019). För att kunna dra största möjliga nytta av implementeringen bör företaget dessutom utveckla en AI-strategi som förklarar hur implementering och adoption ska ske (Keding, 2021). Denna strategi måste stämma överens med företagets övriga existerande mål. Detta understryker att implementeringen av AI inte bara är en teknisk fråga utan också en ekonomisk och organisatorisk utmaning som kräver kompetens, resurser och inte minst tid.

Respondenten från företag 3 som har jobbat med AI-implementering hos flera företag förklarar att medarbetares syn på AI skiljer sig mellan olika företag. En del anställda är väldigt entusiastiska medan andra är fientligt inställda vilket antingen underlättar eller försvårar införandet av AI. I intervjuerna med personalplanerare på företag 1 nämner de anställda flertalet möjligheter men också potentiella risker med att involvera AI i arbetet, vilket stärker resonemanget om att en del är positivt inställda och andra inte. Till exempel menar en respondent att ökad AI-användning skulle minska behovet av personalplanerare. På sikt hade detta kunnat påverka flexibiliteten i organisationen negativt, exempelvis genom färre möjligheter till ledighet och svårare att hantera sjukfrånvaro bland planerare. Däremot kan det ha en ekonomisk positiv effekt då kostnadsbesparingar kan göras när färre anställda krävs. Detta illustrerar en viktig avvägning vid AI-implementering, där ekonomiska vinster av ett minskat personalbehov inom planering måste vägas mot den organisatoriska sårbarheten som uppstår om kompetensen och kapaciteten tunnas ut. En organisation som

reducerar sin planeringspersonal alltför snabbt riskerar att förlora den personbaserade kompetensen och de informella relationerna som idag utgör en kritisk del av planeringsarbetet och som en AI-teknologi inte kan ersätta fullt ut. Således finns det både argument för och emot införande av AI inom företag 1.

En ekonomisk faktor som kan driva införande av AI är konkurrenstryck, det vill säga hur en organisation påverkas av och agerar i förhållande till sina konkurrenter (Alsheibani et al., 2020). Hotet av att förlora en konkurrensfördel blir därför en motivation för adoption av tekniska innovationer, så som AI. Konkurrenstrycket inom järnvägssektorn utgör således en extern drivkraft som ökar incitamenten att omsätta AI i praktisk tillämpning. Detta följer av att en mer kostnadseffektiv personalplanering direkt stärker förmågan att vinna offentliga upphandlingar. Samtidigt innebär detta att organisationer som avstår från att implementera AI kan hamna i ett konkurrensmässigt underläge i takt med att andra aktörer i större utsträckning effektiviserar sina processer. Även om anpassningen mellan teknologi och uppgift inte är perfekt, kan externa faktorer såsom marknadskrav driva på användning och implementering av AI.

För att ett AI-baserat beslutsstöd ska kunna bidra till förbättrad personalplanering inom järnvägssektorn krävs att utmaningar kring data, ekonomi och organisation hanteras parallellt snarare än sekventiellt. Tekniska brister i datakvalitet driver upp kostnader, höga kostnader minskar organisationens vilja att investera och en tveksam organisation skapar sämre förutsättningar för den användning som krävs för att realisera nyttorna. Resultaten indikerar att graden av anpassning mellan teknologi och uppgift mellan de olika planeringsfaserna där preskriptiv AI har högst potential i korttids- och realtidsplanering, medan prediktiva modeller passar bättre för taktisk planering. Samtidigt är nyttorealiseringsen beroende av hur organisatoriska, tekniska och ekonomiska utmaningar hanteras. AI kan bidra till att förskjuta målkonflikten mellan kostnad, robusthet och arbetsmiljö i en mer fördelaktig riktning, men endast om implementeringen tar hänsyn till både tekniska möjligheter och mänskliga begränsningar.

3. Slutsatser

Syftet med studien var att undersöka hur AI kan användas som beslutsstöd i personalplanering inom järnvägssektorn. Tidigare forskning har visat att järnvägssystem är känsliga med komplexa problem kopplade till resursallokering och kapacitetsplanering, vilket intervjustudien förstärker. AI definieras i studien som teknologier som möjliggör för datorer att analysera information, dra slutsatser och anpassa sitt beteende genom inlärning. Studien har utgått från Task-Technology Fit för att undersöka hur väl de presenterade AI-modellernas egenskaper överensstämmer med de krav som de olika stadierna i planeringsprocessen ställer. För att kunna applicera TTF som analytiskt verktyg skapades en variant av ramverket anpassad till just beslutsfattande inom personalplanering. Studien synliggör i vilka faser av planeringsprocessen AI har som störst potential att skapa prestationseffekter och vid vilka faser AI implementering möter begränsningar.

Studiens resultat visar att AI bör användas som beslutsstöd som kompletterar, snarare än ersätter, mänskligt beslutsfattande. Enligt respondenterna så präglas beslutsfattandet av tyst kunskap, där situationsanpassade bedömningar och olika önskemål kan behöva tas hänsyn till. AI kan inte väga in dessa faktorer på samma sätt som en människa kan, eftersom de sällan går att spara som strukturerad data. Att ta hänsyn till personalens preferenser har visat sig vara en viktig del av uppgiften och dessa brister hos AI visar på en sämre uppgiftsteknologianpassning utifrån TTF. Det är därför av stor vikt att AI-teknologin som används är väl anpassad för att stödja den typ av beslutsfattande som förekommer i det aktuella steget av planeringsprocessen.

AI-baserade beslutsstöd måste anpassas till både organisation och planeringsnivå, vilket även skapar potential för konkurrensfördelar. Aktörerna inom branschen behöver hantera olika typer av problem. Därmed måste beslutsstödet anpassas till respektive företag. Även inom företagen skiljer sig problemen inom personalplanering då den strategiska planeringen präglas av andra problem än vad korttidsplaneringen gör. Detta innebär att graden av anpassning mellan AI-teknologi och uppgift varierar beroende på vilken del av planeringsprocessen som analyseras, vilket medför att samma lösning inte kommer kunna implementeras på alla nivåer inom organisationen. Denna komplexitet innebär dock inte ett hinder, utan snarare en möjlighet att skapa konkurrensfördelar genom mer effektiv personalplanering och således kostnadsbesparingar. Därigenom ökar chanserna att vinna de ofta förekommande offentliga upphandlingarna. Branschen präglas av högt konkurrenstryck och pressade marginaler, vilket innebär att förmågan att planera personal mer effektivt än konkurrenterna dessutom kan vara avgörande för ett företags långsiktiga överlevnad på marknaden. Detta kan utgöra tillräcklig drivkraft för att hitta den specifika lösning som ger företaget en effektivare planeringsprocess.

AI har potential att användas som beslutsstöd i samtliga faser av planeringsprocessen, där den största potentialen finns i korttidsplaneringen. Litteraturen visar att de mer avancerade preskriptiva AI-teknologierna möjliggör hantering av komplexa beslutsproblem där många variabler behöver vägas samman. Dessa problem är vanligast förekommande vid planering på

kortare sikt, där AI:s förmåga att analysera komplexa beslutsunderlag kan bidra till att effektivt stödja beslutsfattandet. Ju kortare den aktuella planeringshorisonten är, desto större nytta kan en AI implementering göra. Detta kan förklaras av skillnader i planeringsprocessens egenskaper, där korttidsplanering präglas av hög komplexitet och tidspress vilket leder till att värdet av avancerade AI-teknologier ökar. En AI-teknologi som kan hantera ökade krav är däremot mer komplex och kostnadskrävande. Därför riskerar kostnaderna att överstiga nyttan vid användning av AI i daglig och realtidsplanering. I dagens personalplanering utnyttjas inte det befintliga optimeringsverktyget inom taktisk planering i full utsträckning. Detta indikerar att det finns en risk att en potentiell AI-teknologi inte heller skulle användas till sin fulla potential, om inte denna är väl anpassad till planeringsprocessens egenskaper. Det är därför viktigt att AI implementeras där alla tre faktorer är uppfyllda: potential, kostnadseffektivitet och uppgift-teknologianpassning. Resultaten indikerar att detta skulle vara fallet vid användning av en preskriptiv AI-teknologi i korttidsplaneringen.

AI minskar beroendet av individbaserad kunskap inom resursallokering och kapacitetsplanering, genom att möjliggöra datadrivet beslutsfattande. Detta visar hur teknologins egenskaper möjliggör hantering av uppgifter som annars är svåra att lösa manuellt. Användningen av en väl tränad och implementerad AI-modell kan generera beslut oberoende av individers erfarenhet, vilket minimerar risken att kunskap försvinner när personal lämnar företaget. AI-teknologier kan även bidra med både transparens och spårbarhet. Besluten kan med AI i ännu större utsträckning analyseras, ifrågasättas och förbättras över tid. Detta kan påverka både enskilda beslut, men även bidra till en mer standardiserad och datadriven planeringsprocess. Man kan således skapa bättre förutsättningar för hur organisationen utvecklas och kunskap förs vidare.

AI kan försämra arbetsmiljön för den åkande personalen om mjuka värden inte integreras i optimeringen. Detta sker om den optimerar mot definierade mål för kostnadseffektivitet inom ramen för kollektivavtalets regler. Det kan i sin tur leda till att facken ställer högre krav vid kommande förhandlingar. En sådan utveckling skulle minska planeringsutrymmet och samtidigt öka komplexiteten i planeringsprocessen.

Effektiviseringar av planeringsprocessen med AI kan skapa betydande ekonomiska effekter i form av minskat behov av tidskrävande justeringar och bättre resursutnyttjande. I stället för att upprätthålla redundans genom stor mängd reservpersonal och andra kostsamma åtgärder, kan AI upprätthålla robusthet genom en förbättrad planeringsförmåga. En AI-implementering skulle däremot kräva stora initiala investeringskostnader. Dessa kostnader är delvis relaterade till behovet av att AI-teknologi och övriga system är anpassade till varandra och företagets organisation. Dessutom behöver vald AI-teknologi kunna skydda persondata i enlighet med GDPR och andra dataskyddsregler. Vid lyckad implementering av AI kan de resulterande besparingarna ur ett långsiktigt perspektiv att väga upp för de initiala kostnaderna.

Organisatorisk beredskap inför tekniska förändringar är avgörande för att realisera prestationseffekterna av AI-baserade beslutsstöd. Att det befintliga optimeringsverktyget i

företag 1 idag används i begränsad utsträckning indikerar att tekniska lösningar riskerar att förbli underutnyttjade om de inte upplevs som tillräckligt användbara. Detta kan bero på faktorer såsom bristande användarvänlighet, låg tillit till systemets rekommendationer eller att verktyget inte är anpassat till det dagliga arbetet. Detta visar att hög uppgift-teknologianpassning inte är tillräcklig i sig, utan att faktisk användning av teknologin är avgörande för att prestationseffekter ska uppstå. Även motstånd mot förändring bland användare kan utgöra ett hinder om nyttan med systemet inte tydligt kan påvisas. Vidare krävs en organisatorisk förmåga att bevara och integrera mänsklig kompetens, då ett alltför stort beroende av AI riskerar att minska den kritiska granskningen och därigenom påverka beslutsfattandets kvalitet över tid.

Sammanfattningsvis visar studien, utifrån Task-Technology Fit, att värdet av AI som beslutsstöd är beroende av graden av uppgift-teknologianpassning i respektive steg av planeringsprocessen. Där anpassningen är hög uppstår tydliga prestationseffekter, medan bristande anpassning begränsar nyttan av teknologin. Dessutom krävs det att organisationen är redo i form av ekonomiska medel, organisatoriska förutsättningar och teknisk kompetens. Eftersom denna studie genomförts som en kvalitativ fallstudie i begränsad omfattning hade framtida forskning kunnat undersöka ämnet vidare genom en storskalig kvantitativ studie. Det hade kunnat ge ett annat perspektiv på ämnet och bidra till en ökad förståelse. Dessutom skulle ytterligare studier som i större omfattning analyserar AI-teknologiers värde som beslutsstöd ge en bättre bild över hur införandet kan ske i praktiken. Den pågående tekniska omställningen i dagens företag, där AI-teknologier redan implementerats, tyder på att teknologin förväntas få en stor betydelse även inom järnvägssektorn, antingen till följd av konkurrenskraft, den tekniska utvecklingen i sig eller en kombination av dem båda.

4. Källförteckning

- Afiouni, R. (2019). Organizational learning in the rise of machine learning. *ICIS 2019 Proceedings*. https://aisel.aisnet.org/icis2019/business_models/business_models/2
- Al-Rahmi, W. M., Al-Adwan, A. S., Al-Maatouk, Q., Othman, M. S., Alsaud, A. R., Almogren, A. S., & Al-Rahmi, A. M. (2023). Integrating communication and task–technology fit theories: The adoption of digital media in learning. *Sustainability*, 15(10), 8144. <https://doi.org/10.3390/su15108144>
- Alsheibani, S., Cheung, Y., & Messom, C. (2018). Artificial intelligence adoption: AI-readiness at firm level. *PACIS 2018 Proceedings*. <https://aisel.aisnet.org/pacis2018/37>
- Asmar, M., & Al-Rob, I. A. A. (2024). Application of artificial intelligence in business decision making: Insight from literature review. In A. Hamdan (Ed.), *Achieving sustainable business through AI, technology education and computer science* (Vol. 163, pp. 125–135). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-73632-2_11
- Banverket. (2009). *Årsredovisning 2008*. <https://trafikverket.diva-portal.org/smash/get/diva2:1363244/FULLTEXT01.pdf>
- Blomkvist, P., & Hallin, A. (2015). *Method for engineering students: Degree projects using the 4-phase model*. Studentlitteratur.
- Brezulianu, A., Geman, O., & Popa, I. V. (2023). Artificial intelligence component of the ferodata AI engine to optimize the assignment of rail freight locomotive drivers. *Applied Sciences*, 13(20), 11516. <https://doi.org/10.3390/app132011516>
- Cane, S., & McCarthy, R. (2009). Analyzing the factors that affect information systems use: A task-technology fit meta-analysis. *Journal of Computer Information Systems*, 50(1), 108–123. <https://doi.org/10.1080/08874417.2009.11645368>
- Cardell, L. (2020). Bemanning av färder—Trafikverket som järnvägsföretag [Rutinbeskrivning]. Trafikverket. <https://trvdokument.trafikverket.se/Versioner.aspx?spid=290&dokumentId=TDOK%25>
- Chen, L., Li, Y., Huang, C., Xing, Y., Tian, D., Li, L., Hu, Z., Teng, S., Lv, C., Wang, J., Cao, D., Zheng, N., & Wang, F.-Y. (2023). Milestones in autonomous driving and intelligent vehicles—Part I: Control, computing system design, communication, HD map, testing, and human behaviors. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 53(9), 5831–5847. <https://doi.org/10.1109/TSMC.2023.3276218>
- Consilvio, A., Vignola, G., López Arévalo, P., Gallo, F., Borinato, M., & Crovetto, C. (2024). A data-driven prioritisation framework to mitigate maintenance impact on passengers during

metro line operation. *European Transport Research Review*, 16(1), 6.
<https://doi.org/10.1186/s12544-023-00631-z>

El Naqa, I., & Murphy, M. J. (2015). What is machine learning? In I. El Naqa, R. Li, & M. J. Murphy (Eds.), *Machine learning in radiation oncology* (pp. 3–11). Springer.
https://doi.org/10.1007/978-3-319-18305-3_1

Esaiasson, P., Giljam, M., Oscarsson, H., & Wängnerud, L. (2007). *Metodpraktikan: Konsten att studera samhälle, individ och marknad* (3:e uppl.). Norstedts Juridik.

Furneaux, B. (2012). Task-technology fit theory: A survey and synopsis of the literature. In Y. K. Dwivedi, M. R. Wade, & S. L. Schneberger (Eds.), *Information systems theory* (Vol. 28, pp. 87–106). Springer. https://doi.org/10.1007/978-1-4419-6108-2_5

Gestrelus, S., & Ranjbar, Z. (2023). *Sjävlärande neurala nätverk för operativ lokstyrning – SOL förstudie*. RISE Research Institutes of Sweden.

Ghahramani, Z. (2015). Probabilistic machine learning and artificial intelligence. *Nature*, 521(7553), 452–459. <https://doi.org/10.1038/nature14541>

Goodhue, D. L., & Thompson, R. L. (1995). Task-technology fit and individual performance. *MIS Quarterly*, 19(2), 213–236. <https://doi.org/10.2307/249689>

Gorbachev, R. A., Zakharova, E. M., Makarov, I. S., & Tsurkov, V. I. (2021). Intelligent system for step-by-step control during the operational rebuilding of the schedule. *Journal of Computer and Systems Sciences International*, 60(5), 802–807.
<https://doi.org/10.1134/S1064230721050105>

Gustafsson, K. (2024). *Trafikverkets forsknings- och innovationsplan för åren 2024–2029*. Trafikverket.

Huisman, D., Kroon, L. G., Lentink, R. M., & Vromans, M. J. C. M. (2005). Operations research in passenger railway transportation. *Statistica Neerlandica*, 59(4), 467–497. <https://doi.org/10.1111/j.1467-9574.2005.00303.x>

Indén, T. (2015). Den svenska järnvägen, liberaliseringen och marknadstillträdet. In *Juridiske emner ved Syddansk Universitet*. <https://portal.findresearcher.sdu.dk/en/publications/den-svenska-j%C3%A4rnv%C3%A4gen-liberaliseringen-och-marknadstilltr%C3%A4det/>

IVU Traffic Technologies AG. (u.å.). *IVU.rail*. Hämtad 30 mars 2026 från <https://www.ivu.com/solutions/highlights/ivurail>

Jeppesen ForeFlight Inc. (2026). *Achieving cross-functional integration among crew management solutions*. Hämtad 30 mars 2026 från <https://ww2.jeppesen.com/wp->

[content/uploads/2020/09/13798_Flight-Ops-Crew-Management-Solutions-Infographic_EXT_2026_2_EN-1.pdf](#)

Johannesson, T. (2024). Två år kantade av tågkaos – detta har hänt. Hämtad 25 januari 2026 från <https://www.sn.se/nyheter/sormland/artikel/tva-ar-kantade-av-tagkaos-detta-hant/r1xeq63j>

Jonsson, I., & Virtala, J. (2021). *Optimal uppdelning av tågtrafik: Ett arbete för att möjliggöra produktiv personalplanering baserat på villkorsprogrammering och klustring*. Umeå University.

Jonsson, P., & Matsson, S.-A. (2005). *Logistik—Läran om effektiva materialflöden*. Studentlitteratur.

Jørgensen, B. N., Gunasekaran, S. S., & Ma, Z. G. (2025). Impact of EU laws on AI adoption in smart grids: A review of regulatory barriers, technological challenges, and stakeholder benefits. *Energies*, 18(12), 3002. <https://doi.org/10.3390/en18123002>

Keding, C. (2021). Understanding the interplay of artificial intelligence and strategic management: Four decades of research in review. *Management Review Quarterly*, 71(1), 91-134. <https://doi.org/10.1007/s11301-020-00181-x>

Kilani, M. A., & Kobziev, V. (2016). An overview of research methodology in information systems. *OALib*, 3(11), 1–9. <https://doi.org/10.4236/oalib.1103126>

Lepenioti, K., Bousdekis, A., Apostolou, D., & Mentzas, G. (2021). Human-augmented prescriptive analytics with interactive multi-objective reinforcement learning. *IEEE Access*, 9, 100677–100693. <https://doi.org/10.1109/ACCESS.2021.3096662>

Li, Z., Wu, W., Guo, Y., Sun, J., & Han, Q.-L. (2025). Embodied multi-agent systems: A review. *IEEE/CAA Journal of Automatica Sinica*, 12(6), 1095–1116. <https://doi.org/10.1109/JAS.2025.125552>

Littman, M. L. (2015). Reinforcement learning improves behaviour from evaluative feedback. *Nature*, 521(7553), 445–451. <https://doi.org/10.1038/nature14540>

Makarius, E. E., Mukherjee, D., Fox, J. D., & Fox, A. K. (2020). Rising with the machines: A sociotechnical framework for bringing artificial intelligence into the organization. *Journal of Business Research*, 120, 262–273. <https://doi.org/10.1016/j.jbusres.2020.07.045>

Mejri, O., Ruland, C., Waedt, K., & El Elj, A. (2025). Enhancing AI predictive accuracy in sensitive infrastructure using knowledge representation. *2025 IEEE 9th Forum on Research and Technologies for Society and Industry (RTSI)*, 185–190. <https://doi.org/10.1109/RTSI64020.2025.11212271>

- Mihaljević, B., Bielza, C., & Larrañaga, P. (2021). Bayesian networks for interpretable machine learning and optimization. *Neurocomputing*, 456, 648–665. <https://doi.org/10.1016/j.neucom.2021.01.138>
- Mishra, A. N., & Pani, A. K. (2021). Business value appropriation roadmap for artificial intelligence. *VINE Journal of Information and Knowledge Management Systems*, 51(3), 353–368. <https://doi.org/10.1108/VJIKMS-07-2019-0107>
- Mohammed, A. S., Mallikarjunaradhya, V., Sreeramulu, M. D., Boddapati, N., Jiwani, N., & Natarajan, Y. (2024). Optimizing real-time task scheduling in cloud-based AI systems using genetic algorithms. *2024 7th International Conference on Contemporary Computing and Informatics (IC3I)*, 1649–1653. <https://doi.org/10.1109/IC3I61595.2024.10829055>
- Monostori, L. (2019). *CIRP encyclopedia of production engineering*. Springer. <https://doi.org/10.1007/978-3-662-53120-4>
- Nelldal, B.-L., Näsman, P., Song, H.-S., & Andersson, J. (2022). *Förseningarnas påverkan på efterfrågan av tågresor – en tidsserieanalys*. KTH Royal Institute of Technology.
- Nielsen, L. K. (2011). *Rolling stock rescheduling in passenger railways: Applications in short-term planning and in disruption management*. <https://repub.eur.nl/pub/22444>
- Ning, L., Li, Y., Zhou, M., Song, H., & Dong, H. (2019). A deep reinforcement learning approach to high-speed train timetable rescheduling under disturbances. *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, 3469–3474. <https://doi.org/10.1109/ITSC.2019.8917180>
- Nyström, U. (2022). Bättre planering inom SJ. Hämtad 15 februari 2026 från <https://jarnvagar.nu/battre-planering-inom-sj/>
- Pfriem, J., & Olausson, S. (2024). Efter tågkaoset: MTR lämnar Mälartågen – Transdev tar över. Hämtad 18 februari 2026 från <https://www.svt.se/nyheter/lokalt/sormland/malartags-trafik-tas-over-av-annat-bolag>
- Pious, I. K., Rajalakshmi, A., Kumar, P. R., Varun, C. M., Nalini, M., & Subramanian, S. R. (2024). Enhancing prediction accuracy through random forest in classification and regression. *Proceedings of the 2024 International Conference on Smart Technologies for Sustainable Development Goals (ICSTSDG)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICSTSDG61998.2024.11026358>
- Pumplun, L., Tauchert, C., & Heidt, M. (2019). A new organizational chassis for artificial intelligence—Exploring organizational readiness factors. *ECIS 2019 Research Papers*. https://aisel.aisnet.org/ecis2019_rp/106

- Qamar, R., & Zardari, B. A. (2023). Artificial neural networks: An overview. *Mesopotamian Journal of Computer Science*, 2023, 124–133. <https://doi.org/10.58496/MJCSC/2023/015>
- Schneider, S., Ramesh, A., Roets, A., Stirbu, C., Safaei, F., Ghriss, F., Wülfing, J., Göra, M., Sibon, N., Gentry, R., Liessner, R., Hustache, T., Lecat, T., Deekshith, U., Markin, V., Le, V., Bejjani, W., Kupper, M., & Sturm, I. (2024). Intelligent railway capacity and traffic management using multi-agent deep reinforcement learning. *2024 IEEE 27th International Conference on Intelligent Transportation Systems (ITSC)*, 1743–1748. <https://doi.org/10.1109/ITSC58415.2024.10919999>
- Seko SJ. (2024). *Spårasj kollektivavtal vid SJ AB*. <https://klubb106.se/blogg/wp-content/uploads/2024/06/SPARASJ-240604.pdf>
- Shobika, G. V., Siddharth, S. P., Vishwa, K., Hemachandran, K., & Rege, M. (2023). ANN model for analytics. In H. K, R. V. Rodriguez, U. Subramaniam, & V. E. Balas (Eds.), *Artificial intelligence and knowledge processing* (pp. 195–207). CRC Press. <https://doi.org/10.1201/9781003328414-17>
- SJ. (2025). *SJ års- och hållbarhetsredovisning 2024*. https://cdn.sj.se/files/hulddl9x/production/16fb6d360d7ee535b4ff52d83f9ea23925fb6826.pdf/SJ-ÅHR-2024-länkad_t.pdf
- Szepesvári, C. (2010). *Algorithms for reinforcement learning*. Springer. <https://doi.org/10.1007/978-3-031-01551-9>
- Trafikverket. (2024). *Tågplan – att skapa tidtabeller för tåg*. Hämtad 28 mars 2026 från <https://bransch.trafikverket.se/for-dig-i-branschen/jarnvag/tagplan-att-skapa-tidtabeller-for-tag/>
- Trapeze. (u.å.). *Fixed route scheduling* [Solution guide]. Hämtad 5 april 2026 från <https://go.trapezegroup.com/rs/430-MBX-989/images/Trapeze-SolutionGuide-MPS-FixedRouteScheduling.pdf>
- Tångeberg, J. (2022). Mälartågs kundtjänst överbelastad efter tågstrulet – tvingas dubbla personalstyrkan. Hämtad 7 mars 2026 från <https://www.sn.se/nyheter/sormland/artikel/malartags-kundtjanst-overbelastad-efter-tagstrulet-tvingas-dubbla-personalstyrkan/jok5d2ql>
- Törnquist Krasemann, J. (2012). Design of an effective algorithm for fast response to the re-scheduling of railway traffic during disturbances. *Transportation Research Part C: Emerging Technologies*, 20(1), 62–78. <https://doi.org/10.1016/j.trc.2010.12.004>
- Wamba-Taguimdje, S.-L., Fosso Wamba, S., Kala Kamdjoug, J. R., & Tchatchouang Wanko, C. E. (2020). Influence of artificial intelligence (AI) on firm performance: The business value of

AI-based transformation projects. *Business Process Management Journal*, 26(7), 1893–1924. <https://doi.org/10.1108/BPMJ-10-2019-0411>

Wang, H., Huang, J., & Zhang, Z. (2019). The impact of deep learning on organizational agility. *ICIS 2019 Proceedings*.
https://aisel.aisnet.org/icis2019/governance_is/governance_is/26

Wang, L., Jin, J. G., Sun, L., & Lee, D.-H. (2024). Urban rail transit disruption management: Research progress and future directions. *Frontiers of Engineering Management*, 11(1), 79–91. <https://doi.org/10.1007/s42524-023-0291-z>

Wen, Y., He, X., Lv, D., & Li, F. (2023). Hybrid algorithm of gradient boosted decision tree and multiple linear regression and its application on decision prediction. *2023 IEEE 3rd International Conference on Electronic Communications, Internet of Things and Big Data (ICEIB)*, 253–256. <https://doi.org/10.1109/ICEIB57887.2023.10170440>

Wickenberg, S. (2024). Mälardalstrafik bryter kontraktet med MTR i förtid. Hämtad 10 april 2026 från <https://www.jarnvagsnyheter.se/20240222/15903/malardalstrafik-bryter-kontraktet-med-mtr-i-fortid>

Zehang, D., Yongjian, G., Changzhou, H., Wanlun, M., Junwu, X., Sheng, W., & Yang, X. (2025). AI agents under threat: A survey of key security challenges and future pathways. *ACM Computing Surveys*, 57(7), 1–36. <https://doi.org/10.1145/3716628>

Zigurs, I., Buckland, B. K., Connolly, J. R., & Wilson, E. V. (1999). A test of task-technology fit theory for group support systems. *ACM SIGMIS Database: The DATABASE for Advances in Information Systems*, 30(3–4), 34–50. <https://doi.org/10.1145/344241.344244>

Appendix

Appendix 1: Intervjuguide 1

Om intervjugruppen

- Beskriv kort din roll på företaget och hur länge du har arbetat här.
- Beskriv dina arbetsuppgifter.
- Vilka typer av beslut är du involverad i när det gäller personalplanering?

Dagens planeringsprocess

- Hur ser processen ut för att planera personal idag?
- Vilka verktyg, system eller metoder används idag?
- Hur mycket bygger planeringen på manuella bedömningar jämfört med systemstöd?
- Vilka faktorer är svårast att ta hänsyn till i planeringen (t.ex. förseningar, sjukfrånvaro, efterfrågevariationer eller annat)?

Utmaningar och problem

- Vilka är de största utmaningarna i dagens personalplanering?
 - När uppstår dessa?
 - Hur löser du dem?
- Finns det situationer där nuvarande beslutsstöd inte räcker till? Ge gärna exempel.
- Är övertid ett problem? På vilket sätt?

Relationen till AI

- Vad är din relation till AI? Är det något du ser positivt eller negativt på?
- Använder ni idag någon form av AI i planeringen och/eller som beslutsstöd?
 - Om ja, i vilka sammanhang och på vilket sätt?
 - Om nej, varför tror du att det inte används?
- Hur upplever du tilliten till automatiserade eller datadrivna beslut?

Potential

- Hur tror du att AI skulle kunna användas som beslutsstöd i kapacitetsplanering?
- Vilka beslut skulle du helst vilka ha stöd av AI i?
- Vilka fördelar ser du med AI-baserade beslutsstöd jämfört med dagens arbetssätt?

- Vilka nackdelar ser du med att använda AI i ditt arbete?

Implementering, organisation och framtid

- Hur tror du att medarbetare skulle reagera på ökad användning av AI i planeringen?
- Hur ser du på framtiden för personalplanering inom järnvägssektorn?
- Vad skulle du säga är det viktigaste för en eventuell implementering av AI inom personalplanering?

Appendix 2: Intervjuguide 2

Om intervjugruppen

- Beskriv kort din roll på företaget och hur länge du har arbetat här.
- Beskriv dina arbetsuppgifter.
- Vilka typer av projekt som berört implementering av AI har du varit involverad i?
 - Hur har tillvägagångssättet skiljt sig mellan dessa?

AI som beslutsstöd

- Var i beslutsprocessen skapar systemet mest värde?
- Hur fungerar era beslutsstödsystem i praktiken?
- Hur ofta används rekommendationerna som AI-teknologin ger?

Implementering

- Hur ser en typisk implementeringsprocess ut, från förstudie till driftsättning?
- Hur samlas information om verksamhetens behov och arbetssätt i början av ett projekt?
- Vilka verktyg och metoder används för att kartlägga krav, processer och beroenden?
- Hur avgörs vilken metod som är lämplig för att lösa ett problem?

Tekniska utmaningar

- Vilka är de vanligaste tekniska utmaningarna vid implementering av tekniska system, så som AI?
- I vilka faser uppstår de tekniska problemen oftast?
- Vad krävs tekniskt för att en implementering ska bli hållbar på lång sikt?

Organisatoriska utmaningar

- Vilka är de största mänskliga eller organisatoriska utmaningarna du möter?
- Hur brukar medarbetare reagera på nya system?
- Vilken roll spelar förändringsledning i dina projekt?
- Vad skiljer projekt som lyckas från de som får problem, ur ett organisatoriskt perspektiv?

Appendix 3: AI-deklaration

Samtliga gruppmedlemmar i TEKX18-VT26-16A intygar att inga AI-verktyg använts för att generera färdig text till rapporten. Däremot har AI använts i begränsad omfattning som stöd i processen. Det har handlat om hjälp med att föreslå synonymer eller korta formuleringar, kontrollera språk samt bidra till ökad förståelse av vissa källor. All slutgiltig text har formulerats och granskats av gruppens medlemmar.

INSTITUTIONEN FÖR TEKNIKENS EKONOMI OCH ORGANISATION
AVDELNINGEN FÖR TEKNIK, VETENSKAP OCH SAMHÄLLE
CHALMERS TEKNISKA HÖGSKOLA

Göteborg, Sverige 2026
www.chalmers.se



CHALMERS